

한국식물분류학회 특별 심포지엄 : 통합 분류학적 AI를 향해서

일시 : 2026.08.18.

장소 : 성신여자대학교 운정그린캠퍼스

# Progressive expansion of AI-Based image classification techniques for turtle conservation and management

Chang-Bae Kim(Sangmyung University)  
Jongwon Baek(BioNexus)


CBK. [evodevo@smu.ac.kr](mailto:evodevo@smu.ac.kr)

JWB. [jongwon.baek@bionexus.kr](mailto:jongwon.baek@bionexus.kr)



상명대학교  
SANGMYUNG UNIVERSITY





# CONTENTS

## 01

거북류 보전 및 관리를 위한 인공지능(AI)

## 02

거북류 보전 및 관리를 위한 이미지 분류 기반 연구

- 국제적 멸종위기종(CITES) 거북 종 분류 연구
- 바다거북 종 분류 모델 성능 향상 연구
- 생태계교란 거북 종 분류 모델 성능 향상 연구
- Hyperparameter tuning 가속화를 위한 LLM 기반 에이전트 활용 연구

## 03

에이전트 시연

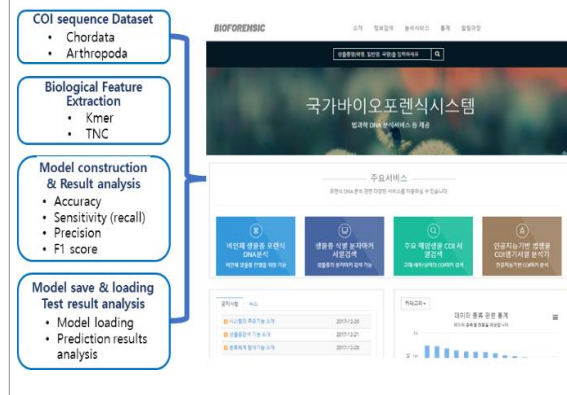
# 김 창 배

전공: 동물계통분류학 / 생물정보학 / 유전체학 / 분류생태환경 분야에 인공지능 기술 활용


## 연구책임자로 수행한 인공지능 과제

- 한국연구재단 ‘인공지능 기술을 활용한 법과학 생체정보 증거의 정량 평가시스템 개발’ 과제 총괄책임자(2016-2021)
- 한국환경산업기술원 ‘멸종위기종 모니터링 및 지능형 객체 인식 기술 개발’ 과제 세부책임자(2018-2020)
- 국립생물자원관 ‘생물정보 빅데이터 활용 전문인력 양성(2025년)’ 과제 총괄책임자(2021-2025)
- 한국환경산업기술원 ‘빅데이터 및 인공지능 기반 수생태계 통합정보 관리 기술개발’ 과제 공동연구원(2025-현재)

### 인공지능 기술을 활용한 법과학 생체정보 증거의 정량 평가시스템 개발



### 멸종위기종 모니터링 및 지능형 객체 인식 기술 개발



### 생물정보 빅데이터 활용 전문인력 양성(2025년)

| 보도자료                                                    |                                                          |
|---------------------------------------------------------|----------------------------------------------------------|
|                                                         | <b>2021년 12월 2일</b> (12. 01. 12:00 이후)부터 보도하여 주시기 바랍니다.  |
| 담당: 국립생물자원관<br>부서: 유전자원활용과<br>배포일시: 2021. 12. 1. / 총 5매 | 유전선 고장 / 배향환 연구관 / 임우영 연구사<br>032-590-7201 / 7232 / 7114 |

**국제적 멸종위기종 판별에 인공지능 기술 활용한다**

- ◇ 국립생물자원관, 인력양성 사업을 통해 인공지능(AI)을 생물 종 판별을 위한 기술 개발에 활용
- ◇ 인공지능 기술로 국제적 멸종위기종 신속·정확하게 판별 기대

보도자료.
 *평생의 평생교육, 평생의 평생교육*

보도시점 2023. 10. 24.(목) 12:00 (수요일 조간) 배포 2023. 10. 23.(월)

**생물 종판별에 인공지능 기술 활용 역량 강화한다**

국립생물자원관, 생물 이미지 빅데이터 분석 위한 전문인력 양성 사업 연선회(워크숍) 개최

# 생물학연구정보센터(BRIC) 연구실 소개

BioWave Vol. 26 No. 3

등록 2023.08.14

상명대학교 생명화학공학과 생물정보학 연구실

김창배 교수

[연구실 홈페이지 >](#)

