

# 보행교통사고 다발지역 예측을 위한 딥러닝의 적용

## : 수도권 노인과 어린이 보행교통사고를 중심으로

---

전희정, 강승엽, 정수영, 김태완, 조철호, 주원영, 김지영, 허재필

SCH Univ.  
Dept. of AI and Bigdata  
Kim JinSeong

# Contents

---

- I. 서론
- II. 이론적 논의
- III. 연구설계
- IV. 분석결과
- V. 결론

# 서론

---

- 한국에서 교통약자(노인, 어린이)의 보행안전성은 높지 않음
  - 2018년 기준 우리나라 보행교통사고 비율 = 전체 교통사고의 약 40% (OECD 평균의 2배)
  - 14세 이하 **어린이** 인구 10만 명당 보행 중 사망자 수 = 0.36명 (OECD 평균의 1.4배)
  - 65세 이상 **노인** 인구 10만 명당 보행 중 사망자 수 = 11.4명 (OECD 중 가장 많음)
- 보행교통사고를 유발하는 물리적 요인에 대한 다수의 연구가 지속해서 진행되어 옴
  - 다수의 연구들은 행정동 수준의 데이터 사용 -> **정확한 영향요인 파악에 한계 존재**
  - 도로 이미지 자료를 기반으로 CV와 DL 기법을 적용한 연구 -> 대부분 보행교통안전이 아닌 **교통흐름에 중점**
  - 보행환경을 분석한 논문 -> 개인이 인식하는 보행안전성 같은 **주관적 자료 기반**



수도권 내 노인과 어린이 보행교통사고 다발/비다발 구분 + 해당 지역의 GSV 이미지 획득하여 CV와 DL기법 활용  
= **보행교통사고 다발 지역과 비다발지역을 예측하는 모형** 구축하고 평가

# 이론적 논의

---

## 1. 노인과 어린이 보행교통사고와 영향요인

- 노인의 경우 보행 능력이 낮아 사고 발생 가능성이 높음 (김홍진, 김홍순, 2004)
- 연령이 높아질수록 무단횡단을 하려는 경향이 높게 나타남 (Moriu and Mizohata, 1995)
- 어린이의 경우 교통사고 발생 가능성이나 안전에 대한 인지가 낮음 (이세영, 이제승, 2014)
- 도로의 물리적 환경이 교통사고 영향요인으로 나타남 (Haleem et al, 2015)
- 도로시설물도 형태에 따라 보행자의 교통사고에 다른 영향 미칠 수 있음 (Leden et al, 2006 / 고동원 박승훈, 2019)



보행자 신호와 같은 **교통 시스템의 체계적인 설계**가 보행자의 **안전**을 향상할 수 있는 주요 원인임

# 이론적 논의

---

## 2. 스마트 보행교통환경 구축을 위한 딥러닝의 적용

- 스마트 도시 계획에서 물리적 환경분석과 관련성 분석한 연구 -> 여전히 전통적인 통계 방법 기반 (이수범 외, 2013 이근희, 너정현, 2015, 강동운, 2014, ..)
- 정형이 아닌 비정형 데이터 포함한 딥러닝 기법 적용해 분석의 정확도 높이기 위한 연구 진행 중임 (Huang et al., 2016)
- 가로공간에서 보행 만족도 예측을 위해 GSV 이미지를 딥러닝 모형에 적용해 분석 진행함 (박근덕, 이수기, 2018)
- 가로공간에 대한 이미지에서 Segmentation 기법을 활용한 지각된 도로의 안정성 파악함 (Kwon and Cho, 2020)



