

19CTAP
-C142170
-02

3차원
센서
데이터를
활용한
도시 분석
자동화
기법
(100m 급
시각영역
과 위상학
지도 제
작)

최
종
보
고
서

2019

국
토
교
통
과
학
기
술
진
흥
원

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

국토교통부/국토교통과학기술진흥원 제2차 연도 최종 보고서

R&D / 19CTAP-C142170-02

3차원 센서 데이 터를 활용한 도시 분석 자동화 기법 (100m 급 시각영역과 위상학 지도 제작)

최종보고서

2020. 02. 07.

주관연구기관 / 한국과학기술원

국토교통부

(전문기관) 국토교통과학기술진흥원

제 출 문

국토교통과학기술진흥원장 귀하

‘3차원 센서 데이터를 활용한 도시 분석 자동화 기법 (100m 급 시각영역과 위상학 지도 제작)’(연구개발 기간 : 2018. 04. 01. ~ 2019. 12. 31.) 과제의 최종보고서 10부를 제출합니다.

2020. 02. 07.

주관연구기관명 : 한국과학기술원 (대표자) 신성철

협동연구기관명 : (대표자)

참여기관명 : (대표자)



주관연구기관책임자: 김영철

협동연구기관책임자:

참여기관책임자:

국토교통부소관 연구개발사업 운영규정 제29조에 따라 최종보고서 열람에 동의합니다.

보고서 요약서

과제 고유 번호	19CTAP-C142 170-02	해당 단계 연구 기간	2018. 04. 01. - 2019. 12. 31	단계구분	2단계/ 2단계
연구사업명	중사업명	국토교통기술촉진사업			
	세부사업명	국토교통기술촉진사업			
연구과제명	대과제명				
	세부과제명	3차원 센서 데이터를 활용한 도시 분석 자동화 기법 (100m 급 시각영역과 위상학 지도 제작)			
연구책임자	김영철	해당단계 참여연구원 수	총: 20명 내부: 20명 외부: 명	해당단계 연구비	정부:370,000천원 민간: 천원 정부외: 천원 상대국: 천원 계:370,000천원
		총 연구기간 참여연구원 수	총: 20명 내부: 20명 외부: 명	총 연구비	정부:370,000천원 민간: 천원 정부외: 천원 상대국: 천원 계:370,000천원
연구기관명 및 소속 부서명	한국과학기술원 건설및환경공학과			참여기업명	
국제공동연구	상대국명:			상대국 연구기관명:	
위탁연구	연구기관명:			연구책임자:	

※ 국내·외의 기술개발 현황은 연구개발계획서에 기재한 내용으로 같음

연구개발성과의 보안등급 및 사유	「국가연구개발사업의 관리 등에 관한 규정」 제 24조의 4에 해당하지 않음
-------------------------	---

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	7	2									

국가과학기술종합정보시스템에 등록된 연구시설·장비 현황

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

요약	보고서 면수 162
----	------------

요약문

연구의 목적 및 내용	- 본 연구는 도시공간의 3차원 디지털 데이터 구축을 위하여 자율 주행을 위한 3차원 지도제작에 사용되는 맵핑 차량 데이터를 처리하여 도심 환경을 분석하는 이론의 세계 최초 구축을 목표 - 도심 환경에서 측정되는 데이터로 학습하고, 학습된 데이터를 통해 기존보다 저비용으로 실제 데이터를 기준으로 자동화하고 정량화할 수 있는 도시공간의 측정과 분석을 위한 기초 원천 이론을 구축 - 도시공간의 형태를 실질적으로 파악하기 위한 기초 연구로, 바탕이 되는 이론의 완성을 목표로 하여 국토설계 기술개발을 위한 기초 원천 기술의 개발이 목표				
연구개발성과	- 도시의 3차원 공간을 모바일 리모트 센서 데이터로 활용하여 3차원 시각영역과 위상적 공간분석의 시스템을 개발하는 원천기술의 개발 - 도시공간의 3차원 시각영역의 특징을 분석하는 자동화된 방법을 개발 - 3가지 진행 단계: (1) 문제 해결 방식의 설정, (2) 센서 데이터 처리 컴퓨터 알고리즘 구성, (3) 도시공간 분석을 위한 3차원 시각영역의 이론화 및 적용 1) 데이터 특성에 따른 3차원 시각영역을 측정하는 이론 정립 2) 3차원 시각영역에 기반한 도시공간의 특징을 구분하는 이론 정립 3) 센서 데이터에서 3차원 시각영역을 분석하는 컴퓨터 알고리즘을 구성 4) 3차원 시각영역의 패턴을 학습하여 도시공간을 분석하는 알고리즘을 구성 5) 맵핑 차량 데이터에 정의된 시각영역을 적용하고 도시 공간의 특징을 분석 6) 실효성 높은 기술 개발을 위해 실제 도심환경 데이터를 통한 도시 분석 - 도시 공간의 3차원 시각적 인식 영역 측정과 분석의 기초 원천 이론을 개발 - 구체적인 연구성과물은 다음의 세 가지를 포함 1) 도시 공간의 3차원 시각적 인식 영역 측정 및 분석의 이론과 본 내용의 논문과 특허 2) 기계 학습 기반 도시 공간의 인식 및 분석을 위한 알고리즘 개발 3) 센서데이터에 기반한 다시점 도시 인식 모델 확립				
연구개발성과의 활용계획 (기대효과)	- 도시의 3차원 공간을 모바일 리모트 센서 데이터를 활용해 공간분석 시스템 원천기술을 개발함으로써, 도시 공간의 분석에 활용 - 도시공간의 3차원 시각영역 특징 분석의 자동화 - 기계 학습 기반 도시 공간의 인식 및 분석 활용 - 센서데이터에 기반한 다차원 및 다시점 도시 인식 모델 활용 - 도시공간을 자동적으로 인식하는 자동화 알고리즘 개발 - 실제 도심 공간 적용을 통한 다양한 데이터와의 연결 활용 - 3차원 도시공간의 실시간 처리 - 도시공간의 문제점 파악 및 효과적인 공간 분석				
국문핵심어 (5개 이내)	도시 공간	포인트클라우드	시각영역	리모트 센싱	라이다
영문핵심어 (5개 이내)	Urban space	Point Cloud	Visibilty	Remote Sensing	LiDAR

※ 국문으로 작성(영문 핵심어 제외)


< 목 차 >

1. 연구개발과제의 개요	5
가. 연구 목표	5
나. 연구 배경 및 개요	6
다. 연구개발 대상의 국내외 현황	14
라. 연구개발의 중요성	27
2. 연구수행내용 및 성과	29
가. 연구수행내용	29
나. 연구개발성과	142
3. 목표 달성도 및 관련 분야 기여도	145
가. 정량적 및 정성적 목표 달성도	145
나. 관련 분야 기여도	153
다. 연구개발의 창의성 · 혁신성	155
라. 목표달성여부	156
4. 연구개발성과의 활용 계획 등	158
가. 연구개발성과의 활용 방안	158
나. 기대효과	159
붙임. 참고문헌	161

1. 연구개발과제의 개요

가. 연구 목표

□ 본 연구는 스마트시티의 기본이 되는 도시공간의 3차원 디지털 데이터를 분석하여 도시 환경을 분석할 수 있는 “도시공간의 3차원 디지털화를 위한 모바일 리모트 센서 데이터에 기반한 3차원 시각영역과 위상적 공간분석을 위한 시스템 개발의 기초 원천 기술의 개발”을 목표로 한다. 기존의 자율 주행을 위한 3차원 지도 제작에 사용되는 매핑 차량 데이터를 도시공간의 분석으로 확대하는 원천기술로, 도심 환경을 분석할 수 있는 데이터로 학습하고, 학습된 데이터를 통해 저비용으로, 실제 데이터를 기준으로, 자동화하고 정량화할 수 있는 기술을 개발하고자 한다. 특히 모바일 매핑 시스템의 리모트 센싱 기술인 라이다를 활용하여, 3차원 100m 시야공간범위의 다시점 도시공간의 시각영역을 측정하고 분석하는 이론을 개발하려고 한다. 또한 본 결과를 바탕으로 향후 진행할 도시공간의 형태와 도시공간정보와의 관계를 분석하기 위한 기술을 수립하려고 한다.



〈그림〉 도심 매핑 센서 데이터 기반의 도시 공간 분석 기법의 개요도

□ 본 연구는 최종성과물은 아래와 같은 주요 성과로 정리할 수 있다.

1) 도심 환경 분석을 위해 정밀 지도 제작 시스템을 활용

- 도시공간 분석을 위해 자율주행 차량용 정밀한 지도 제작 센서 시스템의 데이터를 활용하여 도시공간의 특성을 파악하는 이론을 제시한다.

2) 가상구축 모델이 아닌 데이터 기반 실효성 있는 연구

- 도시를 가상으로 구축된 모델이 아닌 실제 데이터를 바탕으로 도시공간의 특징을 파악하는 자동화된 분석 방법을 제시한다.

3) 빅데이터인 맵핑 데이터의 분석 자동화

- 도시공간의 특징을 분석하기 위하여 기계학습을 이용한 도시 공간의 특징을 파악하는 데이터 학습 방법을 제시한다.

나. 연구 배경 및 개요

□ 도시는 사람이 일생 생활을 영유하는 기본적인 환경이고 다양한 분야의 기술이 직접적으로 적용되는 공간이다. 도시 속에서 이루어지는 다양한 행동, 변화, 공간의 특성들을 분석하려고 하고 그러한 분석결과로 도시를 더욱 발전시키려고 한다. 스마트도시라는 개념의 도입으로 도시는 점차 스스로 도시가 포함하는 특징을 분석하여 문제점과 개선방향을 발견하여 사람이 살기에 더욱 좋은 도시공간이 되도록 연구를 진행하고 있다.

□ 특히 도시공간을 분석하여 도시 속의 특징을 사람이 활동하는 공간과의 연관성을 파악하여 여러 사회문화적인 현상과 연계하여 도시의 특징을 분석하려고 시도하고 있다. “Eyes on streets” 과 같은 도시공간에서 사람들의 시선에 의해 자연스럽게 형성되는 공간의 사회적 안정성에 관한 사회이론과 긴급한 상황에서 시각적 인식에 의해서 공간을 빠져나가는 경향에 관한 연구, 공공공간에서 CCTV의 최적화 설치 등 도시공간에서 물리적 형태와 사람의 시각적

인식의 영향에 관하여 지속적으로 다양한 연구를 발전시키고 있다.

□ 하지만 도시를 구성하는 복잡함이 매우 높아 아직까지 직접적인 분석을 하고 있지 못하고 있다. 기존의 도시공간의 분석은 추가적으로 제작되는 가상데이터 모델이나 기구측된 고가의 수치지도를 바탕으로 이루어지고 있다. 현재는 가정의 의한 한계적인 분석에 머무르고 있어 정밀한 분석이나 고도의 의미를 분석하기에는 한계가 있다. 따라서 데이터를 바탕으로 도시의 특징을 분석하여 예측하는 스마트도시를 구축하기에는 시간과 비용측면에서 비효율적인 현황이다.




□ 고가의 항공센서를 사용한 기존의 방법은 업데이트 주기가 길며 항공부 레벨에서의 도시 지도 작성으로 실제 사람이 인식하는 도시공간의 분석과는 차이가 발생하게 된다. 또한 도시공간의 측정으로 정밀지도 작성을 위한 매핑 차량 관련 연구가 진행 중이나 아직 많은 부분이 수작업에 의존하고, 도로부분에만 집중하여 전체적인 도시를 인지하는 분석에는 한계가 있다. 특히 측정된 데이터의 도로에 집중된 1차원적인 공간정보로만 사용되어, 형태나 위치 등의 직접적인 내용을 측정하는데 머무르고 있고, 이를 바탕으로 데이터가 나타내는 도시공간에서 상위레벨의 의미(semantic)를 분석한 시도가 아직은 없다.

□ 하지만 매핑 차량은 상시 활용이 가능하며 항공 센서 (항공사진, 항공 라이다(LiDAR)센서)에 비해 상대적으로 저가이고 풍부한 도심 데이터의 획득이 가능하다. 매핑 차량에 의한 풍부한 도심 데이터 획득으로 형태나 위치 등의 직접적인 데이터와 함께, 도시 공간에서 상위레벨의 의미(semantic)를 찾는 빅데이터로 활용할 수 있다. 따라서 3차원 센서 데이터를 기계학습법으로 분류하고 분석하여 공간 레이블링을 자동화하는 연구가 필요하고, 도심 데이터를 학습하고 분석에 사용하는 기초 원천 기술의 이론을 구축하여 향후 지속적인 스마트도시를 구축하기 위한 데이터 기반의 도시공간의 연구의 바탕이 되는 원천 기술이 필요하다.



〈그림〉 Google Earth 가 제공하는 항공사진 기반 3차원 도시 모델 (뉴욕시)


- 현재 기술로 도시 공간의 특징을 시각적 기준으로 측정하기 위한 기존의 방법은 관측지점에서 주변부의 시각영역의 범위 (Visual field 또는 Isovist)를 측정하는 2차원 방법이 주로 사용되고 있다. 도시공간은 3차원적으로 구성되어 있어 기존의 2차원 도시공간 분석으로는 한계가 있고, 기존의 3차원 분석을 위한 방법의 구축은 실제적인 측정에 의한 리모트 센싱에 의한 기술개발은 현재 미흡하다.



〈그림〉 국토지리정보원이 제공하는 3차원 정밀지도 (여의도)


□ 국토지리정보원은 3차원 정밀 지도를 구축 중에 있으며, 최근 여의도 등의 도심을 포함한 지역의 센서 데이터도 공개하였다. 미국의 Google사는 최근 업데이트를 통해 전세계 3차원 지도 제공지역을 확장하였다. 본 연구는 활용 가능한 센서 데이터를 사용하여 범용적으로 적용가능한 알고리즘을 개발하는 것을 목표로 한다. 현재의 모바일 매핑시스템은 많은 수작업에 의존한 맵 제작 기법으로 제작된다. 이런 부분을 자동화하기 위해서 본 연구는 도시 분석을 통한 계층 지도 학습을 제안한다. 도시 공간 분석을 통해 요소를 파악하고 주요 공간 요소를 차등화하여 계층 지도를 제작하여 추후 지도 제작 과정을 자동화하고, 고차원의 분석이 가능하다.


□ 리모트 센싱 (Remote sensing) 기술의 발전에 따라 라이다 (LiDAR, Light Detection and Ranging)를 활용하여 환경을 인식하고 지도를 작성하는 기술이 발전 중에 있다. 도시공간을 3차원으로 인식할 수 있는 기술로, 라이다에 의해서 얻어지는 포인트 클라우드 (Point Cloud)로 도시공간을 측정하여 무수하게 많은 공간의 위치 정보 데이터를 획득할 수 있다. 특히 자율주행차량용 인식장비, 공간정보 측정용 항공기 등 기계의 공간 인식 기술로 적용하여 자율 주행, 공간정보 구축에 활용되고 있다.



<그림> 연구진이 보유한 매핑 차량과 보유 기술로 제작된
3차원 정밀 지도(좌)와 항공 사진(우)

□ 도시 공간의 특징을 측정하기 위해서 기존에는 관측지점에서 주변부의 시각영역의 범위 (Visual field 또는 Isovist)를 측정하는 2차원적인 방법을 사용하였다. 도시공간을 관찰자 중심으로 시각 영역을 구분하고, 시각영역의 연결 관계를 표현하여 도시공간의 활용과 영향을 파악하기 위하여 사용하였다. 2차원 (x-y 축)의 도시공간의 시각영역의 중첩과 영역간의 연계성 등의 요소와 교통량, 점유율, 부동산 가격 등의 정보를 연계하여 도시공간의 2차원적 분석에 주로 활용되고 있다. 그러나 도시공간의 3차원적인 특성은 기존의 2차원 도시공간 분석으로는 한계가 있고, 3차원 분석을 위한 방법의 구축이 시도 중이나 리모트 센싱에 의한 기술은 현재 개발되어있지 않다.





<그림> 시각영역의 개념과 도시의 특성 분석 예시 (기존의 연구는 2차원적 데이터에 의존)


- 리모트 센싱으로 구축된 영역을 기계학습 기법으로 분류하고 분석하면 도시공간을 자유로운 다시점 분석이 가능하다. 매핑 차량에 탑재된 센서 데이터를 통해 만든 3차원 센싱 데이터는 기계학습법으로 분류되고 분석되어 공간 레이블링이 가능하다. 따라서 3차원 공간으로 분류된 센서 데이터 내에서 시점변화가 자유롭기 때문에 단일 시각에 의존한 분석이 아닌 다시점 다차원 분석이 가능한 장점이 있다.

- 따라서 도시 공간의 특징을 시각적 기준으로 측정하는 기존의 2차원 방법을 3차원으로 확장하기 위한 이론으로 리모트 센싱 기술을 이용한 도시 공간을 측정하는 이론의 개발이 필요하다. 특히 리모트 센싱 기술을 활용하여 자동화된 도시 공간을 측정하기 위한 기초적인 이론이 필요하다. 국제적으로 리모트 센싱 기술인 라이다(LiDAR)를 이용한 3차원 시각영역의 인식 방법의 가능성을 시사했으나 실제 측정되는 시각영역의 측정과 분석을 위한 구체적인 이론화와 기술적 발전은 아직 없다. 그리고 자동화된 로봇 기술을 적용한 도시 공간의 인식하고 분석하는 방법은 복잡한 도시 공간의 특징을 구분하고 분석하는 방법을

제시하고, 다양한 시점에 의한 도시 공간을 분석하는 자동화된 방법으로 확장할 수 있다.

- 따라서 3차원 시각영역 측정 방법을 이론화하여 도시 공간의 국토설계 기술을 위한 기초적 이론을 구축하고 국제적으로 선도하는 분야로의 발전을 추구하는 연구가 필요하다. 리모트 센싱 기술을 활용한 자동화된 3차원 시각 영역 인식의 측정은 도시 공간의 특징을 파악하기 위한 기초 기술로 지능형 도시 공간인 스마트시티의 공간 정보 체계를 구축하기 위한 기초자료로 활용이 가능하다. 자동화된 기술로 측정된 데이터를 기반으로 구축된 스마트 도시공간에는 3차원 시각영역에 관한 정보가 포함되고, 사람들의 도시공간의 시각적 인지와 연관관계를 표현할 수 있다. 도시 공간의 직접적인 특징과 함께 공간간의 연결을 통한 공간 구조를 파악하여 도시공간의 의미를 나타내는 알고리즘의 구현이 필요하다. 이러한 알고리즘은 도시공간에서 이루어지는 사회적, 문화적 현상과 연관성을 분석하여 스마트시티에서 추구하는 도시 데이터의 분석을 바탕으로 생활의 질을 향상하는 도시 공간의 계획과 관리로 발전을 도모할 수 있다.





〈그림〉 연구진이 보유한 매핑 차량에 탑재한 센서 데이터로 도시공간을 시각화한 예시


- 국제적으로 3차원 시각영역을 분석을 시도하고 있으나 차량 이동형 리모트 센싱 기술로 개발된 이론과 실험이 없다. 국제적으로 기술의 발달에 의해 도시공간 분석에 3차원 요소의 가능성을 제시하고, 시기적으로 국제적으로 널리 사용할 수 있는 새로운 기술의 기초 이론의 원천기술의 제안이 가능한 중요한 시점이다.

다. 연구개발 대상의 국내외 현황

(1) 국내 현황


- 국내 도시 공간의 2차원 시각영역 분석의 연구 현황은 2차원의 시각영역을 활용하여 도시 내 사회적 현상에 관한 분석 연구를 진행하고 있다. 기존의 수치지형도에서 추가적으로 물리적 공간을 구분하여 해당하는 지역에 따라 분석하는 방식으로 진행 중이다. 그러나 리모트 센싱 기술은 국내에는 자율주행, 국토지리정보 구축의 분야에 사용하고 있어, 도시공간의 측정과 분석을 위한 이론은 개발되지 않은 상황이다.

- 국내 도시 공간의 3차원 시각영역 분석의 연구 현황은 3차원 시각영역을 기존에 구축된 수치지형도를 활용하거나 가상으로 도시공간을 형성하여 경관분석에 활용하고 있다. 도시의 경관 분석, 조망권 등 도시계획시설의 영향에 평가하기 위한 방법을 제안하였다. 그러나 실제 도시 공간을 측정하여 적용하지 않고, 기존에 구축된 수치지형도나 수작업으로 작성된 가상공간의 데이터를 활용하는 한계를 보여주고 있다. 도시공간의 영향분석을 위하여 별도로 구축해야하는 도시공간의 정보 (나무 등의 식생 정보)와 정확도에 따라 분석 결과가 부정확할 수 있다. 예로 중요문화재 보호를 위한 주변 도시의 경관 분석시 3차원 시각영역을 활용하였으나 연구자 임의로 영향영역을 설정하고, 수치지형도에 수 시간의 별도 추가 작업을 하여 3차원 도시공간을 분석하는 방법으로 진행하였다.




