

수중 방형구 인식을 위한 2단계 딥러닝 파이프라인

김태우¹, 김경민^{2*}

¹제주대학교 인공지능학과 학부생, ²제주대학교 인공지능학과 교수

A Two-Stage Deep Learning Pipeline for Underwater Quadrat Recognition

Tae Woo Kim¹, Gyeong Min Kim^{2*}

¹Student, Department of Artificial Intelligence, Jeju National University

²Professor, Department of Artificial Intelligence, Jeju National University

요약 해양 생태계 조사에서는 사진 방형구 기반 조사를 통해 표준 면적 내 피복률 등 저서생물군집 정보를 정량적으로 기록하지만, 내부 영역 지정과 주석이 반복되어 자동화가 요구된다. 이에 본 연구는 수중 방형구 이미지에서 방형구 내부 영역을 자동 지정하기 위해 객체 검출과 프롬프트 기반 세그멘테이션을 결합한 2단계 파이프라인을 제안한다. 1단계에서 YOLO11 기반 검출 모델로 방형구 바운딩 박스를 추정하고, 2단계에서 추정 박스를 AquaSAM의 박스 프롬프트로 활용하여 내부 영역 마스크를 생성한다. AquaSAM은 SUIM 데이터셋으로 미세조정하였다. 통합 파이프라인 적용 결과, 대부분의 시험 이미지에서 내부 영역 마스크 생성이 가능했으나 해조류 가림, 반사, 저대비 조건에서는 마스크의 연속성 및 완전성이 저하되어 부분 누락이 관측되었다. 이는 박스 프롬프트 기반 분할이 수중 환경에서 방형구 영역 자동 지정에 활용 가능성을 보이지만, 장면 조건에 따른 품질 편차 완화를 위한 강건성 향상과 정량 평가 체계의 확장이 필요함을 시사한다.

주제어 : 수중 이미지, 방형구 인식, 객체 검출, 프롬프트 기반 세그멘테이션, AquaSAM, YOLO11

Abstract Marine ecosystem surveys record benthic community information such as percent cover within a standardized area using photoquadrat based surveys, but automation is required because interior delineation and annotation are repeated. This study proposes a two stage pipeline that combines object detection with prompt based segmentation to delineate the quadrat interior in underwater quadrat images. In Stage 1, a YOLO11 based detector estimates the quadrat bounding box. In Stage 2, the estimated box is used as a box prompt for AquaSAM to generate an interior mask. AquaSAM was fine tuned on the SUIM dataset. When the integrated pipeline was applied, masks were generated for most test images, but continuity and completeness decreased under seaweed occlusion, reflections, and low contrast, and partial omissions occurred. This demonstrates feasibility, but improved robustness and broader quantitative evaluation are needed to reduce quality variation across scene conditions.

Key Words : Underwater images, Quadrat recognition, Object detection, Prompt-based segmentation, AquaSAM, YOLO11

1. 서론

해양 생태계 조사는 잠수사가 수행하는 수중 시각 조사 방법에 기반하여 연안의 얇은 수역을 대상으로 수행된다[1]. 그러나 이는 비용과 시간 소요가 크고 기상 및 잠수 조건과 인력 제약에 의해 조사 범위와 빈도에 제약이 따른다[2]. 따라서, 방형구(quadrat) 또는 사진 방형구(photoquadrat) 기반 조사는 표준화된 면적의 표본 단위를 설정한 뒤 내부 피복률(coverage) 등을 통해 저서생물군집(benthic community) 정보를 정량적으로 기록하는 방식으로 활용된다[3, 4]. 그러나 사진 방형구 기반 분석은 내부 피복률 산출을 위해 수작업 주석과 분석이 반복되어 시간과 비용 부담이 누적될 수 있다[5]. 또한, 저서 이미지에 AI 기반 주석 도구를 적용하려는 시도가 증가하고 있으나, 수작업 주석 부담이 완전히 해소되기 어렵다는 연구결과가 보고된 바 있다[6]. 따라서, 방형구 이미지에서 분석 대상 영역인 방형구 내부를 자동으로 지정하고, 이후 분석 단계로 연계할 수 있는 전처리 자동화는 필수적이다.

