

POTHOLE 정의 및 학문별 분류

FHWA / LTPP 표준 (미국 연방고속도로청)

직경 150mm(6인치) 이상
하부 기층/노상이 노출될 정도로 아스팔트 표면 손상
사발(Bowl) 모양의 손상
심각도 3단계: Low($\leq 25\text{mm}$) · Moderate(25–50mm) · High($> 50\text{mm}$)

공학적 메커니즘 기반

전 세계적으로 합의된 단일 문장 정의 부재
날카롭고 수직인 모서리
특정 깊이와 너비를 지닌 노면의 국부적 하향 함몰
도로 표면 조직의 Localized Depression

탐지 방법론 분류

비전 기반

카메라 이미지 활용
YOLO · CNN · Mask R-CNN
mAP · FPS 평가

진동 기반

가속도 센서 활용
임계값 · 머신러닝
Accuracy · F1-Score

3D 재구성

스테레오/포인트 클라우드
U-Net · 사진측량
부피 오차율 평가

POTHOLE 탐지 논문 정리

논문 제목	년도	기관	핵심 요약
Potholes Detection Using DL and Area Estimation Using Image Processing	2021	Southern Illinois University	YOLOv5s + IPM 역원근 매핑으로 실시간 탐지(111 FPS) 및 물리적 면적 산출
Computer Vision Based Pothole Detection under Challenging Conditions	2022	University of Windsor	그림자·젖은 노면 악조건 특화 전처리 + YOLO로 오탐지 개선
Pothole Detection Using Deep Learning Under Low-Light Conditions	2024	Keimyung University	YOLOv11 + FPN + Grad-CAM으로 야간 저조도 탐지, mAP(50-95) 0.72 달성
Generative AI Powered Shadow-Resilient Pothole Detection in Autonomous Vehicles	2025	National Institute of Technology Karnataka National Institutes of Health Indian Institute of Technology Bombay	생성형 AI(GAN/Diffusion)로 그림자 실시간 제거 후 YOLO 탐지, 자율주행 적용
Pavement Condition Assessment using Smartphone Accelerometers	2021	North Dakota State University	스마트폰 Z축 가속도 + 머신러닝으로 80~90% 정확도, 실시간 도로 파손 지도 생성
Road Pothole Detection Based on Crowdsourced Data and Extended Mask R-CNN	2024	Tongji University	클라우드소싱 이미지에 Mask R-CNN 적용, 픽셀 단위 분할로 보수 물량 산출
Pothole Assessment Using Photogrammetry-Assisted CNN	2023	University of Waterloo	SfM/MVS 사진측량 + CNN으로 면적·깊이·부피 자동 계산, 실측 오차 극소화
ECC-YOLO with Deformable Convolution and Attention Mechanisms	2026	Chang'an University	변형 가능 합성곱 + 어텐션 메커니즘으로 비정형 포트홀 고정밀 탐지
Pixel-Level Pavement Distress Detection via Stereo Vision and DL	2021	Southeast University	스테레오 비전 + Modified U-Net으로 Precision 0.9632, 부피 오차 4.62%
Review of Recent Automated Pothole-Detection Methods	2022	Korea Institute of Civil Engineering and Building Technology	비전·진동·3D 재구성 3대 범주로 탐지 방법론 체계적 분류 및 비교

Potholes Detection Using DL and Area Estimation Using Image Processing

탐지 알고리즘 객체 탐지: YOLOv5 (L/M/S) & Faster R-CNN (ResNet50, VGG16, MobileNetV2, MVGG16)

면적 추정: IPM (Inverse Perspective Mapping) — 카메라 원근 왜곡 보정
 버드아이 뷰 변환 후 바운딩 박스 영역 → 물리적 표면적 산출

작동 방식

- ① 차량 카메라 실시간 영상 입력
- ② YOLOv5s → 포트홀 2D 바운딩 박스 생성
- ③ IPM으로 버드아이 뷰 변환 (원근 보정)
- ④ 왜곡 제거 후 픽셀 영역 계산 → 실제 표면적 산출

성능 평가

최적 모델: YOLOv5 Small — 속도·정확도 균형 우수, 실시간 채택
 처리 속도: 이미지 1장당 0.009초 → 약 111 FPS (완전 실시간)
 탐지 정확도: mAP@0.95 ≈ 78.4% 이상

평가지표

mAP (Mean Average Precision): 다양한 IoU 기준 종합 정밀도
 Mean Precision: 탐지 박스 중 실제 포트홀 비율
 Inference Time / FPS: 실시간 도로 모니터링 적합성

