

고차원 통계 지표 융합을 통한 과수원 환경에서의 강건한 Out-of-distribution 탐지

Robust Out-of-distribution Detection in Orchard Environments via Fusion of Higher-order Statistics

조 형 래¹, 장 선 호¹, 홍 형 길¹, 윤 해 롱¹, 조 용 준^{1,*}

(Hyeong Rae Cho¹, Sun Ho Jang¹, Hyunggil Hong¹, HaeYong Yun¹, and Yongjun Cho^{1,*})

¹Korea Institute of Robotics & Technology Convergence

Abstract: Ensuring the safety of autonomous robots in unstructured environments, such as orchards, is challenging because conventional semantic segmentation models often misclassify out-of-distribution (OoD) objects—unexpected obstacles—as traversable areas. These OoD objects lead to silent failures that are difficult to detect but critical for safe operation. A widely used post-processing baseline, Standardized Max Logits (SML), recalibrates per-class logit statistics using the mean and variance, but this first- and second-order summary is still insufficient to characterize complex logit distributions in orchard scenes. In this paper, we propose a simple, training-free OoD detection pipeline that augments SML with higher-order statistics—skewness and kurtosis—computed from per-pixel logit vectors. After min-max normalization, the three scores are fused by element-wise multiplication, which acts as a logical AND gate and raises an alarm only when all indicators consistently suggest an anomaly. Experiments on the large-scale 'Robot Driving in Orchard' dataset (approx. 170,000 images) from AI Hub demonstrate improves all evaluation metrics compared with existing logit-based methods, achieving an Area Under the Receiver Operating Characteristic (AUROC) of 94.57% and an Area Under the Precision-Recall Curve (AUPRC) of 22.35%. In particular, the False Positive Rate (FPR), which is directly related to safety, is reduced by 7.29% relative to SML, significantly minimizing the risk of false alarms for practical implementation [A4] while incurring negligible additional computational cost. These results show that incorporating higher-order logit statistics is an effective way to enhance the robustness of existing segmentation models in real-world agricultural environments and potentially other unstructured domains.

Keywords: semantic segmentation, out-of-distribution, anomaly detection

I. 서론

최근 인공지능 기술의 발전은 농업 분야에 혁신적인 변화를 가져오고 있으며, 특히 과수원 환경에서의 자율주행 기술은 노동력 부족 문제 해결과 생산성 향상의 핵심 기술로 주목받고 있다. 자율주행 로봇이나 차량이 과수원 내에서 효율적으로 작업을 수행하기 위해서는 주행 가능한 경로를 정확히 인지하고 안전하게 이동하는 능력이 필수적이다.

이러한 주행 환경 인지를 위해 의미론적 분할(semantic segmentation) [1] 기술이 널리 활용된다. 의미론적 분할 모델은 입력된 이미지의 모든 픽셀을 비포장 도로, 과수 나무 등 사전에 정의된 클래스로 분류하여 주행 가능 영역을 판단하는 데 효과적이다.

하지만 그림 1처럼 기존 모델들은 학습 과정에서 정의된




그림 1. 분포 외(out-of-distribution, OoD) 객체(방제기)를 도로로 오분류한 예시.

Fig. 1. Misclassification of an out-of-distribution (OoD) object (sprayer) as road.

*Corresponding Author

Manuscript received August 25, 2025; revised November 18, 2025; accepted November 30, 2025

조형래: 한국로봇융합연구원 농업로봇자동화연구센터 주임연구원(hy.cho@kiro.re.kr, ORCID[®] 0000-0002-4984-3784)

장선호: 한국로봇융합연구원 농업로봇자동화연구센터 주임연구원(jang1229@kiro.re.kr, ORCID[®] 0000-0003-2484-4630)

홍형길: 한국로봇융합연구원 농업로봇자동화연구센터 책임연구원(honghg@kiro.re.kr, ORCID[®] 0000-0002-3329-3415)

윤해룡: 한국로봇융합연구원 농업로봇자동화연구센터 책임연구원(hyun@kiro.re.kr, ORCID[®] 0000-0001-6952-5356)

조용준: 한국로봇융합연구원 농업로봇자동화연구센터 센터장(cyj@kiro.re.kr, ORCID[®] 0000-0002-8452-982X)

※ 본 논문은 2025년도 정부(농림축산식품부)의 재원으로 농림식품기술기획평가원의 지원을 받아 수행된 연구임(No.RS-2025-02263472, 2025년 기술사업화지원사업).

클래스 내에서만 예측을 수행한다는 명백한 한계를 가진다. [2] 이로 인해 학습 데이터에 없었던 사람, 과수 상자, 작업 도구와 같은 예상치 못한 장애물이 등장할 경우, 이를 비포장도로나 나무와 같은 기존 클래스로 잘못 분류하는 심각한 문제가 발생한다. 이러한 조용한 실패(silent failure)는 자율주행 시스템의 안전성을 크게 위협하며, 치명적인 사고로 이어질 수 있다.

이러한 문제를 해결하기 위해 다양한 Out-of-Distribution (OoD) 탐지 방법이 연구되어 왔다. 특히 [3]이 제안한 SML (Standardized Max Logits) 기법은 추가적인 학습이나 외부 데이터셋 없이, 사전 학습된 분할 모델의 신뢰도를 재평가하여 예상치 못한 객체를 탐지하는 효과적인 후처리 방식을 제시했다. SML [3]은 모델이 특정 클래스로 예측할 때 출력하는 Logit 값의 분포가 클래스마다 다르다는 점에 착안하여, 이를 클래스별 평균과 분산을 이용해 표준화함으로써 일관된 이상 점수를 산출한다. 이 방법은 도시 자율주행 환경에서 그 성능이 입증되었고, 본 연구의 기반이 되는 핵심 아이디어를 제공한다.

