

Robust Helmet-Based Worker Safety-State Recognition and Risk-Aware Decision Support for Industrial Safety Monitoring

Youngmi Baek*, Jung Kyu Park*

*Professor, Division of AI Convergence, Major in Computer Science, Daejin University, Pocheon-si, Korea

[Abstract]

This paper proposes a vision-based framework for worker safety-state recognition and risk-aware decision support using helmet detection. The proposed method classifies worker head regions into helmet and no-helmet states using YOLOv8-based object detection models and uses the detection results as input to a downstream decision module. Experiments on a public safety helmet dataset showed that YOLOv8s achieved the most balanced performance, with an mAP@50 of 0.933 and a no-helmet recall of 0.867, while robustness analysis showed that noise and occlusion caused the largest performance degradation. In the simulation-based downstream decision experiment, the proposed method reduced both safety violations and unsafe exposure time to zero under the tested simulation settings, while achieving a shorter completion time than the distance-only strategy. These results indicate that helmet-state recognition can provide useful contextual information for simulation-based industrial safety monitoring and risk-aware decision support.

▶ **Key words:** worker safety-state recognition, helmet detection, YOLOv8, risk-aware decision support, industrial safety monitoring

[요 약]

본 논문에서는 헬멧 검출을 활용한 영상 기반 작업자 안전상태 인식 및 위험 인지형 의사결정 지원 프레임워크를 제안한다. 제안 방법은 YOLOv8 기반 객체 검출 모델을 이용하여 작업자의 머리 영역을 helmet과 no-helmet 상태로 분류하고, 검출 결과를 후속 의사결정 모듈의 입력으로 사용한다. 공개 안전모 데이터셋을 이용한 실험에서 YOLOv8s는 mAP@50 0.933, no-helmet recall 0.867을 보여 가장 균형적인 성능을 보였으며, 강건성 분석에서는 노이즈와 가림 조건에서 가장 큰 성능 저하가 나타났다. 시뮬레이션 기반 후속 의사결정 실험에서 제안 방법은 안전 조건 위반(safety violation)과 위험 노출 시간(unsafe exposure time)을 테스트한 시뮬레이션 조건에서 모두 0으로 줄였고, 거리 기반(distance-only) 방식보다 짧은 완료 시간을 보였다. 이러한 결과는 헬멧 착용 상태 인식이 시뮬레이션 기반 산업 안전 모니터링과 위험 인지형 의사결정 지원에 유용한 문맥 정보를 제공할 수 있음을 보여준다.

▶ **주제어:** 작업자 안전상태 인식, 헬멧 검출, YOLO 기반 객체 검출, 위험 인지형 의사결정 지원, 산업 안전 모니터링

-
- First Author: Youngmi Baek, Corresponding Author: Jung Kyu Park
 - *Youngmi Baek (ymbaek@daejin.ac.kr), Division of AI Convergence, Major in Computer Science, Daejin University
 - *Jung Kyu Park (jkpark@daejin.ac.kr), Division of AI Convergence, Major in Computer Science, Daejin University
 - Received: 2026. 06. 01, Revised: 2026. 07. 01, Accepted: 2026. 07. 06.

I. Introduction

산업 및 건설 현장에서는 작업자, 장비, 이동 기계가 동일한 공간에서 함께 운용되는 경우가 많다. 이러한 환경에서는 작업자와 기계 사이의 물리적 거리뿐만 아니라, 작업자가 적절한 개인보호장비(Personal Protective Equipment, PPE)를 착용하고 있는지도 중요한 안전 판단 요소가 된다. 특히 안전모는 작업자의 보호 상태를 시각적으로 확인할 수 있는 대표적인 PPE이므로, 영상 기반 헬멧 착용 상태 인식은 산업 안전 모니터링을 위한 핵심 인식 기능으로 활용될 수 있다 [1-3].

최근 딥러닝 기반 객체 검출 기술의 발전으로 작업자의 PPE 착용 여부를 자동으로 인식하는 연구가 활발히 진행되고 있다. 기존 연구들은 안전모, 조끼, 마스크 등 다양한 PPE를 영상에서 검출하고, 이를 통해 현장 안전 준수 여부를 평가하는 데 초점을 두었다 [1-5]. 또한 YOLO 계열 모델은 높은 검출 성능과 빠른 추론 속도를 바탕으로 실시간 안전 모니터링 분야에 널리 활용되고 있다 [7,8]. 최근에는 YOLOv8 기반 PPE 검출을 edge device에 적용하여 실시간 건설 현장 안전 분석에 활용하려는 연구도 보고되었다 [9].

그러나 기존의 PPE 및 헬멧 검출 연구는 대부분 작업자가 보호장비를 착용했는지를 판별하거나 경고를 발생시키는 시각적 준수 여부 검사에 머무르는 경우가 많다. 이러한 방식은 안전 모니터링에 유용하지만, 검출 결과가 실제 위험 판단이나 후속 의사결정에 충분히 활용되지는 않는다. 예를 들어 동일한 거리에 있는 작업자라도 헬멧을 착용한 경우와 착용하지 않은 경우의 위험 수준은 다르게 해석될 수 있다. 따라서 헬멧 착용 상태 인식 결과를 단순 검출 결과로만 사용하는 것이 아니라, 작업자 위치와 결합하여 위험 인지형 의사결정에 활용할 필요가 있다 [6].

또한 실제 산업 현장에서는 조명 변화, 영상 노이즈, 카메라 흔들림, 작업자 간 가림과 같은 다양한 시각적 품질 저하가 발생할 수 있다. 최근 PPE 인식 관련 리뷰 연구에서도 실제 산업 적용을 위해서는 단일 데이터셋에서의 검출 성능뿐 아니라, 환경 변화에 대한 강건성 검증과 통합적인 안전 모니터링 파이프라인이 필요하다고 지적하였다 [6]. 따라서 헬멧 착용 상태 인식 모델은 원본 이미지에서의 정확도뿐만 아니라, 실제 현장 조건을 고려한 강건성 측면에서도 평가될 필요가 있다.

