

겹친 넙치 객체 탐지의 성능 향상을 위한 효과적인 이미지 증강 기법

(Effective Image Augmentation Methods to Enhance the Detection Performance of Overlapping *Paralichthys olivaceus* Objects)

김명환*, 임한규**, 손현승***

(Myeong Hwan Kim, Han Kyu Lim, Hyun Seung Son)

요약

최근 양식장 환경에서 넙치 객체를 정확하게 탐지하는 기술의 중요성이 증가하고 있다. 그러나 복잡한 배경과 어류 간의 높은 밀도로 인해 기존 데이터 증강 기법만으로는 충분한 탐지 성능을 확보하기 어렵다. 본 논문에서는 양식장 환경에 최적화된 새로운 데이터 증강 기법을 제안한다. 제안된 기법은 명확하게 분리된 넙치 이미지를 배경 제거 후, 원본 이미지 내 빈 공간을 탐색하여 적절한 크기와 방향으로 삽입하고, 여러 객체 삽입 시 HSV 값을 일관되게 맞추는 방식을 통해 데이터셋을 확장한다. 이를 통해 비자연적인 객체 간 겹침을 방지하고, 실제 양식장 환경을 반영한 합성 이미지를 생성한다. 제안 기법을 통해 총 404장의 증강 이미지를 추가한 데이터셋을 구성하고 YOLOv8n 모델을 학습한 결과, mAP@50 0.9304로 기존 증강 기법보다 우수한 성능을 기록하였다. 또한, 다른 증강 기법과의 결합을 통해 추가적인 성능 향상 가능성도 확인되었다. 본 연구는 양식장 객체 탐지의 정확도를 높이기 위한 효과적인 데이터 증강 방법을 제시하며, 향후 다양한 어종과 환경에의 확장 가능성을 갖는다.

■ 중심어 : 넙치 ; 수산양식 ; 객체 탐지 ; 이미지 증강 ; YOLOv8

Abstract

Accurate detection of *Paralichthys olivaceus* in aquaculture environments has become increasingly important. However, due to the complex backgrounds and high fish density in aquaculture tanks, existing data augmentation methods are often insufficient to achieve robust detection performance. This study proposes a novel data augmentation technique optimized for aquaculture settings. The proposed method expands the dataset by extracting clearly separated flounder images, removing their backgrounds, and inserting them into empty spaces of the original images with appropriate scaling and orientation. Furthermore, when multiple instances are inserted, their HSV values are unified to maintain color consistency. This approach prevents unnatural overlaps and generates realistic composite images that reflect the complexity of aquaculture environments. Experimental results show that a dataset expanded with 404 augmented images achieves an mAP@50 of 0.9304 using a YOLOv8n model, outperforming datasets generated with conventional augmentation methods. Additionally, combining the proposed technique with other augmentation methods demonstrates the potential for further performance improvement. This study presents an effective data augmentation strategy for enhancing object detection accuracy in aquaculture and offers the potential for broader application to various species and environments.

■ keywords : *Paralichthys olivaceus* ; Aquaculture ; Object Detection ; Image Augmentation ; YOLOv8

최근 국내의 넙치 양식은 전체 어류 양식 생산의 46.8%를 차지할 정도로 경제적 가치가 매우 높다[1].

1. 서론

* 준회원, 한국에너지공과대학교 AI트랙 석사과정

** 정회원, 국립목포대학교 해양수산자원학과

*** 종신회원, 국립목포대학교 컴퓨터학부(컴퓨터공학전공)

이 논문은 2025년도 해양수산부 재원으로 해양수산과학기술진흥원의 지원을 받아 수행된 연구입니다(RS-2022-KS221673, 빅데이터 기반 양식생산성 향상기술).

접수일자 : 2025년 07월 16일

수정일자 : 2025년 08월 12일

게재확정일 : 2025년 09월 05일

교신저자 : 손현승 e-mail : hson@mnu.ac.kr

높은 성장률과 시장 가치로 인해 넙치는 어민들에게 매우 중요한 대상이며, 넙치 자원의 건강과 성장을 유지하는 것이 지속 가능하고 수익성 있는 양식업 운영에 필수적이다.

양식장에서 어류의 건강, 행동, 성장 상태를 지속적인 모니터링으로 문제를 조기에 발견하고 적절한 관리를 할 수 있다[2]. 자동화된 모니터링 시스템은 질병이나 과잉 급식으로 인한 손실을 줄이고 전반적인 생산성을 향상하는데 기여한다. 즉, 넙치의 성장 상태와 질병 징후를 정확하게 파악하면 질병 발생을 예방하고 생산량을 늘릴 수 있으며, 이를 통해 양식업에서 효과적인 관리가 가능해진다. 특히, 넙치의 건강 상태와 성장 속도를 정확히 파악하기 위해서는 신뢰할 수 있는 객체 탐지 기술이 필요하다.

양식업은 전 세계 식량 생산에서 가장 빠르게 증가하는 산업 중 하나이다[3]. 이와 함께 효율성을 높이기 위해 첨단 기술과 데이터 기반 관리 기법이 적극적으로 도입되고 있다. 최근 몇 년 동안, 머신 비전 및 딥러닝 기반 객체 탐지 모델이 양식장에서 자동 모니터링을 위해 폭넓게 활용되고 있다. 이러한 인공지능 기술은 비디오 피드를 실시간으로 분석하여 어류의 수, 크기, 행동 등을 파악함으로써 양식 관리에 필요한 정보를 제공하지만, 양식장의 특수 환경으로 인해 적용에는 여러 어려움이 따른다.

