

딥러닝 기반 물체 탐지 기술을 활용한 넙치(*Paralichthys olivaceus*) 스쿠티카병 주요 증상 진단에 관한 연구

Ri Zheng[†] · Helin Yin[†] · 조미영¹ · 한현자¹ · 김아란¹ · 이남실¹ · 정준범² · 구영현* · 임재웅^{1*}

세종대학교 인공지능데이터사이언스학과, ¹국립수산과학원 병리연구과, ²제주대학교 수산생명의학과

Identifying Major Clinical Signs of Scuticociliatosis in Olive Flounder *Paralichthys olivaceus* Using Deep-Learning-Based Object Detection

RI Zheng[†], Helin Yin[†], Miyoung Cho¹, Hyun-Ja Han¹, Ahran Kim¹, Nam-Sil Lee¹, Joon Bum Jeong², Yeong Hyeon Gu* and Jae-Woong Lim^{1*}

Department of Artificial Intelligence and Data Science, Sejong University, Seoul 05006, Republic of Korea

¹Pathology Research Division, National Institute of Fisheries Science, Busan 46083, Republic of Korea

²Department of Aquatic Life Medicine, Jeju National University, Jeju 63243, Republic of Korea

The olive flounder *Paralichthys olivaceus* is a key aquaculture species in South Korea, accounting for over half of the total farmed fish production in the country. However, frequent disease outbreaks, particularly scuticociliatosis, have economically harmed the aquaculture industry. Conventional approaches to diagnosing scuticociliatosis, such as visual inspection and molecular testing, are subjective, expensive, and unsuitable for field deployment. We developed a two-stage image-based diagnostic pipeline for identifying the major clinical signs of scuticociliatosis using deep learning-based object detection. The first, the olive flounder is localized within the image. Second, six external clinical signs (ulceration, corrosion, erosion, erythema, hernia, and distension) were detected. We evaluated the performance of four object detection models: Faster R-CNN, DETR, YOLO v8, and Co-DETR. The Co-DETR model was superior, with a precision of 94.0% and recall of 97.6%. A prototype web application was developed for practical use in field environments. This study demonstrates the feasibility of applying deep learning-based visual diagnosis in aquaculture and provides a foundation for the development of automated disease detection tools for various fish species.

Keywords: Computer vision, Deep learning, Object detection, Olive flounder, Scuticociliatosis

서론

2024년 통계청 어업생산동향조사 결과(Statistics Korea, 2025)에 따르면, 넙치(*Paralichthys olivaceus*)의 생산량은 약 4만톤으로 전체 수산 양식 생산량의 50% 이상을 차지하며 국내 양식산업에서 경제적, 산업적 가치가 매우 큰 양식어종이다. 다양한 감염성 질병으로 인한 넙치의 폐사가 지속적으로 발생하고 있으며, 이는 양식업자에게 막대한 경제적 피해를 초래하고 있다. 국립수산과학원의 자료에 따르면(NIFS, 2021), 국내 양식생물의 폐사 원인 중 약 54-70%가 감염성 질병에 기인한 것으로 보고되었다. 이러한 대규모 폐사는 양식 산업 전반에 경

제적 타격을 초래할 수 있으며, 따라서 수산생물의 질병을 조기에 진단하고 감염 확산을 사전에 방지하는 것이 매우 중요하다.

기존의 넙치의 질병 진단은 육안 관찰, 분자진단 검사, 병리조직검사 등에 의존해 왔으나 육안 검사는 숙련된 전문가의 경험에 크게 의존하며, 관찰자의 컨디션이나 주관적 판단 등 다양한 요인에 따라 진단 결과가 달라질 수 있어 객관성이 부족하다는 한계가 있다(Hasan et al., 2022). 또한 분자진단을 이용한 검사의 경우, 전문 장비와 실험실 환경이 필요하고, 일반 양식장 현장에서 바로 적용하기 어렵고 높은 비용이 수반된다는 한계가 존재한다(Hwang et al., 2024). 이러한 이유로 최근 수산생물 양식 현장 및 민간 진료기관에서는 현장에서 수산생물질병을 습

*Corresponding author: Yeong Hyeon Gu, Jae-Woong Lim [†]Contributed equally.
Tel:+82. 2. 3408. 2560 Fax: +82. 2. 465. 5266 E-mail: yhgu@sejong.ac.kr
Tel:+82. 51. 720. 2482 Fax: +82. 52. 720. 2498 E-mail: yowoo98@gmail.com



This is an Open Access article distributed under the terms of the Creative Commons Attribution-Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

<https://doi.org/10.5657/KFAS.2025.0263>

Korean J Fish Aquat Sci 58(4), 263-272, August 2025

Received 30 May 2025; Revised 7 July 2025; Accepted 8 August 2025

저자 직위: Ri Zheng(대학원생), Helin Yin(선임연구원), 조미영(연구원), 한현자(연구원), 김아란(연구사), 이남실(박사후연구원), 정준범(교수), 구영현(조교수), 임재웅(연구사)

고 빠르게 진단할 수 있는 보조수단에 대한 수요가 날로 커지고 있는 실상이다.

최근 인공지능 기술의 비약적인 발전으로 인해, 농업, 의료 등 많은 분야에서 활발하게 적용되고 있다. 딥러닝은 인공신경망(artificial neural network)을 기반으로 하는 머신러닝 기법의 하나로, 특히 이미지 인식, 자연어 처리 등 다양한 분야에서 탁월한 성능을 보여주고 있다. 딥러닝 모델은 주로 지도 학습(supervised learning) 방식으로 훈련되며, 이는 입력 데이터와 정답 레이블(label)이 쌍(pair)으로 제공하여 모델이 정확한 출력을 생성하도록 학습하는 방법이다. 영상 처리를 다루는 컴퓨터 비전(computer vision) 분야에서는 주로 분류(classification), 물체 탐지(object detection), 물체 분할(object segmentation) 세 가지 태스크로 구분할 수 있다. 이 중 분류는 이미지 단위로 분석을 수행하며, 입력된 이미지에 대해 가장 높은 확률을 갖는 클래스(class)를 최종 출력한다. 물체 탐지와 물체 분할은 이미지 내 관심영역(region of interests)을 먼저 탐지한 후, 해당 영역에 대해 추가로 분류를 수행하는 태스크이다. 물체 탐지에서는 관심영역을 사각형 형태의 바운딩 박스(bounding box)로 표시하며, 물체 분할에서는 픽셀 단위의 polygon 형태로 표시한다. 분류는 태스크의 특성상 진단 시 관심영역 이외의 불필요한 배경 영역의 영향을 많이 받는 단점이 있다. 반면, 물체 분할은 보다 정교한 탐지가 가능하지만, 데이터 어노테이션(annotation)에 많은 시간과 비용이 드는 단점이 있다. 이러한 이유로 최근 다양한 분야에서는 효율성과 균형을 고려하여 물체 탐지 기술을 활발히 활용하고 있다. 물체 탐지 알고리즘은 크게 one-stage, two-stage, transformer 기반 모델로 구분된다. One-stage 방식은 별도의 영역 제안(proposal) 과정 없이 이미지 내 객체의 위치와 종류를 한 번에 예측하는 구조로, 모델이 경량화되어 빠른 처리 속도를 제공한다. 이러한 특성으로 인해 실시간 처리에 적합하며, 대표적인 알고리즘으로는 YOLO (you only look once)가 있다. Two-stage 방식은 후보 영역을 먼저 생성한 후 분류와 위치 보정을 수행해 정확도가 일반적으로 높지만 속도는 다소 느리고, 대표 모델로는 faster R-CNN이 있다. 최근에는 transformer 구조를 기반으로 한 객체 탐지 모델들이 제안되고 있다. Transformer 기반 방식은 입력 이미지의 전역 정보를 효과적으로 학습하여 기존 CNN 기반 모델의 한계를 극복하고자 하며, DETR과 Co-DETR이 대표적인 예이다.