수중 광학 이미지는 물의 흡수와 산란 영향으로 대비 저하, 색 편차, 비균일 조명, 흐림 등이 발생하기 쉽다[7]. 탁도와 조명 변화, 복잡한 배경은 객체 검출 성능을 저하시킬 수 있는 요인으로 제시되며[8], 결과적으로 방형구 프레임과 격자선처럼 경계가 얇은 구조의 시각적 단서가 약화될 수 있다. 따라서 수중 환경에서 방형구를 안정적으로 분석하기 위해서는 방형구의 위치를 신뢰성 있게 추정하고 해당 위치 정보를 활용해 방형구 내부 영역을 일관되게 분할(segmentation)하는 절차가 필요하다.

본 연구는 수중 이미지에서 방형구 바운딩 박스를 검출한 뒤 이를 프롬프트로 활용하여 방형구 내부 영역을 분할하는 2단계 파이프라인을 제안한다. 본 연구의 2단계 구성은 프롬프트 기반 세그멘테이션 특성을 활용한다. 1단계에서는 YOLO11 객체 검출 모델을 활용하여 방형구의 바운딩 박스를 추정하고, 2단계에서는 추정된 바운딩 박스를 AquaSAM의 프롬프트로 입력하여 방형구 내부 영역 마스크를 생성한다. 본 논문의 구성은 다음과 같다. 2장에서는 객체 검출 및 프롬프트 기반 수중 세그멘테이션 관련 연구를 정리한다. 3장에서는 YOLO11 학습과 AquaSAM 적용 및 통합 추론과 후처리 과정을 기술한다. 4장에서는 시험 데이터에서의 검출 결과와 통합 세그멘테이션 결과를 제시한다. 5장에서는 결론 및 향후 연구 방향성을 제시한다.

2. 관련 연구

2.1 객체 검출 모델

YOLO(You Only Look Once)는 합성곱 신경망을 기반으로 하는 단일 단계(one-stage) 객체 검출 방식으로, 입력 이미지로부터 바운딩 박스와 클래스 확률을 직접 예측을 수행하는 회귀 기반 객체 검출 방식이다[12, 13]. 추론 구조가 단순하여 실시간 검출 등 다양한 응용 시스템에 활용되고 있으며, 그중 YOLO11은 YOLO의 정확도와 효율성 개선을 위해 제안된 모델이다[11].

2.2 수중 세그멘테이션

박스 또는 점 등의 입력 프롬프트를 조건부로 객체 마스크를 생성하는 SAM(Segment Anything Model)은 범용 프롬프트 기반 세그멘테이션 프레임워크로 제안되었다[9]. 수중 환경에서는 대비 저하, 산란, 조명 변화 등으로 입력 분포가 자연 이미지와 상이하여 기본 SAM의 성능 저하 가능성이 제기되었다. 이에 따라 SAM을 수중 데이터로 미세조정하여 수중 전경 세그멘테이션에 적용 가능한 AquaSAM 연구가 제안되었고, 기존 SAM 대비 수중에서 향상된 성능 결과를 보인 바 있다[10].

3. 연구 방법

3.1 데이터셋 구성

3.1.1 SUIM 데이터셋

본 연구에서는 수중 환경에 특화된 세그멘테이션 성능을 확보하기 위해 SUIM(Semantic Segmentation of Underwater Imagery) 데이터셋을 활용하였다. SUIM은 수중 장면의 의미론적 분할을 위한 데이터셋 및 벤치마크로 제시되었으며, 픽셀 단위 주석이 포함된 수중 이미지를 제공한다[14]. 이를 기반으로 수중 환경에 적합한 세그멘테이션 모델로 미세 조정하기 위해 SUIM 데이터셋 전체 1,525장 중 학습용 1,098장, 평가용 122장, 시험용 305장으로 분할하여 사용하였다. 정답 마스크는 후속 학습 목적에 맞추어 배경(0)과 전경(1)으로 이진화하였으며, 상세 구성 정보는 다음의 <Table 1>과 같다.

