

The Efficiency of Image Pre-processing Algorithms on YOLOv8 Object Recognition Performance and Processing Time

Ju-Yeong Park*, Jeongrok Yun*, Hoe-Min Kim**, Un-Yong Kim*, Jin-Taek Seong***, Sungkuk Chun****

*Researcher, Spatial Optical Information Research Center, Korea Photonics Technology Institute, Gwangju, Korea

**Principal Researcher, Spatial Optical Information Research Center, Korea Photonics Technology Institute, Gwangju, Korea

***Professor, Graduate School of Data Science, Chonnam National University, Gwangju, Korea

****Senior Researcher, Spatial Optical Information Research Center, Korea Photonics Technology Institute, Gwangju, Korea

[Abstract]

Object recognition performance in CCTV and low-illumination environments is often degraded by illumination variations and noise. However, real-time systems necessitate both high accuracy and rapid processing speed. This study evaluates the mean Average Precision (mAP) and processing time of YOLOv8 by cross-applying 16 image enhancement and 3 noise removal algorithms to a manufacturing dataset (900 images) and the ExDark (Exclusive Dark) dataset (600 images). Experimental results indicated that 41 combinations of these algorithms improved performance for the manufacturing dataset, specifically, the combination of Global Contrast Enhancement Historical Modification (GCEHM) and a Gaussian filter achieved a 6.98% increase in mAP. For the ExDark dataset, 16 algorithm combinations demonstrated improved object recognition, with the Linear Transformation (LT) and Wiener filter combination achieving a 4.31% increase in mAP. Regarding processing time, 10 algorithms, including LT (2.01 ms) and the Gaussian filter (8.33 ms), satisfied the criteria for real-time operation. These findings demonstrate that incorporating image pre-processing into the object recognition pipeline can significantly enhance detection performance while maintaining real-time efficiency.

▶ **Key words:** Deep learning, Image enhancement, Noise removal, Real-time System, YOLOv8

[요약]

CCTV 및 저조도 환경에서의 객체 인식 성능은 조도 변화와 노이즈로 인해 저하되는 경우가 발생한다. 본 연구에서는 16가지 영상 화질 개선 알고리즘과 3가지 노이즈 제거 알고리즘을 제조 데이터셋(900장) 및 저조도 데이터셋(ExDark, 600장)에 적용하여 YOLOv8의 mAP(mean Average Precision)와 처리 시간을 평가하였다. 실험 결과, 제조 데이터셋의 경우, GCEHM(Global Contrast Enhancement Historical Modification)과 가우시안 필터의 조합이 mAP를 6.98% 향상시켰다. 저조도 데이터셋의 경우, LT(Linear Transformation)와 위너 필터(Wiener filter) 조합이 4.31%의 mAP 개선을 보였다. 처리 시간의 경우, LT(2.01ms)와 가우시안 필터(8.33ms) 등 10가지 알고리즘이 실시간 처리를 만족하였다. 이러한 연구 결과는 객체 인식 과정에 이미지 전처리 알고리즘을 도입함으로써 실시간 성능을 유지함과 동시에 객체 인식 성능을 유의미하게 향상시킬 수 있음을 보여준다.

▶ **주제어:** 딥러닝, 영상 개선, 노이즈 제거, 실시간 시스템, 옴로v8

- First Author: Ju-Yeong Park, Jeongrok Yun, Corresponding Author: Jin-Taek Seong, Sungkuk Chun
- *Ju-Yeong Park (zhselftm@kopti.re.kr), Spatial Optical Information Research Center, Korea Photonics Technology Institute
- *Jeongrok Yun (justin182@kopti.re.kr), Spatial Optical Information Research Center, Korea Photonics Technology Institute
- **Hoe-Min Kim (hmkim@kopti.re.kr), Spatial Optical Information Research Center, Korea Photonics Technology Institute
- *Un-Yong Kim (kuy7023@kopti.re.kr), Spatial Optical Information Research Center, Korea Photonics Technology Institute
- ***Jin-Taek Seong (jtseong@jnu.ac.kr), Graduate School of Data Science, Chonnam National University
- ****Sungkuk Chun (k612051@kopti.re.kr), Spatial Optical Information Research Center, Korea Photonics Technology Institute
- Received: 2025. 11. 06, Revised: 2025. 11. 26, Accepted: 2025. 12. 26.

I. Introduction

1.1 Background and Motivation

딥러닝 기술의 급속한 발전은 컴퓨터 비전 분야의 성능 향상으로 이어지고 있다. 객체 인식 기술은 YOLO(You Only Look Once)와 같은 객체 인식 모델은 실시간 처리 속도와 높은 정확도를 동시에 확보하여, 전통적인 방법을 능가하는 성능을 보이며[1], 자율 주행, 지능형 감시, 스마트 팩토리 등 다양한 분야에서 활용되고 있다[2-4]. 특히, 영상 기반 객체 인식 기술은 위험 요소를 조기에 인식하고 신속하게 대응하여 사고 예방에 기여할 수 있다[5-6]. 그러나 영상 환경은 조명 변화, 분진, 노이즈 등 다양한 환경적 요인으로 인해 화질이 저하되며, 영상 내 객체 에지(Edge) 정보를 훼손하여 딥러닝 모델의 특징점 추출을 방해하고 객체 인식 성능 저하로 이어진다[7]. 따라서, 객체 인식 성능 향상을 위해 영상 화질을 개선하고, 노이즈를 제거하는 전처리 과정이 필요하다. 이에 본 연구는 다양한 환경에서 객체 인식 성능을 검증하기 위해 두 단계의 실험을 수행하였다. 우선, 제조 현장 데이터셋 900장과 ExDark(Exclusively Dark)[8] 저조도 데이터셋 600장을 대상으로, 다양한 전처리 알고리즘을 적용하여 YOLO 기반 객체 인식 성능과 알고리즘별 처리 속도에 미치는 영향을 종합적인 비교 분석을 목표로 하였다. 제조 현장 데이터셋의 객체 인식 평균 정밀도(mean Average Precision, mAP)는 일본 영상(mAP@0.5-0.95: 24.28%) 대비 GCEHM과 Gaussian filter 알고리즘 조합이 31.26%로 개선되었다. 다음으로, ExDark 데이터셋은 일본 영상(mAP@0.5-0.95: 27.45%) 대비 LT와 Wiener filter 알고리즘 조합이 31.76%로 개선되었다. 이를 통해 본 연구는 다양한 환경에 최적화된 알고리즘의 유의미한 객체 인식 성능 개선을 확인하였다.

본 연구의 주요 기여점은 다음과 같다.

- 제조 현장 데이터셋과 ExDark 저조도 데이터셋을 활용하여, 다양한 환경에서 전처리 알고리즘 효율성을 검증하였다.
- 단일 화질 개선 알고리즘 적용 시 발생하는 노이즈가 증폭되는 문제 해결을 위해, 16종의 화질 개선 알고리즘과 3종의 노이즈 제거 알고리즘을 교차 적용하여 객체 인식 성능 개선 효과를 통계적으로 분석하였다.
- 실제 시스템 적용 가능성을 검증하기 위해, 객체 인식 정확도뿐만 아니라 프레임당 처리 속도를 함께 측정하여 실시간성을 평가하였다.

본 논문의 구성은 다음과 같다. 2장은 화질 개선 및 노

이즈 제거, 객체 인식 모델에 관한 기존 연구를 고찰한다. 3장은 본 연구에서 제안하는 전체 시스템 구조와 실험에 적용된 화질 개선 및 노이즈 제거 알고리즘, 객체 인식 모델의 세부 사항을 기술한다. 4장은 실험 환경과 데이터셋 구성을 설명하고, 다양한 알고리즘 조합에 따른 객체 인식 성능과 처리 시간의 비교 분석 결과를 제시한다. 5장은 결론을 맺고 향후 연구 방향을 제시한다.

1.2 Method

본 연구는 전처리 알고리즘의 실효성을 검증하기 위해 두 단계로 구성하였다. 먼저, 별도로 수집한 제조 현장 데이터셋 900장을 대상으로 수행하였으며, 저조도 환경의 특성을 반영한 ExDark 데이터셋 600장을 대상으로 검증을 진행하였다. 또한, 영상 전처리 알고리즘은 다양한 환경에서 발생하는 대비 저하, 조명 불균형, 노이즈 등의 문제를 해결하기 위해 화질 개선 16종 및 노이즈 제거 3종의 알고리즘을 선정하여 적용하였다.

영상의 전역적 및 지역적 대비 불균형 문제 해결을 위한 히스토그램 기반인 HE(Histogram Equalization)[9], AHE(Adaptive Histogram Equalization)[9], CLAHE(Contrast Limited Adaptive Histogram Equalization)[9], JHE(Joint Histogram Equalization)[10], GCEHM(Global Contrast Enhancement Histogram Modification)[11], WTHe(Weighted Thresholded Histogram Equalization)[12]과 비선형적인 밝기 분포를 보정하고, 저조도 조건에서 세부 정보 손실을 줄이기 위해 감마 보정 기반 알고리즘은 AGCIE(Adaptive Gamma Correction for Image Enhancement)[13], AGCWD(Adaptive Gamma Correction with Weighting Distribution)[14], IAGCWD(Improved Adaptive Gamma Correction Weighting Distribution)[15]를 포함한다. 다양한 조도 환경에서 전역적인 밝기 조절과 지역적 대비 개선을 위해, 선형 및 비선형 변환 기반 알고리즘인 CE(Contrast Enhancement)[16], LT(Linear Transformation)[17], AIE(Adaptive Image Enhancement)[18], AINDANE(Adaptive and Integrated Neighborhood Dependent Approach for Nonlinear Enhancement)[19]과 인간의 시각적 인지 특성을 모방하여 색상 왜곡 없이 디테일을 복원하기 위해 Retinex 이론 기반인 Retinex[20], CELA(Contrast Enhancement in images using Luminance Adaptation)[21], DCP(Dual Channel Prior)[22]를 적용하였다.