〈그림〉 중요문화재와 주변 도시공간과 영향을 3차원 시각영역을 활용한 분석

- 국내 모바일 매핑 시스템은 차량이나 드론을 이용한 모바일 매핑 시스템(Mobile Mapping System, MMS)의 상용화를 가속하고 있다. (주)씨투엘이콥먼트는 차량과 드론에 탑재한 MMS를 통해 실내와 실외 매핑을 진행하고 있는데 특히 GPR (Ground Penetrating Radar)를 MMS에 추가하여 도로표면관리 및 동공탐사에 적용하고 있다.





〈그림〉 씨투엘이콥먼트 보유 차량 및 매핑 결과

- 또한 국내기업인 (주)위프코는 시설물과 실내 공간 매핑기술을 보유하고 있으며 특히 대규모 시설의 3차원 복원과 모델링 관련 기술을 보유하고 있다. 해당 기술은 시설물의 정밀 3차원 복원을 목표로 이동형 센서와 융합보다는 정적 센서를 사용하여 정밀 매핑에 중점을 두고 있다.



〈그림〉 위프코 사의 3D 매핑 기술

- 국토지리정보원은 정밀지도를 구축하고 있다. 2016년 자율 주행 자동차를 위한 지도 제작을 진행하여 고속도로 1개 구간과 일반국도 7개 구간 등에 대해서 정밀 지도를 구축하였다. 정밀도로지도는 3차원 전자지도의 형태로 차량용 매핑 시스템을 통한 레이저 측량으로 구축되었다.



〈그림〉 교차로의 정밀 지도 샘플


□ 국토지리정보원은 총 3대의 모바일 매핑 시스템 장비(Optech, Leica, Mitsubishi)를 투입하여 2015년 2016년 시범 사업을 수행하였다. 국토지리정보원에서 구축한 지도는 자율 주행 차량을 위한 데이터이므로 차선레벨 및 교통 표지판, 신호 등의 교통 정보에 집중을 하여 매핑 데이터를 처리하였고, 주로 차선 레벨의 지도 정보를 제공하고 있다. 매핑 정확도는 5~6센티미터 레벨로 이는 GPS와 내장 센서인 IMU 센서의 오차를 포함 하는 값으로 매우 정밀하다. 그러나 해당 시스템은 글로벌 내비게이션 인공위성 시스템 (GNSS, Global Navigation Satellite System) 값의 의존도가 매우 높아 정밀 위성 자료 수신시에는 정밀 지도를 생성할 수 있으나 터널이나 아파트 단지 고층건물 군집 지역에서는 오차가 수m까지 나거나 전혀 매핑이 어려울 수도 있다. 이러한 단점과 추가적인 오류는 현재 수작업에 의존하여 진행되고 있으며 인도 등에서 수 천명의 인력으로 오차를 보정하고 노이즈를 제거하고 있는 실정이다. 따라서 도시 분석과 같은 상위 분석 기술과 도시의 이해는 인력에 의존하기에는 한계가 있으며 자동화 기술 및 센서 처리 기술과의 접목이 필요하다.

□ 국내 기업 및 연구소의 도시 매핑 및 지도 작성 연구 개발로 공간정보연구원은 한국건설기술연구원, 한국생산기술연구원, 자동차부품연구원, 차세대융합기술연구원과 함께 지능형 자동차의 인식기술 개발 지원을 위한 과제를 수행 중이다. 해당 과제 역시 지도와 인식 기술이 자율 주행에 적용되며, 중앙분리대, 차로폭 등과 같이 주행과 관련된 인식 기술이 주로 진행되고 있다. 그리고 현대 MnSoft사 역시 고정밀지도 개발 구축 사업에 들어갔으나 운전자 지원 시스템 (ADAS)의 강화나 향후 개발되는 자율 주행 자동차를 위한 연구 위주로 진행되고 있다.

(2) 국외 현황

□ Google Earth나 각 지도 업체는 3차원 지도 사업을 진행하고 있다. Building Information Model (BIM) 등의 도입을 통해 3차원형상을 제작하고 있으며, Google사는 45도 시야각이 있는 항공사진을 정합하는 vision 처리 기법을 사용하여 항공사진을 통한 도시의 3차원 복원을 시도하고 있다. 다만 항공사진의 경우 정밀한 GNSS 장비를 추가적으로 사용하여 정합이 가능하며, 복잡한 도심 환경의 경우 도심 내부의 시야 확보가 불가하다. 따라서 Google의 경우 주로 대도

심의 모델링을 목표로 하고 하여 항공사진 복원 기술을 적용하고 있다.




〈그림〉 건물 모델을 이용한 3차원 시야 계산

- 도시 매핑 시스템 (Urban Mapping System) 또는 이동형 매핑 시스템은 전 세계적으로 다양한 기업이 개발하였고 지도 제작사업을 진행하고 있다. 거의 대부분의 시스템은 GNSS 또는 고정밀 실시간이동 글로벌 위치정보 시스템 (RTK-GPS, Real Time Kinetic-Global Positioning System)에 의존하여 매핑을 하는 방식을 선정하여 사용하고 있다. 일본의 미쓰비시는 MMS-X, MMS-X320R, MMS-K320 등의 제품군으로 3개에서 6개의 카메라를 사용하여 cm 레벨의 정확도를 갖는 지도를 생성하고 있으며, Topcon의 경우 라이다(LiDAR) 스캐너와 전방향 카메라를 사용하여 매핑시스템을 구축하고 있다.


- 정적 LiDAR 데이터를 이용한 건축물의 3차원 복원을 위해 정밀 측량이 가능한 3차원 LiDAR를 사용하여 도시 내의 건축물에 대한 정밀 복원 기술을 적용하고 있다. 구체적으로 도로면에 위치한 사람의 눈높이에서 측정한 데이터를 정합하여 정밀 건물 복원에 이용하고 있다.

해당 기술은 하나의 건물을 스캔하기 위하여 다양한 각도에서 정적인 데이터를 취득을 필요로 하며, 한 번 스캔에 걸리는 시간이 30분 이상이 필요하다. 따라서 센서의 설치 시 수작업이 필요하여 시간이 많이 소요되고, 해당 방식을 도시 전체에 적용하기에는 효율성이 현저히 낮아서 불가능하다.



〈그림〉 정적인 라이다 (LiDAR) 센서를 이용한 건물 복원

- 센서를 이용한 도심 환경 복원 기술은 하단의 그림과 같이 최근 자동차와 같은 운동성이 있는 플랫폼에 센서를 설치하여 이미지나 LiDAR 데이터를 취득할 수 있는 기술로 발전하고 있다.




〈그림〉 도심환경 복원에 사용되는 다양한 센서의 종류



〈그림〉 수천-수만장의 사진으로부터 도시를 복원하는 SFM 기법

□ 또한 영상의 합성을 통한 Structure-from-motion (SFM) 기법은 여러장의 영상의 합성을 통해서 구조물을 복원하는 기술이다. 궁극적으로 대규모 데이터의 최적화 문제를 푸는 방법으로 최근 Microsoft 사를 비롯한 computer vision 업체에서 진행하고 있다. 관광지나 유적과 같이 수천~수만장의 사진을 찍는 장소를 선정하였으며 인터넷에 업로드 되는 사진으로부터 해당 구조물을 복원하는 기법을 소개하였다. 그러나 해당 기법은 매우 큰 범위(large scale)의 최적화 문제를 풀기에 시간이 매우 오래 걸리며 (수일) 인터넷에 올라온 사진으로부터 초점거리(focal length) 등과 같은 카메라 정보가 존재할 때만 사용이 가능하다. 사진의 다양성에 따라서 최적화 해가 구해지지 않고 왜곡이 발생하는 단점도 존재한다.



<그림> 센서 데이터 기반의 다양한 도심환경 복원 기법

□ 반면 라이다 (LiDAR) 센서의 경우 영상에 비해 직접적으로 구조물의 정보를 데이터화하여 제공하는 장점이 있다. 이 경우 동적 플랫폼에 탑재된 라이다 (LiDAR) 데이터 처리가 필요하다. Riegl 사는 라이다 (LiDAR)와 카메라를 융합한 센서시스템을 통해 색정보가 부과된 매핑 결과를 제시하고 있다. 정교한 내부 보정 (calibration)에 의해 카메라 정보와 라이다 (LiDAR) 정보의 연결이 미리 정의되고 이를 이용하여 색정보가 포함된 3차원 지도의 생성이


가능해졌다.



<그림> Riegl 사의 센서시스템과 도심 매핑 결과


□ 매핑 시스템에서 얻는 데이터는 초당 수백MB의 데이터로 구성되어 있어 대용량 데이터의 표현

및 데이터로부터 정보 측정 기법이 중요하다. 최근 자율 주행 관련 연구에서도 대용량의 데이터를 실시간으로 압축하고 상위 레벨의 표현 기법을 적용하는 연구가 진행하고 있다. 이는 시각영역 계산을 위한 영역 설정에도 기본적으로 필요한 기법이다.



〈그림〉 시각영역의 중첩 방법을 활용한 거리에서 인식되는 도시공간 분석

- 도시 공간의 시각영역을 활용한 분석의 연구 현황은 2차원 시각영역의 분석 방법은 도시의 사회, 문화, 경제적 특성과 연관성을 찾아 도시계획과 정책에 필요한 정보를 제공하는 연구를 진행하고 있다. 또한 도시 환경의 분석에 3차원 시각영역 개념을 도입하여 신재생 에너지인 태양광 에너지 활용을 위한 효율적 배치에 관한 연구도 진행하고 있다. 이처럼 이미 작업되어 구축된 디지털입면모델에 의한 도시경관의 영향 분석에 적용이 주로 진행되는 연구이며 최근에는 항공측량 라이다(LiDAR)의 활용을 시도하고 있다.



〈그림〉 디지털입면모델을 사용한 도시공간의 시각 영향 크기 분석

(3) 기술개발 성숙도

- 현재 리모트 센서에 의하여 도시공간이 3차원으로 구축되고 있으나 이를 활용한 연구는 정밀지도구축에만 활용되고 디지털 데이터로 구축된 3차원 공간이 제공할 수 있는 도시에 적용하여 활용하는 연구는 부족하다.
- 1차년도에는 이론적 아이디어를 이론화하여 기술적 개념을 정립하고자 하며 기존의 구축된 데이터를 일부 사용하여 기초적인 개념을 달성하고, 2차년도에는 이런 기술개념을 실제 도시공간을 분석하여 시각영역과 위상적 공간분석의 성능평가를 이루도록 하려고 한다.

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

라. 연구개발의 중요성

- 본 연구의 3차원 시각 영역 인식의 측정은 도시 공간의 특징을 파악하기 위한 기초 기술로 지능형 도시, 스마트 시티 공간의 공간 정보 체계를 구축하기 위한 기초자료로 활용이 가능하다. 지능형 도시 또는 스마트 시티를 형성하기 위하여 시각영역에 관한 정보가 포함된 기본 지도로 구축이 가능하여 도시공간의 사람들의 시각적 인지와 연관관계를 표현하는데 사용할 수 있다. 따라서 도시의 공간간의 연결과 그 연결을 통한 공간 구조를 표현할 수 있는 지도를 형성할 수 있는 알고리즘을 구현을 위한 이론의 구축을 추구하려고 한다. 도시공간에서 이루어지는 사회적, 문화적 현상과 연관성을 분석하여 지능형 도시, 스마트 시티에서 추구하는 도시 데이터의 취합과 분석의 효과가 사람이 생활하는 공간을 고려한 계획과 관리로 연계를 도모할 수 있다.
- 또한 본 연구는 도시공간을 분석하기 위해 3차원 시각영역을 측정하고 분석하기 위한 자동화 이론을 수립하는데 도움을 줄 수 있다. 본 연구에서 제안할 이론은 발달된 기술을

활용하여 실시간, 실제적인 도시공간의 측정과 분석에 기여할 수 있도록 추진하려고 한다.

- 본 연구는 국제적인 이론을 발표하여 국내의 우수한 이론을 세계의 여러 나라의 연구자, 실무자 등이 쉽게 사용할 수 있는 이론을 제안하고자 한다. 따라서 국제적인 연구자와 실무자 등이 도시공간을 분석할 때 협업을 할 수 있는 이론의 배경을 제공할 수 있으며, 한국의 국제적 인식을 높일 수 있는 국제적인 연구결과를 성취하고자 한다.


- 다학제적 접근을 통한 차별성 있는 연구를 수행하려고 한다. 도시 분야의 도시공간분석을 수행하고 있는 연구책임자가 건설로봇분야의 기계 및 전지전자공학에 특화된 공동연구 그룹과 연구를 수행하여, 융합 전공에서만 도출이 가능한 연구를 수행하려고 한다. 또한 연구책임자 외 학생 연구원 (박사후연구원, 박사과정, 석사과정, 학사과정)의 종합적인 연구체계를 구축하여 추진하려고 하고, 학부생 연구 참여 프로그램을 각 차년도마다 수행하여 융합연구 기회를 제공하려고 한다. 따라서 차세대 융합 연구 인재를 양성하는 교육과 연구 환경을 제공할 수 있도록 추진할 계획이다.

2. 연구수행내용 및 성과

가. 연구 수행 내용

(1) 기존 시각영역의 정의와 기존 방법 한계 조명


- Isovist는 Benedikt 가 1979년 제안 (To take hold of space: isovists and isovist fields. Environment and Planning B: Planning and design, 6(1), 47-65.)한 개념으로써 어떤 공간 속 관측자의 가시 가능 공간의 polygon을 의미한다.
- 2차원에서는 다음과 같다.



〈그림〉 Isovist 의 개념 설명


- 이는 관측자의 위치 (그림에서 까만 점)에 따라 도형의 shape 이 변화하고 이로 인해 유도되는 기타 많은 수치들 (기울기, 넓이, 뾰족한 정도 등)도 함께 바뀌기 때문에 공간 그 지점 자체의 특성이 된다. 따라서 공간의 이동에 따라 isovist 및 isovist 의 물리량들이 어떻게 변화하는지를 연구하는 선행논문들이 많았다.
- 하지만 3차원 공간에서는 가시공간을 어떻게 정의해야 하는지 하나의 합의가 아직까지 존재하지 않는다. 이는 크게 3차원 공간을 모델링하기 어렵다는 점에서 기인한다. 따라서 3차원 공간을 단순화된 건물들의 집합으로 정의하여 분석하려는

시도들은 있었다. 아래와 같다.



〈그림〉 단순화된 건물들의 집합으로 정의된 3차원 공간

- 하지만 이는 도심의 비건물 물체 (나무, 간판, 표지판 등) 들이 관측자의 가시성에 주는 영향을 모두 무시하기 때문에 도심 관측자의 가시도를 정확히 표현하지 못한다고 우리는 지적한다. 하지만 반면 최근 발전되는 3D LiDAR로부터 얻어지는 point cloud 는 우리의 주변 공간을 아주 정확히 어떤 물체의 누락도 없이 캡처한다. 아래는 그 예시이다.




〈그림〉 3D LiDAR로 획득한 Point Cloud Data

- 하지만 이 데이터는 매우 용량이 크다. 그리고 정확한 공간의 shape 을 캡처하는 만큼, 이를 계산하여 유의미한 물리량을 얻어내는 계산 역시 복잡해질 수밖에 없다는 한계를 가지고 있다. 우리는 뒤에서 이 문제들을 해결한다. 우리는 추후 이 데이터를

활용하여 3차원 가시 공간을 정량적으로 계산하는 방법을 제안한다.

- 특히 가시성은 공간의 특성을 파악하는데 주요한 평가지표로 활용되었다. Bishop (2003)은 가시성 분석에 디지털 고도 모델(DEM)을 사용하는 가시성 분석 방법으로 공간을 평가하였고, Lonergan & Hedley (2016)은 3차원 공간을 분석한 연구를 비교하여 3차원 가시성으로 Isovist의 활용성을 나타내었다. Dalton & Dalton (2015)은 새로운 3차원 Isovist 표현인 Contour Isovist(등고선 Isovist), Tri-planar Isovist(3평면 Isovist), 그리고 Circumvoluted Isovist(우회이등변 Isovist)로 3차원 공간을 나타내는데 활용하였다. 또한 Yang et al. (2007)은 3차원 분석의 경우, 관측자가 랜드마크를 올려다볼때의 표고각과 관찰자로부터의 거리를 고려하여 측정값, 인지 영역 등을 제안하여 시각에 관한 중요성을 강조하였다.
- 이처럼 시각영역인 Isovists는 주로 도시 공간 속에서 물체의 인식을 계산하는 분석에 사용되어왔다.
- 기존 시각영역분석의 수학적 정의는 다음과 같다.



<그림> 기존 시각영역분석의 수학적 정의


출처: Kim and Jung, 2014, Distance-weighted isovist area: An isovist index representing spatial proximity

- 기존에서는 2D isovist 가시공간 넓이로 정의되곤 했다. 가시공간의 polygon 그 자체보다 그 polygon의 특징을 요약하는 하나의 값을 추출하는 것이 넓은 공간의 분석 및 시각화를 위해 중요하다. 2D isovist 에서는 polygon의 넓이값이 주요하게 쓰여왔다. Polygon은 아래와 같이 삼각형들의 집합으로 분해될 수 있다.
- 따라서 polygon의 넓이는 수학적으로 아래와 같이 정의된다.

$$\left| \int_{\theta_{LB}}^{\theta_{UB}} \int_{r_{LB}(\theta)}^{r_{UB}(\theta)} r dr d\theta \right|$$


<그림> Polygon의 넓이

- 따라서 Kim & Jung 은 위의 연구에서 area 의 weight 를 거리에 따라 달리 줌으로써 공간의 특징분석을 달리 할 수 있음을 보이기도 했다.



〈그림〉 Area의 weight값을 거리에 따라 다르게 부여한 결과

- 하지만 앞서 소개한 2D isovist 는 큰 단점을 가지고 있다. 3차원 공간의 shape 을 반영하지 못하고 있다. 이는 아래와 같은 결과를 초래한다.




〈그림〉 기존 2D 환경에서의 문제점

- 각 열은 서로 다른 세 가지 환경을 나타낸다. 이 환경들의 2D Map 에서의 형상은 같다. 하지만 실제로는 건물들이 서로 다른 높이를 가지고 있기때문에 상식적으로도 다르게 분석되어야 할 것이다. 하지만 2D isovist 를 이용한다면 projected polygon 만이 고려되기 때문에 세 환경에서 공간의 특성은 같다고 오판단을 내리게 된다. 따라서 이런 3차원 공간에 대응할 수 있는 3차원 가시공간의 효과적인 정의가 요구된다.

(2) 3차원 시각 영역의 이론을 구축하기 위한 새로운 요소 제안


① 3차원 데이터 기반 시각 영역 이론구축 1: POS

- 우리는 3차원 공간을 단순화하면서도 효과적으로 표현하기 위해 POS라는 개념을 도입한다. POS는 Plane Of Sight 의 약자로서 그 자체는 2D polygon 이다. 이는 특정 단방향에서 관측자의 가시공간의 특성을 요약하는 도형이다. 아래와 같다.




<그림> 가시공간에 크기에 따른 특성(왼쪽 - 큰 경우, 오른쪽 - 작은 경우)

- 두 그림은 각각 가시공간이 큰 경우, 작은 경우의 예시그림이다. 우리는 POS를 단순화하기 위해 두 가지 가정을 제시한다.
- 첫 번째로, 관측자의 가시도는 가장 가까운 물체가 결정한다. 즉, 예를 들어 아래와 같은 상황이 있을 수 있다.




〈그림〉 관측자의 시각에 가까운 물체가 있는 경우

- 이 경우, 위와 같이 POS의 shape 은 여러 건물의 존재로 인해 많은 굴곡을 가지게 될 것이다. 하지만 실제 세계에서는 위 예시보다 더 복잡한 건물의 분포, 비건물들의 존재 등으로 인해 POS 의 shape 을 정확히 모델링하기 힘들다. 따라서 우리는 관측자의 가시성은 오직 가장 가까운 물체에 의해서만 결정된다고 가정한다. 이 가정은 실제로 우리가 골목 등을 다니거나 앞에 적당한 높이의 나무를 마주하고 있을 때를 상상해보면 효과적이며 상식적으로 유의미함을 이해할 수 있다. 더 멀리는 더 높은 높이의 아파트 등이 즐비하지만 우리는 우리 바로 앞에 놓인 울창한 나무에 의해 시야가 많이 가려졌고, 답답하다고 느낀다. 따라서 이런 가정을 통해 POS는 아래와 같이 단순화될 수 있다.




〈그림〉 단순화된 관측자의 시각

- 두 번째 가정은 다음과 같다: 2/ POS의 전면부는 flat 하다. 예를 들어 복잡한 shape을 가진 물체가 전방에 있을 때 실제 POS의 모양은 아래와 같다.