인간-기계 및 인간-로봇 상호작용 분야에서는 작업자와 시스템 간 거리, 보호 영역, 속도 조절, 정지 조건 등이 안전 의사결정의 핵심 요소로 다루어져 왔다 [11-16]. 이러

한 거리 기반 안전 판단은 해석이 쉽고 구현이 단순하다는 장점이 있지만, 작업자의 PPE 착용 상태를 직접 반영하지는 못한다. 따라서 거리 정보와 헬멧 착용 상태 정보를 함께 고려하면 작업자 보호 상태에 따른 위험도 기반 안전 대응이 가능하다.

본 연구에서는 딥러닝 기반 헬멧 착용 상태 인식 결과를 위험 인지형 의사결정에 연결하는 프레임워크를 제안한다. 제안 방법은 먼저 YOLOv8 계열 객체 검출 모델을 이용하여 작업자의 머리 영역을 helmet 또는 no-helmet 상태로 분류한다. 이후 검출된 바운딩 박스와 신뢰도 정보를 작업자 상태 변수로 변환하고, 작업자와 시스템 간 거리, 헬멧 착용 여부, 검출 신뢰도를 결합하여 위험도를 계산한다. 최종적으로 계산된 위험도에 따라 정상 동작, 감속, 정지 중 하나의 안전 대응을 선택한다.

본 연구가 갖는 주요 차별성과 학술적 기여도는 다음과 같이 세 가지로 요약할 수 있다. 첫째, YOLOv8 계열 모델을 이용한 헬멧 착용 상태 인식 성능을 비교하였다. 둘째, 저조도, 블러, 노이즈, 가림 조건에서 모델의 강건성을 분석하였다. 셋째, 헬멧 착용 상태와 거리 정보를 결합한 위험 인지형 의사결정 모듈을 제안하고 ablation 분석을 통해 구성요소의 효과를 확인하였다.

II. Related Work

1. Vision-Based PPE and Helmet Detection

산업 및 건설 현장에서 작업자의 개인보호장비 착용 여부를 자동으로 인식하기 위한 연구는 딥러닝 기반 객체 검출 기술의 발전과 함께 활발히 진행되어 왔다. 기존 연구들은 안전모, 조끼, 마스크 등 다양한 PPE를 영상에서 검출하고, 이를 통해 현장 안전 준수 여부를 평가하는 데 초점을 두었다 [1-6]. 특히 헬멧 착용 상태 인식은 작업자의 보호 상태를 직관적으로 판단할 수 있기 때문에 산업 안전 모니터링에서 중요한 응용 분야로 다루어지고 있다.

최근에는 YOLO 계열 모델이 높은 검출 성능과 빠른 추론 속도를 바탕으로 실시간 안전 모니터링에 널리 활용되고 있다 [7,8]. 또한 YOLOv8 기반 PPE 검출을 edge device에 적용하여 실제 건설 현장 안전 분석에 활용하려는 연구도 보고되었다 [9]. 그러나 기존 연구는 주로 PPE 착용 여부 판별과 경고 생성에 초점을 두며, 검출 결과를 후속 위험 판단에 직접 연결하는 연구는 상대적으로 제한적이다.

또한 실제 산업 현장에서는 저조도, 블러, 영상 노이즈,

작업자 가림과 같은 시각적 품질 저하가 빈번하게 발생할 수 있다. 최근 리뷰 연구에서도 PPE 인식 시스템의 실제 적용을 위해서는 다양한 환경 변화에 대한 강건성 평가가 필요하다고 지적하였다 [6]. 따라서 본 연구에서는 헬멧 착용 상태 인식 성능뿐만 아니라, 시각 조건 변화에 따른 모델의 강건성도 함께 분석한다.

2. Safety-Aware Decision Support

작업자 안전 모니터링은 단순한 객체 검출을 넘어, 인식 결과를 기반으로 실제 시스템이 어떻게 반응할 것인지 결정하는 문제와 연결된다. 인간-기계 및 인간-로봇 상호작용 분야에서는 작업자와 시스템 간 거리, 보호 영역, 속도 조절, 정지 조건 등이 안전 의사결정의 핵심 요소로 다루어져 왔다 [11-16]. 이러한 거리 기반 안전 판단은 해석이 쉽고 구현이 단순하다는 장점이 있다. 최근 Speed and Separation Monitoring (SSM) 관련 연구에서도 perception system을 이용해 인간-로봇 간 이격 거리와 속도 조건을 모니터링하고, 이에 따라 로봇 속도 조절 또는 안전 정지를 수행하는 구조가 강조되고 있다 [16].

그러나 거리 기반 방식은 작업자의 보호장비 착용 상태를 직접 반영하지 못한다. 예를 들어 같은 거리에 있는 작업자라도 헬멧을 착용한 경우와 착용하지 않은 경우의 위험 수준은 다르게 해석될 수 있다. 따라서 작업자의 위치 정보뿐 아니라 헬멧 착용 상태와 같은 문맥 정보를 함께 고려하는 의사결정 방식이 필요하다.

본 연구는 기존의 PPE 검출 연구와 거리 기반 안전 판단 연구를 연결하여, 헬멧 착용 상태 인식 결과를 위험 인지형 의사결정에 활용하는 프레임워크를 제안한다. 이를 통해 단순히 헬멧 착용 여부를 검출하는 데 그치지 않고, 검출 결과가 후속 안전 의사결정에 어떤 영향을 주는지 분석한다.

III. Research Method

1. Overall Framework

본 연구는 작업자 이미지에서 헬멧 착용 상태를 인식하고, 그 결과를 위험 인지 의사결정에 활용하는 프레임워크를 제안한다. 기존의 PPE 검출 연구는 주로 작업자가 보호장비를 착용했는지 여부를 판별하거나 경고를 발생시키는 데 초점을 두었다 [1-3]. 반면 본 연구는 검출 결과를 단순 모니터링 정보로 사용하는 데 그치지 않고, 작업자 상태를 의사결정 모듈의 입력으로 변환하고, 이를 기반으

로 안전 대응 수준을 결정한다.