한계: 설문조사에 기반한 **인간의 주관적 인식이 포함**된 보행만족도 및 안전성 결과와 연결해 분석함

차별점: **실제 보행교통사고가 다수 일어난 지역 구분** -> 이를 객관적 자료로 활용함

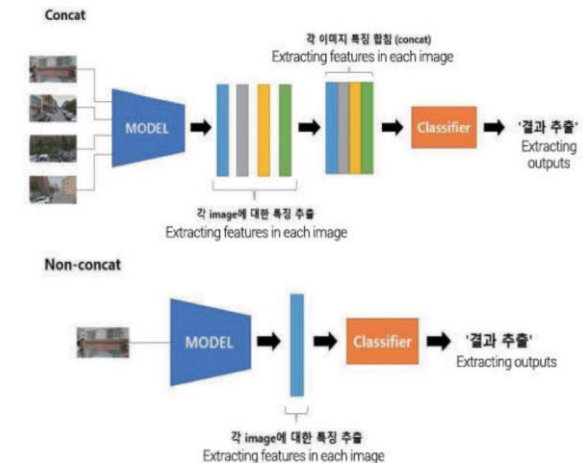
# 연구설계

## 1. 연구자료 및 범위

- 연구 자료: 2012년~2018년까지의 보행교통사고 다발지역 (도로교통공단)  
2020년 9월 GSV(Google Street View) 데이터  
=> Concat방식(한 장소의 360° 파노라마 전체 이미지에 대한 특징 추출해서 분석) 사용함
- 공간적 범위: 서울, 인천, 경기를 포함한 수도권 지역
  - 전국의 49% 차지함
  - 수도권과 비수도권 간 밀도 등의 건조환경의 차이로 나타나는 교통환경의 지역 간 차이 최소화할 수 있음
- 비다발 지역: **다발지역 인근지역** 대한 좌표들 중 **무작위 추출**을 통해 지정함
  - 다발지역과 환경적 측면에서 많은 차이가 나는 경우 지역 간 차이로 나타나는 결과이기 때문임

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	3,411
Total	3,011		400		
Total image	3,011×4=12,044		400×4=1,600		3,411×4=13,644