영상 및 화질 개선 과정에서 발생한 노이즈를 제거하기 위해 Gaussian filter[23], Guided filter[24], Wiener filter[25] 등 3종의 알고리즘을 후속 단계에 적용하였다.

객체 인식 성능 평가는 YOLOv8x 모델을 활용하였으며 평균 정밀도(mAP)를 통해 정량적으로 측정하였다[26]. 또한, 각 알고리즘의 실시간 적용 가능성 검토를 위해 프레임당 평균 처리 시간(Processing time)을 측정하였다.

II. Related Works

2.1 Image Enhancement Algorithms

화질 개선은 객체 인식 성능 향상을 위한 전처리 과정이다. 특히 영상 화질 개선 연구는 저조도 환경에서 시각적 품질 향상을 목표로 색상 복원, 대비 개선, 노이즈 제거에 집중한다[27-28]. 또한, 영상은 노이즈뿐만 아니라 그림자, 반사광 등으로 인해 객체와 배경의 경계가 불분명하다는 특징이 있으므로[29], 본 연구에서는 다음과 같은 알고리즘을 적용하여 객체 인식율을 비교하였다.

히스토그램 기반 알고리즘은 픽셀값의 분포를 조정하여 전역 및 지역적 대비를 향상한다. 대표적인 히스토그램 기반 알고리즘 HE는 이미지 전역 히스토그램의 재분배로 픽셀 강도의 분포를 균일화하여, 대비를 개선한다. 이를 지역적으로 적용한 AHE는 이미지를 $s \times s$ 개의 블록으로 나누고, 각 블록에 독립적으로 HE를 적용하여 지역적 대비를 개선한다. 그러나, 블록 현상, 과도한 대비와 노이즈 증가 문제가 발생할 수 있다. 이를 보완하는 CLAHE는 AHE에 히스토그램 클리핑(clipping)을 적용하여 대비를 제어한다. 클리핑은 히스토그램 빈(bin)의 높이가 임계값을 초과하면 다른 빈에 재분배하는 방식이다. 이는 과도한 대비 증가와 노이즈 발생을 억제한다[9]. JHE는 입력 영상의 픽셀 강도와 그 픽셀의 인접 픽셀 산술 평균의 조합에 대한 2차원 히스토그램을 활용한다. 인접 픽셀 상관관계를 고려한 명암도 매핑 함수를 구성하므로, 이미지 손상을 줄여 대비 향상, 노이즈 억제, 색상 정보를 보존한다[10]. GCEHM은 HE의 과도한 대비를 줄이기 위한 히스토그램 수정 알고리즘이다. 원본과 균일 히스토그램의 가중 평균으로, 히스토그램을 수정 후 HE를 적용한다. 이는 급격한 변동을 줄여 노이즈를 억제하고, 가중치 조정으로 대비 강도를 제어한다[11]. WTHe는 HE 적용 전에 가중치와 임계값을 정의하여 히스토그램을 변형하는 전역적 대비 향상 알고리즘이다. 높은 임계값과 낮은 임계값을 설정하여 빈도수가 극단적인 그레이 스케일 주파수는 감소시키고, 중간 영역은 감마 보

정을 통해 주파수를 증가해 총합을 1로 유지한다. 이러한 과도한 대비 향상을 방지하지만, 기울기 피크가 존재하는 이미지에서 왜곡을 유발하는 단점이 있다[12].

감마 보정 기반 알고리즘은 픽셀 강도를 비선형적으로 변환하여 밝기와 대비를 조정하는 특징이 있다. AGCIE는 영상 전역에 동일한 변환 함수를 적용하는 전역적 향상 기법으로, 대비와 밝기에 따라 감마값을 적응적으로 조정하여 시각적 선명도를 높인다. 하지만, 지역적 세부 정보 부족으로, 색 왜곡 및 노이즈가 증폭될 가능성이 있다[13]. 이를 보완한 AGCWD는 히스토그램 평활화와 감마 보정을 결합하고 가중 분포를 적용하여 과도한 보정으로 인한 왜곡을 억제하면서 영상 특성에 맞게 동적 대비를 향상해 화질을 개선한다. 다만, 밝은 영상은 과포화 및 세부 정보 손실이 있다[14]. 이를 보완한 IAGCWD는 영상 밝기 특성에 따라 다른 보정 방식을 적용한다. 밝은 영상은 네거티브 변환을 어두운 영상은 누적분포함수의 절삭을 통해 감마 보정을 수행하여 이중 전략을 적용한다. 이를 통해 다양한 밝기 왜곡 영상에서 발생하는 과포화 및 세부 정보 손실 문제를 해결하지만, 일부 영상은 효과가 제한적이다[15].

선형 및 비선형 변환 알고리즘은 수학적 변환(선형, 비선형 함수)을 적용하여 명암을 보정하는 방식이다. CE는 영상 내 대비 개선을 통해 화질을 향상한다. 하지만, 과도한 밝기 증가로 인해 영상 내 세부 정보 손실이나 노이즈 증가 문제가 있다[16]. LT는 선형 변환을 통해 대비를 조정하는 간단하고 빠른 알고리즘이다. 모든 이미지에 동일하게 적용되어 과도한 대비 증가, 세부 정보 손실이 발생할 수 있다[17]. AIE는 RGB 이미지를 HSV 색 공간으로 변환하여 명도(V) 채널을 분리하고, 다중 가우시안 함수를 이용해 조명 성분을 추정한다. 이후, 베버-페히너 법칙에 기반한 비선형 보정 함수를 통해 이미지 조명 분포에 따라 적응적으로 파라미터를 조절하여 서로 다른 수준으로 향상된 이미지 두 개를 생성한다[18]. AINDANE는 저조도 및 불균일한 조명 환경에서 적응적 휘도 향상과 대비 향상을 수행하는 두 개의 독립적 단계로 구성된다. 영상 밝기 분포에 따라 비선형 전달 함수를 적용하여 어두운 영역을 보정하고 밝은 영역의 과도한 강도를 억제한다. 색 왜곡을 최소화하여 전반적인 품질을 향상한다[19].

인간 시각 기반 알고리즘은 영상 복원과 색 재현의 화질 향상에 중점을 둔다. Retinex는 인간 시각 시스템이 주변 조명 변화와 관계없이 객체 고유 색상을 일정하게 인식하는 원리를 모방한 이론이다. 특정 지점의 색을 판단할 때 주변 영역과의 상대적인 비율을 계산하여 조명의 영향을 완화하므로, 불균일한 조명 환경에서 안정적인 색 재현이

Table 1. Comparisons of Image Enhancement Algorithms

Algorithms	Representative method	Features	Limitations	Author (Year)
Histogram based	HE	<ul style="list-style-type: none"> • Redistributes the images histogram • Equalizes the distribution of pixel intensities • Enhances the overall (Global) contrast of the image 	• Noise amplification	E.L.Hall (1974)[9]
	AHE		• Block phenomenon	D.J.Ketcham (1976)[9]
	CLAHE		• Parameter dependent	S.M.Pizer (1987)[9]
	JHE		• Signal distortion	T.Celik (2012)[10]
	GCEHM		• Detail loss	T.Arici (2009)[11]
			• Over enhancement	• Visual artifacts
Gamma correction based	AGCIE	<ul style="list-style-type: none"> • Adjusts the images luminance based on the gamma value • Selectively enhances contrast in dark or bright regions, rather than enhancing contrast equally 	• Bright region over enhancement	S.Rahman (2016)[13]
	AGCWD		• Fails on bright images	S.C.Huang (2013)[14]
	IAGCWD		• Detail loss	S.Rani (2014)[15]
Linear/non-linear based	CE	<ul style="list-style-type: none"> • Maps input pixel values to output values using defined linear or non-linear functions 	• Image dependent	- [16]
	LT		• Excessive enhancement	- [17]
	AIE		• Color distortion	J.Zhao (2013)[18]
	AINDANE		• Color noise	L.Tao (2005)[19]
Human visual system based	Retinex	<ul style="list-style-type: none"> • Models principles of human vision to separate illumination from reflectance 	• Excessive enhancement	E.H.Land (1977)[20]
	CELA		• Fails on over exposed regions	Q.Fu (2018)[21]
	DCP		• Chromatic noise	Z.Shi (2018)[22]
			• Over exposure issues	
			• Limited generalization	
			• Color deviation	
			• Halo artifacts	

가능하지만, 후광 아티팩트, 노이즈가 증가할 수 있다[20]. CELA는 Retinex 이론 기반 알고리즘으로, 영상 화질을 향상 전에 조명 변화를 감지하여 휘도 적응을 통해 적절한 전처리를 수행한다. 색상 왜곡이나 특정 영역에서의 과도한 향상을 완화하기 위하여 AGCWD를 함께 적용한다[21]. DCP는 밝은 채널과 어두운 채널이 각기 다른 사전 구조 정보를 포함하고 있다는 점을 활용한다. 이 두 채널이 상호 간의 부족한 구조 정보를 보완함으로써 보정된 투과율을 획득하며, 어두운 영역의 정보 보존과 색상 복원이 가능하지만, 아티팩트가 발생할 수 있다[22].