제안 방법은 크게 세 단계로 구성된다. 첫째, YOLOv8 기반 객체 검출 모델을 사용하여 작업자의 머리 영역을 helmet 또는 no-helmet 상태로 분류한다. YOLO 계열 모델은 실시간 객체 검출에서 정확도와 추론 속도의 균형이 우수하여 산업 현장 모니터링에 적합한 구조로 활용되어 왔다 [7,8]. 둘째, 검출된 바운딩 박스 정보를 이용하여 작업자의 횡방향 위치와 전방 거리를 단순 추정한다. 셋째, 작업자와 시스템 간 거리, 헬멧 착용 상태, 검출 신뢰도를 결합하여 위험도를 계산하고, 이에 따라 정상 동작, 감속, 정지 중 하나의 의사결정을 수행한다.

본 연구에서는 복잡한 제어기 설계보다, 딥러닝 기반 안전상태 인식 결과가 후속 안전 의사결정 성능에 미치는 영향을 평가한다. 따라서 제안 프레임워크는 단순하고 해석 가능한 형태로 구성하였다. Fig. 1은 본 연구에서 제안하는 인식-의사결정 연계 프레임워크의 전체 구조를 나타낸다.




Fig. 1. Overall framework of the proposed recognition-to-decision pipeline.

2. Worker Safety-State Recognition

작업자 안전상태 인식 단계에서는 YOLOv8 계열 객체 검출 모델을 사용하였다. 모델의 입력은 산업 또는 건설 현장 이미지이며, 출력은 각 객체의 클래스, 신뢰도, 바운딩 박스 좌표이다. 본 연구에서는 일본 데이터셋의 helmet과 head 클래스를 각각 helmet과 no-helmet 상태로 재정의하였다.

본 데이터셋에서 head 클래스는 helmet으로 주석 처리되지 않은 작업자 머리 영역을 나타내며, PPE 착용 상태 인식 관점에서는 헬멧이 없는 작업자 머리로 해석할 수 있다. 따라서 본 연구에서는 helmet 클래스를 보호 상태, head 클래스를 헬멧 미착용 상태로 정의하였다. 다만 원본 주석 특성상 일부 애매한 머리 영역이나 부분 가림 사례가 포함될 가능성이 있으므로, 본 연구의 no-helmet 변환은 해당 공개 데이터셋의 annotation 정의에 기반한 label mapping으로 제한된다.

검출 모델은 각 객체 i 에 대해 다음과 같은 출력을 생성한다.

$$d_i = \{c_i, s_i, b_i\} \quad (1)$$

여기서 c_i 는 예측 클래스이며, $c_i \in \{\text{helmet}, \text{no-helmet}\}$ 이다. s_i 는 검출 신뢰도이고, $b_i = (x_i, y_i, w_i, h_i)$ 는 정규화된 바운딩 박스 중심 좌표와 너비, 높이를 의미한다. 본 연구에서는 no-helmet 클래스를 안전상 더 중요한 상태로 간주한다. 이는 헬멧 미착용 작업자의 미검출은 위험 판단 지연으로 이어질 수 있기 때문이다. 따라서 이후 의사결정 단계에서는 단순 객체 위치뿐 아니라 헬멧 착용 여부를 함께 반영한다.

3. Detection-to-State Representation

객체 검출 결과를 의사결정 모듈에서 사용하기 위해서는 이미지 좌표를 작업자 상태 변수로 변환해야 한다. 본 연구에서는 실제 3차원 위치 추정 장비를 사용하지 않고, 단일 이미지 기반의 단순 근사 방법을 사용하였다. 이는 제안 프레임워크의 초기 검증을 위한 경량 구조이며, 향후 depth 카메라나 다중 카메라 기반 위치 추정으로 확장할 수 있다.

먼저 바운딩 박스의 수평 중심 좌표 x_i 를 이용하여 작업자의 횡방향 위치 l_i 를 계산한다.

$$l_i = (x_i - 0.5) W_{lane} \quad (2)$$

여기서 W_{lane} 는 가정한 작업 공간의 폭을 의미한다. 이미지 중심에 가까운 객체는 운용 경로에 가까운 작업자로 해석하고, 이미지 좌우에 위치한 객체는 상대적으로 경로에서 떨어진 작업자로 해석한다.

전방 거리 f_i 는 바운딩 박스의 높이와 수직 중심 위치를 이용하여 근사하였다. 일반적으로 작업자가 카메라에 가까울수록 이미지에서 더 크게 나타나고, 화면 하단에 가까워지는 경향이 있다. 이를 반영하기 위해 다음과 같이 근접도 점수(closeness score) γ_i 를 정의하였다.

$$\gamma_i = \alpha \min\left(\frac{h_i}{h_{ref}}, 1\right) + (1 - \alpha)y_i \quad (3)$$

여기서 h_{ref} 는 기준 바운딩 박스 높이이고, α 는 바운딩 박스 높이와 수직 위치의 반영 비율을 조절하는 계수이다. 이후 전방 위치는 다음과 같이 계산한다.

$$f_i = f_{\max} - \gamma_i(f_{\max} - f_{\min}) \quad (4)$$

여기서 $f_{\min}$ 과 $f_{\max}$ 는 시뮬레이션에서 사용하는 최소 및 최대 전방 거리이다.

최종적으로 각 작업자 상태는 다음과 같이 표현된다.

$$z_i = \{l_i, f_i, p_i, s_i\} \quad (5)$$

여기서 p_i 는 헬멧 착용 상태를 나타내는 이진 변수이다. $p_i = 1$ 이면 헬멧 착용 작업자이고, $p_i = 0$ 이면 헬멧 미착용 작업자이다.

4. Risk-Aware Decision Module

위험 인지 의사결정 모듈은 작업자의 위치와 헬멧 착용 상태를 함께 고려하여 위험도를 계산한다. 먼저 시스템의 현재 전방 위치를 r 이라고 할 때, 작업자 i 와 시스템 사이의 거리는 다음과 같이 계산한다.

$$\delta_i = \sqrt{(f_i - r)^2 + l_i^2} \quad (6)$$

작업자가 가까울수록 위험도가 증가하도록 거리 기반 위험도 $R_i^{(d)}$ 를 다음과 같이 정의한다.

$$R_i^{(d)} = \max\left(0, \frac{D_{\infty} - \delta_i}{D_{\infty}}\right) \quad (7)$$

여기서 D_{inf} 는 작업자가 시스템의 의사결정에 영향을 주는 최대 거리이다.