〈그림〉 복잡한 물체가 시야에 있을 때

- 하지만 마찬가지로 우리의 목표는 POS를 최대한 단순화하는 것에 있기 때문에 전방 부분을 flat 하게 대치한다. 따라서 다음과 같이 단순화될 수 있다.




〈 그림 〉 전방을 Flat하게 대치한 POS의
단순화

- 이는 실제 점유하는 가시공간의 오류를 발생시킬 수도 있지만 실제로 전방의 물체까지 도달하는 거리에 비해 이는 미미한 수준이며 또한 우리는 가시공간의 손실에 독립적인 openness index (2D isovist에서의 넓이와 같이 isovist 를 하나의 숫자로 요약하는 어떤 measure)를 추후에 제안하여, 우리가 제안하는 openness index 가 3차원 환경에서 효과적으로 동작함을 보인다.

② 3차원 데이터 기반 시각 영역 이론구축 2: 새로운 ISOVIST

- 따라서 POS를 활용하면 3차원 가시공간을 쉽게 이산화할 수 있다. 우리는 아래와 같이 3차원 공간을 POS의 집합으로 정의 한다.




〈그림〉 3차원 공간 POS의 정의

- 이때 POS 사이 각이 0이 될 때 (즉, POS의 전체 수가 무한으로 될 때), 실제 가시공간의 부피에 더욱 가까워진다. 이는 사용자 파라미터이다. 따라서 3D isovist는 다음과 같이 수학적으로 정의될 수 있다.

$$I = \{\text{POS}(\phi_i) \mid i = 1, \dots, N \text{ and } \phi_i = \frac{2\pi}{N} \text{ (rad)}\}.$$


〈식〉 3D Isovist의 수학적 정의

- 우리는 더 나아가, POS를 하나의 점으로 정의하는 방법을 제안한다. 궁극적으로 우리가 개발하는 이 일련의 정의들을 3D LiDAR sensor로부터 얻어지는 point cloud data에 직접 적용할 수 있도록 하기 위함이다. 3D LiDAR sensor로부터 point cloud는 아래와 같이 얻어질 수 있다.



〈그림〉 수직 스캔에 대한 예시

- 이는 하나의 수직 스캔에 대한 예시이며, 실제로 일반적인 LiDAR sensor는 360도 전 방향에 대해 이와 같은 스캔을 취득한다. 그리고 각 스캔은 여러 개의 포인트들로 구성된다. 이 때 이 포인트들로부터 어떻게 POS를 구할 수 있을 것인가, 하는 것이 우리의 본질적인 문제가 된다. 따라서 우리는 이 문제를 해결할 수 있는 방법을 여기서 제안한다. 바로 제일 높이 있는 점만을 취하는 것이다.



〈그림〉 HVP(Highest View-limiting Point) 설명

- 우리는 이를 HVP(Highest View-limiting Point) 라고 부른다. 위의 그림에서 바로 알 수 있듯이, 하나의 point로부터 곧, 우리가 정의한 POS가 얻어짐을 알 수 있다. 즉, HVP와 POS는 동치이다. 이 때 HVP는 theta 와 length 두 개의 파라미터로 표현된다. 이 두 값은 LiDAR sensor로부터 바로 측량하여 얻어지는 값이므로 우리는 최종적으로 POS의 shape을 알 수 있다. 따라서 HVP를 이용하면 3D isovist를 아래와 같이 다시 정의할 수 있다.

$$I = \{HVP_i \mid i = 1, \dots, N\}.$$

〈식〉 HVP를 이용한 3D Isovist의

정의

- 따라서 우리는 point cloud data를 input으로 받아 관측자의 가시공간을 모델링할 수 있게 되었다.

③ 3차원 데이터 기반 시각 영역 이론구축 3: 새로운 Data-driven 3D Openness

Index Model

- 우리는 앞서 관측자의 실제 가시공간을 POS와 두 가지 POS의 가정을 도입함으로써 수학적으로 단순하지만 반복적인 구조로 정의할 수 있었다. 하지만 공간의 특징을 요약하고 분석하기 위해서는 이 공간 (3D isovist)의 특징을 하나의 숫자로 요약하는 것이 요구된다. 우리는 이 값을 Openness Index 라고 부른다. 가장 단순하게 생각해서는 2D isovist 에서 area 가 쓰였듯이, 우리는 3D volume 을 생각해볼 수 있다. 이는 자연스럽게 모든 POS들의 area 의 합으로 정의될 수 있다. 하지만 우리는 추후에 이것이 좋지못함을 보일 것이다. 일단 그 전에 Openness Index 함수가 만족해야 할 요건들에 대해서 고찰하였다. 우리는 편의상 POS의 openness 를 그냥 openness, 3D isovist (전체 가시공간) 의 openness 를 Total Openness (TO) 라고 부른다. 이 때 TO는 수식적으로 아래와 같이 정의된다.

$$TO = \sum_{i=1}^N f(POS(\phi_i))$$

<식> TO(Total Openness)의 정의

- 즉, 3D Isovist 의 특징을 잘 요약한다는 것은 POS를 input 으로 받아 실수값을 return 하는 함수 $f: I \rightarrow \mathbb{R}$ 가 잘 정의되었다는 것을 의미한다. 우리는 이 함수 f 가 아래와 같은 constraint 를 만족해야 한다고 주장한다.

$$f(POS(\theta, l)) = 3D \text{ Openness} = HO + VO.$$

<식> POS의 HO(Horizontal Openness)와 VO(Vertical Openness)를

사용한 정의

- HO는, Horizontal Openness 이며 VO는 Vertical Openness 를 의미한다. 이는 직관적으로 우리의 가시성이 건물의 높이에만 결정되지 않는다는 점에서 출발한다. 예를 들어, 가까이 있는 10m 높이의 나무가 멀리 있는 300m 높이의 산보다 우리의 시야를 더욱 많이 가린다고 느낀다. 따라서 우리는 주변의 물체가 우리로부터 얼마나 떨어져 있는지와 얼마나 높이까지 존재하는지 두 가지를 함께 고려해야 한다고 주장하며, 이를 수학적으로 모델링 하였다.
- POS로부터 아래 삼각형 부분의 가로 (즉, 관측자와 물체 사이 떨어진 거리)를 w , 높이를 h 라고 한다면 이는 다음과 같이 정의된다.

$$w = l \cos \theta \text{ and } h = l \sin \theta$$

<식> 관측자와 물체 사이 떨어진 거리

- Theta 와 l 은 LiDAR sensor 로부터 얻어지는 값이기 때문에 우리가 알고 있는 값이며 이로부터 w 와 h 를 위 식과 같이 구할 수 있다. 우리는 w 와 h 를 이용하여 HO와 VO를 다음과 같이 정의한다.

$$HO = w_{normalized} = \frac{l \cos \theta}{l_{max}}$$

$$VO = 1 - h_{normalized} = 1 - \frac{l \sin \theta}{l_{max}}$$

<식> HO(Horizontal Openness)와 VO(Vertical Openness)


- 여기서 normalize 는 편의상 openness 의 값을 0과 1사이로 위치시키기 위해 존재한다. 여기서 theta 는 0에서 90도 사이 값인데, 이 범위에서 cos 과 sin 은 서로 반대로 (하나가 증가하면 다른 하나는 감소) 작동하기 때문에 HO와 VO는 서로 상보적이다.
- 따라서 위와 같이 정의함으로써 우리는 이 두가지를 jointly 고려할 수 있다. 따라서 최종적으로 POS의 openness 를 구하는 식은 아래와 같다.
-

$$f(\theta, l) = \frac{l \cos \theta}{l_{max}} + \left(1 - \frac{l \sin \theta}{l_{max}}\right)$$

〈식〉 POS의 Openness

④ 실험결과 - 포인트클라우드 데이터 기반 새로운 3차원 시각모형의 실험을 통한 유용성 증명 1: Toy-case simulation


- 우리는 앞서 선행연구조사에서 2D isovist 가 구분하지 못한다고 지적했던 환경과 같은 환경에서 제안한 3D isovist 와 제안한 openness index 가 공간에 따라 어떻게 달라지는지 실험하였다. 실험은 matlab 에서 simulation 되었다.



〈그림〉 3D isovist와 openness index가 공간에 따라 달라지는 정도

(low-low / high-low / high-high)

- 위의 그림에서 건물의 높이를 가상으로 각각 low-low / high-low / high-high 로 되어있는 예시이다.
- 우리는 이와 같이 임의의 세 가지 환경을 조성하였다. 그리고 ground 의 각 지점을 이동하면서 isovist 및 isovist로부터 얻어지는 제안한 openness index 를 계산하였다. 얻어지는 과정은 아래와 같다.



〈그림〉 각 지점에서 계산되는 openness index 값

- 위 그림에서는 편의상 POS의 아래 삼각형 부분만 묘사되었다. 제안하였던대로 관측자의 가시공간은 POS들의 집합으로 이산화되었다. 그리고 HVP가 POS를 정의하기 때문에 POS는 각 건물의 최대높이에 존재하는 point 에서 맺히고 있음을 볼 수 있다.
- 우리는 제안하는 openness index 와 volume 을 비교하여, volume 을 관측자의

가시도를 나타내는 척도로 사용하는 것은 무리가 있음을 발견하였다.

- 앞서 언급했듯이 2D isovist 에서 area 가 관측자가 위치한 공간의 특성을 효과적으로 요약하는 measure 로 잘 작동하였기 때문에 연구자들은 3차원 isovist 에서도 이와 연장선 상에 있는 volume 을 사용하면 될 것이라 생각하기 쉽다. 하지만 우리는 volume 을 사용하였을 경우 2D isovist 에 비해 개선된 결과를 얻을 수는 있지만 3차원 공간의 환경변화를 제대로 반영하지 못한다는 점을 지적한다.
- 3차원 가시공간의 Volume 은 우리가 제안한 new 3D isovist 로부터도 다음과 같이 얻어질 수 있다.

$$V = \lim_{\Delta\phi \rightarrow 0} \sum_{i=0}^N A_i \approx \sum_{i=0}^N A_i$$


〈식〉 3D 가시공간의 Volume

- 공간이 최대로 열려있을 때 (아무 장애물도 없을 때) 우리는 그것이 hemisphere 라고 가정하고 이 때 volume 은 아래와 같다.


$$V_{max} = \sum_{i=0}^N A_{max}, \text{ where } A_{max} = \frac{1}{4}\pi l_m^2$$

〈식〉 공간에 장애물이 없을 시 Volume


- 위 세가지 환경에서 volume 값은 아래와 같다.



〈그림〉 Low-Low일 때 Volume값




〈그림〉 High-Low일 때 Volume값




<그림> High-High일 때 Volume 값

- 반면, 제안하는 openness index 로 얻어진 결과는 아래와 같다.




<그림> 제안된 Openness Index로 얻어진

Low-Low일 때 Volume 값




〈그림〉 제안된 Openness Index로 얻어진
High-Low일 때 Volume 값




〈그림〉 제안된 Openness Index로 얻어진
High-High일 때 Volume 값

- 전반적으로 volume 은 환경변화에 따라 값의 변화의 출렁임이 큰 것을 확인할 수 있다. 또한, 우리는 3차원 공간이 복잡하게 변경되는 지점의 공간에 더욱 관심이 있기 때문에 두 건물 사이에서의 값을 집중적으로 추적해보았다. 아래는 그 결과에 대한 분석이다.




〈그림〉 두 건물 사이 세 가지 경로(-3부터 3까지 이동)


- 우리는 위와 같이 두 건물 사이 세 가지 경로를 생각하였다. 각 경로는 파란색, 주황색, 노란색으로 묘사되었으며 세로로 -3 부터 3까지 이동하는 경로이다.
- 다음 그래프는 각 경로 (x축) 를 따라 volume (y축) 과 openness (y축) 값이 어떻게 변하는지를 그린 그래프이다.
- 먼저 volume 에 대한 결과이다.



〈그림〉 각 경로에 대한 Volume 값의 변화(Low-Low)




〈그림〉 각 경로에 대한 Volume 값의 변화(High-Low)




<그림> 각 경로에 대한 Volume 값의 변화(High-High)


- 아래는 제안한 openness index에 대한 결과이다.



<그림> 제안한 Openness Index에 대한 변화 값(Low-Low)



<그림> 제안한 Openness Index에 대한 변화 값(High-Low)



<그림> 제안한 Openness Index에 대한 변화 값(High-High)

- 이 때 volume 의 경우 high-low 그래프에서 한 가지 단점이 드러난다. 노란색 경로와 파란색 경로의 값이 거의 유사한 분포를 가진다. 즉, 낮은 건물 옆을 걸을 때와 높은

건물 옆을 걸을 때 관측자는 유사한 quantity 의 가시도를 느낀다는 결론에 다다른다. 이는 건물과 관측자의 상대위치를 고려하지 않은채 전체적인 3D volume 의 체적만 고려하기 때문에 발생한다.

- 하지만 우리가 제안하는 openness index는 관측자의 가시도를 저해하는 요소의 높이와 관측자로부터 떨어진 거리를 jointly 고려하기 때문에 (가까운 나무와 먼 산 예시) openness index 의 high-low 결과에서는 파란색 경로 (높은건물 옆을 걸을때) 에서 더 낮은 값을 보여주었다. 이는 높은 건물이 멀리있을 때 보다 가까이 있을 때 관측자의 가시도를 더 저해한다는 상식에 부합하는 결과이다.

⑤실험결과 - 포인트클라우드 데이터 기반 새로운 3차원 시각모형의 실험을 통한


유용성 증명 2: Large-scale simulation

- 우리는 제안하는 3D isovist 를 이용하여 복잡한 건물의 분포를 가지는 더 넓은 지역에 대한 실험을 수행하였다. 대상지는 대전 유성구 어은동 일대이며 아래와 같다.





<그림> 실험 영역(대전광역시 어은동 일대 200m x 200m)

- 대상 영역의 크기는 200m x 200m 이다.
- 우리는 대상 영역에 실제로 존재하는 건물들의 outline 참고하여 아래와 같이 다양한 높이 분포를 가지는 임의의 가상환경을 조성하였다.
- 그 결과는 오른쪽에 함께 heat-map 으로 나타내었다. 파란색이 낮은 가시도 이며 빨간색이 높은 가시도를 의미한다. 히트맵에서 가시도의 변화가 continuous하게 일어나는 것으로부터 제안하는 isovist 가 (다양한 방위의 POS들의 합으로 정의되기 때문에) 주변 건물들의 영향을 모두 반영하고 있음을 알 수 있다.





(a) An environment with only high-rise buildings (over 50m).

<그림> 50m 이상의 높은 건물들에 대한 가상환경 설정




(b) An environment with mostly high-rise buildings and some low buildings, type 1. ↵

〈그림〉 높은 건물들과 약간의 낮은 건물들에 대한 가상 환경(Type 1)



(c) An environment with mostly high-rise buildings and some low buildings, type 2. ↵

〈그림〉 낮은 건물들에 대한 가상 환경(Type 2)




(d) An environment with mostly low-rise buildings.

<그림> 낮은 건물들에 대한 가상 환경

⑥실험결과 - 포인트클라우드 데이터 기반 새로운 3차원 시각모형의 실험을 통한


유용성 증명 3: 실제 세계의 데이터 응용

- 우리는 앞서 제안하는 new 3D isovist 및 openness index 가 복잡한 3차원 공간들이 존재하는 환경에서도 효과적으로 작동하는 것을 확인하기 위해 시뮬레이션 환경을 활용하였다. 하지만 제안하는 정의 및 계산식은 실제 3D LIDAR로부터 얻어지는 point cloud data에도 그대로 적용 가능하며, 우리는 궁극적으로 이런 3D data 에 대한 적용을 목표로 한다. 1년차 목표에서는 실제 3D point cloud 로부터 new 3D isovist 를 얻을 수 있음을 보인다. 우리는 국토지리정보원으로부터 얻은 여의도의 point cloud (las format)에 대해 실험을 수행하였다.



<그림> 데이터에 대한 설명((a) - HVP들을 이은 선, (b) - 각 POS들의 아래 삼각형부분만을 시각화 한 것, (c) - 3D isovist 의 top view, (d) - POS의 하늘부분)

- a)의 line 은 HVP들을 이은 선을 의미한다.
- b)의 하늘색부분은 각 POS들의 아래 삼각형부분만을 시각화 한 것이다.
- c)는 3D isovist 의 top view 이다. 즉 new 3D isovist로부터는 2D isovist 를 쉽게 얻을 수 있다. 또한 실제 point cloud data를 기반으로 하기 때문에 도심 속에서 관측자의 시야를 저해할 수 있는 모든 요소들이 반영되어 실제적인 2D isovist 를 얻을 수 있다. 2D map 기반의 2D isovist 혹은 모델기반의 3D isovist 로부터는 취득할 수 없었던 부분이 제안하는 HVP기반의 POS 및 new 3D isovist정의로부터 가능하게 되었다.
- d)의 파란부분은 POS의 하늘부분까지 함께 그린 것이다.
- 이런 실제적인 isovist 분석이 필요한 이유를 우리는 아래와 같은 사례에서 쉽게 이해할 수 있다.



〈그림〉 나무에 가려진 도시의 요소들

- 실제로 HVP의 궤적을 추적해보면 많은 부분이 나무에 의해서 가려지고 있음을 파악할 수 있다. 하지만 기존 도시분석에서는 이런 요소들이 무시되거나, 무시될 수밖에 없었다. 우리가 제안하는 방법을 이용하면 이런 부분들이 모두 반영된 3D isovist 및 openness index 를 계산할 수 있다.
- 위와 같은 결과를 얻는 과정은 아래와 같다.

Algorithm : Point Cloud based 3D Isovist

Input : An observer **O**, number of pieces **N**, radius of Visible Region **R**

Main :

For the given observer **O**,

Save points in Visible Region;

Divide hemisphere(Visible Region) into **N** pieces;

For each piece :

 Select a representative point **P** of the piece by a rule; // In this work, max z

 Get LookUpTriangle(**P**); // Azure, looking up angle = Closedness


 Get PieceOfPie(**P**, **R**); // Blue, indicator of openness to sky

end

Output : Visualization and feature vectors derived from the polygon

〈그림〉 3D isovist 및 openness index 계산 알고리즘


- 이 때 관측자의 위치에 따라 new 3D isovist 가 달라진다. 아래는 예시이다. 즉, 대로에 있을 때와 빌딩 사이에 있을 때 shape 이 다르다. 우리는 이를 이용해서 역으로 3D isovist 로부터 공간의 semantic 한 label 을 매길 수 있을 것으로 기대하며 유사한 기능을 하는 공간들을 클러스터링 할 수 있을 것으로 기대한다.
- 위 실험은 C++ 및 Qt+OpenGL 환경에서 수행되었다.



<그림> 관측자의 위치에 따라 달라지는 Isovist

(3) 로봇 위치인식에의 응용


- 위 과정에서 고안된 3차원 LiDAR로부터 제작되는 Isovist 는 공간의 가시성을 정량화할 수 있지만, 그 자체로 공간을 요약하는 우수한 요약자가 되기도 한다.
- 따라서 본 과제를 통하여, 사회과학적 단서를 이용하여 (즉, HVP, 관측자의 시야에서 가장 높은 점이 관측자의 가시성을 결정하고, 그 장소의 특징 및 쓰임을 결정한다는) 고안된 3차원 포인트클라우드를 요약하는 방법이 로보틱스에서 로봇이 자기 위치를 추정하는 데에도 효과적임을 실험을 통해 발견하였다.
- 로봇은 GPS를 통해 야외에서 효과적으로 위치를 추정할 수 있지만 이는 복잡한 도심에서는 수미터에서 수십미터 정도로 큰 편이며, 또한 GPS를 운용하는 특정 몇 국가의 사정에 의해 지배된다는 단점이 있다.
- 따라서 로봇이 가진 센서만으로 도시의 수많은 위치를 분별할 수 있는 능력이 요구된다.
- 이는 자율주행차 시대가 오며 더욱 중요한 요소가 되었다.
- 해당 내용은 로보틱스 저널에 발표가 되었으며, 특히 제안하는 3차원 가시성 기반의 포인트클라우드 요약자는 장기적인 시간 변화에도 강건함이 밝혀졌다.
- 해당 방법은 현재 로보틱스 분야 LiDAR기반 로봇 위치 인식 방법의 SOTA (state of the art)를 달성하였으며, 이는 사회과학적 지식들이 로봇 분야와 융합되었을 때 어떤 시너지를 낼 수 있는지를 보여준다.