2.2 Noise Removal Algorithms

영상 내 노이즈는 화질과 객체 인식 성능의 저하 원인으로, 영상 처리 전반에 부정적인 영향을 미친다. 따라서 노이즈 제거는 단순한 화질 개선을 넘어, 이미지 보간, 영상 분석 등에 필요한 전처리 과정이다[30]. 본 연구에서 노이즈 문제 해결을 위해 다음과 같은 알고리즘을 적용하였다.

Gaussian filter는 정규 분포 가중치를 적용하여, 픽셀 값의 가중 평균을 산출한다. 중심 픽셀에 높은 가중치를 부여하고 인접 픽셀값의 가중치를 낮춰 평균을 산출하는 저역 통과 필터이다. 이미지는 개선되나, 경계 처리 과정에서 에지와 세부 정보가 흐려질 가능성이 존재한다[23].

Guided filter는 국소 선형 모델을 기반으로, 가이드 이미지의 구조 정보를 보존하면서 노이즈를 제거한다. 에지 보존이 가능하나, 객체 경계 주변에서 후광 아티팩트 현상이 발생할 수 있다[24].

Wiener filter는 영상의 노이즈와 신호의 통계적 특성을 이용하여, 원본 영상과 복원 영상 간의 평균 제곱 오차 (Mean Square Error, MSE)를 최소화하는 알고리즘이다. 이는 노이즈가 포함된 영상에서 왜곡을 제거하고 원본과 구조적으로 유사한 이미지를 생성하는 것을 목표로 한다. 노이즈를 포함한 영상에서 좋은 복원 결과를 보이나, 실시간 처리에 추가적인 최적화를 요구한다[25].

2.3 Object Recognition Model

객체 인식은 영상 내 특정 객체를 인식하고, 그 위치와 경계를 추정하며, 종류를 분류하는 컴퓨터 비전 기술이다. 초기에는 로봇 비전, 얼굴 인식 등 제한된 분야에서 활용하였으나, 최근에는 재난 대응, 스마트 팩토리 등 다양한 영역으로 활용도가 확장되고 있다. 특히, 현장에서는 다중 객체를 동시에 식별하고 실시간 추적이 가능해야 하므로 높은 정확도와 실시간 속도가 동시에 요구된다[30-31].

이를 충족하기 위해 합성곱 신경망(Convolutional Neural Network, CNN)[32] 기반의 다양한 딥러닝 모델이 개발되었다. 그중 YOLO 모델은 단일 신경망으로 이미지를 한 번에 처리하는 특징이 있다.

본 연구에서 활용한 YOLOv8 모델은 실시간 객체 인식을 위해 활용되는 대표적인 신경망 모델이다. 특히, 기존 YOLOv5가 사전에 정의한 앵커 박스와 바운딩 박스의 IoU(Intersection over Union)를 비교하여 객체를 인식했던 것과 달리, 앵커 프리 구조를 도입하였다. 이 구조는 앵커 설정 없이 객체의 중심을 직접 예측함으로써, 다양한 크기와 형태의 객체를 효율적으로 인식하며, 높은 정확도와 빠른 처리 속도를 동시에 제공한다[33].

제안 시스템은 전처리 단계를 모듈화하여, 다양한 전처리 알고리즘 조합이 객체 인식 성능과 연산 효율에 미치는 영향을 분석한다.

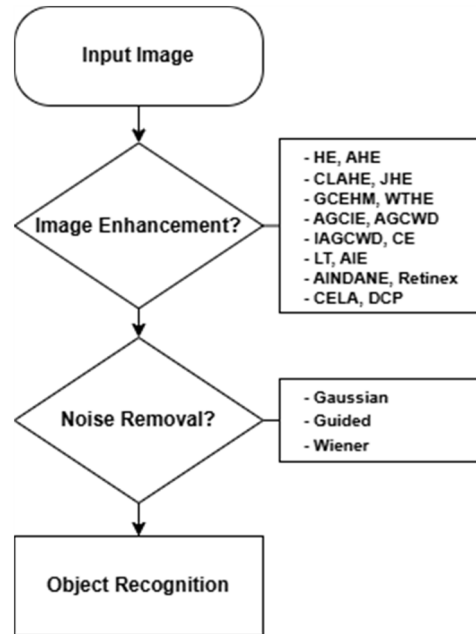


Fig. 1. System Flow

III. The Proposed System

3.1 Overview and Flow of the Proposed System

본 연구에서 제안하는 시스템은 Fig. 1과 같이 화질 개선(Image Enhancement), 노이즈 제거(Noise Removal), 객체 인식(Object Recognition)의 세 단계로 구성된다.

첫째, 화질 개선 단계는 영상의 대비를 개선하고, 세부 정보를 복원하며, 색상을 보정한다. 이를 위해 HE, AHE, CLAHE, JHE, GCEHM, WTHe, AGCIE, AGCWD, IAGCWD, CE, LT, AIE, AINDANE, Retinex, CELA, DCP 알고리즘 16종을 적용한다.

둘째, 노이즈 제거 단계는 화질 개선 과정에서 발생하거나 증폭될 수 있는 노이즈를 억제하고, 객체의 경계를 보존하기 위한 화질 개선의 후속 단계로 Gaussian filter, guided filter, Wiener filter 알고리즘 3종이 수행된다. 이때, 다양한 전처리 알고리즘의 파라미터는 객관적인 성능 비교를 위해 수정 없이 기본값을 적용하였다.

마지막으로, 객체 인식 단계는 신뢰도 임계값을 0.7로 설정하여 mAP를 산출한다. 인식 결과는 객체 정보(Class ID, Confidence, x, y, w, h)를 .txt 파일로 저장하고, 시각화된 결과를 .jpg 파일로 저장한다.

3.2 Details of the Image Enhancement Algorithm

HE는 식(1)에서 누적분포함수를 통해 픽셀 강도를 변환한다. 이 변환 함수는 입력강도(g)의 누적분포CDF(g)를 계산하고, 전체 픽셀 수(n)로 정규화한다. $H(k)$ 는 이미지의 히스토그램으로 밝기값이 k 인 픽셀의 개수이다. 정규화한 값에 최대 밝기값($L-1$)을 곱하여 새로운 출력 강도 $f(g)$ 를 산출한다. 이 과정은 특정 영역에 집중된 픽셀 분포를 전체 동적 범위에 걸쳐 분산한다[9].

$$f(g) = \frac{L-1}{n} CDF(g) = \frac{L-1}{n} \sum_{k=0}^g H(k) \quad (1)$$

AHE는 이미지를 다수의 블록으로 분할하고, 각 블록에 HE를 수행한다. 식(2)는 특정 블록 내 누적분포함수를 계산하는 과정으로, 해당 블록 내에서 픽셀의 밝기값($I_{x,c}$)이 입력강도(g)와 일치하는 픽셀 수($H_{i,j}(g)$)를 기반으로 누적합을 구하여 계산한다. 각 픽셀은 주변 영역의 국부적 통계 특성에 적응적으로 재매핑하여 국부 영역의 밝기 분포가 블록 내에서 균일하게 분포되도록 조정한다[9].

$$H_{i,j}(g) = \sum_{c=j-r}^{j+r} \left(\sum_{x=i-r}^{i+r} [I_{x,c} = g] \right) \quad (2)$$

CLAHE의 핵심인 블록별 히스토그램 클리핑은 식(3)과 같이, 사전에 임계값(C)을 정의하고 히스토그램 빈(bin)의 높이가 이를 초과하지 않도록 제한하여, 특정 밝기에 대한 과집중을 방지한다. 그 후, 잘려 나간 픽셀들의 총합(n_c)을 빈의 개수(L)로 나눈 값($\frac{n_c}{L}$)만큼 모든 빈에 균등하게 재분배하여, 최종적으로 조정된 히스토그램 $\hat{H}(k)$ 을 구한다[9].

$$\sum_{k=0}^a \hat{H}(k) = \sum_{k=0}^a \left(\min\{H(k), C\} + \frac{n_c}{L} \right) \quad (3)$$

JHE는 각 픽셀에 인접 영역의 산술 평균을 담은 평균 이미지의 픽셀 강도와 입력 영상 픽셀 강도의 조합별 빈도를 가지화한 2차원 히스토그램을 활용하여, 노이즈를 줄이고 대비를 개선한다. 식(4)는 히스토그램으로 얻은 2차원 누적분포함수를 통해, 입력 영상의 픽셀값을 대비가 향상된 새로운 값으로 변환하는 매핑 함수이다[10]. CDF_{\min} 은 영상에서 가장 어두운 픽셀 개수이며, $CDF(i, j)$ 는 현재 픽셀과 같은 밝기를 가진 픽셀 수이고, M, N 은 각각 이미지의 세로와 가로 픽셀 수이다.

$$h_{eq}(i, j) = \text{round} \left(\frac{L-1}{MN-1} \times (CDF(i, j) - CDF_{\min}) \right) \quad (4)$$