하지만 SML [3]은 분포의 중심 경향성과 퍼짐 정도만을 고려하므로, 더욱 복잡하고 비정형적인 특성을 갖는 과수원 환경의 장애물을 탐지하는 데에는 한계가 있다. 이에 본 연구에서는 로짓 분포의 왜도(skewness)와 첨도(kurtosis)를 추가적인 불확실성 지표로 사용하여 SML [3]을 보완하는 방안을 제안한다. 제안하는 방법은 SML [3]과 불확실성 지표를 비학습 기반의 융합하고, 모든 조건이 동시에 충족될 때만 장애물로 판단함으로써 단일 지표의 노이즈에 강건한 탐지 메커니즘을 구현한다.

본 연구의 주요 기여는 다음과 같다:

- 첫째, 도시 환경에 집중되었던 SML [3] 기반의 OoD 탐지 기법을 과수원이라는 새로운 도메인에 성공적으로 적용하고 그 가능성을 검증하였다
- 둘째, SML [3]을 왜도, 첨도와 같은 고차원 통계 지표와 수학적으로 융합하는 독창적인 후처리 파이프라인을 제안하여, 기반 모델(SML) [3] 대비 더 높은 장애물 탐지 성능을 달성하였다.
- 셋째, 제안하는 기법이 추가 학습 없이 극히 적은 계산 비용으로 동작함을 보여, 실제 과수원 자율주행 시스템에 적용 가능한 실용적이고 효율적인 해결책을 입증하였다.

본 논문은 다음과 같이 구성된다. 2장에서는 관련 연구를 소개하고, 3장에서 제안하는 방법론을 상세히 설명한다. 4 장에서는 실험 설계 및 결과를 분석하고, 마지막 5장에서 결론을 맺는다.

II. 관련 연구

1. 과수원 환경에서의 의미론적 분할

과수원 환경에서의 자율주행을 구현하기 위해, 주행 가능 영역과 장애물을 식별하는 의미론적 분할 기술이 핵심적인 방법으로 연구되어 왔다. 의미론적 분할은 입력 이미지의 모든 픽셀을 사전 정의된 클래스(예: 도로, 나무)로 분류하는 기술로, 이를 통해 자율주행 시스템은 주행 경로를 확고하고 작업을 수행할 기반을 마련한다[1].

초기에는 색상이나 질감 특징에 기반한 전통적인 컴퓨터

비전 기법으로 나무와 지면을 구분하려는 시도가 있었으나, 과수원의 복잡성으로 인해 명확한 한계를 보였다[4]. 최근 FCN [1], UNet [5], DeepLab 시리즈[6]와 같은 딥러닝 모델이 도입되어 분할 성능이 획기적으로 향상되었다. 이러한 연구들은 주로 주행 경로, 나무 기둥, 과일 등 사전에 정의된 ID (In-Distribution) 객체를 정확하게 분할하는 데 집중되었다.

하지만 이들 연구는 과수원 환경의 고유한 난제들에 직면한다. 첫째, 강한 햇빛과 그로 인한 길은 그림자는 픽셀 값의 편차를 키워 모델의 일반화 성능을 저하시키는 주요 원인이 된다[7]. 둘째, 나뭇가지나 잡초 등에 의해 주요 객체가 가려지는 폐색(occlusion) 문제가 빈번하게 발생한다.[8] 마지막으로, 대규모로 공개된 도시 환경 데이터셋(예: Cityscapes [9])과 달리 과수원 환경은 표준화된 데이터셋이 부족하여 특정 환경에 과적합(overfitting)될 위험이 크다.[10]

위에서 언급된 연구들은 조명, 폐색, 데이터 부족과 같은 문제들을 해결하며 ID 객체에 대한 분할 정확도를 높이는 데 크게 기여했다[7,8,10]. 그러나 이들의 공통적인 한계는, 모델이 학습과정에서 보지 못한 예상치 못한 장애물, 즉 OoD 객체에 어떻게 반응하는지에 대한 고려가 부족했다는 점이다. 이는 실제 과수원에서 작업 도구나 사람 등 미지 객체와 마주쳤을 때 발생할 수 있는 심각한 안전 문제를 간과하는 것으로, 본 연구가 해결하고자 하는 핵심 과제와 직결된다.

2. 의미론적 분할에서 Out-of-distribution 탐지 방법론

의미론적 분할에서의 OoD 탐지는 모델이 학습한 ID 객체 범주에 속하지 않는 픽셀이나 영역을 식별하는 것을 목표로 한다. 기존 연구들은 접근 방식에 따라 크게 네 가지로 분류할 수 있다: 불확실성 기반 방법론, 이상치 노출 방법론, 이미지 재구성 기반 방법론, 생성 모델 기반 분류기.

2.1 불확실성 기반 방법론

가장 대표적인 접근법으로, 모델의 예측 불확실성을 정량화하여 OoD 여부를 판단한다. 초기에는 MSP (Max Softmax Probability) 임계값을 사용하는 간단한 방식이 제안되었으나 [2], 모델의 과신(overconfidence) 문제로 인해 성능에 한계가 있었다. 이를 보완하기 위해 출력 로짓(logit)을 표준화하거나 [3], 에너지 함수[11] 및 엔트로피[12]를 활용하여 불확실성 점수를 재정의하는 연구들로 발전했다. 최근에는 임베딩 공간에서 특징 벡터의 밀도를 고려하는 KNN (K-Nearest Neighbor) 기반의 연구도 제안되었다[13].