최근 수산분야에서도 컴퓨터 비전 기술을 활용한 딥러닝 기반 질병 진단 연구가 활발히 이루어지고 있다(AI Noman et al., 2022; Hasan et al., 2022; Son et al., 2022; Cho and Baik, 2023; Pallathadka et al., 2023; Park et al., 2023). 예를 들어, Park et al. (2023)은 분류 알고리즘을 통해 질병 유무 및 상태를 판별하였고, Son et al. (2022)은 다양한 색공간 전처리를 통한 탐지 성능 향상을 시도하였다. Cho and Baik (2023)은 YOLO v8과 swin transformer 모델을 비교하여 다수 질병 및 증상 분류 실험을 수행하였으며, 또한 학습 데이터 부족 문제를 해결하기

위한 이미지 증강 연구도 진행되고 있다(Son and Choi, 2021; Hwang et al., 2024).

이전 선행연구들은 대부분 이미지 전체를 대상으로 특정 질병 여부를 분류하거나, 전처리 또는 알고리즘 유형에 따른 모델 성능 비교에 중점을 두었다. 반면 본 연구에서는 이미지 내에서 낚치 객체를 우선 식별한 후, 해당 개체 내에서 스쿠티카병의 주요 외부 증상 6종(궤양, 부식, 미란, 발적, 탈장, 팽만)을 개별적으로 탐지하는 ‘2단계 진단 파이프라인’을 제안하였다. 이를 통해 기존 수산생물질병 진단 방식보다 현장 적용에 적합한 구조를 구현하고자 하였다. 또한 다양한 최신 탐지 모델의 성능을 비교 분석하고, 최적 모델을 기반으로 실제 적용 가능한 웹 기반 애플리케이션을 구현함으로써 실용성과 확장성 측면에서 차별화를 이루었다.

특히 스쿠티카병의 주요 증상은 활주세균증, 비브리오팀 등 다른 감염병과 중복되는 경우가 많아, 단일 질병 분류보다 증상 단위의 정밀 탐지가 요구된다. 일반적으로 농업의 병해충은 반점, 변색, 곰팡이 형성 등 비교적 명확한 한두 가지 증상만으로 식별이 가능한 경우가 많지만(Jin et al., 2023), 수산 분야에서는 질병 이미지 데이터 확보가 어렵고, 질병 간 증상이 중복되거나 구별이 모호한 경우가 많아 정확한 진단이 더욱 어렵다.

이에 본 연구에서는 양식 현장에서 낚치의 스쿠티카병 주요 증상을 효과적으로 탐지할 수 있는 딥러닝 기반 2단계 영상 진단 파이프라인을 제안하며, 이를 통해 이미지 기반 질병 진단의 정확도와 현장 적용 가능성을 동시에 향상시키고자 한다.

재료 및 방법

학습 데이터 수집 및 데이터 라벨링

본 연구에서는 낚치의 스쿠티카병을 진단하기 위한 2단계 파이프라인을 제안하였다. 1단계에서는 낚치 촬영 이미지에서 불필요한 배경 영역을 제거하고 낚치 객체를 정확하게 탐지하는 과정이 수행되며, 2단계에서는 탐지된 낚치 객체 내에서 주요 외부 증상을 탐지하는 과정으로 구성된다.

본 연구에서는 AI Hub에서 제공하는 낚치 질병 데이터(AI Hub, 2025)를 활용하였으며, 해당 데이터셋은 RGB 이미지와 초분광 이미지로 총 107,915건으로 구성되어 있다. 이 중 RGB 이미지는 60,956건이며, 낚치의 스쿠티카병, 림포시스티스병 등 총 13종의 질병을 포함하고 있다. 또한 이 데이터셋은 객체 탐지(object detection) 과제에 활용할 수 있도록 바운딩 박스(bounding box) 형태로 어노테이션(annotation)되어 있으며, Fig. 1a와 같이 모두 흰색 판넬 위에 낚치가 놓인 상태에서 촬영된 이미지이다.

1단계 낚치 객체 탐지에서는 AI Hub에서 제공하는 ‘낚치 질병 데이터’ 중, 전체 이미지에서 최대한 여러 각도에서 촬영된 낚치 이미지를 선별하여 총 2,654장의 원본 이미지를 확보하였으며, 이를 처음부터 무작위로 섞은 후, 2,454장을 학습용으로, 200장



Fig. 1. Example of olive flounder *Paralichthys olivaceus* object detection dataset. a, Original clinical image; b, Image annotated with bounding box for object detection model training.

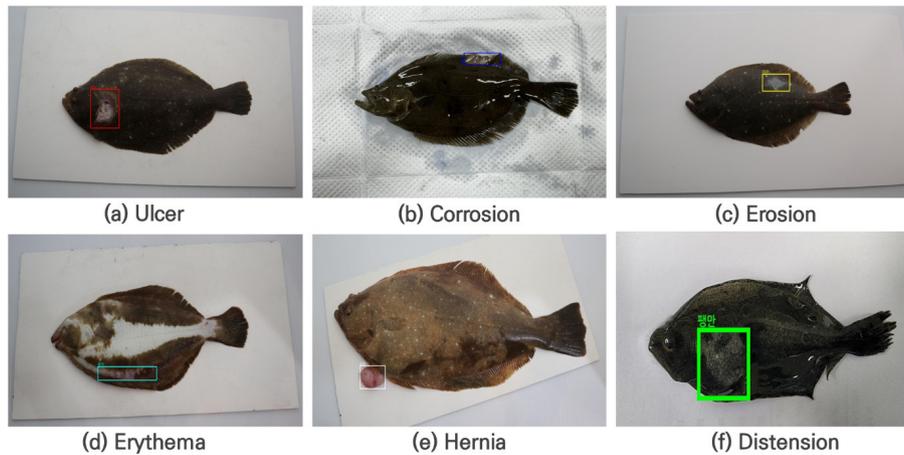


Fig. 2. Representative annotated images for the six major external clinical signs of scuticociliatosis in olive flounder *Paralichthys olivaceus*.

을 테스트용으로 활용하였다. 모든 이미지는 어노테이션 처리가 완료된 상태로 Fig. 1에 그 예시를 제시하였다.

