



# 보행교통사고 다발지역 예측을 위한 딥러닝의 적용 : 수도권 노인과 어린이 보행교통사고를 중심으로\*

## A Deep Learning Approach to Predict Elderly and Child Pedestrian Crash Hot Spots in the Seoul Metropolitan Area

전희정\*\* · 강승엽\*\*\* · 정수영\*\*\*\* · 김태완\*\*\*\*\* · 조철호\*\*\*\*\* · 주원영\*\*\*\*\* · 김지영\*\*\*\*\* · 하재필\*\*\*\*\*

Jun, Hee-Jung · Kang, Seungyeoup · Jung, Suyoung · Kim, Taewan · Cho, Cheol-Ho · Jhoo, Won Young · Kim, Ji Young · Heo, Jae-Pil

### Abstract

An efficient prediction of the pedestrian crash hot spots of the transportation disadvantaged is important for pedestrian-friendly environments and the promotion of sustainable development. This study aims to predict elderly and child pedestrian hot spots in the Seoul Metropolitan Area. For the empirical analysis, we used the traffic accident analysis system data and collected Google Street View images of elderly and child pedestrian crash hot spots and non-hot spots. Then, we conducted experiments using five deep learning models, including VGG16, VGG19, ResNet50, ResNet101, and InceptionV3. We also employed the CAM analysis to visualize the factors contributing to pedestrian crashes. The empirical analysis showed that the VGG16 model was the best model in predicting elderly and child pedestrian crash hot spots. In addition, the CAM analysis suggested that narrow widths of roads, physical facilities for transportation safety, and low openness were related to the pedestrian safety of the elderly and children.

**주제어** 보행교통사고, 딥러닝, 노인, 어린이

**Keywords** Pedestrian Crash, Deep Learning, The Elderly, Child

\* 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 ICT명품인재양성 사업의 연구결과로 수행되었음(IITP-2021-2020-0-01821).

\*\* Associate Professor, Department of Public Administration/Graduate School of Governance, Sungkyunkwan University (First Author: hjun@skku.edu)

\*\*\* Ph.D. Candidate, Graduate School of Governance, Sungkyunkwan University (Corresponding Author: kkangyoup@g.skku.edu)

\*\*\*\* Ph.D. Candidate, Graduate School of Governance, Sungkyunkwan University (syjung1228@skku.edu)

\*\*\*\*\* Ph.D. Candidate, Graduate School of Governance, Sungkyunkwan University (taewankim1202@gmail.com)

\*\*\*\*\* Masters Student, Department of Artificial Intelligence, Sungkyunkwan University (gersys@skku.edu)

\*\*\*\*\* Masters Student, Department of Artificial Intelligence, Sungkyunkwan University (jhoowy@skku.edu)

\*\*\*\*\* Undergraduate Student, Department of Software, Sungkyunkwan University (pitlover@skku.edu)

\*\*\*\*\* Assistant Professor, Department of Computer Science and Engineering/Department of Artificial Intelligence, Sungkyunkwan University (jaepilheo@skku.edu)



## I. 서론

### 1. 연구의 배경 및 목적

보행친화적인 도시는 지속가능성의 3대 요소인 환경보전, 경제개발, 사회적 형평성을 균형적으로 추구하여 지속가능한 개발로서의 도시계획을 가능하게 한다. 특히, 고령화와 저출산 시대를 맞고 있는 한국에서 전체 교통약자의 다수를 차지하는 노인과 어린이의 보행안전성 증진은 사회적 형평성의 관점에서 매우 중요한 과제라고 할 수 있다.

도시의 지속가능성 측면에서 노인과 어린이 보행안전성이 중요함에도 불구하고 한국에서 이들에 대한 보행안전성은 높지 않다. 2018년 기준 우리나라 보행교통사고 비율은 전체교통사고의 약 40%를 차지하여 OECD 평균보다 2배나 높다(도로교통공단, 2020). 또한, 14세 이하 어린이 인구 10만 명당 보행 중 사망자 수는 0.36명으로 OECD 회원국 평균 0.26명에 비해 약 1.4배, 65세 이상 노인 인구 10만 명당 보행 중 사망자 수는 OECD 회원국 중 가장 많은 11.4명으로 OECD 회원국 평균인 2.9명에 비해 4배나 높다(도로교통공단, 2020). 이러한 지표는 교통약자를 위한 더욱 효과적인 교통안전 정책이 추진되어야 하며, 보행교통 사고에 관한 지속적인 연구가 필요함을 의미한다.

한편, 보행안전을 위하여 보행교통사고를 유발하는 물리적 요인에 대한 다수의 연구가 지속해서 진행되어왔다(박준범·남궁미, 2019; 이수기 외, 2016; Kwon and Cho, 2020). 기존의 도시환경과 보행교통사고 간 연결성에 관한 다수의 연구들은 행정수 수준의 데이터를 사용한다는 점에서 보행교통사고를 유발하는 정확한 영향요인의 파악에는 한계가 존재한다. 또한, Google Street View(이하 GSV) 이미지와 같은 도로 이미지 자료를 기반으로 컴퓨터 비전과 딥러닝 기법을 적용한 연구들은 대부분 보행교통안전이 아닌 교통흐름에 중점을 두고 있다(Bustos et al., 2021). 또한, 유사한 방법론을 적용하여 보행환경을 분석한 논문들의 경우 개인이 인식하는 보행안전성과 같은 주관적 자료에 기반하고 있다(Kwon and Cho, 2020; Naik et al., 2014; 박근덕·이수기, 2018).

본 연구는 주요 교통약자로서 위험에 대한 인지나 신체 반응 능력이 상대적으로 떨어진다는 공통점을 가지는 노인과 어린이 집단을 대상으로 보행교통사고 다발지역을 예측하는 딥러닝 모델을 도출하는 것을 목적으로 한다. 보다 세부적으로 수도권 내 노인과 어린이 보행교통사고 다발 및 비다발지역을 구분하고, 객관적 자료로서 해당 지역의 GSV 이미지를 획득하여 컴퓨터 비전과 딥러닝 기법을 활용하여 보행교통사고 다발 지역과 비다발지역을 예측하는 모형을 구축하고 평가한다. 연구를 수행하기 위해서 도로교통공단에서 제공하는 실제 보행교통사고 다발지역 자료를 활용하였고 서울, 경기, 인천을 포함하는 수도권을 대상으로 분

석하였다. 또한, 노인과 어린이 보행교통사고를 유발하는 주요 객체를 시각화하기 위해서 Class Activation Map(이하 CAM) 분석을 실시하였다.

본 연구는 노인과 어린이를 대상으로 보행교통사고에 대한 기존의 선행연구와는 달리, 실제 보행교통사고 지역의 물리적 환경 자료를 바탕으로 예측력이 뛰어난 딥러닝 기법을 적용한다는 점에서 차별화된다. 더불어 사고 유발 주요 객체에 대한 분석을 제시하는 점에서 선행연구와는 차별화된 정책적 시사점을 제공할 것으로 판단된다. 이는 보행교통사고 다발가능 지역에 대한 효과적인 예측을 가능하게 함으로써 저출산 고령화 시대에 스마트도시 관리를 위한 정보를 제공할 것으로 기대된다.

## II. 이론적 논의

### 1. 노인과 어린이 보행교통사고와 영향요인

급격한 고령화와 저출산의 지속으로 고령자는 증가하고, 어린이는 감소하고 있으며 이로 인해 우리나라의 인구구조는 빠르게 변화하고 있다. 「교통약자의 이동편의 증진법」에 따르면 고령자와 어린이는 “교통약자”에 포함되며, 교통약자는 일상생활의 이동에서 불편을 느끼는 사람으로 정의한다(국가법령정보센터, 2021). 이러한 교통약자들은 이동상의 불편을 느낄 뿐만 아니라, 보행 시 교통사고에 노출될 가능성이 다른 그룹에 비하여 높게 나타난다.

노인의 경우 신체적인 노화와 다양한 기저질환, 인지 기능의 저하로 정상적인 보행이 어려울 수 있다(김경범, 2015; 박정호, 2017). 따라서 노인 그룹은 비노인 그룹에 비하여 보행 능력이 낮아 사고 발생 가능성이 있는 상황에서 빠르게 벗어나거나, 대응하기에 한계가 존재한다(김홍진·김홍순, 2004; 최재성 외, 2015). 또한, 연령이 높아질수록 무단횡단을 하려는 경향이 높게 나타난다(Mori and Mizohata, 1995; 최재성 외, 2015), 따라서, 사고의 가능성 역시 노인 그룹에서 높게 나타날 것을 예상할 수 있다. 어린이 그룹 또한 보행 시 교통사고 발생 가능성이나 안전에 대한 인지가 낮다는 특성이 있다(이세영·이제승, 2014). 어린이들의 경우 보행환경에 대한 집중도가 떨어지며 안전하게 보행하는 데 필요한 행동들을 동시에 할 수 없다(Whitebread and Neilson, 2000).