〈그림〉 장기적 시간에 따른 3차원 가시성
기반의 포인트클라우드 변화

- 거친 또는 고운 스케일의 위치인식은 모바일 로봇의 가장 필요하고 기본적인 능력 중 하나이다. 최근에는 실험실 수준의 정적이고 통제된 환경을 넘어 실제 실외 환경에서 운영하기 위해 장기적인 자율성(LTA)으로 초점이 옮겨지고 있다.
- LTA는 시간이 지남에 따라 환경의 모양(예: 빛 상태 또는 폐색)이 변화하여 로봇의 위치인식의 실패를 초래할 수 있기 때문에 특히 중요하다.
- 많은 방법이 제안되었지만, 이 문제를 극복하기 위한 완전한 시각 기반 해결책에 동의하는 사람은 거의 없다. 변화하는 환경에서 LTA를 달성하기 위해, 많은 접근법은 다중 경험을 지역화 프레임워크로 전환하려고 시도했다.
- 하지만 이러한 접근방식은 경험의 수로 데이터베이스 크기를 증가시키기 위해 동일한 위치에 대한 다양한 조건을 포착해야 하기 때문에 내재된 결함을 드러냈다.
- 한편, 시각적 외관과 대조적으로, 장소의 물리적 구조는 시간이 지남에 따라 거의 변하지 않는다. 따라서 한 장소 내에서 인지할 수 있는 구조적 정보를 활용하는 것은 외관에만 기초한 방법보다 장기적인 위치인식에 대한 이점이 있다.
- 그런 의미에서, LiDAR(Light Detection and Ranging)을 이용한 단일 시간 관측은 한 장소의 규범적 성격을 나타낼 수 있어, 강력한 국지화를 위한 다중 경험의 필요성을 제거할 수 있다. 이 연구 라인에서는 점 구름에 대한 위치 인식을 위한 수작업 기술자 기반 및 학습 기반 방법이 널리 제안되었다. 그러나 이러한 연구들은 느리지만 거대한 구조적 변화(예: 건설과 철거)와 도로 위상 변화로부터의 예상치 못한 관점을 포함한 장기적인 국지화 요건을 거의 파악하지 못했다.
- 많은 LiDAR 기반, 글로벌하고 coarse 한 스케일에서의 위치인식 방법들은 장소를 구별할 수 있는 강력한 능력을 가진 강건한 서술자를 만드는 데 초점을 맞추었다. 현재의 서술자에 대한 연구는 비학습과 학습으로 나눌 수 있다.
- 비학습 기반 기술자: M2DP는 수작업으로 디자인된다. 점 구름을 여러 평면에 투영하며, 이 평면의 정상적인 방향은 수동으로 결정된다. M2DP는 히스토그램 기반과 같이 이전에 제안된 방법과 달리 소음 점 구름과 함께 실외 컨텍스트에서도 장소 인식을 효과적으로 수행할 수 있다는 것을 보여주었다. 도시 설계에 사용되는 3D


isovist 의 개념에서 영감을 얻은 Scan Context(SC)는 가시점 구름의 최고점만 추출하면 M2DP를 포함한 다른 점들보다 성능이 우수하다는 것을 보여주었다. 최근에는 구조정보 대신 강도를 이용한 연구가 발표되었다.



<그림> M2DP 방법의 예시




(a) Bin division along azimuthal and radial directions



(b) Scan context

<그림> Scan Context 방법의 예시


- 학습 기반 설명자: 최근, Uy와 Lee는 PointNetVLAD라는 네트워크를 제안했는데, 이 네트워크는 PointNet과 NetVLAD를 결합하여 순무 불변성을 달성하는 점 구름 설명자를 생성하였다. 그들은 네트워크가 충분한 일반성을 제공했다는 것을 검증했다. 즉, 옥스포드 로봇 자동차 데이터 세트로 학습된 네트워크는 다른 환경에서 다른 로봇이 획득한 스캔에 잘 작동한다. PointNetVLAD의 차용 메트릭 학습과는 달리, SegMap은 효율적인 재구성 및 견고한 루프 폐쇄 감지를 가능하게 하기 위해 인코더-디코더 시스템을 도입하여 설명자를 그것의 동시 국부화 및 매핑(SLAM) 프레임워크로 만들었다.



<그림> PointNetVLAD 방법의 예시

- 이렇듯 많은 방법이 제안되었지만, 그럼에도 도시 지역의 장기 위치인식 능력에 대한 LiDAR 기술자의 효과를 보여주는 경험적 연구는 거의 없다. 몇몇 작품들은 베이지안 필터링을 사용하여 이전의 LiDAR 포인트 클라우드 맵 내에서 장기 정확성(cm-수준)의 국산화 문제를 다루려고 시도했다. Maddern은 2.5D 래스터화, 이미지 기반, GPU 가속 검색을 제안했다. 최근, 워더스와 뉴먼은 장면 변경을 처리하고 잘못된 국부화를 피하기 위해 포인트-스위스 거부 방법을 도입했다. 이런 종류의 작업은 대개 대규모 국산화라는 글로벌 플레이스 검색 능력보다는 베이지안 프레임워크 내에서 구조적 장면 변화를 모델링하는 방법에 초점을 맞춘다.
- 앞서 언급한 서술자 기반 범주와는 달리, 심층 학습을 이용하여 로봇의 자세를 직접

주입하는 엔드투엔드 로컬라이저가 요즘 주목을 받고 있다. 이것은 지역화 문제를 6D 포즈 회귀 또는 코스 위치 분류로 공식화한다. 그러나 이러한 이미지 기반 로컬라이저와 비교할 때 입력이 제한되었기 때문에 LiDAR 포인트 클라우드를 받아들이는 직접적인 방법은 거의 없다.




<그림> Classification 기반의 엔드투엔드 이미지 기반 로컬라이저 (PLaNet) 예시

- 클래시피케이션 기반의 엔드투엔드 이미지 기반 로컬라이저 (PLaNet) 의 예시. 이런 시도들과 달리, LiDAR 데이터를 이용한 연구는 거의 없었다.
- 따라서 본 연구에서는 CNN 기반의 엔드투엔드 위치인식 프레임워크를 제시하였다. 제안된 로컬라이저는 구조화되지 않은 포인트 클라우드를 구조화되지 않은 형태로

효과적으로 요약한 Scan Context Image(SCI)라는 포인트 클라우드 설명자를 기반으로 한다. 우리는 단 하나의 경험만이 테스트된 데이터 세트에서 방법의 효과를 입증하기에 충분한지 검증한다. 우리의 접근방식은 장소를 하나의 등급으로 간주하고 CNN을 이용한 분류 작업으로 현지화 과제를 공식화한다는 점에서 PlaNet와 유사하다. 모바일 로봇 내비게이션에 사용할 수 없는 대략적인 위치 범위를 제공하는 PlaNet과 달리, 우리는 수백 미터나 수천 미터 정도의 지도에서 몇 미터 이내의 성공적인 지역화를 보장한다.


- 우리 방법의 요약은 아래 그림과 같다.



〈그림〉 Scan Context Image(SCI)실험과정 요약

- 이 방법에서 주가 되는 SCI는 포인트 클라우드 설명자, 스캔 컨텍스트(SC)에서 생성되므로 먼저 SC에 대한 간략한 리뷰를 제공한다. 다음으로, 장기 국지화를 위한 심층적인 학습 기반의 분류법을 소개한다.
- 스캔 컨텍스트(SC)는 3D 포인트 클라우드를 입력으로 삼고 평면 주변 영역을 최대 범위 내의 섹터와 링으로 나누며, 각각 방위각과 방사방향으로 나뉜다. 구역과 반지의 교차점을 빈이라고 한다. SC는 각 빈에서 최고점 값만 취하여 2D 매트릭스 형태로 배열하고, 이를 통해 빈의 내부 배열이 보존된다. 아래 그림은 SCI의 제작 과정을 보여준다. 이전에 정의한 SC는 장면 주위에 견고한 구조 정보(즉, 점의 최대 높이)를 캡슐화하는 단일 채널 행렬이다. SC는 이미 영상과 같은 형태지만, 우리는 이것을 정상화하고 CNN에 입력으로 적합하도록 세 개의 채널로 변환한다. 변환할 때 [hmin; hmax]의 구조 높이는 포화상태가 된다. 본작에서는 순차적 콜럼맵보다 분산이

큰 제트콜롬맵과 $h_{min} = 0m$, $h_{max} = 15m$ 의 매핑 함수(fc)를 사용한다. 그렇게 함으로써, 우리는 하나의 채널 이미지를 가진 훈련과 비교하여 작은 개선을 경험적으로 검증한다. 제안된 SCI는 차별적 힘을 SC보다 더 많이 증가시키고 또한 CNN을 입력하기에 더 적합한 형식이다. 이 과정은 그림 3에 시각화되어 있다. 우리는 단색 영상 또는 콜롬 선정에 대한 네트워크 튜닝에 대한 추가 조사가 지역화 성능을 향상시킬 수 있다는 점에 주목한다.



〈그림〉 SCI의 제작과정

- 우리는 야외 로봇의 위치인식 문제를 분류 문제로 공식화하기 때문에 분류망을 이용한다. 우리는 우선 훈련 순서에 포함된 지역을 x-y 평면의 동일한 크기(예: 10m x 10m) 격자 셀로 나누고 각 셀에 서로 다른 색인을 할당한다. 하나의 세포는 하나의 장소를 나타낸다. 그런 다음, 셀에서 획득한 모든 SCI는 CNN의 클래스 라벨을

사용하여 훈련한다. 라벨은 해당 플레이스 인덱스의 핫 인코딩 벡터다. 각 장소를 고유 등급으로 간주하기 때문에 레이블 치수는 총 장소 수와 동일하다. 그 후, 네트워크는 분류 네트워크를 훈련시키는 데 일반적으로 사용되는 범주형 교차-엔트로피 손실을 가지고 훈련된다.


- 어떤 CNN 구조든 제안된 지역화 시스템을 구축하기 위해 사용될 수 있지만, 우리는 우리의 방법이 단순한 네트워크와 잘 작동한다는 것을 증명하기 위해 정규화 된 LeNet와 같은 네트워크를 사용한다. 자세한 구조와 매개변수는 다음 표와 같다. 우리가 사용한 간단한 네트워크 구조. BN과 MP는 각각 batch 정규화와 최대 풀링이며, 우리는 22개의 풀링 크기를 사용했다. Conv() 및 FullyConnected() 레이어의 숫자는 각각 필터 수와 노드 수를 의미한다. 모든 net에는 55개의 필터가 사용되었고 모든 Dropout 계층에는 0.7(30% 남아 있음)의 드롭아웃이 적용되었다. N은 총 장소의 수이다. 64개의 배치 크기로 네트워크를 교육하고 기본 파라미터로 Adam Optimizer를 사용하였다(학습율 = 0.001, 1 = 0.9, 2 = 0.999).

Input	(batch_size, 40, 120, 3)
Conv1	BN(MP(ReLU(Conv(64, Input))))
Conv2	BN(MP(ReLU(Conv(128, Conv1))))
Conv3	Flatten(MP(ReLU(Conv(256, Conv2))))
FC1	FullyConnected(64, Dropout(Conv3))
FC2	softmax(FullyConnected(N, Dropout(FC1)))
Output	(batch_size, N)

<그림> 위치인식에 사용된 네트워크의 구조


- 또한, 우리는 장기적인 국지화에서 잠재적 관점 차이를 다루기 위해 관점 불일치를 달성하기 위해 N방향 증대를 제안한다. SCI의 컬럼 순서는 로봇의 헤딩을 나타내기 때문에 훈련 단계에서 합성 SCI를 통한 뷰포인트 변동은 상당히 간단하다(예: 컬럼 이동). 여기서 N은 360도를 일정한 간격으로 나눈 수이다. 2방향 증대의 예(우리가

역증대라고 부르는 것)는 다음과 같다.



<그림> 2방향 증대의 예시

- 그리고 또 하나 중요한 문제가 남아있다. LTA 시나리오에서 로봇은 훈련 세트가 아닌 새로운 장소를 방문할 수 있다. 따라서 LTA에서는 이 미학습 위치의 감지 및 적절한 처리가 매우 중요하다. 지역화 모듈에 앞서, 우리는 우선 잘못된 지역화를 피하기 위해 쿼리 장소가 새로운 장소인지 아닌지를 확인한다(즉, 쿼리 포인트 클라우드가 새로운 장소에서 온 것인지 아닌지).
- 우리는 새로운 장소, 보이지 않는 장소, 그리고 훈련 순서에 있는 기존의 장소를 보이는 장소라고 부른다. 이 과정은 미지의 등급 검출에서 고려할 수 있는데, 이것은 보다 강력한 분류 시스템을 구축하기 위해 컴퓨터 비전 연구자들을 크게 끌어들었다.
- 예를 들어, Dropout Variational Inference는 대략적으로 클래스 확률을 제공할 수 있지만 여러 가지 예측이 필요하며, 이는 시간이 오래 걸리기 때문에 실시간 로봇의 위치인식이 어려울 수 있다.




〈그림〉 inference 시에도 dropout을 적용하는 예시

- 이 값비싼 방법과 달리, 우리는 네트워크로부터 출력 벡터의 엔트로피를 직접 사용하는 방법을 제안한다. 우리는 각 등급 확률의 근사치를 목표로 하지 않는다. 대신에 우리는 오히려 질의가 보이는지 보이지 않는지를 확인하는 데 초점을 맞춘다. § V에서 보여지듯이, 출력 벡터의 이 엔트로피는 보이지 않는 장소 취급을 위한 전통적인 쌍방향 거리 기반 임계값(예: 유클리드 거리)보다 상당히 강한 차별적 성능을 가진다. 구체적으로, 우리는 예측 점수 벡터의 정규화된 엔트로피를 사용한다.
- 제안하는 식은 다음과 같다.

$$H(\mathbf{p}) = -\frac{1}{H_{max}} \sum_{i=1}^N p_i \log_2 p_i$$

〈식〉 정규화된 엔트로피 식


- 예측 벡터의 엔트로피가 주어진 임계값(사용자 매개변수)보다 높을 경우, 새로운 장소로 간주되어 위치인식 없이 거부된다. 한편, 우리는 보이는 것으로 분류된 이미지에 대해서는 다음 단계에서 국산화만 실시한다. 아래 그림은 시퀀스의 알고있는 위치와 처음보는 위치에서 엔트로피의 분포의 예를 보여준다.




〈그림〉 알고있는장소/처음가보는 장소 에 대한 엔트로피의 분포 차이

- 예측 점수 벡터의 엔트로피 분포의 예. 이 예는 옥스퍼드 로봇 자동차 데이터 세트의 2015-06-12-08-52-55 테스트 시퀀스에서 나온 것이다. 왼쪽: 보이는 (가분)장소에서 나오는 예측 엔트로피의 히스토그램은 보통 작은 값을 가진다. 오른쪽: 보이지 않는 (새로운) 장소로부터의 엔트로피의 히스토그램은 큰 차이가 있으며, 보이는 장소의 경우보다 엔트로피가 더 높다.
- 쿼리가 보이는 것으로 간주되는 경우(즉, 점 그룹은 보이는 곳에서 얻음)는 예측 점수 벡터를 사용하여 현지화를 수행한다. 점수가 가장 큰 이 벡터 요소의 지수를 현재 위치로 결론짓는다. 보다 일반적으로, 우리는 쿼리 장소의 기본 진실 지수가 네트워크의 예측 점수 벡터에서 더 큰 순서로 점수가 매겨진 상위 N개 지수 집합에 속한다면 지역화가 성공적이라고 말할 것이다.
- 우리는 두 개의 장기 데이터셋을 사용했는데, 이것은 NCLT와 Oxford Robot-Car 데이터셋이다. 두 데이터 세트는 1년에 걸쳐 유사한 궤적을 따라 여러 시퀀스를 제공하며 동일한 장소에 대한 다양한 환경 변화를 포함한다. NCLT 데이터 세트는 3D LiDAR 스캔을 제공하며 각 스캔은 그림 5의 왼쪽에 설명된 대로 SCI에 직접 인코딩된다. 옥스포드 로봇 자동차 데이터 세트의 경우, 거의 10km의 전체 궤적을 가진 시퀀스를 사용했다. 이 데이터 세트는 3D LiDAR이 없으며, 2D LiDAR은

차량의 이동 방향에 수직으로 장착되었다. 따라서 충분한 길이를 위해 국소 궤적을 따라 2D 스캔을 축적했다. 누적 길이(또는 창 크기)를 SCI의 파라미터인 최대 범위와 동일하게 설정했다. 예시는 아래와 같다.




〈그림〉 3D 스캔의 생성 예시




〈그림〉 2D 스캔의 생성 예시

- 우리는 스캔을 쌓기 위해 데이터셋이 제공하는 시각적 냄새 측정법을 사용한다. 그것들을 쌓음으로써, 우리는 이전 스캔 사이의 상대적인 움직임을 사용하며 최근의 스캔은 원점에 위치한다. 그렇게 함으로써 SCI를 만들기에 충분한 정보를 가진 3D 포인트 클라우드(또는 서브맵)를 만들 수 있다. 우리는 ins.csv 파일에서 이용할 수 있는 글로벌 좌표를 각 장소의 지상 진리로 간주했다. 신뢰할 수 있는 관성 항법 시스템(INS) 상태(즉, INS SOLUTION GOOD)가 있는 장소만 훈련 및 시험에 사용된다.



<그림> 본 실험에 사용한 NCLT dataset 의 예시 1



<그림> 본 실험에 사용한 NCLT dataset 의 예시 2



<그림> 본 실험에 사용한 NCLT dataset 의 예시 3:

NCLT dataset에서 사용된 로봇 플랫폼



<그림> 본 실험에 사용한 Oxford RobotCar dataset 의 예시: 사용된 로봇 플랫폼

- 분석을 위한 격자의 크기는 가로 10m, 세로 10m이다. 이 그리드 맵 분해능을 위해

NCLT와 Oxford RobotCar 데이터 세트는 각각 579개와 700개의 교육 시퀀스를 가지고 있다.

- NCLT와 옥스포드 로봇 자동차 데이터 세트의 장소는 단 한 번의 시퀀스만으로 교육한 다음, 1년에 걸쳐 적용되는 다음 10개의 시퀀스에 대해 현지화가 평가된다. 훈련을 위해 SCI와 비교 방법의 설명자를 1m마다 샘플링한다. 또한 시험 시퀀스는 1m마다 샘플링하여 평가한다. NCLT 및 옥스포드 로봇 자동차 데이터 세트의 교육 및 테스트 시퀀스에 대한 자세한 내용은 아래 표에 요약되어 있다.


Dataset	Train Seq.		Test Seq.															
			2012-01-15	2012-02-04	2012-03-17	2012-05-26	2012-06-15	2012-08-20	2012-09-28	2012-10-28	2012-11-16	2013-02-23	2013-04-05					
NCLT	579 places	Seen	5170	5449	5449	5533	3321	5146	4626	4623	3575	4114	3341					
		Unseen	441	428	428	773	742	835	919	1034	1290	1095	1162					
Oxford Robot Car	2014-07-14		2014-07-14	2014-11-25	2014-12-17	2014-12-17	2015-02-03	2015-03-10	2015-04-17	2015-05-22	2015-06-12	2015-07-10	2015-08-13					
	-14-49-50		-15-16-36	-09-18-32	-18-18-43	-18-18-43	-08-45-10	-14-18-10	-09-06-25	-11-14-30	-08-52-55	-10-01-59	-16-02-58					
	700 places	Seen	4079	5484	5484	3926	5657	5106	5485	5664	4321	4872	5043					
		Unseen	414	2066	2066	1769	2163	2782	2571	2232	3062	2585	2466					

〈그림〉 NCLT 및 옥스포드 로봇 자동차 데이터 세트의 교육 및 테스트 시퀀스

- 우리는 우리의 방법인 SCI-localization을 최첨단 수공예 및 학습 기반 포인트 클라우드 설명자 세 명과 비교한다: M2DP, Scan Context, Point-NetVLAD. 공정한 비교를 위해 두 방법 모두 단일 시퀀스의 설명자만을 사용하여 데이터베이스를 구축하며, 1년 이상 시험 시퀀스의 쿼리 설명자와 비교된다. 가장 가까운 후보의 지수는 질의 위치로 간주된다.
- M2DP는 루프 폐쇄 감지를 위해 설계된 경량 점 구름 설명자다. M2DP의 핵심 아이디어는 3D 포인트 클라우드를 여러 개의 2D 평면에 투사하는 것이다. 우리는 M2DP1의 오픈 소스를 사용하여 원작자와 동일한 파라미터와 절차를 사용했으며, 포인트 클라우드에서 192차원 설명자를 취득한다.
- Scan Context-50은 SCI와 유사한 설명자를 사용하지만 학습에 기반하지 않는다. SC는 쿼리와 후보 사이의 거리를 계산하기 위해 기둥-눈금 비교를 사용했다. 학습 효과를 명확히 검증하기 위해 Scan Context-50과 SCI를 비교한다. 이 방법은 쌍체 비교에 50명의 후보가 필요한 방법이다.
- PointNetVLAD에 대해서는 우리는 원래 논문과 유사한 전처리를 적용했다. [2525m, 25m] 입방 창2 내의 지반 제거된 점 구름은 일정한 숫자(4096개)로 필터링되어 0의 평균으로 [-1, 1]의 범위로 다시 조정된다. 이 처리된 점 구름은 네트워크에 공급되고, 마지막으로 256차원 설명자를 얻게 된다. 저자가 제공한 사전 훈련 모델을 사용했다
- 지금부터는 제안된 방법의 효과와 견고성을 검증하기 위해 집중적인 분석을 제공한다. 교육 데이터와 시험 시퀀스에 대한 자세한 정보는 위의 표에 설명되어 있다. 각 데이터 세트의 시험 시퀀스는 한 해 동안 다양한 조건을 다루기 위해 매달 적어도 한 차례씩 순서를 포함하도록 선택되었다.
- 우리는 우선 방법의 엔트로피 임계값과 쌍방향 거리 임계값(M2DP, PointNetVLAD 및 Scan Context-50의 경우 제안된 거리를 비교 방법으로 변경하여 장기 운영 전체 데이터셋에 대한 Precision-Recall 곡선을 사용하여 일반 성능을 평가한다. s는 보이지 않는 장소 취급에 대한 것이다. 쿼리를 보이는 장소로 간주하는 경우, 우리는

네트워크 출력 벡터의 가장 큰 요소(우리의 방법) 또는 가장 가까운 설명자의 장소 지수(M2DP, Scan Context-50 및 PointNetVLAD의 경우)가 답(예:)과 같으면 위치인식이 정확하다고 간주했다.