## Introduction

최근 다양한 생명공학 기술이 발전하고 널리 활용됨에 따라 대량의 바이오 데이터를 빠르게 생산할 수 있게 되었습니다. 그러나 생산된 바이오 빅데이터로부터 생물학적으로 유용한 정보를 추출하는 작업은 실험만으로 해결하기 어려워 전산학과 통계학적 접근이 함께 필요하게 되었고, 이로 인해 생물정보학(Bioinformatics)이라는 학문이 탄생하게 되었습니다. 생물정보학은 생물학적인 문제를 생물학, 전산학, 통계학 등 다양한 분야의 지식과 기술을 융합하여 바이오 빅데이터로부터 복잡하고 어려운 생물학의 다양한 문제들을 해결하고자 하는 학문 분야입니다.

본 연구실은 생물정보학적 분석방법을 적극 활용하여 다양한 분야의 연구를 수행하고 있습니다. 특히, 환경 멀티오믹스(e-multiomics) 분석, 다양한 동물의 유전체 및 전사체 분석, 인공지능 기술을 이용한 생물의 종 판별, 미토콘드리아 게놈을 포함한 동물유전체 생물정보 분석, 후생유전체 분석, 해양무척추동물 분자계통분류 등의 다양한 연구를 수행하고 있으며 BT와 IT 기술을 고루 겸비한 생물정보학 분야 차세대 융합 인재를 양성하고 있습니다.



Prof. Kim Chang Bae(김창배)

Professor, Department of Biotechnology, Sangmyung University

### Education

Doctor's : Zoology, Seoul National University, 1991

Master's : Zoology, Seoul National University, 1986

Bachelor's : Biological Sciences, Sungkunkwan University, 1984

### Experiences

present : Professor, Department of Biotechnology, Sangmyung University

2011 - 2013 : Co-Editor-in-Chief : Animal Systematics, Evolution and Diversity (ASED)

2000 - 2008 : Principal investigator : Korea Research Institute of Bioscience and Biotechnology

1996 - 2000 : Research Associate : Yale University

01


# 거북류 보전 및 관리를 위한 인공지능(AI)

# 거북류 보전 및 관리를 위한 인공지능(AI)

## [배경]

- 거북류(turtles)는 척추동물 중 가장 오래된 분류군 중 하나로서, 전 세계의 육상, 민물, 해양 생태계에 많은 영향을 미치는 주요 구성원 중 하나
- 특히 거북류는 생태계에서 포식자와 피식자 및 에너지 흐름 촉진 등의 다양한 역할을 수행
- 하지만 이러한 생태학적 중요성에도 불구하고, 최근 야생동물 불법거래, 외래종 침입, 기후 변화 등의 요인으로 급격하게 종과 개체수가 감소하고 있음
- 따라서 이를 막기 위해 IUCN(International Union for Conservation of Nature)과 CITES(Convention on International Trade in Endangered Species of Wild Fauna and Flora)와 같은 다양한 협약 및 단체들이 거북의 보전 및 관리를 위해 노력하고 있음
- 2025년 기준 거북류 378종 중 62%가 위협을 받고 있다고 알려져 있으며 55%는 국제적으로 관리가 필요한 종으로 등록되어 있음

**378 species**



**62%**



**234 vulnerabled species**

Ex (Extinct) : 7 species

CR (Critically Endangered) : 73 species

EN (Endanger) : 56 species

VU (Vulnerable) : 60 species

NT (near Threatened) : 38 species

LC (Least Concern) : 101 species

**55%**



**208 managed species**

Appendix I : 41 species

Appendix II : 167 species

Appendix III : 16 species


# 거북류 보전 및 관리를 위한 인공지능(AI)

- Global threats

- 기후 변화(Climatic change) : 온도에 따라 성별이 결정되는 바다거북의 성 결정 기능 교란
- 야생동물 거래(Wildlife trade) : 희귀종의 불법 밀매, 침입종의 도입

- Local threats

- 서식지 손실(Habitat loss) : 서식지 훼손 및 황폐화
- 지역적 소비(Local consumption) : 지속 불가능한 포획
- 침입종(Invasive species) : 토착종과의 경쟁, 질병 전파