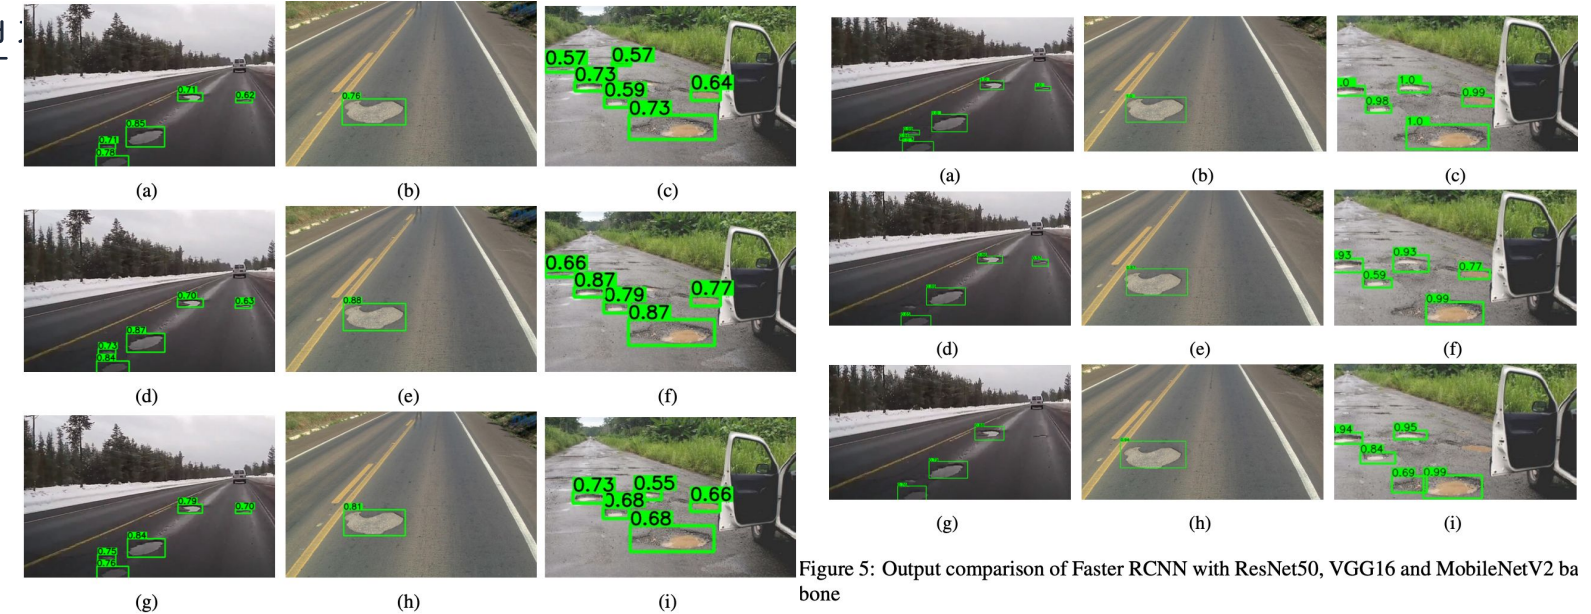


Figure 4: Output comparison of YOLOV5 small, medium and large models

Figure 5: Output comparison of Faster RCNN with ResNet50, VGG16 and MobileNetV2 backbone

Metrics	YOLOv5			Faster RCNN		
	Y_l	Y_m	Y_s	ResNet50 (FPN)	VGG16	Mobile-NetV2
Precision (P)	86.43%	86.96%	76.73%	91.9%	69.8%	63.1%
Training Loss	0.015	0.017	0.020	0.065	0.226	0.209
Mean Average Precision (mAP@0.5-0.95)	63.43%	61.54%	58.9%	64.12%	35.3%	30.5%
Inference speed						
Resolution (1774×2365)	0.014s	0.012s	0.009s	0.098s	0.114s	0.036s
Resolution (204 × 170)	0.018s	0.013s	0.009s	0.065s	0.119s	0.032s
Training time/epoch	26s	16s	12s	124s	173s	80s
Total training time	31200s	19200s	14400s	12400s	17300s	8000s
Model Size (MB)	95.3	43.3	14.8	165.7	175.5	329.8

Table 2: Comparison of YOLOv5 and Faster RCNN performance

Computer Vision Based Pothole Detection under Challenging Conditions

탐지 알고리즘 전처리: 조명 대비 조절, 흐림(Blurring), 노이즈 추가 — 그림자·젖은 노면 상:
 탐지: YOLO 계열(YOLOv5 등) + Faster R-CNN — 악조건 특화 특징 추출
 악조건 집중 데이터로 사전 학습 → 견고한(Robust) 탐지

작동 방식

- ① 그림자·젖은 노면 등 악조건 이미지 입력
- ② 악조건 특화 데이터 증강으로 사전 학습 완료
- ③ 신경망이 어두움(가짜) vs 실제 파손(진짜) 질감·경계 차이 파악
- ④ 방해 요소 필터링 후 실제 포트홀 위치에 바운딩 박스 출력

성능 평가

맑은 날씨 전용 모델: 악천후·그림자 환경에서 오탐지 급증
 특화 파이프라인 모델: 극한 환경에서도 안정적 성능 유지
 짙은 그림자 → 포트홀 오인 / 반사 포트홀 미탐지 오류 획기적 개선

평가지표

Precision: 젖은 노면·그림자 오탐지(False Positive) 감소 측정
 Recall: 어둠·물웅덩이 속 실제 포트홀 미탐지(False Negative)
 mAP: 조명 왜곡 환경에서 바운딩 박스 탐지 성능 종합 평가



Figure 5. Pothole detection results in adverse conditions.