2단계에서는 스키테리카병의 주요 외부 증상 6종에 대한 탐지를 수행하였다(Fig. 2). 해당 단계에서는 AI Hub에서 제공된 ‘넙치 질병 데이터’만을 사용하였으며, 이 중 스키테리카병과 관련된 6종 외부 증상에 해당하는 이미지 데이터를 선별하여 활용하였다. 하지만 제공받은 AI Hub 데이터에는 증상 위치에 대한 어노테이션 오류 및 증상명 불일치 등의 문제가 일부 존재하였다. 이에 보다 정확한 학습 데이터셋 확보를 위해 국립수산과학원과 제주대학교의 수산 질병 전문가들이 참여하여, 제공받은 이미지 중 어노테이션 오류, 증상명 불일치, 그리고 이미지 품질 저하 여부를 면밀히 검토하였다. 검수 과정은 각 이미지별로 증상의 위치와 증상명이 정확히 표기되었는지 확인하는 단계와 증상 유무 및 심각도에 대한 재평가 단계로 구분되었고, 특히 전문가 의견이 서로 상이한 이미지에 대해서는 분석에서 제외하였으며, 여러 차례의 교차 검증을 통해 보다 정확한 증상 이미지만을 선별하였다. 각 증상별 이미지들은 약 9:1 비율로 학습용과 검증용 데이터로 구분하였으며, 최종적으로 증상 탐지 모델 학습에는 1,472장의 이미지가, 검증에는 195장의 이미지가 활용되었다(Table 1).

스쿠테리카병 진단 파이프라인 구성

본 연구에서 제안한 스키테리카병 주요 증상 탐지 파이프라인은 Fig. 3과 같다. 본 파이프라인은 넙치 객체 탐지와 스키테리카병 주요 증상 탐지 두 단계로 구성되어 있다.

임상 이미지 내 일부분만 차지하는 넙치 객체 인식의 정확도 향상을 위해 배경과 같은 잡음(noise) 제거가 필요하다. 이를 위해 Faster R-CNN (Ren, 2016), DETR (Carion et al., 2020),

Table 1. Distribution of training and test image samples for each of the six major clinical signs of scuticociliatosis used in model development and evaluation

Clinical signs	Category ID	Train data	Test data	Total
Ulcer	2	680	85	765
Corrosion	3	349	62	411
Erosion	9	177	20	197
Erythema	10	64	6	70
Hernia	23	100	11	111
Distension	25	102	11	113
Total		1,472	195	1,667

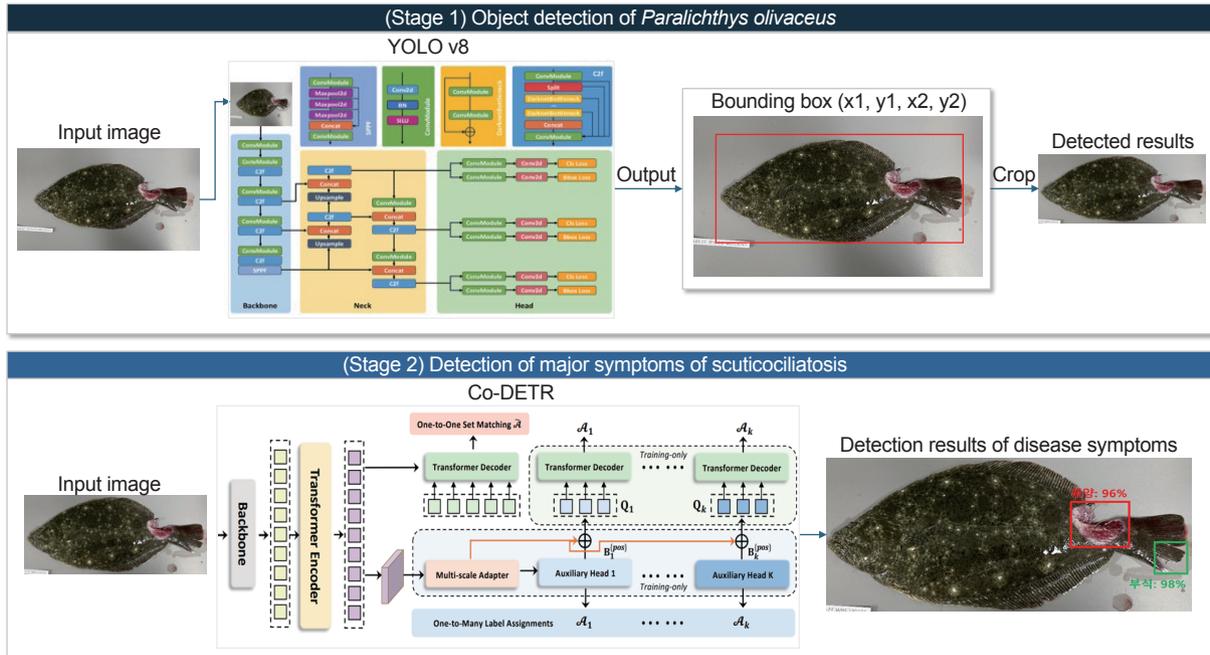


Fig. 3. Schematic of the proposed two-stage deep learning diagnostic pipeline. Stage 1, Olive flounder *Paralichthys olivaceus* detection from clinical images; Stage 2 Identification of six major clinical signs of scuticociliatosis within detected fish regions.

YOLO v8 (Jocher and Qiu, 2023), Co-DETR (Zong et al., 2023) 총 4개 모델의 객체 검출 성능을 평가하였고, 그 중 가장 성능이 우수한 YOLO v8 모델을 사용하였다(Table 2). YOLO v8 모델은 CSPNet (WANG et al., 2020) 구조를 기반으로 네트워크의 연산량을 줄이면서도 중요한 특징 정보의 손실을 최소화되도록 설계되어, 빠른 연산과 높은 정확도를 보인다라는 장점을 갖는다.

넙치 객체 탐지 모델에서는 COCO 데이터셋에서 사전 학습된 (pre-trained) YOLO v8 모델을 기반으로, 보유하고 있는 넙치 이미지를 활용하여 모델을 미세조정(Fine-tuning)하였다. 모델 훈련 시에는 AdamW 최적화 함수를 사용하였고, 학습률(learning rate)은 0.0001, weight_decay는 0.0001, 배치 사이즈(batch size)는 16, 학습 epoch 수는 30으로 설정하였다.

스쿠티카병 주요 증상 탐지 모델 개발을 위해, faster R-CNN, DETR, YOLO v8, Co-DETR의 성능을 비교하였으며, 그 결과 가장 우수한 성능을 보인 Co-DETR 모델을 활용하였다(Table 3).

모델 학습에는 COCO 데이터셋에서 훈련된 Co-DETR 모델을 활용하였으며, 이를 본 연구의 스쿠티카병 주요 증상 데이터셋에 맞게 미세조정(fine-tuning)하였다. 이 때, ResNet50을 백본(backbone) 모델로 사용하였고, AdamW 최적화 함수, 학습률(learning rate) 0.0001, weight_decay 0.0001, 배치 사이즈(batch size) 16, epoch을 30으로 설정해 모델 훈련을 진행하였다.

정확도 평가 방법

모델의 성능을 평가하기 위해, 본 연구에서는 총 3가지 지표인 정밀도(precision), 재현율(recall), IoU (intersection over union)를 사용하였다. 각 성능 지표의 정의 및 수식은 다음과 같다.

정밀도(precision)는 모델이 검출한 객체 중 실제 정답(true positive)인 객체의 비율을 나타내는 지표이다.