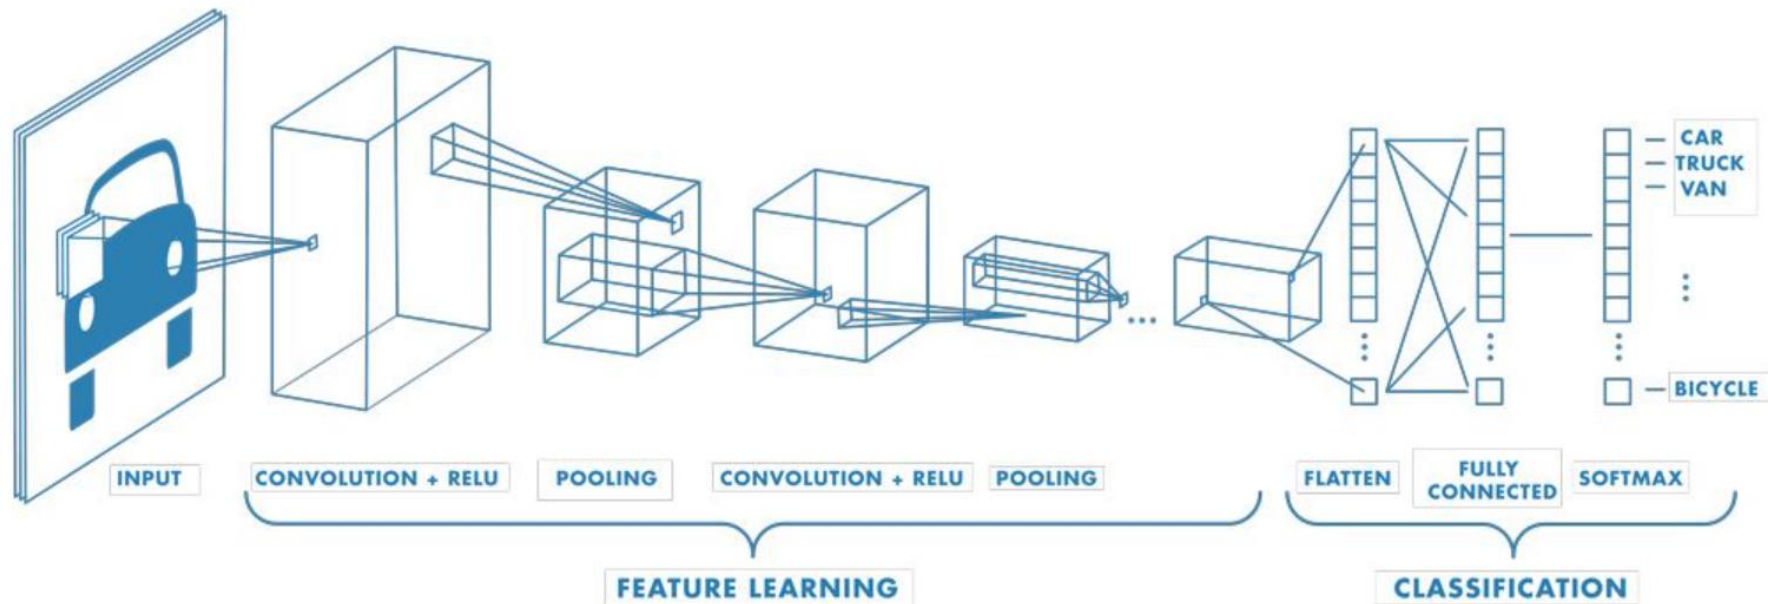
Unit: spot



# 연구설계

## 2. 딥러닝 모형의 적용

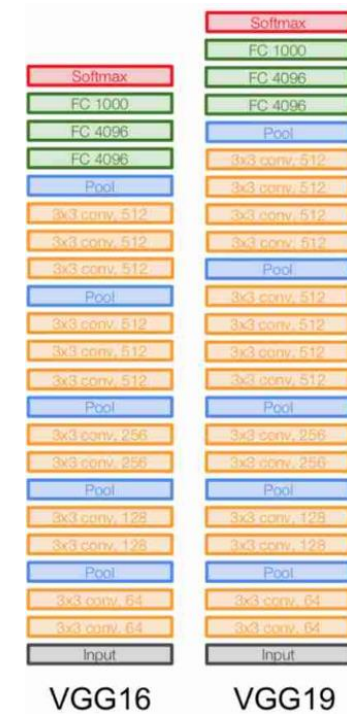

- 사용한 모델: VGG16, VGG19, ResNet50, ResNet101, InceptionV3 (CNN 구조 기반)



CNN(Convolution Neural Network)

# 연구설계

- VGG(Visual Geometry Group)




(이미지 출처: <https://wikidocs.net/164796>)

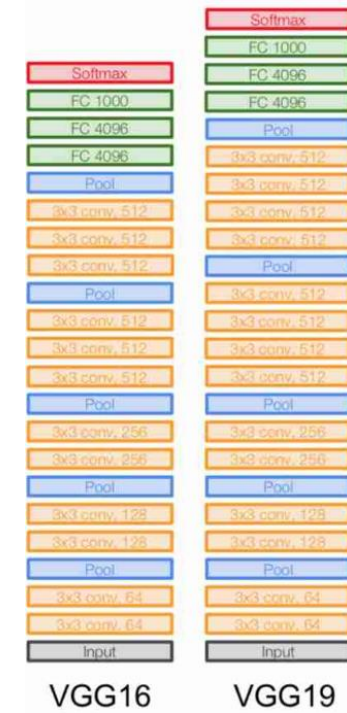


# 연구설계

- VGG(Visual Geometry Group)



(이미지 출처: <https://wikidocs.net/164796>)




VGG16 = 13 Convolution Layer + 3 Fully Connected Layer  
 VGG19 = 16 Convolution Layer + 3 Fully Connected Layer

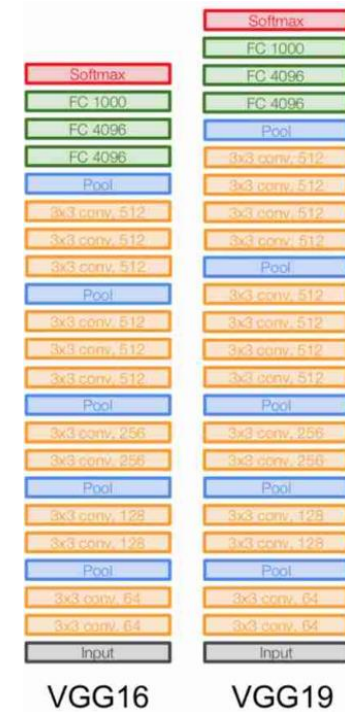
# 연구설계

- VGG(Visual Geometry Group)