2.2 이상치 노출 방법론

이 접근법은 학습 과정에서 의도적으로 OoD 샘플을 모델에 노출시켜, ID 데이터와 OoD 데이터를 명시적으로 구분하도록 학습시킨다. 예를 들어, ImageNet [14]과 같은 대규모 외부 데이터셋을 ‘보지 못한 데이터’의 예시로 활용하여 이상치 탐지 성능을 높이거나[15], 최근에는 실제 주행 환경과 유사한 합성 데이터를 생성하여 학습 효과를 극대화하는 연구도 이루어졌다[16].

2.3 이미지 재구성 기반 방법론

재구성 기반 방법론은 오토인코더(autoencoder) [17]나 생성적 대 신경망(generative adversarial network) [18]과 같은 생성 모델을 활용한다. 이 방법론은 모델이 학습한 ID 데이터는 잘 복원하지만, 생성한 OoD 데이터는 제대로 복원하지 못한다는




그림 2. 제안하는 Out-of-Distribution 탐지 모델의 전체 개요.

Fig. 2. Overview of the proposed out-of-distribution detection model.

가정에 기반한다. 따라서 원본 이미지와 재구성된 이미지 간 차이를 계산하여 오류가 큰 영역을 OoD로 탐지한다[19,20].

2.4 생성 분류기

생성 모델 기반 분류기[21,27]는 데이터의 확률 분포 $P(x)$ 를 직접 모델링하는 생성 모델을 분류기에 통합한 방식이다. 클래스 간 경계선 학습에만 집중하는 일반적인 판별 모델과 달리, 데이터가 생성되는 원리 자체를 학습하므로 ID 데이터의 분포를 더 정교하게 표현할 수 있다. GMMseg [21]는 각 클래스의 특징 분포를 가우시안 혼합 모델로 모델링하여 생성적 분류 성능을 높인 대표적인 연구이다.

본 연구는 앞서 소개한 OoD 탐지 기법 중 불확실성 기반 방법론을 채택한다. 이는 과수원에서 운용되는 자율주행 로봇의 실용적 제약조건을 고려한 전략적 선택이다. 즉, 시스템은 실시간 환경 인지가 가능해야 하며, 이미 검증된 분할 모델의 변경이나 재학습 없이도 OoD 탐지 기능을 모듈 형태로 추가할 수 있어야 한다. 외부 데이터셋이나 복잡한 생성 모델을 요구하는 다른 방법론들과 달리, 불확실성 기반 방법론은 기존 모델의 출력값만을 이용하는 후처리 방식이다. 따라서 이는 본 연구가 목표하는 실시간성과 모듈성 요구를 모두 만족시키는 가장 합리적이고 효율적인 접근법이라 할 수 있다.

III. 제안하는 방법

본 장에서는 과수원 환경에서 예상치 못한 장애물을 효과적으로 탐지하기 위한 방법론을 상세히 기술한다. 제안하는 방법론은 사전 학습된 의미론적 분할 모델을 기반으로 하며, 추가적인 학습 없이 출력 로짓(logit)의 통계적 특성을 분석하는 후처리 파이프라인이다.

1. 전체 시스템 개요

제안하는 시스템의 전체 과정은 그림 2와 같다. 먼저, 과수원 이미지로 사전 학습된 분할 모델(DeepLabv3+ [6])에 입력 이미지를 통과시켜 초기 예측 클래스($\hat{Y}$)와 로짓 벡터(F)를 추출한다. 다음으로, 이 로짓 벡터로부터 본 연구의 핵심인 3가지 통계적 특징 맵, 즉 SML [3], 왜도, 첨도를 계산한다. 이 특징 맵들은 각각 고유한 스케일을 가지므로, 학습 데이터셋을 이용해 사전에 계산된 최솟값-최댓값 정규화를 통해 모든 값을 $[0, 1]$ 범위로 통일한다. 마지막으로, 정규화된 3개의 맵을 원소별 곱셈으로 융합하여 최종 이상 점수 맵을 생성한다. 이 맵의 각 픽셀 값은 해당 위치가 OoD 객체일 가능성에 비례한다.

2. Standardized Max Logits

본 연구에서는 과수원 데이터셋으로 학습된 DeepLabv3+

[6]를 기반 분할 모델로 사용한다. 입력 이미지 $X \in R^{3 \times H \times W}$ 가 주어지면, 분할 네트워크는 최종 Softmax 계층 이전의 로짓 출력 $F \in R^{C \times H \times W}$ 를 생성한다. 여기서 C 는 클래스의 수 (본 연구에서는 비포장도로, 과수 나무로 $C=2$), H 와 W 는 각각 이미지의 높이와 너비이다.