재현율(recall)은 실제 정답 객체(true positive+false negative) 중에서 모델이 올바르게 검출한 객체(true positive)의 비율을 나타내는 지표이다.

IoU는 객체 탐지에서 예측한 바운딩 박스와 실제 정답 바운딩 박스 간의 겹치는 정도를 평가하는 지표이다.

$$P = \frac{TP}{TP+FP}$$

$$R = \frac{TP}{TP+FN}$$

$$IoU = \frac{|A \cap B|}{|A \cup B|}$$

- True positive (TP): 모델이 예측한 객체가 실제 정답 객체와 일치하며, IoU가 설정된 임계값을 초과하여 올바르게 검출된 경우를 의미한다.

- False positive (FP): 모델이 검출한 객체가 실제 존재하지 않거나, IoU가 임계값에 미치지 못해 잘못된 검출로 판단되는 경우를 의미한다.
- False negative (FN): 이미지 내에 실제 객체가 존재함에도 불구하고, 모델이 해당 객체를 탐지하지 못했거나, IoU가 임계값 미만으로 누락된 경우를 의미한다.
- A: 예측한 바운딩 박스 영역을 의미한다.
- B: 정답 바운딩 박스 영역을 의미한다.
- $A \cap B$: 두 박스의 교집합 영역의 면적을 의미한다.
- $A \cup B$: 두 박스의 합집합 영역의 면적을 의미한다.

컴퓨터 환경

본 연구의 모든 모델 학습 및 테스트는 Intel Core i9-9900KF processor, 64GB memory, NVIDIA GeForce RTX 3090 GPU가 장착된 컴퓨터 환경에서 수행되었다. 해당 시스템은 Windows 10 Pro 운영체제에서 실행되었으며, 딥러닝 모델 학습은 Python 3.8 환경에서 PyTorch 1.12.0 프레임워크와 CUDA Toolkit 11.3 (NVIDIA, Santa Clara, CA, USA)을 활용하여 진행하였다.

결 과

넙치 객체 탐지 모델의 성능 비교

YOLO v8, Faster R-CNN, DETR, Co-DETR 모델을 대상으로 넙치 객체 탐지 성능을 비교한 결과, 모든 모델이 정밀도 (precision), 재현율(recall), IoU 측면에서 전반적으로 높은 성능을 보였다(Table 2).

그중에서도 YOLO v8 모델이 IoU 97.2%로 가장 높은 값을 기록하였으며, 정밀도와 재현율도 각각 99.1%, 96.8%로 우수하였다. 이는 넙치 객체가 포함된 다양한 환경과 촬영 각도에서도 안정적인 탐지가 가능함을 의미한다.

Table 2에 제시된 바와 같이, YOLO v8 모델은 빠른 연산 속도와 높은 정확도를 동시에 만족시킴으로써 실제 현장에서의 활용 가능성을 높여준다. Fig. 4에서는 넙치 객체에 대한 실제 탐

지 예시를 시각적으로 확인할 수 있다.

스쿠티카병 주요 증상 탐지 모델의 성능 비교

스쿠티카병 주요 증상 6종에 대해 네 가지 모델의 탐지 성능을 비교하였고, 그 결과를 Table 3에 제시하였다.

스쿠티카병 주요 증상 6종에 대해 네 가지 모델의 탐지 성능을 비교한 결과, Co-DETR 모델이 전반적으로 가장 우수한 결과를 보였다(Table 3). 평균 정밀도는 94.0%, 재현율은 97.6%로 나타났다. 이는 다른 모델 대비 정밀도는 약 2-8%, 재현율은 약 14-25% 이상 높은 성능이다. 특히, Co-DETR 모델은 각 증상 별로도 고르게 높은 재현율을 기록하였으며, 이는 실제 병변을 놓치지 않고 탐지할 가능성이 높다는 점에서 중요한 의미를 가진다. Co-DETR 모델을 활용한 6종 주요 증상 탐지 결과는 Fig. 5에 제시하였다.

혼동 행렬(confusion matrix)은 분류 또는 탐지 모델의 성능을 정량적으로 평가하기 위한 도구로, 실제 클래스와 모델이 예측한 클래스 간의 관계를 시각적으로 확인할 수 있다. 본 실험에서 6종의 스쿠티카병 주요 증상 6종에 대한 각 모델의 탐지 성능을 보다 구체적으로 분석하기 위해 혼동 행렬을 활용하여 성능을 평가하였다. 그 결과, 일부 증상이 다른 증상으로 오분류되거나 배경으로 인식되어 누락된 경우가 있었으나, 대부분은 정확히 탐지되었다(Fig. 6).

Fig. 6a, 6b, 6c는 Faster RCNN, DETR, YOLO v8 모델의 혼동행렬로 서로 다른 증상으로의 오탐지된 일부 사례를 확인할 수 있다. 그러나 대부분의 오탐지 사례는 실증 증상 부위를 배경(background)으로 잘못 분류되어 탐지하지 않았다는 것을 확인할 수 있다.

Table 2. Comparison of object detection performance (precision, recall, and IoU) across four deep learning models for localizing olive flounder *Paralichthys olivaceus* in clinical images

Detection models	Precision	Recall	IoU
Faster R-CNN	0.977	0.986	0.962
DETR	0.943	0.977	0.967
Co-DETR	0.991	0.922	0.912
YOLO v8	0.991	0.968	0.972

IoU, Intersection over union.



Fig. 4. Example outputs showing successful detection of olive flounder *Paralichthys olivaceus* from clinical images using the YOLO v8 model. Bounding boxes represent the predicted fish regions.

마지막으로 Co-DETR 모델은 모든 증상에 대해 재현율 0.941 이상을 기록하며, 다른 모델들과 비교하여 전반적으로 가장 우수한 성능을 보였다. 특히 정밀도와 재현율 모두에서 균형 잡힌 높은 수치를 달성하여, 스쿠티카병 주요 증상 탐지에 가장 효과적인 모델로 평가되었다. 그럼에도 불구하고, 발적 증상에서 1건이 궤양으로 오분류되었고, 궤양, 팽만, 미란 증상에서는 각각 4건, 1건, 2건을 배경으로 잘못 인식하여 누락된 것을 확인할 수 있다.

요약하면, 넙치 객체 탐지에는 YOLO v8 모델이, 스쿠티카병 주요 증상 탐지에는 Co-DETR 모델이 가장 적합한 것으로 판단되며, 제안된 2단계 진단 파이프라인의 유효성이 실험적으로 입증되었다.

넙치 스쿠티카병 주요 증상 탐지 애플리케이션

본 연구에서는 제안한 스쿠티카병 주요 증상 진단 파이프라인을 기반으로, 양식 현장에서 간편하게 활용할 수 있는 프로토타입 애플리케이션(prototype application)을 개발하였다. 이 애플

리케이션은 HTML5, JavaScript, jQuery 기반으로 한 웹(web) 기반 구조로 구현되었으며, Apache 2.4.6 웹 서버와 CentOS 운영체제 환경에서 구동된다. 백 엔드(back-end)는 Python 3.8 기반의 Django 3.1.3 프레임워크로 구성되었고, 주요 기능은 RESTful API 형태로 제공될 수 있도록 개발하였다.