GCEHM은 식(5)처럼 입력 히스토그램(h_i)과 균일 분포 히스토그램(u)의 가중 평균을 통해 수정된 히스토그램(\tilde{h})을 생성 후 HE를 적용하여, 가중치 파라미터(λ)는 원본의 통계적 특성 보존과 대비 향상이라는 두 목표 사이의 균형을 조절한다. 가중치가 0에 근접하면 대비를 개선하고, 커질수록 대비 향상 수준이 감소하면서 원본을 보존한다[11].

$$\tilde{h} = \frac{h_i + \lambda u}{1 + \lambda} \quad (5)$$

WTHE는 HE를 수행하기 전, 히스토그램에 가중치와 임계값을 적용하여, 과도한 대비 향상으로 발생하는 시각적 왜곡을 억제하고, 영상의 세부 정보를 보존한다. 식(6)은 변형된 히스토그램 기반, 최종 픽셀값을 결정하는 변환 함수다. 가중치와 임계값이 적용된 누적분포함수(CDF_{wt})를 통해 원본 픽셀값($F(i, j)$)을 새로운 픽셀값(\tilde{F})으로 매핑한다. 이 과정에서 출력 동적 범위(W_{out})와 평균 밝기 보정(M_{adj})을 적용해 결과 영상의 대비와 밝기를 제어한다[12].

$$\tilde{F}(i, j) = W_{out} \times CDF_{wt}(F(i, j)) + M_{adj} \quad (6)$$

AGCIE는 입력 영상을 평균 강도와 대비에 따라 4개 클래스로 분류하고, 각 클래스에 적합한 감마 파라미터를 동

적으로 산출하여 적용한다. 평균 밝기(μ)가 0.5 미만인 어두운 영상에는 식(7)과 같은 변형된 감마 보정 곡선을 적용한다. $\mu \geq 0.5$ 인 밝은 영상에는 식(8)처럼 표준 감마 보정 곡선을 적용한다. 이때, I_{in} 은 기존 픽셀값, I_{out} 은 변환된 픽셀값, γ 는 대비 조절 강도를 결정하는 감마값이다[13].

$$I_{out} = \frac{I_{in}^{\gamma}}{I_{in}^{\gamma} + (1 - I_{in}^{\gamma}) \times \mu^{\gamma}} \quad (7)$$

$$I_{out} = I_{in}^{\gamma} \quad (8)$$

AGCWD는 가중 분포를 적용하여, 원본 히스토그램의 확률밀도함수에서 발생 가능한 급격한 변화를 보정한다. 식(9)는 특정 밝기값(l)의 빈도에 따라 가중한 확률밀도함수, α 는 빈도에 따른 가중치가 완만하도록 조절하는 값이다. 식(10)은 보정된 확률밀도함수를 누적하여, 이미지의 밝기 분포 특성을 반영하는 수정된 누적분포함수 cdf_w 를 계산한다. 밝기에 따라 동적으로 변하는 적응형 감마값을 결정하여, 최종 픽셀값 계산 시 파라미터로 사용한다[14].

$$PDF_w(l) = PDF_{\max} \left(\frac{PDF(l) - PDF_{\min}}{PDF_{\max} - PDF_{\min}} \right)^{\alpha} \quad (9)$$

$$\gamma = 1 - CDF_w(l) = 1 - \sum_{l=0}^{l_{\max}} PDF_w(l) / \sum PDF_w \quad (10)$$

IAGCWD는 먼저 입력 이미지의 평균 밝기를 기준으로 밝기 특성을 판단하고, 네거티브 변환과 잘린 누적분포함수 두 가지 전략을 사용한다. 어두운 이미지를 처리하는 식(11)은 감마값이 특정 임계치(τ) 이하로 낮아지는 것을 방지하여 밝은 영역의 정보 손실을 방지한다. 또한, 과도한 밝기 왜곡을 줄이고, 시각적 품질을 향상한다[15].

$$\gamma'_w(l) = \max(\tau, 1 - CDF_w(l)) \quad (11)$$

CE와 LT는 동일한 선형 변환 식(12)를 사용한다. 선형 변환을 통해 a 는 대비를, B 는 밝기를 조절한다[16-17].

$$I_{out} = a \cdot I_{in} + B \quad (12)$$

AIE의 식(13)은 베버-페히너 법칙에 따라 이미지 밝기를 비선형 보정 함수로 조절한다. 이미지의 평균 밝기(I_{v-g})와 픽셀 밝기(I_v)를 비교하여 분모를 조절하므로, 과도한 향상을 방지하면서 어두운 영역의 밝기를 강화한다[18].

$$I'_v = \frac{I_v(255+k)}{(\max(I_v, I_{v-g})) + k} \quad (13)$$

AINDANE는 적응형 휘도 향상과 적응형 대비 향상의 두 단계로 구성한다. 이 중 독창적인 대비 향상 식(14)는

인접 픽셀 대비 밝은 픽셀은 더 밝게, 어두운 픽셀은 더 어둡게 변환하기 위하여 지수 $E(x,y)$ 를 활용한다. $E(x,y)$ 는 인접 픽셀의 밝기($I_{conv}(x,y)$) 대비 현재 픽셀의 밝기($I(x,y)$)의 역수이다. 정규화된 $I'_n(x,y)$ 의 지수이므로, $E(x,y)$ 가 1을 초과하면 더 어둡게, 1 미만에서는 더 밝게 조정된다. 대비 조절 파라미터 p 를 인위적으로 조절할 수 있다[19].

$$S(x,y) = 255 \cdot I'_n(x,y)^{E(x,y)} \text{ where } E(x,y) = \left[\frac{I_{conv}(x,y)}{I(x,y)} \right]^p \quad (14)$$

Retinex의 조명-반사 모델 식(15)는 원본 영상에서 각 색상 채널에 대해 추정된 조명 성분을 제거하고, 객체 고유 색상(반사 성분)을 분리한다. 조명 성분은 인접 픽셀 평균 $I_w(x,y)$ 으로 추정하며, 구현에 따라 특정 필터를 적용하는 컨볼루션 연산을 적용할 수 있다[20].

$$R(x,y) = \frac{I(x,y)}{I_w(x,y)} \quad (15)$$

CELA는 이미지 각 영역에서 인간 시각 시스템에 근접한 최소 식별 차이를 산출하여 공간 적응적 조명 약화 인자(β)를 얻어 이를 MSR(Multi Scale Retinex) 모델에 적용해 조명 성분을 제거한다. 식(16)은 $r(x,y)$ 는 조명 약화 MSR 결과, $V(x,y)$ 는 HSV 색 공간의 입력 강도, $F_n(x,y) * V(x,y)$ 는 n번째 스케일의 가우시안 필터로 얻은 조명 성분, w_n 은 스케일에 대한 가중치이며, 어두운 영역에서 과도한 향상과 노이즈 증폭을 완화한다[21].

$$r(x,y) = \sum_{n=1}^N w_n \cdot \{ \log[V(x,y)] - \beta \cdot \log[F_n(x,y) * V(x,y)] \} \quad (16)$$

DCP는 식(17)에서 밝은 채널의 초기 투과율 $\tilde{I}(x)^{bright}$ 를 추정하고, 어두운 채널을 보완 채널로 활용하여 추정 오류를 최소화하는 이중채널 전략을 사용한다. A^c 는 영상의 전체적인 대기광 값이다. 이후, 가이드 필터를 통해 투과율 맵의 에지 정보를 보존하고, 블록 현상을 완화한다[22].

$$\tilde{I}(x)^{bright} = \frac{I^{bright}(x) - A^c}{255 - A^c} \quad (17)$$

3.3 Details of the Noise Removal Algorithm

Gaussian filter는 저역 통과 필터로, 영상의 노이즈를 제거한다. 식(18)은 중심 화소(p)를 기준으로 가까운 이웃 화소(q)일수록 높은 가중치를 부여하여 가중 평균을 계산한다. 가중 평균은 주변의 노이즈를 완화하지만, 경계가 명확한 영역의 화소값까지 평균화해 이미지가 흐려진다. 표준편차(σ)가 클수록 넓은 영역을 평균에 포함해 노이즈

제거 효과가 증가하나 더 흐려진다[23].

$$GF[I]_p = \sum_{q \in S} G_\sigma(\|p-q\|) \cdot I_q \quad (18)$$

Guided filter는 필터링할 영상(p) 외 별도의 가이드 영상(I)을 참조하여 필터링 결과(q)를 생성한다. 식(19)에서 출력 영상(q)의 각 픽셀은 입력 영상의 주변 픽셀들(p_j)에 대한 가중 평균으로 계산한다. 이때, 가중치(w_{ij})는 가이드 영상에 의해 결정하며, 입력 영상(p)과는 독립적이다[24].

$$q_i = \sum_j W_{ij}(I) p_j \quad (19)$$

Wiener filter의 식(20)은 주파수에서 신호와 노이즈의 파워스펙트럼 비율에 따라 필터를 조정한다. 신호 성분이 노이즈보다 큰 주파수 대역에서는 $S_n(u,v)/S_f(u,v)$ 항이 0에 근접하며, 노이즈가 신호 성분보다 큰 주파수 대역에서는 신호 대 잡음비가 감소하므로, 주파수 성분을 억제하고, 노이즈 증폭을 방지한다[25].

