

GloSea6에서 YOLOv8을 활용한 시각장애인 보행자 위험 감지 기법

김남규, 박진성, 김성연, 박혜성, 정성욱*

The Risk Detection Technique for Visually Impaired Pedestrians using YOLOv8 on GloSea6

Nam-Gyu Kim, Jin-Seong Park, Sung-Yeon Kim, Hye-Seong Park, Sung-Wook Chung*

요약 기상 변화는 개인형 이동수단의 안전성에 중대한 영향을 미치며, 비나 눈과 같은 기상 조건은 사고율 증가의 주요 원인으로 지적되고 있다. 이러한 문제를 해결하기 위해 GloSea와 같은 고성능 기상 예측 모델을 활용한 안전 시스템의 필요성이 부각되고 있다. 전 세계적으로 개인형 이동수단의 급속한 보급은 도시 교통 환경과 보행자 안전에 큰 영향을 미치고 있으며, 국내에서도 사용 증가에 따라 보행자, 특히 시각장애인의 안전에 대한 우려가 커지고 있다. 본 연구는 YOLOv8 모델을 사용하여 객체를 탐지하고, 깊이 추정 및 칼만 필터 기반 추적 기법을 통해 객체의 궤적과 위험도를 정량적으로 평가하는 시스템을 제안한다. 실험 결과, 커스텀 YOLOv8 모델이 평균 mAP50 0.774의 성능을 기록하며, 개인형 이동수단 클래스에서는 mAP50 0.717의 높은 성능을 보였다. 위험도가 높은 객체는 빨간색 경계로 시각화되며, 이를 GloSea 기반 기상 데이터와 결합하면, 기상 조건에 따른 사고 위험도 예측 및 경고 시스템 개발에 기여할 수 있다. 향후 음성 피드백과 연계해 시각장애인의 안전한 보행을 지원할 수 있을 것으로 기대된다.

Abstract Weather changes have a significant impact on the safety of personal mobility devices, with conditions such as rain and snow being identified as major causes of increased accident rates. To address these issues, the necessity of safety systems utilizing high-performance weather prediction models like GloSea has been emphasized. The rapid proliferation of personal mobility devices worldwide has greatly influenced urban traffic environments and pedestrian safety. In South Korea, the growing use of these devices has heightened concerns about the safety of pedestrians, particularly those with visual impairments. This study proposes a system that uses the YOLOv8 model for object detection, depth estimation, and Kalman filter-based tracking techniques to quantitatively evaluate the trajectories and risk levels of objects. Experimental results show that the custom YOLOv8 model achieved an average mAP50 of 0.774, with a high performance of mAP50 0.717 for the personal mobility device class. High-risk objects are visualized with red boundaries, and when combined with GloSea-based weather data, the system can contribute to predicting and warning of accident risks under varying weather conditions. In the future, this system is expected to support safe navigation for visually impaired individuals through integration with voice feedback.

Key Words : GloSea6, Visually Impaired Pedestrian Safety, YOLOv8, Object Detection, Object Tracking, Risk Assessment, Depth Estimation, Kalman Filter

1. 서론

기상 변화는 보행자와 개인형 이동수단 간의 사고

위험을 크게 증가시키는 주요 요인 중 하나로, 비, 눈, 안개와 같은 돌발적인 기상 조건은 사고 발생률을 높이고 안전성에 중대한 영향을 미친다. 특히,

This research was funded by the 'Lecturer-Graduate Student-Faculty Collaboration Research Project' at Changwon National University in 2024

*Corresponding Author : Department of Computer Engineering, Changwon National University (swchung@changwon.ac.kr)
Received November 20, 2024 Revised December 06, 2024 Accepted December 16, 2024

GloSea6와 같은 고성능 기상 예측 모델을 활용하면 이러한 기상 상황을 사전에 예측하여 안전 시스템의 성능을 최적화할 수 있다. 이를 통해 비, 눈, 안개 등의 악천후에 대한 사전 대비가 가능해지며, 시각장애인을 위한 안전한 보행 환경을 더욱 효과적으로 보장할 수 있다. 또한 최근 개인형 이동수단의 보급 확대에 따라 도심 교통 환경이 빠르게 변화하고 있다. 전동 킥보드, 전동 이륜 평행차, 전동 자전거 등은 교통 혼잡 해소와 대기 질 개선에 기여하며 미래 교통수단으로 주목받고 있다[1]. 특히 전동 킥보드를 포함한 개인형 이동수단 이용자가 급증하면서 공유 시장이 성장하고 있지만, 보행자와의 충돌 사고가 급증하고 있다[2]. 지난 5년간 5천 명 이상이 부상이나 사망을 입었으며[3][4], 시각장애인은 사고에 더욱 취약하다.

시각장애인을 위한 보행 보조기구 중 기존 센서 기반 하드웨어는 보편화되지 못하고, 가격과 탐지 범위에서 실용성에 한계가 있었다[5]. 이에 스마트폰을 활용한 보행 안전 기술이 대안으로 떠오르고 있다. 스마트폰 카메라를 이용하면 객체를 탐지함으로써 멀리 있는 위험 요소도 감지할 수 있다. 그러나 기상 변화는 객체 탐지 성능에 영향을 미치며, GloSea6와 같은 기상 예측 모델을 활용하면 돌발적인 기상 상황을 예측하고 시스템 성능을 최적화할 수 있다[6].