최종 작업자 위험도 R_i 는 거리 위험도, 헬멧 미착용 패널티, 검출 신뢰도, 그리고 운용 경로 내 헬멧 미착용 작업자에 대한 추가 위험 항을 결합하여 계산한다.

$$R_i = w_d R_i^{(d)} + w_p(1 - p_i) + w_s(1 - s_i) + R_i^{(b)} \quad (8)$$

여기서 w_d , w_p , w_s 는 각각 거리 위험도, 헬멧 상태, 검출 신뢰도에 대한 가중치이다. $R_i^{(b)}$ 는 작업자가 운용 경로 내부에 있고 헬멧을 착용하지 않은 경우 추가되는 위험 항이다. 이 항은 단순히 헬멧 미착용 여부만 고려하는 것이 아니라, 미착용 작업자가 실제 운용 경로에 가까운지를 함께 반영하기 위해 사용된다.

본 연구에서는 거리 위험도, 헬멧 착용 상태, 검출 신뢰도에 대한 가중치를 각각 ($w_d=0.55$), ($w_p=0.40$), ($w_s=0.05$)로 설정하였다. 거리 항은 작업자와 시스템 간 근접성을 반영하는 기본 안전 요소이므로 가장 큰 비중을 부여하였다. 헬멧 상태 항은 보호장비를 착용하지 않은 작업자에 대한 대응 강도를 높이기 위해 두 번째로 큰 비중을 부여하였다. 검출 신뢰도 항은 인식 결과의 불확실성을 보조적으로 반영하기 위한 항이므로 상대적으로 작은 값으로 설정하였다. 또한 운용 경로 내 no-helmet 작업자에 대한 추가 위험 항 $R_i^{(b)}$ 는 0.12로 설정하였다. 이러한 파라미터는 실제 산업 현장 기준으로 최적화된 값이라기보다, 본 연구의 시뮬레이션 기반 초기 검증에서 해석 가능한 위험도 구성을 평가하기 위한 기본 설정이다.

장면 전체의 위험도는 활성 작업자 중 가장 큰 위험도로 정의한다.

$$R_{\max} = \max_i R_i \quad (9)$$

이는 단일 작업자의 위험 상태에도 전체 시스템이 즉각적으로 대응하도록 설계된 보수적 안전 기준을 반영한다. 인간-기계 또는 인간-로봇 상호작용 분야에서도 작업자와 시스템 간 거리, 보호 영역, 감속 및 정지 조건은 안전 의사결정의 핵심 요소로 다루어져 왔다 [11-16].

최종 의사결정은 정상 동작, 감속, 정지의 세 단계로 구성된다.

$$v = \begin{cases} 0, & \delta_{\min} \leq D_{\text{danger}} \text{ or } R_{\max} \geq T_{\text{stop}} \\ \eta_s v_{\max}, & \delta_{\min} \leq D_{\text{safe}} \text{ or } T_{\text{slow}} \leq R_{\max} < T_{\text{stop}} \\ v_{\max}, & \text{otherwise} \end{cases} \quad (10)$$

여기서 $\delta_{\min}$ 은 가장 가까운 작업자와의 거리, D_{danger} 는 즉시 정지 거리, D_{safe} 는 감속을 위한 안전 거리이다. T_{stop} 과 T_{slow} 는 각각 정지 및 감속을 결정하는 위험도 임계값이며, η_s 는 감속 비율이다.

본 실험에서는 $T_{\text{stop}}=0.75$, $T_{\text{slow}}=0.42$ 를 기본 임계값으로 사용하였다. T_{stop} 은 고위험 상태에서 정지 동작을 유도하기 위한 임계값이고, T_{slow} 는 즉시 정지까지는 필요하지 않지만 감속이 필요한 중간 위험 상태를 구분하기 위한 임계값이다. 파라미터 선택이 의사결정 결과에 미치는 영향을 확인하기 위해 본 연구에서는 aggressive, default, conservative의 세 가지 설정에 대한 민감도 분석을 추가로 수행하였다.

본 의사결정 모듈은 규칙 기반으로 설계되었지만, 각 항목은 해석 가능하도록 구성하였다. 거리 항은 기본적인 안전 확보를 위한 요소이고, 헬멧 상태 항은 작업자의 보호 상태를 반영한다. 검출 신뢰도 항은 인식 결과의 불확실성을 반영하며, no-helmet bonus 항은 운용 경로 내 헬멧 미착용 작업자에 대해 더 민감하게 반응하도록 설계되었다. 실험에서는 No adaptation, Distance-only, Full proposed 방식을 비교하였으며, 추가로 헬멧 상태, 검출 신뢰도, no-helmet bonus 항을 순차적으로 추가한 ablation 구성을 평가하였다.

IV. Results

1. Dataset and Experimental Environment

본 연구에서는 공개 Safety Helmet Detection 데이터셋을 사용하여 헬멧 착용 상태 인식 모델을 학습하고 평가

하였다 [10]. 해당 데이터셋은 건설 현장 작업자 이미지와 Pascal VOC 형식의 바운딩 박스 주석으로 구성되어 있으며, 원본 클래스는 helmet, head, person이다. 클래스 변환은 3.2절에서 설명한 label mapping 기준을 동일하게 적용하였으며, helmet은 헬멧 착용 상태, head는 no-helmet 상태로 사용하였다. 전체 데이터는 학습 3,500장, 검증 1,000장, 시험 500장으로 분할하였다. 변환 후 객체 수는 helmet 18,966개, no-helmet 5,785개였다. 시험셋에는 총 580개의 no-helmet 객체가 포함되어 있으며, 본 연구에서는 no-helmet recall을 이용하여 헬멧 미착용 작업자의 미검출 위험을 추가로 분석하였다.

본 데이터셋은 별도의 공식 학습, 검증, 시험 분할을 제공하지 않기 때문에, 본 연구에서는 이미지 단위로 70:20:10 비율의 분할을 생성하였다. 데이터 분할에는 random seed 42를 사용하였으며, 동일한 분할을 모든 detector 비교, 강건성 분석, 후속 의사결정 실험에 공통으로 적용하였다. 이를 통해 모델 간 성능 차이가 데이터 분할 차이가 아니라 모델 구조 및 의사결정 방식의 차이에서 발생하도록 하였다.