기존 연구[4-5]에 따르면, 자연 해양 환경에서 촬영된 데이터를 기반으로 학습된 객체 탐지 모델들은 개별 어류가 자유롭게 움직이고 비교적 명확한 경계를 갖는 상황에 최적화되어 있다. 그러나 이러한 모델은 밀집된 개체나 복잡한 배경에서 탐지 및 추적 성능이 저하되는 한계를 지닌다. 특히, 양식장 환경은 제한된 수조 공간에서의 고밀도 사육, 빈번한 개체 간 가려짐(occlusion), 탱크 구조물·공기 방울·사료 찌꺼기 등 복잡한 배경 요소, 그리고 수질 변화 등으로 인해 탐지 난이도가 더욱 높아진다. 이러한 환경적 요인은 실제 양식장에서 기존 객체 탐지 방법의 정확도를 저하하는 주요 원인으로 보고되고 있다[6]. 예를 들어, 한 연구에서는 정상적인 조건에서 mAP(mean Average Precision) 0.97을 기록하던 YOLOv8 모델이, 가려짐

이 포함된 데이터셋에서는 mAP가 0.912로 하락하는 결과를 확인하였다[7]. 이는 양식장과 같이 어류 밀도가 높고 구조물이 많은 환경에서 오염률 증가와 탐지 실패의 주요 원인이 될 수 있음을 시사한다.

이 문제를 해결하기 위해 양식장 환경에 적합한 데이터셋을 구축하고, 이를 활용하여 객체 탐지 모델을 효과적으로 학습시킬 필요가 있다. 양식장 환경에서 객체 탐지 모델을 성공적으로 적용하려면 데이터셋의 다양성을 확보하고, 모델의 일반화 성능을 향상하는 것이 중요하다[8].

이미지 증강 기법은 모델 성능을 높이는 주요 도구로 활용된다[9]. 이미지 증강은 기존 이미지를 회전, 뒤집기, 색상 조정, 노이즈 추가 등의 방법으로 변형하여 추가 학습 데이터를 생성하는 기법으로 원본 데이터를 변형하여 데이터셋을 확장하고, 모델이 다양한 조건에서 강건하게 학습할 수 있도록 돕는다[10].

기존의 일반적인 증강 기법(예: 무작위 회전, 뒤집기, 색상 변화)은 기본적인 데이터 다양성을 제공하지만, 양식장의 특수한 문제를 완전히 해결하지는 못한다. 양식장에서 가장 문제되는 경우는 여러 넙치가 겹쳐지거나, 일부 어류가 다른 어류나 탱크 장비에 의해 부분적으로 가려지는 경우이다. 이러한 상황은 기존 증강 기법에서는 충분히 다루지 못하므로, 보다 구체적인 목표 지향적인 증강 접근법이 필요하다.

본 논문에서는 양식장 환경의 특성을 현실적으로 반영하여 객체 탐지 모델의 성능을 향상시키는 새로운 데이터 증강 기법을 제안한다. 제안 기법은 양식장 환경의 복잡한 시각적 특성을 반영한 합성 이미지를 생성하여, 모델이 다양한 밀도와 공간 구성을 효과적으로 학습할 수 있도록 돕는다. 실험 결과, 제안한 기법을 적용한 모델이 기존 데이터 증강 기법을 적용한 모델보다 더 높은 객체 탐지 성능을 기록하였다. 본 논문에서는 양식장 환경에서의 객체 탐지 한계를 극복하고 보다 정확한 넙치 탐지를 가능하게 하는 데이터 증강 기법을 제안함으로써, 실시간 모니터링 시스템의 정밀도를 향상하고 양식업의 생산성을 높이는 데 기여하고자 한다.

II. 관련 연구

1. YOLO 기반 객체 탐지 기술

YOLO(You Only Look Once)는 현재 객체 탐지 분야에서 가장 널리 사용되는 모델 중 하나로, 실시간 탐지 성능과 높은 정확도를 동시에 갖춘 대표적인 기법이다. YOLO는 단일 신경망을 사용하여 이미지 전체를 한 번에 분석하고 객체의 위치와 클래스를 동시에 예측하는 방식으로 작동한다[11].

YOLO는 실시간 탐지 성능과 높은 정확도를 동시에 갖추며 지속적으로 발전해왔다. YOLOv1은 한 그리드 셀이 하나의 객체만 예측할 수 있어 밀집된 객체 탐지에 취약했으나, YOLOv3는 Darknet-53 백본과 FPN(Feature Pyramid Network)을 도입하여 작은 객체 탐지 성능을 향상시켰다[12]. 이후 YOLOv4는 CSPNet 백본, Mosaic 데이터 증강, Mish 활성화 함수 등 다양한 최적화 기법을 적용하여 정확도와 속도를 동시에 끌어올렸다[13]. YOLOv5는 Python 기반의 PyTorch 프레임워크를 활용하여 모델의 경량화와 사용 편의성을 극대화하며 다양한 하드웨어 환경에서 효율적으로 동작할 수 있게 했다[14].

YOLOv8은 비교적 최신 버전으로, 이전 모델보다 정확성과 속도를 향상하면서도 가벼운 구조를 유지하고 있다. YOLOv8은 새로운 아키텍처 설계, 개선된 백본 네트워크, 동적 타일 기반 데이터 증강, 훈련 최적화 기법을 적용하여 이전 YOLO 모델 대비 탐지 성능을 더욱 향상시켰다[15]. 또한, 다양한 하드웨어 환경에서 효율적으로 동작할 수 있도록 설계되어, 경량화된 딥러닝 모델을 필요로 하는 응용 분야에서도 폭넓게 활용되고 있다[16].