본 연구에서는 YOLOv8 모델을 활용하여 보행 경로 상의 객체를 실시간으로 탐지하고, 칼만 필터를 통해 이동 경로와 속도를 예측하며, MiDaS 모델을 결합하여 객체의 깊이를 측정한다. 또한, GloSea6 모델을 활용한 기상 예측 데이터를 포함하여 객체의 위험도를 종합적으로 평가하는 시스템을 제안한다.

2. 관련연구

시각장애인은 시각 정보 부족으로 인해 청각과 촉각에 의존하여 환경을 파악하며, 이동속도가 느리고 안전에 각별히 유의해야 한다. 이를 지원하기 위해 시각장애인의 유형별 이동속도를 측정하고 보행 지원 기술의 필요성을 강조한 연구가 진행되었다[7].

센서를 활용한 기존 연구는 장애물 감지 장치를 설계하고 구현했으나, 탐지 범위가 30~100cm로 제한되어 빠른 개인형 이동수단과의 충돌 위험을 충분히 예방하지 못하는 한계가 있었다. 또한, 별도의 하드웨어 장비는 비용 및 접근성 문제로 보편화가 어렵다[8]. 스마트폰 카메라와 YOLOv5를 활용한 연구는 주변 객체를 탐지하였으나, 개인형 이동수단에 대한 인식 기능이 부족하고 위험도 평가 기준이 모호하다[9]. 반면, 칼만 필터를 적용한 연구는 객체의 이동 경로를 예측하고 위험 상황을 효과적으로 분석할 가능성을 보여주었다[10]. 하지만 깊이 정보가 부족한 기존 방식은 객체의 실제 거리와 위치를 반영하지 못하는 한계가 있다[11].

비, 눈, 안개와 같은 악천후 환경에서는 객체를 정확히 탐지하기 어려운 한계가 있다. 이를 극복하기 위해, 악천후 상황에서의 데이터셋을 활용해 모델을 학습시키는 연구가 진행된 바 있다[12]. 해당 연구에서는 동일한 영상에 강우 상황을 시뮬레이션하여 강우 데이터셋을 제작하고 이를 모델 훈련에 활용하였다. 그러나, 눈이나 안개와 같은 더 치명적인 악천후 상황은 포함되지 않았다. 이 연구는 눈과 안개 상황을 추가로 시뮬레이션하고 학습에 반영할 경우 객체 탐지 성능을 더욱 향상시킬 수 있음을 시사하였다. 이러한 방법에 GloSea6 기상예측 데이터를 결합하면, 더욱 정교하고 신뢰도 높은 위험도 계산이 가능할 것으로 기대된다.

다양한 날씨 조건에서 촬영된 이미지 데이터셋을 학습하여 영상을 통해 날씨를 인식하는 연구가 활발히 진행되고 있다[13][14]. [13]에서는 악천후 상황에서 촬영된 이미지를 포함해 학습을 진행함으로써, 모델이 이미지를 기반으로 날씨를 분류하고 악천후에서 객체를 효과적으로 탐지할 수 있음을 보여주고 있다. 이를 통해 반경 100m 내의 객체를 악천후에서도 탐지할 수 있는 가능성을 제시하였다.

그러나 카메라를 통한 이미지 기반의 날씨 인식과 객체 탐지 과정에서 촬영 품질이 저하되어 객체 탐지 오류나 노이즈가 발생할 수 있으며, 노이즈로 인해 맑은 날씨를 흐린 날씨로 판단하는 등의 문제가 발생할 수 있다. 이러한 오류는 시각장애인에게 부정

확한 위험 감지 정보를 전달할 수 있다. 이를 해결하기 위해 [14]에서는 다양한 기후 변화 속에서도 객체를 효과적으로 탐지하기 위해 기상 예보 정보를 사전에 저장하고, 탐지 시점의 기상 예보 데이터를 동적으로 적용하여 이미지를 분류하는 방식을 제안하였다. 이를 통해 넓은 범위의 기상 데이터를 활용하여 객체 탐지를 보다 정확하게 수행할 수 있음을 보여주고 있다.

따라서 GloSea6와 같은 기상 예보 시스템을 활용하여 사전에 기상 정보를 확보하면, 촬영 품질 저하나 날씨로 인한 객체 탐지 오류를 사전에 방지할 수 있다. 기상 예보 정보는 객체 탐지 시스템이 환경적 요인을 보다 정확히 이해하도록 지원하며, 이를 통해 시스템의 신뢰성과 정확성을 크게 향상시킬 수 있다.

본 연구에서는 GloSea6 모델을 사용하여 기후를 예측하고, YOLOv8 모델과 칼만 필터를 결합해 시각장애인의 보행 경로에서 사람, 차량, 개인형 이동수단을 탐지 및 추적하며, MiDaS 모델로 깊이 정보를 분석해 객체의 거리와 속도, 기후를 기반으로 위험도를 평가한다. 이를 통해 시각장애인에게 실시간으로 신뢰성 있는 위험 예측을 제공하고 보행 안전을 강화하고자 한다.

3. 객체 탐지 알고리즘

3.1 기후 예측 모델(GloSea6)

GloSea(Global Seasonal Forecasting System)는 Met Office에서 개발되고 운영되는 계절 예측 시스템이다. GloSea6 모델은 영국 기상청에서 도입한 GloSea5를 한국의 환경에 맞게 업데이트한 버전이다. 이 모델은 전지구 기후모델인 HadGEM3를 기반으로 개발된 앙상블 예측시스템으로, 2022년부터 기상청에서 GloSea6를 현업 기후예측시스템으로 사용중이다.