한편, 선행연구들에 따르면 보행 교통사고에 영향을 미치는 요인들은 근린환경, 교통 시스템 등 매우 다양한 요인으로 제시되고 있다. Haleem et al.(2015)는 연구에서 개인의 특성 요인 외 신호등이 없는 교차로, 어두운 거리, 높은 제한 속도 등의 도로의 물리적인 환경이 교통사고 영향요인으로 나타났다는 결과를 제시하고 있다. Brosseau et al.(2013)의 연구에서는 보행자 신호가 없을 경우, 보행신호의 시간보다 실제 횡단에 걸리는 시간이



길다면 거리 중간에서 차량의 통행이 시작되어 교통사고에 노출될 가능성이 커질 수 있다는 것을 제시했다. 이러한 결과는 윤준호·이수기(2018)의 연구에서 무단횡단을 쉽게 할 수 있는 환경일수록 교통사고의 심각도가 높게 나타난다는 연구결과와 결을 같이한다고 볼 수 있다. 따라서 보행자 신호와 같은 교통 시스템의 체계적인 설계가 보행자의 안전을 향상할 수 있는 주요 요인임을 시사하였다.

한편, Leden et al.(2006)의 연구에서는 스웨덴의 어린이와 노인보행자의 안전을 향상시키기 위해서 도로 환경의 가시성(visibility), 방향성(orientation), 명확성(clarity)을 높이고 속도 제한, 적절한 거리의 방지턱 설치를 통한 운전자들의 보행자에 대한 양보 가능성을 높여야 한다는 것을 제시하였다. 보행자의 안전성을 위한 물리적 도로환경은 국내외 선행연구를 통해서도 파악할 수 있다. 초등학교 주변을 대상으로 물리적 환경이 보행 안전에 미치는 영향을 분석한 박경훈·변지혜(2012)의 연구에서는 보도 위 장애물, 차량의 진·출입 개수, 도로 면적률 등이 보행 안전도의 영향을 미치는 요인으로 분석되었다. 서지민·이수기(2016)의 연구에서는 횡단보도의 밀도가 보행자 교통사고와 정(+)의 관계, 과속방지턱 밀도는 보행자 교통사고와 음(-)의 관계를 보이는 것으로 나타났다. 고동원·박승훈(2019)의 연구에서는 보행자와 운전자의 특성, 사고 유형 등의 개별적 특성과 더불어 교차로, 횡단보도, 신호등 등의 교통 시설물과 어린이 보호구역 여부 등의 근린환경 특성이 보행자 교통사고 심각도의 영향요인으로 분석되었다. 해당 연구결과들은 도로시설물도 형태에 따라 보행자의 교통사고에 다른 영향을 미칠 수 있음을 의미한다.

반면, Ewing and Dumbaugh(2009)의 연구에서는 교통 밀도가 높고, 도로 폭이 좁으며 주변에 장애물로 인하여 개방감이 낮은 곳에서 치명적인 교통사고가 적게 발생하는 결과를 제시했다. 해당 조건에 부합하는 도로 환경일수록 운전자는 차량 운행에 더욱 주의를 기울이며 운전을 하기 때문이다. 이 결과는 고밀도 개발과 토지의 복합용도 활용이 동네의 활력을 올리며 보행 친화적인 근린환경을 만들 수 있다는 Jacobs(1961)의 주장과도 결을 같이한다. 기존 연구들을 통해 고령자와 어린이 그룹에 대한 논의를 살펴보았을 때, 고령자나 어린이와 같은 교통약자 그룹의 경우 성인 그룹에 비하여 위험에 대한 인지나 신체 반응 능력이 상대적으로 떨어진다는 공통점이 존재하여 비슷한 요인들이 두 그룹의 보행 교통사고에 영향을 미칠 것을 예상할 수 있다. 동시에 다른 성인 그룹에 비하여 노인과 어린이 보행 교통사고 영향요인은 다를 수 있음을 시사한다(이세영·이제승, 2014). 예를 들어, 박준태 외(2010)의 연구에서 고령자 보행자 사고 심각도에 미치는 영향요인으로 차량 속도가 가장 크게 나타났으며, 비고령 보행자는 도로의 종류가 가장 큰 영향요인으로 나타났다. Brosseau et al.(2013)의 연구에서는 신호등이 있는 곳에서 보행자의 대기 시간이 길면 보행자들이 신호를 위반하고 위험한 횡단을 할 가능

성이 높음을 제시했다. 이는 앞서 논의한 것처럼 노인보행자 그룹에서 연령이 많을수록 무단횡단을 하려는 경향이 높아지므로 사고에 노출될 가능성이 크다. 어린이 그룹에서는 교통환경에 대한 집중도나 이해도가 낮음으로 위험에 대한 인지 없이 움직일 가능성이 있기에 사고 노출 가능성이 크게 나타날 것을 예상할 수 있다.

## 2. 스마트 보행교통환경 구축을 위한 딥러닝의 적용

기존 보행교통사고에 관한 선행연구들은 지역수준의 평균 데이터를 사용하여 보행교통사고 유발에 관한 연구를 진행함으로써 정확한 영향요인의 파악에는 한계가 존재한다. 특히, 상대적으로 넓은 지역을 포괄한 행정동 수준에서의 보행교통사고 분석은 정확한 요인 파악이 어렵다. 본 연구는 기존의 선행연구들이 가지고 있는 연구분석의 단위가 가질 수 있는 한계점을 극복하였다는 점에서 의미가 있다.

한편, 스마트 도시는 급속하게 발전한 기술을 활용하여 기존에 해결하기 어려웠던 도시문제들을 효율적으로 해결할 수 있는 대안으로 떠오르고 있다. 특히, 효율적인 도시계획을 위해서 교통 분야에서 빅데이터의 활용이 활발하게 이루어지고 있는데 최근 교통사고를 분석하기 위한 방안으로 딥러닝 기법이 주목받고 있다(Najafabadi et al., 2015). 딥러닝(Deep learning) 기법은 다양한 비선형 변환기법의 조합을 바탕으로 다량의 데이터 혹은 복잡한 자료 내 핵심적인 기능 및 내용을 요약할 시도하는 기계학습(machine learning)의 알고리즘의 합으로 정의된다(김윤진, 2017). 딥러닝 기법은 무엇보다 대규모 데이터를 빠르고 효과적으로 학습함과 동시에 다양한 사례에 대한 최적화 신경망 구조를 변형·개선한다는 장점이 있다. 이러한 장점에도 불구하고 현재까지 물리적 환경분석과 관련성을 분석한 연구는 포아송 회귀, 음이항 회귀 등과 같은 전통적인 통계 방법을 기반으로 진행되고 있다(이수범 외, 2003; 이근희·노정현, 2015; 강동운, 2014; 서임기 외, 2015; Lu et al., 2013; Cafiso et al., 2013). 전통적 통계 기법을 활용한 기존 선행연구들의 경우, 개념적 틀을 바탕으로 물리적 환경과 보행교통사고와의 영향 관계 규명을 위한 유의미한 결과를 일부 도출할 수 있다. 그러나 정량적 분석의 진행을 위해서는 관련 데이터의 재가공이 필요하며, 넓은 공간적 범위에 대한 분석결과 적용과 도로를 이용하는 이용자의 인식을 변수로 활용하는 등의 측면에서 일반화에 대한 일부 한계가 존재한다(류종득, 2018).

방법론적 한계를 극복하고, 정형 데이터 중심의 분석에 벗어나 비정형 데이터를 포함한 딥러닝 기법을 적용하여 분석의 정확도를 높이기 위한 연구가 진행되고 있다(Huang et al., 2016; Talebi and Milanfar, 2018; 오주택 외, 2014). 딥러닝은 영상 객체 인식, 음성 인식, 자율 주행, 로봇공학, 자연어처리 등 다양



한 분야에서 활용되고 있다. 딥러닝은 현재 인간이 겪은 다양한 문제들을 해결하고 있으며, 최근 들어서 빅데이터 활용 및 분석 기술, 컴퓨터 하드웨어의 발전과 시너지를 이루며 발전하고 있다. 이들은 이미지 데이터를 중심으로 도시 내 물리적 환경에 대한 분석을 시도하였다. 해당 연구는 분석에 활용될 데이터의 확장 가능성을 높였다는 점에서 연구의 의의가 있으나, 학습하는 데이터의 변이(variation)에 따라 정확도가 상이하게 나타날 수 있다는 점이 존재한다.

한편, 비정형의 이미지 데이터를 활용한 보행교통안전에 대한 국내 연구 또한 활발하게 진행 중이다. 박근덕·이수기(2018)는 가로공간에서 보행 만족도 예측을 위해서 GSV 이미지를 딥러닝 모형에 적용하여 분석을 진행하였으며, Kwon and Cho(2020)의 경우 또한 Naver Street View 이미지를 활용하여 가로공간에 대한 이미지에서 각각의 부분이 차지하는 비율에 대한 Segmentation 기법을 활용하여 지각된 도로의 안전성과의 관계를 파악하였다. 이러한 연구들은 비정형 데이터 혹은 빅데이터를 활용한 측면에서 도시의 교통과 관련된 문제의 해결에 빅데이터 기법을 활용한다는 의의가 있다. 하지만, 설문조사에 기반하여 인간의 주관적 인식이 포함된 보행만족도 및 안전성 결과와 연결하여 분석한다는 점에서 한계가 있다. 이에 실제 보행교통사고가 다수 일어난 지역을 구분하고 이를 객관적 자료로써 활용하여 이에 대한 도로 이미지를 구축하고 컴퓨터 비전과 딥러닝 기법을 적용한다면 보다 효율적인 스마트 도시관리 방안을 도출할 수 있다.