장점: 구조가 간단하여 학습 파라미터의 개수가 적기 때문에 학습 속도가 빠름



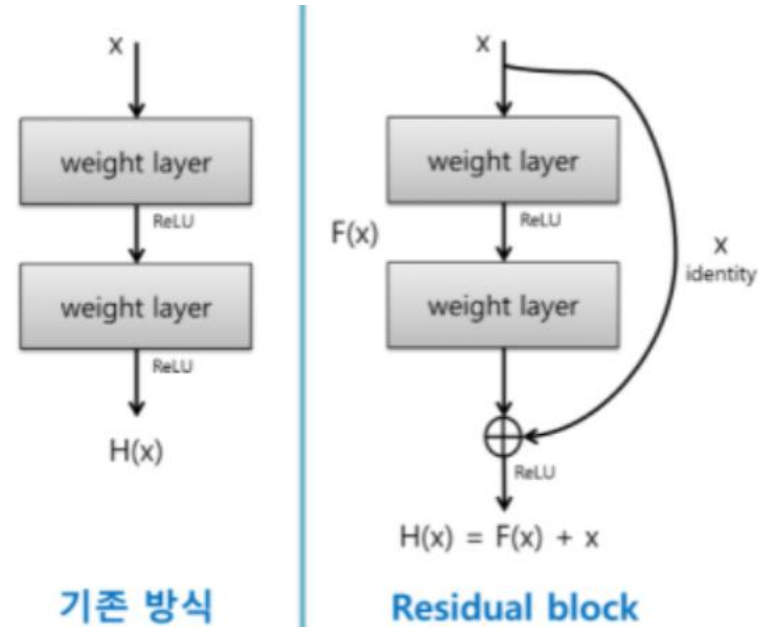

(이미지 출처: <https://wikidocs.net/164796>)



VGG16 = 13 Convolution Layer + 3 Fully Connected Layer  
 VGG19 = 16 Convolution Layer + 3 Fully Connected Layer

# 연구설계

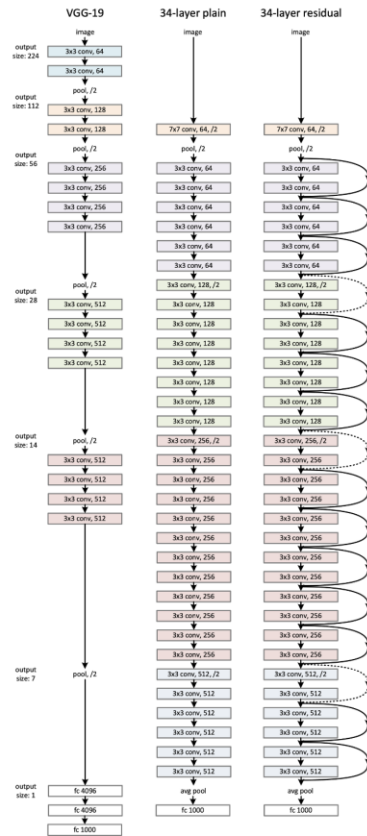
- ResNet(Residual Neural Network)



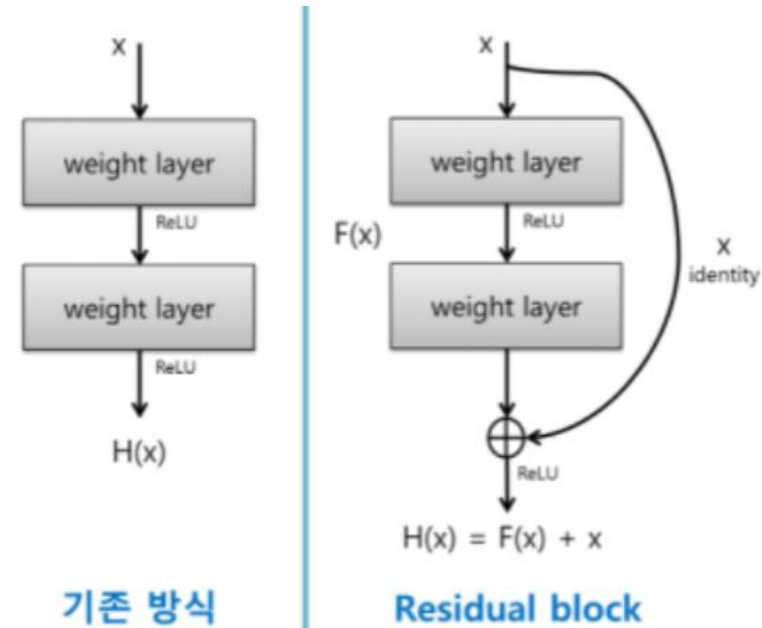
(이미지 출처: <https://wikidocs.net/137252>)

# 연구설계

- ResNet(Residual Neural Network)



특징: 레이어의 입력을 레이어의 출력에 직접 더하는 residual block을 활용함  
상대적으로 깊은 계층으로 구성됨




목적:  $H(x)-x$ (residual)을 0에 가깝게 만드는 것  
즉,  $x$ 는 변하지 않으므로  $F(x)$ 를 0에 가깝게 만드는 것