<Table 1> AquaSAM Fine-tuning Dataset

Mask labels	Train images	Validation images	Test images	Total
0: Background, 1: Foreground	1,098	122	305	1,525

3.1.2 방형구 데이터셋

방형구 검출 모델인 YOLO11의 학습 및 검증을 위해, 제주대학교 자율운영증점연구소에서 운영하는 이삭플랫폼(ESAC Platform)의 수중 방형구 이미지 데이터셋을 활용하였다[14]. 58장의 이미지를 확보하여 학습용 46장, 검증용 6장, 시험용 6장으로 약 8:1:1로 분할하여 사용하였다. 상세한 구성 정보는 <Table 2>와 같다.

<Table 2> YOLO11 Transfer-learning Dataset

Image class	Train images	Validation images	Test images	Total
1(Quadrat)	46	6	6	58

3.2 모델 학습

3.2.1 YOLO11 전이학습

본 실험의 YOLO11은 COCO 사전학습 가중치로 초기화한 뒤 단일 클래스 방형구 검출을 위해 미세조정하였다. 입력 해상도는 640, 학습은 100 epoch로 설정하여 수행하였으며, 배치 크기는 8을 유지하였다. 학습률은 $1e-2$, weight decay는 0.0005를 각각 적용하였다.

3.2.2 AquaSAM 미세조정

AquaSAM은 SAM의 ViT-B 가중치를 백본(backbone)으로 사용하였다. 모델의 효율적인 학습을 위해 이미지 인코더의 가중치는 동결하였으며 마스크 디코더만을 학습 대상으로 설정하였다. 학습 안정성 확보를 위해 배치 크기 1, 총 학습 횟수(epoch) 200회, 학습률 $1e-5$, 옵티마이저 Adam을 적용하였다. 손실 함수로는 객체의 경계와 픽셀 단위의 정확도를 동시에 고려하기 위해 DiceCELoss를 활용하였다. 모델이 단일 마스크만을 생성하도록 다중 마스크 출력(Multimask output) 옵션을 비활성화하였으며, 실험의 재현성을 위한 난수값은 2025로 고정하였다. 세그멘테이션 미세조정의 연산량을 절감하기 위해 이미지 인코더의 출력 임베딩을 사전 계산하여 활용하였다. 각 이미지는 AquaSAM의 전처리를 적용한 뒤 ViT-B 이미지 인코더를 1회 통과시켜 이미지 임베딩을 생성하고 이를 압축 데이터 형식(.npz)으로 저장하였다. 이후 학습 단계에서는 저장된 임베딩을 로드하여 마스크 디코더만 학습함으로써 에포크마다 이미지 인코더의 반복 연산을 생략하였다.

3.3 추론 및 후처리

3.3.1 박스 프롬프트 생성

YOLO11의 추론 출력은 프레임워크 기본 후처리인 비최대 억제(Non Maximum Suppression)를 거친 최종 예측 박스 집합이며 다중 박스가 존재할 경우 신뢰도가 가장 높은 1개를 프롬프트로 사용하였다. 박스 좌표가 이미지 경계를 벗어나는 경우에도 프롬프트 생성이 안정적으로 이루어지도록 하기 위해, 선정된 바운딩 박스에 대해 이미지 경계 내로 좌표를 제한하는 클리핑 처리를 수행하였다. 이후 AquaSAM의 입력 규격에 맞게 스케일링을 수행하여 최종 프롬프트로 활용하였다. 또한 좌표계 일관성을 위해 원본 해상도 기준으로 좌표를 정규화한 뒤, AquaSAM의 내부 입력 크기에 맞게 변환하였다.

3.3.2 마스크 후처리

본 연구는 AquaSAM으로 입력 프롬프트에 대한 마스크 점수를 산출하고 시그모이드(sigmoid) 활성화함수를 적용하여 확률값으로 변환한 뒤, 0.5의 임계값을 적용한 이진화로 예측 마스크를 생성하였다. AquaSAM은 내부적으로 저해상도(256x256) 마스크를 출력하므로, 생성된 이진 마스크는 최근접 보간(nearest-neighbor interpolation)을 통해 원본 이미지의 해상도로 복원하였다. 이후 검출 단계에서 획득한 바운딩 박스를 기준으로 박스 외부 영역을 0으로 마스크하여 관심 영역을 방형구 주변으로 제한하였다. 최종 마스크는 바이너리 형태로 저장하였으며, 정성적 비교를 위해 원본 이미지 위에 예측 마스크를 반투명 색상으로 합성하여 시각화하였다.