YOLOv8 이후에도 YOLOv9와 YOLOv10 등 후속 버전의 연구가 활발히 진행되고 있다. YOLOv9는 PGI(Programmable Gradient Information)와 GELAN(Generalized Efficient Layer Aggregation Network)을 도입하여 학습 중 정보 손실을 최소화

하고 모델의 효율성을 높여, YOLOv8보다 순수 객체 탐지 정확도 측면에서 뛰어난 성능을 보여주었다[17]. 가장 최근에 발표된 YOLOv10은 Non-Maximum Suppression(NMS) 제거를 목표로 한 최초의 End-to-End YOLO 모델로, NMS 없이도 높은 정확도를 유지하며 추론 시간을 획기적으로 단축하여 실시간 응용 분야에서 큰 장점을 제공한다[18].

2. YOLO 기반 어류 탐지 연구

양식장 환경에서의 객체 탐지는 자연 환경과 달리 높은 개체 밀도, 어류 간 빈번한 겹침, 복잡한 배경 요소 등의 문제로 인해 기존의 객체 탐지 모델을 그대로 적용하기 어렵다. 이에 따라 양식장 환경에 최적화된 YOLO 기반 탐지 기법을 개발하기 위한 연구가 활발히 진행되고 있다.

기존 연구에서는 YOLOv8을 활용하여 양식장 내 어류 건강 상태 및 행동을 모니터링하는 시스템을 제안하였다. 해당 연구에서는 비디오 스트림을 실시간 분석하여 어류의 수영 패턴, 이상 행동 등을 탐지하는 딥러닝 모델을 적용하였으며, 이를 통해 비정상적인 움직임을 감지하여 질병 발생 가능성을 조기에 파악하는 데 활용될 수 있음을 보였다[19].

한편, AquaYOLO는 YOLO 기반 탐지 성능을 최적화한 모델로, CSP 네트워크 및 다중 스케일 피쳐 결합을 활용하여 수중 환경에서의 조명 변화 및 어류의 겹침 문제를 해결하는 방식이 연구되었다. 기존 YOLO 모델과 비교하여 AquaYOLO는 보다 높은 정확성과 신뢰도를 제공하며, 양식장 환경에서 실시간 탐지 성능을 향상시키는 것을 목표로 한다[20].

또한, YOLOv8 모델의 가려짐 문제를 해결하기 위한 연구도 활발히 진행되었다. 양식장처럼 어류 밀도가 높아 개체 간 가려짐이 빈번한 환경에서 YOLOv8의 탐지 성능 저하 문제를 극복하기 위해, 한 연구에서는 RT-DETR(Real-time Detection Transf

ormer)의 혁신적인 모듈을 YOLOv8에 통합했다. 특히, 가려짐 상황에서 탐지 성능을 극대화하기 위해 기존의 손실 함수를 Repulsion Loss로 대체함으로써, 객체들이 겹쳐 있을 때에도 각각의 경계 상자를 정확하게 식별하는 능력을 향상시켰다[21].

소형 객체 탐지 및 실시간 성능 향상에 초점을 맞춘 연구도 존재한다. CUIB-YOLO는 YOLOv8n 모델의 경량화를 목표로 개발되었다. 이 모델은 YOLOv8의 C2f 모듈을 새롭게 설계된 C2f-UIB 모듈로 교체하여 모델의 매개변수와 연산량(FLOPs)을 크게 줄였다. 또한, EMA(Exponential Moving Average) 메커니즘을 Neck 네트워크에 도입하여 피쳐 융합 과정을 개선함으로써, 경량화에도 불구하고 원본 모델과 유사한 수준의 높은 정확도를 유지하면서 추론 속도를 향상시켰다. 이러한 접근법은 연산 자원이 제한적인 엣지 컴퓨팅 환경에서도 양식장 어류의 실시간 탐지를 가능하게 한다[22].

이처럼 기존 연구들은 양식장의 특수한 환경을 반영하여 YOLO 모델을 개선하는 방향으로 진행되었으며, 탐지 정확도와 실시간성 향상을 위한 다양한 접근법이 개발되고 있다.

3. 데이터 증강 연구

데이터 증강(data augmentation)은 객체 탐지 모델의 일반화 성능을 높이고 과적합을 방지하기 위해 널리 활용되는 기법이다. 제한된 데이터셋에서 다양한 시각적 변화를 인위적으로 생성함으로써, 모델이 다양한 환경 변화에 적응할 수 있도록 돕는다. 특히, 어류 탐지나 양식장 모니터링처럼 데이터 수집이 어렵고 촬영 환경이 일정하지 않은 경우, 증강 기법의 효과가 더욱 두드러진다.

Lim et al.[23]은 YOLOv5와 YOLOv8을 활용하여 노린재 탐지 모델을 개발하는 과정에서 다양한 데이터 증강 기법을 적용하였다. 연구에서는 뒤집기, 회전, 크기 조정, 대비 조정 등의 증강 기법을 활용하였

으며, 이를 통해 클래스 불균형 문제를 해결하고 탐지 성능을 향상시켰다. 특히, 곱하기(Multiply)와 대비 조정(Contrast) 기법을 적용하였을 때 탐지 성능(mAP50)이 0.992로 가장 높은 결과를 기록하였으며, 특정 클래스에서 오탐지를 줄이는 데 효과적임을 확인하였다.

추가적으로, Watanabe et al.[24]은 한정된 수증 어류 데이터셋 환경에서 PaDiM과 데이터 증강(Neural Filters, Affine Transformations, SinGAN)을 통합한 이상치 기반 탐지 접근을 제안한다. NF와 AT를 적용한 경우, 원본 데이터셋에서의 성능(AUROC 0.836, F1-score 0.483)에 비해 AUROC는 각각 0.940과 0.942로 상승하였으며, F1-score 역시 각각 0.879와 0.766으로 크게 향상되었다. 이러한 결과는 제한된 데이터 환경에서 자동화된 어류 탐지를 향상시킬 잠재력을 시사한다.