Model	Image Resolution	Precision	Recall	mAP@ 0.5	mAP@ [0.5:0.95]	Inference Speed
Yolo v3	640 × 640	0.434	0.346	0.285	0.092	~35 ms
	640 × 640	0.789	0.512	0.563	0.202	~35 ms
	640 × 640	0.708	0.684	0.681	0.268	~35 ms
	640 × 640	0.713	0.751	0.747	0.314	~35 ms
Yolo v3-SPP	1080 × 1080	0.777	0.771	0.771	0.330	~82 ms
	640 × 640	0.812	0.663	0.711	0.286	~36 ms
	1080 × 1080	0.821	0.700	0.791	0.354	~84 ms

Pothole Detection Using Deep Learning Under Low-Light Conditions

탐지 알고리즘 야간 특화 데이터 증강: 어두운 환경·불빛 반사 등 야간 조명 간섭 학습
 YOLOv11 + FPN (Feature Pyramid Network): 다양한 크기 포트홀 정밀 포착
 XAI 융합: Grad-CAM으로 신경망 집중 영역 해석·최적화

- 작동 방식**
- ① 가로등·차량 라이트 반사로 노면 파악 어려운 야간 이미지 입력
 - ② 증강 훈련 신경망이 어둠 속 미세 균열·음영 포착
 - ③ FPN이 원거리 소형 ↔ 근거리 대형 포트홀 정보 교차 융합
 - ④ Grad-CAM으로 내부 가중치 검증 → 정확한 바운딩 박스 출력

성능 평가 최우수 모델: YOLOv11+FPN+Grad-CAM — 저조도에서 비교군 압도
 mAP(50-95): 0.72 달성 (YOLOv8 Medium 0.611 대비 우수)
 mAP50: 0.88 (+1.5% 향상), mAP75: 0.791 (+5.7% 향상)

평가지표 mAP(50-95): IoU 0.5~0.95 범위 평균 — 위치·크기 종합 평가
 mAP50/mAP75: 각 IoU 기준 정밀도 (mAP75 ↑ = 박스 정교함 입증)
 저조도 환경 기준 비교군 대비 성능 향상폭 중점 분석



Figure 8. Comparison of night model performance.

Table 1. Performance metrics of different computer vision models.

Model Title	mAP50	mAP75	mAP50-95
YOLOv8 Nano	0.831	0.732	0.549
YOLOv8 Small	0.840	0.724	0.604
YOLOv8 Medium	0.867	0.719	0.611
YOLOv9	0.773	0.754	0.6
RTDERT	0.674	0.569	0.472
MobileNet	0.643	0.584	0.581
YOLOv10	0.842	0.754	0.641
YOLOv11	0.853	0.734	0.682
Our Model (YOLOv11+FPN+Crad-CAM)	0.88	0.791	0.72

Generative AI Powered Shadow-Resilient Pothole Detection in AVs

탐지 알고리즘 생성형 AI: 조건부 GAN/Diffusion으로 그림자 영역 조명 균일 복원(Shadow Removal)
 데이터 합성: 그림자 덮인 극한 포트홀 데이터 대량 생성 → Shadow-Resilience 극대화
 실시간 탐지: 엣지 컴퓨팅(NVIDIA Jetson 등) 최적화 경량 YOLO 결합

- 작동 방식**
- ① 전방 카메라 → 그림자·햇빛 대비 극심한 도로 영상 캡처
 - ② 생성형 AI가 그림자 조명 왜곡 실시간 보정·상쇄
 - ③ YOLO가 정제된 특징 맵 기반 진짜 포트홀 위치 바운딩 박스 출력
 - ④ 자율주행 제어 시스템에 좌표 즉각 전달 → 회피/감속

성능 평가 그림자 강건성: False Positive(그림자→포트홀 오인) 및 False Negative 고질 문제 해결

실시간성 유지: 생성형 AI 전처리 포함에도 높은 FPS + 향상된 mAP 동시 달성

자율주행 회피 기동에 요구되는 지연 시간 충족

평가지표 mAP: 그림자 간섭 포함 주행 데이터셋 기준 바운딩 박스 정확도

Precision: 그림자 → 포트홀 오탐지 감소율

Recall: 그림자 속 실제 포트홀 검출 향상율

Latency / FPS: 자율주행 제어 시스템 안전성 검증



Fig. 6. Real-world evaluation of the YOLOv11n model for pothole detection. The model successfully detects potholes even in the presence of shadows, demonstrating its robustness to challenging lighting conditions.