3.4 평가 지표

3.4.1 객체 검출 성능

본 연구에서는 방형구 검출 모델의 성능을 정량적으로 평가하기 위해 정밀도(Precision), 재현율(Recall) 그리고 F1 score를 평가지표로 활용하였다. 각 지표는 혼동 행렬(Confusion Matrix)의 요소인 True Positive(TP), False Positive(FP), False Negative(FN)를 기반으로 계산하였으며 수식은 (1)과 같다.

$$Precision = \frac{TP}{TP+FP} \quad Recall = \frac{TP}{TP+FN} \quad (1)$$

$$F1\ Score = \frac{2 \cdot Precision \cdot Recall}{Precision + Recall}$$

검출 결과 집합에서 평가에 포함할 예측 박스를 선택하기 위한 기준으로 신뢰도(Confidence)를 사용한다. 임계값 c 가 낮을수록 더 많은 예측 박스가 평가에 포함되어 재현율은 증가하는 경향이 있으나 오검출 FP도 함께 증가하여 정밀도가 감소할 수 있다. 반대로 c 를 높이면 오검출은 감소하지만 미검출 FN이 증가하여 재현율이 감소할 수 있다. 따라서 F1 score는 c 변화에 따른 정밀도와 재현율의 trade-off를 반영하는 단일 요약 지표이며, 본 연구에서는 c 를 0-1 범위에서 변화시키며 F1을 산출한 F1-Confidence 곡선을 추가적으로 분석한다. 또한, 예측 결과와 실제 정답 간의 겹침 정도를 측정하기 위해 IoU(Intersection over Union) 지표를 도입하였으며 계산식은 (2)와 같다.

$$IoU(A', A) = \frac{Area(A' \cap A)}{Area(A' \cup A)} \quad (2)$$

여기서 A' 는 모델이 예측한 박스 영역을, A 는 실제 정답 박스 영역으로 정의하였다. A' 와 A 는 IoU를 기준으로 1:1 매칭하며, 본 연구에서 설정한 임계값 $\tau=0.5$ 을 기준으로 IoU가 τ 이상인 매칭을 TP, 매칭되지 않은 예측 박스를 FP, 매칭되지 않은 정답 박스를 FN으로 정의하였다.

3.4.2 세그멘테이션 학습 지표

AquaSAM 미세조정에서는 예측 마스크 M' 과 정답 마스크 M 의 영역 중첩 정도를 반영하기 위해 Dice 계수를 학습 지표로 사용하였다. Dice 계수는 (3)과 같이 정의된다.

$$Dice(M', M) = \frac{2|M' \cap M|}{|M'| + |M|} \quad (3)$$

본 연구에서는 Dice 계수와 교차 엔트로피(Cross Entropy, CE)를 결합한 DiceCE 손실을 최소화하도록 학습을 수행하였다. 학습 과정의 안정성은 DiceCE 손실 곡선의 감소 및 수렴 양상을 통해 확인하였다. 또한 손실 함수로는 객체의 경계와 픽셀 단위의 정확도를 동시에 고려하기 위해 DiceCELoss를 활용하였다.

4. 연구 결과

4.1 실험 환경

본 연구의 모든 학습 및 추론 실험은 Ubuntu 22.04.3 LTS 환경에서 수행하였다. 개발 언어는 Python 3.10을 사용하였으며 딥러닝 프레임워크로 torch 2.5.1을 적용하였다. 객체 검출 모델의 학습 및 추론은 ultralytics 8.3.235 기반으로 구성하였다. 연산 자원은 NVIDIA H100 PCIe 80GB GPU를 사용하였다.

4.2 평가 절차

AquaSAM의 미세조정은 Dice 계수와 교차 엔트로피를 결합한 DiceCE 손실을 최소화하는 방식으로 학습하였다. 학습 과정의 안정성은 에포크별 DiceCE 손실의 변화 추이를 통해 확인하였다. 방형구 시험 이미지에 대해서는 픽셀 수준 정답 마스크가 제공되지 않아 통합 파이프라인의 분할 결과는 정량 지표 산출 대신 정성적으로 분석하였다.