# 거북류 보전 및 관리를 위한 인공지능(AI)

- 이러한 위협 속에서 거북류를 보전하기 위해선 불법 야생동물 거래 규제 집행, 멸종 위기 종 및 서식지 모니터링, 침입종 통제 및 관리가 중요하지만, 현재 여기에는 3가지 한계가 존재

## Challenges factors

### 1. 거북류의 형태학적 어려움 (Morphological difficulties in turtles)

- 종 간 높은 형태학적 유사성
- 식성과 서식지 조건에 따른 형질 변이

### 2. 조사 규모 확대 (Increasing survey volume)

- 조사 대상 종 수의 지속적인 증가
- 개체당 조사량의 증가

### 3. 분류학 전문가의 부족 (Shortage of taxonomic experts)


- 형태 분류학자의 수 감소
- 모든 분류군에 걸친 전문가 확보가 제한적

⇒ 신속하고 정확한 종 분류 및 관리 자동화 도구가 필수적

# 거북류 보전 및 관리를 위한 인공지능(AI)

## [거북류 분류를 위한 인공지능 기술의 활용]

- 인공지능(Artificial Intelligence, AI) 기술은 이러한 한계를 완화하기 위한 효과적인 수단이 될 수 있음
- 현재 인공지능은 야생동물 보전 및 관리를 지원하는 데 널리 활용되고 있으며, 유망한 성과를 거두고 있음
- 딥러닝(Deep Learning) 모델은 데이터에서 패턴을 자율적으로 탐지하고 생물학적 특징을 추출한다는 특징을 가짐
- 그 중에서도 Convolutional Neural Network(CNN) 모델은 형태학적 특성에 기반한 이미지 분류에 널리 적용되고 있으며, 2015년 개발된 ResNet 모델은 이전 모델보다 모델의 layer를 깊게 하여 같은 데이터를 인간이 분류했을 때 에러율인 5.1% 미만의 에러율을 나타냄



# 거북류 보전 및 관리를 위한 인공지능(AI)


## [딥러닝 기반 이미지 분류 모델: Object detection]

- Object detection 모델은 CNN 모델을 기반으로 개발되었으며, 최근 생물의 종 식별에 널리 활용되고 있음
- Object detection 모델은 이미지의 분류만 수행하는 CNN 모델과 달리 이미지의 분류 뿐 아니라 이미지 내 객체 영역 회귀(regression)와 분류(classification)를 수행함
- 이미지 내 여러 종과 개체가 존재하는 경우 각 종과 개체의 식별이 가능함

사진 출처 : 국립생태원 외래생물팀




Image



Feature  
extraction



사진 출처 : 국립생태원 외래생물팀



Regression

“붉은귀거북”

Classification

〈Object detection 모델 구조〉


# 거북류 보전 및 관리를 위한 인공지능(AI)

## [딥러닝 기반 이미지 분류 모델: Object detection]

- Object detection 모델은 2가지의 종류로 나뉨
    - 2-stage detectors : 회귀(regression)와 분류(classification)를 순차적으로 수행함(sequentially)
    - 1-stage detectors : 회귀(regression)와 분류(classification)를 동시에 수행함(simultaneously)
  - 기존에 2-stage detectors는 상대적으로 모델의 정확도가 높지만 데이터 처리 속도가 느리다는 특징이 있었고, 1-stage detectors는 상대적으로 모델의 정확도가 낮지만 데이터 처리 속도가 빠르다는 특징이 있었음
  - 하지만 최근 개발되는 1-stage detectors들은 빠른 속도를 유지하며 2-stage detectors와 유사한 정확도를 가지도록 개발되고 있음
- ⇒ 따라서 최근 대부분의 야생동물 탐지 및 분류 연구에서는 1-stage detector가 주로 사용되고 있음


### [2-Stage Detector]

Ex) R-CNN series



### [1-Stage Detector]

Ex) SSD series , YOLO series



〈2-stage detectors와 1-stage detectors의 예시 이미지〉

02


# 거북류 보전 및 관리를 위한 이미지 분류기반 연구

1. 국제적 멸종위기종(CITES) 거북 분류 연구
2. 바다거북 종 분류 연구
3. 생태계교란 거북 종 분류 연구
4. Hyperparameter tuning 가속화를 위한 LLM 기반 에이전트 활용 연구

