

R&D / 18CTAP-C129782-02

시설물 유지관리를 위한 Deep Convolutional Neural Network(DCNN) 기반 사진판독형 콘크리트 성능평가 시스템 개발

최종보고서

2019. 01. 18.

주관연구기관 / 한양대학교 에리카산학협력단
공동연구기관 / 아주대학교 산학협력단

국 토 교 통 부
국토교통과학기술진흥원

제 출 문

국토교통과학기술진흥원 귀하

‘시설물 유지관리를 위한 Deep Convolutional Neural Network(DCNN) 기반 사진판독형 콘크리트’
(연구개발 기간 : 2017. 04. 01. ~ 2018. 12. 31.) 과제의 최종보고서 10부를 제출합니다.

2018. 01. 18.

주관연구기관명 : 한양대학교 에리카산학협력단 (대표자) 좌 용 호 (인)

공동연구기관명 : 아주대학교 산학협력단 (대표자) 최 경 희 (인)

주관연구기관책임자: 안 용 한

공동연구기관책임자: 김 하 영

국토교통부소관 연구개발사업 운영규정 제29조에 따라 최종보고서 열람에
동의합니다.

보고서 요약서

과제 고유 번호	18CTAP-C129 782-02	해당 단계 연구 기간	2017.04.01. - 2018.12.31	단계구분	2 / 2 (해당단계) / (총단계)
연구사업명	중사업명 세부사업명	국토교통기술촉진연구사업 기초원천			
연구과제명	대과제명 세부과제명	대과제가 있을 경우 기재합니다(단위과제일 경우에는 아래에 기재합니다) 시설물 유지관리를 위한 Deep Convolutional Neural Network(DCNN) 기반 사진판독형 콘크리트 성능평가 시스템 개발			
연구책임자	안용한	해당단계 참여연구원 수	총: 18 명 내부: 18 명 외부: 명	해당단계 연구비	정부: 150,000천원 민간: 천원 정부외: 천원 상대국: 천원 계: 천원
		총 연구기간 참여연구원 수	총: 18 명 내부: 18 명 외부: 명	총 연구비	정부: 220,000 천원 민간: 천원 정부외: 천원 상대국: 천원 계: 천원
연구기관명 및 소속 부서명	한양대학교 에리카산학협력단 아주대학교 산학협력단			참여기업명	
국제공동연구	상대국명:			상대국 연구기관명:	
위탁연구	연구기관명:			연구책임자:	

※ 국내·외의 기술개발 현황은 연구개발계획서에 기재한 내용으로 같음

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

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 ○ 연구목표 콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 시스템 개발 ○ 연구내용 1. DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축 2. DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발 ○ 연구개발성과 1. 콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축 2. 콘크리트 구조물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발 3. DCNN 기반 콘크리트 시설물 특성별 성능평가 알고리즘 설계 4. DCNN 기반 콘크리트 시설물 성능평가 융합 알고리즘 구현 ○ 활용계획 건설 분야에 딥러닝(Deep Learning) 기법을 접목함으로써 융복합 원천기술의 기반을 마련하고 다가오는 4차 산업혁명에 선제적으로 대응할 수 있는 중장기적 유지관리 전략을 수립하는데 활용	보고서 면수 : 119
---	--------------------------------

〈 국문요약문 〉

연구개발 목표	본 연구는 콘크리트 시설물의 유지관리를 위한 Big Data를 구축하고 데이터가 축적됨에 따라 정보조합과 자가학습을 통해 단시간에 최적결론이 도출 가능한 딥러닝(Deep Learning) 기술의 Deep Convolutional Neural Network(DCNN) 알고리즘을 포함하는 콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 시스템 개발을 최종 목표로 함.				
연구개발 내용	본 연구는 “DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축”, “DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발”로 구분되며 연구목표에 대한 주요 연구내용은 다음과 같다. ■ DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축 - 주요 연구개발 내용 콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축 - 콘크리트 시설물 유지관리를 위한 콘크리트 성능 영향 요인 - DCNN 기반 사진판독형 콘크리트 시편 표준 자료 DB 구축 DCNN 기반 콘크리트 시설물 성능평가 알고리즘 설계 - DCNN 기반 콘크리트 시설물 성능평가 분류 방법론 개발 - DCNN 기반 콘크리트 시설물 성능평가 분류 알고리즘 설계 ■ DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발 - 주요 연구개발 내용 콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발 - DCNN 기반 알고리즘 피드백을 통한 실험 데이터간 유효상관관계 분석 - 콘크리트 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 DCNN 기반 콘크리트 시설물 성능평가 알고리즘 구현 - 성능지표의 최적 접근을 위한 DCNN 모델의 알고리즘 최적화 - DCNN 기반 콘크리트 시설물 성능평가 알고리즘 구현				
연구개발성과	본 연구는 기초원천 기술 개발 연구로서 연구개발 성과물은 다음과 같음. - 콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축 - 콘크리트 구조물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발 - DCNN 기반 콘크리트 시설물 특성별 성능평가 알고리즘 설계 - DCNN 기반 콘크리트 시설물 성능평가 융합 알고리즘 구현				
활용계획 및 기대효과	■ 활용방안 본 연구결과는 국가적 차원의 시설물 안전 진단 및 유지관리 예산을 절감하고 건설 분야에 딥러닝(Deep Learning) 기법을 접목함으로써 융·복합 원천기술의 기반을 마련하고 다가오는 4차 산업혁명에 선제적으로 대응할 수 있는 중장기적 유지관리 전략을 수립하는데 활용될 수 있다. ■ 기대성과 시설물 유지관리 기술과 ICT기술의 융복합을 통해 콘크리트 성능평가 시스템을 개발하여 국제적 수준 이상의 기술력을 확보하고 국가적으로 시설물 유지관리 비용절감과 유지관리 시장의 경제적 파급효과 견인이 기대됨.				
핵심어(5개 이내)	유지관리	성능평가	딥러닝	알고리즘	시스템

< Summary >

Purpose	The purpose of this study is to develop a performance evaluation algorithm based on Deep Convolutional Neural Network (DCNN), which is a technique to build up Big Data for maintenance of concrete facilities and to derive optimal conclusions in a short time through self – The final goal is to develop a DCNN-based image-reading concrete performance evaluation system for the maintenance of concrete facilities.				
Contents	This research is classified into “Performance Evaluation Algorithm of DCNN-based Concrete Facility and Big Data Construction”, “Development of a performance evaluation system for DCNN-based image-reading concrete facilities” and main research contents are as follows ■ Performance Evaluation Algorithm of DCNN-based Concrete Facility and Big Data Construction ■ Main research Construction of Big Data for Concrete Performance Evaluation for Concrete Facility Maintenance ① Concrete Performance Factors for Concrete Facility Maintenance ② DCNN based photo-reading concrete specimen standard data DB ■ Performance evaluation algorithm of DCNN-based concrete facilities ① DCNN-based Concrete Facility Performance Evaluation Classification Methodology ② Design of Performance Evaluation Classification Algorithm for Concrete Facilities Based on DCNN ■ Development of a performance evaluation system for DCNN-based image-reading concrete facilities ■ Main research Development of DCNN-based photo-reading concrete performance evaluation program considering maintenance of concrete facilities ① Algorithm optimization of DCNN model for optimal approach of performance index ② DCNN-Based image-Reading Concrete Performance Evaluation Program for Concrete Maintenance ■ Implementation of DCNN-based concrete facility performance evaluation algorithm ① Performance evaluation of DCNN-based concrete facility classification integrated algorithm design ② Implementation of DCNN-based concrete facility performance evaluation algorithm				
Development results	Purpose of this research is Development of Basic original technology and final result is as follows: [1] Construction of Big Data [2] Development of DCNN-Based Photo-Reading Concrete Performance Evaluation Program [Main result] [3] Algorithm Design of Performance Evaluation for DCNN Based Concrete Facility Characteristics [4] Implementation of Convergence Algorithm for Performance Evaluation of Concrete Facility Based on DCNN				
Expected Contribution	■ Application plan The result of this study is to establish a foundation of fusion and combined source technology and to preemptively respond to the upcoming fourth industrial revolution by reducing the budget for facility safety diagnosis and maintenance of the national level and applying deep learning technique to the construction field. This can be used to establish mid- to long-term maintenance strategies. ■ Expected outcome Level concrete performance evaluation system through the fusion of facilities maintenance technology and ICT technology, it is expected to secure technological power of more than international level, reduce the maintenance cost of facilities nationwide and lead to economic ripple effect in maintenance market.				
Keywords	Maintenance Management	Performance Evaluation	Deep Learning	Algorithm	System

< Contents >

1. Summary of Research Project	09
2. Domestic and International R&D Trends	14
3. Research Contents and Result	16
4. Goal Achievement and Contributions on Related fields	94
5. Plan to utilize of R&D achievements	99
6. International Scientific and Technical Information	101
7. Security Level of R&D achievements	103
8. Registered Research Facilities and Equipment Status on NTIS	105
9. Safeguards Implementation	107
10. Representative research achievements	109
11. etc consideration	111
12. Reference	113

< 목 차 >

1. 연구개발과제의 개요	09
2. 국내외 기술 개발 현황	14
3. 연구수행내용 및 성과	16
4. 목표 달성도 및 관련 분야 기여도	94
5. 연구개발성과의 활용 계획	99
6. 연구 과정에서 수집한 해외 과학기술 정보	101
7. 연구개발성과의 보안등급	103
8. 국가과학기술종합정보시스템에 등록한 연구시설·장비 현황	105
9. 연구개발과제 수행에 따른 연구실 등의 안전 조치 이행 실적	107
10. 연구개발과제의 대표적 연구 실적	109
11. 기타 사항	111
12. 참고 문헌	113

제1장. 연구개발과제의 개요

1. 연구개발의 개요

가. 최종 목표

- 본 연구과제에서 개발되는 “DCNN(Deep Convolution Neural Network)기반 사진판독형 콘크리트 성능평가 시스템”은 Big Data를 활용한 딥러닝(Deep Learning) 알고리즘을 통하여 기존의 콘크리트 시설물 진단/평가방법을 혁신적으로 단순화함으로써 기하급수적으로 늘어나고 있는 **시설물 유지관리 비용**에 대한 근본적인 문제점을 해결하는 **기초 원천기술**임.
- 본 연구과제는 세계 최초 콘크리트 시설물 유지관리 분야에 딥러닝 기반 모델(DCNN)을 접목하는 창의·도전적인 연구이며 정부가 국토교통 중장기 전략으로 추진 중인 10대 중점 프로젝트(Value Creator 2.0)중 지능형 인프라 자동관리부문의 목표를 달성하기 위해 시급히 요구되는 필수불가결한 기술로서 시의성이 매우 높고 향후 2년 뒤 콘크리트 시설물을 혁신적인 프로세스를 통하여 평가하는 원천기술 확보가 가능한 연구임.




그림 1.1 연구개발의 개요

나. 본 연구개발 기술의 핵심 개념

- 본 연구과제에서 제안하는 “시설물 유지관리를 위한 DCNN기반 사진판독형 콘크리트 성능평가 시스템”은 기존의 콘크리트 시설물 유지관리를 위한 정밀 안전진단 및 점검 평가 방법에 있어 고가의 진단 장비 및 용역 비용 등의 한계점으로 인하여 부실점검 및 저가용역이 발생하는 현상을 해소하기 위하여 콘크리트 성능평가 분야에 **딥러닝(Deep Learning) 기술을 접목시킨 신개념 융합 원천 기술임**.
- 특히, 본 연구의 핵심 기술인 DCNN기반 콘크리트 시설물 성능평가 알고리즘은 콘크리트 성능평가의 Big Data를 이용하여 성능 영향요인과 관련된 유용한 상관관계를 분석하고, Data Mining 및 보완 과정을 거쳐 의사결정하는 사진판독형 고차원 프로세스임. DCNN기반 콘크리트 시설물 알고리즘을 통해 공극, 강도, 염화물 확산계수, 건전도 등의 특성별 데이터를 입출력 하여 성능평가에 사용될 수 있는 고차원적 특성을 추출할 수 있으며, 본 핵심 기술은 시간, 비용 관점에서 효율성을 극대화하고 정확도를 높이는 콘크리트 성능평가 도구가 될 것으로 사료됨.




그림 1.2 연구개발 기술의 핵심개념

2. 연구개발의 필요성

국가 시설물 유지관리 기본 전략 및 정책과의 부합성	본 연구과제는 국토교통 R&D 중장기전략으로 추진 중인 10대 중점 프로젝트(Value Creator 2.0)중 지능화 인프라 자동관리부문에 부합되며, 향후 정부/지자체의 SOC 시설물의 관리 효율화를 위한 진단 자동화·무인화 개발 사업등의 4차 산업 촉진에 있어 전략적 핵심원천기술임.
기초연구 및 원천기술 개발의 시의성	“국토교통기술촉진연구사업” 내 기초원천기술구축 과제로 ICT기반 유지관리기술과 자동화·효율화기술 개발의 목표를 실천하기 위해 시급히 요구되는 필수불가결한 기술로서 시의성이 매우 높으며 1단계 완료 시점인 2018년에 기술개발 완료가능함.
기초연구 및 원천기술 개발의 중요성	국토교통기술 연구개발추진과 실현을 위한 지식기반의 실용적 원천기술로서 유지관리가 필요한 시설물을 새로운 기술을 통하여 평가하는 원천기술 확보가 가능한 연구임.

○ 미래핵심원천기술로서 국가 시설물 유지관리 기본 전략 및 정책과의 부합성

- 본 연구과제는 제 3차 시설물 안전 및 유지관리 기본계획의 ICT기반의 첨단 진단기술 확보와 정책에 부합하는 유지관리기술 개발연구로써, 지식집약적 4차산업으로의 진출에 필수불가분의 과제임.
- 본 연구과제는 국토교통 R&D 중장기 전략으로 추진 중인 10대 중점 프로젝트(Value Creator 2.0)중 지능형 인프라 자동관리부문에 부합되며, 향후 정부/지자체의 사회기반시설물의 관리 효율화를 위한 진단 자동화·무인화 개발 사업에 있어 시설물의 경제성/안전성/효율성을 고려한 유지관리평가기술로서 활용 및 파급 효과가 매우 우수함.

○ 기초연구 및 원천기술 개발의 시의성

- 본 연구과제는 국토교통부의 “국토교통기술촉진연구사업”에 따라 추진 중인 기초원천기술구축에 부합되는 기초 연구과제로서 ICT 기술융합을 통한 사전적 유지관리 시스템개발이라는 사업추진방향과 일치하며, 국가차원의 SOC유지관리 비용절감은 물론, 효율적 관리시스템개발을 위해 시급히 처리되어야 할 과제임.
- 본 연구과제를 통해 개발되는 원천기술은 정부가 추진 중인 SOC 시설물 성능평가 기술개발 및 Big Data의 정보 분석 시스템 개발을 통한 신뢰성 높은 진단평가체계 확보의 목표를 실천하기 위해 시급히 요구되는 필수불가결한 기술로서 시의성이 매우 높음.

○ 기초연구 및 원천기술 개발의 중요성

- 본 연구과제는 국내 국토교통분야와 ICT의 기술융합과 성장을 촉진하고 국제적 기술 변화에 효과적으로 대응할 수 있는 지능형 사회기반시설 진단 및 유지관리시스템에 관한 원천기술임.
- 또한, 국내 건축 환경 및 국제 연구 트렌드에 부합하는 ICT기반 시설물의 지능형 시설물 상태평가기술의 확보와 더불어 기존 기술 수준의 차원을 넘어 국제 시장 선점과 기술적 우위를 확보할 수 있는 중요한 원천기술임.



그림 1.3 연구개발의 중요성

3. 연구개발 범위

- 본 연구과제에서 목표로 하는 “DCNN기반 콘크리트 시설물 성능평가 시스템”의 1차년도 기술개발 성숙도는 콘크리트 시설물의 유지관리 및 성능평가 분야에 딥러닝(Deep Learning), 빅데이터 등을 접목시키기 위한 기술적 개념 및 아이디어 정립, 데이터베이스 구축 단계로서 기초연구 단계인 TRL 2단계에 해당되며, 검증용 데이터를 통하여 알고리즘의 1차 성능을 증명하여 실험적 증명단계인 TRL 3단계 수준까지 완료함.
- 2차년도에는 1차년도에 기 제작한 콘크리트 시편을 대상으로 DCNN기반 콘크리트 시설물 성능평가 알고리즘의 성능을 검증할 계획이며, 지속적인 보완을 통해 DCNN기반 사진판독형 콘크리트 시설물 성능평가 시스템 개발 기술의 개념을 구현하고, 피드백을 통한 실험실 환경에서의 지속적 성능 검증으로 기술개발 성숙도를 응용연구 단계인 TRL 4단계 수준까지 완료함.
- 본 연구과제의 1차년도에는 DCNN기반 콘크리트 시설물 성능평가 알고리즘 개발을 위한 콘크리트 시설물 성능평가의 Big Data를 구축하며, Big Data를 바탕으로 본 연구과제의 핵심기술인 DCNN기반 콘크리트 성능평가 알고리즘을 설계 완료할 계획임. 또한 표준 데이터를 통하여 알고리즘의 1차 성능을 검증하여 TRL 2단계에서 TRL 3단계 수준까지 향상함.
- 2차년도에는 Big Data 및 알고리즘에 대한 지속적인 보완을 통해 알고리즘을 구현하며, DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램을 개발할 계획임. 또한 1차년도에 기 제작한 콘크리트 시편을 대상으로 DCNN기반 콘크리트 시설물 성능평가 알고리즘의 성능을 검증하여 TRL 4단계 수준(실험실 성능평가 단계)까지 완료함.

연구기간	1차년도 연구과제 (2017.04 ~ 2017.12)	2차년도 연구과제 (2018.01 ~ 2018.12)
기술개발 성숙도	TRL 3단계 (2017년 12월 기준)	TRL 4단계 (2018년 12월 기준)
기술수준	기술 개념 구현 및 기본적인 성능 검증 단계	연구실 환경에서의 성능평가 및 신뢰성 시험과 검증 단계
기술수준 향상전략	본 기술의 개념 구현을 위한 Big Data 기반의 DB 구축과 DCNN 기반 알고리즘 개발을 유기적으로 병행하여 전체적인 체계를 구축하고 표준 데이터를 활용하여 성능을 검증.	Big Data 기반의 DB를 지속적으로 검증·보완하고 발전시켜 DCNN 기반 콘크리트 시설물 성능평가 프로그램의 신뢰성을 검증하고 최적화.

구분		연구 착수	연구 종료	단계별 설명
기초연구 단계	TRL 1	☐	☐	TRL 1 이론적 연구단계
	TRL 2	■	☐	TRL 2 기술적 개념정립 단계
실험 단계	TRL 3	☐	☐	TRL 3 실험적 증명 단계
	TRL 4	☐	■	TRL 4 실험실 성능평가 단계
시작품 단계	TRL 5	☐	☐	TRL 5 유사환경 시험 단계
	TRL 6	☐	☐	TRL 6 유사환경 기술시험 단계
실용화 단계	TRL 7	☐	☐	TRL 7 실제환경 시작품 데모 단계
	TRL 8	☐	☐	TRL 8 시제품 설치 및 성능시험 단계
사업화 단계	TRL 9	☐	☐	TRL 9 현장적용/사업화 단계

시설물 유지관리를 위한 Deep Convolutional Neural Network (DCNN) 기반 사진 판독형 콘크리트 성능 평가 시스템






그림 1.4 본 연구개발의 전체 구성도

제2장. 국내외 기술 개발 현황

1. 국내 기술 개발 현황

- 국내의 30년 이상 노후 시설물 비중이 2023년 21.6%로 급증할 것으로 예상되며, 시설물 유지관리 시장의 규모는 지속적으로 증가('01년 1.0조→'10년 2.8조)하고 있으나 국내의 과학적 유지관리 기술은 최고기술 보유국(미국) 대비 76.2%(기술격차 4.3년)에 불과함.
- 국내에는 시설물 유지관리를 위한 사전체계가 일부 개발되었으나 비용, 고성능 장비 등의 한계로 인해 실무에서 활발히 시행되고 있지 못하고 있는 실정이며, 시설물 진단 및 성능평가에 있어 콘크리트의 열화정도를 판단할 수 있는 정량적 평가 시스템의 간편화, 보편화 개발이 필요한 실정임.
- 현재 국내에서는 국토교통 R&D 중장기 10대 전략 중 하나로 지능화 인프라 자동 관리분야가 각광받고 있으며 정부는 향후 SOC 시설물의 관리 효율화를 위한 진단 자동화·무인화 개발, ICT기반 유지관리 기술과 효율화기술을 목표로 하고 있음.
- 국외 선진국에서는 목표내구연한을 맞추기 위한 내구성확보 지침을 발행하고 있으며, 국내의 경우 시설물 유지관리를 위한 진단, 점검 과정에서 인건비, 장비비 등의 비용 발생이 매우 크므로 이를 효율적으로 관리하기 위해 IT 기술을 접목한 지능형 시설물 성능평가 기술에 대한 필요성이 증대되고 있음.


○ 국내 현황

■ 폭발적으로 늘어날 우리나라 노후 구조물 유지관리비 향상 대책 절실	■ 시설물의 안전관리에 관한 특별법 대상 시설물 중 30년 이상 시설물 비중은 2013년 9.5%에서 2023년 21.6%로 급증 예상. 또한, 2012년말 기준 15년 이상 된 아파트는 전국 약 400만호로 노후 공동주택의 재고가 폭발적으로 증가가 예상되므로 유지관리비, 시설물 성능평가 비용 또한 증가될 것임.	 출처: 2014, 한국시설안전공단 30년 이상 노후 시설물 증가추이
■ 시설물 유지관리 체계 관리부실사항 등 다수 지적사항 존재	■ 국민안전처에서 실시한 시설물 유지관리 실태의 개선 필요사항 중 시설 구조물 관리 분야가 1/3 이상을 차지함에 따라 현 내진성능평가 및 정밀 점검 등 시설 구조물 점검부실사례 만연함. ■ 일부 터널 구조물에서, 정밀안전진단 용역 정부 대가 기준인 1억 3천 200만에 한참 못미치는 800만원 짜리 '저가용역'을 하는 등, 정밀안전진단이 필요함에도 불구하고 비용부담이 커 제대로 행해지고 있지 않은 실정임.	 [터널 유지관리]
■ 구조물 내구수명 진단 및 평가 효율화·보편화를 위한 기술개발 필요	■ 건설 구조물 내구성 평가·설계는 열화인자의 침투 및 강재부식 메커니즘 규명에서 출발하여야 함. ■ 열화 정도에 따른 콘크리트의 재료성능과 구조성능의 열화정도를 통합적으로 정량 평가하는 시스템 구축이 매우 중요하나, 이에 관한 연구는 거의 전무한 실정임.	 조장기 환경하중에 의한 구조물 경시 변화 [재료·구조 내구성 동향]
■ 현 유지관리에 관한 국내 문헌 분석	■ 한국시설안전공단에서는 정기점검, 정밀점검, 정밀안전진단의 내용을 포함하고 있으며 점검항목에는 하부구조, 상부구조, 바닥판 등을 고려하고 있음. ■ 유지관리를 위한 점검기준을 따르기 위해서는 많은 장비와 시간, 비용을 필요로 함.	 [구조물 안전진단·점검]

2. 국외 기술 개발 현황

■ 구조물 유지관리에 ICT와 무선센서 네트워크 기술 확대

- 구조물의 내구성을 평가하기 위해서 대량의 Sensor로부터 발생하는 Data를 효율적으로 취득하기 위한 무선 모니터링 기술과 함께, 대량으로 발생하는 Big Data를 종합평가하기 위한 Analysis 기술과 함께 Data Mining 기술을 접목.
- 노후된 구조물의 사용성과 안전성의 확보 및 성능 개선을 위해 구조물의 자산가치 평가개념인 Asset Management를 도입하여 효율적인 유지관리를 추진하고 있음.
- 관리주체의 의사결정지원 체계를 마련하고 유지관리 취약요소를 설계·시공 단계에 피드백하는 선순환적 유지관리 강조.



[센서 모니터링에 의한 유지관리 기술]

■ 국외의 유지관리 시스템 현황


- 미국 도심 지하철에서는 550명의 인원이 주 2회 직접 관찰, 연 4회 자동화 점검 실시 하며 정밀검사 필요시 용역회사에 발주 하는 등 인적 노력과 비용이 많이 발생함.
- 캐나다 도심의 지하철은 매일 23명의 검사원이 손망치로 두드리며 육안으로 부식검사하며 보수는 자체보수와 외부계약보수를 병행하여 진행하고 있음.
- 이러한 구조물 보수로 최근 5년간 유지보수 비용이 약 6억달러가 발생함.



[국외의 유지관리 점검 현황]

■ 국외의 구조물 내구성 설계에 관한 현황


- 해외에서는 선진국을 중심으로 건축사업 설계단계에서 목표내구연한동안 콘크리트 시설물의 내구성 확보를 위한 지침을 제시하고 있음.
- 일본토목학회의 내구설계지침에서는 설계, 시공, 유지관리에 이르는 내구적 저항성을 내구지수로, 열화로 인한 열화지표를 환경지수로 확대하여 내구지수와 환경지수의 정량적인 비교를 기본으로 함.
- 주된 열화대상인자로서는 염해, 중성화 또는 염해 및 중성화의 복합작용을 예로 들고 있으며 기본 및 표준사양을 검토하여 설계조건을 설정한 후 이에 따른 설계내구연한을 도출하며 구조물의 성능저하 과정을 제안함.



[열화대상인자 관련 연구]

■ 해외 전세계적 국가의 정책 지원과 대기업 및 스타트업 기업들이 Deep Learning 기술개발 선도중

- 구글의 '알파고'는 합성곱 신경망이라는 Deep Learning 알고리즘과 몬테카를로 트리탐색 알고리즘을 사용하여 3천만건의 많은 데이터를 스스로 학습할수 있음.
- IBM의 '왓슨'은 차량 외부의 30개 센서로 데이터를 수집하여 AI가 자율주행 가능함.
- 4차 산업혁명의 핵심인 인공지능 시장은 2015년 약 1,270억 달러에 이어 2017년 1,650억 달러로 규모가 커질 것으로 예상됨



[알파고의 Deep Learning 알고리즘]

제3장. 연구수행내용 및 성과

1. 연구개발 목표

구분	내용	
최종 목표	본 연구는 콘크리트 시설물의 유지관리를 위한 Big Data를 구축하고 데이터가 축적됨에 따라 정보조합과 자가학습을 통해 단시간에 최적결론이 도출 가능한 딥러닝(Deep Learning) 기술의 Deep Convolutional Neural Network(DCNN) 알고리즘을 포함하는 콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 시스템 개발을 최종 목표로 함.	
세부 목표	1세부 (한양대)	DCNN기반 사진판독형 콘크리트 시설물의 성능평가 프로그램 개발
	2세부 (아주대)	콘크리트 시설물 성능평가를 위한 DCNN 기반 알고리즘 개발
연구개발 범위	콘크리트 시설물	본 연구개발 과제는 딥러닝 기술과 연계한 시설물 유지관리의 기초원천 기술 개발 연구로서 실험실 환경에서의 콘크리트 시편을 대상으로 DCNN 기반의 사진판독형 성능평가 기술을 개발함으로써 향후 기존 콘크리트 시설물에 효율적인 유지관리 시스템을 적용할 수 있도록 융·복합 기초원천 기술을 개발함.
주요 연구 내용	한양대	1 차년도 콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축 ① 콘크리트 시설물 유지관리를 위한 콘크리트 성능 영향 요인 정의 ② 콘크리트 성능 Big Data 구축을 위한 시편 제작 및 성능 실험 ③ DCNN기반 사진판독을 위한 콘크리트 시편 대표 자료 DB구축 ④ 콘크리트 시설물 성능평가 시스템 검증용 시편 제조
		2 차년도 콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발 ① DCNN기반 알고리즘 피드백을 통한 Big Data Mining ② 콘크리트 시설물 성능평가 알고리즘 Big Data 검증 및 보완 ③ 콘크리트 시설물 유지관리 활용을 위한 최적 사진판독 프로세스 개발 ④ 외부 실험 자료를 이용한 사진판독형 콘크리트 성능평가 프로그램 검증
	아주대	1 차년도 DCNN 기반 콘크리트 시설물 성능평가 알고리즘 설계 ① 콘크리트 시설물 성능평가 모델 설계를 위한 데이터 패턴 분석 ② 성능평가 구현을 위한 DCNN 모델의 입출력 정의 및 실험 ③ 실험자료 및 목표값 Matching을 위한 DCNN 모델의 데이터 전처리 및 증폭 Simulation ④ 성능 목표값 tracking을 위한 DCNN 모델의 신경망 알고리즘 설계
		2 차년도 DCNN 기반 콘크리트 시설물 성능평가 알고리즘 구현 ① 적용성 평가를 위한 DCNN 모델의 입출력 최적화 ② 성능지표(강도, 확산계수, 공극률)의 최적 접근을 위한 DCNN 모델의 데이터 전처리 및 증폭 최적화 ③ Layer Structure의 안정화를 위한 DCNN 모델의 신경망 최적화 ④ 콘크리트 표면 사진과 성능 데이터간 상관성 고도화 및 알고리즘 최적화
최종성과물	[1] 콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축	
	[2] 콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램	
	[3] DCNN 기반 콘크리트 시설물 성능평가 알고리즘 설계	
	[4] DCNN 기반 콘크리트 시설물 성능평가 알고리즘 구현	

DCNN : Deep Convolutional Neural Network

2. 연차별 연구개발 목표 및 내용

■ 본 연구과제는 최종 목표인 “콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 시스템 개발”을 달성하기 위해 다음 표와 같이 연차별 연구개발 목표를 “1차년도 : DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축”, “2차년도 : DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발”로 수립하고 최종성과물인 “[1] 콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축”, “[2] 콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발”, “[3] DCNN 기반 콘크리트 시설물 성능평가 알고리즘 설계”, “[4] DCNN 기반 콘크리트 시설물 성능평가 알고리즘 구현”에 따라 주요 연구내용을 구성함.

구 분	1차년도	2차년도
연구목표	DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축	DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발
	TRL 2단계 → TRL 3단계	TRL 3단계 → TRL 4단계
[1세부] 연구목표	콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축	콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발
1세부 (한양대)	① 콘크리트 시설물 유지관리를 위한 콘크리트 성능 영향 요인 정의 ② 콘크리트 성능 Big Data 구축을 위한 시편 제작 및 성능 실험 ③ DCNN기반 사진판독을 위한 콘크리트 시편 대표 자료 DB구축 ④ 콘크리트 시설물 성능평가 시스템 검증용 시편 제조	① DCNN기반 알고리즘 피드백을 통한 Big Data Mining ② 콘크리트 시설물 성능평가 알고리즘 Big Data 검증 및 보완 ③ 콘크리트 시설물 유지관리 활용을 위한 최적 사진판독 프로세스 개발 ④ 외부 실험 자료를 이용한 사진판독형 콘크리트 성능평가 프로그램 검증
[DCNN기반 사진판독형 콘크리트 구조물의 성능평가 프로그램 개발]		
[2세부] 연구목표	DCNN 기반 콘크리트 시설물 성능평가 알고리즘 설계	DCNN 기반 콘크리트 시설물 성능평가 알고리즘 구현
2세부 (아주대)	① 콘크리트 시설물 성능평가 모델 설계를 위한 데이터 패턴 분석 ② 성능평가 구현을 위한 DCNN 모델의 입출력 정의 및 실험 ③ 실험자료 및 목표값 Matching을 위한 DCNN 모델의 데이터 전처리 및 증폭 Simulation ④ 성능 목표값 tracking을 위한 DCNN 모델의 신경망 알고리즘 설계	① 적용성 평가를 위한 DCNN 모델의 입출력 최적화 ② 성능지표(강도, 확산계수, 공극률)의 최적 접근을 위한 DCNN 모델의 데이터 전처리 및 증폭 최적화 ③ Layer Structure의 안정화를 위한 DCNN 모델의 신경망 최적화 ④ 콘크리트 표면 사진과 성능 데이터간 상관성 고도화 및 알고리즘 최적화
[콘크리트 시설물 성능평가를 위한 DCNN 기반 알고리즘 개발]		




그림 3.1 연차별 연구개발 목표 및 내용

가. 1차년도

■ 본 연구과제의 1차년도 개발 목표는 본 연구과제의 최종 목표인 “콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 시스템 개발”을 위한 “DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축” 연구이며, 연구과제 수행을 통해 기술개발 성숙도를 TRL 2단계에서 3단계 수준까지 향상시킬 예정이다.