객체 검출 모델 비교에는 YOLOv5s와 YOLOv8 계열 모델을 사용하였다. YOLO 계열 모델은 정확도와 추론 속도의 균형이 우수하여 실시간 객체 검출 및 산업 안전 모니터링 분야에서 널리 활용되고 있다 [7,8]. 실험은 Linux 환경에서 NVIDIA RTX A2000 12GB Graphics Processing Unit (GPU)를 사용하여 수행하였다. 검출 성능은 precision, recall, mAP@50, mAP@50:95로 평가하였으며, 안전상 중요한 no-helmet 클래스의 recall을 별도로 분석하였다.

실제 산업 안전 모니터링에서는 검출 정확도뿐 아니라 추론 지연 시간도 중요하다. 본 실험 환경에서 YOLOv8s의 평균 GPU inference time은 약 6.1 ms/image로 측정되어, GPU 기반 처리 환경에서 낮은 추론 지연을 보였다. 그러나 실제 산업 안전 시스템의 실시간성은 카메라 입력, 전처리, 통신, 의사결정 모듈, actuator 또는 제어 시스템 반응 시간을 포함한 end-to-end latency로 평가되어야 한다.

모든 검출 모델은 동일한 data.yaml과 동일한 학습, 검증, 시험 데이터 분할을 사용하여 학습 및 평가하였다. 입력 크기는 640, epoch 수는 50으로 설정하였고, 사전학습 가중치를 초기값으로 사용하였다. YOLOv5s, YOLOv8n, YOLOv8s는 batch size 16, YOLOv8m은 batch size 8로 학습하였다. Optimizer, learning rate schedule, mosaic, color jitter, flipping 등은 Ultralytics 기본 설

Table 1. Performance Comparison with YOLOv5s and YOLOv8 Models

Model	Precision	Recall	mAP@50	mAP@50:95	No-helmet Recall	No-helmet mAP@50
YOLOv5s	0.906	0.882	0.930	0.626	0.862	0.910
YOLOv8n	0.925	0.872	0.929	0.625	0.852	0.904
YOLOv8s	0.922	0.882	0.933	0.626	0.867	0.912
YOLOv8m	0.913	0.885	0.929	0.628	0.854	0.902

정을 사용하였다. 평가는 validation 기준 best.pt 가중치로 수행하였으며, confidence threshold 0.001과 Non-Maximum Suppression (NMS) Intersection over Union (IoU) threshold 0.7을 모든 모델에 동일하게 적용하였다.

후속 의사결정 성능 평가는 시험 이미지 500장을 각각 하나의 정적 시나리오로 간주하여 수행하였다. 각 시나리오에서 검출된 바운딩 박스는 횡방향 위치, 추정 전방 거리, 헬멧 착용 상태, 검출 신뢰도로 변환되었으며, 시스템은 사전에 정의한 직선 경로를 따라 이동하는 것으로 설정하였다. 각 시간 단계에서 작업자와 시스템 간 최소 거리와 장면 위험도를 계산하고, 의사결정 규칙에 따라 정상 동작, 감속, 정지 중 하나를 적용하였다.

2. Performance Comparison with YOLOv5s and YOLOv8 Models

먼저 헬멧 착용 상태 인식 모델의 성능을 비교하기 위해 YOLOv5s와 YOLOv8 계열 모델을 동일한 시험 데이터셋에서 평가하였다. 비교 대상은 YOLOv5s, YOLOv8n, YOLOv8s, YOLOv8m이다. YOLOv5s는 기존 YOLO 계열 경량 detector baseline으로 사용하였고, YOLOv8n, YOLOv8s, YOLOv8m은 모델 크기에 따른 성능 변화를 확인하기 위해 사용하였다. Table 1은 각 모델의 전체 검출 성능과 안전상 중요한 no-helmet 클래스 성능을 나타낸다.

Table 1에서 YOLOv8s는 전체 mAP@50이 0.933으로 가장 높았고, no-helmet 클래스의 recall도 0.867로 가장 높게 나타났다. YOLOv5s는 mAP@50 0.930과 no-helmet recall 0.862를 보여 YOLOv8 계열과 유사한 성능을 보였으나, no-helmet recall과 no-helmet mAP@50에서는 YOLOv8s보다 낮았다. YOLOv8m은 전체 recall과 mAP@50:95 측면에서는 높은 값을 보였지만, no-helmet 클래스 성능은 YOLOv8s보다 낮게 나타났다. 이는 모델 크기를 증가시키는 것이 항상 안전상태 인식 성능 향상으로 이어지지는 않음을 보여준다. 따라서 이후 강건성 분석에서는 전체 mAP@50과 no-helmet 인식 성능이 가장 균형적으로 나타난 YOLOv8s를 중심 모델로 사용하였다.

3. Robustness Analysis under Visual Degradation

실제 산업 현장에서는 조명 저하, 카메라 흔들림, 센서 노이즈, 작업자 간 가림과 같은 시각적 품질 저하가 자주 발생할 수 있다. 기존 연구에서도 PPE 인식 시스템의 실제 적용을 위해서는 다양한 환경 조건에서의 강건성 검증이 필요하다고 보고하고 있다 [6]. 이에 따라 본 연구에서는 시험 이미지에 저조도, 블러, 노이즈, 가림, 저조도+블러 조건을 적용하여 YOLOv8s 모델의 성능 변화를 분석하였다. 저조도 조건은 영상 밝기를 약 55% 수준으로 낮추어 생성하였고, 블러 조건은 (5×5) Gaussian blur를 적용하였다. 노이즈 조건은 평균 0, 표준편차 15의 Gaussian noise를 추가하여 생성하였다. 가림 조건은 이미지 내 임의의 위치에 두 개의 사각형 영역을 삽입하여 작업자 머리 영역이 부분적으로 가려지는 상황을 모사하였다. 저조도+블러 조건은 밝기 감소와 Gaussian blur를 함께 적용한 조건이다. 이러한 열화 조건은 실제 현장에서 발생할 수 있는 조명 변화, 센서 노이즈, 초점 흐림, 작업자 간 가림을 단순화한 것이며, 기존 object detection robustness 연구에서도 noise, blur, weather degradation과 같은 입력 품질 저하가 검출 성능을 크게 낮출 수 있음이 보고되었다 [17].