# 국제적 멸종위기종(CITES) 거북 분류 연구

## [1. 국제적 멸종위기종(CITES) 거북류 36종 판별]

- 2009~2014년간 총 407종의 살아있는 국제적 멸종위기종이 수입된 것으로 집계되었고, 그 중 파충류(Reptile)가 178종으로 가장 많이 수입(Import)됨
- 파충류 중에서는 거북류 51종, 도마뱀류 49종으로 거북류가 가장 많이 수입되는 종으로 나타남
- 특히 거북류는 애완동물로서 인기가 높아 개인 사육이 늘어나면서 수입이 급증하고 있는 추세
- 현재 수입되고 있는 국제적 멸종위기종은 보편적으로 형태학적 특징을 기반으로 종을 판별하고 있음
- 그러나 매일 대량으로 수입되는 국제적 멸종위기종을 현장에서 일일이 형태학적으로 종을 판별하는 것은 한계가 있음
- 따라서, 국제적 멸종위기종의 수입 관리를 위해 현장에서 신속, 정확하게 국제적 멸종위기종을 판별할 수 있는 방법이 필요함



〈전 세계 및 국내 거북류 거래 동향〉

# 국제적 멸종위기종(CITES) 거북 분류 연구

- 거북류는 오래전부터 아시아에서 식품, 의약품으로 이용되어 왔으며, 애완 동물로도 수요가 높은 분류군임
- 매년 아시아로 약 13,000톤의 거북류가 수입되고 있으며, 최근 수요가 증가함에 따라 불법거래 역시 증가하고 있음
- 거북류는 주로 등쪽갑의 색, 무늬, 형태로 식별하나 유사한 색, 무늬를 지닌 종들 간에 식별이 어려울 수 있음
- 특히, 등쪽갑 형태는 생태학적인 영향(섭식, 행동)에 의해 변형이 될 수 있어 거북류의 형태 동정이 어려움
- 수입되는 거북류에는 육지 거북, 담수 거북, 바다 거북이 모두 포함됨