(1) 개발 목표

연구과제 수행기관	한양대학교 에리카산학협력단	주관연구기관
1차년도 연구목표	DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축	
1세부 연구목표	콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축	

(2) 개발 내용 및 범위

①	콘크리트 시설물 유지관리를 위한 콘크리트 성능 영향 요인 정의 - 콘크리트 성능 영향 평가를 위한 실험용 폭로 콘크리트 시편 확보 - 콘크리트의 정밀표면 이미지 데이터를 통한 강도, 공극률, 확산계수 등 시설물 내구성능 영향 요인 정의 - 콘크리트 표면 이미지에서 추출한 공극의 크기 및 분포, 균열의 수준, 미수화시멘트량, 골재의 상태 등의 정보를 활용하여 콘크리트의 내구성능 평가
②	콘크리트 성능 Big Data 구축을 위한 시편 제작 및 성능 실험 - 콘크리트 유지관리 성능 영향 요인을 중심으로 Big Data를 구축하기 위한 시편 제작 - 콘크리트 시편의 성능 파악을 위한 강도실험, 열화실험 등 수행 - 콘크리트 시편 실험데이터와 표면의 미세관측 및 MIP, 강도, 축진 등의 실험 Data 비교 및 수집
③	DCNN기반 사진판독을 위한 콘크리트 시편 표준 자료 DB구축 - DCNN기반 사진판독을 위한 콘크리트 배합조건 및 성능별, 유지 관리 영향 요인 Data Categorizing - DCNN기반 사진판독을 위한 콘크리트 표면 사진 확대 배수 등과 같은 최적 기준 도출 및 콘크리트 성능 표준 자료 DB 구축
④	콘크리트 시설물 성능평가 시스템 검증용 시편 제조 - 콘크리트 성능평가 알고리즘 최적화를 위한 시스템 검증 및 데이터 보완용 시편 추가 제조 - 콘크리트 시설물 유지관리를 위한 성능평가 프로그램 검증 자료 구축




그림 3.2 1차년도 주요 연구내용

(1) 개발 목표

연구과제 수행기관	아주대학교 산학협력단	공동연구기관
1차년도 연구목표	DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축	
2세부 연구목표	DCNN 기반 콘크리트 시설물 특성별 성능평가 알고리즘 설계	

(2) 개발 내용 및 범위

①	콘크리트 구조물 성능평가 모델 설계를 위한 데이터 특성 분석
- 콘크리트 성능 지표를 나타내는 공극, 강도, 염화물 확산계수, 건전도 등의 콘크리트 정밀 표면 이미지 데이터 특성 파악 - 콘크리트 이미지 데이터의 공극, 강도, 염화물 확산계수, 건전도 등의 특성별 데이터 분포 및 상관관계 통계 분석 및 데이터 시각화 분석 실험	
②	성능평가 구현을 위한 DCNN 모델의 입출력 정의 및 실험
- 특성별 입력 데이터 사이즈, 입력 데이터 구조 및 형태, 출력 형태 정의 - 고정 초기 신경망 모델을 활용하여 공극, 강도, 염화물 확산계수, 건전도 등의 연속 변수를 범주화 실험 및 입력 데이터 구조 설계 실험	
③	실험자료 및 목표값 Matching을 위한 DCNN 모델의 데이터 전처리 및 증폭 Simulation
- 조명, 위치, 각도 등에 따른 입력 데이터의 변형 및 왜곡 현상 입력 데이터에 반영 - 이미지 변형 컴퓨터 비전 알고리즘을 적용하여 조명, 위치, 각도 등의 각 변형별 데이터 생성 및 고정 초기 신경망 모델 활용하여 검증	
④	성능 목표값 Tracking을 위한 DCNN 모델의 신경망 알고리즘 설계
- 특성별 입력 데이터 타입, 사이즈 및 구조, 출력 사이즈 및 형태를 반영한 DCNN 구조 설계 - DCNN의 layer 수 및 형태, layer module, filter 사이즈 및 개수 그리고 신경망 전체 구조 설계 - Learning set의 구성은 ① DCNN의 입력데이터, ② DCNN의 Architecture 후보군, ③ DCNN의 학습을 위한 학습 파라미터 set으로 구성	




그림 3.3 1차년도 주요 연구내용

나. 2차년도

■ 본 연구과제의 2차년도 개발 목표는 본 연구과제의 최종 목표인 “콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 시스템 개발”을 위한 “DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발” 연구이며, 연구과제 최종성과물의 성능을 검증하여 기술개발 성숙도를 TRL 3단계에서 4단계 수준까지 향상시킬 계획임.

(1) 개발 목표

연구과제 수행기관	한양대학교 에리카산학협력단	주관연구기관
2차년도 연구목표	DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발	
1세부 연구목표	콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발	

(2) 개발 내용 및 범위

①	DCNN 기반 알고리즘 피드백을 통한 Big Data Mining 1차년도에 개발된 DCNN 기반 알고리즘에 대한 피드백을 통해 콘크리트 성능 영향 요인과 관련된 Big Data 내의 유용한 상관관계 분석 - 시설물 사용자가 콘크리트 성능을 평가하고 콘크리트 시설물의 유지관리를 결정하는 의사결정 정보 Data Mining
②	콘크리트 시설물 성능평가 알고리즘 Big Data 검증 및 보완 - 콘크리트 시설물 성능평가 알고리즘 Big Data 특성 검증 1차년도에 구축된 콘크리트 표면 최적 사진 기준 및 성능 대표 자료를 기반으로 MIP, 강도, 촉진 등 실험 Data 보완
③	콘크리트 시설물 유지관리 활용을 위한 최적 사진판독 프로세스 개발 - DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발 - 콘크리트 시설물 유지관리 활용을 위한 최적 사진 판독 프로세스 개발
④	외부 실험 자료를 이용한 사진판독형 콘크리트 성능평가 프로그램 검증 - 외부 실험 데이터를 이용하여 사진판독형 성능평가 프로그램 검증 - 사진판독형 콘크리트 성능평가 시스템의 신뢰도 향상을 위한 지속적인 피드백 제공

시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능 평가 프로그램




그림 3.4 2차년도 주요 연구내용

(1) 개발 목표

연구과제 수행기관	아주대학교 산학협력단	공동연구기관
2차년도 연구목표	DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발	
2세부 연구목표	DCNN기반 콘크리트 시설물 성능평가 알고리즘 구현	

(2) 개발 내용 및 범위

①	적용성 평가를 위한 DCNN 모델의 입출력 최적화
1차년도에 설계된 특성별 딥러닝 모델(DCNN)을 하나의 모델로 융합과 성능 향상을 위해 입출력 데이터 구조 설계 - DCNN 융합 알고리즘의 성능 개선을 위해 입출력 데이터 최적화 실험	
②	성능지표(강도, 확산계수, 공극률)의 최적 접근을 위한 DCNN 모델의 데이터 전처리 및 증폭 최적화
1차년도에 설계된 딥러닝 모델(DCNN)을 하나의 모델로 융합과 성능 향상을 위해 데이터 전처리 및 효과 분석 - 다양한 데이터 전처리 설계를 통한 각 전처리별 데이터의 융합 알고리즘의 성능 향상 실험	
③	Layer Structure의 안정화를 위한 DCNN 모델의 신경망 최적화
- 공극, 강도, 염화물 확산계수, 건전도 등의 특성 별 모델 구조 및 융합 구조 설계 - 특성 별 모델 구조 및 융합 구조 최적화 실험	
④	콘크리트 표면 사진과 성능 데이터간 상관성 고도화 및 알고리즘 최적화
- DCNN 융합 모델의 예측 속도 향상을 위한 모델 구조 설계 - Model compression 기법을 사용하여 고속 DCNN compression 실험	




그림 3.5 2차년도 주요 연구내용


3. 연구개발 결과

연구과제 수행기관	한양대학교 에리카산학협력단	주관연구기관
-----------	----------------	--------

가. 1차년도 연구수행 내용 및 연구

1) 사진 판독형 콘크리트 성능평가 개념

- 본 연구콘크리트는 외관상으로 보면 20% 정도의 공극을 포함하고 있는 투수 또는 투기와 같은 성질을 가지는 다공체이다. 콘크리트 내부에 산재되어 있는 공극은 콘크리트의 내구성을 지배하는 재료적 인자로서 가장 큰 비중을 차지한다. 각종 공극의 크기, 모양, 직경별 함유량 등의 분포상태는 콘크리트의 내구성을 결정하는 중요한 역할을 하고 있다. 콘크리트의 물성 중에서 가장 중요한 콘크리트의 압축강도가 내부 공극의 양과 크기에 좌우되는 것은 강도이론의 가장 기본이 되는 사실이며, 주된 노후화 요인인 염화물 확산계수 또한 내부의 공극 분포상태에 좌우된다. 다시 말하면, 콘크리트의 압축강도, 염화물 확산계수는 콘크리트의 공극 특성, 즉 공극의 양, 크기, 분포, 모양 등에 의해 크게 영향을 받는다.
- 본 연구여러 연구자들은 염화물 확산계수와 공극률의 상관관계, 압축강도와 공극률의 상관관계를 분석함으로써 콘크리트의 공극이 콘크리트의 내구성에 큰 영향을 미침을 확인하였다. 그러나 공극률은 공극의 특성 중 하나인 공극의 양을 수치화한 값으로 공극의 크기, 분포, 모양 등의 특성은 반영되지 않은 값이다. 본 연구는 콘크리트의 압축강도, 염화물 확산계수를 예측함에 있어 사진 이미지를 통해 공극의 크기, 분포, 모양 등의 공극 특성뿐만 아니라, 골재, 미세균열, 미수화 시멘트 등 사람의 눈으로는 확인 할 수 없지만, 콘크리트의 압축강도와 염화물 확산계수에 영향을 주는 콘크리트의 조직특성이 있을 것으로 가설을 세운다. <그림 2> 는 본 연구에서 제안하는 사진 이미지 기반 콘크리트 성능평가 개념을 도식화한 것이다.



<그림 2> 사진 판독형 콘크리트 성능평가 개념

2) 콘크리트 성능 영향 요인 분석

- 콘크리트 시설물 유지관리를 위한 콘크리트 성능지표에는 강도, 균열, 탄산화, 염화물 함유량, 철근부식, 표면노후, 강재규격 및 강도, 접합상태, 강재 부식도, 접합재 부식도, 내화피복, 변위변형 등이 있다. 본 연구에서는 내구성을 평가하는 지표로 중요성이 강조되고 있는 압축강도와 염화물 확산계수를 선정하였다. 각 지표와 내구성과의 관계, 각 성능지표에 영향을 미치는 요인들을 살펴본 후, 사진 이미지 기반 성능평가의 개념을 정립한다.

(1) 콘크리트 압축강도

① 콘크리트 압축강도와 내구성

- 콘크리트는 시멘트, 물, 골재, 혼화제 등 여러 구성요소들로 이루어진 혼합체로서 (최희복 2005) 일반적으로 경화 콘크리트의 구성은 시멘트 경화체 조직과 골재로 구성되어 있으며, 시멘트 경화체는 시

멘트 수화 생성물과 공극으로 구성되어진다 (고정원 2000). 콘크리트의 품질은 온도, 습도 등과 같은 기상작용 및 주변환경 등의 외부 인자에 의하여 크게 영향을 받으며, 콘크리트 조직내부에 물리화학적 변화가 일어나 콘크리트의 내구성능 및 조직 구조에 영향을 주게 된다 (이승태, 2014). 콘크리트 구조물의 수명에 영향을 주는 요인은 온도변화, 계절 변화, 동결 융해, 강우·습도, 대기조건, 흑의 화학 물질 농도 등 환경적인 것으로 이러한 요인을 큰 범주에서 보면 화학적 요인이 전체 54%를 차지하고 있다 (이장화 2001). 콘크리트의 열화 정도는 구조물이 처하는 주변환경과 페이스트의 미세 구조 및 콘크리트의 압축강도에 좌우되는데, 콘크리트의 투수성과 압축강도는 콘크리트의 품질을 나타내는 대표적인 인자로서 콘크리트의 내구성을 평가하는 기본적인 지표로 활용된다 (이장화 2001). 콘크리트 압축강도에 영향을 미치는 인자는 물시멘트비, 공극구조, 단위 시멘트량, 수화량 등 다양한 요인들이 존재하나, 근본적으로 콘크리트의 강도발현은 시멘트 입자의 공극이 얼마나 수화물로 채워져 있느냐에 달려있다 (Power, 1948; 고정원, 2000). 즉, 콘크리트의 강도발현에 영향을 미치는 공극 특성이 콘크리트 압축강도에 미치는 영향을 파악하고자, 고정원 (2000)은 공극률과 압축강도 간 회귀분석을 통하여 높은 상관관계가 있음을 보여주었으며, 공극률이 증가할수록 압축강도가 감소하는 경향을 실험적으로 나타내었다. 박상순 (2009)는 콘크리트를 구성하고 있는 시멘트 모르타르의 공극률과 내구특성과의 관계에 대한 실험적 연구를 통해 콘크리트 공극률 변화에 따른 강도, 투기성, 염화물 확산계수, 흡수량, 수분확산계수의 변화를 관찰하였다. 콘크리트의 공극구조는 강도뿐만 아니라 내구성에도 깊은 영향이 있으며, 유해인자의 주된 이동통로가 되고, 수분을 보유할 수 있는 역할을 하게 되므로, 염화물질 이동 저항성을 평가할 수 있는 주된 지표가 되고 있다. (박상순, 2009; Uchikawa, 1990)

② 콘크리트 압축강도 영향요인

- 콘크리트 압축강도를 예측하는데 여러 가지 방법이 존재하며 다양한 실험적 연구가 진행되어 왔다. 기존에는 코어 채취법을 통해 압축강도를 측정하였으나, 구조물의 안전성과 비용적인 측면을 고려하여 비파괴 측정법이 많이 활용되고 있다. 비파괴 측정법은 반발경도나 초음파 속도를 이용하여 콘크리트 압축강도를 추정하는 방법으로 압축강도 예측식을 제안하는 연구가 많이 진행되어 왔다 (김무한, 2015). 최근 들어 <표 2>에 보이듯이 인공 신경망을 이용하여 압축강도를 예측하는 방법들이 제안되고 있다.
- 김두기 (2004) 확률이론과 신경망 이론을 결합한 확률신경망을 사용하여 확률적으로 최적으로 콘크리트 압축강도를 예측하고, 시험으로부터 얻어진 압축강도 데이터와 비교 분석을 수행하였다. 윤지연 (2005)은 콘크리트 압축강도와 시멘트량, 물시멘트비, 대체율, 잔골재율, 첨가제, 재생골재, 공기량, 슬럼프 등을 변수데이터로 하여 데이터 마이닝 기법인 신경망 모델과 회귀분석기법을 이용하여 모델 간의 예측 정확도를 비교하였고, 그결과 신경망 모델이 회귀식에 비해 정확한 결과를 나타내었다. 이승창(2002)는 다중 신경망을 이용하여 콘크리트 강도를 추정하였다. 입력층 뉴런수 결정 단계에서 크게 4가지 정보인 기본정보 재료배합, 측정항목, 대기 온/습도로 분류하고 세부적으로 총 73개의 변수를 입력 뉴런의 대상으로 하였다. 출력층 뉴런수는 총 7가지 재령 시간(16시간 20시간 24시간 2일 3일 7일 28일)을 대상으로 하였다. 김인수 (2002)는 신경망을 이용한 콘크리트 배합 요소 및 압축강도를 추정하였다. 신경망 학습에 필요한 배합요소를 물-시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량(S1), 부순모래의 단위량(S2), 단위굵은골재량, 혼화제량, 압축강도, 슬럼프값을 입력층으로 하여 출력층인 배합요소 및 압축강도, 슬럼프값을 추정할 수가 있었다. 이승준(2017)은 콘크리트 배합인자를 고려하여 Machine Learning algorithm 기반 콘크리트 압축강도 추정 기법에 관한 연구를 수행하였다. 박태원 (2010)은 물시멘트비, 잔골재율, 시멘트량, 잔골재량, 조골재량, 단위수량의 6cell의 배합조건과 양생방법(수중, 기중)과 양생기간의 2cell의 양생조의 데이터와 각 데이터 조합 방법들에 대한 공시체 압축강도 실험, 반발경도 및 초음파 속도법에 의한 압축강도 측정결과 값을 이용하여, Neuro-fuzzy Inference system 연산을 수행하고 압축강도 예측 모델을 제안하였다. 신현욱 (2011)은 건설현장에서 배합된 콘크리트의 압축강도를 추정하기 위하여 시멘트, 물, 잔골재, 굵은골재, 플라이애쉬 등의 영향인자를 고려하고 뉴럴 네트워크를 이용하여 압축강도를 추정하였다.

〈표 3〉 콘크리트 압축강도 예측에 관한 기존 연구

연구자	영향 요인	방법론
김두기 (2004)	슬럼프, 물-시멘트비, 잔골재, 단위수량, 단위 시멘트량, 단위 잔골재, 단위 굵은 골재, 혼화재	확률이론, 신경망이론
윤지연 (2005)	시멘트량, 물시멘트비, 대체율, 잔골재율, 첨가제, 재생골재, 공기량, 슬럼프	신경망 모델, 회귀분석기법
이승창 (2002)	재료배합, 측정항목, 대기 온/습도, 재령	다중 신경망 모델
김인수 (2002)	물시멘트비, 잔골재율, 단위수량, 단위시멘트량, 강모래의 단위량, 부순모래의 단위량, 단위굵은골재량, 혼화제량, 슬럼프값	신경망 모델
이승준 (2017)	W/B, 고로슬래그, 플라이애쉬	Machine learning algorithm
박태원 (2010)	콘크리트 배합비(물시멘트, 잔골재율, 단위수량, 단위시멘트량, 굵은골재량, 잔골재량, 잔골재율, 혼화재종류별 질량) 콘크리트 양생특성 및 비파괴 시험데이터	Neuro-fuzzy Inference system
신현욱 (2011)	시멘트, 물, 잔골재, 굵은골재, 플라이애쉬	뉴럴 네트워크

- 기존에는 배합인자를 고려한 콘크리트 압축강도를 추정하는 연구가 진행되어 왔다. 그러나 현장 조건이 결합되지 않은 수학적 예측모델이라는 한계가 존재했다 (박태원 2010). 현장 조건을 고려할 수 있는 입력변수를 반영하여 압축강도를 예측하는 연구도 진행되었다. (박태원, 2010; 신현욱 2011) 그러나 이러한 시도 역시 기존 알고리즘에 비해 정확한 예측값을 도출할 수 있는 있지만, 실제 다양한 환경적인 요인에 의해 균열, 미세공극 등의 열화가 발생한 실제 시설물 콘크리트 압축강도를 진단하기에는 한계가 존재한다.

(2) 콘크리트 염화물 확산계수

① 콘크리트 염화물 확산계수와 내구성

- 콘크리트 내구성에 영향을 미치는 여러 열화 인자 중 염해에 대한 관심이 높아지고 있다. 자연환경 중 다양한 형태로 존재하는 염화물은 콘크리트 구조물의 철근 부식을 야기하며 이에 따른 심각한 내구성 저하와 함께 구조물의 수명을 감소시킨다. 염화물에 의한 콘크리트 내구수명 평가는 크게 두 가지의 항목으로 분류할 수 있다. 첫째, 시간에 따른 콘크리트중의 염화물 침투속도를 산정하는 것이고, 둘째, 철근부식개시를 야기하는 임계 염화물량에 대한 정량화이다 (이창수, 2010). 염해환경에 노출된 철근 콘크리트 구조물의 내구수명을 예측하기 위하여 염화물이온 확산계수, 표면 염화물 이온량 및 임계 염화물량 등이 주요 인자로 사용된다. 특히, 콘크리트의 염화물 확산계수, 임계 염화물량은 염화물 이온 확산계수 및 임계 염화물량에 따라 크게 달라지므로, 이들은 콘크리트 내구수명을 예측하는데 매우 중요한 인자로 평가되고 있다 (박재임, 2010). 해양환경에서 이루어지는 콘크리트 구조물 공사는 염화물이온 확산에 의해 콘크리트 내부의 철근을 부식시키므로 콘크리트 내구성 평가에 있어 염화물 확산계수에 대한 고려가 필요하다 (백승우, 2003).
- 염화물 확산계수는 콘크리트 내부로의 이온 확산 속도를 나타내주는 가장 중요한 지표이며 콘크리트의 배합조건, 양생기간, 양생온도의 초기조건과 양생이후의 온도, 습도에 따라 시간 의존적으로 변하게 된다 (이창수 2010). 염화물 확산예측은 염해에 의한 성능저하 과정 중 잠복기의 예측에 있어서 매우중요하며, 철근 부식을 야기하는 염화물 이온은 공극 또는 공극구조를 통하여 침투하게 된다 (김동석, 2006). 염화물 확산계수는 정량적인 염화물 거동을 평가하고 내구수명을 예측하는데 필수적인 변수이다 (권성준 2012).

② 콘크리트 염화물 확산계수 영향요인

- 김선환(2013)은 콘크리트 균열 패턴에 따른 균열부 콘크리트의 염화물 확산계수 모델링을 수행하였다. 김동석(2006)은 다변수 비선형 회귀분석을 통해 물결합재비(W/B) 및 혼화재별로 치환율을 변수로 하여 범용적 적용이 가능한 염화물 확산계수 예측식을 제안하였다. 김정진(2008)은 부식생성물의 공극충전에 의한, 부식 반응량 및 인산화탄소의 확산속도 변화를 고려한 철분혼입 콘크리트의 염화물 이온침투 예측모델에 관한 연구를 수행하였다.
- 박재임 (2010)은 콘크리트 구조물의 내구수명에 미치는 인자로서 염화물 확산계수의 특성을 평가하기 위하여, 북유럽에서 규격화되어 있는 NT-BUILD 492 방법에 의해 염화물 확산실험을 수행하였다. 실험 결과 염화물 확산계수는 물-시멘트비가 감소하고 재령이 증가함에 따라 작아지는 것으로 나타났으며, 콘크리트 내구수명은 물-시멘트 및 염화물 확산계수가 작을수록 증가함을 보여주었다.
- 원민식(2011)은 가혹환경에 노출된 콘크리트 구조물의 물리적,화학적 성능 저하로 인한 콘크리트의 내구성 열화특성을 분석하기 위해, 동결 융해작용을 받는 콘크리트 시편의 공극률과 염화물 저항성을 분석하였다. 분석 결과, 동결 융해 작용을 적용한 시편은 재령이 지남에 따라 미세균열이 발생하여 공극률이 밀실해지지 못하는 결과를 보여주었으며, 그에 따라 염화물 저항성이 취약해지는 분석결과를 나타내었다.
- 원민식(2011)은 콘크리트 구조물의 내구성 설계 변수인 염소이온 확산계수가 내구수명에 미치는 영향을 평가하기 위해 Life program에 의하여 물-시멘트 및 시험방법에 따라 콘크리트 구조물의 내구수명을 평가하였다. 콘크리트의 염화물 확산계수는 물-시멘트비가 작고 재령이 증가함에 따라 감소하는 것으로 나타났다.
- 이창수(2010)은 실내 염화물 침지 실험을 통해 콘크리트 염화물 고정화 특성을 파악하고 이를 고려한 염화물 침투모델로서 비정상상태의 염화물 침투 해석과 함께 해양침지환경하의 철근콘크리트 구조물의 내구수명 예측을 시도 하였다.
- 윤의식(2005)은 시멘트의 종류에 따른 콘크리트 염화물 침투 및 확산 특성을 비교·검토하기 위하여 CaA 함량이 다른 V종 시멘트, I종 시멘트 및 플라이 애쉬 시멘트 등 총 5종류의 시멘트를 사용한 콘크리트의 강도 및 공극률, 염화물 침투 실험을 통하여 이를 분석·평가하고, 이들의 상관관계를 분석하였다. 콘크리트의 압축강도, 공극률 및 염화물 침투 저항성은 시멘트 종류에 관계없이 높은 상관계수 및 결정계수를 나타내어 높은 상관성을 가지고 있음을 확인하였다.
- 권성준(2012)는 단위수량 증가에 따른 시멘트 모르타르의 공극분포와 내구성능에 관한 연구를 수행하였으며, 공극률 변화에 따라 압축강도, 염화물 확산계수, 물시멘트비(단위수량)에서는 선형적인 관계인 것을 분석하였다.
- 염화물 확산계수 관련 연구들에서는 염화물 확산계수에 영향을 주는 요인들을 도출하고, 상관관계를 분석하는 연구들이 다수를 차지하고 있고, 염화물 확산계수를 예측하는 연구는 상대적으로 부족한 실정이다.

3) 콘크리트 성능평가 Big Data 구축

- 콘크리트 성능 Big Data 구축과정은 다음 <그림 5>과 같다. 콘크리트 성능 Big Data를 구축하기 위해 우선 콘크리트 시편을 제작한다. 각 시편에 대한 사진 이미지 (Input)를 촬영하고, 압축강도 (Output 1), 염화물 확산계수 (Output 2), 공극률 (Output 3)을 시험을 통해 산출한다. 마지막으로, 사진 이미지 (Output)와 각 성능값 (Input 1, 2, 3)을 라벨링 (labeling) 하여 콘크리트 성능 데이터 베이스를 구축한다.



<그림 3> 콘크리트 성능 Big Data 구축과정

(1) 콘크리트 시편 제작

- 본 연구의 최종 목표는 콘크리트의 사진 이미지로 성능값을 예측하는 것이다. DCNN을 촬영하여 콘크리트 성능값을 예측하기 위해서는 콘크리트의 사진 이미지와 해당 사진 이미지에 대한 압축강도, 염화물 확산계수를 학습해야 한다. 콘크리트의 압축강도, 염화물 확산계수에 영향을 주는 대표적인 요인은 공극 특성이며, 이는 물/시멘트비와 재령에 영향을 받는다.
- 따라서 본 연구에서는 다양한 범위의 성능값을 가질 수 있도록 <표 3>과 같이 목표 압축강도 40MPa, 30MPa, 27MPa, 24MPa, 21MPa, 18MPa 기준으로 각각 물시멘트비(W/C) 33%, 40%, 46%, 50%, 62%, 68% 로 OPC100 배합으로 설계하였다. 또한 재령일을 3, 7, 29, 91일로 구분하여 시편 사진이미지 촬영과 성능 시험을 할 수 있도록 시편 수를 설정하였다.
- 콘크리트 시편은 총 2회에 걸쳐 제작되었다 (1차 시편제작: 물시멘트비 33%, 50%, 68%, 2차 시편 제작: 물시멘트비 40%, 46%, 60%). 1차 시편 제작시에는 압축강도 실험을 위한 시편 36개 (배합별 재령일 3, 7, 29, 91일에 각 3개씩), 염화물 확산계수 실험을 위한 시편 27개 (배합별 재령일 7, 28, 91일에 각 3개씩), 공극을 실험을 위한 시편 27개 (배합별 재령일 3, 7, 28일에 각 3개씩)를 제작하였다. 2차 시편 제작시에도 1차와 마찬가지로 압축강도 실험 시편 36개, 염화물 확산계수 실험 시편 27개, 공극을 실험 시편 27개를 제작하였다. 시편의 규격은 $\phi 100 \times 200\text{mm}$ 이며, <그림 4>에서 보이듯이 배합 후 양생, 연마의 과정으로 완성되었다.

<표 4> 최적 콘크리트 배합 설계

단위: Kg

압축 강도	물	시멘트	잔골재	굵은 골재	공기량	S/A	W/C	성능 AE감수제
18MPa	170	250	932	944	45	51	0.68	0.80%
21MPa	185	300	874	921	45	50	0.62	0.40%
24MPa	165	330	852	973	45	48	0.50	0.80%
27MPa	178	390	795	945	45	47	0.46	0.40%
30MPa	165	410	803	955	45	47	0.40	0.40%
40MPa	160	480	749	965	45	45	0.33	0.80%





<그림 4> 콘크리트 시편 제작과정

(2) 콘크리트 시편 사진 이미지 촬영

- 본 연구에서 제안하고 있는 사진 이미지를 통한 콘크리트 성능 평가는 이전에 시도된 적 없는 새로운 접근 방법이다. 따라서 어떠한 배율, 화소에서 사진 이미지를 촬영해야 가능한가에 대한 정보가 전무한 상태이다. 본 연구에서는 <그림 5>에 정리하였듯이 콘크리트 시편 촬영에 USB 현미경과 Macro 렌즈를 장착한 DSLR을 사용하였다.
- 현미경은 표본으로부터 빛을 사용하여 대물렌즈에 의해 표본이 확대된 실상을 맺고, 이것을 접안렌즈에 의해서 재 확대된 실상을 맺고, 이것을 접안렌즈에 의해서 재 확대하는 장치로서 정의된다. 대개의 경우 대물렌즈와 접안렌즈를 갖추고 있는 현미경을 말하나, 넓은 뜻으로는 전자선을 이용하는 전자현미경도 포함된다. 종류와 형식은 사용목적, 제작연대, 제작회사의 차이에 따라 여러 가지 있다. 본 연구에서는 향후 실제 콘크리트 건물의 성능 평가시에 휴대하고 다니기 쉽고, 촬영이 간편한 USB 현미경을 사용한다. 본 연구에서 사용한 USB 현미경은 약 200만 화소를 가지고, 10~200 배율을 가진다. USB 현미경을 사용하여 사진 이미지를 촬영한 결과 가로 0.9cm, 세로 0.5 cm 의 구역을 촬영할 수 있었다.

- Macro 렌즈를 장착한 DSLR은 약 2,430만 화소를 가지고, 촬영가능 구역은 가로 2.5cm, 세로 1.5cm로 USB 현미경보다는 다소 넓은 범위를 가진다. 많은 수의 사진 이미지를 얻기 위해서 한 시편 당 150~200개의 이미지를 촬영함과 동시에 동영상으로도 촬영하였다. 시편의 윗면과 아랫면을 촬영하였으며, 각 면의 다양한 특징을 골고루 겹침 없고 누락 없이 촬영하기 위해 윗면과 아랫면을 <그림 6>과 같이 총 10개의 구역으로 나누어 촬영하였다.