$$R_W(u,v) = \frac{H^*(u,v)}{|H(u,v)|^2 + \left[\frac{S_n(u,v)}{S_f(u,v)} \right]} \quad (20)$$

3.4 Details of the Object Recognition

본 연구에서는 산업 현장 안전 및 위험 요소 인식 모델 학습을 위한 제조 현장 데이터셋을 구축하였다. 이를 위해 Roboflow Universe의 Logistics Dataset[34]과 spark-detector Dataset[35]을 기반으로, 원본 데이터셋의 오픈 소스 라이선스(CC BY 4.0)를 준수하여, 통합 데이터셋을 구축하였다. 클래스 간 중복성을 제거하고 연구 목적의 인식 대상을 명확히 하기 위해, 수집된 데이터를 바탕으로 총 9개 클래스로 라벨링 수정(Relabeling) 작업을 수행하였다. 정의된 클래스는 Fig. 2와 같이 안전 보호 구 착용 확인을 위한 Helmet, Vest, Head, 작업자와 장비 식별을 위한 Person, Forklift, 현장 안전 정보 확인을 위한 Safety Sign, 그리고 화재 및 사고 징후 포착을 위한 Fire, Smoke, Spark로 구성된다. 이러한 정제 과정을 통해 138,389장의 학습 데이터셋을 훈련(Train) 111,260장(80.4%), 테스트(Test) 14,554장(10.51%), 검증(Validation) 12,575장(9.09%)으로 8:1:1로 분할하였다. 모든 이미지의 해상도는 640x640 픽셀로 재설정되었다. 또한, 객체 인식 모델은 COCO 데이터셋으로 사전 학습된 YOLOv8x 모델에 대한 전이 학습(Transfer Learning)을 수행하였다.



Fig. 2. Example of 9 Types of Images of Objects to be Recognized

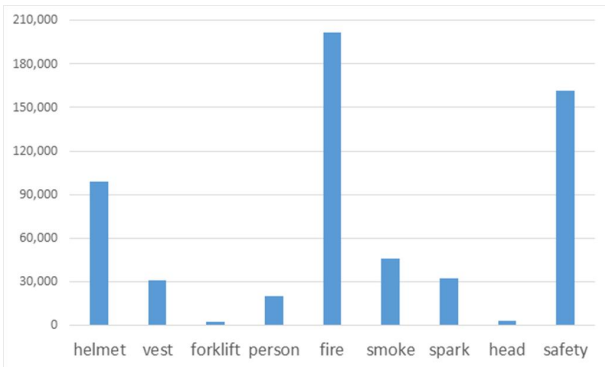


Fig. 3. Class-wise Distribution of the Manufacturing Dataset

학습에 사용된 객체 수는 총 596,432개로, 훈련 데이터 450,196개, 테스트 데이터 60,075개, 검증 데이터 86,161개로 구성되었으며, Fig. 3은 클래스별 분포이다.

추가로 진행된 실험은 저조도 데이터셋에서 YOLOv8x 모델의 인식 성능을 분석하기 위해, Kaggle[36]에서 제공하는 저조도 데이터셋인 ExDark(Exclusively Dark)[8]을 기반으로, 오픈 소스 라이선스(BSD-3)를 준수하였다. 인식 성능 평가는 추가 학습을 거치지 않은 YOLOv8x 모델을 사용하였다.

Fig. 4 혼동행렬(Confusion Matrix)은 분류 모델의 성능을 시각적으로 평가하는 지표로, 실제 정답 클래스와 모델이 예측한 클래스 간의 관계를 나타낸다. 행렬 축의 각 원소값이 1에 근접할수록 해당 클래스에 대한 분류 성능이 우수함을 나타낸다.

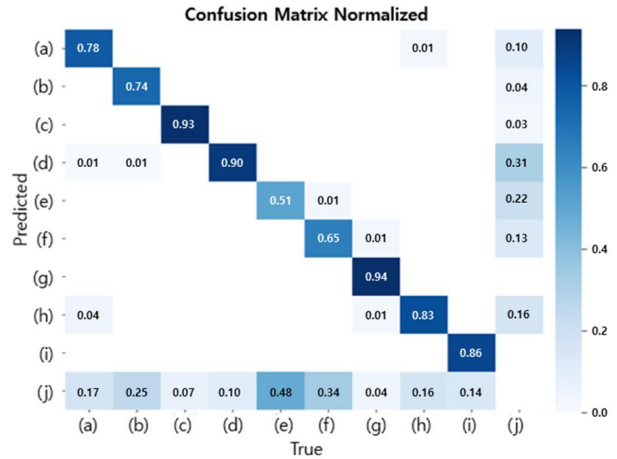


Fig. 4. YOLOv8 Model Performance: Normalized Confusion Matrix: (a)Helmet, (b)Vest, (c)Forklift, (d)Person, (e)Fire, (f)Smoke, (g)Spark, (h)Head, (i)Safety Sign, (j)Background

IV. Experiments

4.1 Experimental Environment

다음의 Table 3, 4는 YOLOv8x 객체 인식 모델의 전이 학습 및 화질 개선, 노이즈 제거, 객체 인식 성능 및 속도 측정 테스트를 위한 수행 환경이다.

Table 3. Processing Environment of YOLOv8x Model Training

Category	Spec
CPU	Intel Core I9-10920X 3.5GHz
RAM	192GB
GPU	RTX3090 Turbo D6X 24GB x 3EA + RTX A6000
OS	Windows 10 Pro

Table 4. Processing Environment of Object Recognition Inference and Image Enhancement

Category	Spec
CPU	Intel Core I9-10900K 3.7GHz
RAM	32GB
GPU	Quadro RTX8000
OS	Windows 10 Pro

4.2 Performance Comparison of Algorithms

4.2.1 Recognition Performance (Manufacturing Dataset)

Table 5. Object Recognition Precision by Image Enhancement and Noise Removal (Manufacturing Dataset)

Image Enhancement	Noise Removal	mAP@0.5-0.95(%)
GCEHM	Gaussian	31.26
HE	Gaussian	30.86
CLAHE	Gaussian	30.58
JHE	Gaussian	30.42
AGCIE	Gaussian	30.40
Original	Gaussian	30.37
IAGCWD	Gaussian	30.37
AGCWD	Gaussian	29.92
WTHE	Gaussian	29.85
CE	Gaussian	29.19
GCEHM	Wiener	28.17
CLAHE	Wiener	27.90
HE	Wiener	27.76
LT	Gaussian	27.69
AGCIE	Wiener	27.61
AHE	Gaussian	27.44
Original	Wiener	27.37
IAGCWD	Wiener	27.37
WTHE	Wiener	27.25
GCEHM	-	27.24
GCEHM	Guided	27.19
AGCWD	Wiener	27.12
JHE	Wiener	27.06
HE	-	26.77
AINDANE	Gaussian	26.64
HE	Guided	26.64
CLAHE	Guided	26.55
CLAHE	-	26.53
Retinex	Gaussian	26.51
CE	Wiener	26.14
AGCWD	-	25.31
LT	Wiener	25.16
AGCWD	Guided	25.14
JHE	-	25.10
JHE	Guided	25.03
AGCIE	-	24.90
AGCIE	Guided	24.90
WTHE	Guided	24.81
WTHE	-	24.73
AHE	Wiener	24.62
CELA	Gaussian	24.54
Original	-	24.28

제조 현장 데이터셋 900장을 대상으로, 화질 개선 16종과 노이즈 제거 알고리즘 3종의 조합을 적용하여 객체 인식 성능을 평가하였다. 성능 평가는 YOLOv8x 모델로 산출한 mAP@0.5-0.95 값을 Table 5에 정리하였다.

실험 결과, 원본 영상(mAP@0.5-0.95: 24.28%) 대비 객체 인식 성능이 향상된 알고리즘은 총 41개 조합이었다.

특히 상위 10개 알고리즘 모두 Gaussian이 포함되었으며, GCEHM(31.26%), HE(30.86%), CLAHE(30.58%), JHE(30.42%), AGCIE(30.40%), Original(30.37%), IAGCWD(30.37%), AGCWD(29.92%), WTHE(29.85%), CE(29.19%) 순으로 나타났다. 객체 인식 정밀도 기반 우수한 성능을 보인 알고리즘은 주로 히스토그램 기반(5개)과 감마 보정 기반(3개) 알고리즘이 차지했다. 이는 히스토그램 기반 알고리즘은 전역 또는 지역적 히스토그램 재분배를 통해 대비가 향상되어 배경과 객체의 경계가 명확해졌으며, 어두운 영역의 정보를 복원하지만, 이 과정에서 노이즈가 증가하는 문제가 존재한다. 또한, 감마 보정 기반은 비선형적인 밝기 조정을 통해 그림자나 저조도 영역의 세부 정보를 가시화하지만, 변환 곡선의 기울기 변화로 인해 노이즈가 증가할 수 있다. 이를 보완하기 위해 후처리 단계의 노이즈 제거 알고리즘 효과를 분석한 결과, Gaussian이 화질 개선 과정에서 발생한 노이즈를 억제하고, 노이즈 증가 문제를 완화한 것으로 분석된다. 결과적으로, 전처리 조합이 YOLOv8x 모델의 특징 추출 효율을 높여 객체 인식 성능이 개선된 것으로 사료된다.