- 학습 기반 기술자인 PointNetVLAD는 수공예 방식인 M2DP를 큰 폭으로 능가했다. 그러나 PointNetVLAD는 장기 국산화 성능 면에서 우리 방식보다 낮은 성능을 드러냈다. 더욱이 제안된 SCI 국산화 방식은 시간의 경과에 따른 성능에서 다른 것들보다 덜 변동하였다. Scan Context-50의 경우 SC의 칼럼-글라스 매칭 기능은 서라운드 캡처 LiDAR로 가정하므로 2D LiDAR를 사용한 옥스퍼드 로봇카 데이터셋에서 저조한 성능을 보였다. SCI는 시간이 지남에 따라 성능이 떨어지지만 여전히 다른 방법보다 성능이 우수하다.
- NCLT dataset 에 대한 결과는 아래와 같다.



2012-02-04 2012-05-26 2012-08-20 2012-10-28 2013-02-23
 2012-03-17 2012-06-15 2012-09-28 2012-11-16 2013-04-05

〈그림〉 NCLT dataset 실험 결과

- Oxford robot car dataset 에 대한 결과는 아래와 같다.




〈그림〉 Oxford robot car dataset 실험 결과

- 한편, 대규모 현지화의 경우 상위 1위뿐 아니라 더 많은 후보(예: 상위 5위, 상위 25위)를 가져가는 것도 의미가 있을 것이다. 따라서 각 방법의 검색력에 대한 보다 심도 있는 분석을 제공한다. 정답 기준을 상위 5명, 상위 25명 후보까지 확대하여 각 방법의 성과가 어느 정도 증가했는지를 조사하였다. 그림 8은 전반적인 성능을

비교한 것이다. 각 시퀀스의 정밀 회수 곡선의 곡선(AUC) 아래 영역을 측정값으로 표시한다. AUC가 1에 가까울수록 국소화는 완벽해진다. 모든 방법의 AUC 값은 상위 25명의 후보를 허용함으로써 증가했지만 우리의 상위 1위 성적은 다른 25위 이상의 성과와 비교되거나 더 우수하다.


- 결과는 아래와 같다.




<그림> 정답 기준 확대하여 조사한 결과

- 본 항에서는 비구조적 및 구조적 변화라는 두 가지 유형의 환경 변화를 조사한다.

- 비구조적 변화: 한 장면의 구조 정보는 LTA에 대해 자연적으로 강건하지만, 포인트 클라우드를 경험과 다르게 만드는 몇 가지 도전적인 요소가 있다.
- 아래 그림은 NCLT 데이터 세트의 도전 사례와 해당 SCI를 시각화한다. NCLT 데이터 세트는 동행하는 인간 조종사로 인해 항상 부분적이고 다양한 폐색 상태를 보였다. 또한 NCLT 데이터 세트에 사용되는 세그웨이 같은 로봇은 자동차 플랫폼에 비해 롤 모션이 불안정했고, 시간이 지나면서 나뭇잎과 같은 부분 구조가 바뀌었다. 이러한 어려운 요소들에도 불구하고, 우리의 방법은 질문을 성공적으로 국산화하는데 성공했다. 왜냐하면 SCI는 원래 장면의 구조적 모양을 잃은 다른 서술자들과는 달리 자기 중심적인 장면 구조의 내적 관계를 유지했기 때문이다.




Construction



〈그림〉 영구적 구조변화의 예시

- 결과는 다음과 같다.




〈그림〉 구조 변화에 대한 결과


- 구조 변경: 장기적 구조적 도전은 시간이 지남에 따라 사라지거나 새로 건설되었을 수 있는 구조적 경험(즉, 훈련 순서에 존재했던 구조물)에서 발생한다. 검증을 위해, 그림 9(a)와 같이 무작위로 선택된 부분 내에서 점을 제거하거나 무작위로 생성된 새로운 벽체 모양의 점을 추가했다. M2DP는 점 투영에 기초하기 때문에 구조물의 외관에 영향을 덜 받지만 철거에 취약하다. PointNetVLAD는 4096점만 입력으로

사용하기 때문에 포인트 제거 및 추가에 민감했다. SC는 SCI와 매우 유사한 설명자를 활용하지만, 우리는 ConvNet 기반 보이지 않는 위치 탐지 및 분류 기반 검색이 현지화 성능에서 우월하다는 것을 검증했다.

- 한편, LTA에서 임의의 관점 변화는 장기 국지화 동안 불가피하게 발생한다. 우리는 또한 N방향 증대가 훈련 단계에서 N을 증가시킴으로써 관점 변화 건전성에 미치는 영향을 검토한다. 불행히도, 원래 데이터 세트의 쿼리 수는 다양한 관점을 가진 경우를 테스트하기 위해 다소 적다. 대신, 우리는 훈련된 네트워크를 쿼리 포인트 클라우드의 머리글을 무작위로 회전시켜 테스트했다. 아래 그림에서 볼 수 있듯이, N방향 확대 없이 SCI-localization의 기준선을 포함한 기존 서술자들은 임의의 관점의 변경에 따라 위치인식을 수행하지 못했다.
- 4방향 증대를 사용하면 관점 변동에 충분한 건전성을 얻을 수 있음을 실증적으로 검증했다. 그렇게 함에 있어서, 일반적인 성능도 아래 그림과 같이 보존된다. 그림의 하단은 의도적인 헤딩 회전 없이 원래 성능에 대한 AUC를 나타낸다.




〈그림〉 일반적인 성능 보존에 대한 결과



<그림> 임의의 회전 변화에도 기존의 회전 없는 경우 대비 94%의 성능을 보존하는 결과

- 또한 보다 정교한 국부화가 가능한지 여부를 확인하기 위해 서로 다른 그리드 크기를 고려함으로써 국부화 성능을 평가하였다. 우리는 같은 실험을 수행했지만, 그리드 셀 크기는 달랐다. 격자 셀은 더 작거나(5m x 5m), 더 크다(20m x 20m).
- SCI 위치인식 네트워크의 출력 노드 수는 새로운 총 장소 수로 재설정되고

재교육되었다. 다른 그리드 셀 크기에 대한 결과는 아래그림에 나와 있다. 5m2 해상도를 위해 1000개 이상의 라벨이 증가했고 성능이 약간 저하되었지만, 우리의 방법은 여전히 두 데이터 세트에 대해 10m 해상도를 가진 PointNetVLAD보다 낮은 분산도로 더 높은 성능을 보여주었다.



〈그림〉 다른 그리드 셀 크기에 대한 결과


- 또한, 제안하는 방법은 시간이 기존 방법보다 빠르다.
- 제안된 방법의 또 다른 강점은 경량 구현이다. 아래 표의 런타임 비교를 위해, 테스트 배치 크기가 1인 NVIDIA GTX 1080Ti에서 파이톤을 사용하여 심층 네트워크를 사용한 몇 개의 부품을 제외한 모든 구현에서는 Matlab을 사용했다. PointNetVLAD는 사전 처리(예: 잡지 제거 및 필터링)와 네트워크를 통과해야 하는 한 세대 동안 가장 긴 시간을 보여주었다. 그러나 PointNetVLAD와 M2DP는 모두 경량 서술자여서 데이터베이스에서 가장 가까운 것을 빨리 찾는다(즉, 짧은 검색 시간). 앞서 보고된 바와 같이, 스캔 컨텍스트-50은 검색 속도가 가장 느리다. SCI의 검색 시간은 다른 방법과 달리, SCI-localization이 전체 데이터베이스와 쌍으로 비교하는 것이 아니라 네트워크를 통해 단일 패스(pass)를 통해 N개소에 대한 점수를 직접 획득하기 때문에 가장 짧다.

Method	Descriptor Generation (sec)	Retrieval (sec)	Total (sec)
SCI	0.0434	0.0047	0.0481
SC-50	0.0413	0.4633	0.5046
PNVLAD	0.1374	0.0220	0.1594
M2DP	0.0758	0.0195	0.0953

<그림> 각 방법의 평균 시간 비용. 비교는 NCLT 데이터 세트의 2013-04-05 시퀀스에 대해 실시됨


- 마지막으로 로봇 위치인식에서의 응용에 관한 본 연구를 하나의 그림으로 요약하면 아래와 같다.

Long-term Localization




<그림> 실험에 대한 요약

- 아래 그림은 전체 파이프라인의 예시를 더욱 자세하게 보여준다. 이 예시는 예전에 방문한 적이 있는 장소에 대한 예시이다.



〈그림〉 과거에 방문한 지역에 대한 결과


- 아래 예시는 예전에 방문한 적이 없는 장소에 대하여 위치인식 판단을 유보하는 예시이다.



<그림> 예전에 미방문한 장소에 대한 결과

(4) SLAM(Simultaneous Localization And Mapping)에의 응용

- 한편, (2) 3차원 시각 영역의 이론을 구축하기 위한 새로운 요소 제안 과 (3)로봇 위치인식에의 응용에서 제안한 방법을 종합하여 로봇의 odometry 와 결합할 경우, SLAM을 수행할 수 있다. 이 내용에 해당하는 부분은 Sparse Depth Enhanced Direct Thermal-infrared SLAM Beyond the Visible Spectrum 논문으로 출판되었다. (뒤 실적 표 참고)
- 본 연구에서는 도시의 LiDAR 3D map 에 열화상 정보를 어떻게 융합할 수 있는지를 제안하고 실험결과를 보여주었다.
- 결과 그림은 아래와 같다.




〈그림〉 열화상 정보와 도시의 LiDAR 3D map 의 융합

- 먼저 기대효과에 대해 설명하자면, 도시의 열정보를 3차원 공간정보에 임베딩시킴으로써 도심의 열원현상 등 로봇기술을 이용하여 도시의 기상 공간 정량


데이터 축적과 열섬현상 등 도시 내 존재하는 사소한 재난현상에 대한 정량적 분석의 자료를 제공할 것으로 기대된다.

- 위와 같은 3차원 열지도 제작을 위한 과정은 아래와 같이 요약된다.



<그림> 3차원 데이터의 SLAM에의 응용 파이프라인

- 제안하는 3차원 점군 데이터와 열화상 정보의 융합을 통한 SLAM을 수행하면, 로봇이 밤과 같은 가시성이 극적으로 떨어지는 환경에서도 효과적으로 3차원 공간에 대한 정보를 정확하게 구축할 수 있다는 장점이 있다.
- 아래 그림은 실험이 수행된 시각과 환경에서의 가시광선 정보와 열화상 정보의 예시이다.



〈그림〉 실험이 수행된 시각과 환경에서의 가시광선 정보와 열화상 정보의 예시


- 이러한 융합방법을 다양한 시각과 환경에 대해 실험한 결과는 다음 페이지 표의 내용과 같다.

TABLE II
ROOT MEAN SQUARE ERROR (RMSE) BETWEEN THE VRS-GPS AND ESTIMATED POSITIONS. THE BLANK (-) INDICATES FAILURES.


Seq. Number	Traveled Distance [m]	Time of day	Proposed [m] (14-bit)	Proposed [m] (8-bit)	ORB-SLAM [m]	LOAM [m] (full FOV)	LOAM [m] (limited FOV)
Seq 01 (2019-01-17-16-27-31)	108	day (4pm)	0.698	4.201	1.160	0.541	0.988
Seq 02 (2019-01-17-16-47-37)	996	day (4pm)	4.758	14.928	6.693	1.525	13.659
Seq 03 (2019-01-17-17-15-56)	1031	day (5pm)	5.340	10.285	15.553	1.434	10.397
Seq 04 (2019-01-30-23-28-13)	129	night (11pm)	0.690	1.505	-	0.594	1.041
Seq 05 (2019-01-30-23-30-43)	284	night (11pm)	1.076	9.487	-	0.884	0.953
Seq 06 (2019-01-31-01-09-33)	835	night (1am)	3.586	-	-	1.613	3.555
Seq 07 (2019-02-16-13-08-52)	390	day (1pm)	1.521	11.595	1.667	0.903	0.930
Seq 08 (2019-02-16-13-15-27)	383	day (1pm)	1.264	2.643	6.821	0.672	1.492
Seq 09 (2019-02-16-16-41-04)	924	day (4pm)	2.931	18.511	6.601	0.880	7.949
Seq 10 (2019-02-16-16-54-30)	883	day (4pm)	3.519	50.967	42.014	0.942	6.502
Seq 11 (2019-02-16-17-15-36)	604	day (5pm)	1.818	14.992	3.108	0.859	2.725
Seq 12 (2019-02-16-19-53-31)	365	night (7pm)	1.195	16.404	-	0.660	0.983
Seq 13 (2019-02-16-20-02-51)	1003	night (8pm)	6.398	-	8.830	1.685	12.685
Seq 14 (2019-02-16-20-16-59)	877	night (8pm)	4.193	-	7.744	0.945	7.789

<그림> 다양한 시각과 환경에 대해 실험한 결과


- 또한, 아래 그림은 제안하는 방법을 통해 제작된 3차원 열지도의 예시를 보여준다.
- 야외 실험은 주차장, 도로, 주변 건물, 나무를 포함한 캠퍼스 환경에서 실시되었다. 이 열 카메라는 가시 카메라에서 획득한 RGB 이미지와 달리, 그림 5와 같이 광원의 영향을 받지 않고 주야간에 상관없이 물체에서 방출되거나 반사되는 적외선 에너지를 감지한다. 평가를 위해 14개의 시퀀스로 구성된 데이터 세트를 수집했다. 데이터 세트의 횡단 거리는 총 8.8 km이며, 주간 및 야간 데이터를 포함한다.
- 각 시퀀스에서 제안된 방법의 추정 궤적 오차를 VRS-GPS를 사용한 다른 방법과 비교했다. 구체적으로는 8비트 축소 이미지, ORB-SLAM 및 LOAM1에 대해 제안된 방법을 비교했다. RGB-D용 ORB-SLAM과 같은 대부분의 RGB-D SLAM 방법은 형상 및 깊이 측정을 연관시키기 위해 밀도 깊은 깊이 지도가 필요한 반면, 우리 시스템은 희박한 깊이 측정만 제공한다. 깊이 없는 공정한 비교를 위해 ORB-SLAM에 대해 유일한 열 카메라 측정을 사용했지만, VRS-GPS가 제공하는 궤적에 맞게 배율을 보정하여 사용했으며, 이 평가에서 8비트 강도 이미지가 필요한 ORB-SLAM의 경우, 원시 온도 값을 0에서 30으로 축소하는 영상을 사용하였다. 제안된 방법의 8비트 영상 평가에 동일한 스케일링이 사용되었다. LOAM과 비교하여, 우리 시스템은 제한된 FOV에서 LiDAR 측정만 사용하기 때문에 전체 FOV와 제한된 FOV가 모두 제시되었다. 실시간 성능이 필요한 추적은 단일 스레드에서 평균 33Hz로 작동한다. 국소 미세화는 키프레임 5개 미만에서 45Hz로 작동한다. 더 빠른 조작이 필요할 경우 키프레임 수를 줄일 수 있다.
- 아래 그림들은 궤적 추정과 3D 열 지도 결과를 세 개의 시퀀스로 나타낸 것이다. 이 그림은 VRS-GPS가 cm 수준에서 정확한 전역 위치를 제공할 수 없는 GPS 거부 지역을 제외하고 생성되었다. 우리의 방법은 전 세계적으로 일관성이 있을 뿐만 아니라 모든 지역에 걸쳐 순조로운 궤적을 제공한다.



(a) Seq 9




<그림> 궤적 추정과 3D 열 지도 결과(Sequence 9)




(b) Seq 11



<그림> 궤적 추정과 3D 열 지도 결과(Sequence 11)




(c) Seq 14



<그림> 궤적 추정과 3D 열 지도 결과(Sequence 14)

- 아래는 또한, 빛이 하나도 존재하지 않는 지하 공동구 환경에서의 실험 결과이다.

지하 터널에서 생성된 3D 온도 지도. 우리는 두 개의 터널, 말굽형 터널, 그리고 사각형 터널에서 실험을 했다. 두 터널의 폭과 높이는 2.5m이다. 경로의 길이는 각각 70m와 80m이다. 우리의 실험은 열 리다르 센서를 손으로 잡고 전방으로 걸어가는 방식으로 진행되었다. 두 터널의 온도 분포는 사뭇 달랐다. 사각형 터널은 천장이 더 차가운 반면 말굽형 터널은 각 터널의 국부적인 시야에서 볼 수 있듯이 전반적으로 따뜻한 온도를 가지고 있다. 추정된 카메라 좌표는 로컬 뷰에서 색상으로 표시된다. 컬러 코드는 x축은 빨간색, y축은 녹색, z축은 파란색이다.



〈그림〉 사각형 터널(Type 1)과 말굽형 터널(Type2)의 결과


- 따라서 제안하는 SLAM에의 응용 방법을 이용하면 도시 내 존재하는 다양한 광조건 환경에서, 다양한 구조물의 3차원 형상을 복원하고 상태를 점검할 수 있을 것으로 기대한다.

(5) 매핑 차량 데이터에 정의된 시각영역을 적용하고 도시 공간의 특징을 분석

①점군 데이터를 활용한 도로 안전에 대한 운전자의 시각 영역 인식 수량화

- 도심에서 발생한 운전자 사고를 막기 위해 학교 앞에 도심 속력을 제한하거나 어린이 보호구역을 만드는 정책이 있다. 운전자들은 시각 영역에 들어오는 정보들로 차량 운행을 한다.
- 본 연구에서는 운전자의 시각적 인식을 측정하고 시선법을 이용하여 분석할 수 있는 새로운 기하학적 시각적 모델을 제안하였다.
- 따라서 본 과제를 통하여 실제 3D Lidar 센서로부터 실시간으로 들어오는 데이터를 통해 실제 도심 환경에 적용할 수 있었다.
- 도로의 유일한 주변부에 따라 운전자의 시각적 인식을 조사하기 위해, 기하학으로서 운전자의 인지적 행동을 적용하여 3가지 시각적 인식 모델을 만들었고, 각각의 모델을 적용하여 가설에 맞지 않는 환경을 제거하였다.
- 판교지역에 이 방법을 적용하여 시각적 인식에 따른 위험 수준 지도를 만들었다. 이는 이전에 고려하기 어려웠던 가로수, 건물 형태, 고가도로 등 실제 도심 형태를 분석할 수 있다는 점에서 일리가 있다.
- 운전자 중심의 시각적 분석과 거의 실제 운전 환경을 위해 3D 모바일 스캐닝 데이터를 사용했다. 본 논문에서는 운전자의 인지행동 특성을 고려한 새로운 유클리드 기하학적 시각인식 모델을 정의한다. 또한, 가시성 분석은 광선 주조를 기반으로 한 도시·지리 분야에서 사용되는 Line of Sight(또는 LOS) 방식을 이용하여 실시한다. 마지막으로 제안된 방법을 3D 모바일 매핑 데이터에 적용하여 도시에서 인지 수량의 차이가 큰 사고 쉬운 위치를 찾는다.
- 본 연구에서는, 기본적으로 사람의 시각적 인식에 대하여 가정을 한다. 첫째로, 기본

형태는 시야 범위가 제한된 반구 형상을 따른다. UFOV는 운전자가 순간적으로 인지하는 시각 영역으로 수평 시각각과 수직 시각각으로 결정된다. 두 번째로, 운전자의 UFOV는 속도에 따라 변화한다(즉, 속도가 증가하면 시각 각도가 감소한다). 단순화하기 위해 인간의 UFOV는 거의 같은 양을 인식한다는 가정이 있다. 따라서 속도가 빠를수록 시야는 작지만 시선은 길어진다. 또한 수직 시각각($\theta_{\text{elevation}}$)은 차량의 크기를 고려하지 않고 수평 시각각(θ_{azimuth})에만 초점을 맞추기 위해 일정한 고정값이다. 아래 그림은 시각각에 대한 그림이다.