 DSLR	이미지 촬영 동영상 촬영	• 화소: 약 2,430만 (4K: 4,096 x 2,160) • 센서: Exmor APS HD CMOS 센서 • 렌즈: 렌즈 전면에서 피사체까지의 최단 작업 거리 2.4cm / 최소 초점 거리 9.5cm	
 USB 현미경	이미지 촬영 동영상 촬영	• 화소: 약 200만 (FHD - 1,920 x 1,080) • 배율: 10 ~ 200배 • 포커스: 수동포커스 • 이미지 센서: 3M pixel	

<그림 5> 콘크리트 시편 이미지 촬영 방법




<그림 6> 사진 이미지 촬영 구역 구획

(3) 콘크리트 시편 성능시험

- 본 연구에서는 압축강도, 염화물 확산계수, 공극률 총 3가지 성능시험을 <그림 7>과 같이 진행하였다. 시험체 규격은 KS F 2405에서 요구하는 $\phi 100 \times 200$ mm를 준수하였으며, 시험 방법으로는 각각 KS F 2405 기준에 따른 강도 측정법 (압축강도), NT Build 492 (염화물확산계수) 그리고 MIP 실험법(공극률)을 활용하였다.

① 압축강도 시험 결과

- 압축강도 시험은 소정기간 양생이 끝난 후 KS F2405의 규정에 의거 측정하며, 200 Ton UTM을 사용하여 측정한다. 1차 실험에서는 물시멘트비 68%, 50%, 33%의 배합별 3개의 시편의 압축강도를 측정하였으며, 2차 실험에서는 물시멘트비 62%, 46%, 40%의 배합비를 갖춘 3개의 시편을 실험하여 다양한 분포의 압축강도 성능을 수집하였다. <표 4>에서 보이는 결과는 1차 실험결과와 데이터 보안을 위해 추가 실험한 2차 시험 결과를 나타낸다.

	시험체 규격	시험방법		W/C	재령일
압축강도	Φ 100 X 200 mm	KS F 2405		68%, 50%, 33% 62%, 46%, 40%	3, 7, 28, 91
염화물 확산계수	Φ 100 X 200 mm	NT Build 492		68%, 50%, 33% 62%, 46%, 40%	7, 28, 91
공극률	10 mm 이하	MIP		68%, 50%, 33% 62%, 46%, 40%	3, 7, 28, 91

<그림 7> 콘크리트 성능 실험 방법

<표 5> 압축강도 시험 결과

1차 시험 결과 - 압축강도 (MPa)				
W/C	재령 3일	재령 7일	재령 28일	재령 91일
68%	10.29	10.57	17.09	20.78
	8.89	10.84	18.83	20.81
	9.21	10.29	18.70	21.52
50%	16.67	18.41	28.29	29.50
	17.29	17.73	27.97	34.55
	16.77	18.08	20.27	30.56
33%	25.96	34.99	40.59	51.40
	26.28	30.58	38.99	45.38
	27.58	33.83	41.48	49.78

2차 시험 결과 - 압축강도 (MPa)				
W/C	재령 3일	재령 7일	재령 28일	재령 91일
62%	11.52	19.01	25.37	28.88
	12.59	18.86	26.73	28.32
	12.65	19.10	25.82	27.60
46%	17.71	25.87	32.08	37.55
	17.72	24.47	37.57	38.68
	18.17	24.97	31.81	38.09
40%	20.19	27.76	35.49	40.83
	20.91	28.01	36.97	41.18
	19.12	28.52	36.67	40.19

② 염화물확산계수 시험 결과

- 염화물확산계수는 NT Build 492 시험법, 즉 촉진시험법으로 실시한다. 이 시험법은 콘크리트 공극이 직경 100mm 의 시편을 두께 약 50mm로 절단하여 그 두께를 버어니어캘리퍼스로 정확하게 측정 한 후 수산화칼슘(Ca(OH)₂) 수용액으로 포화시키며 그 후 시편을 가지고 고무재질의 컨테이너와 조립한 후, 양극에는 0.3M의 NaOH 수용액을, 음극에는 10%의 NaCl 수용액을 채워 전기적 전위차를 인가 하게 된다. 이때 최초의 인가전압은 30V로서 최초 인가시의 전류값(I30V)을 바로 측정하여 인가전압 을 수정(U)하여 유효한 초기 전류값(I0)이 나오는지 확인한 후 해당되는 시간(t)동안 촉진시험을 수행 하게 된다. 해당되는 전위차 인가시간이 끝난 후 시험체를 해체하여 시편을 축방향으로 쪼갠 후 염소 이온 침투깊이를 확인하기 위하여 쪼개진 면에 0.1N의 질산은(AgNO₃) 수용액을 분무한다. 약 15분 경과 후 은색 염화물 침전물이 육안으로 확실하게 나타날 때, 버어니어캘리퍼스를 가지고 0.1mm 단 위까지 7개소에서 정확하게 염화물 침투깊이를 측정하여 평균값을 구한다. <표 5>에서 보이는 결과는 1차 실험결과와 데이터 보완을 위해 추가 실험한 2차 시험 결과를 나타낸다.

<표 6> 염화물 확산계수시험 결과

1차 시험 결과 - 염화물 확산계수 (m ² /s)			
W/C	재령 7일	재령 28일	재령 91일
68%	9.80E-12	9.76E-12	9.76E-12
	6.99E-12	1.18E-11	1.06E-11
	1.20E-11	9.92E-12	8.38E-12
50%	9.02E-12	9.88E-12	6.26E-12
	7.32E-12	7.09E-12	6.53E-12
	8.49E-12	8.83E-12	5.97E-12
33%	3.44E-12	3.37E-12	3.63E-12
	5.59E-12	4.17E-12	3.99E-12
	4.47E-12	4.74E-12	3.14E-12

2차 시험 결과 - 염화물 확산계수 (m ² /s)			
W/C	재령 7일	재령 28일	재령 91일
62%	9.42E-12	6.89E-12	5.64E-12
	8.93E-12	8.21E-12	5.44E-12
	8.52E-12	7.33E-12	5.02E-12
46%	8.19E-12	5.39E-12	2.30E-12
	6.46E-12	4.29E-12	2.48E-12
	7.75E-12	4.88E-12	2.34E-12
40%	5.75E-12	4.62E-12	2.71E-12
	6.73E-12	5.56E-12	2.58E-12
	6.28E-12	5.50E-12	3.07E-12

③ 공극률 시험 결과

- 공극률의 측정은 경화된 모르타르내의 공극 분포 및 공극률을 측정하기 위하여 MIP (Mercury Intrusion Porosimetry)를 이용한다. 사용 시편은 시험체의 중앙부에서 채취한 시편을 대상으로 5mm 정도로 절단한 시편을 아세톤 용액 중에 24시간 담가둔 후 2시간 동안 건조로에서 건조 시킨 후 약 2g 정도 건조 시료를 채취하여 측정시료로 하였다. 공극의 모양을 실린더형 모세관들로 정의하고, Washburn equation 방정식을 사용하여 수은이 침투하는 공극의 크기를 구한다. <표 6>에서 보이는 결과는 1차 실험결과와 데이터 보안을 위해 추가 실험한 2차 시험 결과를 나타낸다.


<표 7> 공극률 시험 결과

1차 시험 결과 - 공극률 (%)				
W/C	재령 3일	재령 7일	재령 28일	재령 91일
68%	23.4	19.9	17.3	23.2
	22.2	19.0	16.3	22.3
	21.2	19.8	16.6	17.2
50%	20.3	17.8	16.2	18.3
	20.5	19.0	16.3	16.7
	21.0	17.7	14.6	18.8
33%	19.5	16.5	13.8	12.0
	16.2	16.2	14.3	12.3
	16.0	10.0	15.9	14.0

2차 시험 결과 - 공극률 (%)				
W/C	재령 3일	재령 7일	재령 28일	재령 91일
62%	22.5	20.0	20.7	16.9
	21.3	20.2	17.6	16.8
	21.9	21.2	21.9	17.3
46%	20.4	20.1	17.3	15.2
	24.2	16.6	18.0	14.9
	21.3	20.6	19.4	14.9
40%	16.9	19.1	17.8	13.6
	20.1	18.1	19.1	13.4
	20.2	19.5	19.4	13.8

(4) 콘크리트 성능평가 데이터베이스 구축

- 본 연구에서 제안하는 사진 이미지를 통한 콘크리트 성능 평가는 콘크리트 시편 사진 이미지를 입력 하면 콘크리트 시편 성능값 (압축강도, 염화물 확산계수)을 예측하는 것을 목표로 한다. 따라서 콘크리트 시편 성능값에 사진 이미지를 라벨링 (labeling)하여 <그림 8>과 같이 콘크리트 성능 데이터베이스를 구축한다. 이는 DCNN 알고리즘이 정보를 스스로 학습할 수 있도록 환경을 만들어 주는 단계이며, 데이터베이스에 정보가 많을수록 예측 정확도는 높아지게 된다.




<그림 8> 콘크리트 성능 데이터베이스 구축 방법

- 본 연구에서는 사진 이미지를 USB 현미경과 DSLR 두 가지로 촬영하였으므로, 두 종류의 데이터베이스를 따로 구축한다. 본 연구과제에서 수집한 이미지 데이터 수는 총 102,007개이며 각각 압축강도, 염화물 확산계수, 공극률의 성능값을 라벨링하여 데이터베이스를 구축하였다. <그림 9>는 이미지 데이터와 성능값을 매칭하여 저장한 데이터리스트를 나타낸다.

<표 8> 콘크리트 성능지표별 DataSet 수집 및 라벨링 현황

데이터 수 수집 장비	1차 실험		2차 실험		소계		총계
	DSLR	현미경	DSLR	현미경	DSLR	현미경	
압축강도	11,829	6,920	12,837	5,784	24,666	12,704	37,370
공극률	11,829	6,920	12,837	5,784	24,666	12,704	37,370
염화물 확산계수	8,280	4,134	10,786	4,067	19,066	8,201	27,267
총계	31,938	17,974	36,460	15,635	68,398	33,609	102,007




<그림 9> 사진 판독형 콘크리트 성능평가를 위한 Database 구축

나. 2차년도 연구수행 내용 및 연구

1) DCNN기반 알고리즘 피드백을 통한 Big Data Mining

- 본 연구과제는 DCNN 알고리즘을 효과적으로 구현하고 시스템의 정확도를 높이기 위하여 입력데이터에 대한 Data Mining을 수행하였다. 데이터 마이닝(Data Mining)은 데이터로부터 알려지지 않은 특성(unknown properties)을 발견하는 기법 중 하나로, 뉴럴 네트워크(Neural Network)와 같은 기계학습(Machine Learning)에서는 데이터 마이닝 방법론을 무감독학습(Unsupervised Learning)이나 데이터 전처리에서 많이 활용하고 있다. 본 연구과제에서는 콘크리트 성능평가의 정확도를 높이기 위한 방법으로 사전 학습(Pre-Training) 기법을 활용하였다. 사전 학습 기법은 데이터 전처리 과정에서 알고리즘의 가중치(W)를 업데이트함으로써 학습시간(Learning Time)을 줄이고 정확도를 향상시키는 효과가 있다.
- 따라서 본 연구과제에서는 콘크리트 이미지를 수집하는데 있어, 단일 이미지 촬영뿐만 아니라 영상촬영을 통해 수집된 연속 이미지를 활용하여 알고리즘을 학습하였다. 영상촬영을 통해 수집된 연속된 이미지의 데이터는 알고리즘의 사전 학습에 활용하였으며, 단일 이미지 데이터는 알고리즘을 학습/검증/평가 하는데 활용하였다.



<그림 10> DCNN 기반 알고리즘 피드백을 통한 Big Data Mining

2) 콘크리트 시설물 성능평가 알고리즘 Big Data 검증 및 보완

- 1차년도에 콘크리트 성능 예측 시스템의 Feasibility를 확인하기 위해, 1차 실험으로부터 수집된 데이터만을 활용하였다. 1차 실험을 통해 구현된 알고리즘을 통해 분석한 결과, 데이터 분석에 최적화된 입력 데이터의 사이즈와 데이터를 수집하는데 보다 적합한 장비가 무엇인지 확인할 수 있었다. 다음 <그림 11>과 <그림 12>는 DSLR 사진과 현미경 사진을 각각 크기별로 분류하여 데이터베이스화 시킨 모습을 나타낸다.



<그림 11> DSLR 사진, 왼쪽부터 이미지크기 96x96, 84x84, 56x56



<그림 12> 현미경 사진, 왼쪽부터 이미지크기 96x96, 84x84, 56x56

- <표9>는 입력 데이터의 사이즈에 따른 압축강도 예측 결과를 나타내고 있다. 입력 이미지 크기에 따라 성능평가 정확도를 비교한 결과, 현미경 이미지와 DSLR 이미지 모두 84x84 사이즈의 이미지를 입력한 결과 에러값(RMSE)이 가장 낮게 나타남을 확인하였다.

<표 9> 다양한 입력 이미지 크기에 따른 DCNN 예측 성능 결과


입력 데이터	이미지크기	Test Loss	RMSE
현미경 이미지	56x56	0.010281	4.67
	84x84	0.006875	3.82
	96x96	0.007103	3.88
DSLR 이미지	56x56	0.01222	5.10
	84x84	0.01014	4.64
	96x96	0.01054	4.73

- <표 9>에 따라, 입력 데이터의 사이즈는 84x84의 형태로 입력하는 것이 가장 높은 정확도를 나타내었으며, 이를 기반으로 112x112 사이즈의 이미지로부터 84x84사이즈의 이미지를 Random Crop 방식으로 추출하여 알고리즘을 Training 하는데 활용하였다.
- <표 10>는 DSLR과 USB 현미경간의 예측 정확도를 비교한 것을 나타낸다.

<표 10> 다양한 모델에 따른 DCNN 예측 성능 결과

입력 데이터	이미지 크기	모델명	Test Loss	RMSE
현미경 이미지	84x84	Model_A	0.01014	4.64
		Model_G1	0.01131	4.90
		Model_G2	0.01039	4.70
		Model_G3	0.01034	4.69
		Model_R	0.00971	4.54
DSLR 이미지	84x84	Model_A	0.00688	3.82
		Model_G1	0.00703	3.86
		Model_G2	0.00646	3.70
		Model_G3	0.00625	3.64
		Model_R	0.005966	3.56

- <표 10>는 DSLR과 USB 현미경 간 예측 정확도를 비교한 것으로서, DSLR이 보다 높은 정확도를 나타내고 있으며, 이는 <그림 5>에 명시된 바와 같이 상대적으로 USB 현미경보다 넓은 표면이 촬영되어 하나의 이미지에 더 많은 정보를 담고 있기 때문에 나타난 결과로 판단된다.




<그림 13> 데이터 수에 따른 성능 평가 예측 정확도 비교 분석

- <그림 13>은 콘크리트 성능지표 중 압축강도를 기준으로 압축강도 성능 값의 구간별 입력데이터 수를 분석하고, 데이터 수에 따른 성능 평가 정확도의 변화를 나타낸 것이다. 입력 데이터 수의 양이 적을수록 어려움이 증가하고 있음을 확인 할 수 있다. 이는 알고리즘의 효과적인 학습을 위해서는 대량의 데이터수가 요구됨을 알 수 있다.
- 2차년도 연구에서는 1차년도에 수집한 데이터를 바탕으로 콘크리트 성능평가 알고리즘의 유효성을 검증하기 위하여 입력데이터의 분석<표 11> 및 알고리즘의 학습곡선의 변화<그림 14>를 분석하였다.


<표 11> 데이터 파라미터수 분석

파라미터 수	이미지 데이터 수 (A)	영상 추출 이미지 데이터 수 (B)	총계
데이터 셋	4,000	61,996	A+B
학습용 데이터 (*0.7)	2,800	43,397	
플립 (Flip) (*2)	5,600	86,793	
Random-crop (28*28)	4,390,400	68,045,712	72,436,112




<그림 14> 학습 곡선 변화


- <표 11>와 같이 데이터 파라미터수는 총 72,436,112개이며, 이를 바탕으로 학습된 알고리즘은 부드럽게 에러값이 줄어드는 모습을 확인할 수 있다 <그림14>. 그러므로, 본 연구에서 수집된 콘크리트 이미지 수는 콘크리트 성능평가의 유효성을 검토하기에 충분한 데이터 수를 나타내었음을 보여준다. 다만, 데이터 수에 따른 실험용 시편 개수의 유효성 검토에서 언급한 바와 같이 학습된 데이터(이미지) 개수에 따라 정확도가 달라지는 것을 확인할 수 있었으므로, 2차 실험에서는 압축강도의 연속성을 확보할 수 있도록 데이터를 추가 확보하여 실험에 활용하였다. 다음 <그림 15>은 1차 실험으로부터 얻은 데이터의 분포와 2차 실험으로부터 얻은 데이터 분포를 나타낸다.



<그림 15> 1,2차 압축강도 데이터 분포



<그림 16> 1,2차 공극률 데이터 분포



<그림 17> 1,2차 염화물확산계수 데이터 분포

- 다음 <그림 16,17>은 각각 1차 실험으로부터 얻은 공극률 및 염화물 확산계수 데이터의 분포와 2차 실험으로부터 얻은 공극률 및 염화물 확산계수 데이터 분포를 나타낸다.

- 본 연구에서는 콘크리트 실험을 수행하면서 얻은 콘크리트 성능 값에 대한 객관성을 확보하기 위해 공인 기관의 시험성적서를 발급받았다. <표 12>는 콘크리트 성능 시험에 대한 공인 시험 성적서를 보여준다.

<표 12> 콘크리트 성능 시험 성적서

시험성적서

1. 검 수 번 호 : KCTL-18-00901
2. 기 관 명 : 한양대학교 안용환 교수
3. 주 소 : 경기도 안산시 상록구 한양대학교 55 한양대학교 2공학관 506호
4. 시 료 명 : 딜러닝 알고리즘 구축 및 학습 데이터용 콘크리트 배합 및 시험평가
5. 성 과 이 용 목 적 : 연구목적용

6. 시 험 결 과 :

시 험 항 목	단 위	시험결과 값	시험방법	비 고
슬럼프	mm	21MPa(W/C62%)	150	KS F 2594 : 2015
		27MPa(W/C46%)	150	
		30MPa(W/C40%)	150	
공기량	%	21MPa(W/C62%)	4.8	KS F 2421 : 2016
		27MPa(W/C46%)	4.5	
		30MPa(W/C40%)	4.5	
압축강도 21MPa(W/C62%)	N/mm ²	재령 3일	12.25	KS F 2405 : 2010
		재령 7일	18.99	
		재령 28일	25.97	
		재령 91일	28.27	
압축강도 27MPa(W/C46%)		재령 3일	17.87	
		재령 7일	25.10	
		재령 28일	33.82	
		재령 91일	38.17	
압축강도 30MPa(W/C40%)		재령 3일	20.07	
		재령 7일	28.09	
		재령 28일	36.38	
		재령 91일	40.74	

※ 시험항목은 현장시험 결과임.
*항목은 KOLAS 인정범위 밖임을 알려드립니다.

작성자 : 이 제 호 승인자 : 이 용 수

※ 본 성적서의 시험결과는 고객이 제시한 시료에 대한 결과임.
2018 . 07 . 02 .
한국콘크리트시험원

KCTL-TP-22-08(00) Korea Concrete Testing Laboratory *전라북도 확인은 상단 연락처로 문의하십시오

시험결과

시 험 항 목	단 위	시험결과 값	시험방법	비 고
*공극률 21MPa(W/C62%)	%	재령 3일	22.5	의뢰자 제시 (수문압입법)
		2	21.3	
		3	21.9	
		7일	20.0	
		2	20.2	
		3	21.2	
		1	20.7	
		2	17.6	
		3	21.9	
		1	16.9	
		2	16.8	
		3	17.3	
*공극률 27MPa(W/C46%)	%	재령 3일	20.4	의뢰자 제시 (수문압입법)
		2	24.2	
		3	21.3	
		1	20.1	
		2	16.6	
		3	20.6	
		1	17.3	
		2	17.9	
		3	19.4	
		1	15.2	
		2	14.9	
		3	14.9	
*공극률 30MPa(W/C40%)	%	재령 3일	16.9	의뢰자 제시 (수문압입법)
		2	20.1	
		3	20.2	
		1	19.1	
		2	18.1	
		3	19.5	
		1	17.8	
		2	19.6	
		3	19.4	
		1	13.6	
		2	13.4	
		3	13.8	

KCTL-TP-22-09(00) Korea Concrete Testing Laboratory

시험결과

상계서번호 : KCTL-B-18-02460
페이지 (1 / 총 3)
주소: 경기도 오산시 동부대로 372
전화: 031-385-1892 팩스: 031-373-1893

시 험 항 목	단 위	시험결과 값	시험방법	비 고
*염화물의 침투깊이 21MPa(W/C62%)	m	재령 7일	0.020 0	NT BUILD 492
		재령 28일	0.015 8	
		재령 91일	0.012 8	
*염화물의 침투깊이 27MPa(W/C46%)		재령 7일	0.017 4	
		재령 28일	0.011 1	
		재령 91일	0.006 5	
*염화물의 침투깊이 30MPa(W/C40%)		재령 7일	0.014 9	
		재령 28일	0.011 9	
		재령 91일	0.007 2	

KCTL-TP-22-09(00) Korea Concrete Testing Laboratory

- 2차년도에 추가적인 실험을 통해 수집한 콘크리트 이미지 데이터와 성능 데이터를 바탕으로 성능 예측 알고리즘을 검토한 결과 <표 13>와 같은 결과 값을 얻을 수 있었다. 알고리즘의 모델은 1차년도에 수행했던 결과를 바탕으로 가장 좋은 결과를 나타내었던 두 개의 알고리즘(Model_A, Model_R)을 활용하였다.

<표 13> 다양한 모델에 따른 DCNN 예측 성능 결과

입력 데이터	성능지표	모델명	Test Loss	RMSE
현미경 이미지	압축강도	Model_R	0.007485	5.20 (Mpa)
		Model_A	0.008035	5.39 (Mpa)
	공극률	Model_R	0.007862	1.53 (%)
		Model_A	0.010089	1.73 (%)
	염회물 확산계수	Model_R	0.019023	1.73E-12 (m ² /s)
		Model_A	0.019626	1.75E-12 (m ² /s)
DSLR 이미지	압축강도	Model_R	0.005884	3.54 (Mpa)
		Model_A	0.007226	3.92 (Mpa)
	공극률	Model_R	0.004443	1.15 (%)
		Model_A	0.006086	1.34 (%)
	염회물 확산계수	Model_R	0.008035	1.48E-12 (m ² /s)
		Model_A	0.007485	1.73E-12 (m ² /s)

- 1차년도에 콘크리트 성능평가 알고리즘의 유효성을 검토하기 위하여 1차적으로 수집한 압축강도 성능 지표와 이미지로 실험된 DCNN 예측성능 결과와 비교한 결과, <표 14>와 같은 결과를 확인하였다.


<표 14> 압축강도 예측 1차 2차 실험 결과 비교

입력 데이터	이미지 크기	모델명	1차 실험 결과		2차 실험 결과	
			Test Loss	RMSE	Test Loss	RMSE
현미경 이미지	84x84	Model_A	0.01014	4.64	0.008035	5.39
		Model_R	0.00971	4.54	0.007485	5.20
DSLR 이미지	84x84	Model_A	0.00688	3.82	0.007226	3.92
		Model_R	0.005966	3.56	0.005884	3.54

- 1차 실험을 통해 수집된 데이터만을 기반으로 실험한 에러값(RMSE) 결과와 2차 실험 데이터를 추가 수집하여 알고리즘을 적용한 결과, 압축강도의 에러값(RMSE)은 Model_R 기준 (1) 현미경 이미지: 4.54(MPa) → 5.20(MPa)을 기록 하였으며, (2) DSLR 이미지 3.56(MPa) → 3.54(MPa)를 기록하였다. 현미경 이미지 데이터의 경우, 학습할 수 있는 데이터의 수를 증가시켰음에도 불구하고, 에러값(RMSE)이 높아짐을 확인하였고, DSLR 이미지 데이터의 경우 에러값(RMSE)이 불과 0.02만큼 감소하였음을 확인하였다. 이는 결과적으로 단순히 이미지를 추가하여 학습한다 할지라도 콘크리트 성능을 예측하는데 큰 영향을 주지 않는다고 판단할 수 있다.
- 따라서 이러한 알고리즘의 정확도를 개선하기 위하여, 본 연구에서는 알고리즘 학습시 콘크리트 성능에 대한 단일 정보만을 학습하는 것이 아니라, 복합 정보를 동시에 학습함으로써, 콘크리트 하나의 이미지에 대한 속성(Label)값을 확장시키는 방안 고안하였다. 그 결과, 콘크리트 성능 예측을 위한 DCNN 기반의 통합 모델을 개발하였으며, 실험 결과 값은 다음 <표 15>와 같다.

<표 15> 개별 모델 대비 통합 모델의 콘크리트 성능 예측 결과

입력 데이터	성능지표		모델명	Test Loss	RMSE
현미경 이미지	압축강도		Model_R	0.007485	5.20 (Mpa)
			Model_A	0.008035	5.39 (Mpa)
	공극률		Model_R	0.007862	1.53 (%)
			Model_A	0.010089	1.73 (%)
	통합모델 (압축강도 + 공극률)	압축강도	Integrated_Model_R	0.014672	5.08 (Mpa)
			Integrated_Model_A	0.015745	5.24 (Mpa)
		공극률	Integrated_Model_R	0.014672	1.50 (%)
			Integrated_Model_A	0.015745	1.56 (%)
DSLIR 이미지	압축강도		Model_R	0.005884	3.54 (Mpa)
			Model_A	0.007226	3.92 (Mpa)
	공극률		Model_R	0.004443	1.15 (%)
			Model_A	0.006086	1.34 (%)
	통합모델 (압축강도 + 공극률)	압축강도	Integrated_Model_R	0.009577	3.41 (Mpa)
			Integrated_Model_A	0.010994	3.62 (Mpa)
		공극률	Integrated_Model_R	0.014672	1.10 (%)
			Integrated_Model_A	0.015745	1.20 (%)



<그림 21> 개별 모델 대비 통합 모델 성능 예측 정확도

- <그림 18>과 같이 개별 모델에 비해 통합 모델의 에러값(RMSE)이 줄어들면서 성능이 모두 향상되었음을 확인하였다. 이러한 결과는 향후 DCNN 기반의 콘크리트 성능을 평가하는데 있어, 하나의 정보만을 학습하여 평가하는 방식에 비해 다양한 정보를 입력함으로써 학습효과를 향상시키는 것이 콘크리트의 성능 평가 시스템의 정확도를 향상시킬 수 있는 방안으로써 제안될 수 있다. 또한, 본 연구의 결과를 바탕으로 콘크리트 배합비율 혹은 콘크리트 시설물의 사용연수 등 다양한 정보와 결합하여 알고리즘을 확장한다면 본 시스템의 활용도가 더욱 높아질 것으로 사료된다.

3) 외부실험자료를 이용한 사진판독형 콘크리트 성능 평가 프로그램 검증

(1) 외부 실험자료를 활용한 콘크리트 성능 평가 프로그램 정확도 검증

- 본 연구의 실험 결과를 바탕으로 외부 실험자료(콘크리트 이미지)를 입력하여 성능을 평가할 경우 얼마나 정확한 결과를 나타내는지 검토하였다. 여기서 외부 실험데이터라 함은 알고리즘을 개발하는 과정(Training/Validation/Test)에서 활용되는 데이터 이외에 독립적으로 수집한 데이터를 말한다. 외부 실험 데이터 수는 총 17,365개의 데이터를 확보하였으며, 각 성능에 대한 데이터 수는 <표 16>와 같다.

<표 16> 콘크리트 성능 평가 프로그램 검증을 위한 외부 실험 자료 데이터 수

데이터 수 수집 장비	외부 실험 자료		총계
	DSLIR	현미경	
압축강도	4,279	1,928	6,207
공극률	4,279	1,928	6,207
염화물확산계수	3,595	1,356	4,951
총계	12,153	5,212	17,365

- 외부 실험 자료를 바탕으로 콘크리트 성능 평가 프로그램을 검증하기 위해 앞서 개발된 알고리즘 중 가장 성능이 뛰어난 모델인 Model_R과 Integrated_Model_R을 활용하여 검증하였다. 프로그램 검증 결과는 <표 17>와 같다.

<표 17> 콘크리트 성능 평가 프로그램 검증 결과

입력 데이터	성능지표		모델명	RMSE
현미경 이미지	압축강도		Model_R	7.02 (Mpa)
	공극률		Model_R	2.27 (%)
	통합모델 (압축강도+공극률)	압축강도	Integrated_Model_R	6.89 (Mpa)
		공극률	Integrated_Model_R	2.23 (%)
DSLIR 이미지	압축강도		Model_R	7.61 (Mpa)
	공극률		Model_R	3.01 (%)
	통합모델 (압축강도+공극률)	압축강도	Integrated_Model_R	7.57 (Mpa)
		공극률	Integrated_Model_R	2.87 (%)

- 검증 결과, 외부 실험 자료는 알고리즘을 개발하는데 활용되지 않은 독립적인 데이터이므로, 알고리즘 성능 테스트(Test)를 위해 검증된 시스템 정확도에 비해 현저히 낮은 정확도를 나타내고 있다. 이는 향후 본 시스템의 실용화를 위해서는 다양한 환경에서 수집된 데이터를 바탕으로 시스템이 학습될 필요성을 나타낸다. 딥러닝 기반 이미지 분석 기술은 다양한 형태의 이미지를 대량으로 학습할수록 정확도가 높아지는 장점이 있으므로, 향후에는 다양한 환경에서 수집된 이미지를 바탕으로 알고리즘을 갱신하여 성능을 개선할 필요가 있을 것으로 사료된다.

(2) 기존 연구와 DCNN기반 콘크리트 성능 평가 알고리즘 정확도 비교

- 콘크리트 성능을 평가하기 위해 기존에 수행된 연구 결과 비교한 결과 본 연구과제에서 제안한 DCNN 기반 성능 평가 기법은 학술적으로 충분히 유효한 결과를 나타내고 있음을 보여준다.

<표 18> 다양한 모델에 따른 DCNN 예측 성능 결과

저자	방법론	알고리즘	입력 데이터	RMSE
Chen et al. (Chen et al. 2017)	NDT	Regression	Rebound hammer test value	4.90
			Ultrasonic pulse velocity test value	4.90
Rashid & Waqas (Rashid and Waqas 2017)	NDT	Regression	Rebound hammer test value	12.4
			Ultrasonic pulse velocity test value	37.9
Yaseen et al. (Yaseen et al. 2018)	Machine learning	SVM	Concrete cement	4.35
			Concrete oven dry density	3.57
			Concrete water/binder	4.00
			Concrete foam	3.33
	Machine learning	M5 Tree	Concrete cement	3.30
			Concrete oven dry density	2.17
			Concrete water/binder	6.84
			Concrete foam	2.29
	Machine learning	MARS	Concrete cement	3.68
			Concrete oven dry density	1.37
			Concrete water/binder	6.41
			Concrete foam	3.57
	Machine	ELM	Concrete cement	3.25


Proposed Methods	learning		Concrete oven dry density	1.06
			Concrete water/binder	3.80
			Concrete foam	1.48
	DCNN	Model_A	Concrete Surface Digital Image	3.82
	DCNN	Model_G	Concrete Surface Digital Image	3.64
	DCNN	Model_R	Concrete Surface Digital Image	3.56

- Chen et al.(2017)이 발표한 연구에서는 슈미트 해머법과 초음파 시험법을 이용하여 콘크리트 성능을 예측하는데 RMSE 값 4.90을 기록하였다. Yaseen et al.(2017)은 Machine Learning 기법의 다양한 알고리즘을 활용하여 콘크리트 성능을 예측하였으며, 그 에러값(RMSE)은 1.48부터 6.84까지 다양한 분포를 나타내는 등 높은 정확도를 나타내고 있으나, 학습하는데 필요한 데이터가 시멘트, 건조도, 물시멘트비, 거푸집 정보가 필요한 단점이 있다. 이는 이미 시공된 콘크리트의 경우 해당 정보를 확인할 수 있는 방법이 제한적이므로, 시설물을 유지관리하기 위한 목적으로 활용되기엔 한계점을 지니고 있다.
- 그러나 본 연구에서 제안하는 DCNN 기반 콘크리트 성능 예측 시스템은 콘크리트 표면 이미지만으로 성능을 예측하기 때문에 데이터를 수집하는데 보다 용이한 장점이 있으며, <표 18>에 나타난 결과와 같이 에러값(RMSE)이 기존 연구보다 훌륭한 성능을 나타내고 있으므로, 본 연구에서 개발한 시스템이 기존 시스템과 비교하였을 때 개선된 시스템이라 할 수 있다.