4.2.2 Recognition Performance (ExDark Dataset)

본 논문에서 제안하는 전처리 알고리즘의 범용성 검증을 위해, ExDark(Exclusively Dark)[8] 저조도 데이터셋 600장을 대상으로 전처리 알고리즘 조합을 교차 적용하여 YOLOv8x 모델로 산출한 mAP@0.5-0.95 값을 Table 6에 정리하였다.

실험 결과, 원본 영상(mAP@0.5-0.95: 27.45%) 대비, 총 16개 조합이 객체 인식 성능이 향상되었다. 이 중, 상위 10개 알고리즘 조합은 LT와 Wiener(31.76%), LT와 Gaussian(31.18%), CE와 Wiener(30.62%), CLAHE와 Gaussian(30.47%), AGCWD와 Gaussian(30.41%), IAGCWD와 Gaussian(30.15%), CLAHE와 Wiener(29.95%), GCEHM과 Wiener(29.49%), Retinex와 Wiener(29.38%), AINDANE와 Wiener(29.21%) 순으로 나타났다. 제조 현장 데이터셋 실험 결과와 달리 ExDark 데이터셋은 LT와 Wiener 조합이 우수한 성능을 보였다. 이는 LT 알고리즘이 전체적인 밝기 선형 변환을 통해 저조도 영역의 정보를 가시화하면서도, Wiener를 통해 영상의 통계적 특성을 기반으로 평균 제곱오차를 최소화하여 노이즈 억제와 객체 인식을 위한 에지 정보를 보존하는 것으로 사료된다. 반면, Retinex 알고리즘은 저조도 영상 개선에 우수한 성능으로 알려졌으나, 본 실험에서는 노이즈를 억제하였음에도 최상위권 성능에는 미치지 못하였다.

이는 Retinex 처리 과정에서 발생하는 후광 아티팩트가 노이즈 제거로 완전히 보정되지 않아, 오히려 객체와 배경의 경계를 일부 왜곡했을 것으로 사료된다. 결과적으로, 저조도 환경에서 객체 인식은 단순한 밝기 향상뿐 아니라, 원본의 구조적 정보를 최대한 보존하면서 노이즈를 정교하게 제어하는 조합이 우수한 성능을 확인하였다.

Table 6. Object Recognition Precision by Image Enhancement and Noise Removal (ExDark Dataset)

Image Enhancement	Noise Removal	mAP@0.5-0.95(%)
LT	Wiener	31.76
LT	Gaussian	31.18
CLAHE	Gaussian	30.47
AGCWD	Gaussian	30.41
IAGCWD	Gaussian	30.15
CLAHE	Wiener	29.95
GCEHM	Wiener	29.49
Retinex	Wiener	29.38
CE	Wiener	29.21
AINDANE	Wiener	29.21
AGCWD	Wiener	29.04
IAGCWD	Wiener	29.02
CE	Gaussian	28.91
CLAHE	Guided	28.28
AGCIE	Wiener	28.18
AGCIE	Gaussian	28.12
Original	-	27.45

4.2.3 Comparison of Processing Time

각 알고리즘의 연산 효율성을 검증하기 위해, 프레임당 평균 처리 시간(ms)을 측정해 Table 7에 정리하였다.

분석 결과, 총 10종의 알고리즘이 실시간 처리 기준인 33ms(약 30FPS) 이내의 수행 속도를 만족하는 것으로 나타났다. 화질 개선 알고리즘은 LT(2.01ms), CE(2.09ms), IAGCWD(8.95ms), WTHE(14.64ms), HE(14.71ms), AHE(15.08ms), CLAHE(19.61ms), AGCWD(26.45ms), GCEHM(30.31ms) 순이며, 노이즈 제거 알고리즘은 Gaussian(8.33ms)만 실시간 처리 기준을 충족하였다. LT 알고리즘은 픽셀 단위 산술 연산이며, Gaussian은 2차원 컨볼루션 연산을 수평 및 수직 방향의 두 차례 1차원 연산으로 분해할 수 있어, 연산 복잡도가 감소한다. 이와 같은

커널 분리 최적화가 가능한 가중 평균으로, 처리 속도가 빠른 것으로 사료된다.

Table 7. Processing Time Comparisons of Image Pre-processing Algorithms

Algorithms	Processing Time(ms)
LT	2.01
CE	2.09
IAGCWD	8.95
WTHE	14.64
HE	14.71
AHE	15.08
CLAHE	19.61
AGCWD	26.45
GCEHM	30.31
AGCIE	35.77
AIE	74.71
JHE	127.24
CELA	130.20
AINDANE	608.39
DCP	2105.47
Retinex	5481.38
Noise Removal	Gaussian 8.33
	Guided 198.86
	Wiener 202.15

4.3 Statistical Analysis of Object Recognition Performance Improvement according to Pre-processing Algorithms by Application Environment

본 절은 제안된 전처리 알고리즘이 객체 인식 모델의 정밀도 수준별 성능(mAP@0.5-0.95)에 미치는 영향을 정량적으로 분석한다. 모든 실험의 표준편차 및 신뢰구간은 IoU 임계값(0.50 ≤ IoU ≤ 0.95, step=0.05) 변화에 따른 10개 지표의 분포를 기반으로 산출하였다. 이를 통해 전처리 알고리즘이 인식 성능의 평균적 향상뿐만 아니라, IoU 변화에 따른 성능 안정성에 미치는 기여도를 평가하였다.

제조 현장 데이터셋에 GCEHM과 Gaussian을 적용한 결과, mAP@0.5-0.95는 24.28%에서 31.26%로 약 6.98% 향상되었다. 특히, 95% 신뢰구간의 상한값이 34.60%에서 44.86%로 10.26% 개선되었다. 이는 전처리 과정이 모델의 최대 인식 성능을 확장하는 데 기여했음을 증명한다.

Table 8. Statistical Analysis of Object Recognition Performance Improvements according to Pre-processing Algorithms for each Application Environment

Dataset	Index	Pre-processing Algorithms	mAP@0.5-0.95	SD (Standard Deviation)	95% Confidence Interval
Manufacturing Dataset		GCEHM+Gaussian	31.26	21.94	[17.67, 44.86]
		Original	24.28	16.66	[13.96, 34.60]
Low Illumination (ExDark)		LT+Wiener	31.76	16.88	[21.30, 42.22]
		Original	27.45	15.62	[17.77, 37.13]

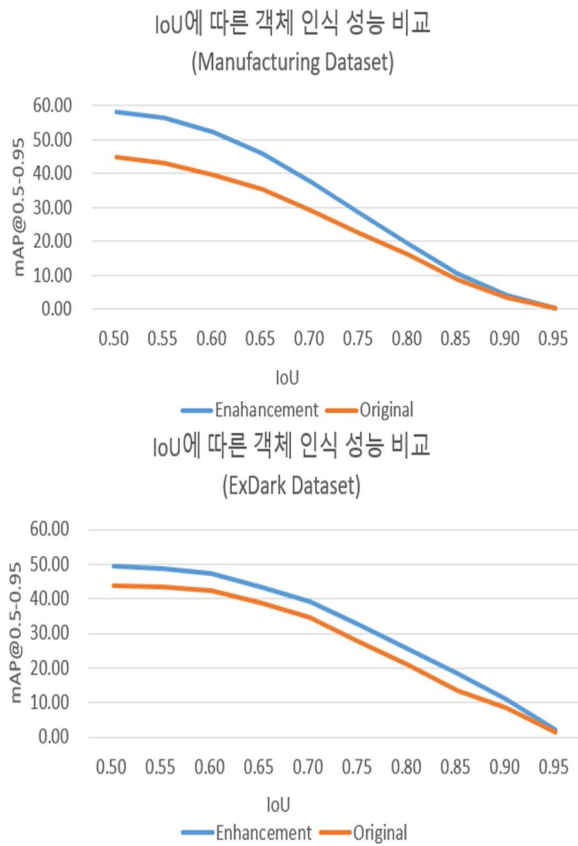


Fig. 5. Comparison of Object recognition Performance according to IoU

반면, 표준편차는 16.66%에서 21.94%로 약 5.28% 증가하였다. 이는 아래 Fig. 5와 같이 IoU 임계값이 낮을수록 GCEHM에 의한 대비 향상에 따른 객체 시인성 및 식별력이 강화되어 높은 성능을 보인 반면, 고정밀 IoU 구간에서는 향상폭이 상대적으로 낮아 성능 편차가 확대된 것으로 분석된다. 그럼에도 불구하고 낮은 IoU 임계값부터, 높은 IoU 임계값까지 모든 구간에서 객체 인식 성능이 개선됨을 확인하였다.

ExDark 데이터셋에서 LT와 Wiener를 적용한 경우, mAP@0.5-0.95는 27.45%에서 31.76%로 4.31% 상승하였다. 제조 현장 데이터셋과 대비하여, 저조도 환경에서는 표준편차의 증가폭(15.62%→16.88%)이 상대적으로 낮게 유지되었다. 이는 전처리 알고리즘이 특정 IoU 임계값에 편향되지 않고, 전 구간에서 균등한 성능 향상을 이끌어냄을 의미한다. 특히, 신뢰구간의 하한값이 17.77%에서 21.30%로 상승한 결과는 Wiener 기반의 적응형 노이즈 제거가 저조도 특유의 무작위 노이즈를 효과적으로 제어했음을 시사한다. 이러한 특성은 LT와 Wiener 알고리즘이 저조도 환경인 입력 영상의 품질 저하가 심각한 상황에서 인식 성능 개선을 확보할 수 있음을 의미한다.