### III. 연구설계

#### 1. 연구자료 및 범위

주요 연구자료는 도로교통공단에서 제공하는 2012년부터 2018년까지의 보행교통사고 다발지역 자료이다. 해당 자료는 전국적으로 10,365곳의 보행교통사고 다발지역 정보를 포함하고 있으며, 보행교통사고 다발지역을 보행 노인사고, 보행 어린이사고, 스쿨존 어린이사고, 무단횡단 사고, 자전거 사고의 유형으로 구분하고 있다. 또한, 각각의 교통사고 다발지역에 대한 위치 정보와 사고 발생 건수, 사상자, 사망자, 중상자, 경상자, 부상자 수를 포함하고 있다.

본 연구는 노인과 어린이 보행교통사고 다발지역에 대한 예측 모형을 구축하고 검증하기 위해서 보행교통사고 다발지역 자료 중 보행 노인, 보행 어린이, 스쿨존어린이 사고에 대한 정보를 활용하였다. 도로교통공단의 보행교통사고 다발지역의 정의에 따르면, 보행 노인사고 다발지역의 경우 65세 이상의 노인보행자가 다치거나 사망한 교통사고 지점 200m 이내에 대상 사고가 3건 이상(사망사고 발생 시 2건) 발생한 지역이다. 보행 어린이 사고 다발지역의 경우 12세 이하 어린이 보행자가 다치거나 사망한 교

통사고로서 교통사고 지점 200m 이내에 대상 사고가 3건 이상 발생지역(사망사고 발생 시 2건)이며, 스쿨존 어린이 사고다발지역의 경우 스쿨존 내에서 12세 이하 어린이 보행교통사고가 2건 이상 또는 사망사고가 발생한 지역이다.

공간적 범위는 서울, 인천, 경기를 포함한 수도권 지역이며 수도권 지역 내 보행 노인사고, 보행 어린이 사고, 스쿨존 어린이사고 다발지역은 총 1,469곳(서울 830, 경기·인천 639)이다. 수도권 지역에 한정하여 분석하는 것은 전국 보행교통사고 다발지역의 약 49%를 차지하는 보행교통사고 밀집지역일 뿐만 아니라 수도권과 비수도권 간 밀도 등의 건조환경(built environment)의 차이로 나타나는 교통환경의 지역 간 차이를 최소화할 수 있기 때문이다.

보행교통사고 다발지역을 예측하는 딥러닝 모형의 적용 시 보행교통사고 비다발지역의 자료 또한 필요하다. 이를 위하여 보행교통사고 비다발지역과 GSV 사진은 보행교통사고 다발지역 인근지역 대한 좌표들 중 무작위 추출을 통해 비다발지역을 선택하였다. 보행교통사고 다발지역 인근 지역에서 비다발지역 GSV 사진 자료를 수집한 이유는 다음과 같다. 교통사고 발생빈도나 안전 정도를 예측하고 추정하는 연구의 경우 연평균 일일 교통량(AADT)이나 도로의 다양한 설계요소 등을 변수를 통해서 판단한다(류종득, 2018). 이때, 차로의 수, 도로 폭, 교통량, 주변 토지 이용 등과 부분이 교통사고 다발지역과 환경적 측면에서 많은 차이가 나는 지역의 경우 이는 교통환경의 차이가 아니라 지역 간 차이로 인해 나타나는 결과로서 본 연구에서 추구하는 목적의 엄밀성을 낮춘다고 판단하였다. 따라서, 보행교통사고 다발지역 인근 지역에서 보행교통사고 비다발지역 도로 이미지를 수집하는 것이 정확한 모형을 구축하는 것에 적합하다고 판단하였다.

한편, 본 연구에서 보행교통사고 다발지역 데이터는 2012~2018년 사이의 자료이며, 2020년 9월에 GSV 사진을 수집하였다. GSV 이미지의 경우 비정기적으로 지속적인 이미지의 업데이트가 진행되지만, 보행교통사고 다발지역으로 규정된 시점과 동일한 시점을 일치시켜 이미지를 구축할 수 없다는 한계가 존재한다. 이에 2019년 서비스 이용자에게 제공되는 최신의 이미지를 수집하였고 수집된 GSV는 대체로 2015년부터 2020년 사이에 업로드된 이미지이다. 즉, 노인과 어린이 보행교통사고 다발지역에서 환경과 GSV가 수집된 시점 간 차이로 인한 보행환경의 변화가 존재할 수 있다. 이러한 한계점에도 불구하고, 본 연구는 비수도권 지역에 비해 개발이 상대적으로 많이 이루어진 수도권 지역을 선정하여 노인과 어린이 보행교통사고 다발지역으로 규정된 시점과 GSV 이미지 자료가 업로드된 시점 간 차이를 최소화하고자 하였다. 이 외에도 본 연구는 한 시점에 발생한 개별적인 보행교통사고가 이루어진 지역을 분석하는 것이 아닌 장기간에 걸쳐 보행교통사고가 다발적으로 이루어진 지역을 분석하기 때문에 보행교통사고 시점 차이로 인한 환경변화를 최소화할 수 있다.

결론적으로 분석에 활용한 총장소는 3,411곳으로 보행교통사



고 다발지역 1,469곳(서울 930, 경기·인천 739)과 비다발지역 1,542곳(서울 910, 경기·인천 832)을 포함한다. 이때 딥러닝 기법의 적용을 위해 필요한 학습데이터와 테스트 데이터 간 비율은 각각 90%와 10%이다. <표 1>은 본 연구의 노인과 어린이 보행교통사고 다발지역과 비다발지역의 표본에 관한 내용이며, 학습자료와 테스트자료를 구분하여 정리한 표이다.

한편, 보행교통사고 다발/비다발지역의 사진 자료는 전체 3,411곳의 위치 정보를 바탕으로 GSV API key를 활용하여 해당 지점의 사진을 수집하였다. GSV에서 제공하는 사진의 경우 360°의 파노라마 형태로 사진이 제공된다. 따라서, 90° 단위로 나누어 한 장소당 4장의 사진을 수집하였으며, 그 결과 수집된 전체 사진 13,644장을 분석에 활용하였다. 수집된 사진들은 600x300의 크기며, 위치(location), 수평각(heading)과 수직 각도(pitch)의 파라미터를 입력하여 이미지를 수집하였다. 다음의 <그림 1>은 본 연구에서 수집된 지역의 이미지 예시이다.

수집된 이미지의 경우 한 장소의 360° 파노라마 전체 이미지에 대한 특징을 추출해서 분석하는 Concat 방식과 한 장소에 한 장의 이미지를 활용하는 Non-Concat의 방식이 있다. 본 연구에서는 도로 환경의 모든 부분의 특징을 고려하기 위하여 4장의 이미지를 모두 활용하는 Concat 방식의 적용을 통해서 모델의 학습과 검증을 하였다. 해당 방법을 적용할 경우 각각의 이미지에 대한 특징을 모두 추출한 뒤 이를 취합한 다음 분류하는 형태로서 도로 환경의 더욱 많은 정보를 포함할 수 있다. 다음의 <그림 2>는 본 연구에서 Concat 형태 분석의 원리의 도식화 자료이다.



그림 1. GSV 360° 파노라마 뷰 예시  
Figure 1. Example of GSV 360° panoramic view

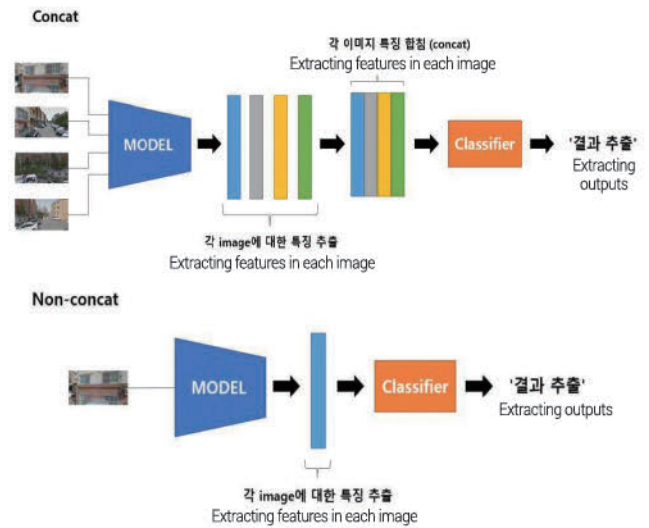


그림 2. Concat/non-concat 구조  
Figure 2. Concat/non-concat structure

## 2. 딥러닝 모형의 적용

본 연구에서 사용된 딥러닝은 합성곱신경망 네트워크(Convolutional Neural Network, CNN) 구조의 형태로서 학습에 사용한 모델은 ResNet50, ResNet101, VGG16, VGG19, InceptionV3이다(He et al., 2016; Jaderberg et al., 2016; Szegedy et al., 2015; LeCun et al., 1998). 이때 모델별로 수도권 내 서울과 경기/인천 지역을 구분하여 노인과 어린이 보행교통사고 다발 및 비다발지역의 데이터에 대한 성능을 측정하였다.