각 픽셀 위치 (h, w) 에서의 Max Logit [22] $L_{h,w}$ 과 예측 클래스 $\hat{Y} \in R^{H \times W}$ 는 다음 수식 (1)과 (2)를 통해 계산된다.

$$L_{h,w} = \max_c F_{c,h,w} \quad (1)$$

$$\hat{Y}_{h,w} = \operatorname{argmax}_c F_{c,h,w} \quad (2)$$

SML [3]은 Max Logit 값이 예측된 클래스 $\hat{Y}$ 에 따라 서로 다른 분포를 갖는다는 문제점을 해결하기 위한 기법이다. 이를 위해 SML [3]은 각 클래스별로 Max Logit의 평균과 표준편차를 구해 정규화를 수행한다. 구체적으로, 학습 데이터셋의 모든 픽셀에 대해 특정 클래스(c)로 예측된 픽셀들의 Max Logit 평균(μ_c)과 분산(σ_c^2)을 수식 (3)과 (4)와 같이 사전에 계산한다.

$$\mu_c = \frac{\sum_i \sum_{h,w} \mathcal{I}(\hat{Y}_{h,w}^{(i)} = c) \cdot L_{h,w}^{(i)}}{\sum_i \sum_{h,w} \mathcal{I}(\hat{Y}_{h,w}^{(i)} = c)} \quad (3)$$

$$\sigma_c^2 = \frac{\sum_i \sum_{h,w} \mathcal{I}(\hat{Y}_{h,w}^{(i)} = c) \cdot (L_{h,w}^{(i)} - \mu_c)^2}{\sum_i \sum_{h,w} \mathcal{I}(\hat{Y}_{h,w}^{(i)} = c)} \quad (4)$$

여기서 i 는 학습 샘플의 인덱스, $\mathcal{I}(\cdot)$ 는 지시 함수이다. 이후 추론 단계에서, 각 픽셀의 Max Logit $L_{h,w}$ 는 해당 픽셀의 예측 클래스 $\hat{Y}_{h,w}$ 에 해당하는 μ 와 σ 를 이용해 수식(5)와 같이 SML 값 $S_{h,w}$ 로 표준화된다.

$$S_{h,w} = \frac{L_{h,w} - \mu_{\hat{Y}_{h,w}}}{\sigma_{\hat{Y}_{h,w}}} \quad (5)$$

3. 고차원 통계 지표를 이용한 Out-of-distribution 탐지 방법

SML [3]이 분포의 평균과 분산에 의존하는 반면, 본 연구에서는 로짓 분포의 고차원적 특성을 포착하기 위해 왜도와 첨도를 추가로 활용한다.

3.1 왜도

왜도는 로짓 분포의 비대칭성을 나타내는 지표이다. 본 연구는 정상적인 ID 픽셀의 로짓 분포는 대칭에 가까울 것이라

는 가설에 기반한다. 따라서 왜도 값이 특정 범위를 벗어나 한 쪽으로 치우쳐 있다는 것은 예측의 신뢰도가 낮아지는 이상 신호로 해석될 수 있다. 각 픽셀 (h, w)에서의 왜 도는 다음 수식 (6)과 같이 계산된다.

$$Sk_{h,w} = \frac{\frac{1}{C} \sum_{c=1}^C (F_{c,h,w} - \mu_{h,w})^3}{\sigma_{h,w}^3} \quad (6)$$

여기서 $F_{c,h,w}$ 는 픽셀 (h, w)의 c 번째 클래스 로짓 값이며, $\mu_{h,w}$ 와 $\sigma_{h,w}$ 는 해당 픽셀의 모든 클래스(C) 로짓 값들에 대한 평균과 표준편차이다.

3.2 침도

침도는 로짓 분포의 뽀죽한 정도, 즉 꼬리 분포의 두께를 나타내는 지표이다. 네트워크의 예측 불확실성이 높을 경우, 로짓 분포는 여러 클래스에 걸쳐 확률이 분산되며 완만한 형태를 띤다. 따라서 침도가 낮다는 것은 불확실성이 높은 이상 객체일 가능성을 시사한다. 각 픽셀 (h, w)에서의 침도는 다음 수식 (7)과 같이 계산된다.

$$K_{h,w} = \frac{\frac{1}{C} \sum_{c=1}^C (F_{c,h,w} - \mu_{h,w})^4}{(\sigma_{h,w})^4} \quad (7)$$

한편, 본 연구에서 사용하는 Alhub 과수원 데이터셋은 비포장도로와 과수 나무 두 개의 ID 클래스만을 포함하는 이진 분할 문제($C = 2$)이다. 이 경우 각 픽셀의 로짓 벡터는 차원이 2에 불과하므로, 식 (6), (7)의 왜도와 침도를 고전적인 의미의 표본 모멘트 추정량으로 해석할 때 표본 수가 적다는 한계가 존재한다. 본 연구에서는 이 지표들을 정확한 통계량 추정치라기보다, 두 클래스 로짓 간의 상대적인 분포 모양(평탄도, 집중도 등)을 비선형적으로 압축한 보조 불확실성 특징량으로 사용한다. 따라서 개별 픽셀 수준의 통계량 신뢰도보다는, 전체 학습·평가 데이터의 픽셀 집합에서 이 지표들이 ID와 OoD를 얼마나 잘 분리하는지에 초점을 맞추어 설계 및 검증하였다.

4. 고차원 통계 지표 융합

추출된 3개의 정규화된 특징 맵은 원소별 곱셈을 통해 최종 이상 점수로 융합된다. SML, 왜도, 침도 각 지표는 특정 조건을 만족할 때 이상 객체임을 나타내므로, 수식 (8)과 같이 값이 1에 가까울수록 이상함을 의미하는 일관된 점수 형태로 변환한 후 융합한다.

$$A_{h,w} = (1 - S_{norm}) \times (1 - Sk_{norm}) \times (1 - K_{norm}) \quad (8)$$

여기서 $S_{norm}, Sk_{norm}, K_{norm}$ 은 각각 정규화 및 변환된 SML, 왜도, 침도 값을 의미한다. 수식의 각 항은 독립적인 이상 점수로 기능한다. 예를 들어, 정상 상태를 의미하는 높은 SML값은 $(1 - S_{norm})$ 을 통해 0에 가까운 이상 점수로 변환된다. 이러한 융합 방식은 세 지표 중 단 하나라도 정상 상태(해당 항이 0에 가까워짐)로 판단하면 최종 점수가 크게 낮아지게 만든다. 즉, 제안하는 방식은 모든 통계 지표가 일관되게 이상 신호를 보낼 때만 강하게 반응하는 논리적 AND 게이트 역할을 수행하여, 단일 지표의 노이즈로 인해 발생할 수 있는 오탐지를 효과적으로 억제한다.