Shermaine et al.[25]은 다양한 항공기 탐지 환경에서 객체 인식 성능을 높이기 위해, 이미지 합성(image compositing)을 핵심으로 하는 새로운 데이터 증강 전략을 제안한다. 제안된 방법은 배경 이미지와 객체 이미지를 결합하여 다양한 시각적 조건을 인위적으로 생성함으로써, 학습 데이터의 다양성과 현실성을 동시에 확보하도록 설계되었다. 이를 상용 및 군사용 항공기 이미지로 구성된 맞춤형 데이터셋에 적용하고, YOLOv8 모델을 기반으로 탐지 성능을 평가하였다. 실험 결과, 이미지 합성 기법은 정밀도·재현율·mAP@0.50에서 모든 비교 기법 중 가장 높은 향상을 보였으며(예: mAP 0.911, P 0.904, R 0.907), 복잡한 배경, 다양한 거리, 잡음 등 실제 환경 조건에서도 모델의 범용성과 강건성을 유의하게 개선하는 것으로 확인되었다.

이처럼 다양한 증강 전략이 객체 탐지 모델의 일반화와 성능 극대화를 위해 활발히 연구되고 있다.

III. 제안한 이미지 증강 기법

양식장 낚치 탐지에서는 가려짐, 배경 - 채색 유사성, 밀집 배치로 인해 단순한 좌우 반전·크롭·밝기/대비 조정과 같은 일반적 증강만으로는 성능 향상에 한계가 있다[23]. 이미지 합성 기반 증강은 객체 - 배경 조합을 다양화하여 성능과 강건성을 높일 수 있으나, 합성 흔적과 객체 간 충돌을 정량적으로 통제하지 못하면 일반화 이득이 제한된다[24]. 또한 표적 증강은 난이도 높은 클래스에 선택적으로 적용하여 자원 효율과 성능을 동시에 개선할 수 있으나, 탐지 장면의 공간 배치 문제를 직접 다루지는 않는다[22]. 아울러 포토메트릭/기하 변환은 제한된 데이터 환경에서도 성능 향상에 기여함이 보고되었다[21]. 이에 본 논문은 합성의 장점을 유지하면서 충돌 최소화 및 색상 일관화를 구조적으로 포함한, 낚치 탐지 특화의 객체-수준 합성 증강을 제안한다.

그림 1은 제안한 데이터 증강 기법의 전체 절차를 시각적으로 나타낸 것으로, 본 기법은 객체 분리, 배경 제거, 공간 탐색, 크기 조정, 방향 조정, HSV 조정의 총 여섯 단계로 구성된다.




그림 1. 제안한 증강 기법 구조

표 1은 제안한 데이터 증강 알고리즘으로, 원본 이미지에서 비중첩 객체를 분리한 뒤 배경을 제거하고, 마스크 기반 공간 탐색을 통해 배치 가능한 빈 영역을 찾은 후 크기 조정, 방향 조정(선택적), HSV

색상 보정을 거쳐 합성 이미지를 생성하는 방식이다. 이 과정에서 객체는 평균 크기에 맞추어 스케일링되고 무작위 반전으로 방향성이 다양화되며, 색상·채도·명도는 기준 객체에 맞춰 조정되어 일관성을 유지한다. 최종적으로 빈 영역에 삽입된 객체는 라벨과 마스크가 갱신되어 합성 이미지와 함께 반환되며, 이는 학습 데이터의 다양성과 현실성을 높이는 데 활용된다.

표 1. 데이터 증강 알고리즘

Algorithm 1 데이터 증강 알고리즘

```

1: Step 1: 객체 분리
2: original_images ← load original images
3: isolated_objects ← select non-overlapping objects
   using IoU < 0.01
4: Step 2: 배경 제거
5: clean_objects ← remove background from isolated_o
   bjects (using remove.bg)
6: Step 3: 공간 탐색
7: for image ∈ original_images do
8:   mask ← load corresponding mask image
9:   binary_mask ← binarize(mask)
10:  occupied ← update with existing bounding boxes
11:  integral_img ← compute_integral_image
   (occupied)
12: Step 4: 크기 조정
13: avg_size ← compute average bbox size in image
14: scale_candidates ← [1.0, 0.9, 0.8]
15: Step 5: 방향 조정 (선택적)
16: flip object horizontally and/or vertically at random
17: Step 6: HSV 조정
18: ref_hsv ← get HSV of first object
19: for object ∈ clean_objects do
20:   object ← adjust_to_reference(object, ref_hsv)
21:   candidates ← find_empty_regions(integral_
   img, object size)
22:   if candidates ≠ ∅ then
23:     insert object at random(candidate)
24:     update label and mask
25:   end if
26: end for
27: end for
28: Return: 합성 이미지 및 업데이트된 라벨

```

각 단계(1~6)에 대한 상세한 설명은 아래에서 순차적으로 서술한다.

1. 객체 분리

첫 단계에서는 원본 이미지로부터 객체 간의 겹침 정도를 계산하여, 서로 겹치지 않고 명확히 구분되는 낚치 객체들만 자동으로 추출하였다. 객체 간 겹

침은 IoU(Intersection over Union)를 기반으로 측정하였고, IoU가 0.01 미만인 객체들만 선택하였다. 이를 위해 각 객체의 YOLO 형식 라벨을 이미지 크기에 맞게 변환하여 바운딩 박스를 계산하였고, 모든 객체 쌍 간의 IoU를 비교하였다. 이 과정을 통해 원본 이미지에서 겹치지 않는 객체들만 잘라내어 별도로 저장하였으며, 총 11개의 객체가 추출되었다. 그림 2는 원본 이미지를 나타내며, 그림 3은 IoU 기반으로 분리된 겹치지 않는 객체들의 예시를 보여준다.