CNN은 음성, 이미지, 텍스트 등 다양한 분야에서 활용되는데 최초의 CNN 모델인 Lenet은 1998년에 LeCun에 의해 제시되었다(LeCun et al., 1998). 기존의 Deep Neural Network(DNN)은 구조상 1차원 데이터만을 수용할 수 있다. 이미지 데이터와 같은 2차원 이상의 데이터는 평면화(flatten)시켜야 한다는 문제가 있었다. 이러한 방식은 이미지 데이터의 지역적, 공간적 정보 손실을 주고, 모델의 정확도를 낮추게 된다. CNN은 DNN의 이러한 문제점을 해결하기 위해 등장하였으며, 2D 형태의 이미지 데

표 1. 수도권 노인과 어린이 보행교통사고 다발지역과 비다발지역의 테스트와 트레이닝 핫스팟 지역의 수  
Table 1. Number of elderly and child pedestrian crash hot spots and non-hot spots

Division	Train data		Test data		Total
	Hot spot	Non-hot spot	Hot spot	Non-hot spot	
Seoul	830	810	100	100	1,840
Gyeonggi·Incheon	639	732	100	100	1,571
Subtotal	1,469	1,542	200	200	
Total	3,011		400		3,411
Total image	3,011×4=12,044		400×4=1,600		3,411×4=13,644

Unit: spot



이터 차원을 바꾸지 않고 그대로 사용하여 이미지의 공간정보를 유지한다는 장점이 있다. CNN은 국소 영역의 특징을 추출하는 필터(filter)를 사용하는데, 이러한 방식의 활용으로 이미지 분류(classification) 문제에서 뛰어난 성능을 거두게 되었다.

CNN의 구조는 Conv레이어(convolutional layer), Relu레이어, Pooling레이어로 구성되는데 Conv레이어와 Pooling레이어는 이미지의 특징을 추출하는 데 이용된다. Conv레이어에서 사용되는 필터는 이미지의 입력 픽셀값을 특정 범위만큼 전체적으로 훑어가며 이미지의 특징을 추출하고 이 과정에서 입력 이미지와 필터 사이에 합성곱을 계산하며 결과적으로 피쳐맵(feature map)을 생성한다. Pooling레이어의 경우 Conv레이어의 출력값인 피쳐맵에서 좀 더 유의미한 이미지의 특징을 추출하는 역할을 한다. Pooling레이어의 종류로는 max pooling, average pooling, min pooling 등이 있으며 피쳐맵의 특정 영역 안에서의 각각 최댓값, 평균값, 최솟값을 대푯값을 선정하여 최종 피쳐맵을 결정한다. Relu레이어는 활성화 함수(activation function)의 한 종류로서 Conv레이어와 Pooling레이어 사이에 위치한다. 이는 CNN을 비선형 모델로 구성하는 역할을 하며, 이를 통해 선형 모델로는 풀기 힘든 문제를 풀 수 있게 된다. <그림 3>은 본 연구에서 활용한 CNN 모형의 도식화 자료이다.

본 연구에서는 이미지 분류에 있어 대표적인 딥러닝 모델인 VGG16, VGG19, Resnet-50, Resnet-101, InceptionV3 모델을 사용하였다. 이 모델들은 이미지 인식 및 분류 알고리즘의 성능을 평가하는 대회인 Imagenet Large Scale Visual Recognition Competition(ILSVRC)에서 모두 우수한 성능을 보인 모델이다. VGG 모델은 옥스퍼드 Visual Geometry Group에서 개발한 모델로, 2014년 ILSVRC 대회에서 근소한 차이로 2위를 차지하였다(He et al., 2016).

VGG16은 구조가 간단하여 학습 파라미터의 개수가 적기 때문에 학습 속도가 빠르다는 장점이 있다. Resnet은 2015년 ILSVRC 대회에서 1위를 차지한 모델이다(Simonyan and Zisserman, 2014). Resnet은 마이크로소프트에서 개발한 모델로, 기본적인 구조는 VGG와 비슷하다. 당시 딥러닝 모델의 깊이가 깊어질수록 모델의 학습이 어렵다는 단점이 존재했는데, 레이어의 입력을 레이어의 출력에 직접 더하는 residual block을 활용하여




그림 3. CNN 구조 모형  
Figure 3. CNN Structure

이러한 문제를 해결한 것이 특징이다. 때문에 Resnet-50과 Resnet-101은 이전 모델에 비해 상대적으로 깊은 각각 50개, 101개의 계층으로 구성된다. InceptionV3 모델은 GoogLeNet으로 많이 알려진 모델이다. 일반적인 CNN 모델은 필터의 크기가 하나로 고정되어 있고 따라서 이미지의 특징을 추출하는 영역의 크기 또한 하나로 고정되어 있는 단점이 있었다(Szegedy et al., 2015). 이러한 부분을 해결하기 위해서 Inception 모델은 서로 다른 크기의 필터를 함께 사용하여 이미지의 특징을 추출하며, 이를 통해 모델 성능을 향상시켰다.

본 연구에서는 이와 같은 모델들을 모두 적용하여 교통사고 다발지역 분류모델을 만들었으며 각 모델의 성능을 비교하여 가장 적합한 모델을 선정하였다. 선정된 모델들은 본 연구에서 교통사고 '다발(positive)'과 '비다발(negative)' 두 가지의 사고 유형으로 판단하는 성능의 검토가 필요하다. 일반적으로 이러한 분류의 성능을 검증하기 위해서는 Confusion matrix를 통해서 모형의 성능을 평가한다(Muller and Guido, 2016). 다음의 <표 2>는 본 연구에서 보행교통사고 다발과 비다발지역을 구분하기 위한 Confusion matrix의 예측값과 실재값을 요약한 표이다.

true positive(TP)의 경우 실제 보행교통사고 다발지역을 다발지역이라고 정확하게 분류하는 경우이고, true negative(TN)의 경우 실제 비다발지역을 비다발지역이라고 예측하는 경우이다. 반면, false positive(FP)의 경우 실제 비다발지역을 다발지역이라고 예측하는 것이며, false negative(FN)의 경우 실제 다발지역을 비다발지역이라고 예측하는 경우를 의미한다.

Confusion matrix를 바탕으로 모델의 성능을 평가하는 대표적인 방법으로 정밀도(precision), 재현율(recall), 정확도(accuracy), F1-Score 방법을 적용할 수 있다. 정확도(accuracy)는 가장 기본적으로 모델의 성능을 평가하는 방법으로, 전체 데이터 가운데 정확하게 분류된 데이터의 비율을 의미하는 형태로서 직관적으로 모델의 성능을 나타낼 수 있다(Muller and Guido, 2016). 다음의 수식 1은 정확도를 산출하는 공식이다.

$$Accuracy = \frac{TP + TN}{TP + FN + FP + TN} \tag{1}$$

수식 2는 정밀도를 산출하는 식이다. 정밀도(precision)는 다발지역으로 예측한 경우의 수(TP+FP)에서 실제 다발지역(TP)을 맞춘 비율을 나타내는 지표로서 다발지역의 경우만을 고려해 정

표 2. 컨퓨전 매트릭스

Table 2. Confusion matrix

Division	Actual Class	
	True	False
Predicted class	True	False
	True positive (TP)	False positive (FP)
	False negative (FN)	True negative (TN)



확도를 판단하므로 테스트 데이터의 구성에 관계없이 다발지역에 대한 정확도를 계산할 수 있다.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

재현율(recall)의 경우 실제 다발지역의 샘플(TP+FP) 가운데 모델이 다발지역(TP)이라고 찾아낸 비율을 의미하는 것이다. 다음의 수식 3은 재현율(recall)의 산출식이다.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

F1-Score의 경우 앞서 설명된 정밀도(precision)와 재현율(recall)의 조화평균으로서 정밀도의 값과 재현율은 서로 반비례의 관계를 가짐으로써 두 값이 적절하게 균형을 이루는 모델이 가장 적절한 모델이라고 할 수 있으며, 이때 F1-Score를 활용한다. 다음의 수식 4는 F1-Score의 산출식이다.

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

### 3. Class Activation Map (CAM) 분석

CNN 구조의 딥러닝 모형의 경우 모델의 성능에 관한 결과가 수치로 제시된다는 한계점이 존재한다. 따라서, 이러한 분류모델의 한계를 극복하기 위해서 분석결과 시각화를 위해서 CAM의 알고리즘을 분석결과에 적용하였다. 해당 방법은 모델이 예측 결과를 도출하는 데 있어, 이미지의 각 영역이 어느 정도의 영향을 주었는지 분석하는 기법이다. 일반적으로 분류를 수행하는 딥러닝의 경우 마지막 연결층(fully connected layer)을 통해서 최종결과를 제시하는데, 본 연구에서도 활용한 CNN 구조의 모형에서 다층의 레이어가 이미지의 어떠한 특성을 통해서 실제 교통사고 지역을 분류하는지를 조합하여 이를 시각적으로 표현하고자 한다. <그림 4>는 CAM 방식에 대한 시각화 자료이다.