4) 콘크리트 시설물 유지관리 활용을 위한 최적 사진판독 프로세스


(1) DCNN 기반 콘크리트 평가 시스템의 시설물 종합평가 적용 방안

- 본 연구과제는 콘크리트 시설물 정밀점검 및 진단 프로세스의 비효율성과 시설물 성능 평가 기술을 개선함에 있어 콘크리트 시설물 열화정도 및 성능평가 시스템에 ICT 분야의 혁신적인 기술인 딥러닝(Deep Learning) 기술을 접목하였다. 건설 기술 분야에서는 다루어지지 않던 딥러닝(Deep Learning) 기술은 기존의 성능평가 프로세스를 단순화하고 시설물 성능평가 시스템에 대한 신개념 융·복합 산업을 선도할 수 있는 발판을 마련하였다. 이는 급격히 증가할 것으로 예상되는 노후된 콘크리트 시설물을 효율적으로 관리하는데 있어 콘크리트 성능평가 프로세스를 간소화하고 신속한 의사결정을 지원할 수 있는 기초·원천 기술로써, 향후 국가적 차원의 Database를 구축하여 알고리즘을 적용한다면 실용화 기술로 충분히 활용될 수 있을 것이라 판단된다.
- 시설물 종합 평가 결과 산정절차는 시설물별로 다소 차이가 있지만, 대표적으로 <그림 19>와 같은 평가절차를 따르고 있으며, 전반적으로 외관조사에 따른 상태평가 결과와 안전성 평가 결과 중 낮은 결과를 시설물의 종합평가 결과로 결정한다.



<그림 22> 시설물의 종합평가 결과 산정 절차

- 본 연구의 결과물로 제안하는 콘크리트 상태 평가 시스템은 <그림 19> 절차 중 외관상태 평가에 해당하는 1)개별부재의 상태평가, 2)결함종류별 결과산정, 3)결함종류별로 산정된 결과 산술평균, 4)개별부재상태결과 결정(a-e) 과정에서 활용될 수 있을 것이라 판단된다.
- 현재 「시설물 안전관리체계 종합개선대책 수립 연구」에 따르면, 1·2종 시설물에 대한 안전점검 흐름도는 <그림 20>과 같으며, 점검 종류에 따라 본 연구에서 구현한 DCNN기반 성능 평가 시스템은 <표 19>에 명시된 시설물 점검 방법 중 정밀점검, 긴급점검, 정밀안전진단 시 구조물의 성능을 평가하는데 추가적인 시험수단으로 적용할 수 있을 것으로 판단된다.



<그림 23> 2종 시설물에 대한 안전점검 흐름도

<표 19> 시설물 점검 종류 및 점검 사항

구분	수행 시기	설명	점검 사항	적용
정기 점검	A,B,C 등급 : 2회/년 D,E 등급 : 3회/년	경험과기술을 갖춘 사람에 의한 세심한 외관조사 수준의 점검으 로서 시설물의 기능적 상태를 판 단하고 시설물이 현재의 사용요 건을 계속 만족시키고 있는지 확 인하기 위한 관찰	용도변경, 구조부재 변경, 주변조건 변경, 균열발생 현황, 누수·백태현 황, 철근노출 및 부식 상태, 강재구 조 노후상태, 마감재 상태	
정밀 점검	3년에 1회	시설물의 현 상태를 정확히 판단 하고 최초 또는 이전에 기록된 상태로부터의 변화를 확인하며 구조물이 현재의 사용요건을 계 속 만족시키고 있는지 확인하기 위하여 면밀한 외관조사와 간단	- 주요부재의 외관조사(육안검사) - 콘크리트 균열, 누수, 박리, 박락, 층분리, 백태, 철근 노출 - 강재균열 및 도장, 부식상태 - 간단한 비파괴 현장시험 - 반발경도시험	✓

		한 측정·시험장비로 필요한 측정 및 시험을 실시	- 탄산화시험	
긴급 점검	관리주체 필요시 또는 관계기관 장의 요청시	관리주체가 피요하다고 판단한 때 또는 관계행정기관의 장이 필요하다고 판단하여 관리주체에게 요청한 때에 실시하는 정밀점검 수준의 안전점검이며 실시목적에 따라 손상점검과 특별점검으로 구분하여 실시	정밀점검 수준의 점검	✓
정밀 안전 진단	정밀점검 또는 긴급점검 결과에 따라 실시	안전점검으로 쉽게 발견할 수 없는 결함부위를 발견하기 위하여 정밀한 외관조사와 각종 측정·시험장비에 의한 측정·시험을 실시하여 시설물의 상태평가 및 안전성평가에 필요한 데이터를 확보	- 전체부재의 외관조사(육안검사) 및 외관조사망도 작성 - 콘크리트 균열, 누수, 박리, 박락, 층분리, 백태, 철근노출 - 강재균열 및 도장, 부식상태 - 비파괴 현장시험 - 콘크리트 비파괴 시험 - 강재 비파괴 시험	✓

<표 20> 정밀 점검 및 정밀 안전진단 세부 점검 사항

대분류	중분류	중요도	소분류	중요도	평가항목	
정밀 점검	부재 상태 및 내구성	0.7	콘크리트강도	*	압축강도	
			균열	*	균열폭, 면적율	
			콘크리트탄산화	*	탄산화깊이	
			표면노후화	*	박리	최소값
					박락 및 층 분리	
					누수 및 백태	
					철근노출	
변위 · 변형	0.7	기울기	0.9	건물기울기		
		기초침하	0.9	부동침하기울기		
정밀 안전 진단	안전성 평가	0.9	내력벽	0.9	내력비	
			슬래브	0.5	내력비	
	상태 평가	0.7	콘크리트강도	*	콘크리트압축강도	
			균열	*	균열크기, 균열면적	
			콘크리트탄산화	*	탄산화	
			염화물함유량	*	염화물	
			철근부식	*	철근부식	
			표면노후	*	박리	최소값
				*	박락 및 층 분리	
				*	누수 및 백태	
	*	철근노출				
	변위 · 변형	0.7	기울기	0.9	건물기울기	
			기초침하	0.9	부동침하기울기	

* 내구성계수표 적용항목

- <표19> 명시된 바와 같이 정밀점검 (긴급점검) 및 정밀안전진단 시 부재 상태 및 내구성 평가에 있어 콘크리트 강도와 염화물 함유량에 대한 평가가 이루어지게 되어 있음을 확인할 수 있다.
- 본 연구의 결과물로서 제안된 콘크리트 상태 평가 시스템은 콘크리트의 성능 중 1)압축강도, 2)염화물 확산계수, 3)공극률을 평가할 수 있는 시스템으로써 콘크리트 내구성과 관계성이 높은 성능지표를 측정할 수 있다는 점은 시설물 종합 평가를 수행하는데 있어 새로운 평가 방법으로써 활용될 수 있음을 시사한다.

(2) 시설물 유지관리를 위한 DCNN기반 콘크리트 성능 평가 프로세스

① 기존 프로세스

- 콘크리트 시설물 유지관리를 위해 기존의 프로세스를 분석하고, 본 연구에서 제안하는 프로세스와 비교하였다. 기존의 콘크리트 성능 평가 방법은 크게 파괴 방식과 비파괴 방식으로 구분된다. 파괴 방식인 코어 채취법의 경우 통해 성능평가가 요구되는 시설물을 대상으로 코어를 채취한 후, 압축강도 테스트 및 탄산화 깊이 등을 측정하게 된다. <표 20, 21>

<표 21> 코어 채취법

개요	▪ 벽체에 코어채취기를 이용하여 공시체를 채취한 후, 압축시험기로 압축강도시험을 하여 콘크리트의 성능을 평가하는 방법																	
시험방법	▪ 구조물에 손상이 없도록 채취 위치 및 수량 선정 ▪ 코어채취기를 이용하여 공시체를 채취한다. ▪ 공시체를 지름의 1% 이내의 오차에서 그 중심축이 가압판의 중심과 일치하도록 놓는다. ▪ 시험기의 가압판과 공시체의 끝면은 직접 밀착시키고 그 사이에 쿠션재를 넣어서는 안된다. ▪ 공시체에 충격을 주지 않도록 똑같은 속도로 하중을 가한다. 하중을 가하는 속도는 압축응력도의 증가율이 매초 0.6 ± 0.4 MPa가 되도록 한다. ▪ 공시체가 급격한 변형을 시작한 후에는 하중을 가하는 속도의 조정을 중지하고 하중을 계속 가한다. ▪ 공시체가 파괴될 때까지 시험기가 나타내는 최대하중을 유효숫자 3자리까지 읽는다. ▪ 코어 공시체의 압축강도시험방법은 KS F 2405에 따른다. 다만, 공시체의 높이가 그 지름의 2배보다 작은 경우에는 시험에서 얻어진 압축강도에 보정계수를 곱하고 지름의 2배 높이를 가진 공시체의 강도로 환산한다.																	
절차	코어 채취 위치 및 수량 선정 ↓ 코어채취기를 이용한 공시체 절취 ↓ KS F 2405에 의한 압축강도시험 실시 ↓ 얻어진 압축강도에 보정계수 계산 ↓ 압축강도 산정 <코어 채취법 흐름도>																	
보정방법	▪보정계수 <table><tr><th>높이와 지름의 비 h/d</th><th>보정계수</th><th>비고</th></tr><tr><td>2.00</td><td>1.00</td><td rowspan="4">- h/d 가 이 표에 나타내는 값의 중간에 있을 경우, 보정계수는 보간법으로 구한다.</td></tr><tr><td>1.75</td><td>0.98</td></tr><tr><td>1.50</td><td>0.96</td></tr><tr><td>1.25</td><td>0.93</td></tr><tr><td>1.00</td><td>0.89</td><td>- 높이가 지름의 2배보다 작을 경우 보정계수를 적용</td></tr></table>			높이와 지름의 비 h/d	보정계수	비고	2.00	1.00	- h/d 가 이 표에 나타내는 값의 중간에 있을 경우, 보정계수는 보간법으로 구한다.	1.75	0.98	1.50	0.96	1.25	0.93	1.00	0.89	- 높이가 지름의 2배보다 작을 경우 보정계수를 적용
높이와 지름의 비 h/d	보정계수	비고																
2.00	1.00	- h/d 가 이 표에 나타내는 값의 중간에 있을 경우, 보정계수는 보간법으로 구한다.																
1.75	0.98																	
1.50	0.96																	
1.25	0.93																	
1.00	0.89	- 높이가 지름의 2배보다 작을 경우 보정계수를 적용																

<표 22> 슈미트 해머 (반발경도 시험법)

개요	- 표면의 반발경도를 측정하여, 콘크리트의 압축강도를 추정하는 검사방법 - 슈미트해머는 경화된 콘크리트 표면을 타격시, 반발도(R)와 콘크리트의 압축강도(f_c)와의 사이에 특정 상관관계가 있다는 실험적 경험을 기초로 한다.																																																																
시험방법	- 반발경도 측정은 선정된 부위에 그라인딩 작업으로 표면 정리를 한 다음 타격점 상호간의 종·횡 간격을 30mm기준으로 그어 직교되는 부위에 20점 이상을 타격하여 반발경도 값의 산술 평균값을 구하고, 각 반발경도 값이 평균값의 $\pm 20\%$ 범위를 벗어나는 값들은 제외시키고 나머지 값들을 다시 산술평균하여 반발경도를 결정 - 보-기둥의 모서리에서는 최소 30~60mm 이격 하고, 측정부재의 최소두께는 반발도의 영향을 고려하여 100mm이상을 원칙으로함 - 측정치는 원칙적으로 정수값을 읽고, 표면 건조상태의 부위를 선정, 측정하여 건습에 따른 보정, 압축응력에 따른 반발도의 보정과 타격 방향에 대한 보정 및 재령에 따른 보정을 적용함.																																																																
절차	기종 선정 ↓ 점검기에 의한 정도확인 ↓ 측정 장소의 확인. 요철 제거 ↓ Marker 등에 의한 측정점의 표시 ↓ 측정, 20점 이상의 평균 ↓ 타격 방향, 습윤 및 재령의 보정 ↓ 강도추정식에 의한 압축강도 산출 ↓ 압축강도의 추정 <반발경도법에 의한 강도추정 흐름도>																																																																
보정방법	- 타격방향에 따른 보정($\Delta R1$)<table><tr><th rowspan="2">반발경도(R)</th><th colspan="4">수평과 이루는 각도</th><th rowspan="2">비고</th></tr><tr><th>+ 90°</th><th>+ 45°</th><th>- 45°</th><th>- 90°</th></tr><tr><td>10</td><td>-</td><td>-</td><td>+ 2.4</td><td>+ 3.2</td><td rowspan="3">상향수직 : + 90°</td></tr><tr><td>20</td><td>-5.4</td><td>-3.5</td><td>+ 2.5</td><td>+ 3.4</td></tr><tr><td>30</td><td>-4.7</td><td>-3.1</td><td>+ 2.3</td><td>+ 3.1</td></tr><tr><td>40</td><td>-3.9</td><td>-2.6</td><td>+ 2.0</td><td>+ 2.7</td><td rowspan="3">하향수직 : - 90°</td></tr><tr><td>50</td><td>-3.1</td><td>-2.1</td><td>+ 1.6</td><td>+ 2.2</td></tr><tr><td>60</td><td>-2.3</td><td>-1.6</td><td>+ 1.3</td><td>+ 1.7</td></tr></table> - 콘크리트 재령에 따른 보정(α)<table><tr><th>구분</th><th>7일</th><th>14일</th><th>21일</th><th>28일</th><th>100일</th><th>500일</th><th>750일</th><th>1000일</th><th>2000일</th><th>3000일</th></tr><tr><td>재령</td><td>1.7 2</td><td>1.36</td><td>1.1 2</td><td>1.0 0</td><td>0.78</td><td>0.67</td><td>0.66</td><td>0.65</td><td>0.64</td><td>0.63</td></tr></table> $R_o = R + \Delta R1$ 여기서, $\Delta R1$: 타격방향에 따른 보정 값	반발경도(R)	수평과 이루는 각도				비고	+ 90°	+ 45°	- 45°	- 90°	10	-	-	+ 2.4	+ 3.2	상향수직 : + 90°	20	-5.4	-3.5	+ 2.5	+ 3.4	30	-4.7	-3.1	+ 2.3	+ 3.1	40	-3.9	-2.6	+ 2.0	+ 2.7	하향수직 : - 90°	50	-3.1	-2.1	+ 1.6	+ 2.2	60	-2.3	-1.6	+ 1.3	+ 1.7	구분	7일	14일	21일	28일	100일	500일	750일	1000일	2000일	3000일	재령	1.7 2	1.36	1.1 2	1.0 0	0.78	0.67	0.66	0.65	0.64	0.63
반발경도(R)	수평과 이루는 각도				비고																																																												
	+ 90°	+ 45°	- 45°	- 90°																																																													
10	-	-	+ 2.4	+ 3.2	상향수직 : + 90°																																																												
20	-5.4	-3.5	+ 2.5	+ 3.4																																																													
30	-4.7	-3.1	+ 2.3	+ 3.1																																																													
40	-3.9	-2.6	+ 2.0	+ 2.7	하향수직 : - 90°																																																												
50	-3.1	-2.1	+ 1.6	+ 2.2																																																													
60	-2.3	-1.6	+ 1.3	+ 1.7																																																													
구분	7일	14일	21일	28일	100일	500일	750일	1000일	2000일	3000일																																																							
재령	1.7 2	1.36	1.1 2	1.0 0	0.78	0.67	0.66	0.65	0.64	0.63																																																							
압축강도 추정식	- 방법 1 : $F_c = (-18.0 + 1.27 \times R_o) \times \alpha$ (MPa) $\Rightarrow$ 일본재료학회 추정식 - 방법 2 : $F_c = \{(7.3R_o + 100) \times 0.098\} \times \alpha$ (MPa) $\Rightarrow$ 일본건축학회 추정식 - 방법 3 : $F_c = (2.304R_o - 38.80) \times \alpha$ (MPa) $\Rightarrow$ 권영웅외 추정식 - 방법 4 : $F_c = \{(15.2R_o - 112.8) \times 0.1\} \times \alpha$ (MPa) $\Rightarrow$ 일본건축학회 추정식																																																																

- 그러나 콘크리트 시편을 직접 채취하여 실험을 통해 상태를 평가하는 코어 채취법은 장비와 인력이 많이 투입되고 비용이 많이 소모되며, 시설물을 파괴할 뿐만 아니라 내부에 배근된 철근이 절단되거나 부식될 수 있어 안전상에 문제가 지적되고 있다. 이러한 문제점을 해결할 수 있는 방안으로 대상 구조물의 성능평가 시 구조물의 피해를 최소화할 수 있는 비파괴 시험방법이 개발되었으며 현재까지 널리 활용되고 있는 방법이다. 비파괴 방식의 경우, <표 22>에 설명된 슈미트 해머법 (반발경도 시험법)등을 활용하여 성능을 추정하고, 학계에서 제시하고 있는 추정식을 적용하여 성능을 평가하게 된다. 그러나 평가 절차가 복잡하고 추정식에 따라 결과가 상이하게 나올 수 있는 단점이 존재한다.

② 제안된 프로세스

- 본 연구에서 제안한 DCNN 기반 사진판독형 콘크리트 성능 시스템은 기존의 복잡한 성능평가 절차와 달리 이미지만을 수집하여 콘크리트 시설물의 성능을 평가할 수 있는 장점을 갖추고 있으며, 본 연구의 실험 결과에 근거하여 평가 방법을 제안하였다.

<표 23> DCNN을 활용한 콘크리트 상태 평가 방법

개요	▪ 콘크리트 표면 이미지를 활용하여 콘크리트의 성능(압축강도, 염화물 확산계수, 공극률)을 예측하는 방법
시험방법	▪ 디지털 카메라 (성능 4K)을 준비하고 표면으로부터 약 15mm 이격하여 이미지를 촬영 ▪ 수집된 데이터를 서버에 전송하여 DCNN 알고리즘에 인풋데이터로 입력 ▪ 콘크리트 성능(압축강도, 염화물 확산계수, 공극률)을 예측
절차	<pre> graph TD A[사진 촬영 위치 선정] --> B[콘크리트 그라인더 활용 표면 처리] B --> C[데이터 수집 및 전송] C --> D[DCNN 알고리즘 활용한 콘크리트 성능 예측] </pre> <DCNN을 활용한 콘크리트 상태 평가 방법 흐름도> 

다. 결 론

- 국내 콘크리트 건축물의 노후화가 진행됨에 콘크리트의 내구성 평가에 대한 중요성이 증대되고 있다. 콘크리트 내구성을 평가하는 기본적인 지표 중 하나인 압축강도는 현장에서 코어 채취, 비파괴 검사 등을 통해 측정하고 있으나 시설물의 안전문제, 고비용, 낮은 신뢰성 등의 문제점을 가지고 있다. 최근 들어 영상 처리 기법을 적용한 연구들이 진행되고 있으나, 콘크리트 특징 추출에 있어 한계를 가진다. 이에 본 연구에서는 심층 컨볼루션 신경망을 활용하여 영상 기반 콘크리트 압축강도 예측 모델을 제안하고, 실험실 환경에서 구축한 콘크리트 압축강도 데이터셋을 적용하여 그 유효성을 확인하였다.
- 본 연구는 딥 러닝 기술을 활용하여 영상으로 콘크리트 압축강도를 예측할 수 있는 방법을 제안함으로써 시설물 유지관리 분야에 적용 가능한 새로운 기술의 가능성을 제시하였다. 본 연구에서 제안한 콘크리트 압축강도 예측 모델은 딥 러닝 기술의 활용을 통해 기존에 알려진 콘크리트 압축강도에 영향을 미치는 특성뿐만 아니라 고차원의 특성을 추출함으로써 예측 정확도를 향상시킬 수 있을 것으로 기대된다. 또한 콘크리트 표면 영상만으로 장소의 제한 없이 압축강도를 진단함으로써 시설물 유지관리에 드는 시간과 비용 감소에 기여할 수 있을 것이다. 그러나 본 연구는 심층 컨볼루션 신경망을 활용하여 영상을 통해 콘크리트 압축강도 예측이 가능한지 여부를 확인하는데 목적을 가지고, 실험실 환경에서 제작한 콘크리트 시편만을 대상으로 학습, 검증, 테스트를 진행했다는 점에서 한계를 가진다. 향후 연구에서는 실제 노후화된 콘크리트 시설물을 바탕으로 빅데이터를 구축하고, GoogleNet, ResNet 등과 같은 다양한 심층 컨볼루션 신경망 모델을 활용하여 예측 성능을 개선해야할 것이다.

가. 당해연차 세부 연구 내용 (DCNN 기반 콘크리트 시설물 특성별 성능평가 알고리즘 설계)

- DCNN 알고리즘을 학습하기 위해서는 우선 알고리즘의 입력과 출력 그리고 입출력을 정의한 후 layer 수, convolutional layer, fully connected layer 등의 layer type과 각 layer의 filter size, filter 수 등의 DCNN의 세부 구조를 설계해야 한다. 같은 데이터를 이용하더라도 DCNN의 입력과 출력을 어떻게 정의하느냐에 따라서 알고리즘의 성능이 달라진다. 입력으로는 본 연구에서는 두 가지 센서 데이터를 사용함으로 이미지의 입력 사이즈, 전처리, 증폭 등으로 입력을 정의할 수 있고, 출력 타입으로는 실측 값을 그대로 타겟 값으로 사용하거나, 각종 normalization, 또는 카테고리 형태로 변형하여 사용할 수 있다. 따라서, 구축된 USB 현미경 데이터베이스와 DSLR 데이터베이스를 가지고 압축강도, 공극률, 염화물 확산 계수를 예측 알고리즘을 생성하기 위해서는 DCNN의 입력과 출력을 정의가 선행 되어야 한다.
- 본 연구에서는 DCNN을 학습시키기 위해 사용되는 입출력데이터에 대한 검증을 실시하였다. 첫째로 USB 현미경, 디지털 카메라와 같이 다른 센서로부터 생성된 입력데이터를 가지고 네트워크를 학습시켰을 때 어떤 센서로부터 생성된 데이터가 압축강도, 공극률 그리고 염화물 확산 계수 예측과 관련하여 각각 단일 실험을 진행 하였다. 둘째로 압축강도와 공극률을 통합한 통합모델을 만들어 기존 단일 모델에 비해 정확도를 향상시키는 실험을 진행하였다.




그림6. DCNN의 입출력의 예

1) 데이터 셋

- 본 연구에서는 노후화된 콘크리트 시설물의 압축강도를 측정함에 있어 파괴강도시험법과 비파괴시험법을 대체할 방법으로 최근 영상처리 기술을 이용한다. 영상 처리를 통한 콘크리트 압축강도 예측은 특징 추출, 특징 선택, 후처리 등의 순서로 진행되어 왔고, 이 중에서도 특징 추출이 가장 중요하고 어려운 부분이었다. 앞서 언급하였듯이 콘크리트는 다상재료로써 골재, 시멘트 수화 생성물, 공극 등의 복잡한 공간적 분포 상태에 의해 압축강도가 영향을 받는다. 구성 재료들이 불균질하고, 불규칙적인 형상을 가지기 때문에 연구자가 압축강도에 영향을 주는 모든 특징을 추출하는데 한계가 존재한다. 이러한 한계점을 극복하기 위해 현재 예측분야에서 뛰어난 성능을 보여주고 있는 심층 컨볼루션 신경망을 활용하고자 한다. 이를 위해 실험실 환경에서 제작한 콘크리트 시편의 영상과 사진을 촬영하고, 시험을 통해 압축강도, 공극률, 염화물 확산 계수를 산출한 후, 촬영한 데이터에 산출한 압축강도, 공극률, 염화물 확산 계수를 레이블링하여 모델을 학습시켰다. 본 연구에서 콘크리트 시편의 동영상 촬영을 통해 획득한 영상 데이터는 화질이 많이 흔들림으로 인해 학습데이터로 사용하기 어려운 문제가 발생하였다. 따라서 동영상에서 구축한 영상 데이터 셋을 사전학습 (pre-training)에 사용하였다. 이때 학습을 위한 연산량이 많아지고, 과하게 학습하여 실제 데이터에 대해 오차가 증가하는 과적합을 방지하기 위해 영상 학습 시에도 사진 촬영분 데이터 48개와 동영상 추출분 데이터 4개, 총 52개를 미니배치 (mini batch)로 사용하여 학습을 진행하였다. 마지막으로 동영상으로 촬영한 이미지 중 일부를 테스트 데이터 셋으로 설정하였고 이를 이용하여 압축강도와 공극률 모델의 성능을 테스트 하였다.

- 사진으로 구축된 데이터 셋은 USB 현미경과 DSLR 카메라 두 가지 센서로부터 획득한 것이다. 그림7에서와 같이 DSLR 카메라로부터 얻은 이미지의 사이즈는 6000 x 3376 이고, 이를 256 x 256으로 변환 시켰다. USB현미경으로부터 얻은 이미지의 사이즈는 640 x 480 에서 256 x 256으로 변환 시켰다. (이미지의 성능은 DSLR 이미지의 경우는 4096 x 2160 이지만, 실제 이미지 사이즈는 6000 x 3376 이다. USB 현미경 데이터는 1920 x 1080 이지만, 실제 이미지 사이즈는 640 x 480 이다.)

DSLR 	• 이미지 : 약 2,430만 화소 (4K: 4,096 x 2,160) • 센 서 : Exmor APS HD CMOS 센서 • 렌즈 : 렌즈 전면에서 피사체까지의 최단 작업 거리 2.4cm / 최소 초점 거리 9.5cm	Size : 약 2.5 X 1.5 
USB 현미경 	• 배 율 : 10 ~ 200배 • 포커스 : 수동포커스 • 이미지 : 약 200만 화소 (FHD - 1,920 x 1,080) • 이미지 센서 : 3M pixel	Size : 약 0.9 X 0.5 

그림7. 콘크리트 표면 사진 촬영 설명


		
압축강도: 20.78 공극률: 23.20	압축강도: 20.81 공극률: 22.26	압축강도: 21.52 공극률: 17.21
		
압축강도: 29.00 공극률: 18.30	압축강도: 30.56 공극률: 18.79	압축강도: 34.55, 공극률: 16.70
		
압축강도: 45.38 공극률: 12.26	압축강도: 49.78 공극률: 14.02	압축강도: 51.40 공극률: 12.02

그림 8. USB 현미경 데이터의 예시, 이미지(256 x 256)와 압축강도, 공극률

		
염화물확산계수: 1.06E-11	염화물확산계수: 3.14E-12	염화물확산계수: 3.36E-12
		
염화물확산계수: 3.99E-12	염화물확산계수: 5.97E-12	염화물확산계수: 6.26E-12
		
염화물확산계수: 6.53E-12	염화물확산계수: 8.38E-12	염화물확산계수: 9.76E-12

그림9. USB 현미경 데이터의 예시, 이미지(256 x 256)와 염화물 확산 계수 이미지

- 그림 8, 그림9 는 각각 USB 현미경을 통해 획득한 압축강도 와 공극률, 염화물 확산 계수의 이미지 와 해당 값을 표현 하였다. 원본 이미지들의 사이즈는 640x480 이며 256 x 256 로 축소한 이미지이다. 그림8, 그림9에서 확인 할 수 있듯이 사람의 육안만으로는 이미지의 압축강도, 공극률 그리고 염화물 확산 계수를 예측하는데 한계가 있다. 데이터 베이스에는 jpg 이미지와 별도의 동영상 데이터가 존재 한다. 동영상 데이터는 흔들림으로 인한 화질 문제로 DCNN을 사진 이미지와 같이 학습하는데 이용되었다. 각 이미지들을 train, validation, test 데이터 셋으로 구분하여 학습을 하였고, USB 현미경 테스트 데이터의 압축강도 분포는 표2과 같다. 표2에서 확인 할 수 있듯이 압축강도의 범위는 8.89 에서 51.40 이다. 공극률의 분포는 표3과 같다. 범위는 12.01 에서 24.20 이다. 염화물 확산 계수의 분포는 표4와 같다. 범위는 1.06에서 9.92이다. 획득된 압축강도, 공극률, 염화물 확산 계수의 값들은 재령 3일, 7일, 28일, 91일 값들이다.

<표2> USB 현미경 데이터의 테스트 데이터 셋의 압축강도 분포

압축강도	비율	압축강도	비율	압축강도	비율
8.89	3	35.49	2	28.88	3
10.29	4	20.19	2	29.00	2
10.57	2	20.78	1	30.58	2
10.84	2	20.81	2	32.08	1

11.52	2	20.91	2	34.55	2
12.59	1	24.47	2	34.99	2
16.67	3	25.37	1	36.97	1
17.09	3	25.87	2	37.55	2
17.29	4	25.96	4	37.57	2
17.71	2	26.28	1	38.68	2
17.72	3	26.73	1	38.99	2
18.41	2	26.79	2	40.59	2
17.73	1	27.76	2	40.83	2
18.83	2	27.97	2	41.18	2
18.86	3	28.01	2	45.38	2
19.01	2	28.29	2	51.40	3

<표3> USB 현미경 데이터의 테스트 데이터셋의 공극률 분포

공극률	비율	공극률	비율	공극률	비율
22.17	3	17.84	2	16.89	3
23.40	4	16.87	2	18.30	2
20.31	2	23.20	1	16.27	2
20.49	2	22.26	2	17.26	1
22.54	2	20.10	2	16.70	2
21.32	1	16.55	2	16.16	2
19.89	3	20.65	1	19.06	1
19.52	3	20.13	2	15.16	2
19.03	4	17.38	4	17.95	2
20.39	2	16.35	1	14.88	2
24.20	3	17.60	1	14.30	2
17.80	2	16.76	2	13.83	2
19.03	1	19.11	2	13.56	2
16.23	2	16.17	2	13.35	2
20.20	3	18.13	2	12.26	2
19.97	2	16.48	2	12.02	3

<표4 > USB 현미경 데이터의 테스트 데이터 셋의 염화물 확산 계수 분포

염화물 확산 계수 (단위 E-12)	비율	염화물 확산 계수 (단위 E-12)	비율	염화물 확산 계수 (단위 E-12)	비율
1.06	2	4.74	1	7.09	2
1.18	2	4.88	2	7.32	2
1.20	2	5.02	2	7.33	2
2.30	2	5.39	2	7.75	2
2.34	1	5.44	2	8.19	2
2.48	2	5.50	1	8.21	2
2.58	2	5.56	2	8.38	2

2.71	3	5.59	2	8.49	2
3.07	2	5.64	2	8.52	2
3.14	2	5.75	2	8.83	2
3.37	2	5.97	2	8.85	2
3.44	1	6.26	2	8.93	2
3.63	1	6.28	2	9.02	2
3.99	2	6.46	2	9.42	2
4.17	2	6.53	2	9.76	4
4.29	2	6.73	2	9.88	2
4.47	1	6.89	2	9.92	2
4.62	2	6.99	2		

- DSLR를 통해 획득한 압축강도와 공극률의 이미지는 그림 10과 같다. 원래 이미지의 사이즈를 6000 x 3376 에서 256 x 256로 축소한 이미지들이다. 그림 11는 염화물 확산 계수의 대한 이미지이다.