그림 2. 원본 이미지



그림 3. 겹치지 않는 이미지

2. 배경 제거

배경 제거는 웹 기반 도구인 [remove.bg](https://www.remove.bg) (<https://www.remove.bg>)를 이용하여 수행한다. 이 도구는 업로드된 이미지에서 객체를 자동으로 분리하고, 배경을 투명하게 제거한다. 이 과정을 통해 배경이 제거된 낚치 객체 이미지를 확보하였다. 그림 4는 그 결과를 보여준다.



그림 4. 배경을 지운 낚치 이미지

3. 공간 탐색

그림 5는 객체 삽입이 허용되는 마스킹 영역을 시각화한 것으로, 이 영역 내에서만 삽입 가능한 빈 공간을 탐색하였다. 먼저, 마스킹 이미지를 이진화하여 삽입 가능 영역(픽셀 값 0)과 불가능 영역(픽셀 값 1)을 구분하였고, 여기에 기존 객체의 바운딩 박스 정보를 반영하여 점유된 영역을 추가로 제외하였다. 이후, 이진화된 마스크를 적분 이미지로 변환하고, 슬라이딩 윈도우 방식으로 지정된 크기의 영역을 이동시키며 해당 영역 내의 픽셀 합을 계산하였다. 픽셀 합이 임계값 이하인 위치는 삽입 가능한 빈 공간으로 간주되어 후보로 저장되며, 최종적으로 이 중 무작위로 하나를 선택하여 객체 삽입에 활용한다.




그림 5. 마스킹 영역 표시

4. 크기 조정

객체 크기 조정은 기존 이미지 내 객체들의 평균 바운딩 박스 크기를 기반으로 수행하였다. 삽입 대상 객체의 원본 크기와 평균 크기를 비교하여 스케일 비율(base_scale)을 계산하고, 해당 비율을 기준으로 1.0, 0.9, 0.8의 세 가지 크기 후보를 생성하였다. 각 크기에 대해 빈 공간 탐색을 수행한 뒤, 삽입 가능한 경우 가장 큰 스케일을 우선 적용하였다. 이를 통해 공간 효율성을 유지하면서도 객체의 왜곡을 최소화할 수 있도록 하였다.

5. 방향 조정

객체 삽입 시 여러 객체가 동시에 배치되는 경우, 동일한 방향으로 정렬될 경우 발생할 수 있는 비자

연스러운 배열을 방지하기 위해 방향을 임의로 조정하였다. 구체적으로는 좌우 및 상하 방향에 대해 flip 연산을 적용하여 객체의 방향을 무작위로 변화시켰으며, 이를 통해 더욱 다양하고 자연스러운 배치를 유도하고, 객체 간 겹침도 최소화하였다.

6. HSV 조정

객체 삽입 시 색상 톤의 일관성을 유지하기 위해, 첫 번째 삽입 객체로부터 HSV(Hue, Saturation, Value) 평균값을 추출하고 이를 참조값으로 사용하였다. 이후 삽입되는 모든 객체들은 해당 참조 HSV와의 채널별 평균 차이를 기반으로 색상, 채도, 명도를 보정하여 전체 이미지의 색감이 자연스럽게 유지되도록 하였다. 이를 통해 원본 이미지 내 어류 수를 인위적으로 증가시키면서도, 실제 양식장 환경과 유사한 색상 분위기를 반영한 현실적인 합성 이미지를 생성할 수 있었다.



그림 6. 생성된 최종 합성 이미지

그림 6은 위의 전 과정을 적용하여 생성된 최종 합성 이미지의 예시를 보여준다.

IV. 실험 및 결과 분석

1. 실험 환경

본 논문에서는 넙치 객체 탐지를 위해 YOLOv8 계열 중 경량화된 YOLOv8n(nano) 모델을 사용하였다. YOLOv8n은 파라미터 수와 연산량이 적어 학습 및 추론 속도가 빠르며, 제한된 연산 자원에서도 실

시간 처리가 가능하다는 장점이 있다. 이는 특히 양식장 CCTV와 같이 장시간 연속 모니터링이 필요한 환경에서 모델을 직접 적용하기에 적합하다. 따라서 본 논문에서는 넙치 객체 탐지 성능을 확보하면서도 실시간 처리와 현장 적용이 가능한 경량 모델을 구현하기 위해 YOLOv8n을 채택하였다. 모델의 학습 파라미터 설정은 에포크 수는 100으로 설정하였으며, 배치 크기는 8, 이미지 크기는 640으로 설정하였다. 최적화 알고리즘으로는 Adam을 사용하였으며, 초기 학습률은 0.002로 설정하였다. 가중치 감소(weight decay)는 0.0005, 모멘텀(momentum)은 0.97로 설정하였다. 이러한 파라미터들은 원본 데이터를 활용한 다양한 조합의 실험을 통해 성능 지표가 가장 우수했던 설정을 기준으로 결정되었다.