Table 2에서 저조도 조건의 mAP@50은 0.932로, 원본 조건의 0.933과 거의 동일하였다. 원본 조건에서 no-helmet recall은 0.867이었고, 저조도 조건에서는 0.872로 나타났다. 반면 노이즈 조건에서는 전체 mAP@50이 0.854로 감소하였고, no-helmet recall도 0.746까지 낮아졌다. 가림 조건에서도 no-helmet recall은 0.820으로 감소하였다. 이는 영상 노이즈나 머리 영역 가림이 헬멧 미착용 작업자 인식에 직접적인 영향을 줄 수 있음을 의미한다.

노이즈, 블러, 가림 조건에서의 성능 저하는 시각적 특징 손상과 관련이 있다. 노이즈는 머리 영역과 헬멧 경계의 색상 및 질감 정보를 왜곡하고, 블러는 작은 head 영역이나 헬멧 윤곽의 경계 정보를 약화시킨다. 또한 가림은 머리 영역 일부를 직접 가려 검출 confidence와 localization 성능을 저하시킬 수 있다. 산업 안전 관점에서는 no-helmet 작업자의 false negative가 특히 중요하다

Table 2. Robustness Analysis of YOLOv8s under Visual Degradation Conditions

Condition	Precision	Recall	mAP@50	mAP@50:95	No-helmet Recall
Original	0.922	0.882	0.933	0.626	0.867
Low brightness	0.920	0.882	0.932	0.624	0.872
Blur	0.912	0.842	0.905	0.590	0.826
Noise	0.912	0.776	0.854	0.558	0.746
Occlusion	0.894	0.833	0.879	0.583	0.820
Brightness+Blur	0.922	0.831	0.904	0.590	0.819

다. 시험셋의 no-helmet 객체 수 580개를 기준으로 하면, 원본 조건에서는 약 77개의 미검출 사례가 추정되었고, noise 조건에서는 약 147개, occlusion 조건에서는 약 104개로 증가하였다. 이는 영상 노이즈와 작업자 가림이 헬멧 미착용 작업자의 미검출 위험을 증가시킬 수 있음을 보여준다.

따라서 실제 현장 적용을 위해서는 노이즈와 가림 상황을 고려한 데이터 증강, 영상 품질 개선, 시간적 추적, 다중 카메라 또는 depth 기반 보완이 필요하다. 또한 본 연구의 강건성 분석은 단일 열화 수준에서 수행한 초기 평가이므로, 향후 연구에서는 열화 강도별 성능 변화와 실제 현장 영상 기반 검증을 추가로 수행할 필요가 있다.

4. Safety-Aware Decision Performance and Ablation Analysis

다음으로 4.1절의 시뮬레이션 프로토콜에 따라 헬멧 착용 상태 인식 결과가 후속 의사결정에 미치는 영향을 분석하였다.

비교 대상은 No adaptation, Distance-only, 그리고 제안한 safety-aware 방식이다. No adaptation은 안전 상태 정보를 사용하지 않고 최대 속도로 동작하는 기준선이며, Distance-only는 작업자와 시스템 간 거리만을 사용하여 감속 또는 정지를 결정한다. 거리 기반 안전 개념은 기존 인간-기계 및 인간-로봇 상호작용 안전 연구에서 널리 사용되어 왔다 [11-16]. 제안 방식은 여기에 헬멧 착용 상태, 검출 신뢰도, 그리고 운용 경로 내 no-helmet 작업자에 대한 추가 위험 향을 반영한다. Table 3은 주요 의사결정 방식과 ablation 구성을 함께 비교한 결과이다. 여기서 safety violation은 사전에 정의한 안전 조건을 시

간 단계에서 위반한 횟수를 의미하며, unsafe exposure time은 no-helmet 작업자가 위험 영역에 노출된 누적 시간을 의미한다. 따라서 safety violation은 시나리오 수가 아니라 시간 단계 단위로 누적되므로, 전체 시험 이미지 수인 500보다 크게 나타날 수 있다. Table 3의 D, H, C, B는 각각 distance, helmet state, detection confidence, no-helmet bonus를 의미한다.

Table 3에서 No adaptation은 완료 시간이 7.662초로 가장 짧았지만, safety violation이 759회 발생하였고 unsafe exposure time도 40.3초로 가장 높았다. 이는 안전 상태 정보를 사용하지 않는 방식이 운용 효율은 높지만, 사전에 정의한 안전 요구조건을 만족하기 어렵다는 것을 보여준다.

Distance-only 방식은 safety violation을 0으로 줄였지만, 완료 시간이 8.840초로 가장 길었다. 이는 모든 작업자를 동일한 거리 기준으로 처리하기 때문에 보수적인 의사결정이 발생한 것으로 해석된다. Distance + Helmet 구성은 완료 시간이 8.482초로 감소하여 헬멧 착용 상태 정보가 불필요한 보수성을 줄이는 데 기여함을 보여준다. 그러나 unsafe exposure time은 여전히 1.3초로 유지되었다. Confidence 향을 추가해도 완료 시간, 최소 이격 거리, unsafe exposure time의 변화는 제한적이었다.

반면 Full proposed 구성은 완료 시간이 8.652초로 Distance + Helmet 구성보다 다소 증가하였지만, unsafe exposure time을 0.0초로 줄였다. 이는 운용 경로 내부의 헬멧 미착용 작업자에게 추가 위험 향을 부여하는 방식이 본 시뮬레이션 조건에서 unsafe exposure time을 줄이는 데 중요한 역할을 함을 보여준다. 실험 분석 결과, 제안한 프레임워크는 테스트한 시뮬레이션 조건에서 safety

Table 3. Component-Wise Ablation Analysis of the Safety-Aware Decision Module

Variant	Components	Completion Time (s)	Minimum Separation (m)	Safety Violations	Unsafe Exposure (s)
No adaptation	—	7.662	1.718	759	40.3
Distance-only	D	8.840	2.326	0	1.3
Distance + Helmet	D + H	8.482	2.073	0	1.3
Distance + Helmet + Confidence	D + H + C	8.494	2.083	0	1.3
Full proposed	D + H + C + B	8.652	2.224	0	0.0

violation과 unsafe exposure time을 0으로 줄이는 동시에 Distance-only보다 짧은 완료 시간을 유지하였다.