<그림> (a) - 사람의 정지 상태에서 시야,


(b) - 시야의 단위 선에 의한 분할,

(c) - 시야의 수직 및 수평선,

(d) - 시야의 선에 의한 물체 인식

- 이 연구에서 우리는 운전자의 UFOV에서 감지 정도를 통해 운전자의 인지 시야를

측정하고자 하였다. 구현된 방법은 운전자의 위치에서 시선 세트를 주조한다. 따라서 정의된 가시 공간은 가시선으로 대체해야 한다. 첫 번째로, 위 그림에서 (a)는 정지 상태의 가시공간은 반구형 기하형이다. 여기서 우리는 그림 (b)와 같이 공간을 일정한 양으로 나누고 그 양에 해당하는 선을 생성하였다. 이 때, 그림의 (c)와 같이 각 시야의 라인은 수직 및 수평 각도와 시야 거리로 정의 된다. 그림 (d)와 같이 선의 광선은 정의된 영역에서 물체를 식별한다.



〈그림〉 운전자의 시각 영역 형태

- 위의 그림과 같이 하나의 시각인식 공간은 수평 시야각($\theta_{\text{elevation}}$), 수직 시야각(θ_{azimuth}), 시야 거리로 정의된다. (c)는 결정된 변수에 따라 운전자의 시각 인식 공간을 3차원으로 시각화 하는 것을 나타낸다. (d)에서는 시야 내에서 시야선은 물체를 인식하여 조정됨을 보여준다. 이 지역에서 생성된 LoS는 시각적 인식 모델이 된다. 우리는 이 LoS 세트에 대한 정의를 아래 식과 같이 S로 표현하였다.

$$S = \{LoS(\phi_i, \phi_j) | i = 1, \dots, I, j = 1, \dots, J \text{ and } \phi_i = \frac{\theta_{azimuth}}{I}(rad), \phi_j = \frac{\theta_{elevation}}{J}(rad)\}$$

<식> LoS에 대한 정의

- LoS에 대한 정의는 위의 식과 같이 정의할 수 있다.
- 시각 영역에 장애물이 있으면 시선은 물체에 의해 막히고 LoS 또한 감소한다. 따라서 장애물에 따라 인식의 정도가 달라지는데, 이는 시각장치의 부피가 줄어들수록 시각장치에 더 많은 장애물이 존재한다는 것을 의미한다. 그래서 우리는 LoS를 볼륨으로 대체한다. 하나의 선은 반구의 한 세그먼트에 해당하기 때문에, 그 영역의 볼륨은 LoS 거리(eq2)의 입방체의 합에 비례한다. 볼륨에 대한 식은 아래와 같다.

$$Volume = \sum_{i=1}^N \alpha * (length \text{ of } LoS)^3$$

<식> Volume에 대한 식

- 따라서 전체 볼륨을 n 조각으로 나누었을 때, 정지된 가시 공간의 부피에 따라 다음과 같은 공식으로 표현할 수 있다. 하지만 본 연구에서는 alpha 가 일정하다는 가정하에, Virtual Perceptual Degree를 다음과 같은 공식으로 표현할 수 있다.


$$Total \ Volume = \frac{4}{6} * \pi * (Sight \ distance) = N * \alpha * (Sight \ distance)^3$$

<식> 전체 Volume에 대한 식

$$VPD = \frac{\sum (Scale\ of\ LoS)^3}{N}$$


<식> Virtual Perceptual Degree(VPD)에 대한 식

- 따라서 본 과제를 통하여 실제 3D Lidar 센서로부터 실시간으로 들어오는 데이터를 통해 실제 도심 환경에 적용할 수 있다.
- 기본적으로 도로가 진행 방향으로 열려 있고, 유일한 특징은 도로의 요소에 의해 가려져 있다는 것을 가정으로 한다. 따라서, 시야각이 좁을수록 VPD가 높다. 그러나 모바일 센서를 이용해 자유롭게 데이터를 스캔하기 때문에 도로 위의 예기치 않은 물체는 불가피하게 촬영될 수 있다. 이 경우 시각인식모형에 따라 분류하는 것이 도움이 되지 않기 때문에 모델에 따라 도로 유형을 인식하기 어렵다. 따라서 적절한 임계값을 설정하여 사례를 나누었다. 마지막으로, 이 연구의 목적인 도로 안전에 따라 등급이 지정된다. 또한, 사례에 속하지 않는 관찰자 자세는 본 연구의 목적에 맞지 않기 때문에 고려되지 않는다.
- 이동 센서 데이터에 대한 운전자의 관점에서 도로 상황에 따라 가시성을 지속적으로 측정하는 것은 한계가 있다. 이는 도로위의 다른 물체(예: 자동차, 사람 등) 때문이다. 따라서, 한 모델에 따라 운전자의 UFOV를 측정하면 도로상의 예기치 않은 물체에 따라 결과가 일치하지 않을 수 있다. 따라서 운전자의 UFOV로부터 도로 주변부의 가시성을 평가하기 위해서는 잘못된 관찰자 자세를 제거할 필요가 있다. 이 때문에, 운전자의 시각 인식 특성에 따라 세 가지 모델을 설정하였다.




〈그림〉 운전자의 시야각 (30도 각도)

- 본 연구에서는, 세 가지 유형의 시각 인식 모델이 적용되며, 기하학적 변수는 위의 그림과 같이 설정된다. 첫 번째 그림은 모든 유형의 수직 시야각이 30도 각도로 고정되어 있음을 보여준다.



〈그림〉 세 가지 유형의 시야각에 대한 설명

- 위의 그림에서는 세 가지 유형의 시야각을 보여준다. 첫 번째 유형은 속도가 시속 100km 일 때 시야각은 30도 각도이며 시야 거리는 120m이다. 두 번째 유형은 속도가 시속 60km일 때 시야각은 60도 각도이며 시야 거리는 85m이다. 세 번째 유형은 속도가 시속 40km일 때 시야각은 120도, 시야 거리는 60m를 나타 낸다.




〈그림〉 각 Case의 VPD 각도에 대한 분류


- 본 실험은 기본적으로 길이 열려 있고, 유일한 도로 특징에 의해 시야가 가려진다는 점을 가정한다. 따라서 이러한 가정에 따라 시야각이 좁을수록, VPD(30도 각도 > 60도 각도 > 100도 각도)가 높아진다.
- 하지만, 모바일 센서를 이용해 데이터를 자유롭게 스캔하기 때문에 도로상의 예상치 못한 물체를 촬영할 수 밖에 없다는 단점이 있다.
- 이 경우, 시각적 인식 모델에 따라 분류하는 것이 도움이 되지 않아 모델에 따라 도로 유형을 인식하기 어려운 단점이 있다. 따라서, 적절한 임계값을 설정하여 사례를 구분하였다. 또한, 사례에 속하지 않는 관찰자의 자세는 고려되지 않았다.
- 첫 번째로 (Case 1), 세 모델 모두 VPD가 0.6보다 크다. 이 경우, 도로의 구성 물체를

둘러싼 도로 폭과 도로의 영향을 크게 받지 않기 때문에, 도시에서 가장 안전한 거리 유형 중 하나다. 그러나, 이 경우에는 도로의 형태보다 불필요하게 취해진 물체에 의해 각도의 VPD 순서가 변경될 수 있다. 따라서 이 유형은 어떤 별도로 분류하고 안전한 1등급을 부여한다.

- 두 번째로 (Case 2), 세 모델 모두 VPD가 0.4 미만이다. 이 경우 Case 1과 대조적으로, 도로 폭과 주변 구성 요소에 큰 영향을 미친다. 길이 너무 좁거나 그 지점에서 너무 많은 물체가 인식되는 경우를 나타낸다. 그러므로, 도시의 도로에서 가장 위험한 거리 등급 중 하나로 판별한다. 이 경우에는 도로의 형태에 관계없이 각도당 VPD의 순서가 나올 수 있다. 이 사례도 별도로 분류되며 본 연구에서는 4등급으로 가장 낮은 등급을 부여 한다.
- 세 번째로 (Case 3), 시야각이 좁아질수록 VPD가 증가하는 경우다. 이 경우 도로 주변의 모양은 불필요하게 인식되는 다른 물체보다 운전자의 VPD에 영향을 미친다. 이런 조건을 만족하는 오퍼버 포인트는 VPD의 정도에 따라 추출하여 분류할 수 있다. 본 연구에서는 4등급만 분류 되었다. 이 경우, 등급 구분 기준은 모델 3의 VPD로 구분되는데, 가장 큰 시야각 때문에 주로 도로 기하학의 영향을 받는다. 모델 3이 0.4보다 작으면 4등급, 0.4 ~ 0.5이면 3등급, 0.5 ~ 0.6이면 2등급, 마지막으로 0.6이상이면 1등급이 인정된다.
- 실험을 수행한 결과, 운전자에게 시각적으로 영향을 미치는 몇 가지 요인을 식별할 수 있었다. 첫째는 도로 폭, 둘째는 건물이었다. 이전까지의 연구는 도로폭과 건물의 존재 여부에 따라 시야를 점검할 수 있었다. 하지만, GIS 상 정보로는 확인할 수 없는 위험 구역이 있다. 이러한 영역을 구분하고, 스트리트뷰와 포인트클라우드 데이터 뷰어를 통해 어떤 기능을 가지고 있는지 확인하였다.
- 시각적 인식 모델은 세 가지 유형의 시각적 인식 모델에 의해 운전자의 자세에 적용된다. 관찰자가 자세 당 수천만 개의 포인트 클라우드 데이터를 분석할 필요가 없기때문에, 선택된 관측자 각각에 대해 지역적 범위를 정의한다. 또한, 모델 종류에 따라 분석할 반경이 시거리와 같기 때문에 지역의 범위가 결정된다.



〈그림〉 도심 공간의 샘플 포인트 클라우드 데이터



〈그림〉 도심 공간의 샘플 포인트 클라우드 데이터에 대한
복셀화

- 본 연구에 사용된 포인트 클라우드는 포인트로 구성되어 있기 때문에 볼륨(부피)이 없다. 그래서 ray casting 알고리즘을 이용한 LoS방식을 적용하기는 어렵다. 이러한 한계점을 극복하기 위해 Octree방법을 사용하여 포인트 클라우드를 복셀화 하였다. 위의 그림은 샘플 포인트 클라우드 데이터와 그 포인트 클라우드 데이터를 복셀화 해 시각화한 결과다.



〈그림〉 판교 지역 위성 사진




〈그림〉 판교 지역 레이저 스캐닝 결과

- 본 연구에서는 도시의 교통안전을 평가하기 위해 제안된 시각 인식 모델을 위의 그림에서 알 수 있듯이 판교 모바일 레이저 스캔 데이터에 적용하였다. 데이터셋은 77,416,102개의 포인트와 200510 차량 정보 데이터로 구성된다. 차량 정보 데이터는

운전자의 위치값이다. 그러나 20만 점 이상 모든 위치 값을 분석하는데 오랜 시간이 걸리므로, 본 연구에서는 간격 668 위치 값들만 사용하였다.





〈그림〉 운전자의 경로 포인트클라우드 시각화 결과





〈그림〉 운전자의 경로 포인트클라우드 GIS 상 시각화 결과



- 위의 그림은 우리가 분석하고자 하는 운전자의 경로와 일정 간격으로 추출한 위치정보를 시각화한 지도다.



〈그림〉 운전자의 시각 인지 특성에 따른 인지 경향성 확인 결과
(Case 30도)




〈그림〉 운전자의 시각 인지 특성에 따른 인지 경향성 확인 결과
(Case 60도)



〈그림〉 운전자의 시각 인지 특성에 따른 인지 경향성 확인 결과
(Case 100도)

- 우리는 판교 포인트 클라우드 데이터를 이용한 668지점 중 세가지 시각적 인지 모델을 사용하였다. 위 그림은 각도에 대한 VPD를 측정한 후 VPD값에 따라 경로에

시각화 된 결과이다. 순서대로 30도, 60도, 100도이며, 시야각이 좁아질수록(속도가 빠름) VPD가 불규칙해진다. 정규성 분석 결과 각도가 클수록 정규화된 것으로 나타났다. 특히 히스토그램과 주파수 분포도에서는 각도 30도에서 VPD가 불규칙하거나 0인 경우가 많다. 반면 시야각이 클수록 VPD가 고르게 분포되기 때문에, 도로상의 예측 불가능한 상황에 대응하기 쉽다는 것을 알 수 있다.



〈그림〉 주변 요소를 고려한 시각적 인식에 따른 도로 사고 위험성 지도

- 이러한 결과를 바탕으로, 도로상의 움직이는 물체를 제외한 도시 내 도로 주변의 도로와 요소만을 고려하여 사고 위험성을 평가하기 위해, 보편적 인식 특성을 적용한다. 앞서 기술한 분류법을 이용하여 진행하면, 위와 같은 결과를 얻을 수 있다.



〈그림〉 분석 결과에 따른 도로 안전성 평가 지도

- 위 그림과 같이, 결과 또한 도로 차선의 수와 운전자의 시야에 따른 도로의 형태가 거의 일치함을 알 수 있다.



〈그림〉 분석 결과에 따른 도로 안전성 평가 지도(6가지 구역)

- GIS 정보와의 비교를 통해 운전자의 시각 인식에 영향을 미치는 몇 가지 요인을

확인할 수 있다. 대표적인 요인으로 도로 폭과 건물의 유무이다. 이전의 연구들과는 다르게 위의 그림처럼 특이한 점이 발견되는 6가지 구역은 다음과 같다. 나무 밀집 구역, 건물 밀집 구역, 오픈된 공간, 도시 변화 구역, 교량 그리고 예외 지역이다.



〈그림〉 나무 밀집 구역(1-A, 1-B)

- 첫 번째로 나무 밀집 구역이다. 도로 폭과 건물 위치가 1-A, 1-B 지역에서는 비슷하지만 VPD는 각각 다를 수 있다. 이때, 실제 가로경관을 확인하면 B도로에 더 촘촘하게 심어진 것을 알 수 있다. 이것은 거리의 시야에서 볼 수 있듯이 운전자의 시야를 흐리게 하여 위험을 증가시킬 수 있다



〈그림〉 건물 밀집 지역(2-A, 2-B)

- 두 번째로 건물의 배치와 밀도다. 2-A와 2-B의 위치는 도로 폭과 건물 위치와 비슷하지만 VPD는 다르다. 가로경관을 보면, 2-A의 경우 도로와 매우 가깝고 건물 스케일이 2-B보다 크다는 것을 알 수 있다. 건물이 뺄수록 운전자의 시야를

가리기 쉽다.



〈그림〉 오픈스페이스(열린 공간) 구역(3-A, 3-B)

- 세 번째로, 열린 공간이다. 도로 폭과 배치가 일정하더라도 도로에는 출입구 및 공원 등 개방된 공간이 있을 수 있다. 이 경우, 운전자의 시야가 갑자기 열려 높은 VPD가 발생한다. 위의 그림과 같이 아파트 주차장 입구 3-A와 3-B에서 시야가 확보되어 있다. 따라서 주변보다 VPD가 갑자기 증가할 경우 안전에 유의할 필요가 있다.



〈그림〉 새롭게 지어진 건물(4)

- 네 번째로, GIS 데이터에 의해 생성된 가상환경에서는 고려하기 어려운 경우이다.

매년 데이터를 업데이트하기 어려움이 있어서 지도상으로 확인이 안되는 경우이다. 실제로 위의 그림과 같이, A지점에서 원래 없던 건물이 2015년에 새롭게 생겨난 것을 확인할 수 있다. 모바일 센서 데이터의 경우 보다 현실적인 안전성 평가를 위해 데이터를 신속하게 업데이트 할 수 있도록 스캔할 수 있다.



〈그림〉 교량(5-A, 5-B, 5-C)

- 또한, 모바일 스캔 데이터의 경우, 기존의 3D 가상 환경에서는 구축하기 어려웠던 도시의 3차원 요소를 고려할 수 있다. 위에서 볼 수 있듯이, 고가도로 및 교량의 경우 VPD가 낮음을 알 수 있다.



〈그림〉 도로상의 물체가 함께 스캔된 경우(6-A, 6-B)

- 단, 위에서 기술한 바와 같이, 이동형 스캔 데이터의 경우, 도로상의 물체가 함께 스캔되기 때문에 불가피한 예외가 발생할 수 있다. 6-A의 경우 왕복 8차선의 넓은


도로임에도 불구하고 VPD가 낮다. 6-B는 직진차로의 차량들에 의해 우회전하는 이동 센서가 영향을 받는 경우도 있다. 두 경우 모두 주행 도로 주변 요인에 관계없이 VPD가 낮다.

- 이러한 예외 경우를 피하기 위해, 차량이 가장 적은 시간에 측정하거나 조사에서 교차점을 제외할 필요가 있다. 그러나 교차로는 가장 빈번한 사고 중 하나로 본 연구 결과와 관계없이 항상 안전을 요구하는 구간이다.
- 본 연구에서는 인간의 시각영역을 정의하여 모바일 센서 데이터에 대한 운전자의 시각 지각을 평가하는 방법을 제안하였다. 이를 통해 사고 발생 가능성이 높은 위치를 신속하게 찾아내는 방법을 제안하였고 실제 3D 포인트 클라우드 데이터에 적용하여 분석하였다. 본 과제를 통하여, 기존의 파악이 어려웠던 도로의 실상을 3차원 점군 데이터를 활용하여, 보다 현실적이고 다변화된 도시 안전 평가를 달성하는데 기여할 수 있다.

(6) 실제 도심환경 대용량 점군 데이터를 통한 도시 분석

① 3차원 점군 데이터를 활용한 도시 거리의 특징에 대한 인식

- 도시에서 거리의 요소들은 해당 도시 거리에 대한 인식을 보여주는 중요한 요인이다. 거리의 구성요소는 다르고, 그 구성요소에 대한 인식은 거리를 보고 있는 사람들에게 영향을 미칠 수 있다.
- 사람들은 거리를 인식하는 정도는 도시 거리의 구성요소에 따라 차이를 보인다.
- 기존 연구에서는 crowd-sourced data 및 스트리트뷰 사진 기반의 이미지들을 활용한 사람들의 거리 인식을 연구하였다.
- 본 연구에서는 도시 거리의 대용량 점군 데이터와 점군데이터 객체탐지 알고리즘을 사용하여 도시 거리의 물체 탐지를 통한 거리의 인식 평가를 목표로 설정하였다.



<그림> 실험과정


- 본 연구의 실험 진행 과정은 다음과 같다. 먼저 실제 도심 거리의 포인트 클라우드 데이터를 획득한 후, 포인트 클라우드 데이터에 대한 객체 탐지 알고리즘을 적용하였다. 다음으로, 실제 도시를 촬영한 스트리트뷰 사진 등을 토대로 탐지 결과와 거리 인식에 대한 분석을 실시 하였다. 위의 그림은 실험 과정에 대한 간단한

설명이다.




〈그림〉 Leica BLK 360 Lidar 카메라

- 실제 도심환경 점군 데이터를 얻기 위하여, 대전광역시 3개 지역의 거리를 측정하였다. 궁동, 대화동, 신성동 순으로 데이터를 획득하였으며, 데이터 획득에 사용된 장비는 위 사진에 나온 Leica BLK 360 Lidar 카메라를 활용하였다.



〈그림〉 궁동지역 포인트 클라우드 스캔 결과




〈그림〉 궁동지역 스트리트뷰(출처: map.kakao.com)




〈그림〉 궁동지역 스트리트뷰(출처: map.kakao.com)

- 위의 데이터는 대전광역시 궁동 지역을 스캔한 결과다. 대전광역시 궁동 지역은 평소 대학로로 사람들의 방문이 잦은 지역이다. 사람의 이동이 잦으며, 탐지되는 물체들 또한 다량으로 존재한다.



〈그림〉 대화동 지역 포인트클라우드 스캔 결과




〈그림〉 대화동 지역 스트리트뷰(출처: map.kakao.com)




〈그림〉 대화동 지역 스트리트뷰(출처: map.kakao.com)


- 위의 데이터는 대전광역시 대화동 지역 스캔 결과다. 대화동 지역은 지역 발전이 더딘 지역으로, 공단 근처에 위치하여, 사람들의 왕래가 많지 않은 지역이다.



〈그림〉 신성동 지역 포인트클라우드 스캔 결과




〈그림〉 신성동 지역 스트리트뷰(출처: map.kakao.com)




〈그림〉 신성동 지역 스트리트뷰(출처: map.kakao.com)

- 위의 스캔데이터는 대전광역시 신성동 지역 스캔 결과 사진이다. 신성동 지역은 비교적 조용한 지역으로 상업 시설이 다양하여 특정 시간대에 사람들의 방문이 잦다.