*Geochelone elegans*



*Geochelone platynota*



*Chelonoidis chilensis*



*Geochelone sulcata*



*Chelonoidis denticulate*



*Chelonoidis carbonaria*




〈거북의 종 간 형태학적 유사성(Morphological similarity)을 나타내는 대표 이미지〉

# 국제적 멸종위기종(CITES) 거북 분류 연구

〈거북류 36종의 dataset 구축 결과〉

| Number | Family           | Species                        | Training set | Validation set | Test set |
|--------|------------------|--------------------------------|--------------|----------------|----------|
| 1      | Carettochelyidae | <i>Carettochelys insculpta</i> | 156          | 33             | 34       |
| 2      | Chelidae         | <i>Chelodina mccordi</i>       | 105          | 22             | 23       |
| 3      | Cheloniidae      | <i>Caretta caretta</i>         | 109          | 23             | 24       |
| 4      | Cheloniidae      | <i>Chelonia mydas</i>          | 126          | 27             | 28       |
| 5      | Cheloniidae      | <i>Eretmochelys imbricata</i>  | 106          | 22             | 24       |
| 6      | Cheloniidae      | <i>Macrochelys temminckii</i>  | 158          | 33             | 35       |
| 7      | Emyidae          | <i>Clemmys guttata</i>         | 150          | 32             | 33       |
| 8      | Emyidae          | <i>Graptemys ouachitensis</i>  | 109          | 23             | 25       |
| 9      | Emyidae          | <i>Malaclemys terrapin</i>     | 164          | 35             | 36       |
| 10     | Emyidae          | <i>Terrapene carolina</i>      | 173          | 37             | 38       |
| 11     | Emyidae          | <i>Terrapene ornata</i>        | 157          | 33             | 35       |
| 12     | Geoemydidae      | <i>Cuora amboinensis</i>       | 124          | 26             | 28       |
| 13     | Geoemydidae      | <i>Cuora flavomarginata</i>    | 110          | 23             | 25       |
| 14     | Geoemydidae      | <i>Cuora galbinifrons</i>      | 108          | 23             | 24       |
| 15     | Geoemydidae      | <i>Geoclemys hamiltonii</i>    | 106          | 22             | 24       |
| 16     | Geoemydidae      | <i>Heosemys spinosa</i>        | 107          | 23             | 24       |
| 17     | Geoemydidae      | <i>Mauremys sinensis</i>       | 173          | 37             | 38       |
| 18     | Podocnemididae   | <i>Podocnemis unifilis</i>     | 128          | 27             | 29       |
| 19     | Testudinidae     | <i>Aldabrachelys gigantea</i>  | 214          | 45             | 47       |
| 20     | Testudinidae     | <i>Chelonoidis carbonaria</i>  | 252          | 54             | 55       |
| 21     | Testudinidae     | <i>Chelonoidis chilensis</i>   | 112          | 24             | 24       |
| 22     | Testudinidae     | <i>Chelonoidis denticulata</i> | 143          | 30             | 32       |
| 23     | Testudinidae     | <i>Chersina angulata</i>       | 121          | 26             | 27       |
| 24     | Testudinidae     | <i>Geochelone elegans</i>      | 135          | 29             | 30       |
| 25     | Testudinidae     | <i>Geochelone platynota</i>    | 125          | 26             | 28       |
| 26     | Testudinidae     | <i>Geochelone sulcata</i>      | 105          | 22             | 23       |
| 27     | Testudinidae     | <i>Gopherus berlandieri</i>    | 105          | 22             | 23       |
| 28     | Testudinidae     | <i>Indotestudo elongata</i>    | 107          | 22             | 24       |
| 29     | Testudinidae     | <i>Malacochersus tornieri</i>  | 147          | 31             | 32       |
| 30     | Testudinidae     | <i>Manouria emys</i>           | 105          | 22             | 23       |
| 31     | Testudinidae     | <i>Manouria impressa</i>       | 109          | 23             | 24       |
| 32     | Testudinidae     | <i>Stigmochelys pardalis</i>   | 192          | 41             | 42       |
| 33     | Testudinidae     | <i>Testudo horsfieldii</i>     | 166          | 22             | 23       |
| 34     | Testudinidae     | <i>Testudo hermanni</i>        | 86           | 31             | 33       |
| 35     | Testudinidae     | <i>Testudo marginata</i>       | 142          | 30             | 31       |
| 36     | Trionychidae     | <i>Lissemys punctata</i>       | 105          | 22             | 23       |
| Total  |                  |                                | 4840         | 1023           | 1071     |




〈Single Shot MultiBox Detector (SSD) Model Architecture〉

- **Data collection** : iNaturalist와 Google에서 국내로 수입되는 거북류 51종의 이미지를 수집 → 이미지 수가 부족한 15종을 제외한 36종의 이미지 dataset을 구축
- **Data selection** : 형태 특징이 기재된 기재 논문 및 도감, 저품질의 이미지 제거 (Total : 6,934)
- **Data augmentation** : Horizontal flip, Rotate, Zoom-in, Zoom-out, Translate
- **Model training** : Object detection 모델 중 1-stage detectors의 일종인 Single Shot MultiBox Detector (SSD) 모델을 활용

# 국제적 멸종위기종(CITES) 거북 분류 연구

〈8개 모델의 성능 평가 결과〉



〈학습된 모델의 성능 평가 결과〉

| Model       | mAP   | Inference time (s) |
|-------------|-------|--------------------|
| VGGNet16    | 0.780 | 0.029              |
| ResNet18    | 0.877 | 0.024              |
| ResNet34    | 0.867 | 0.029              |
| ResNet50    | 0.859 | 0.032              |
| DenseNet18  | 0.861 | 0.033              |
| DenseNet30  | 0.852 | 0.035              |
| DenseNet50  | 0.855 | 0.046              |
| DenseNet121 | 0.849 | 0.051              |

- **mAP** : 8개 모델 중 VGGNet16 model(77.7%)이 가장 낮았으며, ResNet18 model(87.7%)이 가장 높게 나타남
- **Inference time** : ResNet18 model(0.024s)이 가장 빨랐고, DenseNet121 model(0.052s)이 가장 느리게 나타남
- ResNet18 model이 가장 높은 mAP와 Inference time을 보였음