개발한 넙치 스쿠티카병 주요 증상 탐지 애플리케이션의 기능은 넙치 이미지 업로드, 넙치 스쿠티카병 증상 탐지, 넙치 스쿠티카병 증상 탐지 결과 분석이며, 애플리케이션은 총 7개의 화면으로 구성되었고 그 예시는 Fig. 7과 같다.

홈 화면(Fig. 7a): 사용자는 점선으로 표시된 영역을 클릭하여 분석할 이미지를 업로드할 수 있다.

이미지 업로드 화면(Fig. 7b): 이미지 업로드 방식은 '직접 촬영(Fig. 7c)' 또는 '갤러리에서 불러오기(Fig. 7d)' 중 선택 가능할 수 있게 구현하였다.

업로드한 이미지 확인(Fig. 7e): 업로드된 이미지를 검토할 수 있으며, 만약 입력된 이미지가 잘못된 경우, '뒤로 가기' 기능을 통해 이미지를 다시 등록할 수 있도록 구성되었다.

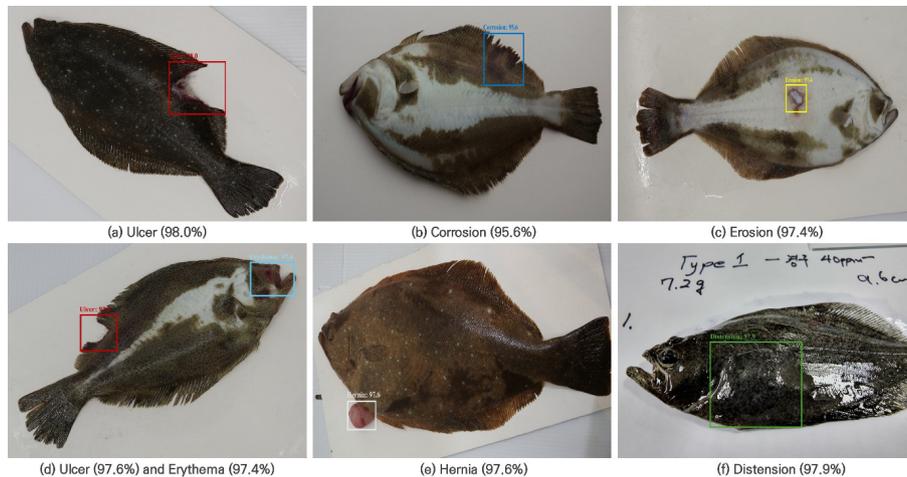


Fig. 5. Visualization of major symptom detection results using the Co-DETR model. a, Ulcer; b, Corrosion; c, Erosion; d, Ulcer and Erythema; e, Hernia; f, Distension.

Table 3. Comparison of detection performance (precision and recall) for six clinical signs of scuticociliatosis across four object detection models: Faster R-CNN, DETR, YOLO v8, and Co-DETR

Clinical signs	Faster R-CNN		DETR		YOLO v8		Co-DETR	
	Precision	Recall	Precision	Recall	Precision	Recall	Precision	Recall
Ulcer	0.940	0.811	0.915	0.929	0.962	0.950	0.975	0.975
Corrosion	0.793	0.779	0.847	0.862	0.953	0.788	0.945	1.000
Erosion	1.000	0.666	1.000	0.705	0.938	0.859	0.944	0.971
Erythema	0.625	0.588	0.800	0.666	0.866	0.812	0.842	0.941
Hernia	1.000	0.666	1.000	1.000	0.823	0.700	0.952	1.000
Distension	0.756	0.819	0.930	0.837	0.935	0.852	0.985	0.971
Average	0.852	0.721	0.915	0.833	0.912	0.826	0.940	0.976

분석 중 화면(Fig. 7f): ‘분석 시작’ 버튼을 클릭 후, 입력된 이미지를 개발한 스킨카병 주요 증상 진단 파이프라인에 전달하는 과정을 나타낸다. 사용자의 원본 이미지는 자동으로 1,024×1,024 크기로 리사이징되며, 변환된 이미지는 서버에 자동으로 저장되도록 설계되어 있다.

스킨카병 증상 탐지 화면(Fig. 7g): 탐지된 병변 부위는 입력 이미지 내에서 바운딩 박스로 표시되며, 증상명과 신뢰도(confidence score)가 함께 제시된다. 또한, 탐지된 각 증상 부위는 개별적으로 크롭되어 하단에 시각적으로 제시됨으로써 사용자가 탐지 결과를 보다 직관적으로 확인할 수 있도록 설계되어 있다.

고 찰

본 연구에서는 영상 분석 기반 물체 탐지 기술을 활용하여 넙치의 스킨카병 주요 증상을 탐지하기 위한 2단계로 구성된 진단 파이프라인을 제안하였다. 제안한 진단 파이프라인에서는 우선 이미지 내의 넙치 객체를 탐지하고, 그 다음 넙치 객체를 대상으로 주요 증상에 대한 탐지를 수행한다.

1단계에서는 넙치 촬영 이미지에서 불필요한 잡음 영역을 제거하고 넙치 객체를 정확하게 탐지하기 위해 총 2,454장의 이미지를 사용하였고, 성능 평가는 별도로 분리된 200장의 테스트 이미지를 통해 수행되었다. Faster R-CNN, DETR, YOLO v8,