〈그림〉 포인트넷 알고리즘(Pointnet Algorithm)의 구조

- 데이터 획득 후, 거리의 요소 탐지를 위한 점군 데이터 탐지 알고리즘인 Pointnet 알고리즘을 사용하였다. Pointnet 알고리즘은 딥러닝 기반 3차원 비전 객체 인식 기술로, 분류 네트워크(classification network)와 분할 네트워크(segmentation network)로 이루어져 있다. Pointnet 알고리즘은 기존의 점군 데이터 처리 방법으로 활용되던 voxelization의 단점 중 하나인 빈 공간 발생을 포인트 순열의 불변성을 이용하여 3차원 점군데이터에서 객체를 인식할 수 있는 장점을 가진다.




〈그림〉 라벨링 된 포인트 클라우드(벤치)



〈그림〉 라벨링 된 포인트 클라우드(자동차)

- Pointnet 객체 탐지를 위하여 요소별 라벨링 작업을 통해 거리의 요소에 대한 라벨링 된 물체 데이터 학습을 진행하였으며, 학습된 데이터를 토대로 실험을 진행하였다. 라벨링 된 물체 데이터는 가로등(Street light), 벤치(Bench), 나무(Tree), 전봇대(Telephone Pole), 자동차(Car), 자전거(Bicycle) 총 6개로 학습을 진행하였다. 위의 그림과 같이 자동차와 벤치 등을 탐지할 수 있었으며, 각각의 탐지된 결과에 따라 요소별로 점수를 부여하였다.




<그림> Classification(분류) 된 포인트 클라우드 결과

- 도시 거리에 대한 인식 정도는 4가지 카테고리로 나누어 탐지 요소별 점수 부여를 통한 평가를 진행하였다. 4가지 카테고리는 안전함(Safe), 위험함(Unsafe), 활기참(Lively), 지루함(Boring)으로 구분하였으며, 각각의 카테고리에 대한 탐지된 물체에 대한 점수는 아래 그림과 같다.

Perception Categories	Item	Score
Safe	Street Light	+0.3
	Bench	+0.2
	Tree	+0.1
Unsafe	Telephone Pole	-0.3
	Car	-0.2
	Bicycle	-0.1
Lively	Car	+0.3
	Bicycle	+0.2
	Bench	+0.1
Boring	Telephone Pole	-0.3
	Tree	-0.2
	Street Light	-0.1


〈그림〉 요소에 따른 인식 카테고리 및 점수

- 실험을 수행한 결과, 사람들이 많이 몰리는 교차로 혹은 상가 건물 앞이 안전하고 활기찬 거리에 대한 인식을 주었다. 안전한 요소들과 활기찬 요소들이 많음과 동시에 거리에 대한 인식 또한 높은 점수를 나타내는 것을 확인하였다. 아래는 신성동의 거리 인식에 대한 결과를 나타낸다. 실험 결과는 주로 사람이 많이 모이는 상업 시설에는 물체가 많이 탐지 되기 때문에 Lively 하며, Safe 한 결과를 보임을 알 수 있다.
- 참고로 각 도로의 평가를 위해 선정된 요소는 실제 점군데이터로 해당하는 요소의 구분과 그에 따른 거리의 평가가 가능한지를 파악하기 위한 실험적인 연구를 위해 선정하였다. 실험 결과에 따라 선정 요소의 검토 및 방법의 고도화가 필요하다.



Lively & Boring


〈그림〉 신성동의 거리 인식 정도(Lively & Boring)



Safe & Unsafe

〈그림〉 신성동의 거리 인식 정도(Safe & Unsafe)


- 공동 또한 사람들이 많이 몰리는 상업 시설 및 일부 위치에서 좀 더 활발한 객체 탐지가 되었다. 거리의 입구나 끝 같은 경우, 활발한 중심 지역과 달리 탐지되는 물체들과 시설이 적은 편에 속하기 때문에, 낮은 점수를 나타내게 된다.



Lively & Boring

〈그림〉 궁동의 거리 인식 정도(Lively & Boring)


- 궁동의 안전성 점수 또한, 사람이 많이 모이는 지역이 안전함을 나타내었다. 대학로 같은 골목의 경우 자동차와 자전거가 거의 지나다니지 못하고 건물 앞에 주차 되어 있는 경우가 많다. 사람들의 보행이 주된 풍경인 대학로 지역에서 건물 앞이 좀 더 위험한 물체들이 많이 탐지되어 Unsafe에 대한 점수가 높음을 확인하였다.



Safe & Unsafe

〈그림〉 궁동의 거리 인식 정도(Safe & Unsafe)


- 대화동의 경우, 전체적으로 통행이 많이 몰리는 중심 지역이 좀 더 Lively에 대한 점수가 높음을 알 수 있었다. 주로 주택이 밀집되어 있으며, 공단과 가까운 동네라 통행량이 많이 있는 지역에 활발한 활동이 있음을 알 수 있다.



Lively & Boring

〈그림〉 대화동의 거리 인식 정도(Lively & Boring)

- 반면, Safe와 Unsafe에 대한 점수는 다른 지역과 확연한 차이를 보였다. 재개발 구역으로 선정된 대화동은 다른 지역과 다르게 낡은 전봇대 등의 요소들이 다량 탐지 되었다. 그 결과, 다른 지역보다 Unsafe에 대한 점수가 전체적으로 높게 나타났다.



〈그림〉 대화동의 거리 인식 정도(Safe & Unsafe)

- 본 연구에서는 실제 도심 지역의 거리 촬영 후 얻은 포인트 클라우드 데이터를 토대로, 객체 탐지 알고리즘을 활용해 도시 공간의 포인트 클라우드에 대한 탐지를 실시하였다. 탐지된 물체들에 점수를 부여하여 안전한 정도 및 활발한 정도를 파악하였다.
- 본 연구를 통하여 실제 도심 지역에 대용량 포인트클라우드 데이터를 토대로 도시 공간의 특성과 거리 인식에 대한 분석을 할 수 있는 기초 연구로 활용할 수 있다. 또한, 기존의 2차원 이미지에서의 도시 인식과 다르게 3차원 점군 데이터 기반 거리의 구성 요소들 탐지를 통한 인식 정도 분석이 가능한 것을 확인하였다.

나. 연구 개발 성과

(1) 논문 게재 성과

Kim, G., Park, B., & Kim, A. (2019). 1-Day Learning, 1-Year Localization: Long-term LiDAR Localization using Scan Context Image. *IEEE Robotics and Automation Letters (RA-L) (with ICRA)*, 4(2):1948-1955. [Scopus]

Jeong, J., Cho, Y. & Kim, A. (2019). The Road Is Enough! Extrinsic Calibration of Non-Overlapping Stereo Camera and LiDAR Using Road Information. *IEEE Robotics and Automation Letters (RA-L) (with IROS)*, 4(3):2831 - 2838. [Scopus]

Shin, Y.-S. & Kim, A. (2019). Sparse Depth Enhanced Direct Thermal-infrared SLAM Beyond the Visible Spectrum. *IEEE Robotics and Automation Letters (RA-L) (with IROS)*, 4(3):2918-2925. [Scopus]

Kim, G., Kim, A. & Kim, Y. (2019). A new 3D space syntax metric based on 3D isovist capture in urban space using remote sensing technology. *Computers, Environment and Urban Systems*, 74:74-87, 2019. [SSCI]

Jang, K. M., & Kim, Y. (2019). Crowd-sourced cognitive mapping: A new way of displaying people's cognitive perception of urban space. *PLOS ONE*, 14(6), e0218590. [SCIE]

Kang, N. Y., & Kim, Y. (2019). Potential of Urban Land Use by Autonomous Vehicles: Analyzing Land Use Potential in Seoul Capital Area of Korea. *IEEE Access*, 7, 101915-101927. [SCIE]

Kim, Y., & Kim, T. W. (2019). How do people explore a large concourse in university campus? A computational analysis. *Journal of Computational Design and Engineering*, 6(4), 666-674. [SCIE]

(2) 특허 성과

- 등록

① 등록국: KR, 등록번호: 10-1973903, 발명의 명칭: 3차원 센서 데이터를 활용한 도심 속 관측자 중심의 시각 영역 분석 자동화 방법 및 장치, 발명자명: 김아영, 김기섭, 김영철, 등록기관: 한국과학기술원, 등록일: 2019.04.23., 공개유무: 공개

- 출원

① 3차원 센서 데이터를 활용한 도심 속 관측자 중심의 시각 영역 분석 자동화 방법 및 장치, 김아영 김기섭 김영철, 특허출원, 출원번호 제10-2018-0086409호, 2018년 7월 25일


② 자율 주행 차량에 의한 도시의 토지 이용 변화 예측 방법, 김영철 강나운, 특허출원, 출원번호 제10-2019-0057391호, 2019년 5월 16일

(3) 기술적 성과

- 실시간 3차원 공간 정보 취득을 위한 모바일 매핑 시스템 (MMS) 자체 구축력 (HW/SW) 보유
- 해당 기술은 바퀴 정보, 카메라 정보, 관성 센서 정보, 3차원 LiDAR 포인트 클라우드 정보 등 대규모의 정보를 실시간으로 처리하는 기술이 요구되며, 이를 융합 (퓨전) 하는 이론 및 기술적 능력이 요구됨.
- 국내외 경쟁사의 3차원 지도를 제작하기 위하여 경우 비싸고 오래 걸리는 다양한 후처리가 요구됨. 본 연구과제에 쓰인 센서 정보 융합 기반 SLAM 및 그래프 기반 로봇 이동 경로 최적화 기술을 이용하여 넓은 도심지역에 대해 빠르게 정보를 취득하고, 빠르게 대규모 도심 가시성 분석이 결과적으로 가능하였음.
- 이런 로봇관련 기술을 앞의 논문 게재 성과 2 ~ 3에 보고 하였고, 이런 실시간 대규모 3차원 정보 취득 및 최적화 기술을 이용한 효율적인 3차원 센서 기반 도심 가시성

측정 방법에 대한 논문을 논문 게재 성과 1, 4 에 해당하는 논문에 보고 하였음. 특히 논문4의 경우 SSCI (Social Sciences Citation Index) 저널에 해당함으로써 로봇 기술을 이용해 사회과학 쪽 분야의 방법론의 수준 자체를 높임. 기존에는 정적이고 모델 기반의 가상 환경에서 도심 가시성 분석이 수행되었다면, 실제 데이터를 이용하여 더 정밀하고 더 빠르고, 더 대규모의 분석이 체계적으로 수행가능함을 보임.

- 특허의 알고리즘도는 아래와 같다.



3. 목표 달성도 및 관련 분야 기여도

가. 정량적 및 정성적 목표 달성도

(1) 정량적 목표 달성도

구분			목표	실적	달성도(%)	점수	
논 문	SCI(E)급 학술지 게재	2점	4 (8점)	4	100%	8점	
	일반 학술지 게재	1점	1 (1점)	3	300%	3점	
특 허	특허 출원	1점	2 (2점)	2	100%	2점	
	특허 등록	2점	1 (2점)	1	100%	2점	
등록 · 기탁 대상 성과물			보고서 원문				
			연구시설 · 장비				
			기술요약정보				
			생명자원	생명정보			
				생물자원			
				신품종			
			소프트웨어				
			화학물				
소계(점수)		14점	14점		15점		

(2) 정성적 목표 달성도

구분		핵심 성과물 (level1)	단위 성과물 (level2)		성과점검기준						목표성 과건수	달성성과건수
					질적목표(측정방법)	목표치	달성치	검증방법	가중치			
주관	1	도시 공간에서 취득하는 데이터 특성에 따른 3 차원 시각영역 을 측정 이론	1-1	선행연구 조사 및 문제점 도출	①	기존 시각영역 방식의 문 제 점 도출	시각영 역의 정의와 기존의 방법 제시	100%	주요 선행 연구 분석	0.7	논문 1건	특허: 출원 건 등록 건 논문: 1 건 시제품: 건 S/W: 건
			1-2	목표 이론의 설정	①	3차원 시각영역의 이론을 구축하기 위한 요소 설정	이론의 검증	100%	테스트 공간에 적용	1.3		
			1-3	3차원 시각영역의 측정 이론	①	리모트 센싱 기술을 고려하여 필요에 따라 이론의 수정을 제안	이론의 확정	100%	테스트 공간에 적용	1.3		
	5	매핑 차량 데이터에 정의된 시각영역 을 적용하여 도시 공간의 특징을 분석	5-1	우선 선정된 지역을 매핑 차량으로 데이터 획득	①	복잡도가 낮은 지역을 기준으로 선정한 지역에서 매핑 차량으로 공간 포인트 클라우드 데이트 측정	우선 선정 지역의 주요 공간의 포인트 클라우 드 측정	100%	측정 공간의 데이터 확보	1.3	논문 1건	특허: 출원 건 등록 건 논문: 1 건 시제품: 건 S/W: 건
			5-2	우선 선정 지역의 데이터로 도시 공간의 특징 분석	①	알고리즘에 의해 도시공간의 3 차원적 특징을 분석	알고리 즘으로 선정 지역의 3차원 시각영 역 분석	100%	지역과 시각영 역의 표시 결과 비교	2		
	6	실제 도심 환경을 제안한 알고리즘 과 센서를 통해 3 차원 시각영역 을 측정하고 기계학습	6-1	복잡도가 높은 도심의 3차원 공간 데이터 획득	①	복잡도가 높은 지역으로 선정한 지역에서 매핑 차량으로 공간 포인트 클라우드 데이터를 측정	복잡도 높은 지역의 주요 공간의 포인트 클라우 드 측정	100%	측정 공간의 데이터 확보	1.3	논문 1건	특허: 출원 건 등록 건 논문: 1 건 시제품: 건 S/W: 건
			6-2	실제 도심	①	알고리즘에	알고리	100%	지역과	2.1		

		을 활용하여 도시공간 의 특징을 자동으로 구분		환경의 도시공간의 특징을 분석		의해 분석되는 도시공간의 특징을 분석	증으로 선정 지역의 3차원 시각영 역 분석		시각영 역의 표시 결과 비교			
공동	2	리모트 센싱 기술로 3 차원 시각영역 을 측정하고 도시공간 의 특징을 구분하는 이론	2-1	3차원 시각영역 관련 성행 특허를 조사	①	3차원 시각영역 이론의 정립을 위해 관련 선행 특허 조사 및 자료 구축	관련 성행 특허를 점검	100%	선행 특허의 분석과 자료 구축	1.3	논문 3건 특허 출원 1건	특허: 출원 1 건 등록 1 건 논문: 3건 시제품: 1 건 SW: 1 건
			2-2	새로운 3차원 시각영역 특허를 출원	①	3차원 시각영역의 이론의 특허 출원	독자적 아이디 어와 이론을 확보	100%	특허 출원	2.1		
	3	취합한 포인트 클라우드 데이터에 서 3차원 시각영역 을 분석하는 알고리즘	3-1	알고리즘의 구성과 테스트	①	3차원 시각영역의 이론을 구하는 알고리즘의 구성과 테스트 실행하여 보완	알고리 즘의 구성	100%	결과와 포인트 클라우 드 비교	1.3		
			3-2	알고리즘의 구현과 확정	①	알고리즘의 성능을 테스트하여 3 차원 시각영역을 측정과 분석 알고리즘 확정	알고리 즘의 확정	100%	결과와 포인트 클라우 드 비교	2		
	4	도시공간 의 3차원 시각영역 의 패턴을 학습하여 도시공간 을 분석하는 알고리즘	4-1	기계학습의 모델을 설정	①	3차원 시각영역의 패턴에 따른 특징을 분석하기 위한 기계학습의 모델을 구성	기계학 습을 위한 모델을 구성	100%	효율성 과 정확성 확인	0.7	특허 등록1건 논문1건	특허: 출원 1 건 등록 1 건 논문: 1 건 시제품: 1 건 SW: 1 건
			4-2	도시공간의 특징에 따른 학습 진행	①	기계학습 모델에 도시공간의 3 차원 특성을 파악하여 구분하는 학습을 진행	도시공 간의 세부적 인 특성 구분	100%	효율성 과 정확성 확인	1.3		
			4-3	기계학습의	①	도시공간의 3	시각영	100%	효율성	1.3		

				모델로 도시공간을 파악하는 알고리즘 고안	차원 시각영역의 패턴에 따라 도시공간의 특징을 구분, 인식 알고리즘 고안	역의 패턴에 따른 특징을 구분하 는 알고리 즘 구성		과 정확성 확인			
계									20		특허: 출원2건 등록1건 논문: 7건

(3) 자체외부자문회의 반영 사항 내용

- 중간 모니터링 시 제안이 있었던 외부자체평가를 실시하였음
- 외부자체평가 및 자문 내용을 연구 진행 및 결과, 향후 계획에 반영함

구분	수정·보완의견 (요구사항)	반영여부 (√ 표기)	수정·보완의견 (요구사항) 반영내용 요약	비고
A	- 3차원 Isovist를 통한 2차원 분석 의 한계 극복	☒ 보완 ☐ 보완불가	- 본 연구의 3차원 공간 분석의 기여 부분	
	- 거리 가중치와 높이에 대한 고려가 되어 도시 공간을 분석하는 유용한 도구로 판단	☒ 보완 ☐ 보완불가	- 본 연구의 거리와 높이를 고려한 3차원 공간 분석 방법	
	- Volume과 Openness의 차이를 통해 분석 지표의 특성을 부각	☒ 보완 ☐ 보완불가	- 본 연구의 이론을 검토하기 위해 진행한 부분	
	- 공간상의 분포를 시뮬레이션을 통해 시각화한 분석 자료가 위상학 지도로 설계되어 직관적으로 표현될 수 있기를 기대함	☒ 보완 ☐ 보완불가	- 대전 지역의 주거지를 가상 공간화 하여 검토 - 실제 대전 지역의 3가지 거리를 대상으로 시각적 인식의 영향을 검토	
	- 추후 장기적으로 지도위에	☒ 보완	- 자문 내용과 같이 추후	

구분	수정·보완의견 (요구사항)	반영여부 (√ 표기)	수정·보완의견 (요구사항) 반영내용 요약	비고
	스크롤을 통해 위치를 잡으면 Openness 분석 자료가 실시간으로 보일 수 있는 플랫폼 연구로 발전할 수 있는 가능성이 있음	☐ 보완불가	연구에서 Openness에 의한 실시간 지표 개발 예정	
	- Openness의 유용성을 강조하는 다양한 사례 분석으로 도시 분석의 새로운 지표가 가능할 수 있기를 기대함	☒ 보완 ☐ 보완불가	- Openness에 따른 시각적 인식의 활용 가능한 부분의 연구를 진행	
B	- 시의적절하고 성과를 생산한 훌륭한 연구	☒ 보완 ☐ 보완불가	- 본 연구의 시의적으로 적절함을 강조	
	- 도시 내 정적대상(건물, 식생)뿐만 아니라 동적대상(차, 사람 등)에 대한 데이터 수집 및 처리에 대한 고민 필요	☒ 보완 ☐ 보완불가	- 본 연구에서는 건물의 변화를 인식하는 연구를 포함 - 추후 동적 변화의 대상을 넓히는 연구를 고려함	
	- 한번의 데이터 수집 이후, 충분한 n이 쌓이면 경험적 measure를 추정하는 연구로 발전 가능 - 예를 들어, 1년간 N회 데이터 수집으로 도시형태 변화율이 유용한 변수 도출 가능성	☒ 보완 ☐ 보완불가	- 본 연구의 자동화 방법을 활용하여 축적된 데이터로 변화율에 유용한 변수 도출을 계획	
C	- 기존 GPS 및 공중 촬영 방식의 도시 3D 구축 방식에서 진일보한 도시 공간 측정 기술로 기대됨	☒ 보완 ☐ 보완불가	- 본 연구는 거리를 기준으로 자세한 분석에 반영	

구분	수정·보완의견 (요구사항)	반영여부 (√ 표기)	수정·보완의견 (요구사항) 반영내용 요약	비고
	- 부동산 분야와 접목 가능한 요소는 기존 도시공간데이터와 연계하여 실질적으로 거주자가 인식하는 공간 중심 개선 요인을 분석하여 보다 효율적인 환경 개선을 시행, 부동산 및 도시의 가치 향상에 기여할 수 있을 것으로 보임	☒ 보완 ☐ 보완불가	- 본 연구에서 제시한 시각 영역과 점군데이터 활용한 이론은 추후 연구에서 고도화하여 활용 영역을 확장을 고려	
	- 거주자, 방문자가 인식하는 공간 중심에 어떤 요소를 반영, 가중 평가할지에 대한 보다 객관적인 근거가 있으면, 적극적인 데이터 활용에 도움이 될 것으로 판단	☒ 보완 ☐ 보완불가	- 본 연구에 거리 상의 운전의 판단을 기준으로 자동화한 거리 평가 연구를 진행	
	- Safe-unsafe의 데이터를 실질적인 사고 및 범위 data와 비교하여 보완하는 방안이 가능할지 궁금	☒ 보완 ☐ 보완불가	- 본 연구는 제안하 이론의 활용 가능성을 판단. 추후 연구에 반영 예정	
D	- 3D Lidar 센서로부터 수집된 점군 데이터를 도시 계획에 활용하는 기초연구로서 향후 스마트시티 계획, 설계 유지관리 등 다양한 활용이 예상	☒ 보완 ☐ 보완불가	- 본 연구의 기여 부분에 강조	
	- 기계학습 기법을 이용한 빅데이터처리에 특화된 강점을 갖는 것으로 판단	☒ 보완 ☐ 보완불가	- 본 연구의 방법에 기계학습 방법을 활용	
	- 실제 측정된 데이터에 기반하여	☒ 보완	- 실제 데이터인 대전, 판교	