# 국제적 멸종위기종(CITES) 거북 분류 연구

|              |    | Predicted results |      |      |      |      |      |      |      |      |      |     |      |      |      |     |     |      |      |      |      |      |      |     |     |    |      |      |     |    |     |     |     |    |    |     |     |     |
|--------------|----|-------------------|------|------|------|------|------|------|------|------|------|-----|------|------|------|-----|-----|------|------|------|------|------|------|-----|-----|----|------|------|-----|----|-----|-----|-----|----|----|-----|-----|-----|
|              |    | 1                 | 2    | 3    | 4    | 5    | 6    | 7    | 8    | 9    | 10   | 11  | 12   | 13   | 14   | 15  | 16  | 17   | 18   | 19   | 20   | 21   | 22   | 23  | 24  | 25 | 26   | 27   | 28  | 29 | 30  | 31  | 32  | 33 | 34 | 35  | 36  |     |
| True results | 1  | 91.2              | —    | 2.9  | —    | —    | —    | —    | —    | —    | —    | —   | 5.9  | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 2  | 8.7               | 69.6 | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | 4.4  | 8.7  | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | 4.4 | —   | —   | —  | —  | —   | 4.4 |     |
|              | 3  | 4.2               | —    | 79.2 | 12.5 | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   | 4.2 |
|              | 4  | —                 | —    | 14.3 | 60.7 | 14.3 | —    | —    | —    | 3.6  | —    | 3.6 | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | 3.6 | —   | —   | —  | —  | —   | —   |     |
|              | 5  | —                 | —    | 4.2  | 8.3  | 83.3 | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | 4.2 | —  | —  | —   | —   |     |
|              | 6  | —                 | —    | —    | 2.9  | 2.9  | 77.1 | —    | —    | —    | —    | —   | —    | —    | —    | 5.7 | 2.9 | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | 2.9 | 5.7 | —   | —  | —  | —   | —   |     |
|              | 7  | —                 | —    | —    | —    | —    | —    | 90.9 | —    | —    | —    | 3.0 | —    | —    | —    | 3.0 | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 8  | —                 | —    | —    | —    | —    | —    | —    | 84.0 | —    | —    | —   | —    | —    | —    | —   | —   | 12.0 | 4.0  | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 9  | —                 | —    | —    | —    | —    | —    | —    | —    | 88.9 | —    | —   | 2.8  | —    | —    | —   | 2.8 | 2.8  | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | 2.8 |     |
|              | 10 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | 94.7 | 2.6 | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | 2.6 | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 11 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | 5.7 | 94.3 | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 12 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | 82.1 | 3.6  | —   | —   | —    | 10.7 | 3.6  | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 13 | —                 | 4.0  | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | 4.0  | 76.0 | 4.0 | —   | 4.0  | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 14 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | 4.2 | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 15 | —                 | —    | —    | —    | —    | —    | 4.2  | 4.2  | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 16 | —                 | 4.2  | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | 83.3 | —    | 4.2  | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | 4.2 | —   | —  | —  | —   |     |     |
|              | 17 | —                 | —    | —    | —    | —    | —    | —    | 2.6  | —    | —    | —   | —    | —    | —    | —   | —   | 2.6  | 89.5 | 2.6  | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | 2.6 |     |
|              | 18 | —                 | —    | 3.5  | —    | —    | —    | —    | —    | —    | —    | —   | —    | 6.9  | —    | —   | 3.5 | 3.5  | 3.5  | 75.9 | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | 3.5 | —   | —  | —  | —   | —   |     |
|              | 19 | 2.1               | —    | —    | —    | —    | 2.1  | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | 2.1  | —    | 91.5 | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | 2.1 | —   |     |
|              | 20 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | 96.4 | —    | 3.6 | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 21 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | 75.0 | —   | —   | —  | —    | 16.7 | —   | —  | —   | 4.2 | —   | —  | —  | —   | 4.2 |     |
|              | 22 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 23 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | 3.1 | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 24 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 25 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | 3.6  | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | 73.3 | 26.7 | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 26 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 27 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 28 | —                 | —    | —    | —    | —    | —    | —    | 4.2  | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 29 | —                 | —    | —    | —    | —    | 3.1  | —    | —    | —    | 3.1  | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 30 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 31 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 32 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 33 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 34 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 35 | —                 | —    | —    | —    | —    | —    | —    | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |
|              | 36 | 4.4               | —    | 4.4  | —    | —    | —    | 8.7  | —    | —    | —    | —   | —    | —    | —    | —   | —   | —    | —    | —    | —    | —    | —    | —   | —   | —  | —    | —    | —   | —  | —   | —   | —   | —  | —  | —   | —   |     |