기상청의 장기예보 서비스는 주 단위, 계절 단위의 비교적 긴 시간 규모에서의 평균 상태에 대한 평년 대비 경향성을 예보한다. 이 때 GloSea6가 산출한 예측값과 실제값(평년 기후값)의 편차를 계산하여

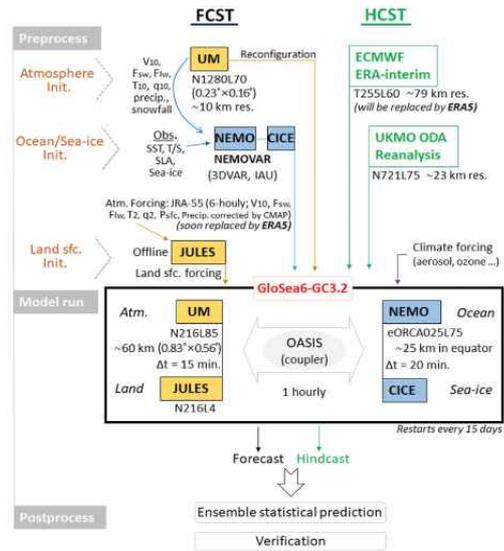


그림 1. GloSea6 모델 실행 구조[6]

Fig 1. GloSea6 model execution structure[6]

미래 날씨를 확률적으로 예측한다. 따라서 과거의 상태를 재현하는 기후장(hindcast, HCST) 생산과, 미래의 상태를 산출하는 예측장(forecast, FCST)을 모두 수행하도록 구성된다.

GloSea6는 대기(Unified Model, UM)와 해양(NEMO), 해빙(CICE), 지면(JULES) 총 4개의 기상예보 모델이 OASIS 결합자를 통해 연결되어 동작한다. 이러한 4개의 기상예보 모델이 격자를 기반으로 데이터를 수집하면 적분 과정을 통해 기상 예측을 위한 결과 데이터를 생성한다[6].

3.2 객체 탐지(YOLOv8)

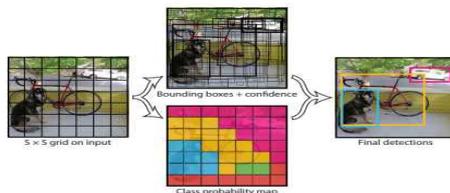


그림 2. YOLOv8 모델 흐름도[15]

Fig. 2. Flow chart of YOLOv8[15]

YOLOv8 모델은 입력 이미지를 S x S 크기의 그리드 셀로 나누고, 각 셀에서 미리 설정된 경계 박스를 사용해 객체의 위치와 크기를 탐지한다. 경계 박스는 중앙 좌표(x, y), 너비와 높이(w, h)를 0~1로 정규화한 값, 그리고 신뢰도(confidence score)를 출력한다. 신뢰도는 식 1과같이 박스가 실제로 객체를 포함할 확률(Pr(Object))과 IOU(Intersection Over Union)을 곱한 값으로, IOU는 예측 박스와 실제 객체의 교집합 비율을 나타내며 값이 클수록 정확도가 높다.

YOLOv8 모델은 이미지를 한 번만 분석해 객체를 탐지하므로, 다른 모델에 비해 처리 속도가 빠르다. 이는 실시간 탐지가 필요한 상황에서 YOLO 모델이 효율성을 높일 수 있다는 것을 보여준다.

$$P_c = \text{Pr}(\text{Object}) * \text{IOU} \quad (34)$$

3.3 칼만 필터를 이용한 객체 추적

칼만 필터는 루돌프 칼만이 개발한 재귀적 필터로, 잡음이 포함된 선형 역학계의 상태를 추적하는데 사용된다. 이 필터는 과거와 현재의 값을 바탕으로 최적값을 예측한다. 칼만 필터는 두 가지 가정하에 적용 가능하다. 첫째는 모션 및 측정 모델이 선형적이고, 둘째는 가우시안 분포를 따른다는 점이다. 이 가정을 활용하여 동영상에서의 객체 추적에도 적용할 수 있다. 동영상은 여러 프레임으로 구성되며, 프레임 간 객체를 탐지할 때 경계 박스의 오차가 발생할 수 있다. 칼만 필터는 이러한 오차를 줄이기 위해 이전 프레임의 경계 박스 위치와 속도를 기반으로 다음 프레임의 위치를 선형적으로 예측한다. 칼만 필터 알고리즘의 흐름은 그림 3과 같다. 측정값(Measured Value)이 입력되면 알고리즘 내부에서 연산 후 추정값(Estimated Value)을 출력한다.