구분	수정·보완의견 (요구사항)	반영여부 (√ 표기)	수정·보완의견 (요구사항) 반영내용 요약	비고
	정확한 결과를 제공해 나갈 수 있음	☐ 보완불가	지역의 데이터를 적용	
E	- 3D Lidar 센서로부터 수집된 점군 데이터를 도시 계획에 활용하는 기초연구로서 향후 스마트시티 계획, 설계 유지관리 등 다양한 활용이 예상	☒ 보완 ☐ 보완불가	- 본 연구의 기여 부분에 강조	
F	- 경관이나 사람(보행자)을 유사 시점에서 인지하거나 연속적으로 느끼는 환경 등에 대한 객관적 지표 평가가 가능함	☒ 보완 ☐ 보완불가	- 본 연구의 활동과 추후 계획에 반영	
	- 공공사업을 통한 건물의 배치나 공원, 조경, 시설물 등 배치에 대한 첫 번째 관점에서 시뮬레이션이 가능함	☒ 보완 ☐ 보완불가	- 본 연구에서 거리의 요소에 따른 평가 방법에 반영	
	- 경관이 사람의 시점이 아니라 2D 시점에서 가이드라인이 전해지는 것에서 입체적 평가 후 가이드라인 제안이 가능	☒ 보완 ☐ 보완불가	- 본 연구의 기대 및 활용 방안에 강조	
	- 특히 원도심(낮은 건물이 많은 곳) 사업 적용이 가능함			
	- 원도심 대상 측정을 통해 데이터화 후 상권의 재프로그래밍 필요 거리나 거점 대지를 찾을 수 있을 듯함	☒ 보완 ☐ 보완불가	- 본 연구의 활용 방안 및 향후 계획에 고려	
	- Point Cloud 값과 RGB, 사진	☒ 보완	- 본 연구의 거리 요소에 따른	

구분	수정 · 보완의견 (요구사항)	반영여부 (√ 표기)	수정 · 보완의견 (요구사항) 반영내용 요약	비고
	등에서 데이터 복합 후 건물의 연속적 경관 재료, 오픈 정도 등 도출이 가능 및 인지적 Pattern 추출이 가능할 것으로 예상	☐ 보완불가	물체 인식과 거리의 영향에 반영	
G	- 포인트 클라우드 처리 및 시각화 방안에서 1개의 포인트가 32byte(x, y, z, rgba)라고 할 때, 약 2억 7천개(8GB) 정도의 point를 실시간 시각화 하여 point를 많이 압축하지 않고 interactive 하게 사용 가능	☒ 보완 ☐ 보완불가	- 본 연구의 활용 계획에 반영	
	- Vertex data가 최종적으로 화면에 뿌러지기 전까지 크게 2단계(1단계 - 계산, 2단계 - 래스터화)를 거치는데, 두 번째 단계의 계산 로드가 많으므로 계산시간이 오래 걸리며 1단계에서 화면안에 래스터라이징 할 vertex만 남긴 후 빠르게 시각화 할 수 있음	☒ 보완 ☐ 보완불가	- 본 연구의 데이터 처리에 반영	
	- 1단계에서 화면안에 래스터라이징할 vertex만 남긴 후 빠르게 시각화 할 수 있음	☒ 보완 ☐ 보완불가	- 본 연구의 데이터 처리에 반영	
	- 1단계처리는 ①NVIDIA RTX 카드(메쉬데이터용 전처리), ②기타 카드(OpenGL의 Compute	☒ 보완 ☐ 보완불가	- 본 연구의 활용 계획에 반영	

구분	수정 · 보완의견 (요구사항)	반영여부 (√ 표기)	수정 · 보완의견 (요구사항) 반영내용 요약	비고
	Shader + Vertex & Fragment Shader)로 가능			
	- 1단계에 사용하는 기술적 요소 ☐ Frustum Culling: 화면(시야) 밖에 보이는 포인트 제거 ☐ Small Primitives: 떨어져 작게 보이는 것들은 적절한 비율로 생략 후 래스터라이징 단계로 넘김	☒ 보완 ☐ 보완불가	- 본 연구의 활용 연구에 반영	

나. 관련 분야 기여도

(1) 취합한 포인트 클라우드 데이터에서 3차원 시각영역을 분석하는 컴퓨터 알고리즘을 구성

- 실제 측정에 필요한 이론을 설정하는 단계로, 리모트 센싱 기술인 라이다에 도시공간을 측정하는 컴퓨터 알고리즘을 구성하였다.
- 실제 측정 시에 각 측정 지점과 3차원 시각 영역 간의 조건을 고려하고 1단계에서 선정한 포인트클라우드 데이터의 3차원 시각 영역 측정의 개념을 리모트 센싱 기술에 적용하는 알고리즘의 구성하였다.
- 구체적으로 자동차에 설치된 라이다를 활용할 계획으로 이동하는 측정자의 3차원 시각 영역 인식의 이론화를 추진하였다.

(2) 포인트클라우드 데이터에서 나타나는 도시 공간 요소를 구분

- 포인트 클라우드에 의해 측정된 도시공간과 실제 인식되는 도시공간을 상호 확인하였다.

- 도시 공간 내 요소를 학습시켜 도시 공간에 대한 인식 및 거리 평가에 사용 가능하게 하였다.


(3) 3차원 시각영역의 패턴을 학습하여 도시공간을 분석하는 알고리즘 개발

- 기계 학습법을 센서 데이터에 적용하여 도시공간을 측정 시 나무, 건물, 도로 등 주요한 도시공간의 특징을 구분하였다.
- 시각적 인지 영역에 대한 연구로 도로위의 사고위험성 및 도시 공간 인지에 대한 연구를 진행 하였다.

(4) 도시공간 분석을 위한 3차원 시각영역의 이론화 및 적용

(가) 매핑 차량 데이터에 정의된 시각영역을 적용하고 도시 공간의 특징을 분석


- 리모트 센싱 기술인 라이다를 활용한 3차원 시각영역의 이론 구축. 실제 도시공간에 적용하면서 3차원 시각영역의 측정을 위한 이론을 완성하였다.
- 도시공간의 형태와 3차원 시각영역을 연계한 도시공간의 특성을 분석하는 방법으로 확장을 도모하고 센서 데이터로 구성된 3차원 공간에서 시점변화가 자유로워지므로 다시점, 다차원 분석이 가능성을 확인하였다.



<그림> 3차원 포인트 클라우드 데이터의 Ray Casting Algorithm 분석 예시

(나) 실제 도심환경 데이터를 통한 도시 분석

- 실제 도시에 3차원 시각영역을 구축하면서 측정과 분석의 이론을 점검하였다.
- 실제 단순한 도시 공간의 시각영역 데이터를 얻어 대표건물 및 거리의 요소들을 분석하여 점차적으로 대도시 및 사람이 많이 몰리는 도심 지역 분석까지 확대 가능하였다.
- 데이터의 취득 시, 라이다를 활용한 실제 측정으로 실험에 접근 가능하였다.
- 대표적인 건물이나 사람들이 많이 찾는 지역 위주로 도시 공간의 특성과 및 거리들의 요소 탐지로 거리의 점수 평가가 가능하였다.




〈그림〉 3차원 포인트 클라우드 데이터의 시각화 예시

다. 연구개발의 창의성 · 혁신성

- 본 연구의 창의성은 리모트 센싱 기술인 라이다를 이용하여 3차원 시각영역으로 측정하는 창의적 이론의 구축이다. 기존 도시공간의 분석을 완성된 수치지도를 바탕으로 2차원의 분석의 한계를 보유하고 있어 리모트 센싱 기술을 활용하여 정확한 물리적 정보의 획득이 가능하며 도시공간의 분석을 3차원으로 확장하는 창의적 접근

방식을 제안했다. 또한 리모트 센싱 기술의 활용으로 도시의 물리적 특징을 실시간으로 파악할 수 있는 기술로 발전시켰다.

- 본 연구의 혁신성은 대지 위의 움직이는 관찰자의 시선에서 도시공간의 물리적 공간의 측정을 낮은 비용으로 달성할 수 있는 혁신적인 방법 제시이다. 항공측정 방식보다 낮은 비용으로 도시공간의 물리적 환경을 측정할 수 있는 혁신적인 방법으로 쉽게 측정할 수 있고, 실제 사용하는 도시 환경에 근접한 측정이 가능한 방법이다. 대지 위의 관찰자의 시선으로 측정하여 도시 내 발생하는 다양한 데이터를 사람의 활동 방식과 연관할 수 있으며, 움직이는 시선에 의한 도시공간을 파악하기 위한 라이다의 창의적인 활용 방법을 개발하였다.
- 이처럼 본 연구는 발전하는 기술을 국토설계 기술로 혁신적인 응용을 추구하였다. 리모트 센싱 기술인 라이다를 이용하여 국토 공간을 측정하고 분석하는 창의적인 이론을 제안하여 기존의 도심지역을 측정하여 도시를 파악하고 관리하는 혁신적인 기술로 확장하였다. 본 연구의 결과는 자율 주행, 스마트시티 등 데이터 기반으로 도시공간을 파악하는 방식의 기술로 응용이 가능하다.
- 또한 새로운 이론과 기초원천 기술로 저비용으로 실제 데이터를 분석을 추구하였다. 기존의 항공 라이다를 활용시에는 고비용과 연구자들이 쉽게 접근할 수 없는 기술로 도시공간의 효율적 분석에 장애 요소이다. 그러나 본 연구에서 제안하는 이론화는 상대적으로 저비용으로 연구자들이 쉽게 접근이 가능한 기초 원천 연구인 혁신성을 보유하고 있다. 그리고 기존의 별도의 수작업 또는 구축된 디지털 입면모델을 활용하는 기존의 방법은 실제 정확한 데이터를 고려하지 않아서 발생하는 잘못된 결과 도출의 위험요소를 포함하였다. 따라서 본 연구에서 제안하는 방법은 실제 측정된 데이터를 기반으로 정확한 결과를 제공하는 혁신성을 보유하고 있다.
- 본 연구는 수집 방법이나 뷰어 등과 같은 표면적 기술보다는 공간정보의 요약과 표현이라는 더 원론적인 문제를 해결한다. 일레로 옥스퍼드(영국)나 미시간대학교(미국)에서 취득한 데이터에 대해서도 개발한 방법을 적용하여 개발된 기술이 범용적으로 쓰일 수 있다는 점을 증명하였다. 각각 생성 예시는 p74와 p75에 자세히 기술되어 있다.



[그림] 제안하는 방법은 왼쪽의 미시간대학교 데이터나

오른쪽의 옥스퍼드대학의 데이터에서 모두 적용이 가능하다.

- 분석 측면으로 본 연구의 차별성 또한 매우 크다. 기존의 2D 또는 모델 기반의 방법이 아닌 실제 데이터 기반의 3차원 분석이라는 점에서 리모트 센싱 분야를 도시 분야에 접목하여 실제 분석 지표 개발까지 완성한 연구라는 점에서 또한 차별성이 있다.

라. 목표 달성 여부

- 본 과제는 포인트 클라우드 데이터에서 3차원 시각영역을 분석하는 컴퓨터 알고리즘을 구성하는 논문을 게재함으로써 목표 달성을 완료하였다.
- 본 과제는 포인트클라우드 데이터에서 나타나는 도시 공간 요소를 구분하고, 실제 도심 공간에 적용함으로써 목표 달성을 완료하였다.
- 본 과제는 3차원 시각영역의 패턴을 학습하여 도시공간을 분석하는 알고리즘을 개발함으로써 도시공간의 특징을 구분하였고, 그에 상응하는 결과를 얻음으로써 목표 달성을 완료하였다.
- 본 과제는 도시공간 분석을 위한 3차원 시각영역의 이론화 및 적용으로 정량적, 정성적 목표를 충실히 달성하였다.

4. 연구개발성과의 활용 계획 등

가. 연구개발성과의 활용 방안

(1) 최종성과물은 도시공간에서 리모트 센싱 기술인 라이다에 의한 데이터를 활용하여 3차원 시각영역과 위상적 공간분석의 이론을 구축

- 도시공간을 리모트 센싱 기술을 활용하여 측정하는 기술로 발달
- 도시공간 내 물리적 공간의 시각적 분석을 3차원으로 확장
- 실시간으로 물리적 특징을 파악할 수 있는 기술로 발달
- 기존 도시공간을 측정하여 도시를 관리, 유지하는 방법에 적용
- 후속 연구시 데이터처리의 속도를 향상하기 위한 GPU 및 병렬처리, 데이터처리 방안을 후속 연구에 고려

(2) 새로운 이론의 제안으로 미래원천기술을 확보

- 도시공간에서 리모트센싱 기술인 라이다에 의한 데이터를 활용하여 3차원 시각영역을 측정하는 기술을 활용
- 기존 도시 공간을 측정하여 도시를 관리, 유지하는 방법에 작용을 고려
- 도시공간과 도시 내 발생하는 다양한 데이터와 연결 관계를 분석할 수 있는 기반을 제공할 수 있는 방향으로 발전

(3) 후속 연구로 발전하여 점군데이터를 도시 공간 분석에 적극적으로 활용

- 도시 재난재해 위험성 분석 등 도시 공간의 물리적 특성을 파악하는 연구에 점군데이터 처리 방법을 도입하여 정밀도 및 정확성의 확대에 기여 추진
- 빅데이터 처리 방법의 연구를 진행하여 실제 분석에 걸리는 시간을 단축하고 분석하기 위한 도시 영역의 범위의 확대를 추진

(4) 기존 도시 공간 분석 방법에 본 연구의 성과를 접목하여 새로운 연구분야를 활성화

- 국토설계 기술의 기초 원천 기술의 확보로 기존에 2차원적 도시 공간의 분석에 3차원 도시 공간의 분석 방법을 적극적으로 도입 추진
- 새로운 이론의 기초 원천 기술을 바탕으로 향후 기술의 개발을 이루어 국제적으로 한국의 기술이 넓게 사용

(5) 도시 분석 및 관리, 평가에 본 연구의 성과를 적극적으로 활용

- 스마트시티에서의 공간 정보 구축과 더불어 지속적인 인프라 공간 정보를 분석 관리하는데 본 연구의 성과를 활용을 고려
- 3차원 점군데이터로 구축된 정밀지도로 도시의 변화 등 성장과 쇠퇴의 주기 분석에 활용 가능
- 3차원 점군데이터로 탐지된 녹지 공간의 분석으로 도시 재생에 있어서 주요한 자연 환경 요소를 구분하는 기준 자료로 사용 가능
- 드론 등 항공 라이다 측정으로 실제적인 3차원 물리적 공간을 구성하는 건조 환경과 자연 환경을 구분과 분석에 활용 가능

나. 기대효과

(1) 기술적 측면

도시공간의 형태를 측정하고 표현하는 방식의 획기적 발전

- 도시공간의 물리적 형태를 표현하는 측정기술의 이론으로 지능형 도시, 스마트 도시를 형성하기 위한 바탕이 되는 물리적 공간의 특징을 디지털 데이터화
- 도시공간을 리모트 센싱 기술로 측정하여 도시공간의 활용과 분석에 활용할 수 있고, 무엇보다 이러한 분석을 위해서 기본적으로 필요한 3차원 지도를 바탕으로 공간

특징의 파악을 자동화

(2) 경제적 · 산업적 측면

빠른 시간에 측정되는 도시의 물리적 공간은 다양한 도시공간 데이터와 연계하여 도시의 계획, 설계, 관리, 유지 분야 등의 발전

- 실시간으로 도시의 3차원 공간을 처리
- 실생활에 적용 가능한 3차원 공간 분석의 기술

(3) 사회적 측면

도시공간의 질적인 향상

- 본 이론을 바탕으로 도시공간을 효과적으로 분석
- 분석된 결과를 바탕으로 도시 재생 및 재난 위험성 탐지에 활용 가능
- 도시 공간에서의 시각 영역에 따른 사고 위험성 분석 및 도시 계획에 이바지 가능
- 효과적인 공간의 분석은 현재 도시공간의 문제점을 파악하는데 사용할 수 있고, 이러한 문제점과 해결방안을 위한 다양한 요소들과의 관계를 파악하는데 사용

(4) 국제적 측면

도시공간의 측정과 인식의 이론과 기초 원천 기술 개발로 국제적이고 선도적인 연구의 교류

- 도시 재생 분야 적용을 위한 물리적, 사회적 데이터의 분석과 예측된 결과를 해석하기 위한 도시 계획 및 정책적 논의의 국제적 연구기관과 협력
- 도시 재생을 위한 포인트 클라우드 데이터 분석 방안 논의
- 포인트 클라우드 분석 기술에 따른 도시 계획 및 정책에 적용하는 방안 논의
- 영국과 유럽의 쇠퇴지역의 활발한 연구활동으로 인해 한국 지역의 연구 진행에 따른 연구 조언 및 협력으로 성공 가능성이 높음

- 쇠퇴지역 재생을 위한 기술 개발을 위해서 선도적인 도시 포인트 클라우드 빅데이터 연구 기관과 협력으로 도시 재생을 위한 실질적인 연구 성과와 기술 개발을 이룰 수 있음
- OECD 국가간의 공동지원 및 연구를 위한 기관과의 협력으로 국제 기준 및 도시재생에 필요한 요소의 검토 및 연구 협력 방안 추진
- 도시 환경의 주요 데이터를 기반한 도시 문제의 분석 및 해결 방안의 연구를 쇠퇴지역 위험성 분석과 도시재생에 있어 중요한 요소를 통합하는 연구 협력을 고려

붙임. 참고문헌

- ♦ Altun, M., & Celenk, M. (2017). Road scene content analysis for driver assistance and autonomous driving. *IEEE transactions on intelligent transportation systems*, 18(12), 3398-3407.
- ♦ Bishop, I. D. (2003). Assessment of visual qualities, impacts, and behaviours, in the landscape, by using measures of visibility. *Environment and Planning B: Planning and Design*, 30(5), 677-688.
- ♦ Chen, L., Sun, L., Yang, T., Fan, L., Huang, K. & Z. Xuanyuan, Z. (2017). RGBT SLAM: A flexible SLAM framework by combining appearance and thermal information,” in *Proc. IEEE Intl. Conf. on Robot. and Automat.*, May, 5682-5687.
- ♦ Dalton, R., & Dalton, N. (2015). The Problem of Representation of 3D Isovists. In *Proceedings of the 10th Space Syntax Symposium*, 141:1-141:18, London, UK:University College London.
- ♦ Dubey, A., Naik, N., Parikh, D., Raskar, R., & Hidalgo, C. A. (2016, October). Deep learning the city: Quantifying urban perception at a global scale. In *European conference on computer vision*, 196-212, Springer, Cham
- ♦ Kakao Maps, <https://map.kakao.com/>
- ♦ Lonergan, C., & Hedley, N. (2016). Unpacking isovists: A framework for 3D spatial visibility analysis. *Cartography and Geographic Information Science*, 43(2), 87-102.
- ♦ Naver Maps, <http://map.naver.com/>
- ♦ Qi, C. R., Su, H., Mo, K., & Guibas, L. J. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 652-660.
- ♦ Tsimhoni, O., & Green, P. (2001). Visual demand of driving and the execution of display-intensive in-vehicle tasks. In *Proceedings of the Human Factors and Ergonomics Society Annual Meeting*, 45(23), 1586-1590, October, Sage CA: Los Angeles, CA: SAGE Publications.
- ♦ Uy M. A., & Lee, G. H. (2018). PointNetVLAD: Deep Point Cloud Based Retrieval for Large-Scale Place Recognition, In *Proc. IEEE Conf. on Comput. Vision and Pattern Recog.*, 2018, In press.
- ♦ Yang, P. P. J., Putra, S. Y., & Li, W. (2007). Viewsphere: A GIS-based 3D visibility analysis for urban design evaluation. *Environment and Planning B: Planning and Design*, 34(6), 971-992.
- ♦ Zhang, J. & S. Singh, S. (2015). Visual-lidar odometry and mapping: Low-drift, robust, and fast, In *Proc. IEEE Intl. Conf. on Robot. and Automat.*, 2174-2181.

주 의

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