		
압축강도: 20.78 공극률: 23.20	압축강도: 20.81 공극률: 22.26	압축강도: 21.52 공극률: 17.21
		
압축강도: 29.00 공극률: 18.30	압축강도: 30.56 공극률: 18.79	압축강도: 34.55 공극률: 16.70
		
압축강도: 45.38 공극률: 12.26	압축강도: 49.78 공극률: 14.02	압축강도: 51.40 공극률: 12.02

그림10. DSLR 데이터 의 예시: 이미지(256 x 256)와 압축강도, 공극률

		
염화물확산계수: 1.06E-11	염화물확산계수: 3.14E-12	염화물확산계수: 3.36E-12
		
염화물확산계수: 3.99E-12	염화물확산계수: 5.97E-12	염화물확산계수: 6.26E-12
		
염화물확산계수: 6.53E-12	염화물확산계수: 8.38E-12	염화물확산계수: 9.76E-12

그림11. DSLR 데이터의 예시: 이미지(224x224)와 염화물 확산 계수

- DSLR의 압축강도, 공극률 과 염화물 확산 계수의 테스트 데이터 셋의 범위는 표5, 표6과 같다. USB 현미경 데이터와 마찬가지로, 압축강도의 범위가 8.89에서 51.40, 공극률의 범위는 12.01에서 24.20 이다. 그리고 염화물 확산 계수의 범위는 1.06 에서 9.92까지 분포되어 있다는 것을 확인할 수 있다.

<표5> DSLR 데이터의 테스트 데이터 셋의 압축강도 분포

압축강도	비율	압축강도	비율	압축강도	비율
8.89	2	35.49	2	28.88	2
10.29	3	20.19	2	29.00	2
10.57	1	20.78	2	30.58	2
10.84	2	20.81	2	32.08	2
11.52	2	20.91	2	34.55	2
12.59	2	24.47	2	34.99	3
16.67	2	25.37	2	36.97	3
17.09	3	25.87	2	37.55	2
17.29	3	25.96	2	37.57	2
17.71	2	26.28	2	38.68	2

17.72	3	26.73	2	38.99	2
18.41	2	26.79	2	40.59	2
17.73	2	27.76	2	40.83	2
18.83	1	27.97	2	41.18	2
18.86	2	28.01	2	45.38	2
19.01	2	28.29	2	51.40	2

<표6> DSLR 데이터의 테스트 데이터 셋의 공극률 분포

공극률	비율	공극률	비율	공극률	비율
22.17	2	17.84	2	16.89	2
23.40	3	16.87	2	18.30	2
20.31	1	23.20	2	16.27	2
20.49	2	22.26	2	17.26	2
22.54	2	20.10	2	16.70	2
21.32	2	16.55	2	16.16	3
19.89	2	20.65	2	19.06	3
19.52	3	20.13	2	15.16	2
19.03	3	17.38	2	17.95	2
20.39	2	16.35	2	14.88	2
24.20	3	17.60	2	14.30	2
17.80	2	16.76	2	13.83	2
19.03	2	19.11	2	13.56	2
16.23	1	16.17	2	13.35	2
20.20	2	18.13	2	12.26	2
19.97	2	16.48	2	12.02	2

<표7>DSLR 데이터의 테스트 데이터 셋의 염화물 확산 계수 분포

염화물 확산 계수 (단위 E-12)	비율	염화물 확산 계수 (단위 E-12)	비율	염화물 확산 계수 (단위 E-12)	비율
1.06	2	4.74	1	7.09	1
1.18	1	4.88	2	7.32	1
1.20	2	5.02	2	7.33	2
2.30	3	5.39	2	7.75	1
2.34	2	5.44	2	8.19	2
2.48	2	5.50	2	8.21	2
2.58	2	5.56	2	8.38	2
2.71	3	5.59	2	8.49	3
3.07	2	5.64	2	8.52	1
3.14	2	5.75	2	8.83	2
3.37	2	5.97	2	8.85	2
3.44	2	6.26	2	8.93	2
3.63	1	6.28	2	9.02	2
3.99	2	6.46	2	9.42	2
4.17	1	6.53	2	9.76	5

4.29	2	6.73	2	9.88	1
4.47	1	6.89	2	9.92	1
4.62	2	6.99	1		

<표8>. 압축강도, 공극률 입력 데이터 셋 분포 요약

	학습데이터	검증데이터	테스트데이터	합계
USB 현미경	5514	786	1576	7876
디지털카메라	5673	801	1620	8094

<표9> 염화물 확산 계수 입력 데이터 셋 분포 요약

	학습데이터	검증데이터	테스트데이터	합계
USB 현미경	3734	532	1070	5336
디지털카메라	6524	922	1862	9308

<표10> 동영상으로 획득한 압축강도, 공극률 입력, 염화물 확산 계수 데이터 셋 분포 요약

	압축강도, 공극률	염화물 확산 계수
USB 현미경	415576	423210
디지털카메라	226455	398672




그림12. 압축강도 데이터 셋 분포표

2) 입력 데이터 크기 정의

- 이미지의 크기가 크면 정보의 양은 많아지나 curse of high dimensionality와 중복픽셀로 인하여, 학습에 오히려 방해가 될 수 있으며, 이미지의 크기를 너무 줄이면 정보의 양이 현저히 줄어들기 때문에 DCNN의 성능을 저해한다. 따라서 DCNN 알고리즘 성능과 학습을 위하여, 최적의 입력 이미지 사이즈를 찾는 일은 DCNN 알고리즘 설계 시 매우 중요한 일이다. 이미지 크기에 의해 알고리즘의 성능이 많이 좌우됨으로 많은 연구들에서 새로운 이미지 데이터 셋에 대하여 최적의 이미지 사이즈를 찾는 연구는 중요하게 다루어지고 있다. 이미지 사이즈 96x96, 84x84, 56x56 등 다양한 사이즈에 대해 실험결과 1차년도 과제에서 확인했듯이 84x84 이미지 사이즈가 가장 적합하다는 것을 알 수 있었다. 본 실험에서는 84x84 최적화된 이미지 사이즈를 가지고 실험을 진행하였다.



그림13. DSLR으로 찍은 사진, 왼쪽부터 이미지 크기 96x96, 84x84, 56x56



그림14. DSLR으로 찍은 사진, 왼쪽부터 이미지 크기 96x96, 84x84, 56x56

3) 출력 데이터 정의

- 콘크리트 구조물의 내구성능이란 기상작용, 물리, 화학적 작용, 기계적 작용 등의 성능저하 외력에 저항하여 역학적, 기능적인 성능을 보유할 수 있는 능력을 의미한다. 콘크리트 구조물의 내구성이 저하되면 균열이 발생하고, 표면이 붕괴되면, 박리 등의 현상들이 나타나게 된다. 이런 것들은 콘크리트 구조물이 가지는 고유의 사용 수명과 관계가 있다. 콘크리트 내구성능 평가 지표로는 압축강도, 염화물 확산 계수 등이 있다. 압축강도는 가장 기본적인 콘크리트의 공학적 특성이며, 대표적인 내구성 지표이다.
- 염화물 확산 계수는 제설제에 노출된 도로시설물, 해양환경에 건설되는 콘크리트 구조물의 경우는 염소이온의 침투 및 확산에 의한 철근부식이 내구성 저하에 가장 큰 원인이 되고 있다. 동결 융해와의 상승 작용 및 건습의 반복작용 등을 받게 되면 훨씬 더 빠른 속도로 콘크리트 내구성을 저하시킨다. 염화물 확산 계수는 염해저항성에 대한 평가 지표를 의미한다.
- 콘크리트는 물, 시멘트, 골재 (세골재, 조골재) 및 혼화재로 (혼화제, 혼화재) 등으로 구성된 복합재료이다. 일반적으로 70~80%의 용적비를 가진 골재와 시멘트의 수화조작으로 이루어져 있으며, 그 사이에 크기가 다양한 공극이 존재한다. 혼합 시 연행된 Entrapped air, AE 제 또는 발포제 등에 의해 제조된 Entrained air, 시멘트 수화 후에도 수화물로 채워지지 못한 부분이 발생하여 모세관 공극, 수화물 사이의 작은 겔 공극, 건조 수축이나 팽창에 의해 만들어진 미세균열, 블리딩에 의해 만들어진 비교적 큰 공극, 골재와 시멘트 페이스트 경계면에서의 공극이 있다. 염화물 이온과 같은 각종 유해이온은 물론 물의 이동이 공극을 통하여 이루어지기 때문에 공극은 내구성에 큰 영향을 미친다. 따라서 공극률은 염화물질 이동 저항성을 평가할 수 있는 주된 지표이다.
- 본 과제에서는 압축강도, 공극률, 염화물 확산 계수에 대한 실험을 진행하였다. 따라서 현미경과 DSLR 카메라로부터 콘크리트 시편의 이미지를 획득한 후 각 이미지의 타겟 값으로 압축강도, 공극률, 염화물 확산 계수를 사용하였다. 본 과제에서 획득한 압축강도의 범위는 8.89에서 51.40로 실수 값이다. 공극률의 범위는 12.01에서 24.20 이다. 그리고 염화물 확산 계수의 범위는 1.06 에서 9.92 의 실수 값이다. 따라서 단일 DCNN 모델의 경우 출력 값으로 각 각 압축강도, 공극률, 염화물 확산 계수를 사용하였다. 압축강도와 공극률 통합 모델의 경우 출력 값으로 압축강도 와 공극률 값을 사용하였다.

- 압축강도, 공극률, 염화물 확산 계수 실수 값을 예측하기 위해 DCNN 학습을 위한 Loss function 으로 식 (1)과 같은 Euclidean loss를 사용하였다. 여기서 N은 데이터의 총 갯수이며, 는 DCNN의 출력 값 즉 압축강도 예측 값이고, 는 압축강도의 실측 값이다. DCNN은 이 loss 함수를 가지고, 역전파 알고리즘을 이용하여 이 에러함수가 최소가 되는 방향으로 DCNN의 가중치들이 학습된다. 앞서 설명하였듯이, 실험을 통해 얻은 압축강도 실측치는 8부터 50이상의 값으로 실수 값의 범위가 다양하고 광범위함으로 정규화를 통해 성능 개선 실험을 진행하였다. 정규화의 경우 min-max normalization을 통해 0에서 1사이의 값으로 변경하였다.

나. 모델링 (Modeling)

- 본 연구에서는 콘크리트 시편을 촬영하여 구축한 USB 현미경 데이터와 DSLR 데이터를 활용하여 콘크리트 구조물의 성능평가에 중요한 지표인 압축강도, 공극률, 염화물확산계수를 예측하는 DCNN 알고리즘 구조 설계가 목표이다. 압축 강도를 예측하는 데 도움이 될 수 있는 특징 (feature)들을 학습할 수 있도록 최적의 구조를 찾는 것은 알고리즘 성과와 학습에 있어서 매우 중요한 일이다. 또한 많은 연구들에서 각종 데이터에 최적의 구조를 찾는 연구들이 진행되고 있으며, 구조 별로 성능 차이는 현저하다.
- 일반적으로 딥러닝 분야에서는 충분한 데이터가 존재한다면 신경망 구조가 깊을수록 높은 정확도를 갖는 것을 실험적으로 증명되어져 있다. 특히, 본 과제와 관련있는 DCNN 구조는 layer 수가 증가할수록, 즉 신경망이 깊을수록 고 성능을 보여줌을 확인할 수 있다. Computer vision 분야에서 제일 큰 challenge의 결과를 보면 DCNN의 정확도면에서의 성능을 확연히 알 수 있다.
- 그림15에서 보면 2011년도까지의 모델은 deep learning기반 모델이 아니었고 전통적인 기계학습 알고리즘 기반으로 challenge에서 우승한 알고리즘의 에러는 25.81%이지만 2012년의 supervision (AlexNet)은 16.42%로 에러가 9% 가까이 줄인 매우 큰 성능 개선이 있었다. 2012년 이후 AlexNet 이후에도 이 challenge에서 우승한 모든 알고리즘은 DCNN기반의 알고리즘들이다. 또한 알고리즘의 깊이도 AlexNet 8 layer이고 VGGNet은 19 layers, GoogleNet은 22 layers 그리고 최근에 우승한 ResNet은 152 layers로 우승을 차지 하였다.




그림 15. ImageNet challenge 결과

- DCNN의 구조를 결정하는 것은 DCNN의 layer 수, 각 layer의 종류, layer 마다 출력 뉴런수 등 파라미터를 결정, 활성화 함수 결정, 가중치 연결 등 다양한 것들이 있다. Layer의 종류로는 fully connected layer, convolutional layer, normalization layer, recurrent layer, long short-term memory layer, pooling layer 등이 있다. 또한 이 각 layer에 다양한 파라미터가 존재하는 데 이에 따라 구조가 달라진다. 따라서 DCNN의 구조를 결정하는 것들은 무수히 많은 조합이 있다. 현재까지

DCNN의 최적 구조를 이론적으로 찾는 방법이 없기 때문에 경험적인 trial-error를 바탕으로 최적화된 구조를 찾아야 한다.

- 본 과제에서는 우선 최적 구조를 찾기 위하여 세 가지 DCNN 구조 (AlexNet, GoogleNet, ResNet)를 기반으로 실험 데이터에 맞게 구조를 변경하여 실험을 진행하였다. 위의 구조들은 이미지 인식 경진 대회인 ILSVRC (ImageNet Large-Scale Visual Recognition Challenge)에서 성능을 인증 받은 모델들로서 각각 다른 장점을 가지고 있기 때문에 본 연구 역시 구조에 따른 실험 성능평가를 수행하였다. 먼저 세 가지 DCNN 구조 별 세부특징 장점을 다음과 같이 소개한다.
- AlexNet은 ILSVRC 2012 에서 두각을 나타낸 모델로서 DCNN 구조가 대규모 이미지 인식에서 성능을 인증 받는 데 기여한 초기 모델이다. 이 모델의 특징은 첫째, 기존의 모델들과 다르게 포화하지 않는 ReLU 비선형성 뉴런을 가진 신경망이라는 점이다. Tanh처럼 포화하는 비선형성 뉴런을 가진 기존 신경망 모델보다 포화하지 않는 ReLU 뉴런을 가진 AlexNet 모델은 일관되게 개선된 학습 속도를 가진다. 둘째, Overlapping Pooling(풀링 겹치기)로서 풀링이 적용되는 지역들을 overlapping 하면서 과적합의 억제와 에러를 감소에 기여한다.




그림16. AlexNet 구조 (16)

- GoogleNet은 ILSVRC 2014 에서 성능의 월등함을 보인 모델이다. 22개 레이어 (층)를 가진 구조로 성능에 우수성을 보임과 동시에 신경망이 깊어지면서 발생할 수 있는 과적합, 연산량 증가 등의 부작용을 9개의 인셉션 모듈을 적용함으로써 해결하였다. 인셉션 모듈의 특징에 대해 살펴보자면, 첫째, 다양한 커널 사이즈의 convolution을 병렬적으로 사용한다. 이는 곧 지역적으로 다양한 feature를 추출하기에 적합한 구조가 된다. 둘째, 1x1 convolution을 활용하여 feature map의 수를 축소한다. 1x1 convolution은 다양한 사이즈의 convolution을 병렬적으로 사용함으로써 급증하는 연산량을 조절하는 기능을 한다. 앞서 살펴본 AlexNet과 비교했을 때, 신경망의 깊이는 훨씬 깊어 학습능력은 강화되었는데 파라미터는 1/12 수준으로 적어 연산량에 대한 부담이 감소하였다. 셋째, 보조 classifier를 통해 깊은 신경망을 학습하는 동안 발생할 수 있는 그레디언트 소실 방지한다. 그레디언트 소실이란 다층 레이어를 통과하면서 작은 값이 연속으로 곱하여 지면서 그레디언트가 0으로 수렴하는 것을 말하는데, 보조 classifier는 보조 classifier에서의 값이 결합하기 때문에 그레디언트가 감소하는 것을 방지하고 수렴을 더 잘 하도록 기여한다.




그림20. ResNet architecture compared to VGGNet

- 위의 세가지 알고리즘 (AlexNet, GoogleNet, ResNet) 중 1차년도 과제에서 확인했듯이 먼저 초기 모델의 feasibility 검증을 위해서 AlexNet을 사용하고 최종 모델을 생성하기 위해 ResNet 알고리즘을 채택하여 이를 바탕으로 콘크리트 시설물 성능평가를 위한 알고리즘을 설계한다. ResNet같은 경우 layer 수에 따라 명칭이 달라지는데 이번 연구에서는 layer 수가 50인 알고리즘, 즉, ResNet50을 사용하였다. 각 알고리즘은 콘크리트 시설물 성능평가 모델 설계를 위한 데이터 패턴을 분석하는 기능을 가진다. 우선, DCNN 모델의 입출력을 정의하고 실험자료 및 목표값 Matching을 위해 DCNN 모델의 데이터를 전처리 및 증폭 과정을 거친다. 콘크리트 데이터의 input 사이즈에 맞게 알고리즘 수정 후 세가지 알고리즘이 성능 목표값을 효율적으로 tracking하기 위해 알고리즘 구조를 콘크리트 데이터에 최적화 시킨다. 압축강도, 공극률, 염화물 확산 계수 각각에 대하여 위 세가지 알고리즘을 적용시켜 단일 출력 특성화 모델을 만들어 평가하였다.




그림21. DCNN 단일 모델의 Architecture

- 데이터의 증폭을 위해 random crop 과 더불어 horizontal flipping을 사용하였으며, 동영상 촬영으로 획득한 데이터에 대해서는 학습데이터와 같이 학습을 시켰다. Random crop은 256x256의 축소된 이미지에 좌측 상단의 18x18 중에 random seed가 생성된 후 그 점을 우상단 좌표로 하여 84x84로 데이터를 생성하였다. Horizontal flipping은 x축으로 180도 회전한 것과 같다. 예시는 그림 22, 23과 같다.




그림22. Random crop 예시



그림23. Horizontal flipping 예시

- 위와 같이 증폭한 데이터 셋을 이용하여 학습을 진행하였다. 또한 learning rate 등 학습에 관련된 hyper parameter를 찾는 실험도 진행하였다.

다. 최적화 (Optimization)

- 딥러닝 기반의 모델의 파라미터를 θ , 학습 데이터의 예제(example) 개수를 M 이라고 할 때, 손실함수 (loss function) $L(\theta)$ 는 아래와 같이 전체 학습 데이터에 대한 average로 표현 가능하다.

$$L(\theta) = \frac{1}{M} \sum_{i=1}^M L_i(\theta)$$

- 이러한 손실함수를 최소화 시키기 위한 대표적인 방법이 경사하강법 (Gradient Descent) 으로서, $L(\theta)$ 에 대한 Gradient의 반대 방향으로 학습률 (learning rate) η 만큼 파라미터를 업데이트 하는 과정을 여러 반복과정 (iteration)을 통해 반복하여 최적의 파라미터 θ^* 를 찾아낸다.
- Deep neural network의 손실함수와 같이 복잡한 Non-convex function일수록 Gradient 값은 파라미터 상태에 따라 크게 변하므로, 큰 배치(batch size)를 사용하면 오래 전 Gradient로 부정확한 변수 업데이트를 하게 될 위험이 커지게 되고, 학습률을 크게 가져가지 못하는 원인이 될 수 있다.
- 논문 (22)에서는 학습에서 배치의 크기(Batch size)의 영향을 조금 더 이론적인 측면에서 접근한다. 그림24과 같은 손실함수에서의 최적화 문제를 생각 해볼 때, Sharp minima는 손실함수의 작은 변화에도 민감하게 반응하기 때문에 Flat minima에 비해 일반화 측면에서 훨씬 불리하다고 볼 수 있다.





그림 24. Flat Minimum 과 Sharp Minimum [22]

- 이 논문은 작은 배치 크기와 큰 배치 크기의 일반화 성능 차이를 Sharpness of minima의 관점에서 설명하고, 실험적으로 그러한 주장을 뒷받침하였다. 또한 이러한 현상의 원인에 대해, “작은 배치 크기를 사용할 경우 Gradient의 노이즈가 커지기 때문에 Sharp minimizer에서 쉽게 벗어날 수 있고 Noise에 둔감한 Flat minimizer로 수렴하게 된다.”는 직관적인 해석을 덧붙였다.
- 딥러닝 기반의 알고리즘을 학습시키는데 있어서 어떤 Optimizer를 사용하는지 또한 매우 중요한 변수이다. 이는 학습 속도, 정확도에 직접적으로 관여하기 때문이다. 가장 기본적인 형태의 Optimizer는 Stochastic Gradient Descent (SGD)이지만 이는 학습 속도가 매우 느리고, 정확도 측면에서 다른 Optimizer들에 비해 좋지 않다는 것이 논문(23)을 통해 증명이 되었다. 최근 딥러닝 학습에 있어서 대부분의 경우 Adam을 주로 사용하고 있고 그림25에서 볼 수 있듯이 Adam을 쓸 경우 일반적으로 좋은 학습 결과를 기대할 수 있다. 이러한 점들을 참고하여 이번 연구에서의 Optimizer는 Adam을 사용하였다.

그림 25. MNIST 데이터 셋에 대한 Optimizer 별 학습 곡선



- 본 연구에서는 초기 학습율을 0.00001로 설정하였고, dropout 비율은 0.5로 설정하였다. 제안한 콘크리트 압축강도를 예측을 학습하기 위해서 딥러닝 프레임워크 Caffe를 사용하였고 Geforce GTX 1080Ti 그래픽 카드를 사용하여 학습을 실시했다. 본 연구에서 제시한 예측모델을 학습 및 검증하는데 96시간이 걸렸으며, 테스트하는데 약 0.28초의 시간이 소요되었다.

라. 소결

- 본 연구에서 제안한 모델을 통해 각 영상 크기별로 콘크리트 압축강도, 공극률, 염화물 확산 계수를 각각 90,000,000 반복 (iteration) 수행한 결과는 아래 그림26-31과 같다. 학습 손실 (train loss)과 검증 손실 (validation loss) 모두 반복 (iteration)이 증가함에 따라 줄어들고 있음을 확인할 수 있다. 이는 본 연구에서 제안하는 모델이 과적합 없이 잘 학습됨을 의미한다.
- 본 과제의 conjecture는 스스로 데이터 기반의 특징들을 학습할 수 있는 DCNN이 압축강도, 공극률, 염화물 확산 계수 예측에 도움이 되는 콘크리트 이미지에 특징들을 학습할 수 있을 것이라는 것이다. 이 conjecture를 검증하기 위해서 실험을 우선 256x256 이미지 사이즈를 고정하고 두 개의 다른 입력 데이터 (DSLRL, USB 현미경 데이터)를 이용하여 압축강도, 공극률, 염화물 확산 계수에 대해 관한 단일 DCNN을 만들어 실험을 진행하였다. 또한 DCNN 구조 또한 고정한 후 실험을 진행하였다.
- 그림 26과 그림 27은 압축강도와 관련된 USB 현미경 데이터와 DSLR 데이터에 대한 DCNN 모델의 학습 커브를 그린 것이다. 학습 loss와 validation loss 둘 다 iteration이 증가함에 따라 줄어든다는 것을 확인할 수 있다. 과적합 없이 잘 학습됨을 알 수가 있다. 따라서 본 실험의 결과로 USB 현미경 데이터와 DSLR 데이터 모두에 대해서 압축강도를 예측할 수 있는 패턴들이 이미지 데이터에 포함되어 있음을 확인하였고, 이 패턴들을 DCNN이 학습할 수 있음을 확인하였다. 공극률, 염화물 확산 계수도 이와 마찬가지로 패턴을 보이는 학습 그래프를 가진다는 것을 실험에서 확인하였다.
- 1차 연구년도에서는 AlexNet, GoogleNet, ResNet(Model_A, Model_G1, Model_G2, Model_G3, Model_R) 알고리즘을 활용하여 콘크리트 구조물의 압축강도를 예측하는 연구를 하였다. 그 결과는 표11-12에 요약되어 있다. 이를 통해 ResNet 알고리즘이 해당 문제를 해결하기 위한 가장 최적화된 알고리즘이라는 것을 찾았다. 따라서 이번 연구에서는 AlexNet (Model_A)으로 feasibility를 확인하고 ResNet (Model_R) 알고리즘으로 성능을 개선시키는 방향으로 연구를 진행하였다.




그림 26. 압축 강도에 대한 현미경 데이터 입력에 대한 학습 커브




그림 27. 압축 강도에 대한 DSLR 데이터 입력에 대한 학습 커브

<표11> 1차 년도 DSLR 압축강도 실험 결과

모델명	DSLR	Test Loss	RMSE
Model_A	84x84	0.00688	3.82
Model_G1	84x84	0.00703	3.86
Model_G2	84x84	0.00646	3.7
Model_G3	84x84	0.00625	3.64

<표12> 1차 년도 현미경 압축강도 실험 결과

모델명	DSLR	Test Loss	RMSE
Model_A	84x84	0.00688	3.82
Model_G1	84x84	0.00703	3.86
Model_G2	84x84	0.00646	3.7
Model_G3	84x84	0.00625	3.64
Model_R	84x84	0.00971	4.54

- 아래의 표13, 표14은 DSLR (압축강도, 공극률, 염화물 확산 계수), USB현미경 이미지 에 대한 AlexNet에 대한 실험 결과값이다. 표13, 표14 은 DSLR(압축강도, 공극률, 염화물 확산 계수), USB현미경 이미지에 대한 ResNet에 대한 실험 결과값이다. 위에 실험은 결과값으로 root mean squared error를 계산하여 비교하였다. Root mean squared error는 아래와 같이 DCNN의 예측값과 실험을 통해 얻은 압축강도, 공극률, 염화물 확산 계수 실측 값을 비교하여 측정한다.

<표13> 단일 특성 예측 모델 실험 결과 (DSLR)

특성	모델명	Test Loss	RMSE
압축강도	Model_R	0.005884	3.54
	Model_A	0.007226	3.92
공극률	Model_R	0.004443	1.15
	Model_A	0.006086	1.34
염화물 확산 계수	Model_R	0.008035	1.48
	Model_A	0.007485	1.73

<표14> 단일 특성 예측 모델 실험 결과 (USB 현미경)

특성	모델명	Test Loss	RMSE
압축강도	Model_R	0.007485	5.20
	Model_A	0.008035	5.39
공극률	Model_R	0.007862	1.53
	Model_A	0.010089	1.73
염화물 확산 계수	Model_R	0.019023	1.73
	Model_A	0.019626	1.75

- 표13, 표14 의 결과 또한 DSLR 이미지 에서 Test Loss, RMSE 값이 더 작은 값을 가지는 것을 확인할 수 있었다. 원인을 생각해 보면 DSLR 이미지가 콘크리트 시편 표면 면적을 더 많이 포함하고 있어서 현미경에 비해 더 많은 정보가 주어짐에 따라 예측 성능도 DSLR 이미지의 결과가 더 좋을 수 있었다.
- AlexNet과 ResNet 모델의 Test loss, RMSE 값을 표11-14를 통해 비교하면 ResNet 모델에서 USB 현미경, DSLR에 이미지에 대해서 더 작은 값을 가지는 것을 확인할 수 있다. AlexNet보다 ResNet이 더 좋은 성능을 가진다는 것은 이미 많은 실험을 통해 증명이 된 바가 있지만, 그것은 ImageNet, CIFAR-100 과 같은 정형화된 데이터 셋에 대한 실험이었다. (12) 이번 콘크리트 구조물의 이미지에 대한 실험에서의 결과에서 알 수 있듯이. 이번 연구에서의 결과 역시 ResNet 성능이 더 좋은 것을 확인할 수 있었다.
- 표15-26은 DSLR, USB 현미경 테스트 데이터 중 예측이 가장 잘 된 상위 50개와 예측이 가장 나쁜 하위 20개를 대표로 뽑아 압축강도, 공극률, 염화물 확산 계수를 ResNet 모델을 통해 예측한 값과 정답 그리고 차이를 나타내었다. 일부 아웃라이어 (outlier)가 존재하긴 하지만 전반적으로 예측한 값과 실제 값의 차이는 크지 않았다. 이는 해당 모델이 일반화에 성공하였고 이 모델을 실제로 콘크리트 구조물을 평가하는데 사용할 수 있다고 해석할 수 있다.