YOLO11의 방형구 검출 성능은 시험 이미지 6장에 대하여 예측 박스와 정답 박스를 비교하여 평가하였다. IoU 임계값 $\tau=0.5$ 를 기준으로 1:1 매칭을 수행하여 TP, FP, FN를 정의하고 Precision, Recall, F1 score를 계산하였다. 또한 Confidence 임계값 c 를 0에서 1까지 변화시키며 각 임계값에서 신뢰도가 해당 임계값 이상인 예측만 평가에 포함한 뒤 동일한 매칭 절차로 F1 score를 산출하여 F1-Confidence 곡선을 도출하였다. 마지막으로, 통합 파이프라인 평가는 동일한 시험 이미지에 대해 YOLO11이 검출한 바운딩 박스를 AquaSAM의 프롬프트로 입력하여 최종 세그멘테이션 마스크를 생성한 뒤, 검출 성공 여부 및 마스크 형상을 기준으로 정성 분석하였다.

4.3 실험 결과 및 분석

4.3.1 방형구 검출 결과


본 절에서는 YOLO11 기반 방형구 검출 성능과 YOLO11-AquaSAM 통합 파이프라인의 정성 결과를 제시한다. 공통적으로 시험 이미지 6장을 대상으로 검출 성능을 평가하였다. 미세조정된 YOLO11의 방형구 검출 성능을 시험 이미지 6장에 대해 분석하였다. Fig. 1은 Confidence 임계값을 변화시키면서 산출한 F1-Confidence 곡선을 나타낸다. 임계값이 낮은 구간에서는 평가에 포함되는 예측 박스의 수가 증가하여 미검출

이 감소하는 경향이 있어 재현율이 유지되지만, 동시에 오검출이 증가하여 정밀도가 저하될 수 있다. 반대로 임계값이 높아질수록 오검출은 감소하나 미검출이 증가하여 재현율이 감소할 수 있으며, 이러한 정밀도와 재현율의 trade-off로 인해 F1 score는 임계값에 따라 변화한다. 본 시험 범위에서는 confidence 0.834 부근에서 F1 score가 최대값을 보였으며 1.00이 관측되었다.



[Fig. 1] F1-Confidence curve

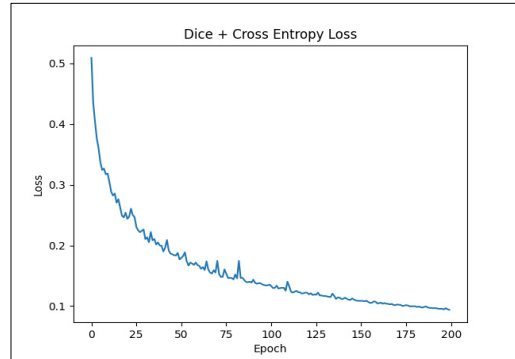
시험 이미지에 대한 정성적 결과는 Fig. 2에 제시하였다. 시각화 결과에서 표시된 Confidence는 0.8~0.9 범위로 나타났으며, 총 6장의 이미지 중 4장이 0.9 신뢰도로 방형구 프레임을 검출하였다. 반면, 해초에 의한 방형구 가림 정도가 비교적 큰 2장의 이미지에서는 상대적으로 낮은 0.8의 신뢰도가 관측되었다.



[Fig. 2] YOLO11 quadrat detections on 6 test images


4.3.2 통합 세그멘테이션 결과

통합 파이프라인은 1단계에서 산출된 바운딩 박스를 2단계 분할 모델의 프롬프트로 입력하여 방형구 마스크를 생성하였으며, Fig. 3은 AquaSAM 미세조정 과정에서 사용한 DiceCE 손실의 에포크별 변화를 나타낸다.