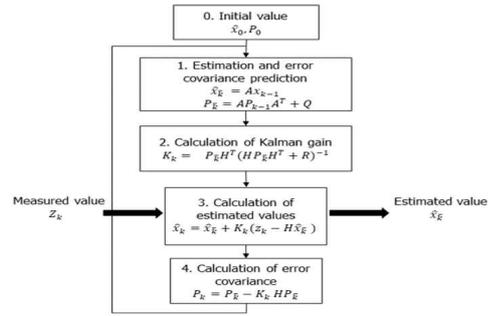


그림 3. 칼만 필터의 흐름도[16]
Fig. 3. Flow chart of Kalman filter[16]

그림 3의 과정 1에서는 직전 추정값(\hat{x}_{k-1})과 오차 공분산(P_{k-1})이 입력되면 현재 추정값 \hat{x}_k 와 추정값에 대한 오차 공분산인 P_k 를 계산하는 예측 과정을 수행한다. 이 때 오차 공분산은 추정값이 얼마나 정확한지 판단하는 척도로 사용된다. 과정 2에서는 칼만 이득(K_k)을 계산한다. 과정 2의 식을 전개해보면 다음과 같다.

$$K_k = \frac{P_k}{P_k + R} \quad (2)$$

해당 칼만 이득을 통해 과정 3에서 측정값과 예측값에 대한 가중치를 결정한다. 과정 4에서는 칼만 이득을 이용하여 오차 공분산을 계산한 후 과정 1의 예측 단계로 넘겨준다. 이러한 흐름을 통해 오차 공분산을 최적화하게 된다[16].

본 연구에서 칼만 필터를 적용시키기 위해 그림 3에서의 A값을 상태 전이 행렬(State Transition Matrix)로 표현하였으며, 이는 탐지된 객체의 현재 상태에서 다음 상태로의 이동을 표현한다.

$$A = \begin{bmatrix} 1 & 0 & dt & 0 \\ 0 & 1 & 0 & dt \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \quad (3)$$

또한 현재 상태에 대한 상태 변수 x에 탐지된 객

체의 x, y 좌표와 속도위반 정보를 적용한다.

$$x = \begin{bmatrix} x \\ y \\ v_x \\ v_y \end{bmatrix} \quad (4)$$

맨 처음 객체가 탐지될 때에는 속도를 알지 못하므로 초기 속도값은 0으로 초기화한다. 그 후 재귀적으로 x 와 A의 행렬곱을 진행하여 현재 상태 x 를 다음 상태로 예측한다. 식 3의 dt 는 시간 변화를 나타내며, 첫 번째 행과 두 번째 행에서 dt 가 곱해지는 것은 위치가 시간에 따라 속도만큼 변화하는 것을 나타낸다. 예를 들어 현재 프레임에서의 위치 x 는 이전 위치와 $dt \cdot v_x$ 를 더하여 업데이트한다. 그 후 그림 3과 같은 과정을 진행함으로써 객체의 움직임을 추적하고 예측한다. 이때 시간에 따른 변화와 위치-속도 간의 관계를 고려하여 상태를 업데이트한다. 이를 통해 실시간 상황에서 객체를 보다 정확하게 추적할 수 있다.

3.4 객체의 깊이 추정

본 연구에서는 객체의 위치와 속도뿐만 아니라 깊이 정보를 추가로 추정하여 2차원 영상에서 감지된 객체의 거리 정보를 파악하고자 한다. 깊이 추정은 Stereo 방식과 Mono 방식으로 나뉘며, Stereo 방식은 두 장의 이미지를 사용해 시차(disparity)를 계산해 깊이를 추정한다. 반면 Mono 방식은 단일 이미지로 시차를 추정하며, 본 연구에서는 Mono 방식을 채택하고 MiDaS 모델을 활용한다.

MiDaS 모델은 다양한 환경에서 훈련된 Mono Depth Estimation 모델로, 실내외 환경, 조명 조건, 시각적 노이즈 등 다양한 상황에서도 높은 정확도를 제공한다. 이를 통해 복잡한 도시 환경에서 이동수단과 보행자가 혼재된 상황에서도 신뢰성 있는 깊이 추정이 가능하다[17].



그림 4. 원본 영상과 깊이 추정 맵 예시
Fig. 4. Example of original image and depth map

해당 모델의 입력에 사진을 넣으면 그림 3의 우측 사진과 같이 입력된 사진의 깊이를 추정하여 깊이 맵(Depth Map)을 생성한다. 가까이 있는 물체일수록 밝게, 멀리 있는 물체일수록 어둡게 표현하였다. 깊이 맵에서는 각각의 좌표에 모두 깊이 추정값이 저장되어 있어 객체가 탐지되면 해당 객체 경계 박스의 좌표를 활용하여 객체의 깊이를 알아낼 수 있다. 또한 탐지된 특정 객체들의 각 깊이 값을 특정 프레임마다 추정하여 깊이 변화율도 계산할 수 있다.

3.5 객체의 크기 변화율 계산

객체가 보행자에게 다가올 경우, 그림 4와 같이 탐지된 객체의 경계 박스 크기가 점점 커진다. 이를 활용해 프레임 단위로 객체의 크기 변화율을 계산하여 접근 여부를 판단한다.

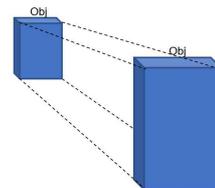


그림 5. 객체 크기 증가 예시
Fig. 5. Example of increasing object size

단, 새로 탐지된 객체는 초기 값의 혼란을 방지하기 위해 변화율 계산에서 제외한다. 또한 경계 박스의 미세한 오차로 인한 착각을 줄이기 위해 변화율 계산은 3프레임마다 수행한다. 객체의 크기 변화율 ΔS 는 식 5과 같다.

$$\Delta S = \frac{S_{current} - S_{previous}}{S_{previous} + \epsilon} \quad (5)$$

크기 변화율은 식 5와 같이 경계 박스의 가로, 세로 길이로 구한 넓이를 기반으로 계산한다. 이때 경계 박스 크기가 증가할 경우에만 양수로 계산되며, 감소 시에는 0으로 설정한다. 또한 division by zero 오류를 방지하기 위해 1×10^{-5} 의 작은 상수 ϵ 를 추가하였다.