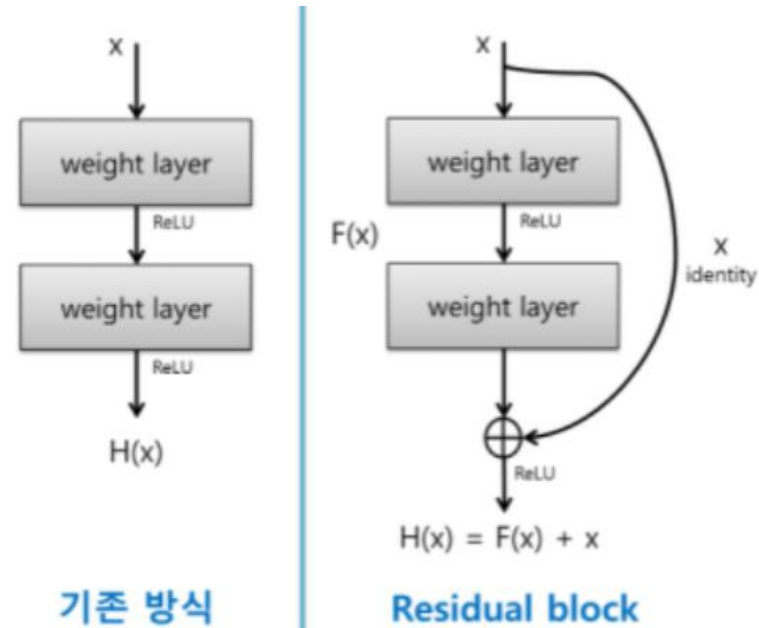
(이미지 출처: <https://wikidocs.net/137252>)

# 연구설계

- ResNet(Residual Neural Network)



특징: 레이어의 입력을 레이어의 출력에 직접 더하는 residual block을 활용함  
상대적으로 깊은 계층으로 구성됨




목적:  $H(x)-x$ (residual)을 0에 가깝게 만드는 것  
즉,  $x$ 는 변하지 않으므로  $F(x)$ 를 0에 가깝게 만드는 것

(이미지 출처: <https://wikidocs.net/137252>)

ResNet50 = 50개의 계층  
ResNet101 = 101개의 계층

# 연구설계


- InceptionV3



(이미지 출처: <https://cloud.google.com/tpu/docs/inception-v3-advanced?hl=ko>)

# 연구설계

- InceptionV3



(이미지 출처: <https://cloud.google.com/tpu/docs/inception-v3-advanced?hl=ko>)

특징: 서로 다른 크기의 필터를 함께 사용하여 이미지의 특징을 추출하며, 이를 통해 모델 성능 향상

# 연구설계

## 2. 딥러닝 모형의 적용

- 성능 검증: 정밀도(Precision), 재현율(Recall), 정확도(Accuracy), F1-Score

Devision		Actual Class	
		True	False
Predicted class	True	True Positive(TP)	False Positive(FP)
	False	False Negative(FN)	True Negative(TN)