그림28. DSLR 데이터에 대한 압축강도 예측이 잘된 이미지의 예

 예측값: 16.67 실측값: 16.67	 예측값: 17.09 실측값: 17.09
 예측값: 17.29 실측값: 17.29	 예측값: 25.39 실측값: 25.37
 예측값: 16.66 실측값: 16.67	 예측값: 25.81 실측값: 25.82

그림29. DSLR 데이터에 대한 공극률 예측이 잘된 이미지의 예

 예측값: 23.4 실측값: 23.4	 예측값: 13.36 실측값: 13.35
 예측값: 19.03 실측값: 19.03	 예측값: 12.01 실측값: 12.02
 예측값: 16.35 실측값: 16.35	 예측값: 19.98 실측값: 19.97

그림30. DSLR 데이터에 대한 염화물 확산 계수 예측이 잘된 이미지의 예

 예측값: 5.56 실측값: 5.56	 예측값: 6.73 실측값: 6.73
 예측값: 2.48 실측값: 2.48	 예측값: 2.48 실측값: 2.48
 예측값: 4.88 실측값: 4.88	 예측값: 8.49 실측값: 8.49

그림31. USB 현미경 데이터에 대한 압축강도 예측이 잘된 이미지의 예

 예측값: 25.87 실측값: 25.87	 예측값: 32.07 실측값: 32.08
 예측값: 25.97 실측값: 25.97	 예측값: 26.74 실측값: 26.73
 예측값: 25.95 실측값: 25.96	 예측값: 17.27 실측값: 17.29

그림32. USB 현미경 데이터에 대한 공극률 예측이 잘된 이미지의 예

 예측값: 13.36 실측값: 13.35	 예측값: 17.85 실측값: 17.84
 예측값: 17.37 실측값: 17.38	 예측값: 16.27 실측값: 16.27
 예측값: 16.55 실측값: 16.55	 예측값: 19.1 실측값: 19.11

그림33. USB 현미경 데이터에 대한 염화물 확산 계수 예측이 잘된 이미지의 예

 예측값: 7.1 실측값: 7.09	 예측값: 7.33 실측값: 7.33
 예측값: 5.57 실측값: 5.56	 예측값: 4.61 실측값: 4.62
 예측값: 5.03 실측값: 5.02	 예측값: 5.74 실측값: 5.75

<표15> DSLR 데이터에 대한 압축강도 예측이 잘 된 예시

DSLR	이미지 이름	예측값	정답	차이
1	3-50A-10_(15).JPG	16.67	16.67	0
2	28-68A-10_(10).JPG	17.09	17.09	0
3	3-50B-10_(10).JPG	17.29	17.29	0
4	28_62A_10_18.JPG	25.36	25.37	0.01
5	3-50A-1_(23).JPG	16.66	16.67	0.01
6	91_62B_09_10.JPG	25.81	25.82	0.01
7	28_40B_05_14.JPG	36.96	36.97	0.01
8	07_46A_01_09.JPG	25.88	25.87	0.01
9	28_40B_03_06.JPG	36.98	36.97	0.01
10	3-50B-2_(20).JPG	17.27	17.29	0.02
11	07_62A_04_07.JPG	19.03	19.01	0.02
12	7-50A-1_(2).JPG	18.43	18.41	0.02
13	3-33A-7_(16).JPG	25.98	25.96	0.02
14	03_62B_05_03.JPG	12.56	12.59	0.03
15	28-68B-8_(2).JPG	18.86	18.83	0.03
16	28-68B-10_(4).JPG	18.8	18.83	0.03
17	91_33B_06_06.JPG	45.35	45.38	0.03
18	28-68A-10_(5).JPG	17.05	17.09	0.04
19	28-33B-7_(9).JPG	38.95	38.99	0.04
20	3-50B-3_(1).JPG	17.25	17.29	0.04
21	7-68A-1_(11).JPG	10.61	10.57	0.04
22	91_40B_10_03.JPG	41.14	41.18	0.04
23	3-68B-7_(4).JPG	8.85	8.89	0.04
24	03_62A_05_23.JPG	11.56	11.52	0.04
25	03_40B_02_07.JPG	20.87	20.91	0.04
26	3-50A-4_(9).JPG	16.63	16.67	0.04
27	28_62A_10_21.JPG	25.41	25.37	0.04
28	91_46B_08_16.JPG	38.64	38.68	0.04
29	03_40A_08_11.JPG	20.14	20.19	0.05
30	91_46B_06_12.JPG	38.73	38.68	0.05
31	03_40B_05_02.JPG	20.85	20.91	0.06
32	07_40A_05_05.JPG	27.7	27.76	0.06
33	3-33A-3_(22).JPG	26.02	25.96	0.06
34	91_33B_10_11.JPG	45.44	45.38	0.06
35	91_50B_04_14.JPG	34.62	34.55	0.07
36	91_62A_04_14.JPG	28.81	28.88	0.07
37	3-68A-5_(16).JPG	10.22	10.29	0.07
38	91_46B_01_18.JPG	38.61	38.68	0.07
39	28-33A-10_(5).JPG	40.66	40.59	0.07
40	3-33B-9_(12).JPG	26.21	26.28	0.07
41	28-33A-7_(8).JPG	40.67	40.59	0.08
42	91_50A_04_17.JPG	28.92	29	0.08
43	07_40A_02_13.JPG	27.68	27.76	0.08
44	28-33A-9_(6).JPG	40.67	40.59	0.08
45	28-68A-9_(2).JPG	17.01	17.09	0.08
46	07_46A_03_01.JPG	25.78	25.87	0.09
47	28-33B-9_(8).JPG	39.08	38.99	0.09
48	3-50B-4_(19).JPG	17.38	17.29	0.09
49	28_40B_03_11.JPG	37.06	36.97	0.09
50	91_40A_09_09.JPG	40.73	40.83	0.1

<표16> DSLR 데이터에 대한 공극률 예측이 잘 된 예시

DSLR	이미지 이름	예측값	정답	차이
1	3-68A-1_(18).JPG	23.4	23.4	0
2	91_40B_01_05.JPG	13.36	13.35	0
3	3-50B-4_(17).JPG	19.03	19.03	0
4	91_68A_06_13.JPG	12.01	12.02	0
5	3-33B-5_(7).JPG	16.35	16.35	0
6	07_62A_09_21.JPG	19.98	19.97	0
7	91_68A_04_17.JPG	12.02	12.02	0
8	91_33B_10_11.JPG	12.27	12.26	0
9	28-68A-3_(8).JPG	19.54	19.52	0.01
10	91_50A_04_08.JPG	18.79	18.79	0.01
11	3-50A-10_(2).JPG	19.89	19.89	0.01
12	07_40A_03_02.JPG	19.1	19.11	0.01
13	3-50B-2_(25).JPG	19.03	19.03	0.01
14	3-68A-10_(15).JPG	23.39	23.4	0.01
15	28_46A_10_06.JPG	17.26	17.26	0.01
16	91_40B_10_16.JPG	13.35	13.35	0.01
17	03_40B_08_02.JPG	20.1	20.1	0.01
18	28_62A_05_15.JPG	20.64	20.65	0.01
19	7-33A-6_(1).JPG	16.14	16.16	0.01
20	07_62A_09_01.JPG	19.98	19.97	0.01
21	3-68A-2_(22).JPG	23.42	23.4	0.01
22	03_46B_04_20.JPG	24.19	24.2	0.01
23	91_62B_09_17.JPG	16.75	16.76	0.01
24	28_46B_10_20.JPG	17.94	17.95	0.01
25	03_46A_09_11.JPG	20.38	20.39	0.01
26	07_40A_08_06.JPG	19.09	19.11	0.02
27	91_40A_08_15.JPG	13.54	13.56	0.02
28	7-68B-4_(7).JPG	20.47	20.49	0.02
29	28_62A_10_05.JPG	20.64	20.65	0.02
30	7-50B-3_(4).JPG	19.01	19.03	0.02
31	7-33A-7_(8).JPG	16.13	16.16	0.02
32	3-50B-7_(9).JPG	19.04	19.03	0.02
33	28_40A_10_14.JPG	17.86	17.84	0.02
34	03_40B_10_10.JPG	20.08	20.1	0.02
35	28-50A-4_(1).JPG	16.48	16.46	0.02
36	3-33B-9_(23).JPG	16.37	16.35	0.02
37	3-68A-3_(16).JPG	23.42	23.4	0.02
38	7-68A-2_(1).JPG	20.33	20.31	0.02
39	3-68B-6_(4).JPG	22.19	22.17	0.02
40	28-33B-7_(8).JPG	14.31	14.3	0.02
41	07_40A_03_15.JPG	19.13	19.11	0.02
42	3-50B-6_(22).JPG	19	19.03	0.02
43	3-68B-3_(5).JPG	22.2	22.17	0.03
44	07_46A_01_10.JPG	20.17	20.13	0.03
45	91_68B_06_12.JPG	22.28	22.26	0.03
46	91_68A_07_20.JPG	11.99	12.02	0.03
47	28_40B_04_07.JPG	19.03	19.06	0.03
48	07_46A_05_05.JPG	20.16	20.13	0.03
49	91_46B_02_03.JPG	14.9	14.88	0.03
50	91_62A_09_14.JPG	16.92	16.89	0.03

<표17> DSLR 데이터에 대한 염화물 확한 계수 예측이 잘 된 예시

DSLR	이미지 이름	예측값	정답	차이
1	28_40E_08_06.JPG	5.56	5.56	0
2	07_40E_04_14.JPG	6.73	6.73	0
3	91_40E_02_19.JPG	2.58	2.58	0
4	91_46E_08_10.JPG	2.48	2.48	0
5	28_46F_02_17.JPG	4.88	4.88	0
6	7-50E2-9_(15).JPG	8.49	8.49	0
7	28_46D_04_07.JPG	5.39	5.39	0
8	28_40F_04_11.JPG	5.5	5.5	0
9	07_46E_02_13.JPG	6.46	6.46	0
10	07_40D_03_05.JPG	5.76	5.75	0.01
11	28-33E-10_(4).JPG	4.16	4.17	0.01
12	91_40D_03_01.JPG	2.72	2.71	0.01
13	28_46D_03_04.JPG	5.4	5.39	0.01
14	7-33E2-10_(12).JPG	4.46	4.47	0.01
15	91_46E_09_03.JPG	2.49	2.48	0.01
16	28_62F_01_02.JPG	7.34	7.33	0.01
17	07_46D_09_02.JPG	8.2	8.19	0.01
18	91_40D_03_05.JPG	2.7	2.71	0.01
19	28_46F_01_03.JPG	4.89	4.88	0.01
20	28_46D_05_16.JPG	5.38	5.39	0.01
21	91_46E_04_07.JPG	2.47	2.48	0.01
22	91_40E_07_21.JPG	2.56	2.58	0.02
23	91_40D_05_18.JPG	2.69	2.71	0.02
24	28-68D-3_(8).JPG	9.74	9.76	0.02
25	91_40E_07_08.JPG	2.56	2.58	0.02
26	28_46F_04_11.JPG	4.86	4.88	0.02
27	28-33D-7_(13).JPG	3.35	3.37	0.02
28	91_46D_04_15.JPG	2.28	2.3	0.02
29	91_62E_02_05.JPG	5.46	5.44	0.02
30	91_46E_02_07.JPG	2.46	2.48	0.02
31	28_46D_08_10.JPG	5.37	5.39	0.02
32	7-50D2-4_(3).JPG	9.04	9.02	0.02
33	28-50F-3_(14).JPG	8.81	8.83	0.03
34	91_33E_04_06.JPG	3.96	3.99	0.03
35	91_40E_05_06.JPG	2.61	2.58	0.03
36	91_50D_04_14.JPG	6.23	6.26	0.03
37	28_46E_07_10.JPG	4.32	4.29	0.03
38	07_40F_04_05.JPG	6.31	6.28	0.03
39	28-33E-8_(10).JPG	4.14	4.17	0.03
40	28_46D_07_10.JPG	5.42	5.39	0.03
41	07_46E_09_03.JPG	6.43	6.46	0.03
42	28_40E_04_14.JPG	5.6	5.56	0.04
43	91_46D_03_07.JPG	2.26	2.3	0.04
44	07_40D_02_17.JPG	5.79	5.75	0.04
45	28_46F_09_14.JPG	4.84	4.88	0.04
46	91_62D_03_03.JPG	5.68	5.64	0.04
47	91_40E_06_24.JPG	2.62	2.58	0.04
48	91_40E_07_16.JPG	2.54	2.58	0.04
49	28_40D_09_06.JPG	4.58	4.62	0.04
50	28_62E_07_05.JPG	8.17	8.21	0.04

<표18> DSLR 데이터에 대한 압축강도 예측이 잘 되지 않은 예시

DSLR	이미지 이름	예측값	정답	차이
1	91_33A_01_01.JPG	28	51.4	23.4
2	91_33A_06_01.JPG	31.62	51.4	19.78
3	91_33B_02_10.JPG	27.02	45.38	18.36
4	28-68B-2_(8).JPG	35.68	18.83	16.85
5	91_33A_07_15.JPG	35.56	51.4	15.84
6	28-68B-2_(11).JPG	34.61	18.83	15.78
7	28-33B-6_(7).JPG	23.7	38.99	15.29
8	7-50B-9_(2).JPG	32.2	17.73	14.47
9	7-68B-10_(7).JPG	25.11	10.84	14.27
10	7-50A-7_(4).JPG	32.49	18.41	14.08
11	28-68A-4_(14).JPG	31.11	17.09	14.02
12	7-68B-10_(10).JPG	24.84	10.84	14
13	91_50A_06_12.JPG	42.67	29	13.67
14	91_33A_07_11.JPG	38.02	51.4	13.38
15	91_33A_07_13.JPG	38.18	51.4	13.22
16	07_62A_09_22.JPG	32.04	19.01	13.03
17	7-50A-7_(1).JPG	31.4	18.41	12.99
18	7-68B-10_(11).JPG	23.52	10.84	12.68
19	7-50B-8_(1).JPG	29.57	17.73	11.84
20	28_40B_06_08.JPG	25.23	36.97	11.74

<표19> DSLR 데이터에 대한 공극률 예측이 잘되지 않은 예시

DSLR	이미지 이름	예측값	정답	차이
1	03_40A_06_03.JPG	22.36	16.87	5.49
2	91_33A_07_15.JPG	17.48	12.02	5.46
3	91_33A_01_01.JPG	17.22	12.02	5.2
4	03_40A_07_04.JPG	21.98	16.87	5.11
5	91_33A_07_11.JPG	16.98	12.02	4.96
6	91_33B_02_10.JPG	17.01	12.26	4.74
7	03_46B_07_17.JPG	19.8	24.2	4.41
8	03_46A_06_07.JPG	16.16	20.39	4.23
9	28-50B-4_(9).JPG	15.01	19.09	4.07
10	28-50B-3_(11).JPG	15.06	19.09	4.03
11	28-33B-6_(7).JPG	18.31	14.3	4.02
12	03_46B_06_13.JPG	20.25	24.2	3.95
13	03_40A_07_12.JPG	20.77	16.87	3.9
14	91_68A_04_08.JPG	15.84	12.02	3.82
15	91_68A_03_16.JPG	15.76	12.02	3.74
16	91_68B_07_15.JPG	18.53	22.26	3.73
17	03_62A_08_10.JPG	18.85	22.54	3.69
18	28-68A-1_(13).JPG	15.92	19.52	3.6
19	03_40A_07_01.JPG	20.36	16.87	3.49
20	7-33B-2_(4).JPG	19.76	16.27	3.49

<표20> DSLR 데이터에 대한 염화물 확산 계수 예측이 잘 되지 않은 예시

DSLR	이미지 이름	예측값	정답	차이
1	7-68E2-2_(1).JPG	9.53	1.2	8.33
2	28-68D-9_(3).JPG	1.81	9.76	7.95
3	7-68E2-5_(6).JPG	9.07	1.2	7.87
4	7-68E2-4_(10).JPG	8.5	1.2	7.3
5	7-68E2-1_(2).JPG	8.19	1.2	6.99
6	7-68E2-4_(5).JPG	8.16	1.2	6.96
7	7-68E2-4_(7).JPG	7.54	1.2	6.34
8	7-68E2-5_(1).JPG	7.5	1.2	6.29
9	7-68E2-7_(1).JPG	7.47	1.2	6.27
10	7-68E2-1_(4).JPG	7.14	1.2	5.94
11	7-68E2-7_(13).JPG	6.99	1.2	5.79
12	28-68D-9_(11).JPG	4	9.76	5.76
13	7-68E2-3_(4).JPG	6.77	1.2	5.57
14	7-68E2-2_(12).JPG	6.61	1.2	5.4
15	28-68E-1_(6).JPG	6.45	1.18	5.27
16	07_62D_02_06.JPG	4.2	9.42	5.22
17	7-50E2-4_(4).JPG	3.3	8.49	5.18
18	7-68E2-3_(5).JPG	6.17	1.2	4.97
19	7-68E2-2_(7).JPG	6.15	1.2	4.95
20	28-68F-1_(11).JPG	5.04	9.92	4.88

<표21> USB 현미경 데이터에 대한 압축강도 예측이 잘 된 예시

현미경	이미지 이름	예측값	정답	차이
1	07_46C_03_05.jpg	25.87	25.87	0
2	3-68C-7_(22).jpg	32.07	32.08	0.01
3	3-68C-7_(14).jpg	25.97	25.96	0.01
4	28-68C-1_(4).jpg	26.74	26.73	0.01
5	3-68C-5_(6).jpg	25.95	25.96	0.01
6	3-68C-9_(4).jpg	17.27	17.29	0.02
7	03_40C_08_09.jpg	25.98	25.96	0.02
8	28_46C_10_22.jpg	18.84	18.86	0.02
9	91_50C_09_02.jpg	20.8	20.78	0.02
10	07_40C_05_17.jpg	18.88	18.86	0.02
11	28_62C_02_11.jpg	39.02	38.99	0.03
12	28-68C-10_(1).jpg	16.7	16.67	0.03
13	3-68C-3_(24).jpg	10.33	10.29	0.04
14	28-50C-7_(5).jpg	45.42	45.38	0.04
15	91_68C_02_07.jpg	37.01	36.97	0.04
16	28_62C_10_13.jpg	28.06	28.01	0.05
17	3-33C-9_(3).jpg	28.24	28.29	0.05
18	91_46C_02_12.jpg	17.34	17.29	0.05

19	03_62C_06_11.jpg	26.34	26.28	0.06
20	03_46C_05_12.jpg	24.53	24.47	0.06
21	28_40C_04_12.jpg	37.03	36.97	0.06
22	07_46C_10_08.jpg	20.97	20.91	0.06
23	3-50C-7_(12).jpg	24.54	24.47	0.07
24	91_62C_08_01.jpg	20.7	20.78	0.08
25	3-50C-6_(18).jpg	17.63	17.72	0.09
26	91_33C_08_09.jpg	38.77	38.68	0.09
27	7-33C-9_(9).jpg	38.58	38.68	0.1
28	3-50C-6_(31).jpg	37.45	37.55	0.1
29	03_62C_05_09.jpg	20.81	20.91	0.1
30	3-33C-10_(32).jpg	38.57	38.68	0.11
31	3-50C-7_(8).jpg	11.63	11.52	0.11
32	91_46C_01_10.jpg	40.7	40.59	0.11
33	3-50C-5_(9).jpg	16.55	16.67	0.12
34	28-33C-9_(11).jpg	11.64	11.52	0.12
35	3-50C-8_(32).jpg	16.54	16.67	0.13
36	28-68C-4_(7).jpg	26.09	25.96	0.13
37	3-50C-7_(33).jpg	20.77	20.91	0.14
38	3-33C-3_(1).jpg	17.59	17.73	0.14
39	3-50C-8_(24).jpg	28.86	29	0.14
40	7-33C-7_(8).jpg	25.72	25.87	0.15
41	03_62C_01_01.jpg	20.66	20.81	0.15
42	07_40C_06_03.jpg	25.81	25.96	0.15
43	28-68C-5_(14).jpg	17.24	17.09	0.15
44	28-33C-5_(3).jpg	10.69	10.84	0.15
45	28-50C-6_(9).jpg	26.43	26.28	0.15
46	03_46C_01_09.jpg	25.8	25.96	0.16
47	91_68C_02_14.jpg	27.81	27.97	0.16
48	07_62C_10_04.jpg	20.94	20.78	0.16
49	03_62C_02_13.jpg	26.44	26.28	0.16
50	07_40C_10_11.jpg	16.5	16.67	0.17

<표22> USB 현미경데이터에 대한 공극률 예측이 잘 된 예시

현미경	이미지 이름	예측값	정답	차이
1	3-50C-6_(24).jpg	13.36	13.35	0
2	3-33C-1_(3).jpg	17.85	17.84	0
3	07_46C_09_07.jpg	17.37	17.38	0
4	91_62C_01_01.jpg	16.27	16.27	0
5	91_62C_03_11.jpg	16.55	16.55	0.01
6	07_62C_05_17.jpg	19.1	19.11	0.01
7	91_62C_08_15.jpg	20.19	20.2	0.01
8	28-68C-10_(2).jpg	19.12	19.11	0.01
9	91_46C_04_09.jpg	16.33	16.35	0.01
10	7-50C-10_(3).jpg	12.25	12.26	0.01

11	3-50C-5_(10).jpg	19.03	19.03	0.01
12	3-33C-8_(23).jpg	19.87	19.89	0.01
13	03_40C_02_06.jpg	17.27	17.26	0.01
14	03_46C_09_01.jpg	20.33	20.31	0.02
15	7-50C-1_(1).jpg	16.78	16.76	0.02
16	7-50C-3_(1).jpg	13.58	13.56	0.02
17	3-50C-4_(5).jpg	17.35	17.38	0.02
18	91_40C_06_11.jpg	13.58	13.56	0.02
19	3-50C-2_(13).jpg	12.04	12.02	0.02
20	03_62C_04_18.jpg	17.62	17.6	0.02
21	3-68C-5_(17).jpg	12.29	12.26	0.03
22	28_62C_09_06.jpg	17.3	17.26	0.03
23	91_50C_08_12.jpg	16.72	16.7	0.03
24	3-33C-3_(25).jpg	17.4	17.38	0.03
25	28-50C-4_(2).jpg	20.36	20.39	0.03
26	28-68C-1_(6).jpg	19.14	19.11	0.03
27	3-50C-1_(15).jpg	17.41	17.38	0.03
28	03_62C_06_08.jpg	16.13	16.16	0.03
29	7-33C-7_(16).jpg	20.52	20.49	0.04
30	3-33C-9_(25).jpg	23.37	23.4	0.04
31	91_46C_07_04.jpg	17.64	17.6	0.04
32	03_62C_02_11.jpg	17.41	17.38	0.04
33	28_62C_10_12.jpg	19.49	19.52	0.04
34	3-68C-7_(3).jpg	15.2	15.16	0.04
35	03_62C_07_17.jpg	16.23	16.27	0.04
36	07_40C_02_06.jpg	19.93	19.97	0.04
37	03_40C_05_12.jpg	18.08	18.13	0.05
38	03_62C_07_11.jpg	16.74	16.7	0.05
39	3-68C-5_(3).jpg	17.9	17.95	0.05
40	28-33C-8_(7).jpg	17.43	17.38	0.05
41	28-33C-8_(11).jpg	17.9	17.95	0.05
42	28_62C_01_05.jpg	19.08	19.03	0.05
43	28_62C_06_05.jpg	17.75	17.8	0.05
44	07_40C_06_03.jpg	17.33	17.38	0.05
45	03_46C_03_01.jpg	13.41	13.35	0.05
46	07_40C_10_13.jpg	17.32	17.26	0.05
47	07_62C_03_14.jpg	21.37	21.32	0.05
48	91_33C_07_06.jpg	17.43	17.38	0.05
49	7-33C-10_(7).jpg	18.85	18.79	0.06
50	3-33C-9_(32).jpg	16.76	16.7	0.06

<표23> USB 현미경 데이터에 대한 염화물 확산 계수 예측이 잘 된 예시

현미경	이미지 이름	예측값	정답	차이
1	28-50E-5_(9).jpg	7.1	7.09	0
2	28_62F_09_13.jpg	7.33	7.33	0
3	28_40E_10_02.jpg	5.57	5.56	0.01
4	28_40D_01_06.jpg	4.61	4.62	0.01
5	91_62F_09_15.jpg	5.03	5.02	0.01
6	07_40D_08_05.jpg	5.74	5.75	0.01
7	07_40F_06_12.jpg	6.29	6.28	0.01
8	07_40E_09_01.jpg	6.72	6.73	0.01
9	07_40D_03_12.jpg	5.74	5.75	0.01
10	91_62D_08_09.jpg	5.63	5.64	0.01
11	07_40F_06_04.jpg	6.26	6.28	0.02
12	91_33E_10_11.jpg	4.01	3.99	0.02
13	28_62D_06_06.jpg	6.86	6.89	0.03
14	91_68E_10_12.jpg	1.09	1.06	0.03
15	91_46E_08_01.jpg	2.51	2.48	0.03
16	28-50E-1_(2).jpg	7.06	7.09	0.03
17	28_40E_06_09.jpg	5.53	5.56	0.03
18	91_46F_09_02.jpg	2.3	2.34	0.04
19	91_33E_04_01.jpg	3.94	3.99	0.05
20	28_46F_05_09.jpg	4.83	4.88	0.05
21	07_46D_08_12.jpg	8.24	8.19	0.05
22	28_40E_03_01.jpg	5.61	5.56	0.05
23	28-50E-8_(11).jpg	7.14	7.09	0.05
24	91_40F_01_06.jpg	3.02	3.07	0.05
25	28_62F_04_06.jpg	7.27	7.33	0.06
26	28_40F_03_13.jpg	5.44	5.5	0.06
27	28_62D_10_06.jpg	6.95	6.89	0.06
28	07_62F_10_13.jpg	8.58	8.52	0.06
29	91_33E_03_09.jpg	4.05	3.99	0.06
30	91_62F_03_11.jpg	5.08	5.02	0.06
31	07_40E_04_07.jpg	6.67	6.73	0.06
32	91_33D_01_01.jpg	3.57	3.63	0.06
33	07_62F_05_02.jpg	8.46	8.52	0.06
34	91_33F_01_06.jpg	3.2	3.14	0.06
35	28_40E_10_04.jpg	5.62	5.56	0.06
36	91_33E_02_02.jpg	3.93	3.99	0.06
37	91_46F_08_03.jpg	2.27	2.34	0.07
38	07_40D_07_05.jpg	5.82	5.75	0.07
39	91_33F_05_02.jpg	3.07	3.14	0.07
40	28_46E_04_03.jpg	4.22	4.29	0.07
41	28_62F_01_02.jpg	7.41	7.33	0.08
42	91_50F_10_06.jpg	6.05	5.97	0.08
43	28_46E_08_12.jpg	4.21	4.29	0.08

44	91_33F_02_18.jpg	3.06	3.14	0.08
45	28_40E_01_04.jpg	5.48	5.56	0.08
46	91_46F_02_10.jpg	2.26	2.34	0.08
47	91_40E_06_12.jpg	2.67	2.58	0.09
48	07_62E_07_04.jpg	9.02	8.93	0.09
49	91_33F_08_16.jpg	3.23	3.14	0.09
50	28_46D_03_15.jpg	5.3	5.39	0.09

<표24> USB 현미경 데이터에 대한 압축강도 예측이 잘 되지 않은 예시

현미경	이미지 이름	예측값	정답	차이
1	7-68C-8_(8).jpg	12.92	40.83	27.91
2	7-33C-10_(5).jpg	20.07	45.38	25.31
3	07_46C_01_06.jpg	35.99	10.84	25.15
4	07_40C_08_04.jpg	33.89	10.84	23.05
5	91_40C_07_08.jpg	32.99	10.57	22.42
6	28_40C_05_11.jpg	23.04	45.38	22.34
7	3-68C-3_(12).jpg	39.86	17.71	22.15
8	07_40C_06_11.jpg	20.53	41.18	20.65
9	07_40C_02_02.jpg	31.17	10.57	20.6
10	7-68C-8_(7).jpg	30.91	10.84	20.07
11	91_33C_01_02.jpg	36	17.09	18.91
12	91_68C_04_03.jpg	19.62	37.57	17.95
13	28-50C-6_(12).jpg	33.9	17.29	16.61
14	3-33C-6_(30).jpg	34.84	51.4	16.56
15	28_46C_06_16.jpg	34.28	17.73	16.55
16	07_62C_09_14.jpg	19.3	35.49	16.19
17	91_33C_01_11.jpg	24.34	8.89	15.45
18	28_46C_05_10.jpg	21.66	36.97	15.31
19	3-50C-4_(3).jpg	25.52	10.29	15.23
20	03_62C_08_06.jpg	31.77	16.67	15.1

<표25> USB 현미경 데이터에 대한 공극률 예측이 잘되지 않은 예시

현미경	이미지 이름	예측값	정답	차이
1	03_62C_06_04.jpg	23.59	12.02	11.57
2	07_46C_07_11.jpg	14.84	22.26	7.41
3	3-50C-5_(5).jpg	15.74	22.26	6.51
4	03_62C_03_16.jpg	15.87	22.26	6.39
5	91_62C_09_05.jpg	19.74	13.35	6.38
6	07_40C_02_16.jpg	16.2	22.26	6.06
7	28_62C_04_05.jpg	21.29	16.23	5.06

8	03_62C_02_06.jpg	17.01	12.02	4.99
9	28_62C_07_05.jpg	15.7	20.65	4.95
10	07_40C_08_13.jpg	17.35	22.26	4.91
11	07_46C_03_02.jpg	19.31	24.2	4.89
12	91_68C_04_04.jpg	21.76	16.87	4.89
13	7-68C-5_(2).jpg	17.39	22.26	4.87
14	3-50C-5_(32).jpg	16.77	12.02	4.75
15	28_62C_10_08.jpg	12.29	16.89	4.61
16	3-33C-8_(4).jpg	16.58	12.02	4.56
17	07_40C_06_11.jpg	17.63	13.35	4.27
18	91_40C_09_11.jpg	19.15	23.4	4.25
19	28_46C_04_15.jpg	20.72	16.55	4.17
20	3-33C-7_(8).jpg	19.33	15.16	4.16

<표26> USB 현미경 데이터에 대한 염화물 확산 계수 예측이 잘되지 않은 예시

현미경	이미지 이름	예측값	정답	차이
1	91_68D_10_08.jpg	2.82	9.76	6.94
2	07_62E_01_14.jpg	2.49	8.93	6.44
3	91_46E_08_04.jpg	8.85	2.48	6.37
4	7-68E2-7_(1).jpg	7.52	1.2	6.32
5	91_46D_05_08.jpg	8.54	2.3	6.24
6	91_68D_10_09.jpg	3.66	9.76	6.1
7	91_68E_10_06.jpg	7.12	1.06	6.06
8	91_68D_07_02.jpg	3.96	9.76	5.8
9	91_68D_03_15.jpg	3.97	9.76	5.79
10	91_68D_09_14.jpg	4.05	9.76	5.71
11	91_68E_06_07.jpg	6.73	1.06	5.67
12	7-68E2-6_(4).jpg	6.85	1.2	5.65
13	91_68D_09_05.jpg	4.18	9.76	5.58
14	91_68D_01_13.jpg	4.18	9.76	5.58
15	91_68E_05_04.jpg	6.4	1.06	5.34
16	91_68E_08_12.jpg	6.3	1.06	5.24
17	91_40D_08_11.jpg	7.94	2.71	5.23
18	91_68E_06_12.jpg	6.25	1.06	5.19
19	28_62E_03_01.jpg	3.07	8.21	5.14
20	91_68D_01_14.jpg	4.64	9.76	5.12

가. 당해연차 세부 연구 내용 (DCNN 기반 콘크리트 시설물 성능평가 융합 알고리즘 구현)

- 앞선 연구는 각 특성(압축강도, 공극률, 염화물 확산 계수)에 따른 모델 (AlexNet, ResNet)을 개별적으로 만들어 학습시켜 성능을 평가하였다. 이번 연구에서는 앞선 연구를 바탕으로 개별 특성들을 통합하여 하나의 모델로 융합하는 모델을 구축하였다. 통합 모델에 대한 실험은 하나의 이미지를 입력값(Input)으로 받아 융합 모델을 거쳐 두 가지 값 (압축강도, 공극률)을 출력 (Output)으로 내는 모델과 세 가지 값 (압축강도, 공극률, 염화물 확산 계수)를 출력으로 내는 두 가지 모델에 대한 실험을 진행하였다. 일반적으로 Deep Neural Network 기반의 모델은 Input 값이 상관관계 (Correlation)가 높을 수록 성능이 좋아진다고 알려져 있다. 압축강도, 공극률, 염화물 확산 계수는 상당히 상관관계가 높기 때문에 하나의 이미지에 대해 압축강도와 공극률 모두 입력으로 주고 동시에 예측(출력)하는 모델을 설계한다면 개별적으로 예측하는 모델에 비해 더 개선된 성능을 보일 것이라는 관점으로 통합 알고리즘을 구현하였다. 첫번째 통합 모델은 압축강도와 공극률을 통합한 모델이며 이 모델에 대한 실험도 마찬가지로 AlexNet 알고리즘으로 feasibility를 확인한 후 ResNet 알고리즘을 사용해 정확도를 개선시켰다. 통합 모델에 염화물 확산 계수를 통합 모델에 적용시키지 못한 이유는 학습에 사용된 데이터 셋 자체가 압축강도, 공극률과 다르기 때문이다.