Ref.	GAN Technique	Detection Algorithm	Accuracy (mAP@0.5) Pre/Post-Augmentation	Inference Time (ms)
[17]	MUNIT	YOLOv8, RT-DETR, Modified YOLOv8	0.755 → 0.814, 0.831 → 0.856, 0.839 → 0.867	N/A, 20, 28.6
[18]	ESRGAN	YOLOv5, EfficientDet	0.30 → 0.46, 0.20 → 0.39	N/A
[19]	AsphaltGAN	YOLOv8	0.201 → 0.304	N/A
[20]	WGAN-GP	YOLOv5s	0.637 → 0.678	N/A
Our Work	CycleGAN	YOLOv9t, YOLOv10n, YOLOv11n, YOLOv12n	0.794 → 0.875, 0.720 → 0.763, 0.831 → 0.883, 0.747 → 0.787	4.4, 3.0, 2.3, 3.9

Pavement Condition Assessment using Smartphone Accelerometers

탐지 알고리즘 신호 전처리: Low/High-pass Filter로 중력·엔진 잔진동 노이즈 제거
 z축(수직) 가속도 변화 집중 분석
 임계값 기반: z축 피크값·z-DIFF가 설정값 초과 여부 판단
 머신러닝: SVM · 의사결정나무 · 랜덤 포레스트로 정상/방지턱/포트홀

작동 방식

- ① 차량 내 스마트폰이 가속도 + GPS 실시간 기록
- ② 포트홀 통과 시 z축 그래프에 하강→강한 상승 피크 발생
- ③ 필터가 엔진 노이즈 제거 → 충격 패턴 포착 → 포트홀 이벤트 판별
- ④ GPS 좌표와 함께 중앙 서버 전송 → 실시간 파손 지도 갱신

성능 평가

탐지 정확도: 약 80~90% 이상 (값비싼 비전 장비 불필요)
 보정 기법: 주행 속도·거치 위치·서스펜션 종류에 따른 동적 임계값 조
 실시간 도로 파손 지도 업데이트 가능

평가지표

Accuracy / F1-Score: 도로 파손 vs 정상 노면 분류 종합 평가
 TPR (True Positive Rate): 실제 포트홀 감지율 극대화
 FPR (False Positive Rate): 맨홀·요철 오탐지율 최소화
 ROC 분석으로 최적 임계값 도출