Confusion Matrix

$$\text{Precision} = \frac{TP}{TP + FP}$$

$$\text{Recall} = \frac{TP}{TP + FN}$$

$$\text{F1 - Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}$$

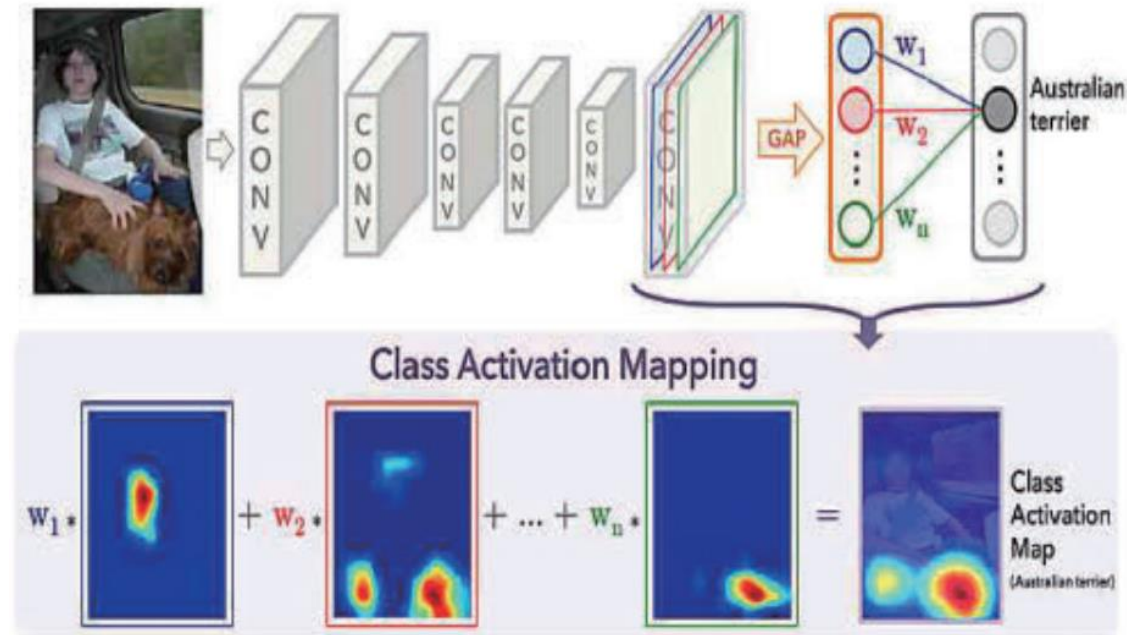
TP: 보행교통사고 다발지역을 다발지역이라고 정확하게 분류  
TN: 보행교통사고 비다발지역을 비다발지역이라고 정확하게 분류  
FP: 실제 비다발지역을 다발지역이라고 예측  
FN: 실제 다발지역을 비다발지역이라고 예측