데이터셋은 총 410장의 원본 이미지로 구성되었으며, 이 중 304장은 학습 데이터로, 76장은 검증 데이터로, 30장은 최종 모델 성능 평가를 위한 테스트 데이터로 분리하였다. 제안한 증강 기법의 효과를 분석하기 위해, 학습 데이터에 증강 이미지를 5장씩 순차적으로 추가하며 성능 변화를 측정하였다. 이 과정에서 과적합을 방지하고 일반화 성능을 확보하기 위해 검증 데이터셋의 종합 mAP 지표($\text{fitness} = 0.1 \times \text{mAP}@0.5 + 0.9 \times \text{mAP}@0.5:0.95$)가 20 에포크 동안 개선되지 않을 경우 학습을 조기 종료(patience=20)하였고, 테스트 세트는 전량 원본 이미지로 구성하여 합성 편향을 배제한 상태에서 성능을 확인하였다. 최종적으로, 성능이 가장 우수했던 404장의 증강 이미지를 학습 데이터에 추가하여 총 708장(원본 304장 + 증강 404장)으로 모델을 훈련하였다. 모델 성능 평가는 독립적으로 분리한 30장의 테스트 데이터를 사용하였다.

2. 성능 평가 및 결과 분석

본 논문에서는 제안한 데이터 증강 기법의 최적 이미지 수를 결정하기 위해, 219장의 초기 제작 이미

지에서 시작하여 5장씩 추가하면서 YOLOv8n 모델의 성능을 평가하였다. 이는 학습·검증 비용을 과도하게 늘리지 않으면서(전체 학습세트 대비 약 소폭 증분) 성능 곡선의 미세 변동과 상위 포락선 변화를 충분히 관찰하기 위한 절충이다. 그림 7은 F1 Score의 변화를, 그림 8-9는 각각 mAP@50, mAP@50-95의 성능 변화를 나타낸다.




그림 7. F1 Score 성능 지표 그래프




그림 8. mAP@50 성능 지표 그래프




그림 9. mAP@50-95 성능 지표 그래프

본 논문에서는 객체 탐지 성능을 mAP@50, mAP@50-95, F1 Score로 평가한다. mAP@50은 IoU 임계값 0.5에서 클래스별 AP를 평균한 값으로,

객체의 존재/비존재를 안정적으로 구분하는 데 초점을 둔다. mAP@50-95는 0.50-0.95(0.05 간격)의 다중 IoU에서 AP를 평균하는 COCO 지표로, 박스의 정밀한 정합(높은 IoU 값)까지 동시에 요구한다. F1 Score는 정밀도와 재현율의 조화평균으로 검출 성공률의 균형을 나타낸다. 양식장 모니터링의 주된 목표가 개체의 존재 판별, 대략적 위치 추정, 개체 수집계에 있으므로, 경계 상자의 수 픽셀 수준 정합까지 요구하는 높은 IoU 대역(mAP@50-95)보다 존재 검출의 안정성을 민감하게 반영하는 mAP@50을 주지표로 채택한다. 다만 박스 경계 정합 수준과 정밀도-재현율의 균형을 보조적으로 점검하기 위해 mAP@50-95와 F1 Score를 함께 보고한다.

실험 결과, 그림 8과 같이 mAP@50=0.9304로, original(0.9208) 대비 절대 +0.0096(상대 +1.04%) 향상을 보였다. 증강 이미지를 5장 단위로 추가하는 과정에서 mAP@50은 상승과 하락이 교차하는 변동 패턴을 보였으나, 상위 봉우리가 점차 높아지며 404장에서 0.9304로 최대치에 도달하였다. 이는 합성 기반의 겹침 완화·배치 다양화·색감 정합이 존재 검출 안정성을 전반적으로 끌어올린 결과로 해석된다. F1=0.8921로 정밀도-재현율의 균형도 동반 개선되었고, mAP@50-95=0.6138로 original(0.6062) 대비 +0.0076(약 +1.25%) 상승하여 고 IoU 대역에서도 제한적이거나 경계 정합 품질이 향상되었음을 확인하였다. 종합하면, 제안한 데이터 증강 기법은 객체 탐지 성능 개선에 유효하며, 최적 증강 데이터 수는 404장으로 판단된다.

본 논문에서 관찰된 성능 개선은 이미 높은 기준선(original mAP@50=0.9208)에서 달성된 것으로, 절대 0.96%p(상대 1.04%)의 향상은 고기준선 상황에서 유의미한 이득으로 판단된다. 또한 본 방법은 추가 어노테이션 없이 합성 증강만으로 성능을 개선하였으므로 비용 대비 효율성이 높다. 아울러 증강 수 증가에 따른 상위 포락선의 상승과 경험적 최적

점(404장)의 확인은, 과적합 없이 성능이 개선되었음을 시사한다.

표 1에서 확인할 수 있듯이, 제안한 데이터 증강 기법은 기존의 여러 증강 방법에 비해 F1 Score와 mAP@50에서 우수한 성능을 기록하였다. 특히, 제안 방법을 적용하면 mAP@50이 0.9304로 나타났으며, 이는 양식장과 같이 복잡한 환경에서도 객체 탐지의 정확도를 효과적으로 향상함을 시사한다. 반면, 기존 증강 기법(좌우 반전, 그레이스케일 변환, 블러, 노이즈 추가, 크롭, 회전, 전단 변환, 스케일 조정, 대비 및 밝기 조정, 색조 및 채도 변경, 탄성 변형, 퍼스펙티브 변형)과 multiply_contrast 기법은 각각 mAP@50 및 F1 Score에서 제안한 방법보다 다소 낮은 성능을 보였다. 또한, 기존 연구에서 높은 성능을 보인 것으로 평가된 Multiply_Contrast 기법을 적용하여 추가적인 증강 효과를 확인하였다. 그림 11-21은 각 증강 기법을 적용한 결과이다.