3.6 위험도 계산

객체의 위험도는 칼만 필터로 추정된 위치, MiDaS 모델로 얻은 깊이, 객체의 크기 변화율, 깊이 변화율을 가중치와 합산하여 계산하며, 여기에 GloSea6로 예측한 기상 수치를 반영해 기상 상황에 따른 위험도를 종합적으로 평가한다. [11]의 연구에서는 객체의 경계 박스 변화율과 위치 변화율, 방향 계수를 사용하여 위험도를 측정했으나, 본 연구에서는 객체의 경계 박스 변화율과 위치 벡터를 기반으로 코사인 유사도를 계산하고, 깊이 변화율까지 반영한다.

$$\vec{d}_{direction} = \vec{p}_{current} - \vec{p}_{previous} \quad (6)$$

감지된 객체의 방향 벡터는 수식 6과 같이 객체 경계 박스의 중심 벡터인 $\vec{p}_{current}$ 와 3프레임 이전 위치인 $\vec{p}_{previous}$ 를 이용하여 계산한다. 또한 카메라 중심 벡터는 수식 7과 같이 카메라의 중심 좌표 \vec{p}_{camera} 를 기준으로 객체의 현재 위치를 연결하는 벡터이다.

$$\vec{d}_{camera} = \vec{p}_{camera} - \vec{p}_{current} \quad (7)$$

그 후 두 벡터가 이루는 각에 대한 $\cos\theta$ 값은 수식 8과 같이 구할 수 있다.

$$\cos\theta = \frac{\vec{d}_{direction} \cdot \vec{d}_{camera}}{|\vec{d}_{direction}| \cdot |\vec{d}_{camera}|} \quad (8)$$

수식 8의 분자는 두 벡터의 내적을 나타내며, $\cos\theta$ 값이 양수일 경우 두 벡터가 예각을 이루고, 음수일 경우 둔각을 이룬다. 객체의 방향 벡터는 현재 프레임과 이전의 프레임을 통해 벡터의 방향이 결정되므로 두 벡터가 이루는 각이 예각이면 객체가 카메라로 다가오고, 둔각이면 멀어지는 것을 의미한다. 본 연구에서는 객체가 다가오는 경우에만 코사인 유사도를 측정하여 위험도를 계산한다.

$$Risk = \cos\theta * w_{\cos\theta} + D(\Delta S * w_{\Delta S} + S * w_S) + \Delta D * w_{\Delta D} + C \quad (9)$$

식 9에서 w 는 각 요소들에 대한 가중치를 의미하며, 모든 가중치의 합은 1이다. 객체의 크기인 S 와 크기 변화량 ΔS 는 객체의 Depth와 정비례하므로 각각을 곱해준다. ΔD 는 객체의 깊이 변화율을 나타낸다. C 는 GloSea6 모델로 예측한 기상 예측 수치를 나타낸다. 따라서 식 9의 가중치를 어떻게 설정하는지에 따라 위험 예측 성능이 달라질 수 있다.

4. 실험 및 실험결과

4.1 실험 환경

본 연구의 실험에 사용된 자세한 실험 환경은 표 1과 같다.

표 1. 실험 환경
Table 1. Experimental environment

	Specifications
OS	Ubuntu 22.04.3 LTS
CPU	Intel(R) Xeon(R) Gold 6246R CPU @ 3.40GHz
Memory	256GB
IDE	Visual Studio Code 1.76.2
Program Language	Python 3.10.13
Module	Numpy, Matplotlib, Ultralytics, OpenCV, PyTorch

실험에 사용된 데이터셋은 AI-Hub의 ADAS AI 인지모델 학습용 데이터로, 차량, 보행자, 개인형 이동장치 등의 객체를 포함한 이미지 600,412장 중 개인형 이동장치가 포함된 6,000장을 추출했다. 이 중 경계 박스가 큰 이미지를 3,176장 선별하여 학습에 사용하였다. 각 이미지는 여러 클래스를 포함하며, 이륜차 클래스에 속하는 자전거, 오토바이, 개인형 이동수단을 탐지하기 위해 해당 클래스가 포함된 이미지를 추출했다. 이후, 객체들의 경계 박스 네 꼭짓점 좌표를 바탕으로 중심점 좌표를 계산하여 YOLOv8 모델에 맞게 전처리했다.



그림 6. 원천 데이터셋 예시
Fig. 6. Example of a source dataset

YOLOv8 모델의 라벨 데이터 형식은 클래스 번호, 경계 박스 중심점 x, y 좌표, 가로 및 세로 크기로 이루어져 있으며, 학습에 사용된 클래스는 자동차, 사람, 자전거, 오토바이, 개인형 이동장치 5개이다. 기존 모델에는 전동 킥보드 클래스가 없어 이를 추가했다. 원본 이미지는 1920x1080 크기였으나, YOLOv8 모델에 맞게 640x640으로 크기를 조정하여 학습시켰다. 이 과정에서 모델은 원본 영상의 화면비율을 유지하는 방식을 사용하며, 부족한 영역은 검정색 여백(padding)으로 채워진다. 따라서 원본 영상의 일부를 자르거나 왜곡하지 않고 크기를 변환한다. 이러한 변환 방식은 객체 탐지 성능에 미치는 영향이 최소화되도록 설계되었다. 학습에 사용된 YOLOv8m 모델의 성능은 50번 Epoch에서 가장 높았다.

```

{"id": "246be6f18c9fd25f99f7e05f8e217a778e2a90cf7eaf00f47ce0c42065ee2d4",
 "type": "bbox",
 "attributes1": "일반자전거",
 "attributes2": "경차/세단",
 "points1": "199,548",
 "points2": "587,548",
 "points3": "587,696",
 "points4": "199,696",
 0 0.37213541666666666 0.7509259259259259 0.043229166666666666 0.06666666666666667
 0 0.4513020833333333 0.8842592592592593 0.2942708333333333 0.23148148148148148
 1 0.31822916666666667 0.7296296296296296 0.010416666666666666 0.04814814814814815
 1 0.33203125 0.7314814814814815 0.011979166666666667 0.04814814814814815
 4 0.165625 0.862037037037037 0.1375 0.2759259259259259
 0 0.4041666666666667 0.7310185185185185 0.034375 0.025
    
```