IV. 실험 및 결과

본 장에서는 제안하는 이상 탐지 방법론의 우수성을 입증하기 위해 수행한 정량적 및 정성적 평가 결과를 기술한다. 평가는 Alhub 과수원 주행 데이터셋[23]을 대상으로 진행하였으며, 기존의 주요 로짓 기반 방법론들과 성능을 비교 분석하였다.

1. 실험 환경

1.1 구현 세부 정보

본 연구의 분할 아키텍처는 DeepLabv3+ [6]를 채택하였으며, 백본 네트워크로는 ResNet101 [24]을 사용하고 출력 스트라이드는 8로 설정하였다. 네트워크 학습에는 Alhub의 '과수원 내 로봇 주행 데이터'[23]를 사용하였으며, ID 클래스로 정의된 과수 나무와 비포장도로 2개 클래스의 분할 라벨만을 이용하였다. 모든 OoD 탐지 실험에는 이렇게 학습된 동일한 단일 네트워크를 기반으로 하였다.

1.2 평가 지표

정량적 성능은 AUROC (Area Under Receiver Operating Characteristics)와 AUPRC (Area Under the Precision-Recall Curve)를 통해 비교하였다. 또한, 안전이 중요한 자율주행의 특성을 고려하여, 재현율이 95%일 때의 오탐지율을 측정하는 FPR 지표를 추가로 사용하였다[25].

1.3 데이터셋

본 연구에서 제안하는 OoD 탐지 성능을 평가하기 위해, 과수원 환경에서 실제로 자주 등장하지만 학습에는 포함되지 않은 객체들로 별도의 OoD 테스트 세트를 구축하였다. 구체적으로 사람, 손수레, 운반차, 트럭, 방제기, 사다리, 과수박스의 일곱 가지 객체를 사전에 정의되지 않은 OoD 클래스로 설정하고, 각 클래스당 14~15장의 이미지를 수집하여 총 100장의 OoD 테스트 세트를 구성하였다. 구체적으로 사람과 운반차 클래스에는 각각 15장, 나머지 다섯 개 클래스(손수레, 트럭, 방제기, 사다리, 과수박스)에는 각각 14장의 영상을 포함하였다.

2. 정성적 평가

그림 4는 각 방법론이 생성한 이상 점수 맵을 시각적으로 비교한 결과로, 수치만으로는 파악하기 어려운 모델의 실제 탐지 경향을 직관적으로 보여준다. 실험 결과, MSP [2]와 Max Logit [22]은 정작 탐지해야 할 OoD 객체에는 거의 반응하지 못하면서, 오히려 객체의 경계나 비포장도로 표면의 ID 영역



그림 3. Alhub ‘과수원 내 로봇 주행 데이터’[23] 기반 평가 데이터셋 예시.

Fig. 3. Examples of the evaluation dataset based on Alhub’s “Robot Driving in Orchard Data” [23].




그림 4. 방법론별 이상 점수 맵 시각적 비교.

Fig. 4. Visual comparison of anomaly score maps by methodology.

에서 높은 이상점수를 출력하는 것을 보였다. SML [3]은 이들 에 비해 OoD 객체를 탐지하는 경향을 일부 보였으나, ID 배경 여러 곳을 이상으로 판단하여 높은 점수를 부여하는 한계를 나타냈다. 반면, 본 연구에서 제안하는 방법론은 다른 방법들과 명확히 구분되는 강점을 보였다. OoD 객체에 대해서는 높은 이상 점수를 명확히 출력하면서도, 동시에 ID 영역은 OoD 로 오인하지 않고 안정적으로 낮은 점수를 유지했다. 이를 통해 제안하는 방식이 오탐지는 효과적으로 억제하고 실제 위험만을 정밀하게 식별하는, 가장 이상적인 특성을 가짐을 시각적으로 확인할 수 있다.

3. 정량적 평가

제안하는 방법론의 객관적인 성능을 평가하기 위해 기존의 대표적인 로짓 기반 방법론들과 성능을 비교하였으며, 그 결과는 표 1과 같다.

실험 결과, 제안하는 방법론은 모든 평가 지표에서 기존 방법론들을 상회하는 가장 우수한 성능을 달성하였다. 특히, 자율주행 안전성과 직결되는 FPR 지표에서 기존 모델인 SML [3] 대비 7.29% 감소하며 오탐지율을 개선하였다. 이는 제안하는 다차원 통계 지표 융합 방식이 더 강건하고 정밀한 탐지가 가능함을 시사한다.

표 1. 주요 이상 탐지 방법론 성능 비교.

Table 1. Performance comparison of key anomaly detection methodologies.

Method	AUROC ↑	AUPRC ↑	FPR ↓
MSP [2]	88.21	11.35	59.04
Max Logits [22]	90.50	13.76	51.91
SML [3]	92.85	17.57	35.79
Ours	94.57	22.35	28.50

표 2. 주요 이상 탐지 방법론 Out-of-Distribution 객체별 AUPRC 성능 비교.

Table 2. Class-wise AUPRC performance comparison of major anomaly detection methods on OoD objects.