〈학습된 모델의 분류결과를 나타낸 confusion matrix〉

- Average correct classification rate : 82.8%
- 8개 모델 중 mAP가 가장 높았던 ResNet18 model의 분류 성능을 confusion matrix를 통해 나타냄
- 분류 정확도가 가장 낮은 종은 *Chelonia mydas* (60.7%) 였고, 가장 높은 종은 *Stigmochelys pardalis* 로 100% 정확하게 분류됨

# 국제적 멸종위기종(CITES) 거북 분류 연구

*Caretta caretta*



*Chelonia mydas*



〈수중 환경에서의 화질 저하〉

*Graptemys ouachitensis*



*Mauremys sinensis*



〈데이터 부족〉

*Geochelone elegans*



*Geochelone platynotan*



〈형태적 유사성〉

- **Challenge factors** : 수중 환경에서의 화질 저하(Underwater image degradation), 데이터 부족(Insufficient data), 형태적 유사성(Morphological similarity)
- **Future studies** : 수중 환경에서의 성능 향상(Underwater performance enhancement, 형태 특징을 잘 보여주는 이미지 추가 수집(Collection of morphology-clear image), 최신 모델 사용 (Adoption of advanced models) (e.g. YOLOv5)

# 국제적 멸종위기종(CITES) 거북 분류 연구

[www.nature.com/scientificreports](http://www.nature.com/scientificreports)

scientific reports

Check for updates

OPEN Deep learning-based image classification of turtles imported into Korea

Jong-Won Baek<sup>1,2</sup>, Jung-Il Kim<sup>1,2</sup> & Chang-Bae Kim<sup>1,2</sup>

Although turtles play a key role in maintaining healthy and balanced environments, these are endangered due to global trade to meet the high demand for food, medicine, and pets in Asia. In addition, imported non-native turtles have been controlled as alien invasive species in various countries, including Korea. Therefore, a rapid and accurate classification of imported turtles is needed to conserve and detect those in native ecosystems. In this study, eight Single Shot MultiBox Detector (SSD) models using different backbone networks were used to classify 36 imported turtles in Korea. The images of these species were collected from Google and were identified using morphological features. Then, these were divided into 70% for training, 15% for validation, and 15% for test sets. In addition, data augmentation was applied to the training set to prevent overfitting. Among the eight models, the Resnet18 model showed the highest mean Average Precision (mAP) at 88.1% and the fastest inference time at 0.024 s. The average correct classification rate of 36 turtles in this model was 82.8%. The results of this study could help in management of the turtle trade, specifically in improving detection of alien invasive species in the wild.

Turtles, order Testudines, are major biodiversity components of the ecosystems they inhabit, and often serve as keystone species beneficial to other animals and plants<sup>1,2</sup>. However, most turtles are endangered due to indiscriminate global trade<sup>3-5</sup>. Turtles have traditionally been used for food, medicine, and pets in East and Southeast Asia<sup>6-8</sup>. Consequently, Asia, including China, Hong Kong, Japan, Taiwan, and Korea, imports and exports large quantities of live turtles<sup>9-11</sup>. The annual trade of live turtles in Asia has exceeded 13,000 metric tons, the highest number expected to be collected in the wild<sup>9</sup>. According to the National Institute of Biological Resources (NIBR), the turtle was the second most commonly imported taxon among endangered species that were imported into Korea between 2009 and 2014<sup>9</sup>. In addition, the demand for turtles in Asia has increased in recent decades<sup>9</sup>. In order to satisfy the rising demand for food, medicines, and pets, the illegal trade of turtles has increased<sup>9</sup>. In particular, due to pet preference, the illegal trade of rare turtle species, such as *Cuora flavomarginata*, increases<sup>10,11</sup>. Various international conventions and conservation bodies, including the Convention on International Trade in Endangered Species of Wild Fauna and Flora (CITES) and the International Union for the Conservation of Nature and Natural Resources (IUCN), seek to protect turtles from extinction and illegal trade.