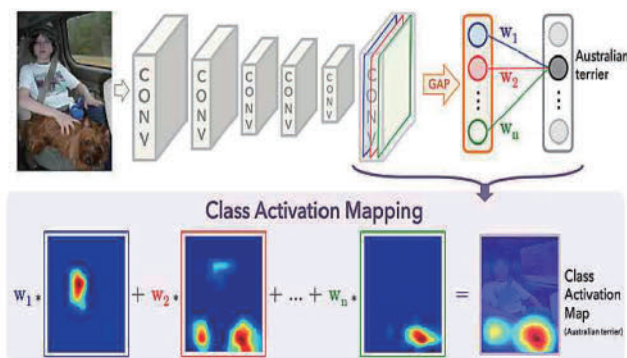


그림 4. Class Activation Map 구조  
Figure 4. CAM Structure

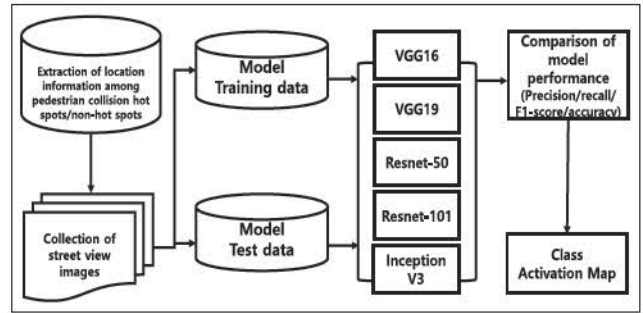


그림 5. 연구분석의 방법 및 과정  
Figure 5. Research Framework

<그림 5>는 본 연구의 분석틀을 도식화한 것이다. 우선 보행교통사고 다발지역 자료를 바탕으로 수도권 지역의 교통사고 다발지역을 선정하고 이를 바탕으로 비다발지역 위치 정보를 구성한다. 구성된 정보가 가지고 있는 위치 정보를 바탕으로 구글 스트리트 뷰 API를 활용하여 교통사고 다발지역과 비다발지역에 대한 이미지를 수집한다. 수집한 이미지에 대해서 학습용 데이터와 모델 검증데이터를 9:1 비율로 구분하여 총 5개의 모델에 대한 학습을 한 뒤 각각의 모델별로 교통사고 다발지역과 비다발지역 분류 모형 성능을 비교한다. 마지막으로 분류된 모델의 이미지에서 어떠한 측면의 부분을 다발지역과 비다발지역으로 구분하는지에 대해 CAM을 통해 확인한다.

이상의 연구설계 내용들을 바탕으로 실제 분석이 실시된 환경은 Ubuntu 18.04.5 LTS 운영체제를 바탕으로 Python 3.8.2 버전과 PyTorch 1.7.0의 프로그램에서 분석환경을 설정하고 분석하였으며, 이때 가용된 GPU 자원은 GeForce GTX 1080이다.

## IV. 분석결과

### 1. 보행교통사고 다발/비다발지역 예측모델 성능 검증

보행교통사고 다발지역과 비다발지역 이미지를 딥러닝 모형을 적용하여 서울, 경기/인천, 수도권 전체 지역의 보행교통사고 다발/비다발지역의 이미지 분류 모형의 성능을 검증하였다. 3,011곳의 12,044장의 이미지를 학습을 위한 데이터(training data)로 사용하였으며, 이중 다발지역은 1,469곳(이미지 5,876장)이며, 비다발지역은 1,542곳(이미지 6,168장)이다. 성능 평가를 위해서 활용한 검증 데이터(test data) 지역은 총 400곳으로 다발지역 200곳(이미지 800장), 비다발지역 200곳(이미지 800장)이다.

다음의 <표 3>과 <표 4>는 앞서 설명된 Confusion matrix를 기반으로 모델의 성능을 평가하는 지표들의 결과이다.

먼저, <표 3>의 경우 보행교통사고 다발지역과 비다발지역에 대한 모델별 정밀도(precision)와 재현율(recall), F1-Score의 값이다. 앞서 기술한 것과 같이 F1-Score의 경우 정밀도와 재현율의 산술평균값으로 해당 값을 바탕으로 모델의 성능을 평가해



표 3. 노인과 어린이 보행교통사고 다발지역 예측모델 정밀도, 재현율, F1-Score

Table 3. Precision, recall, and F1-score

Model	Area	Precision	Recall	F1-score
VGG 16	SE	74.49	89.02	81.11
	G-I	61.16	79.57	69.16
	CR	67.12	84.00	74.62
ResNet 50	SE	77.22	74.39	75.78
	G-I	63.11	69.89	66.33
	CR	69.23	72.00	70.59
ResNet 101	SE	68.57	87.80	77.01
	G-I	61.72	84.95	71.49
	CR	64.81	86.29	74.02
VGG 19	SE	77.94	64.63	70.67
	G-I	65.38	54.84	59.65
	CR	71.23	59.43	64.80
Inception V3	SE	69.64	47.56	56.52
	G-I	55.06	52.69	53.85
	CR	60.69	50.29	55.00

SE: Seoul, G-I: Gyeonggi-Incheon, CR: Capital Region

표 4. 노인과 어린이 보행교통사고 다발/비다발지역 예측모델 정확도 비교

Table 4. Accuracy comparison among models of the elderly and children pedestrian crash hot spots

Model	Area	Hot spot (%)	Non-hot spot (%)	Average (%)
VGG 16	SE	89.02	69.14	79.9
	G-I	79.57	52.53	66.2
	CR	84.30	60.84	73.0
ResNet 50	SE	74.39	77.78	76.0
	G-I	69.89	61.62	65.8
	CR	72.14	69.70	70.9
ResNet 101	SE	87.80	59.26	74.6
	G-I	84.95	50.51	67.9
	CR	86.38	54.89	71.3
VGG 19	SE	64.63	81.48	72.4
	G-I	54.84	72.73	63.7
	CR	59.74	77.11	68.1
Inception V3	SE	47.56	79.01	62.1
	G-I	52.69	59.60	56.1
	CR	50.13	69.31	59.1

SE: Seoul, G-I: Gyeonggi-Incheon, CR: Capital region

보면 VGG16 모델에서 가장 높은 성능을 나타내는 것으로 나타났다. 서울지역의 경우 보행교통사고 다발지역을 맞게 예측하는 경우는 약 81.11%로 나타났다. 하지만, 해당 결괏값은 다발지역

(positive)만을 기준으로 모델의 성능을 판단하는 한계점이 존재한다. 따라서 이를 위해 정확도(accuracy)를 통해서 성능을 추가적으로 판단하였다. ResNet50, ResNet101, VGG16, VGG19, InceptionV3 모델별로 서울, 경기/인천, 수도권 지역을 구분하여 정확도(accuracy)를 통한 모델의 성능 평가결과 다음의 <표 4>와 같은 결과가 도출되었다.

본 연구에서 사용된 학습 모델은 성능검증 결과 전체 지역에서 가장 높은 분류 성능을 보인 모델은 정확도(accuracy)기준 73.03%의 정확도를 기록한 VGG16 모델이다. 해당 모델은 모든 지역에서 가장 높은 수준의 예측력을 나타냈다.

특히, 서울지역의 경우 다발지역과 비다발지역 분류에 있어서 다발지역의 경우 89.02%, 비다발지역 69.14% 수준의 정확도를 나타내며, 평균 약 79.9% 예측력을 나타냈다. 기타 모델의 성능 테스트 결과를 살펴보면 ResNet101 71.29%, ResNet50 70.88%, VGG19 68.05%, InceptionV3 59.09%의 순서로 예측력의 결과가 나타났다.

VGG16 모델의 정확도 결과를 바탕으로 해당 수치가 의미하는 것을 정리하면 다음과 같다. 서울지역의 경우 보행 교통사고 다발지역 10곳 가운데 약 8.9곳의 지역을 보행교통사고 다발지역으로 맞게 예측하는 수치이며, 비다발지역의 경우 10곳 가운데 약 7곳을 비다발지역으로 맞게 예측하는 결과이다. 평균적으로 해당 모델에 100장의 이미지를 제시할 때 분류된 이미지의 정확도가 평균 79.9%이 정확도를 나타냄으로 약 80장의 이미지를 보행교통사고 다발/비다발지역으로 구분하는 것이다.

## 2. 보행교통사고 다발/비다발지역에 대한 CAM 분석결과

보행교통사고 다발/비다발지역 예측결과는 보행교통 사고 다발 지역과 비다발지역을 구분하는 정도를 수치로만 나타낸다는 측면에서 결과의 명확한 이해에 한계점을 가진다. 따라서, 이러한 한계를 보완하기 위하여 CAM 분석을 실시했다. CAM 분석에서는 앞서 모델들 가운데 ResNet 101의 결과를 바탕으로 분석을 진행하였다. VGG16 모델의 경우 직렬형 구조모델인데, 이를 CAM 분석을 진행하기 위해서 수정할 경우 VGG 모델의 본래의 성격을 상실하게 되며, 기존의 예측력이 변화되는 기술적 문제가 존재한다. 따라서, 병렬적 모형 형태를 가지고 있으며, CAM 분석을 실시할 때 기존 모델의 구조를 수정하지 않아도 분석이 가능한 ResNet101 모델의 결과를 바탕으로 분석을 진행하였다. 다음의 <그림 6>은 CAM 분석결과의 일부이다.

<그림 6>의 사진에서 빨갭게 표시된 부분의 농도가 짙을 때 주의(attention)가 많이 가해진 부분이다. 즉, 학습된 모델을 바탕으로 테스트 데이터를 검증할 때 어떤 부분에 중점적으로 초점을 두고 해당 지역을 보행교통사고 다발지역과 비다발지역으로 구분하는지를 시각적으로 표출한 결과이다.