[Fig. 3] DiceCE Training loss curve during AquaSAM Fine-Tuning

DiceCE 손실은 학습에서 최소화하는 목적함수이며, 손실 값이 감소하는 추이는 학습 목적함수 관점에서 모델 파라미터가 갱신되고 있음을 의미한다. Fig. 3에서는 학습 초기에 손실이 크게 감소한 뒤 점진적으로 감소하



[Fig. 4] End-to-End results of integrated pipeline (YOLO11+AquaSAM)

며 완만해지는 양상이 관측되었다. 다만 본 곡선은 SUIM 기반 미세조정의 학습 진행을 나타내는 지표이며, 방형구 시험 이미지에 대해서는 픽셀 수준 정답 마스크가 제공되지 않아 통합 파이프라인의 분할 성능을 Dice/IoU로 직접 정량화하지 못한다. 따라서 통합 파이프라인의 분할 결과는 Fig. 4의 마스크 형상을 중심으로 정성 결과를 제시하였다.

최종 결과는 추가적인 후처리 없이 AquaSAM의 예측 마스크를 원본 해상도로 보간하여 생성하였고, 이를 바운딩 박스와 함께 시각화하였다. Fig. 4는 시험 이미지 6장에 대해 통합 파이프라인을 적용한 정성 결과이다.

실험 결과, 시험 이미지 6장 모두에서 방형구 바운딩 박스가 산출되었으며, 이를 박스 프롬프트로 입력하여 전 샘플에 대한 분할 결과가 생성되었다. 반면 해조류에 의한 가림, 반사, 저대비 조건이 동반된 1번, 2번 샘플에서는 내부 채움이 균일하지 않거나 국소적으로 분절된 마스크가 나타났고, 일부 영역 누락이 확인되었다. 본 파이프라인은 비최대 억제 이후의 예측 박스 집합에서 신뢰도가 가장 높은 1개 박스만을 프롬프트로 사용하며, 이후 후처리 단계에서 검출 박스를 기준으로 박스 외부 영역을 0으로 마스크하여 관심 영역을 제한한다. 이러한 구조에서 Fig. 2와 같이 가림 정도가 큰 일부 시험 이미지(1, 2번 샘플)에서 검출 신뢰도가 상대적으로 낮게 관측된 점은, 가림 조건이 검출 단계의 불확실성을 증가시킬 수 있음을 보여준다. 따라서 가림이나 반사로 인해 검출 박스의 경계가 실제 방형구 프레임과 불일치하거나 박스 내에 배경 성분이 크게 포함되는 경우, 분할 마스크의 연속성과 채움 완전성에 영향이 발생할 수 있음을 시사한다.

5. 결론

본 연구는 수중 이미지에서 방형구를 자동으로 인식하기 위해 YOLO11 기반 객체 검출과 AquaSAM 기반 프롬프트 세그멘테이션을 결합한 2단계 파이프라인을 제안하였다. 제안된 시스템은 YOLO11이 산출한 바운딩 박스를 AquaSAM의 입력 프롬프트로 활용하여 최종 마스크를 생성하도록 구성하였다.

실험 결과, 검출 결과를 프롬프트로 활용한 통합 파이프라인은 시험 이미지에서 방형구 내부 영역 마스크를 생성할 수 있었으며, 프레임 및 내부 격자 식별성이 높은 장면에서는 내부 채움이 비교적 안정적으로 나타났다.

다만 가림과 대비 저하가 큰 장면에서는 마스크의 연속성 및 채움 완전성이 저하되는 사례가 관측되어, 수중 환경 변화에 대한 강건성 향상과 정량 평가의 확장이 필요하다. 또한 방형구 시험 데이터는 픽셀 수준 정답 마스크가 제공되지 않아 통합 파이프라인의 분할 결과는 정량 지표 산출 대신 정성적으로 분석하였다.

향후 연구에서는 해조류 가림과 탁도 변화가 큰 장면을 포함하도록 검출 학습 데이터를 확장하고, 가림에 대한 강건성을 높이기 위한 증강 및 학습 전략을 적용할 필요가 있다. 또한 방형구 프레임과 격자 구조를 직접 학습할 수 있도록 방형구 전용 픽셀 수준 정답 마스크를 구축하여 세그멘테이션 모델을 목표 과제에 맞게 재학습해야 한다. 아울러 통합 파이프라인의 평가를 정량화하기 위해 방형구 내부 또는 프레임 영역에 대한 IoU와 Dice 지표를 체계적으로 산출하고 다양한 수중 환경에서의 일반화 성능을 추가로 검증하고자 한다.