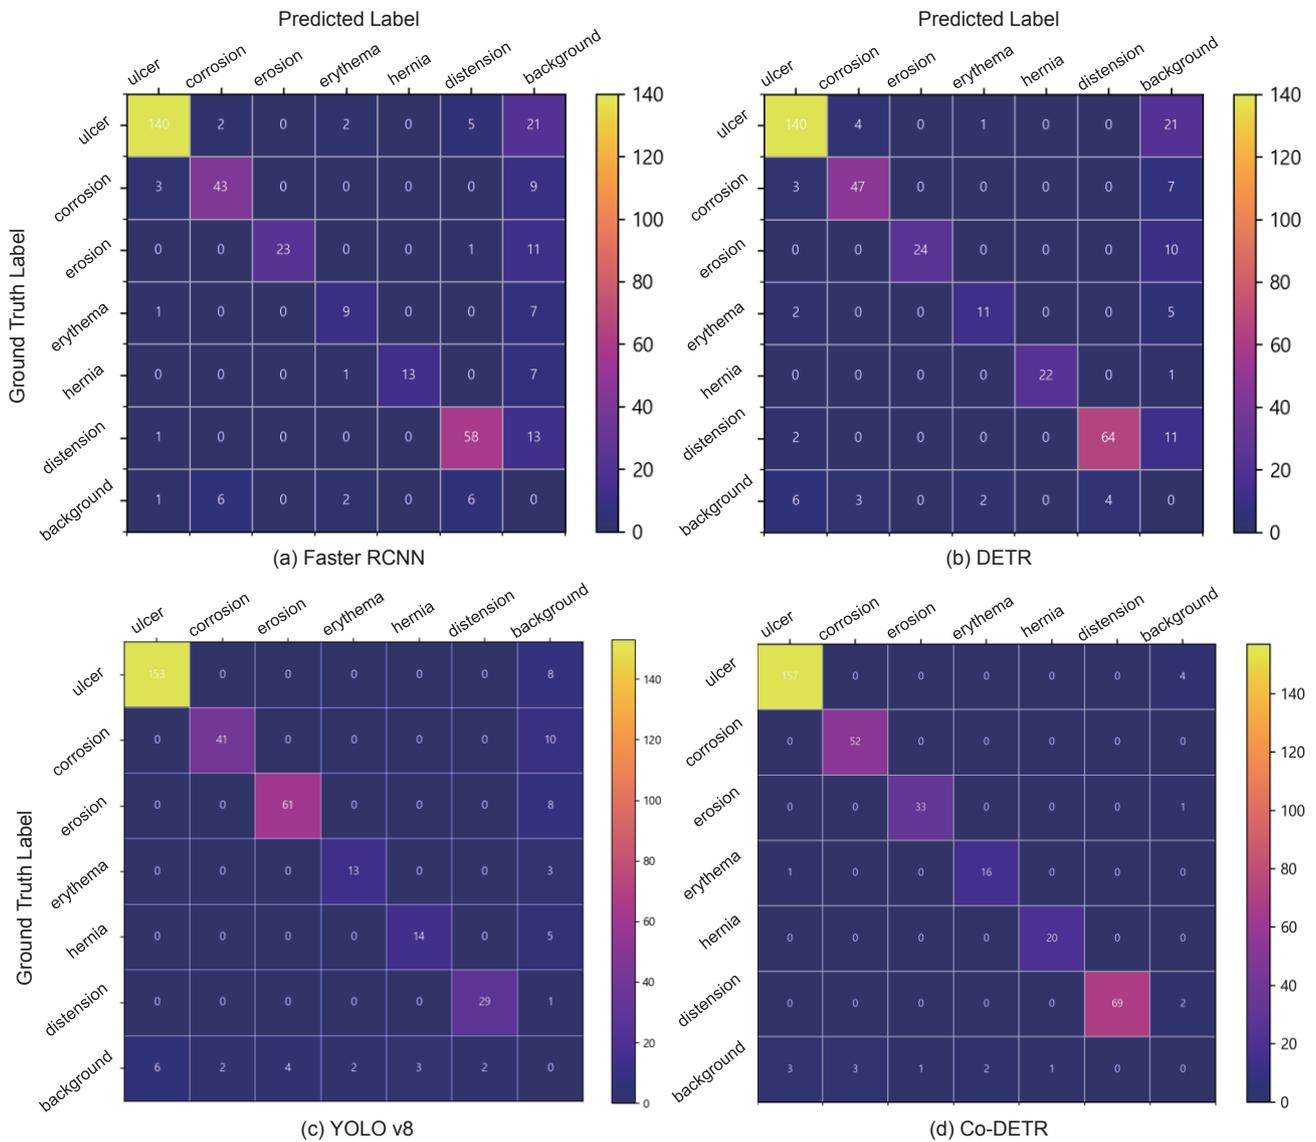


Fig. 6. Confusion matrices for the detection of six major clinical signs of scuticociliatosis by each model. The matrices illustrate classification performance and highlight misdetections and symptom confusion.

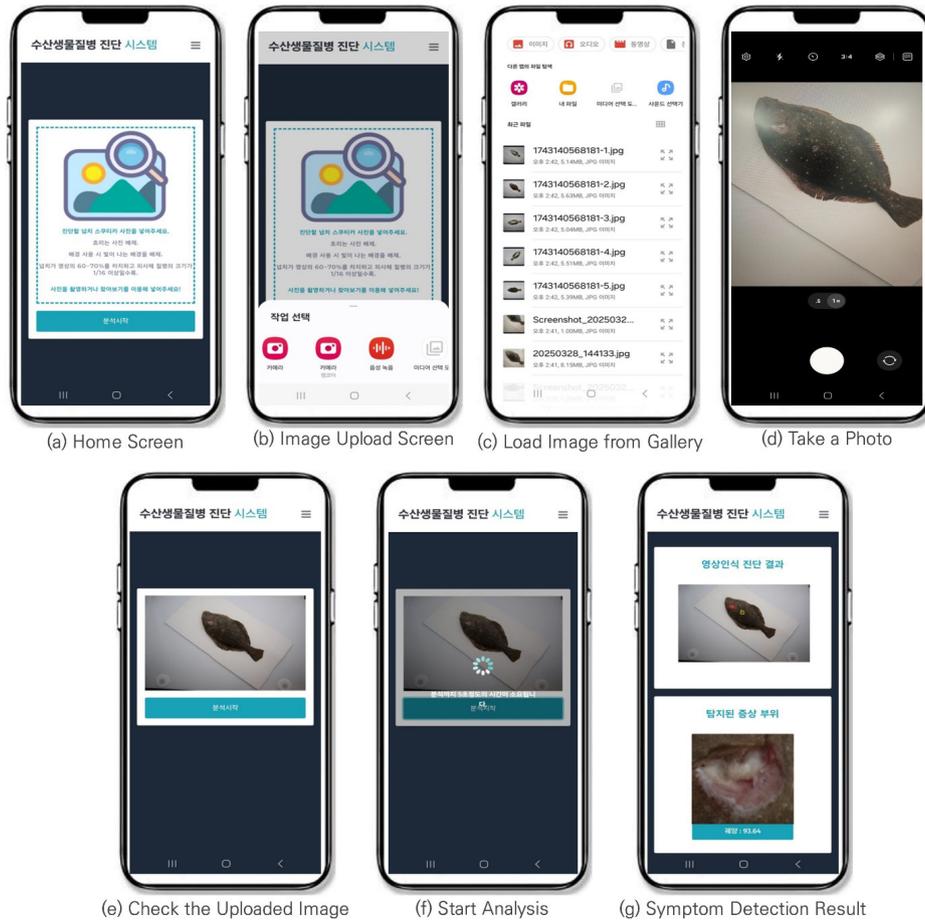


Fig. 7. User interface screenshots of the prototype application for symptom detection. a, Home screen; b, Image upload screen; c, Load image from gallery; d, Take a photo; e, Check the uploaded image; f, Start analysis screen; g, Detection results with bounding boxes and symptom labels.

Co-DETR 총 4개의 객체 탐지 모델의 성능 측정 결과, YOLO v8 모델이 정밀도 99.1%, 재현율 96.8%, IoU 97.2%를 기록하며 가장 우수한 탐지 성능을 보였다(Table 2). 또한 Fig. 4에 제시된 바와 같이 다양한 각도에서 촬영된 낚치 객체에 대해서도 안정적으로 탐지하는 모습을 확인하였으며, 이는 실제 양식장 환경에서도 본 모델이 충분히 활용 가능성을 시사한다.

2단계인 스쿠티카병 주요 증상 탐지에서는 6종의 증상에 대해 모델 성능을 비교하였다. Co-DETR 모델이 평균 정밀도 94.0%, 재현율 97.6%로 가장 뛰어난 성능을 나타냈으며, 특히 재현율에서 타 모델 대비 14~25% 높은 결과를 보여 실제 병변을 놓치지 않고 탐지하는 데 가장 효과적인 모델임을 입증하였다(Table 3).