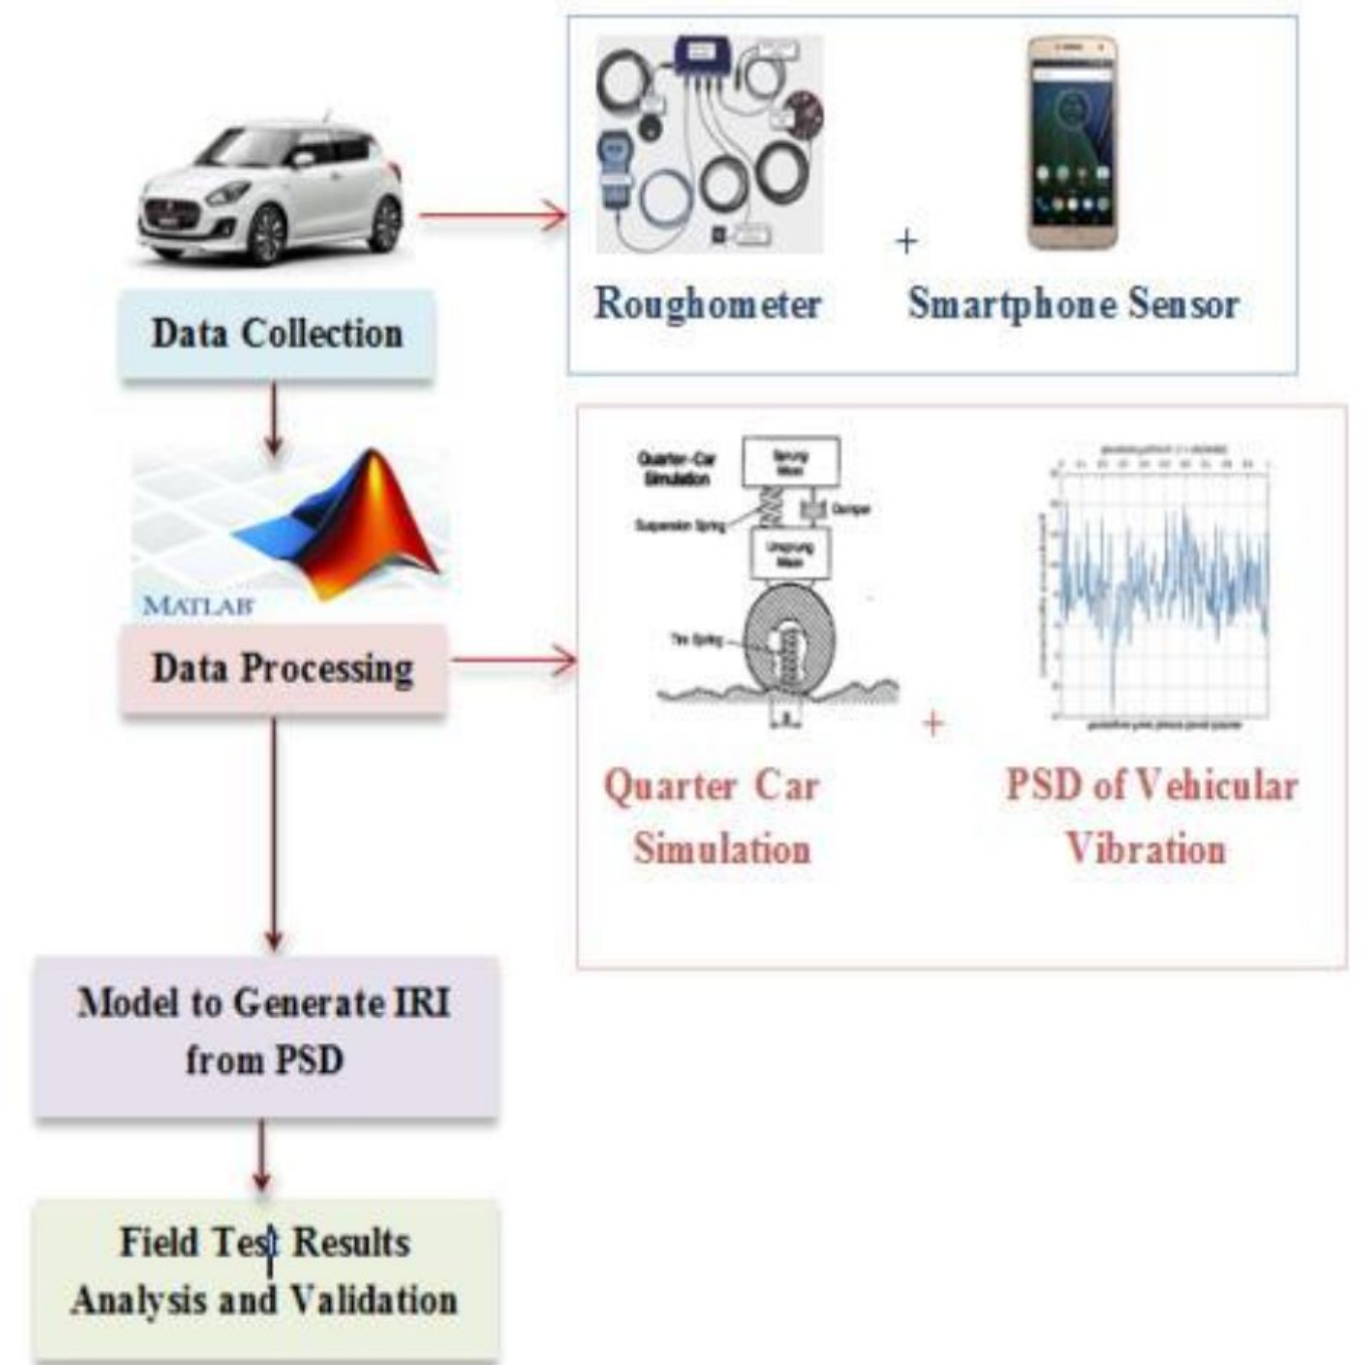


Fig 2. Project Approach

Road Pothole Detection Based on Crowdsourced Data and Extended Mask R-CNN

탐지 알고리즘 인스턴스 분할: Mask R-CNN 기반 — 경계선까지 픽셀 단위 추출

백본: ResNet + FPN 결합으로 다양한 크기 포트홀 특징 추출

RoIAlign: RoIPooling 대체 — 소수점 단위 위치 왜곡 방지, 정밀 마스크 생성

작동 방식

- ① 다양한 화질·각도의 이미지 입력
- ② 백본 네트워크가 크고 작은 포트홀 특징 맵 추출
- ③ RPN → 후보 영역 제안, RoIAlign → 오차 없는 픽셀 정렬
- ④ 출력: ① 클래스 분류 ② Bbox 좌표 ③ 픽셀 정밀 마스크




Fig. 9. Comparison of the results of our proposed model for detecting pavement potholes. (The figure consists of three columns: the first column displays the original images, the second column displays the annotated images, and the third column displays the results of our model testing.)