그림32. DCNN 통합 알고리즘 적용 모델의 Architecture

나. 소결

- 앞서 설명한 것과 같이, AlexNet, ResNet을 본 연구의 입출력 및 데이터 타입에 맞게 재설계한 알고리즘을 USB 현미경 데이터와 DSLR 데이터에 각각 적용하여 성능 검증을 실시 하였다. 이번 실험도 앞선 실험과 마찬가지로 DSLR 이미지 데이터 셋과 현미경 이미지 데이터 셋에 대한 실험을 각각 진행하였다. 우선 AlexNet 기반의 모델을 통해 해당 데이터 셋에 대한 feasibility를 알아보았다. AlexNet 기반의 모델에서의 결과는 표27, 표82에서 확인할 수 있다. 표27 에서 알 수 있다시피 통합모델의 손실률이 기존 개별 모델들에 비해 낮아졌다는 것을 확인 할 수 있었다. 따라서 통합모델 기반의 알고리즘이 개별 모델보다 성능이 나아진다는 것을 실험적으로 검증하여 통합 모델의 feasibility를 알아보았다. 이 결과를 바탕으로 더욱 발전된 알고리즘인 ResNet 기반의 알고리즘을 작성하여 정확도를 개선시키는 작업을 진행하였다. ResNet 기반의 알고리즘을 적용시킨 모델이 실험결과 가장 좋은 성능을 보였으며 AlexNet 기반의 알고리즘 모델보다 성능이 더욱 개선되었다. ResNet의 결과 역시 단일 모델보다 통합 모델의 손실률이 더 낮은 것으로 확인되었다. 또한 단일 모델, 통합 모델을 통틀어 AlexNet 기반의 알고리즘보다 ResNet 기반의 알고리즘의 손실률이 더 작다는 것을 확인할 수 있었다. ResNet 알고리즘 적용 모델을 바탕으로 최종 평가 데이터 셋에 대한 실험을 진행하였다. 통합 모델의 성능 (Loss, RMSE) 역시 단일 모델의 개별 예측보다 통합 모델이 높았다는 것을 알 수 있었다. 최종 평가 데이터 셋에 대한 통합 모델의 실험 결과는 학습 이후 사용된 Test 데이터 셋에 대한 실험 결과와 크게 차이가 없음을 확인할 수 있었다. 최종 평가 데이터 셋에 대한 통합 모델2의 실험 결과도 마찬가지로 학습 이후 사용된 Test 데이터 셋에 대한 실험 결과와 크게 차이가 없음을 확인할 수 있었다. 이는 본 연구에서 사용한 모델이 콘크리트 이미지를 입력 값으로 받아 구조물을 평가하는 문제에 있어서 일반화에 성공했다고 볼 수 있다.

<표27> 통합 예측 모델 실험 결과 (DSLR)

특성	모델명	Test Loss	RMSE
압축강도	Model_R	0.007485	5.20
	Model_A	0.008035	5.39
통합 모델 압축강도	Integrated_Model_R	0.009577	3.41
	Integrated_Model_A	0.010994	3.62
공극률	Model_R	0.007862	1.53
	Model_A	0.010089	1.73
통합 모델 공극률	Integrated_Model_R	0.009577	1.10
	Integrated_Model_A	0.010994	1.20

<표28> 통합 예측 모델 실험 결과 (USB 현미경)

특성	모델명	Test Loss	RMSE
압축강도	Model_R	0.007485	5.20
	Model_A	0.008035	5.39
통합 모델 압축강도	Integrated_Model_R	0.014672	5.08
	Integrated_Model_A	0.015745	5.24
공극률	Model_R	0.007862	1.53
	Model_A	0.010089	1.73
통합 모델 공극률	Integrated_Model_R	0.014672	1.50
	Integrated_Model_A	0.015745	1.56

- 표27, 28 의 결과를 보면 알 수 있듯이 제안한 모델 중에서 ResNet 알고리즘을 적용시킨 통합 모델이 가장 성능이 좋았다는 것을 확인할 수 있었다. 통합 모델에서도 마찬가지로 DSLR과 USB 현미경 데이터에 대해 압축강도, 공극률을 예측한 값의 오차율 상위 50개와 하위 20개를 비교한 샘플을 표 29-36에 작성하였다.

그림34. DSLR 데이터에 대한 압축강도 예측이 잘된 이미지의 예

 예측값: 10.29 실측값: 10.29	 예측값: 18.82 실측값: 18.83
 예측값: 24.48 실측값: 24.47	 예측값: 8.88 실측값: 8.89
 예측값: 26.27 실측값: 26.28	 예측값: 28.89 실측값: 28.88
 예측값: 17.7 실측값: 17.71	 예측값: 26.74 실측값: 26.73
 예측값: 17.72 실측값: 17.71	 예측값: 36.98 실측값: 36.97

그림35. DSLR 데이터에 대한 공극률 예측이 잘된 이미지의 예


 예측값: 20.13 실측값: 20.13	 예측값: 12.02 실측값: 12.02
 예측값: 22.54 실측값: 22.54	 예측값: 17.26 실측값: 17.26
 예측값: 12.02 실측값: 12.02	 예측값: 14.3 실측값: 14.3
 예측값: 20.65 실측값: 20.65	 예측값: 16.89 실측값: 16.89
 예측값: 19.06 실측값: 19.06	 예측값: 17.6 실측값: 17.6

그림36. USB 현미경 데이터에 대한 압축강도 예측이 잘된 이미지의 예

 예측값: 25.96 실측값: 25.96	 예측값: 37.56 실측값: 37.55
 예측값: 8.88 실측값: 8.89	 예측값: 24.48 실측값: 24.47
 예측값: 17.7 실측값: 17.71	 예측값: 24.49 실측값: 24.47
 예측값: 25.89 실측값: 25.87	 예측값: 29.02 실측값: 29
 예측값: 20.76 실측값: 20.78	 예측값: 28.91 실측값: 28.88

그림37. USB 현미경 데이터에 대한 공극률 예측이 잘된 이미지의 예

 예측값: 20.13 실측값: 20.13	 예측값: 17.37 실측값: 17.38
 예측값: 19.03 실측값: 19.03	 예측값: 19.03 실측값: 19.03
 예측값: 19.89 실측값: 19.89	 예측값: 16.27 실측값: 16.27
 예측값: 20.48 실측값: 20.49	 예측값: 17.38 실측값: 17.38
 예측값: 14.3 실측값: 14.3	 예측값: 13.84 실측값: 13.83

<표29> DSLR 데이터에 대한 압축강도 예측이 잘 된 예시

DSLR	이미지 이름	예측값	정답	차이
1	3-68A-7_(10).JPG	10.29	10.29	0
2	28-68B-8_(2).JPG	18.82	18.83	0.01
3	07_46B_07_08.JPG	24.48	24.47	0.01
4	3-68B-9_(5).JPG	8.88	8.89	0.01
5	3-33B-2_(20).JPG	26.27	26.28	0.01
6	91_62A_06_15.JPG	28.89	28.88	0.01
7	03_46A_01_02.JPG	17.7	17.71	0.01
8	28_62B_03_10.JPG	26.74	26.73	0.01
9	03_46A_03_11.JPG	17.72	17.71	0.01
10	28_40B_05_08.JPG	36.98	36.97	0.01
11	3-50B-6_(8).JPG	17.28	17.29	0.01
12	91_40A_01_12.JPG	40.81	40.83	0.02
13	28-33A-3_(15).JPG	40.57	40.59	0.02
14	28_40A_03_11.JPG	35.47	35.49	0.02
15	3-50A-7_(18).JPG	16.65	16.67	0.02
16	3-50B-7_(1).JPG	17.27	17.29	0.02
17	3-33B-9_(2).JPG	26.25	26.28	0.03
18	07_62A_03_20.JPG	18.98	19.01	0.03
19	03_46A_03_15.JPG	17.74	17.71	0.03
20	7-33B-5_(12).JPG	30.55	30.58	0.03
21	7-50B-7_(12).JPG	17.7	17.73	0.03
22	28_62A_03_06.JPG	25.4	25.37	0.03
23	91_62A_02_10.JPG	28.91	28.88	0.03
24	28_62A_09_16.JPG	25.34	25.37	0.03
25	07_62B_04_10.JPG	18.83	18.86	0.03
26	3-33A-3_(22).JPG	25.93	25.96	0.03
27	28-33A-2_(10).JPG	40.55	40.59	0.04
28	3-50B-5_(11).JPG	17.33	17.29	0.04
29	3-68A-10_(5).JPG	10.33	10.29	0.04
30	3-68B-3_(5).JPG	8.85	8.89	0.04
31	07_62B_04_09.JPG	18.91	18.86	0.05
32	3-50B-6_(22).JPG	17.34	17.29	0.05
33	91_50B_05_07.JPG	34.6	34.55	0.05
34	91_50A_04_12.JPG	28.95	29	0.05
35	3-68B-4_(5).JPG	8.94	8.89	0.05
36	7-33A-5_(10).JPG	35.04	34.99	0.05
37	07_62A_04_07.JPG	19.07	19.01	0.06
38	3-50B-3_(7).JPG	17.23	17.29	0.06
39	91_46B_07_12.JPG	38.74	38.68	0.06
40	3-50A-3_(6).JPG	16.61	16.67	0.06
41	03_46B_01_19.JPG	17.78	17.72	0.06
42	07_46A_01_10.JPG	25.81	25.87	0.06

43	07_46B_02_10.JPG	24.53	24.47	0.06
44	91_40B_10_08.JPG	41.24	41.18	0.06
45	91_40B_10_03.JPG	41.24	41.18	0.06
46	28_40B_03_18.JPG	37.04	36.97	0.07
47	07_62A_03_16.JPG	18.94	19.01	0.07
48	91_68B_09_07.JPG	20.88	20.81	0.07
49	91_46B_03_12.JPG	38.75	38.68	0.07
50	3-68A-10_(15).JPG	10.36	10.29	0.07

<표30> DSLR 데이터에 대한 공극률 예측이 잘 된 예시

DSLR	이미지 이름	예측값	정답	차이
1	07_46A_08_08.JPG	20.13	20.13	0
2	91_33A_03_07.JPG	12.02	12.02	0
3	03_62A_04_01.JPG	22.54	22.54	0
4	28_46A_10_11.JPG	17.26	17.26	0
5	91_33A_10_13.JPG	12.02	12.02	0
6	28-33B-3_(5).JPG	14.3	14.3	0
7	28_62A_07_04.JPG	20.65	20.65	0
8	91_62A_06_03.JPG	16.89	16.89	0
9	28_40B_01_02.JPG	19.06	19.06	0
10	28_62B_10_13.JPG	17.6	17.6	0
11	91_46B_02_03.JPG	14.89	14.88	0.01
12	03_40B_08_07.JPG	20.11	20.1	0.01
13	07_40A_02_04.JPG	19.12	19.11	0.01
14	28_40B_04_02.JPG	19.06	19.06	0.01
15	28_62B_04_04.JPG	17.62	17.6	0.01
16	3-68A-1_(22).JPG	23.39	23.4	0.01
17	91_62B_09_16.JPG	16.75	16.76	0.01
18	28_40A_10_16.JPG	17.85	17.84	0.01
19	28_40B_10_02.JPG	19.07	19.06	0.01
20	91_50A_02_08.JPG	18.81	18.79	0.01
21	3-50B-2_(7).JPG	19.01	19.03	0.01
22	3-68A-1_(11).JPG	23.39	23.4	0.01
23	7-33A-7_(11).JPG	16.17	16.16	0.01
24	28_46B_06_02.JPG	17.94	17.95	0.01
25	7-33A-5_(10).JPG	16.14	16.16	0.02
26	28_40A_01_10.JPG	17.82	17.84	0.02
27	3-33B-2_(19).JPG	16.37	16.35	0.02
28	3-68B-3_(8).JPG	22.15	22.17	0.02
29	91_62B_08_03.JPG	16.74	16.76	0.02
30	28_40A_06_04.JPG	17.86	17.84	0.02
31	91_33B_06_10.JPG	12.24	12.26	0.02
32	91_50A_05_01.JPG	18.77	18.79	0.02
33	3-50A-9_(12).JPG	19.86	19.89	0.02

34	3-50A-10_(2).JPG	19.86	19.89	0.02
35	03_46A_07_04.JPG	20.37	20.39	0.02
36	28-33B-7_(9).JPG	14.32	14.3	0.02
37	28-33B-6_(1).JPG	14.32	14.3	0.02
38	28_46A_04_03.JPG	17.28	17.26	0.02
39	07_62A_03_11.JPG	19.99	19.97	0.02
40	07_62A_06_08.JPG	19.95	19.97	0.02
41	91_62B_08_04.JPG	16.78	16.76	0.02
42	07_46B_08_09.JPG	16.57	16.55	0.02
43	28_46A_09_07.JPG	17.24	17.26	0.02
44	07_62B_02_11.JPG	20.18	20.2	0.03
45	3-50A-7_(7).JPG	19.92	19.89	0.03
46	28-33A-7_(4).JPG	13.86	13.83	0.03
47	3-50B-9_(22).JPG	18.99	19.03	0.03
48	3-33A-4_(6).JPG	17.35	17.38	0.03
49	3-50B-8_(16).JPG	19.06	19.03	0.03
50	3-33A-3_(3).JPG	17.34	17.38	0.03

<표31> DSLR 데이터에 대한 압축강도 예측이 잘 되지 않은 예시

DSLR	이미지 이름	예측값	정답	차이
1	91_33A_01_01.JPG	30.59	51.4	20.81
2	7-50B-9_(2).JPG	37.51	17.73	19.78
3	91_33A_07_15.JPG	34.85	51.4	16.55
4	91_33A_07_13.JPG	35.56	51.4	15.84
5	7-50B-8_(1).JPG	33.04	17.73	15.31
6	7-68B-10_(11).JPG	25.73	10.84	14.89
7	91_68A_04_17.JPG	35.37	20.78	14.59
8	28-68B-2_(11).JPG	33.09	18.83	14.26
9	28-68B-2_(9).JPG	32.59	18.83	13.76
10	07_46B_08_04.JPG	38.13	24.47	13.66
11	7-68B-10_(10).JPG	24.41	10.84	13.57
12	91_50A_06_12.JPG	42.47	29	13.47
13	91_33B_09_16.JPG	32.08	45.38	13.3
14	28-68A-4_(14).JPG	30.04	17.09	12.95
15	28_62B_01_17.JPG	39.21	26.73	12.48
16	07_62A_09_22.JPG	31.16	19.01	12.15
17	7-68B-9_(9).JPG	22.96	10.84	12.12
18	7-33B-2_(4).JPG	18.52	30.58	12.06
19	7-50A-10_(11).JPG	30.33	18.41	11.92
20	91_62B_02_01.JPG	37.68	25.82	11.86

<표32> DSLR 데이터에 대한 공극률 예측이 잘되지 않은 예시

DSLR	이미지 이름	예측값	정답	차이
1	7-50B-9_(2).JPG	5.21	5.21	5.21
2	03_46B_06_13.JPG	5.09	5.09	5.09
3	91_33A_07_15.JPG	4.81	4.81	4.81
4	91_33A_07_13.JPG	4.73	4.73	4.73
5	91_68A_03_20.JPG	4.31	4.31	4.31
6	03_40A_06_03.JPG	4.24	4.24	4.24
7	03_40A_07_04.JPG	4.13	4.13	4.13
8	91_33A_01_01.JPG	4.09	4.09	4.09
9	91_50A_06_12.JPG	4.08	4.08	4.08
10	03_40A_03_09.JPG	4	4	4
11	91_50A_06_02.JPG	3.96	3.96	3.96
12	28-50B-1_(11).JPG	3.89	3.89	3.89
13	7-50B-8_(1).JPG	3.72	3.72	3.72
14	03_46B_03_03.JPG	3.69	3.69	3.69
15	03_46B_07_04.JPG	3.61	3.61	3.61
16	91_68B_07_15.JPG	3.57	3.57	3.57
17	28-68A-4_(14).JPG	3.51	3.51	3.51
18	03_46B_07_17.JPG	3.49	3.49	3.49
19	28-50B-5_(10).JPG	3.44	3.44	3.44
20	03_62A_05_04.JPG	3.41	3.41	3.41

<표33> USB 현미경 데이터에 대한 압축강도 예측이 잘 된 예시

DSLR	이미지 이름	예측값	정답	차이
1	3-33A-3_(12).jpg	25.96	25.96	0
2	91_46A_04_06.jpg	37.56	37.55	0.01
3	3-68B-6_(25).jpg	8.88	8.89	0.01
4	07_46B_09_02.jpg	24.48	24.47	0.01
5	03_46A_03_05.jpg	17.7	17.71	0.01
6	07_46B_09_07.jpg	24.49	24.47	0.02
7	07_46A_06_11.jpg	25.89	25.87	0.02
8	91_50A_03_03.jpg	29.02	29	0.02
9	91_68A_03_08.jpg	20.76	20.78	0.02
10	91_62A_10_02.jpg	28.91	28.88	0.03
11	3-33A-2_(12).jpg	25.92	25.96	0.04
12	3-68A-6_(12).jpg	10.25	10.29	0.04
13	28_40B_06_02.jpg	37.02	36.97	0.05
14	7-68B-10_(1).jpg	10.79	10.84	0.05
15	91_62B_06_08.jpg	25.77	25.82	0.05
16	91_46A_02_01.jpg	37.61	37.55	0.06
17	07_62B_01_02.jpg	18.8	18.86	0.06
18	03_62B_04_08.jpg	12.53	12.59	0.06

19	3-50B-1_(25).jpg	17.36	17.29	0.07
20	91_40B_02_10.jpg	41.11	41.18	0.07
21	28_40B_01_09.jpg	36.9	36.97	0.07
22	91_50B_05_14.jpg	34.63	34.55	0.08
23	91_40A_02_09.jpg	40.75	40.83	0.08
24	03_46B_06_10.jpg	17.81	17.72	0.09
25	91_68A_01_09.jpg	20.87	20.78	0.09
26	3-68B-10_(24).jpg	8.98	8.89	0.09
27	03_46A_10_11.jpg	17.8	17.71	0.09
28	3-68B-2_(24).jpg	8.8	8.89	0.09
29	3-33A-8_(11).jpg	26.06	25.96	0.1
30	28-68A-8_(17).jpg	16.99	17.09	0.1
31	91_33A_09_07.jpg	51.51	51.4	0.11
32	91_62A_09_12.jpg	28.76	28.88	0.12
33	28-68B-3_(11).jpg	18.71	18.83	0.12
34	3-33A-8_(1).jpg	26.08	25.96	0.12
35	3-50B-3_(2).jpg	17.42	17.29	0.13
36	91_62A_10_03.jpg	28.75	28.88	0.13
37	91_33A_01_11.jpg	51.27	51.4	0.13
38	91_40A_03_02.jpg	40.96	40.83	0.13
39	28_40B_06_04.jpg	36.83	36.97	0.14
40	28-50B-5_(14).jpg	28.11	27.97	0.14
41	03_46A_07_02.jpg	17.56	17.71	0.15
42	07_46B_03_11.jpg	24.32	24.47	0.15
43	07_62B_07_17.jpg	18.71	18.86	0.15
44	91_46B_01_07.jpg	38.52	38.68	0.16
45	03_46B_07_08.jpg	17.55	17.72	0.17
46	07_46A_10_09.jpg	26.04	25.87	0.17
47	3-33B-8_(4).jpg	26.45	26.28	0.17
48	07_46B_01_09.jpg	24.65	24.47	0.18
49	3-68B-6_(9).jpg	9.07	8.89	0.18
50	28_46A_03_17.jpg	31.89	32.08	0.19

<표34>USB 현미경 데이터에 대한 공극률 예측이 잘 된 예시

DSLR	이미지 이름	예측값	정답	차이
1	07_46A_05_05.jpg	20.13	20.13	0
2	3-33A-8_(13).jpg	17.37	17.38	0
3	3-50B-10_(27).jpg	19.03	19.03	0
4	3-50A-5_(26).jpg	19.89	19.89	0
5	7-33B-3_(16).jpg	16.27	16.27	0
6	07_40A_09_14.jpg	19.11	19.11	0
7	7-68B-4_(8).jpg	20.48	20.49	0
8	3-33A-10_(7).jpg	17.38	17.38	0.01
9	28-33B-4_(12).jpg	14.3	14.3	0.01
10	28-33A-5_(10).jpg	13.84	13.83	0.01

11	91_40A_07_15.jpg	13.57	13.56	0.01
12	03_46B_06_09.jpg	24.19	24.2	0.01
13	28-33B-6_(7).jpg	14.31	14.3	0.01
14	07_46B_03_01.jpg	16.56	16.55	0.01
15	3-68A-8_(22).jpg	23.39	23.4	0.01
16	7-33A-9_(2).jpg	16.14	16.16	0.01
17	28_62B_04_07.jpg	17.6	17.6	0.01
18	91_33B_02_06.jpg	12.27	12.26	0.01
19	28_46A_06_04.jpg	17.25	17.26	0.01
20	7-33B-6_(14).jpg	16.29	16.27	0.02
21	91_40A_10_07.jpg	13.54	13.56	0.02
22	3-33B-5_(18).jpg	16.33	16.35	0.02
23	07_62A_05_08.jpg	20	19.97	0.02
24	3-68A-7_(23).jpg	23.42	23.4	0.02
25	28-68A-9_(15).jpg	19.55	19.52	0.02
26	07_62B_06_10.jpg	20.22	20.2	0.02
27	91_33B_03_10.jpg	12.24	12.26	0.02
28	28_40A_02_01.jpg	17.86	17.84	0.02
29	91_33B_10_12.jpg	12.29	12.26	0.02
30	3-50B-8_(28).jpg	19	19.03	0.02
31	7-33A-5_(8).jpg	16.13	16.16	0.02
32	7-50A-4_(8).jpg	17.83	17.8	0.02
33	7-50A-5_(14).jpg	17.82	17.8	0.02
34	28_46B_09_16.jpg	17.93	17.95	0.02
35	3-33A-9_(21).jpg	17.4	17.38	0.03
36	91_50A_10_05.jpg	18.82	18.79	0.03
37	3-33B-4_(3).jpg	16.38	16.35	0.03
38	91_46B_02_12.jpg	14.85	14.88	0.03
39	3-33B-2_(10).jpg	16.38	16.35	0.03
40	03_40B_05_08.jpg	20.13	20.1	0.03
41	3-68B-2_(8).jpg	22.2	22.17	0.03
42	3-50B-9_(25).jpg	19	19.03	0.03
43	3-33A-9_(16).jpg	17.35	17.38	0.03
44	28_40A_08_01.jpg	17.81	17.84	0.03
45	3-33A-2_(12).jpg	17.34	17.38	0.04
46	3-50A-7_(3).jpg	19.84	19.89	0.04
47	07_62A_07_01.jpg	20.02	19.97	0.04
48	03_40B_01_05.jpg	20.06	20.1	0.04
49	3-50B-10_(26).jpg	18.99	19.03	0.04
50	7-33B-8_(10).jpg	16.31	16.27	0.04

<표35> USB 현미경 데이터에 대한 압축강도 예측이 잘 되지 않은 예시

현미경	이미지 이름	예측값	정답	차이
1	62B_09_16.JPG	24.72	24.72	24.72
2	03_62A_03_03.JPG	24.61	24.61	24.61
3	28-50A-9_(2).JPG	22.8	22.8	22.8
4	28-68B-8_(6).JPG	22.23	22.23	22.23
5	28_40A_10_13.JPG	22.18	22.18	22.18
6	91_50A_10_12.JPG	20.61	20.61	20.61
7	03_46A_06_05.JPG	20.18	20.18	20.18
8	28-50A-3_(14).JPG	19.9	19.9	19.9
9	28_40B_04_17.JPG	19.54	19.54	19.54
10	91_50B_04_05.JPG	18.6	18.6	18.6
11	3-33B-2_(7).JPG	17.71	17.71	17.71
12	07_62B_04_04.JPG	16.98	16.98	16.98
13	28_62B_01_15.JPG	16.7	16.7	16.7
14	07_62A_06_15.JPG	16.26	16.26	16.26
15	28-68B-2_(9).JPG	16.22	16.22	16.22
16	28-50B-8_(3).JPG	15.11	15.11	15.11
17	91_40A_02_13.JPG	14.82	14.82	14.82
18	28-33B-9_(5).JPG	14.66	14.66	14.66
19	28_46A_01_09.JPG	14.65	14.65	14.65
20	28_46A_04_14.JPG	14.45	14.45	14.45

<표36> USB 현미경 데이터에 대한 공극률 예측이 잘되지 않은 예시

현미경	이미지 이름	예측값	정답	차이
1	91_62B_09_16.JPG	3.64	3.64	3.64
2	03_62A_03_03.JPG	6.1	6.1	6.1
3	28-50A-9_(2).JPG	2.02	2.02	2.02
4	28-68B-8_(6).JPG	1.16	1.16	1.16
5	28_40A_10_13.JPG	3.38	3.38	3.38
6	91_50A_10_12.JPG	4.32	4.32	4.32
7	03_46A_06_05.JPG	1.16	1.16	1.16
8	28-50A-3_(14).JPG	1.6	1.6	1.6
9	28_40B_04_17.JPG	3.37	3.37	3.37
10	91_50B_04_05.JPG	2.98	2.98	2.98
11	3-33B-2_(7).JPG	5.3	5.3	5.3
12	07_62B_04_04.JPG	2.89	2.89	2.89
13	28_62B_01_15.JPG	0.13	0.13	0.13
14	07_62A_06_15.JPG	3.04	3.04	3.04
15	28-68B-2_(9).JPG	2.28	2.28	2.28
16	28-50B-8_(3).JPG	3.37	3.37	3.37
17	91_40A_02_13.JPG	2.65	2.65	2.65
18	28-33B-9_(5).JPG	3.59	3.59	3.59
19	28_46A_01_09.JPG	4.34	4.34	4.34
20	28_46A_04_14.JPG	0.88	0.88	0.88

다. 소결




- 본 연구는 딥러닝 기술을 활용하여 건축물의 영상을 기반으로 콘크리트 건축물 유지관리를 위한 내구성 평가 항목인 콘크리트 압축강도, 공극률, 염화물 확산 계수를 예측하는 알고리즘을 설계하고 실제 응용할 수 있도록 알고리즘을 검증하였다. 국내 콘크리트 건축물의 노후화가 진행됨에 따라 콘크리트의 내구성 평가에 대한 중요성이 증대되고 있다. 콘크리트 내구성을 평가하는 기본적인 지표들 중 압축강도, 공극률, 염화물 확산 계수는 현장에서 코어 채취, 비파괴 검사 등을 통해 측정하고 있으나 시설물의 안전문제, 고비용, 낮은 신뢰성 등의 문제점을 가지고 있다.(3, 6-10) 최근 들어 영상 처리 기법을 적용한 연구들이 진행되고 있으나, 콘크리트 특징 추출에 있어 한계를 가진다.(3) 이에 본 연구에서는 심층 컨볼루션 신경망을 활용하여 영상 기반 콘크리트 압축강도, 공극률, 염화물 확산 계수 한번에 예측하는 통합 모델을 제안하고, 실험실 환경에서 구축한 콘크리트 압축강도 데이터 셋을 적용하여 그 유효성을 확인하였다.
- 앞선 1년차 연구에서는 입력데이터의 경우 어떤 센서로부터 생성되었는지, 어떤 데이터 인지, 단일 모델에 대하여 DCNN 모델의 학습률이 달라지고 그에 따른 정확도가 어떻게 차이가 나는지 확인하였다. ImageNet challenge의 경우 이미지를 보고 그에 해당되는 여러 클래스의 출력값들과의 차이를 통해 가장 loss가 출력 값을 classification 하는 것이라면 regression의 경우에는 테스트 시 학습을 통해 나온 예측 값이 출력 값과의 차이, 즉 loss가 최소화하는 방법이다. 이 결과를 토대로 USB현미경, 디지털카메라 이외의 다른 센서를 통해 얻은 이미지를 가지고 실험을 진행한 결과를 이용하여 DCNN 구조 설계 와 구조 최적화 실험을 진행하였다.
- 본 2년차 연구에서는 단일 모델의 연구 결과를 바탕으로 더욱 높은 성능을 가진 통합 모델을 만들기 위해 1년차 연구 결과를 바탕으로 딥러닝 알고리즘을 활용하여 압축강도와 공극률 그리고 염화물 확산 계수를 한번에 예측하는 독창적 알고리즘을 설계하였다. 그 결과 단일 출력 모델에 비해 높은 정확도를 가진다는 것을 실험적으로 확인하였다. 본 연구는 유지관리 분야에 딥러닝 기술을 접목하는 창의적인 원천기술 개발 연구로써 기존 연구와 차별화된다. 딥러닝 기술로 콘크리트 성능 및 열화 평가 빅데이터와 기존 알려진 특성뿐만 아니라 성능 평가에 사용될 수 있는 고차원 특성을 추출하여 콘크리트 구조물에 대한 전문적 지식의 반영없이 오직 콘크리트 이미지 만을 입력 값으로 받아 압축강도, 공극률, 염화물 확산 계수를 예측하는데 있어서 정확도가 상당히 높은 알고리즘을 구축하는데 성공하였다. 기존 연구와 다르게 부재 표면 사진, 또는 영상만으로 장소의 제한 없이 구조물의 성능을 평가할 수 있는 비용절감형 성능평가 알고리즘을 개발하였기 때문에 콘크리트 구조물의 성능을 평가하는데 투입되는 인건비 등의 비용을 감소시킬 수 있을 것으로 예상된다.
- 본 연구는 딥러닝 기술을 활용하여 영상으로 콘크리트 압축강도, 공극률, 염화물 확산 계수를 예측할 수 있는 방법을 제안함으로써 시설물 유지 관리 분야에 적용 가능한 새로운 기술의 가능성을 제시하였다. 본 연구에서 제안한 예측 모델은 콘크리트 구조물에 대한 영상으로부터 기존에 알려진 콘크리트 건축물 유지관리에 영향을 미치는 특성뿐만 아니라 고차원의 특성을 추출함으로써 예측 정확도를 향상시킬 수 있을 것으로 기대된다. 본 연구 결과를 토대로 콘크리트 시설물을 적은 비용으로 체계적인 관리가 가능할 것이며 기존의 성능 평가 방식보다 평가 정확도를 향상시킬 수 있을 것으로 예상된다.

제4장 목표 달성도 및 관련 분야 기여도

1. 목표 달성도

가. 연구개발 성과

■ 본 연구는 당초 핵심 연구목표로 계획된 “DCNN기반 콘크리트 시설물 성능평가 알고리즘 및 Big Data 구축”, “DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 개발”, 등의 연구개발 성과를 달성하기 위해 성실하게 연구를 완료하였음.