본 연구에서는 스쿠티카병 증상 탐지에서 정밀도와 재현율 두 가지 지표를 사용하여 모델의 성능을 평가하였다. 정밀도는 모델이 예측한 영역 중 실제 정답과 일치하는 영역의 비율을 의미하고, 재현율은 실제 정답 영역 중 모델이 정확히 예측한 영역의

비율을 뜻한다. 본 연구의 최종 목적은 스쿠티카병의 주요 증상을 탐지하는 것이므로, 실제 존재하는 외부 증상을 놓치지 않는 것이 매우 중요하다. 따라서 정밀도보다 재현율을 보다 더 중요한 지표로 간주하여 모델의 성능을 해석하였다. Table 3의 주요 증상 탐지 결과에 따르면, Co-DETR을 제외한 모델들은 평균 정밀도 약 85.2~91.5%, 재현율 약 72.1~83.3%를 기록하였다. 이처럼 정밀도가 상대적으로 높고 재현율이 낮게 측정된 것은, 이들 모델에서는 실제 증상을 탐지하지 못한 사례가 다수 존재하며, 특정 증상에 대해 과도하게 많은 예측 박스를 생성한 결과로 해석된다. 반면, Co-DETR은 정밀도 94.0%, 재현율 97.6%로 가장 높은 수치를 기록하며, 다른 벤치마크 모델들에 비해 상대적으로 우수한 성능을 보였다.

한편, Co-DETR 모델이 스쿠티카병 주요 증상 탐지에서 높은 성능을 기록하였지만, 여전히 일부 증상에 대해 다른 증상으로 오탐지되거나 배경으로 잘못 인식하여 탐지가 누락되는 사례가 존재함을 확인할 수 있었다. 혼동 행렬 분석 결과(Fig. 6), 각

탐지 모델에서 일부 증상은 다른 증상으로 오탐지되었으나, 대부분의 경우에는 병변을 배경으로 잘못 인식하여 탐지가 이루어지지 않은 것을 확인할 수 있다. 이러한 결과는 본 연구에서 사용된 학습 데이터의 수량 부족 및 클래스 간 데이터 불균형 문제에서 기인한 것으로 분석된다. 실제로 본 연구에서 스쿠티카병 주요 증상 탐지 모델을 학습하기 위해 사용된 이미지는 총 1,472장으로 6종 증상에 대한 데이터로는 상대적으로 적은 수량이며, 증상별 특징을 충분히 학습하기에는 한계가 있었던 것으로 판단된다. 또한 증상 간 데이터의 수량 차이도 상당히 큰 것으로 확인되었으며, 예로 궤양 증상은 680장의 이미지가 사용된 반면, 발적 증상은 64장에 불과하였다. 이러한 데이터 불균형은 Fig. 6a, 6b, 6d에서 발적 증상이 궤양 증상으로 오분류된 사례에서도 확인할 수 있다. 이와 같은 결과는 모델이 상대적으로 더 많은 데이터를 학습한 증상(예: 궤양)에 편중되어 판단하는 경향이 있음을 시사하며, 이는 데이터 불균형이 모델 성능에 영향을 미치는 주요 요인 중 하나임을 의미한다.

본 연구에서는 AI Hub에서 제공하는 ‘넙치 질병 데이터’를 활용하여 딥러닝 기반 스쿠티카병 진단 파이프라인을 개발하였으나, 사용한 데이터셋이 모두 흰색 판넬 위에서 촬영된 제한된 환경에서 수집된 점은 중요한 한계점으로 작용될 수 있다. 이러한 데이터 다양성 부족은 모델의 일반화 능력과 실제 현장 적용 가능성에 영향을 미칠 수 있다. 이러한 문제를 해결하기 위해, 후속 연구에서는 미란, 발적 등 저빈도 증상에 대한 현장 이미지 수집을 확대하고, 이미지 증강 기법을 적극적으로 활용할 필요가 있다. 실제로 기존 연구들에서도 데이터 부족 문제를 해결하기 위한 다양한 시도가 보고되고 있다. 예를 들어, Son and Choi (2021)는 SinGAN 기반 이미지 합성 기법을 통해 넙치에서 자주 발생하는 스쿠티카병, 비브리오병, 림포시스티스병의 질병 이미지 데이터를 4배로 확장하였으며, Hwang et al. (2024)은 생성적 적대 신경망(generative adversarial networks)과 이미지 조화 기술을 활용한 병변 이미지 증강 방법을 제안하였다. 이와 같은 데이터 증강 전략은 향후 본 연구의 진단 모델 성능을 향상시키는 데 기여할 수 있을 것으로 사료된다. 더불어, 다양한 배경과 조명 조건, 촬영 각도 등을 포함하는 현장 환경 기반의 데이터 수집과 함께, 다양한 환경에서의 모델 성능 검증을 통해 실제 적용 가능성을 높이는 연구를 병행해야 할 것이다.

본 연구에서 활용한 AI Hub ‘넙치 질병 데이터’는 질병별로 분류된 이미지 데이터임에도 불구하고, 단일 감염인지 복합 감염인지, 또는 타질병에 의해 발생한 증상 여부에 관한 구체적인 정보가 제공되지 않아 이를 명확히 구분하기 어렵다는 한계가 존재한다. 이로 인해 본 연구 결과 해석 및 모델의 일반화 가능성에 일정 부분이 제약이 있을 수 있음을 인지하고 있으며, 향후 연구에서는 단일 질병과 복합 감염 여부를 명확히 구분할 수 있는 보다 세밀하고 체계적인 데이터 확보와 이를 반영한 모델 개발이 필요할 것이다.

또한, Park et al. (2023)은 수중 환경에서 넙치, 참돔 등 여러

어종과 4종 질병(출혈, 결손, 괴사 및 정상)을 대상으로 연구를 진행하였으며, 6종의 분류 알고리즘을 비교 분석하여 CoAtNet 모델이 64.1%의 정확도를 보였음을 보고하였고, Son et al. (2022)은 림포시스티스, 스쿠티카병, 비브리오증 이미지에 대해 다양한 색공간 변환 기법을 YOLO v4 모델에 적용하여 HLS 기반 변환이 71.9%의 mean average precision (mAP)로 가장 우수한 성능을 입증하였다. Cho and Baik (2023)은 넙치의 연쇄구균증, 비브리오증, 스쿠티카병을 포함한 7종 질병, 안구 돌출, 탈장, 출혈 등 33종 증상에 대해 YOLO v8과 Swin transformer 모델을 비교하여 각각 89.9%, 91.0%의 mAP를 기록하였으며, 이는 전통적인 CNN과 트랜스포머 기반 모델 간의 성능 차이를 시사한다. 이와 같은 선행연구들은 딥러닝 모델 유형, 전처리 기법, 증강 전략 등이 탐지 정확도에 상당한 영향을 미친다는 점을 보여주며, 본 연구 결과의 해석과 모델 고도화 방향 설정에 중요한 참고자료로 활용하였다.