다만 본 의사결정 실험은 공개 이미지 데이터셋과 단일 이미지 기반 위치 근사를 이용한 시뮬레이션 기반 초기 검증이다. 실제 배치를 위해서는 카메라 설치 조건, 작업자 이동, 장비 동역학, 통신 지연 등을 고려한 추가 검증이 필요하다.

의사결정 결과는 이미지 기반 상태 변환 파라미터와 위험도 기반 제어 파라미터의 영향을 받는다. 재현성과 해석 가능성을 높이기 위해 본 연구에서 사용한 주요 시뮬레이션 및 의사결정 파라미터를 Table 4에 정리하였다.

거리 관련 파라미터는 상대적 이격 조건을 모사하기 위해 설정하였고, 위험도 가중치는 거리 위험도와 헬멧 미착용 상태를 주요 안전 요인으로 반영하도록 설정하였다.

위험도 파라미터의 영향을 확인하기 위해 aggressive, default, conservative 설정을 비교하였다. 각 설정별 주요 위험도 임계값과 의사결정 결과는 Table 5와 같다. Aggressive 설정은 완료 시간이 가장 짧았지만 unsafe exposure time이 1.3초 발생하였다. Conservative 설정은 unsafe exposure time을 0.0초로 줄였으나 emergency stop이 98회로 증가하였다. Default 설정은 unsafe exposure time을 0.0초로 유지하면서 emergency stop을 21회로 제한하여 안전성과 운용 효율 사이에서 가장 균형적인 결과를 보였다.

Fig. 2는 대표적인 세 가지 의사결정 방식의 완료 시간, 최소 이격 거리, unsafe exposure를 함께 비교한 결과이다. No adaptation은 완료 시간이 7.662초로 가장 짧아 운용 효율은 높았지만, 최소 이격 거리가 1.718 m로 가장 작고 unsafe exposure time이 40.3초로 나타나 안전성이 낮은 기준선으로 해석된다. Distance-only는 최소 이격 거리를 2.326 m로 가장 크게 유지하였으나, 완료 시간이 8.840초로 증가하여 가장 보수적인 동작을 보였다. 반면 제안 방식은 unsafe exposure time을 0.0초로 줄이면서도 완료 시간을 8.652초로 유지하여, Distance-only보다 짧은 완료 시간과 충분한 안전성을 동시에 보였다.

Table 4. Simulation and Decision Parameters

Parameter	Value	Role
Δt	0.1 s	Simulation time step
$v_{\max}$	1.0 m/s	Maximum operating speed
W_{lane}	4.0 m	Assumed lateral operating width
W_{corridor}	1.2 m	Half-width of operating corridor
h_{ref}	0.20	Reference normalized bounding-box height
α	0.65	Weight for bounding-box height in closeness score
$f_{\min}$	1.0 m	Minimum estimated forward distance
$f_{\max}$	8.0 m	Maximum estimated forward distance
D_{inf}	4.0 m	Influence distance for distance-based risk
D_{safe}	1.5 m	Slowdown distance threshold
D_{danger}	1.0 m	Immediate stop distance threshold
η_{stop}	0.0	Stop speed fraction
η_s	0.30	Slowdown speed fraction
w_d	0.55	Distance-risk weight
w_p	0.40	No-helmet penalty weight
w_s	0.05	Confidence-uncertainty weight
$R_i^{(b)}$	0.12	Additional no-helmet corridor risk
T_{stop}	0.75	Stop risk threshold
T_{slow}	0.42	Slowdown risk threshold




Fig. 2. Comparison of Completion Time, Minimum Separation, and Unsafe Exposure across Decision Strategies.

Table 5. Sensitivity Analysis of Risk-Aware Decision Parameters

Setting	T_{stop}	T_{slow}	$R_i^{(b)}$	Completion Time (s)	Min. Separation (m)	Unsafe Exposure (s)	Stops
Aggressive	0.85	0.50	0.05	8.447	2.042	1.3	0
Default	0.75	0.42	0.12	8.652	2.224	0.0	21
Conservative	0.65	0.35	0.20	8.686	2.248	0.0	98

Note. Safety violations were 0 for all settings. D_{safe} and D_{danger} were fixed at the default values shown in Table 4.

V. Conclusion

본 연구에서는 헬멧 착용 상태 인식 결과를 위험 인지형 의사결정에 활용하는 딥러닝 기반 산업 안전 모니터링 프레임워크를 제안하였다. 제안 방법은 YOLOv8 계열 모델을 이용하여 작업자의 머리 영역을 helmet과 no-helmet으로 분류하고, 검출 결과를 작업자 상태 변수로 변환한 뒤, 거리 정보와 헬멧 착용 상태를 함께 고려하여 안전 대응 수준을 결정한다. 실험 결과, YOLOv8s는 전체 mAP@50 0.933과 no-helmet recall 0.867을 보여 모델 크기와 성능 측면에서 가장 균형적인 결과를 보였다. 또한 강건성 분석에서는 저조도 조건에서는 성능 저하가 크지 않았으나, 노이즈와 가림 조건에서는 no-helmet recall이 감소하였다. 이는 영상 노이즈와 머리 영역 가림이 헬멧 미착용 작업자의 false negative 위험을 증가시킬 수 있음을 의미하며, 실제 현장 적용 시 영상 품질 저하와 작업자 가림에 대한 보완이 필요함을 확인하였다.

제안한 safety-aware 방식은 테스트한 시뮬레이션 조건에서 safety violation과 unsafe exposure time을 0으로 줄였고, distance-only 방식보다 짧은 완료 시간을 유지하였다. Ablation 분석 결과, 헬멧 착용 상태 정보는 불필요한 보수성을 줄이는 데 기여하였고, no-helmet bonus 항은 본 시뮬레이션 조건에서 unsafe exposure time을 0.0초로 줄이는 데 중요한 역할을 하였다. 본 연구는 단일 이미지 기반 위치 근사, 시뮬레이션 기반 검증, 수동 위험도 파라미터, GPU 환경의 inference time만을 사용했다는 한계가 있다. 향후 연구에서는 실제 산업 현장 데이터, 다중 카메라 또는 depth 센서, 시간적 추적 기법, edge device 기반 end-to-end latency 평가, 실제 제어 시스템 연동을 통해 실환경 적용성을 검증할 계획이다.