Class	MSP [2]	Max Logits [22]	SML [3]	Ours
Human	11.05	13.15	16.65	21.15
Cart	11.15	13.45	14.05	21.65
Vehicle	11.20	14.65	18.45	22.25
Truck	11.40	13.75	17.45	22.15
Sprayer	11.45	13.85	19.75	22.65
Ladder	11.55	13.85	17.95	22.85
Fruit Box	11.65	14.52	18.69	23.75

추가로, 제안 방법의 클래스별 성능을 보다 세밀하게 분석하기 위해 사전에 정의되지 않은 일곱 개 OoD 클래스(사람, 손수레, 운반차, 트럭, 방제기, 사다리, 과수 박스)에 대한 영상 단위 탐지 성능을 표 2에 정리하였다. 전체 OoD 테스트 세트는 총 100장의 영상으로 구성되어 있으며, 표 2에서 볼 수 있듯이 제안 방법(Ours)은 다양한 OoD 객체에 대해 기존 방법들과 비교하여 전반적으로 우수한 성능을 유지한다. 이를 통해 제안 방법이 특정 객체 유형에 편중되지 않고, 여러 유형의 OoD 객체 전반에서 일관된 탐지 성능을 보임을 확인할 수 있다.

4. 연산 비용 비교

제안하는 방법의 연산 효율성을 입증하기 위해 GFLOPs와 추론 시간을 측정했다. 표 3에 나타난 바와 같이, 제안하는 방법은 기존 모델인 MSP [2], Max Logits [22] SML [3] 대비 GFLOPs와 추론 시간 측면에서 요구하는 추가 연산 비용이 미미하다.

5. 제안 방법론 분석

표 4에서 볼 수 있듯이, 두 지표 중 하나라도 제거할 경우 모든 평가지표에서 성능이 하락하였다. 이는 왜도와 첨도가 서로 상보적으로 작용하며, 최종 탐지 성능 향상에 기여하는 핵심 구성 요소임을 입증한다.

다음으로, 표 5는 왜도와 첨도를 각각 단독으로 사용했을 때의 성능을 나타낸다. 이때 실험 설정은 (5)식의 SML 분기를 완전히 제거하고, (6), (7)식으로 계산된 왜도 혹은 첨도만을 이용해 이상 점수를 구성한 경우이다. 두 지표를 단독으로 사용할 경우 전반적인 OoD 탐지 성능(AUROC, AUPRC)은 표

표 3. Out-of-Distribution 탐지를 위한 연산 비용 비교.

Table 3. Comparison of computational cost for out-of-distribution detection.

Method	GFLOPs	Infer. Time(ms)
MSP[2]	2139.86	60.54
Max Logits[22]	2139.86	59.17
SML[3]	2139.86	75.02
Ours	2139.86	77.90

표 4. 제안 방법의 구성 요소 제거에 따른 성능 변화.

Table 4. Performance analysis by removing components of the proposed method.

Method	AUROC ↑	AUPRC ↑	FPR ↓
Ours (Full)	94.57	22.35	28.50
Ours w/o Skew	93.82	20.54	30.15
Ours w/o Kurto	92.21	20.13	31.68

표 5. 단일 통계 지표 적용 시 성능 비교.

Table 5. Performance comparison when applying a single statistical metric.

Method	AUROC ↑	AUPRC ↑	FPR ↓
Skewness Only	70.34	5.82	17.45
Kurtosis Only	72.18	6.51	18.28

1의 최종 모델(Ours)은 물론 기존 SML에 비해서도 현저히 낮지만, 오탐지율(FPR)은 17-18% 수준으로 오히려 더 낮게 나타난다. 이는 단일 고차원 통계량 기반 이상 점수가 로짓 분포의 꼬리 두께나 비대칭성이 크게 달라지는 극단적인 픽셀에서만 민감하게 반응하는 보수적인 탐지기로 동작하여, 일부 이상 픽셀을 놓치는 대신 정상 픽셀을 이상으로 잘못 탐지하는 비율은 줄어든다는 것을 의미한다. 따라서 전체 탐지율과 오탐지율을 함께 고려했을 때, 단일 고차원 통계 지표만으로는 안정적인 OoD 탐지가 어렵다.

반면, 표 4에서와 같이 SML에 왜도 또는 첨도를 각각 추가한 설정인 Ours w/o Skew와 Ours w/o Kurto에서는 AUROC가 SML의 92.85와 비슷하거나 'Ours w/o Skew'의 경우 93.82로 오히려 향상되며, 두 지표를 동시에 사용하는 Ours (Full)에서 AUROC 94.57과 FPR 28.50으로 가장 우수한 성능을 달성하였다. 이는 1차와 2차 모멘트에 기반한 SML이 전체적인 OoD 감도와 재현율을 확보하고, 왜도와 첨도가 ID와 OoD의 로짓 분포 형태 차이를 이용해 SML이 과대 평가한 영역을 추가로 억제하는 상보적인 역할을 수행하기 때문이다. 다시 말해, 고차원 통계 지표는 단독 OoD 지표라기보다 SML의 결정 경계를 정교하게 다듬는 보조 신호로 기능하며, 세 지표를 함께 융합하는 본 연구의 전략이 보다 균형 잡힌 성능을 제공함을 확인할 수 있다.

나아가 제안 방법론의 신뢰도를 직관적으로 보이기 위해, 그림 5와 같이 ID 및 OoD 데이터에 대한 최종 이상 점수 분포를 시각화하여 기존 SML [3]과 비교하였다.