4.4 Image Visualization

정량적 성능 평가 결과를 시각적으로 검증하기 위해, 전처리 알고리즘이 적용된 영상과 객체 인식 결과를 예시로 제시한다. Fig. 6과 Fig. 7은 제조 현장 데이터셋 결과이며, Fig. 8과 Fig. 9는 ExDark 데이터셋 결과이다. 원본 영상에 화질 개선과 노이즈 제거 알고리즘을 적용한 후, YOLOv8x 모델을 통해 객체를 인식한 모습을 보여준다. 이미지 내 초록색 경계 상자는 실제 객체의 정답(Ground Truth)이며, 빨간색 경계 상자는 모델이 예측한 결과이다.

V. Conclusions

딥러닝 기반 객체 인식 기술은 영상 분석의 핵심이지만, 조명 변화나 노이즈와 같은 환경적 요인으로 인해 객체 인식 성능이 저하되는 경우가 존재한다. 본 연구에서는 이러한 문제를 해결하기 위해, 제조 현장 데이터셋 900장과 ExDark 저조도 데이터셋 600장을 활용하여, 화질 개선 알고리즘 16종(HE, AHE, CLAHE, JHE, GCEHM, WTHE, AGCIE, AGCWD, IAGCWD, CE, LT, AIE, AINDANE, Retinex, CELA, DCP)과 노이즈 제거 알고리즘 3종(Gaussian, Guided and Wiener filter)을 적용하였다. 다양한 환경의 인식 성능 평가는 YOLOv8x 모델을 적용하여, mAP@0.5-0.95 값을 기준으로 수행하였고, 처리 속도는 프레임당 평균 처리 시간을 실험적으로 분석하였다.

실험 결과, 영상의 특성에 따라 최적의 전처리 알고리즘 조합을 확인하였다. 제조 현장 데이터셋에서 원본(24.28%) 대비 mAP값이 향상된 조합은 총 41개이며, 상위 3개 알고리즘 조합은 GCEHM과 Gaussian(31.26%), HE와 Gaussian(30.86%), CLAHE와 Gaussian(30.58%)이다. 그 중, GCEHM과 Gaussian 조합은 원본 대비 mAP가 6.98% 증가하여, 28.75%의 성능 향상을 보였다. 이는 GCEHM이 가중 평균 히스토그램을 통해 대비를 높여 객체 경계를 명확히 하고, Gaussian이 커널 분리 특성을 통해 연산 최적화가 가능하기 때문이다. 노이즈를 억제하여, YOLOv8x 모델의 특징 추출에 기여한 것으로 사료된다.

ExDark 저조도 데이터셋에서 원본(27.45%) 대비 향상된 조합은 총 16개로 나타났으며, 상위 3개 알고리즘 조합은 LT와 Wiener(31.76%), LT와 Gaussian(30.47%), CE와 Wiener(30.61%)이다. 그 중, LT와 Wiener는 원본 대비 mAP가 4.31% 증가하여 14.74%의 성능 향상을 기록하였다. 이는 LT 알고리즘이 선형 변환을 통해 정보를 가시화하고, Wiener filter는 영상의 통계적 특성을 기반으

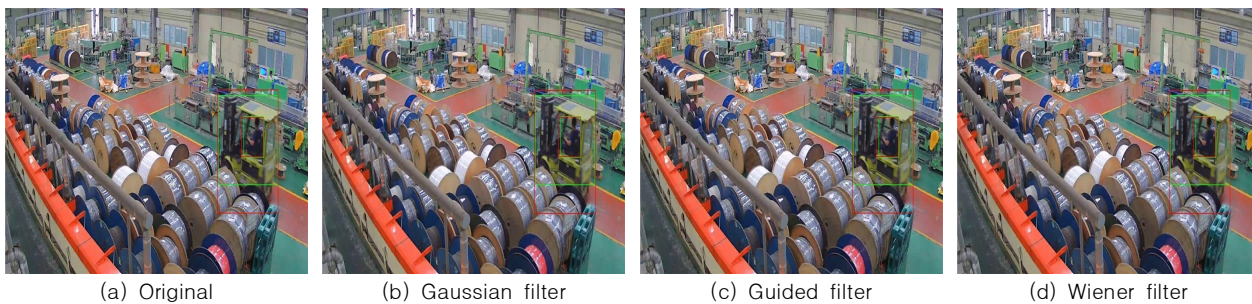


Fig. 6. Examples of Noise Removal Algorithms Results (Manufacturing Dataset)




Fig. 7. Examples of Image Enhancement Algorithms Results (Manufacturing Dataset)




Fig. 8. Examples of Noise Removal Algorithms Results (ExDark Dataset)




Fig. 9. Examples of Image Enhancement Algorithms Results (ExDark Dataset)

로 평균 제곱오차를 최소화하여 노이즈를 억제하면서도 객체 인식을 위한 에지 정보를 보존한 것으로 사료된다.

처리 속도 측면에서는 총 10개 알고리즘이 실시간 기준 (33ms)을 충족하였으며, 그중 LT(2.01ms), CE(2.09ms), IAGCWD(8.95ms)가 가장 빠른 처리 속도를 기록하였다. 노이즈 제거 알고리즘 중에서는 Gaussian(8.33ms)만이 실시간 처리 기준을 만족하였다.

적용 범위 측면에서 야간 모니터링과 자율 주행 시스템에 적용할 수 있는 것으로 사료된다. 특히, 주간이나 일반 조명은 GCEHM 기반의 알고리즘을, 야간이나 터널 등 저조도 데이터셋은 LT 기반의 알고리즘을 선택적으로 적용하여, 시스템을 구축할 수 있는 것으로 사료된다.

실험을 통해 응용 환경에 따라 영상 전처리 알고리즘을 적용하여 객체 인식 성능을 개선할 수 있음을 확인하였다.

향후 연구는 각 클래스별 전처리 알고리즘의 객체 인식 성능 분석과 영상의 특성 및 노이즈를 실시간으로 분석하여, 상황에 맞게 알고리즘의 종류와 파라미터를 동적으로 조절하는 적응형 전처리 시스템으로 확장하고자 한다.

ACKNOWLEDGEMENT

This research was supported by Culture, Sports and Tourism R&D Program through the Korea Creative Content Agency grant funded by the Ministry of Culture, Sports and Tourism in 2024(Project Name: Development of UX service technology based on new technology convergence content for enjoyment of cultural content by passengers in mobility, Project Number: RS-2024-00441262, Contribution Rate: 100%).

REFERENCES

- [1] D.M. Park, "A Study on the Applicability of Media Videos of Deep Learning Models Related to Computer Vision," *Communication Theories*, Vol. 18, No. 1, pp. 111-154, Mar. 2022. DOI: 10.20879/ct.2022.18.1.111
- [2] R.Y. Kim, H.J. Cha, and A.R. Kang, "A Study on the Impact of Noise on YOLO-based Object Detection in Autonomous Driving Environments," *Journal of the Korea Society of Computer and Information*, Vol. 29, No. 10, pp. 69-75, Oct. 2024. DOI: 10.9708/jksci.2024.29.10.069
- [3] J.R. Yun, J.Y. Park, H.M. Kim, U.Y. Kim, S.H. Hong, and S.K. Chun, "A framework for extracting worker movement paths in manufacturing sites based on object recognition using non-contact image sensors," *The Korean Society of Manufacturing Technology Engineers*, pp. 418, Dec. 2024.
- [4] J.H. Eom, "An Architecture of a Smart Safety Management System to prevent safety Accidents in Workplace," *Journal of Digital Contents Society*, Vol. 21 No. 4, pp. 817-823, Apr. 2020. DOI: 10.9728/dcs.2020.21.4.817
- [5] J.I. Park, "Development of Workplace Risk Assessment System Based on AI Video Analysis," *Journal of The Korea Society of Computer and Information*, Vol. 29, No. 1, pp. 151-161, Jan. 2024. DOI: 10.9708/jksci.2024.29.01.151
- [6] H.I. Jeong, J.M. Lee, B.K. Kim, J.H. Kim, and J.H. Kim, "Real-Time Monitoring System for Safety Equipment Compliance and Fall Detection," *Proceedings of the Korean Society of Computer Information Conference*, Jul. 2025.
- [7] Z. Jing, S. Li, and Q. Zhang, "YOLOv8-STE: Enhancing Object Detection Performance Under Adverse Weather Conditions with Deep Learning," *Electronics*, Vol. 13, No. 24, Nov. 2024. DOI: 10.3390/electronics13245049
- [8] P.Y. Loh, and C.S. Chan, "Getting to know low-light images with the exclusively dark dataset," *Computer vision and image understanding*, Vol. 178, pp. 30-42, Jan. 2019. DOI: 10.1016/j.cviu.2018.10.010
- [9] P. Hartinger, and C. Steger, "Adaptive histogram equalization in constant time," *Journal of Real-Time Image Processing*, Vol. 21, No. 93, pp. 1-9, May. 2024. DOI: 10.1007/s11554-024-01465-1
- [10] S. Agrawal, R. Panda, P.K. Mishro, and A. Abraham, "A novel joint histogram equalization based image contrast enhancement," *Journal of King Saud University - Computer and Information Sciences*, Vol. 34, No. 4, pp. 1172-1182, Apr. 2022. DOI: 10.1016/j.jksuci.2019.05.010.
- [11] W. Deng, L. Liu, H. Chen, G. Jiao, and X. Bai, "Image Contrast Enhancement and Brightness Preservation Based on an Adaptive Histogram Correction Framework," *Applied Optics*, Vol. 64, No. 13, pp. 3502-3515, Apr. 2025. DOI: 10.1364/AO.557280
- [12] Y. Qi, Z. Yang, W. Sun, M. Lou, J. Lian, W. Zhao, X. Deng, and Y. Ma, "A Comprehensive Overview of Image Enhancement Techniques," *Archives of Computational Methods in Engineering*, Vol. 29, No. 1, pp. 583-607, Apr. 2021. DOI: 10.1007/s11831-021-09587-6
- [13] S. Panagiotou, and A.S. Bosman, "Denoising diffusion post-processing for low-light image enhancement," *Pattern Recognition*, Vol. 156, pp. 110799, Dec. 2024. DOI: 10.1016/j.patcog.2024.110799
- [14] R. Rout, P. Parida, and S. Dash, "Automatic skin lesion segmentation using a hybrid deep learning network," *International Journal of Computer Information Systems and*