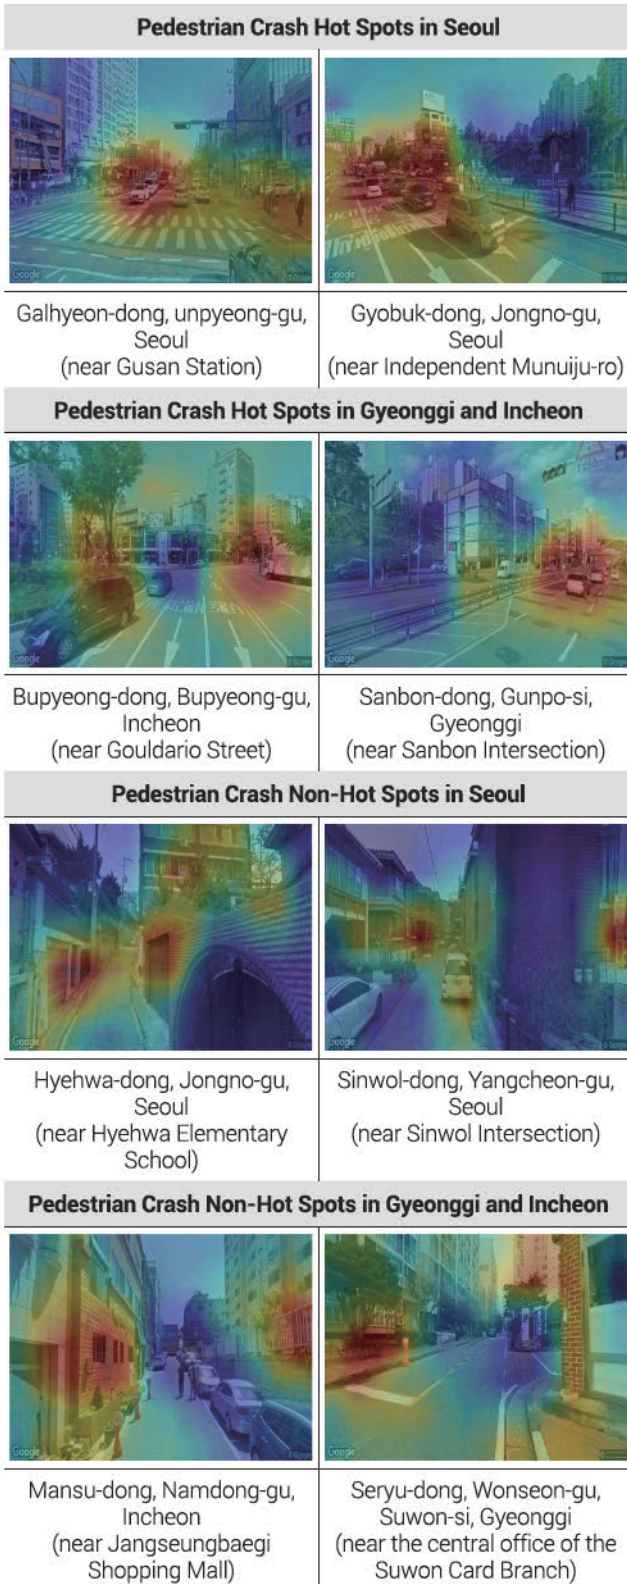


그림 6. 노인과 어린이 보행교통사고 다발/비다발지역 CAM 결과  
Figure 6. CAM Results

사진들을 바탕으로 보행교통사고 다발지역과 비다발지역을 판단해보면 다음과 같은 특징을 정리할 수 있다. 첫째, 보행교통사고 다발지역의 경우 도로의 환경에 있어 비다발지역보다 도로의 폭이 상대적으로 넓은 지역의 경우 보행교통사고 다발지역으로

예측하는 것으로 나타났다.

또한, 도로의 개방감 측면에서 시야가 넓은 지역일수록 교통사고 다발지역으로 인식하는 것으로 나타났다. 도로상에 존재하는 구조물과 사물의 측면에서 볼 때, 교통사고 다발 지역의 경우 차량에 많은 초점이 맞춰지고 있으며, 일부의 결과에서는 인도나 혹은 도로 위에 존재하는 교통 관련 시설물 부분에 주의가 집중되어 있다.

반면, 보행교통사고 비다발지역의 경우 다발지역과 달리 도로의 폭이 좁은 경우 다수의 지역에서 보행교통사고 비다발지역으로 예측하는 것으로 나타났다. 즉, 도로가 협소할 경우 교통사고가 덜 발생할 것으로 예측한다는 점이다. 또한, 비다발지역의 경우 다발지역처럼 차량과 같은 물체를 통해서 다발지역이라고 인식하는 것과 달리 도로 주변에 존재하는 나무, 중앙분리대, 주차금지 구조물과 같은 교통구조물을 통해서 비다발지역으로 예측하고 있다.

이러한 결과를 바탕으로 보행자 교통사고의 안전성 측면에서 도로의 폭이 좁고, 개방감이 적으며, 도로 주변으로 교통안전 구조물을 포함한 물리적 시설물이 존재할 경우 보행자 교통사고가 적게 일어난다는 결론을 지을 수 있다. Ewing and Dumbaugh (2009)은 도로의 환경에서 조성된 환경과 교통의 안전성 관계에 관한 연구를 통해 도로 공간의 밀도가 높을수록 교통사고의 확률을 낮춘다는 연구결과를 제시하고 있다. 차선이 좁거나, 도로 주변으로 가로수와 같은 장애물이 밀집해 있으면 운전자는 운행속도를 낮추게 되며 그 결과 교통사고의 사망확률을 낮춘다는 것이다. 이는 본 연구에서 결과와 맥락을 같이 하는 결과로 볼 수 있다.

딥러닝 기법을 통해서 보행교통사고 다발지역과 비다발지역의 구분에 어떠한 측면을 통해서 판단하는지에 여부에 대한 실험결과를 통해서 판단할 때, 다발지역과 비다발지역을 판단하는 기준에는 도로의 개방성 측면과 규모, 구조물의 측면에서 차이를 나타내고 있음을 알 수 있다. 이러한 모델의 검증을 통해서 향후 수도권 지역에서의 보행자 친화적이고, 안전한 도로 환경에서 구성 요소가 어떠한 부분이 중점적으로 고려되어야 하는지를 판단하는 의사결정에 도움을 줄 것이며 기존에 존재하는 도로의 안전성의 판단에 해당 모형을 유용하게 활용할 수 있음을 의미한다.

## V. 결론

본 연구의 목적은 CNN 구조의 딥러닝 방식을 적용하여 도로의 실제 이미지를 통해 보행교통사고 다발지역과 비다발지역을 구분하는 모형을 도출하는 것이다. 분석을 위해 도로교통공단의 교통사고 다발지역 위치 정보를 바탕으로 총 3,411곳의 GSV 이미지 13,644장을 수집하였다. 수집한 이미지 가운데 12,044장을 학습용 데이터(training data)로, 1,600장을 검증 데이터(test data)로 할당하여 분석을 시행했다.



분석에 사용한 검증모형은 VGG16, ResNet50, ResNet101, VGG19, InceptionV3로 총 5가지 모형을 통해서 분류모델의 성능을 검증하였다. 검증결과 VGG16 모델이 평균 약 73% 수준으로 보행교통사고 다발지역과 비다발지역을 구분하는 것으로 나타났다.

교통사고 지역 분류 모형에 관한 결과를 시각화하기 위해 추가로 CAM 분석을 실시했다. 분석결과 교통사고 다발지역의 경우 도로상의 차량에 대한 주의(attention)가 집중적으로 발생하였고, 도로의 환경에 있어 상대적으로 도로가 넓고, 도로 주변으로 구조물이 적은 지역일수록 보행교통사고 다발지역으로 예측하는 것으로 나타났다. 한편, 비다발지역의 경우 도로의 폭이 좁고, 도로 주변으로 건물이나 혹은 교통안전 시설물과 같은 물리적 구조물에 주의(attention)가 집중되었으며 앞서 다발지역과의 전체적인 맥락에서 환경적인 차이를 보이는 지역들이 비다발지역으로 예측하는 것을 확인하였다.

일부 선행연구들의(Kwon and Cho, 2020; 박근덕·이수기, 2018) 개방감이 클수록 인지된 도로의 안전성이 높다는 결과를 제시하고 있다. 하지만, 운전자의 경우 도로 환경에서 차선의 폭이 넓고 주변에 통행의 흐름을 방해하는 요소가 없으면 과속의 가능성을 가지고 있다. 엄승섭 외(2013)는 도로 유형에 따라 운전자의 시선에 미치는 영향에 관한 연구를 통해서 도로의 특성에 따라 운전자가 기울이는 주의는 차이가 있다는 것을 주장한다. 특히, 도로의 수준에 있어서 시외 도로보다 시내 도로에서의 경우 전방과 좌우를 더 많이 응시한다는 결과를 제시하고 있다. 또한, 운전자의 인지된 심리적 측면에서 개방감이 높은 도로의 상황에서는 과속하는 경향이 높다는 선행연구(오주석·이순철, 2007; 한덕웅·한인순, 2001)의 연구결과를 통해서 볼 때 본 연구에서 덩러닝 모형으로 구분되는 도로 환경들 가운데 보행교통사고 다발지역은 해당 선행연구들을 지지하는 결과로 볼 수 있다.

이상의 결과와 논의들을 통해, 다음과 같은 정책적 시사점을 고려할 수 있다. 첫째, 노인과 어린이와 같은 교통약자들의 보행교통사고를 예방하고 보행친화적인 도시개발을 위하여 덩러닝, 컴퓨터 비전 등의 신기법의 활용이 필요하다. 이러한 기법들은 보행교통사고 다발지역을 GSV와 같이 무료로 이용가능한 데이터를 활용하여 예측하였다. 이러한 기법들을 사용한다면, 지방정부들은 현장조사나 설문을 위한 자원을 절약하고 보다 효과적으로 노인보호구역 혹은 어린이 보호구역 등을 선정할 수 있을 것이다.