분석 결과, SML [3]의 경우 ID와 OoD 데이터의 점수 분포가 상당 부분 중첩되어 있어 정상 픽셀이 이상으로 오탐지될 가능성이 상대적으로 높게 나타났다. 반면, 제안 방법론은 ID와 OoD 분포를 효과적으로 분리하여 두 분포 간 중첩 영역을 최소화하였으며, 이는 모델이 정상 ID 데이터를 보다 안정적으로 식별하고 있음을 보여준다. 이러한 결과는 제안 방법이 기존 SML [3] 대비 더 높은 강건성을 가지며, 실제 환경에서의 신뢰성 향상에 기여할 수 있음을 시사한다.

요약하면, 왜도와 첨도는 ID와 OoD를 단독으로 완전히 구분하는 주 지표라기보다, SML이 포착하지 못하는 로짓 분포의 형태 정보를 보완하는 보조 지표로 기능한다. 특히 본 연구와 같이 $C = 2$ 인 이진 분할 환경에서는 고전적인 통계량으로서의 해석 가능성이 제한적이지만, 표 4, 표 5 및 그림 5에서 보이듯이 세 지표를 융합한 경우 AUROC와 AUPRC가 향상되고 FPR이 감소하는 등 실질적인 성능 개선 효과를 확인하였다. 한편, 클래스 수가 보다 큰 일반적인 다중 클래스 상황($C > 2$)에서 고차원 통계 지표의 이론적 분석 및 추가적인 성능 평가를 수행하는 것은 향후 연구 과제로 남겨두고자 한다.




그림 5. 제안 방법론의 ID 및 OoD 점수 분포.

Fig. 5. Distribution of ID and OoD scores for the proposed methodology.

V. 결론

본 연구는 과수원 환경의 자율주행 로봇을 위한 효과적인 예상치 못한 장애물 탐지 기법을 제안한다. 기존 SML [3] 기법이 1, 2차 통계량에만 의존하는 한계를 보완하기 위해, 로짓 분포의 비대칭성을 나타내는 왜도와 뽀족 함을 의미하는 첨도 등 고차원 통계 지표를 융합 하는 독창적인 후처리 파이프라인을 개발했다. 실험을 통해 제안된 방식은 SML [3]을 포함한 기존 방법론들을 모든 평가지표에서 능가했으며, 특히 안전성과 직결되는 오탐지율(FPR)을 약 7.29% 감소시켜 탐지의 정밀성과 강건함을 입증했다.

본 연구의 의의는 SML [3] 기반 OoD 탐지 기법을 과수원이라는 새로운 도메인에 성공적으로 확장하고, 고차원 통계량을 융합하는 독창적인 방법으로 그 성능을 한 단계 발전시켰다는 데 있다. 또한, 추가적인 학습이나 복잡한 연산 없이 가볍게 동작하므로, 실제 농업용 로봇 시스템에 즉시 적용 가능한 실용적인 해결책을 제시했다는 점에서도 의미가 크다.

향후 연구로는, 다양한 분할 네트워크 백본 모델에 제안하는 기법을 적용하여 일반화 성능을 검증할 수 있다. 또한, 각 통계 지표의 신뢰도를 동적으로 반영하는 Attention 기반의 융합 메커니즘을 도입하여 탐지 성능을 더욱 고도화하는 방안을 모색할 계획이다.

REFERENCES

- [1] J. Long, E. Shelhamer, and T. Darrell, "Fully convolutional networks for semantic segmentation," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 3431-3440, 2015.
- [2] D. Hendrycks and K. Gimpel, "A baseline for detecting misclassified and out-of-distribution examples in neural networks," *arXiv preprint arXiv:1610.02136*, 2016.
- [3] S. Jung, J. Lee, D. Gwak, S. Choi, and J. Choo, "Standardized max logits: A simple yet effective approach for identifying unexpected road obstacles in urban-scene segmentation," *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 15425-15434, 2021.
- [4] S. Bargoti and J. P. Underwood, "Image segmentation for fruit detection and yield estimation in apple orchards," *Journal of Field Robotics*, vol. 34, no. 6, pp. 1039-1060, 2017.
- [5] O. Ronneberger, P. Fischer, and T. Brox, "U-net: Convolutional networks for biomedical image segmentation," *International Conference on Medical Image Computing and Computer-assisted Intervention*, pp. 234-241, Springer, 2015.
- [6] L.-C. Chen, Y. Zhu, G. Papandreou, F. Schroff, and H. Adam, "Encoder-decoder with atrous separable convolution for semantic image segmentation," *Proceedings of the European Conference on Computer Vision (ECCV)*, pp. 801-818, 2018.
- [7] A. Milioto, P. Lottes, and C. Stachniss, "Real-time semantic segmentation of crop and weed for precision agriculture robots leveraging background knowledge in cnns," *2018 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 2229-2235, IEEE, 2018.