- Industrial Management Applications, Vol. 15, pp. 238-249, Jun. 2023.
- [15] L. Yu, E. Yang, and B. Yang, "Afe-orb-slam: robust monocular vslam based on adaptive fast threshold and image enhancement for complex lighting environments," *Journal of Intelligent & Robotic Systems*, Vol. 105, No. 26, May. 2022. DOI: 10.1007/s10846-022-01645-w
- [16] Y. Liu, S. Panezai, Y. Wang, and S. Stallinga, "Noise amplification and ill-convergence of Richardson-Lucy deconvolution," *Nature Communications*, Vol. 16, No. 1, Jan. 2025, DOI: 10.1038/s41467-025-56241-x
- [17] S.A. Yoon, D.S. Kim, and J.J. Ho, "Improved Multimodal Object Detection Technique Via Enhanced Image Contrast Adjustment," *The Journal of Korean Institute of Information Technology*, Vol. 22, No. 1, pp. 39-50, Jan. 2024, DOI: 10.14801/jkiit.2024.22.1.39
- [18] W. Wang, Z. Chen, X. Yuan, and X. Wu, "Adaptive image enhancement method for correcting low-illumination images," *Information Sciences*, Vol. 496, pp. 25-41, Sep. 2019. DOI: 10.1016/j.ins.2019.05.015
- [19] G. Zhang, J. Lin, E. Cao, Y. Pang, and W. Sun, "A Medical Endoscope Image Enhancement Method Based on Improved Weighted Guided Filtering," *Mathematics*, Vol. 10, No. 9, Apr. 2022. DOI: 10.3390/math10091423
- [20] T.R. Rasheed, G. Guo, D. Shi, H. Khan, and X. Cheng, "An Empirical Study on Retinex Methods for Low-Light Image Enhancement," *Remote Sensing*, Vol. 14, No. 18, Sep. 2022. DOI: <https://doi.org/10.3390/rs14184608>
- [21] M.W. Mirza, A. Siddiq, and I.R. Khan, "A combined multiple action recognition and summarization for surveillance video sequences," *Applied Intelligence*, Vol. 51, pp. 690-712, Feb. 2021. DOI: 10.1007/s10489-020-01823-z
- [22] L. Wang, "Natural low-illumination image enhancement based on dual-channel prior information," *Heliyon*, Vol. 10, No. 17, Sep. 2024. DOI: 10.1186/s13640-018-0251-4
- [23] P. Ivo, "Novel Low-Pass Two-Dimensional Mittag-Leffler Filter and Its Application in Image Processing," *Fractal and Fractional*, Vol. 7, No. 12, pp. 881, Dec. 2023. DOI: 10.3390/fractalfract 7120881
- [24] X. Zhang, and C.J. He, "Robust double-weighted guided image filtering," *Signal Processing*, Vol. 199, No. 1, pp. 108609, Oct. 2022. DOI: 10.1016/j.sigpro.2022.108609
- [25] P.K. Lendale, N.M. Nandhitha, and S. Chutke, "Fusion of Wiener Filtering and BM3D Denoising for Improved Image Restoration," *International Journal of Computational and Experimental Science and Engineering*, Vol. 10, No. 4, pp. 1689-1694, Dec. 2024. DOI: 10.22399/ijcesen.702
- [26] J.S. Moon, C.H. Bae, E.T. Choi, and S.J. Lee, "A Multi-Stage Detection with Image Upscaling for Enhancing Small Object Detection in Early Fire Detection," *Journal of Embedded Systems and Applications*, Vol. 20, No. 3, pp. 147-156, Jun. 2025. DOI: 10.14372/IEMEK.2025.20.3.147
- [27] S.W. Zamir, A. Arora, S. Khan, M. Hayat, F.S. Khan, M.H. Yang, and L. Shao, "Learning Enriched Features for Fast Image Restoration and Enhancement," *IEEE transactions on pattern analysis and machine intelligence*, Vol. 45, No. 2, pp. 1934-1948, Apr. 2022. DOI: 10.1109/TPAMI.2022.3167175
- [28] T.S. Wang, G.T. Kim, M.Y. Kim, and J.W. Jang, "Contrast Enhancement-Based Preprocessing Process to Improve Deep Learning Object Task Performance and Results," *Applied Sciences*, Vol. 13, No. 19, Sep. 2023. DOI: 10.3390/app1319 10760
- [29] S.W. Zamir, A. Arora, S. Khan, M. Hayat, F.S. Khan, and M.H. Yang, "Restormer: Efficient Transformer for High-Resolution Image Restoration," *Proceeding of the IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR)*, pp. 5728-5739, Nov. 2021. DOI: 10.48550/arXiv.2111.09881
- [30] J.H. Song, M.S. Hong, Y.G. Kim, and J.R. Kim, "Improving Person Detection Performance via Depth Estimation-Based Data Refinement," *Journal of Broadcast Engineering*, Vol. 29, No. 6, pp. 783-793, Nov. 2024. DOI: 10.5909/JBE.2024.29.6.783
- [31] Y.G. Shin, and Y.H. Yoo, "Smart Factory Safety System Using Artificial Intelligence Object Detection," *KIISE Transactions on Computing Practices*, Vol. 28, No. 10, pp. 493-504, 2022. DOI: 10.5626/KTCP.2022.28.10.493
- [32] A. Krizhevsky, I. Sutskever, and G.E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Communications of the ACM*, Vol. 60, No. 6, pp. 84-90, Jun. 2017. DOI: 10.1145/3065386
- [33] M.A. Kang, "Structure and Development Trends of YOLO Object Detection Models," *Journal of artificial intelligence convergence technology*, Vol. 5, No. 1, pp. 43-48, Mar. 2025. DOI: 10.23374/jaict.2025.5.1.007
- [34] Large Benchmark Datasets, *Logistics Computer Vision Model*, <https://universe.roboflow.com/large-benchmark-datasets/logistics-sz9jr>
- [35] Avian AG, *spark-detector Computer Vision Model*, <https://universe.roboflow.com/avian-ag-sd77w/spark-detector>
- [36] BHARATH MUNDLURU, exxxx, <https://www.kaggle.com/code/bharathmundluru/exxxx/notebook>

Authors



Ju-Yeong Park received the M.S. degree in Data Science from Chonnam National University in 2025. He is currently a research scientist at the Korea Photonics Technology Institute (KOPTI).

Interests: Image Processing, Machine Learning.



Jeongrok Yun received his M.S. degree of Science in Electrical Engineering and Computer Science from Chonnam National University in 2019. He is currently a research scientist at the Korea Photonics

Technology Institute (KOPTI). Interests: Image Processing, Machine Learning.



Hoe-Min Kim received a B.S. in mechanical engineering from Chung-Ang University, Korea in 2002, and M.S. and Ph.D. degree in mechatronics at GIST in 2004 and 2012, respectively.

He is currently a principal researcher of Korea Photonics Technology Institute (KOPTI) in Gwangju, Republic of Korea. His research interests include realistic image synthesis, AI and AR/VR.



Un-Yong Kim received the B.S. degree in Computer Science from Honam University in 2018. He is currently a research scientist at the Korea Photonics Technology Institute (KOPTI).

Interests: Image Processing, Machine Learning.



Jin-Taek Seong received the B.S. degree from the University of Seoul, Seoul, Korea, in 2006 and the M.S. and Ph.D. degree from the Gwangju Institute of Science and Technology (GIST), Gwangju, Korea, in 2008 and 2014,

respectively. He was an associate professor at the Department of Convergence Software, Mokpo National University from March 2018 to February 2023. Since then, he is currently working as a full professor at the Graduate School of Data Science, Chonnam National University. His main research interests include artificial intelligence, information theory, and data analysis in multi-domain areas.



Sungkuk Chun received his B.S. and M.S. degrees in Media Engineering from Soongsil University, Seoul, Korea, in 2009 and 2011, respectively, and earned his Ph.D. in HCI and Robotics from the University of Science

and Technology (UST), Korea, in 2017. He is currently a senior research scientist at the Korea Photonics Technology Institute (KOPTI). His research interests include computer vision, artificial intelligence-based human motion analysis, and natural user interaction.