성능 평가

강건성: 해상도·조명·각도가 제각각인 실제 운전자 제보 데이터에서 경계 정확 인식

픽셀 단위 분할로 실제 면적·둘레 형태 정교 추출

보수 물량 산출 기초 데이터로 즉시 활용 가능한 수준

평가지표

Bbox mAP: 바운딩 박스 위치 정확도

Mask mAP / Mask IoU: 픽셀 마스크가 실제 포트홀과 겹치는 정도

Precision: 맨홀·아스팔트 패치 오탐지율 최소화

Recall: 실제 파손 부위 빠짐없이 탐지




Fig. 7. Comparison of the results of our proposed model and the benchmark models for pothole segmentation. (Sub-figures (a) and (b) depict the missed detection phenomenon comparison. Sub-figures (c) and (d) illustrate the comparison of repeated detection phenomenon. Sub-figures (e) and (f) show the comparison of the false detection phenomenon.)

Models	$AP_{0.5}$	$AP_{0.75}$	AP_S	AP_M	AP_L
ResNet-50	0.885	0.685	0.365	0.538	0.661
ResNet-101	0.876	0.705	0.406	0.547	0.660
Swin-T	0.871	0.692	0.413	0.515	0.648
Our proposed model	0.921	0.772	0.441	0.614	0.711

Pothole Assessment Using Photogrammetry-Assisted CNN

탐지 알고리즘 사진측량: SfM + MVS로 다중 시점 2D 이미지 → 3D 포인트 클라우드 생성
 정사영상(Orthoimage) + DEM(수치표고모델) 구축
 CNN: 정사영상 픽셀 단위 포트홀 영역 분할
 상태 평가: CNN 2D 경계 + DEM 깊이 적분 → 깊이·면적·부피 자동 산출