그림 7. 라벨링 데이터와 전처리된 데이터
Fig. 7. Labeled data and preprocessed data

입력 영상의 FPS는 30FPS, 1프레임 당 시간은 0.3333초였다. 객체의 경계 박스 변화율을 1초마다 측정하기 위해 3프레임 주기로 업데이트하였다. 시각장애인의 평균 보행속도는 0.68m/s로 가정하고 [7], 이를 기준으로 100명의 보행자에 대해 평균 박스 크기 변화율을 측정하여 위험 요소를 판단하였다. 보행자의 박스 변화율은 0.3에 수렴하며, 이 값 이상일 때만 위험 요소로 인식했다. 또한, YOLOv8 모델에서 탐지한 객체의 정확도가 0.6 이상일 때만 경계 박스를 그리도록 하여 정확도를 높였다.

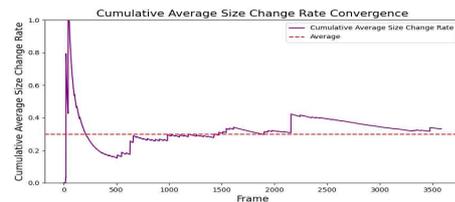


그림 8. 보행자의 평균 경계 박스 변화율
Fig. 8. The average bounding box change rate of pedestrians

그림 7의 y축은 보행자의 평균 박스 크기 변화율을 나타내며, x축은 프레임의 의미를 나타낸다. 변화율은 0.3에 수렴하고, 이를 기준으로 위험 객체의 변화율 임계값을 0.3으로 설정했다. 0.3 이하의 객체는 느리게 다가와 위험도가 낮다고 판단한다. 또한, YOLOv8 모델에서 정확도가 0.6 이상인 객체만 탐지하여 경계 박스를 그리도록 하여 불필요한 객체 인식을 방지했다.

4.2 실험 결과 및 평가

본 연구에서는 YOLOv8 모델을 학습시킨 결과를 mAP50 수치로 평가했다. mAP50은 평균 정밀도(IoU) 임계값 0.50에서 계산된 값으로, mAP50-95는 더 엄격한 평가지표이다.

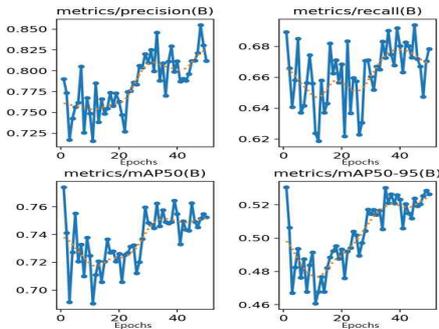


그림 9. 전체 학습 결과
Fig. 9. Overall learning results

그림 8은 YOLOv8 모델의 학습 결과를 나타내며, x축은 Epoch, y축은 성능 지표를 보여준다. precision은 0.81188, recall은 0.6784를 기록했다. mAP50 수치는 0.774였고, 자동차 0.903, 사람 0.80, 자전거 0.609, 개인형 이동장치 0.717, 오토바이 0.842의 성능을 보였다.

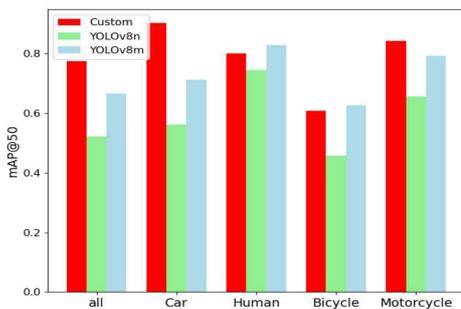


그림 10. 클래스별 성능 비교
Fig. 10. Class-by-class performance comparison

그림 9는 본 연구에서 커스텀한 YOLO 모델과 기존 YOLOv8 모델의 mAP50 수치를 비교한 그래프이다. 커스텀 모델은 mAP50 수치가 0.774로, 기

존 YOLOv8n 모델(0.521)과 YOLOv8m 모델(0.667)보다 높았다.

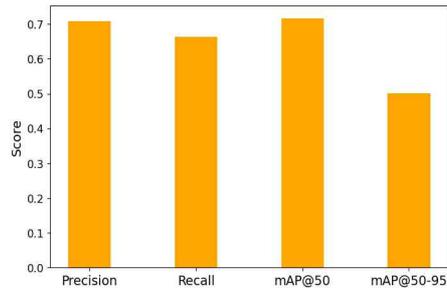


그림 11. 개인형 이동장치 클래스 학습 결과
Fig. 11. Personal mobility class learning outcomes

그림 10은 개인형 이동장치 클래스를 추가로 학습시킨 결과로, Precision Score는 0.708, Recall은 0.664, mAP50은 0.717, mAP50-95는 0.502였다. 이를 종합적으로 비교한 그림 11에서, 커스텀 모델의 mAP50 수치가 가장 높아 보행 상황에서 위험 요소를 판단하는 객체 탐지 성능이 뛰어남을 알 수 있다.