본 연구에서는 이미지 기반 질병 진단 분야를 포함한 다양한 응용 영역에서 널리 활용되고 있는 네 가지 객체 탐지 모델의 성능을 비교 분석하였다. 비록 해당 모델들이 이미지 기반 질병 진단 분야에서 전반적으로 우수한 성능을 보이고 있으나, 실제 현장 진단에서는 여전히 주의가 요구된다. 특히 이미지 기반 질병 진단의 특성상, 모델이 실제 질병을 다른 질병으로 오진할 가능성이 상당히 높기 때문이다. 이에 대한 보완책으로 여러 모델의 예측 결과를 종합하여 최종 진단을 내리는 앙상블(ensemble) 기법이나, 유사 이미지 검색(similarity-based image retrieval) 기술을 통해 사용자에게 입력 이미지와 가장 유사한 질병 이미지를 제공함으로써 사용자가 직접 판단하여 최종 의사결정에 도움을 주는 연구(Yin et al., 2020; Gu et al., 2021; Jin et al., 2025)가 활발히 진행되고 있다. 마찬가지로, 향후 연구에서는 본 연구에서 제안한 2단계 파이프라인에 유사 증상 이미지 검색 기술을 접목하여 사용자의 의사결정 지원을 강화하는 시스템으로 확장할 수 있을 것으로 기대된다.

본 연구에서 제안한 2단계 파이프라인은 현재 스쿠티카병 진단에 한정되어 있으나, 향후에는 여윌증, 비브리오병, 활주세균증, 림포시스티스 등 다양한 어류 질병의 주요 증상 탐지로 적용 범위를 확대할 계획이다. 특히, 다중 증상 기반 진단 접근법은 질병 간 증상이 중복되는 수산 분야의 특성을 효과적으로 반영할 수 있다는 점에서 확장성이 높다고 판단된다. 아울러, 현재 개발된 프로토타입 애플리케이션은 실제 사용자와의 현장 테스트 및 피드백 수집을 통해 기능 개선과 사용자 경험(user experience) 향상을 지속적으로 추진해 나갈 필요가 있으며, 궁극적으로는 민간 진료기관 및 양식 현장에서 실용적인 진단 지원 도구로 활용될 수 있을 것으로 기대된다.

사 사

이 논문은 국립수산물과학원 “수산생물 질병 특성 연구(R2025052)” 연구개발비 지원에 의해 수행되었습니다.

References

- AI Hub. 2025. Olive Flounder Disease Data. Retrieved from <https://aihub.or.kr/aihubdata/data/view.do?dataSetSn=71345>, accessed on Jul 11, 2025.
- Statistics Korea. 2025. 2024 Fisheries Production Trend Survey Results (Provisional). Retrieved from https://kostat.go.kr/boardDownload.es?bid=225&list_no=435155&seq=1 on Jul 11, 2025.
- NIFS (National Institute of Fisheries Science). 2021. Comprehensive Plan for Management Techniques to Respond to Emerging Aquatic Animal Diseases Established. Retrieved from https://www.nifs.go.kr/news/actionNewsView.do?MENU_ID=M0000307&NEWS_D_DATE_BEGIN=2021-06-23&NEWS_D_DATE_END=2021-06-23&NEWS_SEQ=3831 on Jul 11, 2025.
- Hasan N, Ibrahim S and Azlan AA. 2022. Fish diseases detection using convolutional neural network (CNN). *Int J Non-linear Anal Appl* 13, 1977-1984. <https://doi.org/10.22075/ijnaa.2022.5839>.
- Hwang SB, Kim HY, Heo CY, Jung HY, Jung SJ and Cho YJ. 2024. Flatfish disease detection based on part segmentation approach and disease image generation. *arXiv* 2407, 11348. <https://doi.org/10.48550/arXiv.2407.11348>.
- Pallathadka H, Mustafa M, Sanchez DT, Sajja GS, Gour S and Naved M. 2023. Impact of machine learning on management, healthcare and agriculture. *Mater Today Proc* 80, 2803-2806. <https://doi.org/10.1016/j.matpr.2021.07.042>.
- Cho KW and Baik R. 2023. Performance analysis of deep learning-based *Paralichthys olivaceus* disease symptom classification model. *J Korea Contents Assoc* 23, 96-106. <https://doi.org/10.5392/JKCA.2023.23.12.096>.
- Park SY, Xianghua P, Dong J, Helin Y and Gu YH. 2023. Image-based fish disease classification study. In: *Proceeding of the 2023 IEIE Summer Annual Conference*. Jeju, Korea, 1625-1629.
- Al Noman MA, Hossen MS, Islam M, Ani JF, Ria NJ and Rakshit A. 2022. HYBRID-CNN: For identification of Rohu fish disease. In: *Proceedings of the 2022 13th International Conference on Computing Communication and Networking Technologies (ICCCNT)*, Kharagpur, India, 1-6. <https://doi.org/10.1109/ICCCNT54827.2022.9984516>.
- Son HS, Lim HK and Choi HS. 2022. A study on disease prediction of *Paralichthys olivaceus* using deep learning technique. *Smart Media J* 11, 62-68. <https://doi.org/10.30693/SMJ.2022.11.4.62>.
- Jin D, Yin H, Zheng R, Yoo SJ and Gu YH. 2023. PlantInfoCMS: Scalable plant disease information collection and management system for training AI models. *Sensors* 23, 5032. <https://doi.org/10.3390/s23115032>.
- Ren S, He K, Girshick R and Sun J. 2016. Faster R-CNN: Towards real-time object detection with region proposal networks. *IEEE Trans Pattern Anal Mach Intell* 39, 1137-1149. <https://doi.org/10.1109/TPAMI.2016.2577031>.
- Carion N, Massa F, Synnaeve G, Usunier N, Kirillov A and Zagoruyko S. 2020. End-to-end object detection with transformers. In: *Computer Vision-ECCV 2020*. Vedaldi A, Bischof H, Brox T and Frahm JM, eds. Springer, Cham, Swiss. https://doi.org/10.1007/978-3-030-58452-8_13.
- Jocher G, Chaurasia A and Qiu J. 2023. Ultralytics YOLOv8. Retrieved from <https://github.com/ultralytics/ultralytics> on Apr 14, 2025.
- Zong Z, Song G and Liu Y. 2023. DETRs with collaborative hybrid assignments training. *arXiv* 2211, 12860. <https://doi.org/10.48550/arXiv.2211.12860>.
- Wang CY, Liao HYM, Wu YH, Chen PY, Hsieh JW and Yeh IH. 2020. CSPNet: A new backbone that can enhance learning capability of CNN. *arXiv* 1911, 11929. <https://doi.org/10.48550/arXiv.1911.11929>.
- Son HS and Choi HS. 2021. Image augmentation of *Paralichthys olivaceus* disease using SinGAN deep learning model. *J Korea Contents Assoc* 21, 322-330. <https://doi.org/10.5392/JKCA.2021.21.12.322>.
- Yin H, Gu YH, Park CJ, Park JH and Yoo SJ. 2020. Transfer learning-based search model for hot pepper diseases and pests. *Agriculture* 10, 439. <https://doi.org/10.3390/agriculture10100439>.
- Gu YH, Yin H, Jin D, Park JH and Yoo SJ. 2021. Image-based hot pepper disease and pest diagnosis using transfer Learning and Fine-Tuning. *Front Plant Sci* 12, 724487. <https://doi.org/10.3389/fpls.2021.724487>.
- Jin D, Yin H and Gu YH. 2024. Shuffle-PG: Lightweight feature extraction model for retrieving images of plant diseases and pests with deep metric learning. *Alex Eng J* 113, 138-149. <https://doi.org/10.1016/j.aej.2024.11.052>.