표 1. 각 이미지 증강 기법에 따른 모델 성능 평가

증강	F1 Score	mAP@50	mAP@50-95
original	0.8811	0.9208	0.6062
flip	0.8794	0.9197	0.6105
grayscale	0.8700	0.9010	0.5996
blur	0.8894	0.9191	0.6108
noise	0.8506	0.8851	0.5847
crop	0.8747	0.9148	0.6145
rotate	0.8931	0.9225	0.6153
scale	0.8709	0.9107	0.5962
contrast	0.8708	0.9153	0.6082
brightness	0.8732	0.9114	0.5958
hue	0.8718	0.9174	0.6037
elastic	0.8753	0.9116	0.5962
perspective	0.8777	0.9203	0.6082
multiply_contrast	0.8855	0.9192	0.6160
제안 방법	0.8921	0.9304	0.6138



그림 10. flip 증강 적용



그림 11. grayscale 증강 적용




그림 12. blur 증강 적용




그림 13. noise 증강 적용



그림 14. crop 증강 적용




그림 15. rotate 증강 적용



그림 16. scale 증강 적용



그림 21. perspective 증강 적용




그림 17. contrast 증강 적용




그림 18. brightness 증강 적용




그림 19. hue 증강 적용



그림 20. elastic 증강 적용

V. 결 론

본 논문은 양식장 환경에서 낚치 객체 탐지 성능을 향상시키기 위해, 겹침이 없는 객체를 분리한 뒤 빈 공간을 탐색하여 배치하고(IoU 제약), 장면 평균 크기에 맞춘 스케일·방향 조정과 참조 HSV 정합으로 색상 톤을 일관화하는 객체-수준 합성 증강을 제안하였다. 제안 기법을 적용해 404장의 합성 이미지를 추가한 결과, $mAP@50=0.9304$ 로 원본 대비 절대 0.96%p(상대 1.04%) 향상되었으며, $F1=0.8921$, $mAP@50-95=0.6138$ 로 보조지표도 동반 개선되었다.

동일 조건에서 비교한 기존 증강들(좌우 반전, 회전, 대비·밝기 조정 등) 대비 $mAP@50$ 기준 최고 성능을 기록하였다. 또한 rotate와 multiply_contrast는 $mAP@50-95$ 에서 제안 방법보다 소폭 높아, 병용 시 높은 IoU 정합 보완의 여지가 있음을 시사한다.

이러한 결과는 합성 과정에서 발생하는 객체 간 충돌과 색상 불일치를 구조적으로 억제하는 설계가 존재 검출 안정성($mAP@50$) 개선으로 연결될 수 있음을 보여준다. 실무적으로는 추가 라벨링 없이 데이터 확충이 가능해 정기적 미세튜닝 등 운영 파이프라인에 부담이 적고, 경량 모델인 YOLOv8n과 결합하면 CCTV·NVR 등 옛지 장비에서도 적용이 가능하다. 운용 시 원본:합성=1:1~1:1.5의 혼합 비율을 권장하며, 합성 경계 이음새·크기 왜곡·색조 불일치에 대한 간단한 품질 점검을 병행하는 것이 바람직하다. 처리 속도에 대한 정량 실험은 본 연구 범위를

벗어나 제출본에는 포함하지 않았다.

합성 이미지는 현장 데이터를 대체하기보다 보완하는 용도로 적절하다. 본 연구는 테스트 세트를 전량 원본 이미지로 구성하여 합성 편향 없이 개선 효과를 확인하였으나, 계절·조도·탁도 변화에 따른 분포 이동에는 추가 검증이 필요하다. 또한 합성 비율 상한과 배치 제약 강도의 조절이 성능과 안정성에 미치는 영향은 실제 운영 환경에 맞춰 점검할 필요가 있다.

본 논문에서 합성 데이터 제작 시 웹 기반 배경 제거 도구를 사용하였다. 대체 구현에 대한 검토는 본 연구 범위를 벗어나며, 이에 따른 도구 의존성은 한계로 남긴다. 또한 합성 이미지의 자연성 점수 산정은 수행하지 않았고, 평가는 전량 원본 테스트 세트에서의 mAP@50, mAP@50-95, F1로 대체하였다.

종합하면, 제안한 증강 기법은 제한된 데이터 상황에서도 양식장 환경의 난점을 완화하며, 낚치 객체 탐지의 정확도와 운용 가능성을 동시에 높일 수 있음을 보였다. 향후에는 다양한 어종·양식장으로의 확장 검증과 최신 탐지 모델과의 결합, 합성 품질 자동 점검 및 혼합 비율 민감도 분석을 통해 적용 가이드를 구체화할 예정이다.