둘째, 노인과 어린이와 같은 교통약자들의 보행친화성에 대한 재점검이 필요하다. 특히, 개방감의 경우 운전자의 시야를 확보하여 보행교통사고를 줄인다고도 알려져 있으나 본 연구에서는 도로폭이 좁고, 건물이나 교통안전 시설물이 위치하여 상대적으로 개방감이 낮은 지역이 보행교통사고 비다발지역으로 구분되는 것을 파악하였다. 이러한 결과를 바탕으로, 보행교통사고 다발지역에 대한 road diet와 같은 도로폭의 수정, 교통안전 시설

물의 확대 설치 혹은 운전자의 주의를 높일 수 있는 시설물의 확보가 고려되어야 한다.

본 연구는 실제의 도로 환경을 기반으로 하여 교통사고 다발지역과 비다발지역을 구분하고 더 나아가 어떤 요소가 교통사고 발생에 영향을 미치는 요인으로 판단되는지에 대해서 더욱 객관적인 측면에서의 분석이 이루어졌다는 점에서 기여도가 높다. 하지만, 본 연구가 가지는 연구의 한계점은 다음과 같다.

첫째, 연구자료의 제한된 합리성이다. 본 연구는 개별적으로 일어나는 보행교통사고 지역이 아닌 다발적으로 일어나는 보행교통사고 지역의 중심지 좌표를 기반으로 GSV 이미지를 수집하였기 때문에 개별 보행교통사고가 발생한 지역과의 환경적 차이가 존재할 수 있다. 또한, 보행교통사고 다발지역의 시점과 GSV 이미지의 시점 간 차이가 있다. 그럼에도 불구하고, 본 연구는 스트리트뷰 이미지에 대하여 컴퓨터 비전, 덩러닝과 같은 국토계획분야의 새로운 분석 기법을 이용하여 주요 교통약자인 노인과 어린이 대상 보행교통사고 다발지역을 탐색적으로 분석하였다는 데 의의가 있다.

둘째, 교통사고 지역에 대한 변수들의 수치화의 한계이다. 이미지를 바탕으로 컴퓨터의 학습에 의한 판단이 이루어질 뿐 구체적인 변수의 영향 관계를 확인하는 부분에서는 한계점을 가진다. 따라서, 향후 후속 연구에서는 노인과 어린이와 같은 교통약자들의 보행교통사고 다발지역에 대한 보다 명확한 영향요인을 파악하기 위하여 object detection과 semantic segmentation과 같은 기법을 사용하여 교통약자들의 보행교통환경에 대한 보다 개선된 결과를 제시하는 연구가 필요하다.

## 인용문헌

## References

1. 강동운, 2014. "상관성이 있는 변수를 고려한 주성분 분석 기반의 안전성능함수 개발", 서울대학교 대학원 석사학위논문.  
Kang, D.W., 2014. "Safety Performance Functions with Correlated Influential Factors Using Principal Component Analysis", Master's Dissertation, Seoul National University.
2. 고동원·박승훈, 2019. "개별 사고특성 및 근린환경 특성이 서울시 보행자 교통사고 심각도에 미치는 영향", 「대한건축학회 논문집, 계획계」, 35(8): 101-109.  
Ko, D.W. and Park, S.K., 2019. "The Effects of Individual Accidents and Neighborhood Environmental Characteristics on the Severity of Pedestrian Traffic Accidents in Seoul", *Journal of the Architecture Institute of Korea, Planning and Design*, 35(8): 101-109.
3. 김경범, 2015. "고령사회 도래에 따른 노인 보행자 교통사고 특성 및 감소방안: 제주지역을 중심으로", 「한국콘텐츠학회논문지」, 15(4): 197-207.



- Kim, K.B., 2015. "The Traffic Accident Characteristics and Reduction Methods of Elderly Pedestrian in Accordance with the Advent of the Aging Society: Focused on Jeju", *Journal of the Korean Contents Association*, 15(4): 197-207.
4. 김윤진, 2017. "딥 러닝(Deep Learning)을 활용한 이미지 빅데이터(Big Data) 분석 연구", 중앙대학교 대학원 박사학위논문.  
Kim Y.J., 2017. "Analysis of Image Big Data Using Deep Learning", Ph.D. Dissertation, Chung-Ang University.
5. 김흥진·김홍순, 2004. "노인 보행자 교통사망사고 예방에 관한 연구", 「도시행정학보」, 17(3): 139-163.  
Kim, H.J. and Kim, H.S., 2004. "A Study on Prevention of Death Caused by Car Accidents of the Aged Pedestrians", *The Journal of the Korean Urban Administration Association*, 17(3): 139-163.
6. 도로교통공단, 2020. 「2020년판(2018년 통계) OECD 회원국 교통사고 비교」, 원주.  
KOROAD, 2020. *2020(based on the 2018) Comparison of Traffic Accidents in OECD Member Countries*. Wonju.
7. 류종득, 2018. "딥 러닝을 이용한 고속도로 교통사고 건수 예측모델 개발에 관한 연구", 아주대학교 대학원 박사학위논문.  
Ryu, J.D., 2018. "Development of Expressway Traffic Accident Prediction Model Using Deep Learning", Ph.D. Dissertation, Ajou University.
8. 박정훈·변지혜, 2012. "초등학교 주변 물리적 환경이 보행안전에 미치는 영향: 창원시 초등학교를 대상으로", 「한국지리정보학회지」, 15(2): 150-160.  
Park, K.H. and Beon, J.H., 2012. "Effects of the Physical Environment around Elementary School on Children's Walking Safety: A Case Study of the Elementary Schools in Changwon", *Journal of the Korean Association of Geographic Information Studies*, 15(2): 150-160.
9. 박근덕·이수기, 2018. "가로공간 보행만족도 예측을 위한 딥러닝 모형의 적용과 검증", 「한국도시설계학회지 도시설계」, 19(6): 19-34.  
Park, K.D. and Lee, S.G., 2018. "Application and Validation of a Deep Learning Model to Predict the Walking Satisfaction on Street Level", *Journal of the Urban Design Institute of Korea Urban Design*, 19(6): 19-34.
10. 박정호, 2017. "노인 보행의 특성: 정상과 비정상", 「대한신경과학회지」, 35(4):1-4.  
Park, J.H., 2017. "Characteristics of Gait in the Elderly: Normal vs. Abnormal", *Journal of the Korean Neurological Association*, 35(4):1-4.
11. 박준범·남궁미, 2019. "고령 보행자 교통사고에 영향을 미치는 환경요인에 관한 연구: 부산광역시를 중심으로", 「한국지리학회지」, 8(2): 289-303.  
Park, J.B. and Namgung, M., 2019. "A Study on the Environmental Factors Influencing Elderly Pedestrian Traffic Accidents in Busan", *Journal of the Association of Korean Geographers*, 8(2): 289-303.
12. 박준태·김용석·이수범, 2009. "로짓모형을 이용한 고령운전자 고속도로 교통사고 특성 분석 연구", 「한국도로학회논문집」, 11(4): 1-7.  
Park, J.T., Kim, Y.S., and Lee, S.B., 2009. "The Analysis of Older Driver's Traffic Accident Characteristic at Expressway using Logit model", *International Journal Highway Engineering*, 11(4): 1-7.
13. 서임기·강동윤·박제진·박신형, 2015. "고속도로 선형 동질구간 기반의 안전성능함수 개발", 「대한토목학회논문집」, 35(2): 397-405.  
Seo, I.K., Kang, D.Y., Park, J.J., and Park, S.H., 2015. "Development of Safety Performance Function Based on Expressway Alignment Homogeneous Section", *Journal of the Korean Society of Civil Engineers*, 35(2): 397-405.
14. 서지민·이수기, 2016. "서울시 보행자 교통사고에 영향을 미치는 물리적 환경요인에 관한 연구: 2014 TAAS 자료를 중심으로", 「국토계획」, 51(3): 197-216.  
Seo, J.M. and Lee, S.G., 2016. "A Study on the Physical Environmental Factors Influencing Pedestrian Traffic Accidents in Seoul, Korea: Focused on the 2014 TAAS Data", *Journal of Korea Planning Association*, 51(3): 197-216.
15. 엄승섭·이영석·김진용·정창현·박준현, 2013. "도로 유형별 특성이 운전자 시선에 미치는 영향 연구", 한국자동차공학회 추계 학술대회 및 전시회, 고양: KINTEX.  
Uhm, S.S., Lee, Y.S., Kim, J.Y., Jung, C.H., and Park, J.H., 2013. "A Study on The Effect of Road Characteristics on Driver's Gaze", Paper presented at the KSAE 2013 Annual Conference and Exhibition, Goyang: KINTEX.
16. 오주석·이순철, 2007. "사고 및 음주운전자들의 운전행동결정 요인 특성이 위험행동 및 교통사고에 미치는 영향: 경로분석 연구", 「대한교통학회지」, 25(2): 95-105.  
Oh, J.S. and Lee, S.C., 2007. "The Effects of Driving Behavior Determinants on Dangerous Driving and Traffic Accidents in the Reckless Drivers Group: A Path Analysis Study", *Journal of Korean Society of Transportation*, 25(2): 95-105.
17. 오주택·윤일수·황정원·한음, 2014. "비선형 회귀분석, 인공신경망, 구조방정식을 이용한 지방부 4지 신호교차로 교통사고 예측 모형 성능 비교 연구", 「대한교통학회지」, 32(3): 266-279.  
OH, J.T., Yun, I.S., Hwang, J.W., and Han, E., 2014. "A Comparative Study On Accident Prediction Model Using Non-linear Regression And Artificial Neural Network, Structural Equation for Rural 4-Legged Intersection", *Journal of Korean Society of Transportation*, 32(3): 266-279.
18. 윤준호·이수기, 2018. "중앙버스전용차로 정류장 주변 보행자 교통사고 요인 분석: 서울시 TAAS (2014-2016) 자료를 중심으로", 「국토계획」, 53(4): 123-142.  
Yoon, J.H. and Lee, S.G., 2018. "Analysis of Pedestrian Traffic Accident Factors around the Exclusive Median Bus Lane Station Area: Focused on TAAS (2014-2016) Data in Seoul, Korea", *Journal of Korea Planning Association*, 53(4): 123-142.
19. 이근희·노정현, 2015. "확률모수를 이용한 교통사고예측모형 개발수도권 및 부산광역시 4지 교차로를 대상으로", 「한국ITS학회논문집」, 14(6): 91-99.  
Lee, G.H. and Rho, J.H., 2015. "A Development of Traffic Accident Model by Random Parameter: Focus on Capital Area and Busan 4-legs Signalized Intersections", *The Journal of The Korea Institute of Intelligent Transportation Systems*, 14(6): 91-99.
20. 이세영·이제승, 2014. "어린이·노인 보행자 교통안전을 위한 근린환경요인", 「한국도시설계학회지 도시설계」, 15(6): 5-15.