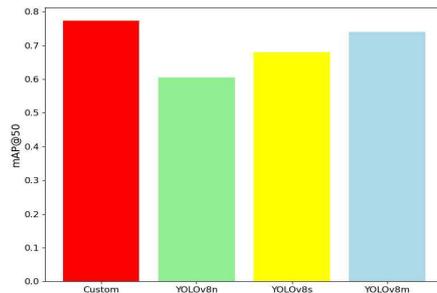


그림 12. mAP50 성능 평가 비교
Fig. 12. mAP50 performance evaluation comparison

그림 12에서는 모델을 통해 객체를 탐지하고, 칼만 필터를 이용하여 추적하여 속도와 방향 요소를 고려하며 깊이를 추정 후 위험도를 평가하여 시각 장애인 시점에서 위험하다고 평가되는 요소의 경계 박스를 빨간색으로 시각화하였다.



그림 13. 객체 탐지 및 추적 영상 캡처
Fig. 13. Object Detection and Tracking Video Capture

위험도 평가는 식 9를 이용하여 계산하였으며, [11]에서는 크기 변화율에 대한 가중치를 0.5, 위치 변화율에 대한 가중치를 0.3333, 방향 계수에 대한 가중치를 0.167로 지정하였다. 본 연구에서는 객체의 깊이를 고려해 가중치를 재설정하였다. 크기 변화율에는 0.5, 위치 변화율 0.3333, 깊이 변화율에 0.0835를 부여하였으며, 크기 변화율과 객체 크기 값에 Depth를 곱하여 계산하였다. 그림 14는 GloSea6로 예측한 눈 관련 기상 상황을 히트맵으로 나타낸 예시이다.

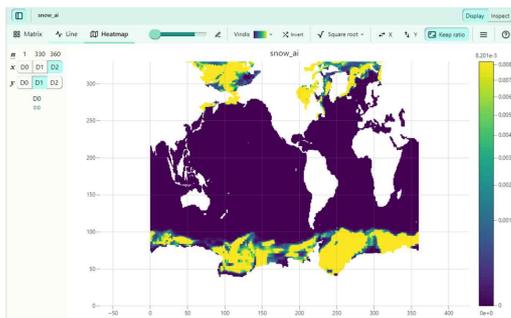


그림 14. GloSea6 기상 예측 히트맵
Fig. 14. GloSea6 Weather Forecast Heatmap

따라서 위험도에 GloSea6로 예측한 현재의 기상 예측 수치를 추가로 반영하였다. 위험도 값은 100에서 1,000 사이로, 1,000을 초과하는 객체를

위험한 객체로 판단하였다. 또한, 객체의 깊이는 가까운 객체일수록 커지고, 이를 기준으로 위험한 객체는 빨간색 경계 박스로 표시하고, 종류와 식별 번호를 화면에 나타내며, 음성 메시지로 출력할 수 있다.

5. 결론

기상 변화는 보행자와 개인형 이동수단 간 사고 위험을 증가시키는 중요한 요인으로, 돌발적인 기상 상황이 객체 탐지와 시스템 성능에 미치는 영향을 고려하는 것이 필수적이다. 본 연구는 GloSea6와 같은 기상 예측 모델을 활용하여 기상 변화에 따른 사고 위험을 사전에 예측하고 경고할 수 있는 가능성을 제시했다.

본 연구는 시각장애인의 보행 환경에서 잠재적 위험 요소를 탐지하고 평가하기 위해 YOLOv8 모델을 기반으로 한 객체 탐지 시스템을 개발했다. 개인형 이동수단 클래스를 추가한 YOLOv8 모델은 mAP50에서 평균 0.774의 성능을 보였으며, 개인형 이동수단 클래스는 0.717로 높은 정확도를 기록했다. 모델은 객체 탐지 후 경계 박스를 생성하고, 칼만 필터로 객체의 이동 경로를 추적했다. 또한 크기 변화율, 객체 깊이, 이동 방향을 고려해 위험도를 평가했다.

실험 결과, 시스템은 위험한 객체를 효과적으로 식별하고 시각화했으며, 음성 메시지로 시각장애인에게 위험 정보를 전달할 가능성도 확인했다. 그러나 현재 시스템은 다양한 악천후 상황에 대한 데이터셋을 충분히 시뮬레이션하지 않아, 비, 눈, 안개와 같은 기상 조건에서 객체 탐지 성능이 저하될 가능성이 있다. 이러한 한계를 극복하기 위해 악천후를 포함한 다양한 기상 조건을 시뮬레이션한 데이터셋을 추가적으로 학습에 반영할 필요가 있다. 또한, GloSea6로 예측한 기상 수치를 위험도 평가뿐만 아니라 객체 탐지 과정에서도 활용한다면, 기상 상황에 따른 탐지 정확도를 더욱 향상시켜 보다 정밀한 위험 예측이 가능할 것으로 기대된다. 또한, 음성 전달 시스템을 추가해 실시간 대응이 가능하도록 할 예정이다.