# 연구설계

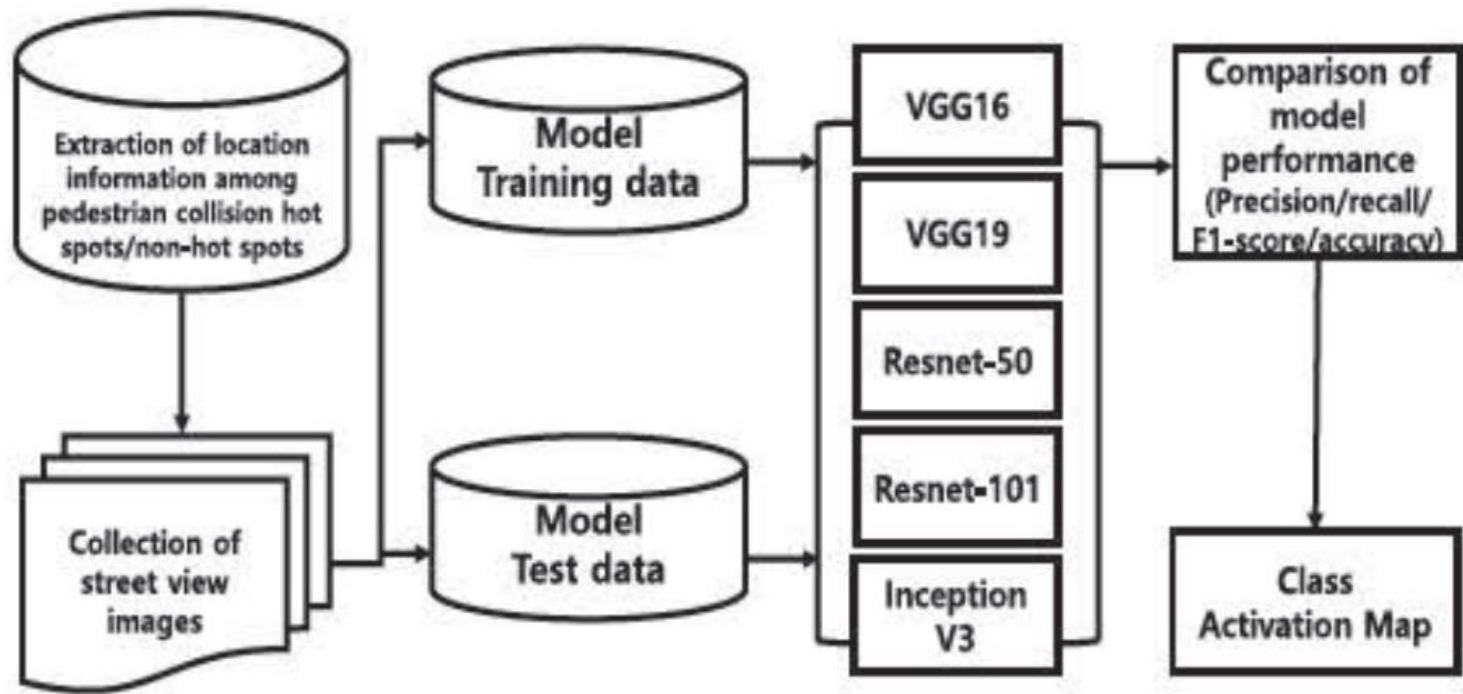
## 3. Class Activation Map (CAM) 분석

- CNN 구조의 딥러닝 모형의 경우 결과가 수치로 제시된다는 한계점이 존재함
- CAM 분석: 모델이 예측 결과를 도출하는 데 있어, **이미지의 각 영역이 어느 정도의 영향**을 주었는지 분석하는 기법



# 연구설계

## 연구분석의 방법 및 과정



수도권 지역의 교통사고 다발 지역 선정 → 비다발 지역 위치 정보를 구성 → GSV API 활용해서 이미지 수집  
→ 5개 모델로 학습 → 성능 비교 → 어떠한 측면의 부분을 다발/비다발 지역으로 구분하는지 CAM으로 확인

# 분석결과

## 1. 보행교통사고 다발/비다발 지역 예측모델 성능 검정

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

노인과 어린이 보행교통사고 다발지역 예측모델 정확도, 재현율, F1-Score

Model	Area	Hot spot (%)	Non-hot spot (%)	Average (%)	
VGG 16	SE	89.02	69.14	79.9	73.03
	G-I	79.57	52.53	66.2	
	CR	84.30	60.84	73.0	
ResNet 50	SE	74.39	77.78	76.0	70.88
	G-I	69.89	61.62	65.8	
	CR	72.14	69.70	70.9	
ResNet 101	SE	87.80	59.26	74.6	71.29
	G-I	84.95	50.51	67.9	
	CR	86.38	54.89	71.3	
VGG 19	SE	64.63	81.48	72.4	68.05
	G-I	54.84	72.73	63.7	
	CR	59.74	77.11	68.1	
Inception V3	SE	47.56	79.01	62.1	59.09
	G-I	52.69	59.60	56.1	
	CR	50.13	69.31	59.1	

노인과 어린이 보행교통사고 다발/비다발지역 예측모델 정확도 비교

# 분석결과

## 1. 보행교통사고 다발/비다발 지역 예측모델 성능 검정

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

노인과 어린이 보행교통사고 다발지역 예측모델 정확도, 재현율, F1-Score

Model	Area	Hot spot (%)	Non-hot spot (%)	Average (%)	
VGG 16	SE	89.02	69.14	79.9	73.03
	G-I	79.57	52.53	66.2	
	CR	84.30	60.84	73.0	
ResNet 50	SE	74.39	77.78	76.0	70.88
	G-I	69.89	61.62	65.8	
	CR	72.14	69.70	70.9	
ResNet 101	SE	87.80	59.26	74.6	71.29
	G-I	84.95	50.51	67.9	
	CR	86.38	54.89	71.3	
VGG 19	SE	64.63	81.48	72.4	68.05
	G-I	54.84	72.73	63.7	
	CR	59.74	77.11	68.1	
Inception V3	SE	47.56	79.01	62.1	59.09
	G-I	52.69	59.60	56.1	
	CR	50.13	69.31	59.1	