REFERENCES

- [1] T.H.T.Hsu, S.Gordon, R.Ferrari, A.S.Hoey and W.F.Figueira, "Optimizing remote underwater video sampling to quantify relative abundance, richness, and corallivory rates of reef fish," *Coral Reefs*, Vol.44, No.2, pp.435-449, 2025.
- [2] Z.Gold, J.Sprague, D.J.Kushner, E.Zerecero Marin and P.H.Barber, "eDNA metabarcoding as a biomonitoring tool for marine protected areas," *PLOS ONE*, Vol.16, No.2, pp.e0238557, 2021.
- [3] A.J.Spyksma, K.I.Miller and N.T.Shears, "Diver-generated photomosaics as a tool for monitoring temperate rocky reef ecosystems," *Frontiers in Marine Science*, Vol.9, pp.953191, 2022.
- [4] G.Perrois et al., "Environmental impact on marginal coastal benthic communities within the Jeju Island, South Korea temperate transition zone," *Frontiers in Marine Science*, Vol.11, pp.1345518, 2024.
- [5] M.S.Mills, M.Ungermann, G.Rigot, J.den Haan, J.X.Leon and T.Schils, "Coral reefs in transition: Temporal photoquadrat analyses and validation of underwater hyperspectral imaging for resource-efficient monitoring in Guam," *PLOS ONE*, Vol.19, No.3, pp.e0299523, 2024.
- [6] M.Zotou, M.Sini, V.Trygonis, N.Greggio, A.D.Mazaris and S.Katsanevakis, "Towards scalable ecological monitoring: Assessing AI-based annotation of benthic images," *Journal of Marine Science and Engineering*, Vol.13, No.9, pp.1721, 2025.
- [7] Y.M.Alsakar, N.A.Sakr, S.El-Sappagh, T.Abuhmed and

M.Elmogy, "Underwater image restoration and enhancement: A comprehensive review of recent trends, challenges, and applications," The Visual Computer, Vol.41, No.6, pp.3735-3783, 2025.

- [8] M.Jian, N.Yang, C.Tao, H.Zhi and H.Luo, "Underwater object detection and datasets: A survey," Intelligent Marine Technology and Systems, Vol.2, No.1, pp.9, 2024.
- [9] A.Kirillov et al., "Segment anything," in Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV), Paris, France, 2023, pp.4015-4026.
- [10] M.Xu, J.Su and Y.Liu, "AquaSAM: Underwater image foreground segmentation," in Digital Multimedia Communications (IFTC 2023), Beijing, China, 2023, pp.3-14.
- [11] R.Khanam and M.Hussain, "Yolov11: An overview of the key architectural enhancements," arXiv preprint arXiv:2410.17725, 2024.
- [12] J.Redmon, S.Divvala, R.Girshick and A.Farhadi, "You only look once: Unified, real-time object detection," in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, USA, 2016, pp.779-788.
- [13] Y.LeCun, L.Bottou, Y.Bengio and P.Haffner, "Gradient-Based Learning Applied to Document Recognition," Proceedings of the IEEE, Vol.86, No.11, pp.2278-2324, 1998.
- [14] M.J.Islam et al., "Semantic segmentation of underwater imagery: Dataset and benchmark," in 2020 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), Las Vegas, USA, 2020, pp.1769-1776.
- [15] Jeju National University Energy-Smart Agriculture Convergence Education Center, ESAC Platform [Internet], <https://esac.jeju.ac.kr/>

김 경 민(Gyeong Min Kim)

[정회원]




- 2023년 2월 : 고려대학교 컴퓨터학과 (공학박사)
- 2023년 3월 ~ 2024년 2월 : 고려대학교 Human-Inspired AI연구원 박사 후 연구원
- 2024년 9월 ~ 현재 : 제주대학교 인공지능학과 교수

<관심분야>

인공지능(AI), 자연어처리, 언어모델

김 태 우(Tae Woo Kim)

[준회원]



- 2024년 3월 ~ 현재 : 제주대학교 인공지능학과 (학사과정)

<관심분야>

딥러닝, 자연어처리, 언어모델