- Lee, S.Y. and Lee, J.S., 2014. "Neighborhood Environmental Factors Affecting Child and Old Adult Pedestrian Accident", *Journal of the Urban Design Institute of Korea*, 15(6): 5-15.
21. 이수기·고준호·이기훈, 2016. "근린환경특성이 보행만족도에 미치는 영향 분석: 서울서베이 2013년 자료를 중심으로", 「국토계획」, 51(1): 169-187.
- Lee, S.G., Ko, J.H., and Lee, G.H., 2016. "An Analysis of Neighborhood Environment Affecting Walking Satisfaction: Focused on the 'Seoul Survey' 2013", *Journal of Korea Planning Association*, 51(1): 169-187.
22. 이수범·김정현·김태희, 2003. "도로 및 교통특성에 따른 계획 단계의 도시부 도로 교통사고 예측모형개발", 「대한교통학회지」, 21(4): 133-144.
- Lee, S.B., Kim, J.H., and Kim, T.H., 2003. "Development of Traffic Accident Prediction Models by Traffic and Road Characteristics in Urban Areas", *Journal of Korean Society of Transportation*, 21(4): 133-144.
23. 최재성·김상엽·김성규·연중형·김철현, 2015. "무단횡단 교통사고 요인에 관한 연구: 서울시 사례를 중심으로", 「한국ITS학회 논문지」, 14(3): 38-49.
- Choi, J.S., Kim, S.Y., Kim, S.K., Yeon, J.H., and Kim, C.H., 2015. "A Study of Pedestrian Crashes Contributing Factors During Jaywalking: Focused on the Case of Seoul", *The Journal of the Korea Institute of Intelligent Transportation Systems*, 14(3): 38-49.
24. 한덕웅·한인순, 2001. "과속운전 행동에 영향을 미치는 심리요인들", 「한국심리학회지: 건강」, 6(2): 39-62.
- Han, D.W. and Han, I.S., 2001. "An Application of Theory of Planned Behavior to Passenger Car Drivers' Speed-limit Violation", *The Korean Journal of Health Psychology*, 6(2): 39-62.
25. Brosseau, M., Zangenehpour, S., Saunier, N., and Miranda-Moreno, L., 2013. "The Impact of Waiting Time and Other Factors on Dangerous Pedestrian Crossings and Violations at Signalized Intersections: A case Study in Montreal", *Transportation Research Part F: Traffic Psychology and Behaviour*, 21: 159-172.
26. Bustos, C., Rhoads, D., Solé-Ribalta, A., Masip, D., Arenas, A., Lapedriza, A., and Borge-Holthoefer, J., 2021. "Explainable, Automated Urban Interventions to Improve Pedestrian and Vehicle Safety", *Transportation Research Part C: Emerging Technologies*, 125: 103018.
27. Cafiso, S., D'agostino, C., and Persaud, B., 2013. "Investigating the Influence of Segmentation in Estimating Safety Performance Functions for Roadway Sections", In 92nd Annual Meeting of the Transportation Research Board, Washington, DC.
28. Ewing, R. and Dumbaugh, E., 2009. "The Built Environment and Traffic Safety: A Review of Empirical Evidence", *Journal of Planning Literature*, 23(4): 347-367.
29. Haleem, K., Alluri, P., and Gan, A., 2015. "Analyzing Pedestrian Crash Injury Severity at Signalized and Non-signalized Locations", *Accident Analysis and Prevention*, 81: 14-23.
30. He, K., Zhang, X., Ren, S., and Sun, J., 2016. "Deep Residual Learning for Image Recognition", Paper presented at the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas: Caesar's Palace.
31. Huang, H., Song, B., Xu, P., Zeng, Q., Lee, J., and Abdel-Aty, M., 2016. Macro and Micro Models for Zonal Crash Prediction with Application in Hot Zones Identification. *Journal of Transport Geography*, 54: 248-256.
32. Jacobs, J., 1961. *The Death and Life of Great American Cities*, New York: Random House.
33. Jaderberg, M., Mnih, V., Czarnecki, W.M., Schaul, T., Leibo, J.Z., Silver, D., and Kavukcuoglu, K., 2016. "Reinforcement Learning with Unsupervised Auxiliary Tasks", arXiv preprint arXiv:1611.05397.
34. Kim, D., Kim, D.K., and Lee, C., 2013. "Safety Performance Functions Reflecting Categorical Impact of Exposure Variables for Freeways", *Transportation Research Record*, 2398(1): 67-74.
35. Kwon, J.H. and Cho, G.H., 2020. "An Examination of the Intersection Environment Associated with Perceived Crash Risk among School-aged Children: Using Street-level Imagery and Computer Vision", *Accident Analysis and Prevention*, 146: 105716.
36. LeCun, Y., Bottou, L., Bengio, Y., and Haffner, P., 1998. "Gradient-based Learning Applied to Document Recognition", *Proceedings of the IEEE*, 86(11): 2278-2324.
37. Leden, L., Garder, P., and Johansson, C., 2006. "Safe Pedestrian Crossings for Children and Elderly", *Accident Analysis and Prevention*, 38(2): 289-294.
38. Lu, J., Haleem, K., Alluri, P., and Gan, A., 2013. "Full versus Simple Safety Performance Functions: Comparison based on Urban Four-lane Freeway Interchange Influence Areas in Florida", *Transportation Research Record*, 2398(1): 83-92.
39. Mori, Y. and Mizohata, M., 1995. "Characteristics of Older Road Users and Their Effect on Road Safety", *Accident Analysis and Prevention*, 27(3): 391-404.
40. Müller, A.C. and Guido, S., 2016. *Introduction to Machine Learning with Python: A Guide for Data Scientists*, O'Reilly Media.
41. Naik, N., Philipoom, J., Raskar, R., and Hidalgo, C., 2014. "Streetscore - predicting the Perceived Safety of One Million Streetscapes", Paper presented at the IEEE Conference on Computer Vision and Pattern Recognition Workshops, OH: Columbus.
42. Najafabadi, M.M., Villanustre, F., Khoshgoftaar, T.M., Seliya, N., Wald, R., and Muharemagic, E., 2015. "Deep Learning Applications and Challenges in Big Data Analytics", *Journal of Big Data*, 2(1): 1-21.
43. Simonyan, K. and Zisserman, A., 2015. "Very Deep Convolutional Networks for Large-scale Image Recognition", Paper presented at International Conference on Learning Representations, CA: San Diego.
44. Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., and Rabinovich, A., 2015. "Going Deeper with Convolutions", Paper presented at the IEEE Conference on Computer Vision and Pattern Recognition, MA: Boston.



45. Talebi, H. and Milanfar, P., 2018. "Learned Perceptual Image Enhancement". Paper presented at 2018 IEEE International Conference on Computational Intelligence and Computing Research, PA: Pittsburgh.
46. Whitebread, D. and Neilson, K., 2000. "The Contribution of Visual Search Strategies to the Development of Pedestrian Skills by 4-11 Year-old Children", *British Journal of Educational Psychology*, 70(4): 539-557.
47. 국가법령정보센터, "교통약자의 이동편의 증진법", 2021.5.20. 읽음. <https://www.law.go.kr/%EB%B2%95%EB%A0%B9/%EA%B5%90%ED%86%B5%EC%95%BD%EC%9E%90%EC%9D%98%EC%9D%B4%EB%8F%99%ED%8E%B8%EC%9D%98%EC%A6%9D%EC%A7%84%EB%B2%95>  
 Korea Ministry of Government Legislation, "How to Improve the Convenience of Transportation for the Handicapped ", Accessed May 20, 2021. <https://www.law.go.kr/%EB%B2%95%EB%A0%B9/%EA%B5%90%ED%86%B5%EC%95%BD%EC%9E%90%EC%9D%98%EC%9D%B4%EB%8F%99%ED%8E%B8%EC%9D%98%EC%A6%9D%EC%A7%84%EB%B2%95>

Date Received	2021-06-02
Reviewed(1 <sup>st</sup> )	2021-07-18
Date Revised	2021-09-03
Reviewed(2 <sup>nd</sup> )	2021-10-01
Date Accepted	2021-10-01
Final Received	2021-11-17