연번	핵심 연구 목표	핵심성과 설명	달성도
1	콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축	시설물 유지관리를 위한 콘크리트 성능 영향 요인(공극, 강도, 염화물 확산계수 등)을 정의하고 실험을 통해 도출된 성능값과 콘크리트 시편 표면 이미지 데이터와의 상관관계를 분석하여 구축된 콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 	100% 데이터 구축
2	콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발	콘크리트 표면 이미지를 매개변수 Input Data로 설정하고 DCNN기법의 기계학습 알고리즘을 통하여 콘크리트 성능평가의 결과값인 Output Data를 도출 가능하도록 설계된 DCNN기반 사진판독형 콘크리트 시설물 성능평가 프로그램 	100% 시스템 구축
3	DCNN 기반 콘크리트 시설물 특성별 성능평가 알고리즘 설계	콘크리트 성능 및 열화 평가 빅데이터와 기존 알려진 특성뿐만 아니라 성능평가에 사용될 수 있는 고차원 특성을 추출할 수 있는 딥러닝(Deep Learning) 기반 모델(Deep Convolutional Neural Network, DCNN) 활용하여 콘크리트 성능평가 알고리즘 설계 	100% 설계 완료
4	DCNN 기반 콘크리트 시설물 성능평가 융합 알고리즘 구현	DCNN을 사용한 콘크리트 구조물의 특성별 성능평가 알고리즘의 융합 구현 및 최적화를 하고, 실시간 처리속도를 갖는 지속가능성 평가기술 	100% 기술 개발

나. 정량적 성과

- 본 연구는 당초 계획된 정량적 성과를 달성하기 위해 성실하게 연구를 수행하였음.
- 특히, SCI(E)급 논문은 2건이 게재되고, 2건의 논문이 Accept 되었으며, 일반 학술지 2건, 학술발표대회 논문 1건 그리고 특허출원 2건을 달성함.

성과지표	성과 목표	최소 성과 목표	성과 목표
SCI(E)급 학술지 게재(2점)	4건	2건	3건
일반학술지게재(1점)	3건		2건
특허출원(1점)	2건	1건	2건
특허등록(2점)			
디자인 등록(1점)			
소프트웨어(1점)	1건		
하드웨어(1점)			
기타(1점)			
소계(점수)	14점	5점	10점

구분	핵심성과 (CTE)		단위성과	성과점검기준						양적 성과 건수
				질적 성과지표	목표치	달성치	측정방법	검증방법	가중치	
주관	1	콘크리트 시설물 유지관리를 위한 콘크리트 성능평가 Big Data 구축	1-1 콘크리트 시설물 유지관리를 위한 콘크리트 성능 영향 요인	① 콘크리트 시설물 유지관리를 위한 콘크리트 성능 영향 요인의 유효성	유효성 증명	-	사례분석 (구조물 유지보수 사례의 콘크리트 성능과 분석 요인간 유효성 분석)	사례분석 연구 보고서	10%	논문: 1건
			1-2 DCNN 기반 사진판독형 콘크리트 시편 표준 자료 DB	① DCNN 기반 사진판독형 콘크리트 시편 표준 자료 DB 구축	DB 구축	-	전문가지문 (사진판독형 콘크리트 시편 표준 자료 DB에 대한 전문가 검토)	전문가 의견서	10%	
	2	콘크리트 시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램 개발	2-1 DCNN 기반 알고리즘 피드백을 통한 실험 데이터간 유효상관관계 분석	① DCNN 기반 알고리즘 피드백을 통한 실험 데이터간 유효상관관계의 유효성	유효성 증명	-	실험분석 (실험분석대상의 기존 데이터와 DCNN 기반 알고리즘 분석 데이터간 비교분석)	실험분석	10%	특허: 출원 1건 논문: 2건 SW: 1건
			2-2 콘크리트 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램	① 콘크리트 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 프로그램	1건	-	프로그램 개발여부 (DCNN 기반 성능평가 기술에 대한 프로그램 개발 및 등록)	S/W 등록증	20%	
공동	3	DCNN 기반 콘크리트 시설물 성능평가 알고리즘 설계	3-1 DCNN 기반 콘크리트 구조물 성능평가 분류 방법론	① DCNN 기반 콘크리트 시설물 성능평가 분류 방법에 대한 유효성	유효성 증명	-	사례분석 (DCNN의 입출력 정의에 따른 성능평가 예측 정확도 비교를 통한 유효성 분석)	사례분석 연구 보고서	10%	특허: 출원 1건 논문: 1건
			3-2 DCNN 기반 콘크리트 구조물 성능평가 분류 알고리즘 설계	① 콘크리트 시설물 성능평가를 위한 분류 모형인 DCNN 구조 설계 유효성	유효성 증명	-	사례분석 (DCNN 구조에 따른 성능평가 예측 정확도 비교를 통한 유효성 분석)	사례분석 연구 보고서	10%	
	4	DCNN 기반 콘크리트 시설물 성능평가 알고리즘 구현	4-1 DCNN 기반 콘크리트 구조물 성능평가 분류 통합 알고리즘 설계	① 콘크리트 시설물 성능평가를 위한 분류 모형인 DCNN 통합 구조 설계 유효성	유효성 증명	-	사례분석 (DCNN 통합 구조에 따른 성능평가 예측 정확도 비교를 통한 유효성 분석)	사례분석 연구 보고서	10%	논문: 1건
			4-2 DCNN 기반 콘크리트 구조물 성능평가 분류 통합 알고리즘	① 콘크리트 시설물 성능평가를 위한 DCNN 분류 성능	유효성 증명	-	사례분석 (DCNN 의 분류예측 정확도와 전문가 예측 정확성 비교)	사례분석 연구 보고서	20%	
계				-	-	-	-	-	100%	특허: 출원 2건 논문: 5건 SW: 1건

2. 관련 분야 기여도

- 콘크리트 시설물 평가 관련 제도 및 정책 개발 등의 **종합적인 중·장기 계획이 필요할 것으로** 사료되는 바, 본 연구에서 제안하는 **DCNN기반 콘크리트 성능평가기술의 원천기술 확보**가 무엇보다 중요하며 국제적 수준의 **콘크리트 성능평가기술의 확보**를 통한 **국내 내수 시장의 활성화** 및 **국제 경쟁력 강화**가 기대됨.
- 콘크리트 시설물에 발생하는 열화 및 외적환경변화를 이미지 모니터링으로 측정하고 평가할 수 있는 **새로운 개념의 진단 시스템 개발을** 목적으로 내구성 진단에 필요한 콘크리트 성능평가 Big Data를 구축하고 사진판독형 프로그램을 개발함으로써 **시간 및 비용의 효율이 극대화**되어 세계적으로 유지관리 비용이 기하급수적으로 늘어나는 현 시점에서 **국제 시장주도 및 국내 건축 산업의 경제적 역량**이 제고될 것으로 기대됨.

기술적 측면	시설물 안전/유지관리 기술과 첨단과학기술 6T분야 중 IT기술의 융복합을 통한 성능평가 프로그램을 개발하여 국제적 수준 이상의 기술력 확보
경제·산업적 측면	콘크리트 성능평가 시스템의 시간 및 비용 효율성 극대화를 통해 국가적 시설물 유지관리 비용 절감 과 유지관리 시장의 경제적 파급효과 견인
사회적 측면	콘크리트 시설물의 노후도가 높아짐에 따른 유지 관리 기술 수출을 통한 국제 시장 주도 및 국내 건축 산업의 경제적 역량 제고




그림 4.1 연구개발의 기대효과

(1) 기술적 측면

시설물 안전/유지관리 기술과 첨단과학기술 6T분야 중 IT기술의 융복합을 통한 성능평가 시스템을 개발하여 국제적 수준 이상의 기술력 확보	
국가적 원천기술 및 기초과학기술 확보	국제적 시설물 안전/유지관리 기술의 성장과 정책의 변화에 대응할 수 있는 콘크리트 성능평가기술에 대한 국가적 원천기술 및 기초 과학기술 확보
국내 IT 분야와 건축분야의 융합	DCNN기반의 콘크리트 시설물 성능평가 시스템 개발을 통한 4차 산업혁명에 적합한 IT분야와 건축분야의 융·복합 기초 원천 기술 확보
지능형 성능평가 시스템 개발	딥러닝(Deep Learning) 기술을 융합함으로써 시설물 유지관리를 위한 지능형 콘크리트 성능평가 기술력 확보 및 성능진단 기술의 신기술 파급
시설물 유지관리 기술 경쟁력 강화	기존 시설물 유지관리 프로세스를 간소화시키는 지능형 콘크리트 성능평가 시스템을 개발함으로써 시설물 유지 관리 기술력 확보 및 국가 경쟁력 강화

(2) 경제·산업적 측면

콘크리트 성능평가 시스템의 시간 및 비용 효율성 극대화를 통해 국가적 시설물 유지관리 비용 절감과 유지관리 시장의 경제적 파급효과 견인	
국가적 시설물 유지관리 비용 절감	본 개발기술을 이용하여 시설물 유지관리의 효율적인 평가 기술개발을 통한 미래 유지관리 비용 절감 효과 기대
유지관리 적정 예산 분배 의사결정 지원	국가적 차원의 시설물 유지관리 예산 분배 의사결정을 지원함으로써 유지관리 적정 예산 기준을 마련함으로써 경제적 효과 기대
시설물 유지관리 기술의 질적 성장	시설물 유지관리 시장의 증가에 따른 건설분야와 IT분야의 융·복합 기술력을 바탕으로 시설물 성능평가 기술의 질적 성과 효과를 기대
4차 산업 혁명 시대의 신성장 동력 창출	시설물 유지관리를 위해 실시간으로 수집되는 Big Data와 지능형 시스템을 융합함으로써 4차 산업 혁명 시대의 신성장 동력 창출 효과 기대

(3) 사회적 측면

콘크리트 시설물의 노후도가 높아짐에 따른 유지 관리 기술 수출을 통한 국제 시장주도 및 국내 건축 산업의 경제적 역량 제고	
철저한 유지관리 국가 이미지 제고	콘크리트 성능평가 시스템의 효율성 극대화를 통해 지속가능한 국가 이미지를 제고하기 위한 기술력 바탕으로 대외적 홍보 가능
미래지향적 건설경제 기틀마련	시설물 유지관리 단계까지 고려하고 불필요한 보수 낭비를 막아 건축물 유지 관리에 대한 국민의식 고취와 미래지향적 건설경제 기틀마련 가능
관련 정책 개발 및 운영의 기초자료	지속가능한 국가 발전에 필수불가결한 시설물의 노후도 평가기술 및 결과를 통해 관련정책 개발과 운영, 심의 등의 기초자료로 활용 가능
고위험 노후화된 건축물에 대한 재정적 지원 확대	고위험 노후화 콘크리트 시설물의 증가로 유지관리단계의 중요성이 대두됨에 따라 정확도 높은 평가기술의 개발로 재정적 지원 확보 가능

3. 후속연구의 필요성

■ 본 연구에서는 사전에 수집된 콘크리트 이미지의 데이터 셋을 활용하여 DCNN 기반 성능 평가 알고리즘을 개발하고, 평가 정확도를 검증하였다. 하지만, 본 연구 과제를 통해 개발된 기술을 산업에 실용화하기 위하여 지속적인 연구가 필요할 것으로 사료된다.

- 최근 이미지뿐만 아니라 영상데이터를 활용하여 실시간으로 물체의 특징을 분석하여 분류하거나 감지하는 연구가 활발히 진행 중이다. 딥러닝 기반의 실시간 물체 인식 기술은 본 연구 결과를 실용화 기술로 발전시키기 위한 도구로 활용될 수 있다.



그림 4.2 물체 인식 연구 및 실시간 감지 기술 (좌 : 물체 인식 기술 우: 실시간 물체 감지 기술)

- 본 연구의 결과를 토대로 그림 4.3 과 같이 1) 실시간 평가기술 2) 알고리즘 간소화 기술 3) 데이터 서버 구축 4) 데이터 분석 프로세스 5) 스마트기기용 어플리케이션 개발의 프로세스로 후속 연구를 수행한다면, 기술 실용화가 가능할 것으로 사료된다.



그림 4.3 후속 연구 흐름도

제5장. 연구개발성과의 활용계획

■ 콘크리트 시설물 평가 관련 제도 및 정책 개발 등의 종합적인 중·장기 계획이 필요할 것으로 사료되는 바, 본 연구에서 제안하는 DCNN기반 콘크리트 성능평가기술의 원천기술 확보가 무엇보다 중요하며 국제적 수준의 콘크리트 성능평가기술의 확보를 통한 국내 내수 시장의 활성화 및 국제 경쟁력 강화가 기대됨.

1. 최종목표의 국가적 활용방안

시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 시스템

건설분야에 딥러닝 기법을 적용한 융복합 기술 기반 마련

건설분야와 ICT 기술분야의 융복합으로 다가오는 4차 산업혁명에 선제적으로 대응할 수 있는 지능형 유지관리 전략 수립 및 내수시장 활성화 기반 마련

국가적 차원의 시설물 안전 진단 및 유지관리 예산 절감

고가 진단 장비 및 전문인력이 투입되는 기존의 성능진단방식을 탈피하여 유지관리에 사용되는 국가 예산 절감

중·장기적 유지관리 대응 전략 수립

콘크리트 시설물의 성능을 효율적으로 예측하여 시기적절한 중·장기적 유지관리 대응 전략 수립 가능



시설물 지능형 유지관리 기술 고도화 실현

그림 5.1 최종목표의 국가적 활용방안

시설물 유지관리를 위한 DCNN 기반 사진판독형 콘크리트 성능평가 시스템

정책적 활용방안	시설물 유지관리 분야의 선도적 기술개발로 지능형 기술 촉진 전략 제고
	시설물의 안전 및 유지 관리 기본계획에 부합하는 선진적 관리체계 확립
	시설물 노후화 증가에 따른 중·장기적 유지관리 예산 분배 전략 수립
경제적 활용방안	기존의 고가의 장비와 전문 인력에 의존하는 방식을 탈피하는 평가방법 단순화로 유지관리 비용 절감
	제안기술 실용화를 통한 4차 산업혁명 시대의 신성장 동력 창출
	개발 기술을 바탕으로 해외 유지관리 시장 진출을 통한 Global Frontier 역할 수행
기술적 활용방안	건설 분야와 ICT 분야의 연계를 통하여 창조적 융·복합 원천 기술 선점
	국내외 요구를 수용할 수 있는 시설물의 지능형 콘크리트 성능평가 기술 보급
	건설 분야 전반에 걸쳐 새로운 고부가가치 기술 혁신 유도

● 정책적 활용방안

- 시설물 유지관리 분야의 선도적 기술개발로 지능형 기술 촉진 전략 제고
- 시설물의 안전 및 유지 관리 기본계획에 부합하는 선진적 관리체계 확립
- 시설물 노후화 증가에 따른 중·장기적 유지관리 예산 분배 전략 수립

● 경제적 활용방안

- 제안기술 실용화를 통한 4차 산업혁명 시대의 신성장 동력 창출
- 개발 기술을 바탕으로 해외 유지관리 시장 진출을 통한 Global Frontier 역할 수행
- 기존의 고가의 장비와 전문 인력에 의존하는 방식을 탈피하는 평가방법 단순화로 유지관리 비용 절감

● 기술적 활용방안

- 건설 분야와 ICT 분야의 연계를 통하여 창조적 융·복합 원천 기술 선점
- 국내외 요구를 수용할 수 있는 시설물의 지능형 콘크리트 성능평가 기술 보급
- 건설 분야 전반에 걸쳐 새로운 고부가가치 기술 혁신 유도



지능형 콘크리트 성능평가 기술 보급으로 4차산업혁명 신성장 동력을 창출하며, 유지관리 시장의 Global Frontier역할 수행


그림 5.2 연구결과의 구체적 활용방안

제6장. 연구 과정에서 수집한 해외 과학기술 정보

■ 해외에서는 Image 기반 데이터 분석 기술의 발전을 위하여 매년 ImageNet Large Scale Visual Recognition Challenge(ILSVRC)를 개최해 Computer Vision 분야의 기술 경쟁력을 확보하고 있음.


ImageNet Large Scale Visual Recognition Challenge (ILSVRC)

ImageNet Classification Error (Top 5)




* 2011년 이미지 분류 에러값이 26.0을 기록하면서 사람의 에러값인 5.0보다 현저히 낮은 정확도를 보이고 있으나, 2015년 이후 ResNet이 등장하면서 사람보다 높은 정확도를 나타내기 시작하였다.

Alexnet (2012)




* Alex Krizhevsky가 2012년 "ImageNet classification with deep convolutional neural networks." 논문을 발표하면서 CNN 방법론의 등장하였다.

GoogleNet (2014)




* Christian Szegedy (Goole社)가 2014년 "Going deeper with convolutions." 논문을 발표하면서 사람에 가까운 정확도를 나타내는 알고리즘이 개발되었다.

Resnet (2015)



* Kaiming He가 2015년 "Deep Residual Learning for Image Recognition." 논문을 발표하면서 사람보다 정확한 결과를 나타내면서 육안으로 구분하기 어려운 이미지를 분석할 수 있음을 암시하였다.


Luo et al (2018)



* 구조물 진단을 위한 Computer Vision기반 변위 검출 방법에 관한 연구 Edge Enhanced-Matching(EEM) 기술을 적용한 유지관리 기술이 개발되고 있음.

Luo, L. and Feng, M. Q. (2018) "Edge-Enhanced Matching for Gradient-Based Computer Vision Displacement Measurement" *Computer-Aided Civil and Infrastructure Engineering* 33 (2018) 1019-1040

Wang et al (2018)



* 석조 건축물 대상으로 CNN 기법을 활용하여 손상 탐지 방법에 대한 연구가 진행되고 있으며, 손상, 균열, 풍화 및 백화 현상을 인식하는 기술이 개발됨.

Wang, N., Zhao, Q., Li, S., Zhao, X. and Zhao, P. (2018) "Damage Classification for Masonry Historic Structures Using Convolutional Neural Networks Based on Still Images" *Computer-Aided Civil and Infrastructure Engineering* 33 (2018) 1073-1089

제7장. 연구개발성과의 보안등급

보안등급 분류	보안	일반
		√
결정 사유		

제8장. 국가과학기술종합정보시스템에 등록된 연구시설·장비 현황

구입 기관	연구시설/ 연구장비명	규격 (모델명)	수량	구입 연월일	구입 가격 (천원)	구입처 (전화번호)	비고 (설치 장소)	NTIS장비 등록 번호
----------	----------------	-------------	----	--------	---------------	---------------	---------------	-----------------

해당사항 없음.

제9장. 연구개발과제 수행에 따른 연구실 등의 안전 조치 이행 실적

(1) 연구실 안전점검

1) 연구실 일상 점검

- 연구시작 전 각 연구실 책임자는 육안으로 장비 및 시설을 매일 점검

2) 연구실 정기 점검

- 과학기술분야 연구실의 일반안전, 산업위생, 전기안전, 소방안전, 화공안전, 가스안전, 기계안전 등의 전문분야 점검
- 매월 각 연구실을 주기적으로 점검

3) 연구실 정밀안전진단

- 산업안전보건법 제39조에 의거 유해인자를 취급 연구실
- 과학기술부령이 정하는 독성가스를 취급하는 연구실
- 매년 1회 이상 외부 전문기관에 의뢰하여 실시 후 중대결함이 발견될 경우, 교육과학기술부에 보고

(2) 교육 훈련

1) 개요

- 연구실 안전 확보 및 종사자의 건강보호, 실험 및 연구활동에 기여, 안전환경조성에 관한 법률 의거 연구실의 환경안전교육이 의무화 목표수립.

2) 교육대상

- 교수, 대학원생, 소속연구원, 전문직원, 실험참여 학부생 등

3) 교육실시

- 1학기 - 법정 교육시간인 6시간을 온라인 및 집합교육으로 실시
- 2학기 - 법정 교육시간인 6시간을 온라인 교육으로 실시

(3) 시설 및 물품 보험 가입 현황

보 험 명	보 상 내 용	대 상	주관부서
연구실 안전공제 보험	사망 : 1억원	연구활동 종사자	시설팀
	부상 : 최대 1,000만원	연구활동 종사자	시설팀
	후유장애 : 최대 1억원	연구활동 종사자	시설팀
학교시설 및 물품 보험가입	- 시설 : 학연산 지원센터 19개동 - 물품 : 서버 외 5115개 품목	학교시설 및 물품	구매관재팀



2019. 1. 8.

연구실안전관리시스템



안전교육 이수증명서

1. 교육생 정보

성명	정진학	학(사)번	2018107739	소속	건축시스템공학과
----	-----	-------	------------	----	----------

1. 안전교육 이수정보

번호	교육구분	과정명	이수일자	이수시간	이수번호	유효기한
1	창기	2018년 2학기 실험실 안전교육	2018.10.24	6	한양대학교 20181024_06077	2018.12.31
총 이수시간						6

위와 같이 안전교육을 이수하였음을 증명합니다.

2019년 01월 08일

**직인
생략**

제10장. 연구개발과제의 대표적 연구 실적

번호	구분 (논문/ 특허/ 기타)	논문명/특허명/ 기타	소속 기관명	역할	논문 게재지/ 특허 등록 국가	영향력 지수	논문 게재일 /특허 등록일	사사 여부 (단독 사사 또는 중복 사사)	특기 사항 (SCI 여부/인용 횟수 등)
1	특허 출원	심층신경망을 이용한 콘크리트 구조물 열화 평가 시스템 및 방법	아주 대학교 산학 협력단	발명자	대한민국	-	2017.11.28	단독사사	-
2	특허 출원	콘크리트 시설물의 표면 이미지 및 딥 컨볼루션 신경망 알고리즘을 이용한 콘크리트 압축강도 예측 방법 및 그 시스템	한양 대학교 에리카 산학 협력단	발명자	대한민국	-	2018.05.14	단독사사	
3	논문	Early Forecasting of Rice Blast Disease Using Long Short-Term Memory Recurrent Neural Networks	아주 대학교 산학 협력단	제1저 자	Sustainability	1.789	2017.12.23	단독사사	SCI
4	논문	Improving financial trading decisions using deep Q-learning : Predicting the number of shares, action strategies, and transfer learning	아주 대학교 산학 협력단	제1저 자	Expert Systems With Application		2018.09.20	단독사사	SCI
5	논문	Introducing a model for evaluating concrete structure performance using deep convolutional neural network	한양 대학교 산학 협력단	제1저 자	International Journal of Sustainable Building Technology and Urban Development		2017.09.30	단독사사	비SCI

6	논문	심층 컨볼루션 신경망을 활용한 영상 기반 콘크리트 압축강도 예측 모델	아주 대학교 산학 협력단	제1저 자	한국건설관 리학회 논문 집		2018.11.26	단독사사	비SCI
7	학술 발표 대회	DCNN(Deep Convolution Neural Network)기반 콘크리트 압축강도 예측 모델을 위한 기초연구	한양 대학교 에리카 산학 협력단	제1저 자	한국건설관 리학회 2017 정기학술발 표대회		2017.11.17	단독사사	학술발표

제11장. 기타 사항

해당 사항 없음

1. 고정원. (2000), 공극분포가 경화콘크리트의 압축강도에 미치는 영향에 관한 실험적 연구 (공학 석사학위). 건국대학교, 서울.
2. 권성준·이학수·박선규 (2012), “단위수량 증가에 따른 시멘트 모르타르의 내구성능과 공극분포에 관한 연구”, 한국구조물유지관리공학회 논문집, 16(3), 75-83
3. 권혁찬·정원경·윤경구 (2004), “이미지 분석에 의한 콘크리트의 공극 분포 및 공기량 분석”, 강원대학교 산업기술연구소 논문집, 24(A), 157-164
4. 기철민·조태훈 (2017), “CUDA를 이용한 Convolutional Neural Network의 효율적인 구현”, 한국정보통신학회 논문지, 21(6), 1143-1148
5. 김동석 (2006), “범용적 적용을 위한 콘크리트 염화물 확산계수 예측에 관한 연구”, 대우건설 기술연구원, 21-24
6. 김두기·이종재·장성규 (2004), “콘크리트 압축강도 추정을 위한 확률신경망”, 한국구조물진단학회 논문집, 8(2), 159-167
7. 김선환·배상운·권성준(2013), “균열 패턴엔 따른 균열부 콘크리트의 염화물 확산계수 모델링”, 건설환경연구소 논문집, 8(2), 1-8
8. 김인수·이종현·양동석·박선규 (2002), “신경망을 이용한 콘크리트 배합요소 및 압축강도 추정”, 한국콘크리트학회 논문집, 14(4), 457-466
9. 김정진·박순전·고주환·한천구 (2008), “염해환경에서의 염화물이온 침투 예측에 관한 연구”, 한국콘크리트학회 학술발표대회 논문집, 20(1), 513-516
10. 김지원·표현아·하정우·이찬규·김정희 (2015), “다양한 딥러닝 알고리즘과 활용”, 정보과학회지, 33(8), 25-31
11. 박재임·배수호·유재원·이광명 (2010), “콘크리트 구조물의 내구수명에 영향을 미치는 인자”, 한국콘크리트학회 학술발표대회 논문집, 22(2), 21-22
12. 박태원·정란 (2010), “콘크리트 압축강도 예측을 위한 뉴로 퍼지 모델이용”, 전산구조공학, 23(3), 61-68
13. 백승우 (2003), “염해를 고려한 철근콘크리트구조물의 내구성 평가”. 석사학위논문, 연세대
14. 신현욱 (2011), “뉴럴네트워크를 사용한 현장배합 콘크리트의 압축강도 추정에 관한연구”, 공학석사학위논문, 강원대학교
15. 안선만 (2016), “딥러닝의 모형과 응용사례”, 지능정보연구, 22(2), 127-142
16. 원민식·이수현·최윤석·양은익 (2011), “동결융해 작용을 받는 콘크리트의 공극구조 및 확산계수 특성”, 한국콘크리트학회 학술대회 논문집, 23(2), 231-232
17. 윤의식·이택우·박승범 (2005), “시멘트 종류별 콘크리트 강도 및 공극률과 염화물 확산계수의 상관관계 분석”, 한국콘크리트학회 논문집, 17(5), 735-742
18. 윤지연·강경인 (2005), “데이터마이닝 기법을 적용한 재생골재 콘크리트 압축강도예측에 관한연구-신경망과 회귀분석 기법을 중심으로-”, 대한건축학회 논문집(구조계), 21(10), 119-126
19. 이승준·이한승 (2017), “배합인자를 고려한 Machine Learning algorithm 기반 콘크리트 압축강도 추정 기법에 관한 연구”, 한국 건축시공학회 학술, 기술논문발표회 논문집, 17(1), 152-153
20. 이승창·임재홍 (2002), “다중 신경망을 이용한 콘크리트 압축강도 추정”, 한국콘크리트학회 학술발표대회 논문집, 14(2), 647-652

-
21. 이창수·박종혁·김영욱 (2010), “염화물 고정화를 고려한 철근 콘크리트 구조물의 내구수명 예측”, 한국방재학회논문집, 10(1),15-22
 22. 한국시설안전공단, 안전점검 및 정밀안전진단 세부지침해설서(건축물), 서울: 시설안전공단, 2011. RD-11-E6-026
 23. LeCun, Y., Bottou, L., Bengio, Y. and Haffner, P. (1998), “Gradient-Based Learning Applied to Document Recognition.” Proceedings of the IEEE, 56(11), 2278-2324.
 24. 김중적 (2014), 비파괴 검사기술의 활용·촉진을 위한 제도개선방안 연구, (사) 한국비파괴검사협회
 25. 국토교통부, 시설물 안전관리체계 종합개선대책 수립 연구, 2017.03 발간등록번호 11-1613000-001781-01
 26. Al-Amoudi OSB, Al-Kutti WA, Ahmad S, Maslehuddin M. Correlation between compressive strength and certain durability indices of plain and blended cement concretes. Cement and Concrete Composites. 2009;31(9):672-6.
 27. Başıyigit C, Comak B, Kılınçarslan Ş, Üncü İS. Assessment of concrete compressive strength by image processing technique. Constr Build Mater. 2012;37:526-32.
 28. Baygin M, Ozkaya SG, Ozdemir MA, Kazaz I. A New Approach Based on Image Processing for Measuring Compressive Strength of Structures. International Journal of Intelligent Systems and Applications in Engineering. 2017:21-5.
 29. Chung S, Han T, Yeom KS, Kim JS. Analysis of Constituents of Insulating Concrete using Micro CT Images. Journal of Korean Society of Hazard Mitigation. 2013;13(2):43-8.
 30. Dogan G, Arslan MH, Ceylan M. Concrete compressive strength detection using image processing based new test method. Measurement. 2017;109:137-48.
 31. Jamkar S, Rao C. Index of aggregate particle shape and texture of coarse aggregate as a parameter for concrete mix proportioning. Cem Concr Res. 2004;34(11):2021-7.
 32. Jia Y, Shelhamer E, Donahue J, Karayev S, Long J, Girshick R, et al. Caffe: Convolutional architecture for fast feature embedding. Proceedings of the 22nd ACM international conference on Multimedia; ACM; 2014.
 33. Lee HS, Kwon SJ. Modeling on compressive strength in high performance concrete using porosity. Journal of the Korea institute for structural maintenance and inspection. 2012;16(6):124-33.
 34. Lee HS, Kwon SJ. Modeling on compressive strength in high performance concrete using porosity. Journal of the Korea institute for structural maintenance and inspection. 2012;16(6):124-33.
 35. Lee H, Lee B, Oh K, Kim Y. Reliability Evaluation for Prediction of Concrete Compressive Strength through Impact Resonance Method and Ultra Pulse Velocity Method. Journal of the Korea institute for structural maintenance and inspection. 2015;19(4):18-24.
 36. 조홍범, 윤상천, 지남용. 배합표에 의한 현장콘크리트의 압축강도 추정. 대한건축학회 논문집-구조계. 2003;19(4):105-12.
-

-
37. Mnih V, Kavukcuoglu K, Silver D, Rusu AA, Veness J, Bellemare MG, et al. Human-level control through deep reinforcement learning. *Nature*. 2015;518(7540):529.
 38. He K, Zhang X, Ren S, Sun J. Deep residual learning for image recognition. *Proceedings of the IEEE conference on computer vision and pattern recognition*; ; 2016.
 39. Howard AG, Zhu M, Chen B, Kalenichenko D, Wang W, Weyand T, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*. 2017.
 40. Huang G, Liu Z, Van Der Maaten L, Weinberger KQ. Densely connected convolutional networks. *CVPR*; ; 2017.
 41. Iandola FN, Han S, Moskewicz MW, Ashraf K, Dally WJ, Keutzer K. Squeezenet: Alexnet-level accuracy with 50x fewer parameters and < 0.5 mb model size. *arXiv preprint arXiv:1602.07360*. 2016.
 42. Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Advances in neural information processing systems*; ; 2012.
 43. Larsson G, Maire M, Shakhnarovich G. Fractalnet: Ultra-deep neural networks without residuals. *arXiv preprint arXiv:1605.07648*. 2016.
 44. Lin T, Dollár P, Girshick RB, He K, Hariharan B, Belongie SJ. Feature Pyramid Networks for Object Detection. *CVPR*; ; 2017.
 45. Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*. 2014.
 46. Szegedy C, Liu W, Jia Y, Sermanet P, Reed S, Anguelov D, et al. Going deeper with convolutions. *Proceedings of the IEEE conference on computer vision and pattern recognition*; ; 2015.
 47. Zeiler MD, Fergus R. Visualizing and understanding convolutional networks. *European conference on computer vision*; Springer; 2014.
 48. Keskar NS, Mudigere D, Nocedal J, Smelyanskiy M, Tang PTP. On large-batch training for deep learning: Generalization gap and sharp minima. *arXiv preprint arXiv:1609.04836*. 2016.
 49. Kingma DP, Ba J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*. 2014.
-

주 의

1. 이 최종보고서는 국토교통부에서 시행한 국토교통기술촉진연구사업의 연구보고서입니다.
2. 이 최종보고서 내용을 발표하는 때에는 반드시 국토교통부에서 시행한 사업의 연구개발성과임을 밝혀야 합니다.
3. 국가과학기술 기밀 유지에 필요한 내용은 대외적으로 발표 또는 공개하여서는 안 됩니다.