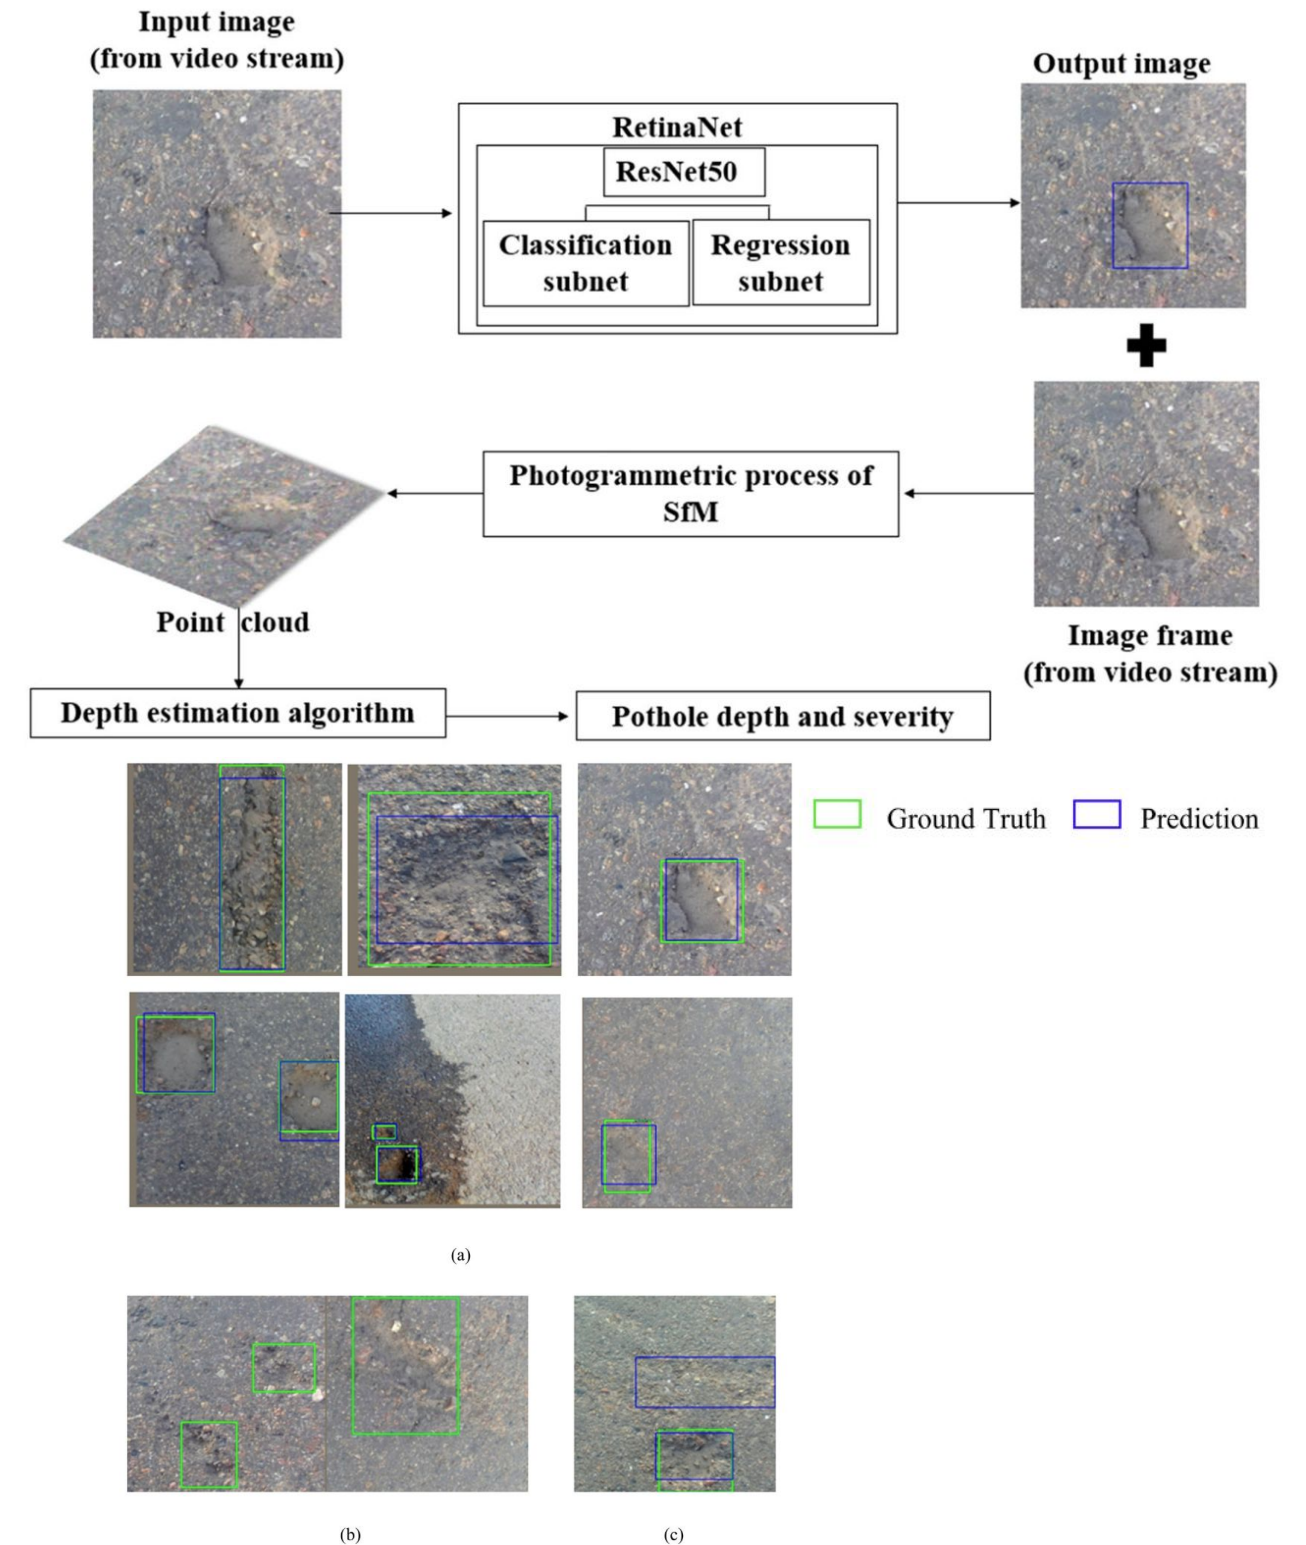
- 작동 방식**
- ① 카메라/드론으로 도로 구간 다각도 연속 촬영(사진 간 겹침 유지)
 - ② 사진측량 알고리즘 → 3D 노면 지도(DEM) + 2D 정사영상 생성
 - ③ CNN이 정사영상 위 포트홀 윤곽선 마스크
 - ④ 2D 영역 → 3D 표고 투영 → 면적·최대 깊이·보수 부피 리포트 출력

성능 평가 레이저 스캐너 불필요 — 일반 카메라/드론으로 정밀 3D 데이터 확보
 깊이·부피 데이터를 전문가 수작업 측정과 비교 → 오차율 매우 낮음
 실제 도로 보수 예산·채움재 물량 산출에 즉시 활용 가능

평가지표 탐지/분할: Precision · Recall · F1-Score · IoU
 Relative Error (%): 실제 부피 대비 예측 오차율

Table 9. mAP and IoU for test data.

	mAP	Average IoU of TP detections
Dataset-A	90.16%	94.7%
Dataset-B	96.21%	97.00



ECC-YOLO with Deformable Convolution and Attention Mechanisms

탐지 알고리즘 ECC-YOLO: 최신 YOLO 기반 맞춤형 고정밀 아키텍처

변형 가능 합성곱(DCN): 필터 형태를 객체 윤곽에 따라 유연하게 변형 → 비정형 포트를 잘 잡아줌
 어텐션 메커니즘: 배경(맨홀·차선 등) 가중치 ↓, 포트를 질감·음영 가중치 ↑