- [8] I. Sa, Z. Ge, F. Dayoub, B. Upcroft, T. Perez, and C. McCool, "Deepfruits: A fruit detection system using deep neural networks," *Sensors*, vol. 16, no. 8, p. 1222, 2016.
- [9] M. Cordts, M. Omran, S. Ramos, T. Rehfeld, M. Enzweiler, R. Benenson, U. Franke, S. Roth, and B. Schiele, "The cityscapes dataset for semantic urban scene understanding," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 3213-3223, 2016.
- [10] A. Kamilaris and F. X. Prenafeta-Boldu, "Deep learning in 'agriculture: A survey," *Computers and Electronics in Agriculture*, vol. 147, pp. 70-90, 2018.
- [11] Y. Tian, Y. Liu, G. Pang, F. Liu, Y. Chen, and G. Carneiro, "Pixel-wise energy-biased abstention learning for anomaly segmentation on complex urban driving scenes," *European Conference on Computer Vision*, pp. 246-263, Springer, 2022.
- [12] R. Chan, M. Rottmann, and H. Gottschalk, "Entropy maximization and meta classification for out-of-distribution detection in semantic segmentation," *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 5128-5137, 2021.
- [13] D. Dimitric, V. Risojevic, and M. Simic, "Nearest neighbor based out-of-distribution detection in remote sensing scene classification," *2023 22nd International Symposium INFOTEH-JAHORINA (INFOTEH)*, pp. 1-4, IEEE, 2023.
- [14] O. Russakovsky, J. Deng, H. Su, J. Krause, S. Satheesh, S. Ma, Z. Huang, A. Karpathy, A. Khosla, M. Bernstein, et al., "Imagenet large scale visual recognition challenge," *International Journal of Computer Vision*, vol. 115, no. 3, pp. 211-252, 2015.
- [15] D. Hendrycks, M. Mazeika, and T. Dietterich, "Deep anomaly detection with outlier exposure," arXiv preprint arXiv:1812.04606, 2018.
- [16] D. Zhang, K. Sakmann, W. Beluch, R. Hutmacher, and Y. Li, "Anomaly-aware semantic segmentation via stylealigned ood augmentation," *Proceedings of the IEEE/CVF International Conference on Computer Vision*, pp. 4065-4073, 2023.
- [17] D. Bank, N. Koenigstein, and R. Giryes, "Autoencoders," *Machine Learning for Data Science Handbook: Data Mining and Knowledge Discovery Handbook*, pp. 353-374, 2023.
- [18] I. J. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial nets," *Advances in neural information processing systems*, vol. 27, 2014.
- [19] K. Lis, S. Honari, P. Fua, and M. Salzmann, "Detecting road obstacles by erasing them," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 46, no. 4, pp. 2450-2460, 2023.
- [20] Y. Xia, Y. Zhang, F. Liu, W. Shen, and A. L. Yuille, "Synthesize then compare: Detecting failures and anomalies for semantic segmentation," *European Conference on Computer Vision*, pp. 145-161, Springer, 2020.
- [21] C. Liang, W. Wang, J. Miao, and Y. Yang, "Gmmseg: Gaussian mixture based generative semantic segmentation models," *Advances in Neural Information Processing Systems*, vol. 35, pp. 31360-31375, 2022.
- [22] D. Hendrycks, S. Basart, M. Mazeika, A. Zou, J. Kwon, M. Mostajabi, J. Steinhardt, and D. Song, "Scaling out-of-distribution detection for real-world settings," arXiv preprint arXiv:1911.11132, 2019.
- [23] AI-Hub, "Robot Driving Data in Orchards." <https://aihub.or.kr/aihubdata/data/view.do?dataSetSn=71697>, 2023.
- [24] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 770-778, 2016.
- [25] H. Blum, P.-E. Sarlin, J. Nieto, R. Siegwart, and C. Cadena, "The fishyscapes benchmark: Measuring blind spots in semantic segmentation," *International Journal of Computer Vision*, vol. 129, no. 11, pp. 3119-3135, 2021.
- [26] A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, Ł. Kaiser, and I. Polosukhin, "Attention is all you need," *Advances in Neural Information Processing Systems*, vol. 30, 2017.
- [27] H. R. Cho, W.-J. Ahn, S. Cho, J. H. Kim, and M. T. Lim, "VQ-VAE codebooks for detecting out-of distribution objects in urban scenes," *Proceedings of the 2024 Institute of Control, Robotics and Systems Annual Conference*, pp. 173-174, 2024.



조 형 래

2023년 경상국립대학교 정보통신공학과(학사), 2025년 고려대학교 전기전자공학(석사), 2025년~현재 한국로봇융합연구원 주임연구원 관심분야는 농업용 로봇, 컴퓨터 비전, 로봇 비전, 이상 탐지.



장 선 호

2020년 강원대학교 제어계측공학과(학사), 2022년 고려대학교 전기전자공학과(석사), 2022~현재 한국로봇융합연구원 주임 연구원, 2023년~현재 고려대학교 전기전자공학과 박사과정. 관심분야는 강화학습, 자율주행 시스템.



홍 형 길

2012년 동국대학교 전기전자공학과(학사), 2014년 동국대학교 전기전자공학과(석사), 2018년 동국대학교 전기전자공학과(공학박사), 2017~2024년 한국로봇융합연구원 선임연구원, 2024~현재 한국로봇융합연구원 선임연구원, 관심분야는

농업용 로봇, 영상 처리, 자동 제어, 딥러닝.



윤 해 룡

2010년 안동대학교 기계공학과(학사),
2012년 안동대학교 기계공학과(석사),
2017년 안동대학교 기계공학과(공학박사), 2017~2019년 경북테크노파크 선임연구원, 2019~2024년 한국로봇융합연구원 선임연구원, 2024~현재 한국로봇융합연구원 책임연구원, 관심분야는 농업용 로봇, 기계 설계, 센서.



조 용 준

2007년 안동대학교 전자공학과(학사),
2009년 안동대학교 바이오전자공학과(석사), 2019 세종공업(주) 전장연구소 선임연구원, 2019~2022년 한국로봇융합연구원 선임연구원, 2024년 안동대학교 바이오ICT융합공학과(공학박사), 2022~현재 한국로봇융합연구원 농업로봇자동화연구센터 센터장, 관심분야는 센서, 회로설계, 로봇제어, 농업용 로봇.