REFERENCES

[1] S. Kang and S. Kang, "A Study on Major Safety

- Problems and Improvement Measures of Personal Mobility," Journal of the Society of Disaster Information, Vol. 18, No. 1, pp. 202-217, 2022.
- [2] H. Jo, H. Noh, H. Yoo, J. Kang, J. Jung and H. Kim, "A Study on the Use Behavior and Safety of Electric Scooters," The Geographical Journal of Korea, Vol. 55, No. 1, pp. 43-55, 2021.
- [3] D. Han, E. Kim and M. Ji, "Analysis of Severity Factors in Personal Mobility(PM) Traffic Accidents," Journal of Korean Society of Transportation, Vol. 38, No. 3, pp. 232-247, 2020.
- [4] J. Lim, "Results of the National Pedestrian Traffic Survey and Analysis of Factors Affecting Pedestrian Accidents," Proceedings of the KOR-KST Conference, 2023.
- [5] H. Park, Y. Ko, S. Lee, J. Jang and B. Lee, "Walking Assistance System for Visually Impaired People using Vultiple sensors," The Journal of the Korea institute of electronic communication sciences, Vol. 12, No. 4, pp. 533-538, 2017.
- [6] H. Kim, J. Lee, Y. Hyun and S. Hwang, "The KMA Global Seasonal forecasting system (GloSea6) - Part 1: Operational System and Improvements," Atmosphere. Korean Meteorological Society, Vol. 31, No. 3, pp. 341-359, 2021.
- [7] M. Kim, H. Ji, I. Kim, J. Lee and E. Kim, "A Study on Walking Speed of Visually Handicapped People in Welfare Center," Korean Institute of Fire Science & Engineering, pp. 324-327, 2011.
- [8] H. Kim and Y. Choi, "Study on the Development of Working Safety Device for Visually Impaired Person," The Journal of Korea Institute of Information, Electronics, and Communication Technology, Vol. 9, No. 4, pp. 366-372, 2016.
- [9] S. Son, E. Jeong, H. Kim, "Object Detection for the Visually Impaired in a Voice Guidance System," Korea Information Processing Society, Vol. 30, No. 2, pp. 1206-1207, 2023.
- [10] P. R. Gunjal, B. R. Gunjal, H. A. Shinde, S. M. Vanam and S. S. Aher, "Moving Object Tracking Using Kalman Filter," 2018 International Conference On Advances in Communication and Computing Technology (ICACCT), Sangamner, India, pp. 544-547, 2018.
- [11] Lai Y-C and Lin T-Y, "Vision-Based Mid-Air Object Detection and Avoidance Approach for Small Unmanned Aerial Vehicles with Deep Learning and Risk Assessment," Remote Sensing, Vol. 16, No. 5, pp. 756, 2024.
- [12] Sharma T, Debaque B, Duclos N, Chehri A, Kinder B and Fortier P, "Deep Learning-Based Object Detection and Scene Perception under Bad Weather Conditions," Electronics, Vol. 11, No. 4, pp. 563, 2022.
- [13] D. Kumar, N. Muhammad, "Object Detection in Adverse Weather for Autonomous Driving through Data Merging and YOLOv8." Sensors, Vol. 23, No. 20, 2023.
- [14] M. Chen, J. Sun, K. Aida, A. Takefusa, "Weather-aware object detection method for maritime surveillance systems," Future Generation Computer Systems, Vol. 151, pp. 111-123, 2024.
- [15] J. Redmon, S. Divvala, R. Girshick and Ali Farhadi. "You Only Look Once: Unified, Real-Time Object Detection," 2016.
- [16] K. Kim, S. Son, M. Kim, J. Jeon, I. Lee, J. Cha and H. Choi, "Object Tracking Method using Deep Learning and Kalman Filter," Journal of broadcast engineering, Vol. 24, No. 3, pp. 495-505, 2019.
- [17] R. Ranftl, K. Lasinger, D. Hafner, K. Schindler and V. Koltun, "Towards Robust Monocular Depth Estimation: Mixing Datasets for Zero-Shot Cross-Dataset Transfer," in IEEE Transactions on Pattern Analysis & Machine Intelligence, Vol. 44, No. 3, pp. 1623-1637, 2022.

저자약력

김 남 규 (Nam-Gyu Kim)

[학생회원]



• 2020년 3월 ~ 현재: 창원대학교 학부 과정

〈관심분야〉 AI, 데이터 분석, 서버

박진성 (Jin-Seong Park)

[학생회원]



- 2022년 3월 ~ 현재: 창원대학교 학부 과정

〈관심분야〉 AI, 데이터 분석, 머신러닝

박혜성 (Hye-Sung Park)

[학생회원]



- 2020년 3월 ~ 2024년 2월: 창원대학교 학부 졸업
- 2024년 3월 ~ 현재: 창원대학교 석사 과정

〈관심분야〉 AI, 머신러닝, 데이터 분석

김성연 (Sung-Yeon Kim)

[학생회원]



- 2020년 3월 ~ 현재: 창원대학교 학부 과정

〈관심분야〉 IoT, 데이터 분석, 머신러닝

정성욱 (Sung-Wook Chung)

[종신회원]



- 2010년 8월: CISE dept. Univ. of Florida, USA, (Ph.D)
- 2012년 3월 ~ 현재: 창원대학교 컴퓨터공학과 정교수

〈관심분야〉 IoT, 스마트모빌리티, HPC, 실시간 분산 멀티미디어 시스템