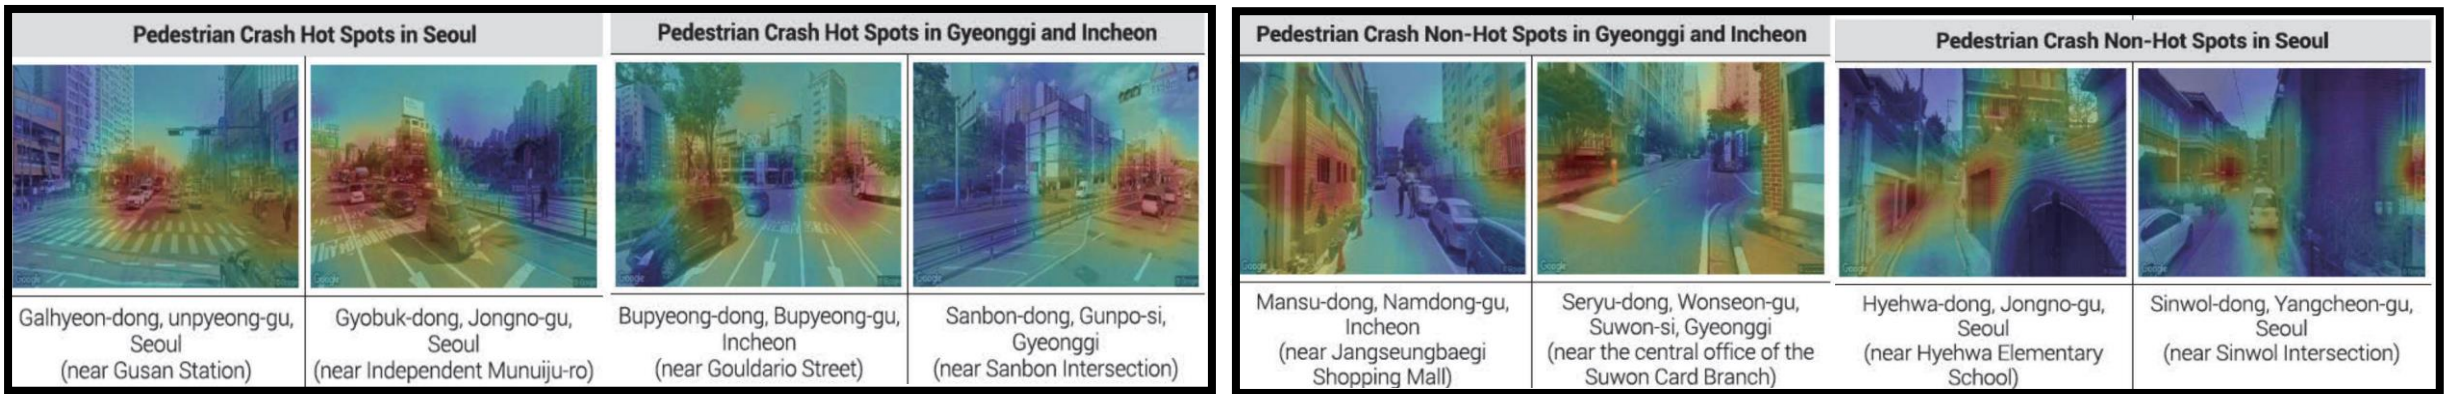
노인과 어린이 보행교통사고 다발/비다발지역 예측모델 정확도 비교

# 분석결과

## 2. 보행교통사고 다발/비다발에 대한 CAM 분석결과

- ResNet101결과를 바탕으로 분석 진행

(VGG16모델의 경우 직렬형 구조모델 -> CAM분석 진행 할 경우 VGG 모델의 본래의 성격을 상실함)



### - 다발지역의 특징

- 도로의 폭이 상대적으로 넓음
- 도로의 개방감 측면에서 시야가 넓은 지역
- 교통 관련 시설물 보다는 차량에 초점

### - 비다발지역의 특징

- 도로의 폭이 상대적으로 좁음
- 도로의 개방감 측면에서 시야가 좁은 지역
- 교통 관련 시설물에 초점

도로의 폭이 좁고, 개방감이 적으며, 도로 주변으로 교통안전 구조물을 포함한 물리적 시설물이 존재할 경우 보행자 교통사고가 적게 일어남

# 결론

---

- 정책적 시사점
  1. 노인과 어린이와 같은 교통약자들의 보행 교통사고를 예방하고 보행 친화적인 도시개발을 위해 DL, CV 등의 신기법의 활용이 필요함
  2. 교통약자들의 보행친화성에 대한 재점검이 필요함  
(도로폭의 수정, 교통안전 시설물의 확대 설치 혹은 운전자의 주의 높일 수 있는 시설물의 확보)
- 한계점
  1. 연구자료의 제한된 합리성
    - GSV 이미지를 수집하였기 때문에 개별 보행교통사고가 발생한 지역과의 환경적 차이가 존재할 수 있음
    - 보행교통사고 다발지역의 시점과 GSV 이미지의 시점 간 차이가 있음
  2. 교통사고 지역에 대한 변수들의 수치화의 한계
    - 구체적인 변수의 영향 관계를 확인하는 부분에서 한계점 가짐
    - Object Detection과 Semantic Segmentation과 같은 기법을 사용해 보행교통환경에 대한 개선된 결과를 제시하는 연구가 필요함

# Thank you