작동 방식

- ① 형태가 다양한 도로 파손 이미지 ECC-YOLO 입력
- ② 어텐션: 정상 아스팔트 흐리게, 파손 의심 영역 집중
- ③ DCN: 필터가 포트를 찌그러진 테두리를 따라 유연하게 이동
- ④ 비정형 기하학 완벽 파악 → 불규칙 포트를 감싸는 고정밀 박스 실시간 출력

성능 평가

비정형 포트를 탐지: 경계 모호·길쭉한 포트에서 기존 YOLO 대비 높은 정밀도

DCN + 어텐션 추가에도 효율적 네트워크 설계 → 실시간 추론 속도 유지
 정확도와 속도 균형 달성 (High-precision & Real-time)

평가지표

mAP: 비정형 포트를 바운딩 박스 정확도 종합 평가

Precision: 어텐션 기반 가짜 포트를 필터링 효과

Recall: 특이 형태 포트를 미탐지 감소율

FPS: 엣지 컴퓨터 환경에서 실시간 처리 가능성 검증



YOLOv11n



ECC-YOLO

Figure 8 presents the prediction results of RT-DETR-r18, YOLOv11n, and ECC-YOLO in typical road scenarios.

Table 4 Ablation Experiment Results.

numbe r	Experiment	Precision/ %	Recall/ %	mAP@0.5/ %
1	YOLOv11n	82.8	65.4	72.8
2	YOLOv11n+C3k2DCY	80.5	63.5	72.3
3	YOLOv11n+CDFA	77.5	65.4	74.2
4	YOLOv11n+CDFA+ELA- HSFPN	81.2	64.4	73.2
5	YOLOv11n+C3k2DCY+ELA- HSFPN+CDFA	84.5	67.9	74.2

Pixel-Level Pavement Distress Detection via Stereo Vision and DL

탐지 알고리즘 스테레오 비전: 좌우 카메라 시차(Disparity) → 3D 포인트 클라우드 생성
 PCA 알고리즘: 포인트 클라우드 기울기 보정 + 컬러·깊이 정렬 정사영상 생성
 Modified U-Net: 컬러 + 깊이 정보 융합 → 균열·포트홀 픽셀 단위 분할
 부피 측정: 2D 마스크 + 3D 깊이 데이터 매핑 → 깊이 적분으로 체적 산출

작동 방식

- ① 스테레오 카메라 → 좌/우 이미지 쌍 동시 촬영
- ② 스테레오 비전 + PCA → 3D 깊이 맵 + 정사영상 즉시 생성
- ③ Modified U-Net → 성한 노면 / 파손 경계 픽셀 단위 마스크
- ④ 픽셀 면적 + 깊이 값 융합 → 포트홀 형태·보수 필요 3D 부피 도출

성능 평가

Precision: 0.9632, Recall: 0.9552, F1-Score: 0.9592 (초고정밀 픽셀 분할)
 3D 체적 자동 측정 vs 수동 측정 전체 상대 오차율: 4.62%
 실제 도로 보수용 아스팔트 소요량 산출에 즉시 활용 가능

평가지표

Precision / Recall / F1-Score: 픽셀 단위 분할 안정성 평가
 Overall Relative Error (%): 실제 포트홀 부피 vs 예측 부피 오차율
 3D 복원 정확도 검증 핵심 지표




Fig. 3. Mathematical model of 3D reconstruction.




Fig. 17. Typical pothole segmentation images.

Review of Recent Automated Pothole-Detection Methods

비전 기반 (Vision-based)

알고리즘

- 특징 추출: 가우시안 필터, Edge Detection, SIFT
- 탐지: YOLO(v2/v4/v5), CNN, SVM

성능

- mAP 80~90% 이상 + 실시간 FPS(20~30+)
- 평가: Precision · Recall · F1 · mAP · FPS

작동 방식

- 차량 카메라 2D 이미지 → 딥러닝 → 바운딩 박스 + 확률 출력

진동 기반 (Vibration-based)

알고리즘

- 신호 처리: Low/High-pass Filter, 푸리에 변환
- 분류: Thresholding · k-NN · 랜덤 포레스트

성능

- 연산량 적어 초고속 실시간 처리 / 저저장 공간
- 평가: Accuracy · Precision · Recall

작동 방식

- z축 가속도 실시간 모니터링 → 충격 피크 패턴 → 포트홀 판별

3D 재구성 기반 (3D Reconstruction)

알고리즘

- 데이터 처리: PCA로 포인트 클라우드 보정
- 분할·체적: Modified U-Net + 체적 계산 알고리즘

성능

- 부피 측정 오차율 4.62% (특정 연구)
- 평가: Relative Error · Precision · Recall · IoU

작동 방식

- 스테레오/스캐너 → 3D 지도 → 파인 영역 추출 → 부피 계산