REFERENCES

- [1] N. D. Nath, A. H. Behzadan, and S. G. Paal, "Deep learning for site safety: Real-time detection of personal protective equipment," *Automation in Construction*, Vol. 112, pp. 103085. Jan. 2020. DOI: 10.1016/j.autcon.2020.103085
- [2] V. S. K. Delhi, R. Sankarlal, and A. Thomas, "Detection of Personal Protective Equipment (PPE) Compliance on Construction Site Using Computer Vision Based Deep Learning Techniques," *Frontiers in Built Environment*, vol. 6, pp. 136. Sep. 2020. DOI: 10.3389/fbuil.2020.00136
- [3] J. C. P. Cheng, P. Kok-Yiu Wong, H. Luo, M. Wang, and P. H. Leung, "Vision-based monitoring of site safety compliance based on worker re-identification and personal protective equipment classification," *Automation in Construction*, Vol. 139, pp. 104312. Jul. 2022. DOI: 10.1016/j.autcon.2022.104312
- [4] H. Liang and S. Seo, "Automatic Detection of Construction Workers' Helmet Wear Based on Lightweight Deep Learning," *Applied Sciences*, Vol. 12, No. 20, pp. 10369. Oct. 2022. DOI: 10.3390/app122010369
- [5] J. Wu, N. Cai, W. Chen, H. Wang, and G. Wang, "Automatic detection of hardhats worn by construction personnel: A deep learning approach and benchmark dataset," *Automation in Construction*, Vol. 106, pp. 102894. Jul. 2019. DOI: 10.1016/j.autcon.2019.102894
- [6] A. M. Vukicevic, M. Petrovic, P. Milosevic, A. Peulic, K. Jovanovic, and A. Novakovic, "A systematic review of computer vision-based personal protective equipment compliance in industry practice: Advancements, challenges and future directions," *Artificial Intelligence Review*, Vol. 57, pp. 319. Oct. 2024. DOI: 10.1007/s10462-024-10978-x
- [7] C.-Y. Wang, A. Bochkovskiy, and H.-Y. M. Liao, "YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 7464–7475. 2023. DOI: 10.1109/CVPR52729.2023.00721
- [8] YOLO models. <https://github.com/ultralytics/ultralytics>
- [9] D. Kim and S. Xiong, "Enhancing worker safety: Real-time automated detection of personal protective equipment to prevent falls from heights at construction sites using improved YOLOv8 and edge devices," *Journal of Construction Engineering and Management*, Vol. 151, No. 1, pp. 04024187. 2025. DOI: 10.1061/JCEMD4.COENG-14985
- [10] Safety Helmet Detection, <https://www.kaggle.com/datasets/andrewwmvd/hard-hat-detection>
- [11] V. Villani, F. Pini, F. Leali, and C. Secchi, "Survey on human-robot collaboration in industrial settings: Safety, intuitive interfaces and applications," *Mechatronics*, Vol. 55, pp. 248–266. Nov. 2018. DOI: 10.1016/j.mechatronics.2018.02.009
- [12] J. A. Marvel and R. Norcross, "Implementing speed and separation monitoring in collaborative robot workcells," *Robotics and Computer-Integrated Manufacturing*, Vol. 44, pp. 144–155, Apr. 2017, doi: 10.1016/j.rcim.2016.08.001.
- [13] P. A. Lasota, T. Fong, and J. A. Shah, "A Survey of Methods for Safe Human-Robot Interaction," *Foundations and Trends in Robotics*, Vol. 5, No. 4, pp. 261–349. May. 2017. DOI: 10.1561/23000000052
- [14] A. Zacharaki, I. Kostavelis, A. Gasteratos, and I. Dokas, "Safety bounds in human robot interaction: A survey," *Safety Science*, Vol. 127, pp. 104667. Jul. 2020. DOI: 10.1016/j.ssci.2020.104667
- [15] C. Byner, B. Matthias, and H. Ding, "Dynamic speed and

separation monitoring for collaborative robot applications— Concepts and performance," *Robotics and Computer-Integrated Manufacturing*, Vol. 58, pp. 239–252. Mar. 2019. DOI: 10.1016/j.rcim.2018.11.002

- [16] O. Adamides, K. Subramanian, S. Arora, and F. Sahin, "Perception and Computation for Speed and Separation Monitoring Architectures," *Robotics*, Vol. 14, No. 4, Article no. 41, 2025. DOI: 10.3390/robotics14040041.
- [17] S. Gholinavaz, N. Saeedi, and S. Samadi Gharehveran, "Robustness analysis of YOLO and Faster R-CNN for object detection in realistic weather scenarios with noise augmentation," *Scientific Reports*, Vol. 15, Article no. 44888, 2025. DOI: 10.1038/s41598-025-28737-5.

Authors



Youngmi Baek received her Ph.D. in Computer Engineering from Kyungpook National University in 2015. She began her research career at the POSTECH Information and Communication Research Laboratory

(PIRL) in 2002 and joined the DGIST CPS Global Center in 2015. From February 2017, she served as a Research Professor at DGIST. She worked at Changshin University as an Assistant Professor from 2020 and joined Daejin University as an Associate Professor in 2026. Her research focuses on system modeling and network security, including cyberattack and anomaly detection, in automotive cyber-physical systems and autonomous manufacturing.



Jung Kyu Park received his Ph.D. degree in Computer Engineering from Hongik University in 2013. He was a Research Professor at Dankook University from 2014. From October 2015 to February 2017,

he worked at UNIST. In 2018, he joined the Department of Computer Software Engineering at Changshin University as an Assistant Professor. Since August 2024, he has been serving as an Associate Professor in the Division of AI Convergence, Major in Computer Science, at Daejin University. His research interests include data storage, robotics, system software, embedded systems.