REFERENCE

- [1] 국립수산물학원, “수과원, 제주 낚치 양식장 정해진 장에 담은 포스터 발간,” 보도자료, 2022-11-22. [Online]. Available: https://www.nifs.go.kr/news/actionNewsView.do?MENU_ID=M0000307&NEWS_SEQ=4143 (accessed Jul., 16, 2025).
- [2] D. Li and L. Du, “Recent advances of deep learning algorithms for aquacultural machine vision systems with emphasis on fish,” *Artificial Intelligence Review*, vol. 55, no. 5, pp. 4077-4116, 2022.
- [3] FAO, “The State of World Fisheries and Aquaculture 2020,” Food and Agriculture Organization of the United Nations, p. 8, 2020.
- [4] W. Li, Z. Zhang, B. Jin, and W. Yu, “A Real-Time Fish Target Detection Algorithm Based on Improved YOLOv5,” *Journal of Marine Science and Engineering*, vol. 11, no. 3, p. 572, 2023.
- [5] R. Lumaug and M. Nava, “Fish tracking and counting using image processing,” in *Proc. 2018 IEEE 10th Int. Conf. Humanoid, Nanotechnology, Inf. Technol., Commun. Control, Environ. Manage. (HNICEM)*, pp. 1-4, 2018.
- [6] C. Cai, S. Tan, X. Wang, B. Zhang, et al., “Real-time detection of hypoxic stress behavior in aquaculture fish using an enhanced YOLOv8 model,” *Aquaculture International*, vol. 33, no. 3, 2025.
- [7] E. Li, Q. Wang, J. Zhang, W. Zhang, H. Mo, and Y. Wu, “Fish Detection under Occlusion Using Modified You Only Look Once v8 Integrating Real-Time Detection Transformer Features,” *Applied Sciences*, vol. 13, no. 23, p. 12645, 2023.
- [8] C. Shorten and T. M. Khoshgoftaar, “A survey on image data augmentation for deep learning,” *Journal of Big Data*, vol. 6, no. 1, pp. 1-48, 2019.
- [9] L. Perez and J. Wang, “The effectiveness of data augmentation in image classification using deep learning,” *Convolutional Neural Networks Vis. Recognit*, vol. 11, pp. 1-8, 2017.
- [10] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet classification with deep convolutional neural networks,” in *Advances in Neural Information Processing Systems* vol. 25, 2012.
- [11] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, “You Only Look Once: Unified, Real-Time Object Detection,” in *Proc. IEEE Conf. Comput. Vis. Pattern Recognit. (CVPR)*, 2016, pp. 779-788.
- [12] J. Redmon and A. Farhadi, “YOLOv3: An Incremental Improvement,” *arXiv preprint arXiv:1804.02767*, 2018.
- [13] A. Bochkovskiy, C. Y. Wang, and H. Y. M. Liao, “YOLOv4: Optimal Speed and Accuracy of Object Detection,” *arXiv preprint arXiv:2004.10934*, 2020.
- [14] G. Jocher et al., “YOLOv5,” *GitHub*, 2021. Available: <https://github.com/ultralytics/yolov5> (accessed Jul., 16, 2025).
- [15] Ultralytics, “YOLOv8 Overview,” 2023. [Online]. Available: <https://docs.ultralytics.com/ko/models/yolov8/#overview> (accessed Jul., 16, 2025).
- [16] M. L. Ali and Z. Zhang, “The YOLO Framework: A Comprehensive Review of Evolution, Applications, and Benchmarks in Object Detection,” *Computers*, vol. 13, no. 336, 2024.

- [17] C. Y. Wang, I. H. Yeh, and H. Y. M. Liao, "YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information," In European Conference on Computer Vision, pp. 1-21, 2024.
- [18] W. F. Tian et al., "YOLOv10: Real-Time End-to-End Object Detection," Advances in Neural Information Processing Systems, Vol. 37, pp. 107984-108011, 2024.
- [19] Z. Zhao, "Abnormal Behavior Fish and Population Detection Method based on Deep Learning," Frontiers in Computing and Intelligent Systems, vol. 4, no. 3, pp. 44-48, 2023.
- [20] M. Vijayalakshmi and A. Sasithradevi, "AquaYOLO: Advanced YOLO-Based Fish Detection for Optimized Aquaculture Pond Monitoring," Scientific Reports, vol. 15, no. 6151, pp. 1-10, 2025.
- [21] E. Li, Q. Wang, J. Zhang, W. Zhang, H. Mo, and Y. Wu, "Fish Detection under Occlusion Using Modified You Only Look Once v8 Integrating Real-Time Detection Transformer Features," Applied Sciences, vol. 13, no. 23, p. 12645, 2023.
- [22] Q. Zhang and S. Chen, "Research on Improved Lightweight Fish Detection Algorithm Based on Yolov8n," Journal of Marine Science and Engineering, vol. 12, no. 10, p. 1726, Oct. 2024.
- [23] J. Lim, Y. Choi, and J. Park, "딥데이터 증강 기술을 활용한 딥러닝 기반의 노린재 탐지 연구," 한국산학기술학회논문지, vol. 25, no. 4, pp. 605-613, 2024.
- [24] K. Watanabe, T. Nguyen-Nhu, S. Takano, D. Mori, and Y. Fujimoto, "Data Augmentation for Enhanced Fish Detection in Lake Environments: Affine Transformations, Neural Filters, SinGAN," Animals, vol. 15, no. 10, p. 1466, 2025.
- [25] A. J. N. Shermaine, M. Lazarou, and T. Stathaki, "Image compositing is all you need for data augmentation," in Proc. 17th Int. Joint Conf. Comput. Vis., Imaging Comput. Graphics Theory Appl., pp. 100-107, 2025.

저자 소개



김명환(준회원)

2025년 국립목포대 컴퓨터공학과 학사 졸업

2025년 ~ 현재 : 한국에너지공과대학교 AI 트랙 석사 재학중

<주관심분야 : 영상처리, 딥러닝, 객

체 감지>



임한규(정회원)

1994년 부경대학교 학사 졸업

1996년 부경대학교 석사 졸업

1998년 부경대학교 박사 졸업

1998년 ~ 2013년 : 국립수산물연구원 해양양수산연구소

2013년 ~ 현재 : 국립목포대학교 해양수산자원학과 교수

<주관심분야 : 어류 번식, 양식 동물 생리, 수산동물 양식 등 >



손현승(종신회원)

2007년 홍익대학교 학사 졸업

2009년 홍익대학교 석사 졸업

2015년 홍익대학교 박사 졸업

2021년 3월 ~ 현재 : 국립목포대학교 컴퓨터공학과 조교수

<주관심분야 : 딥러닝, 스마트양식, 메타모델, 모델변환, 테스트, SW재사용>