The wildlife trade has been known to be a source of alien invasive species<sup>12-14</sup>. These negatively affect native species through predation and competition, diffuse pathogens, and modify the functioning of the ecosystem and abiotic features of environments<sup>15,16</sup>. In particular, turtles have a greater impact on the native population than other animals as they are long-lived organisms which can survive for decades in suboptimal habitats where environmental characteristics are suitable for breeding<sup>17,18</sup>. The introduction of alien turtles into the wild has continued due to abandonment of breeding as pets, religious release, and careless management<sup>19,20</sup>. Alien invasive turtles have been reported in various countries. Since 1997, the European Union has prohibited the import of slider turtle, *Trachemys scripta elegans*, because it competes for food and basking spots with the threatened European pond turtle, *Emys orbicularis*<sup>21-23</sup>. Native to the Americas, *Chelydra* and *Macrochelys*, are found in the Yangtze River basin in China<sup>24</sup>. The snapping turtle, *Chelydra serpentina*, was imported to Japan from the American continent as a pet, but some have been and continue to be abandoned in the wild<sup>25</sup>. In Korea, invasive turtles have also been reported, where non-native turtles such as *Graptemys ouachitensis* and *Macrochelys temminckii* have been observed<sup>26,28</sup>. These are now included on the NIBR's list of imported turtle species<sup>9</sup>. In order to preserve native ecosystems, it is essential to detect and classify these non-native turtles coming no through the pet trade.

To identify which species are being traded, species identification based on morphological features has been used as a standard and effective method<sup>22-28</sup>. However, this requires skilled experts to identify targeted wildlife<sup>9</sup>.

<sup>1</sup>Department of Biotechnology, Sangmyung University, Seoul 03016, Korea. <sup>2</sup>These authors contributed equally: Jong-Won Baek and Jung-Il Kim. <sup>\*</sup>email: [evodevo@smu.ac.kr](mailto:evodevo@smu.ac.kr)

Scientific Reports | (2023) 13:22577 | <https://doi.org/10.1038/s41598-023-48022-3> nature portfolio

# 바다거북 종 분류 모델 성능 향상 연구

## [2. Instance segmentation 모델을 활용한 모델 성능 향상]

- 전 세계에 서식하는 바다거북(sea turtles) 7종 모두는 멸종위기종으로 지정되어 있으며 CITES Appendix I에 포함되어 국제적인 보호를 받고 있음
- 연구 1에서 *Chelonia mydas* 는 가장 낮은 분류 성능을 보였으며 수중 환경에서 모델 성능이 저하되는 것을 확인함
- 실제로 해안 및 수중 환경은 파도, 반사광, 부유물, 다양한 해양생물 등 복잡한 배경 요소를 포함하고 있어 객체 탐지와 분류 정확도를 저하시키는 주요 요인으로 작용할 수 있음
- 따라서, 수중에 서식하는 바다거북의 분류 정확도를 향상시키기 위해서는 배경과 객체를 잘 구분하는 기술 적용이 필요함
- You Only Look Once(YOLO)는 회귀(regression)와 분류(classification)를 동시에 수행하는 대표적인 객체 탐지 모델임. 기존 객체 탐지 모델 대비 높은 정확도와 빠른 처리 속도를 보이며, 다양한 생물 및 야생동물 분류 연구에도 성공적으로 활용되고 있음

*Caretta caretta*



*Lepidochelys kempii*



*Lepidochelys olivacea*



*Chelonia mydas*



*Eretmochelys imbricata*



*Natator depressus*




*Dermochelys coriacea*




# 바다거북 종 분류 모델 성능 향상 연구

- YOLO-seg는 객체를 픽셀 단위로 구분하여, 복잡한 이미지에서 보다 정밀한 분류가 가능하도록 개발된 인스턴스 세그멘테이션 모델(instance segmentation model)임
- 따라서, 단순 객체 위치 탐지를 넘어 **객체의 형태와 경계까지 세밀하게 구분**할 수 있는 특징이 있음
- COCO Dataset 기준으로 Mask R-CNN 및 YOLACT보다 우수한 성능을 보였으며, 정확도와 처리 속도 측면에서 높은 경쟁력을 확인하였음
- 특히 복잡한 해안 및 수중 배경 환경에서도 **객체의 경계를 정밀하게 구분**할 수 있어, 보다 정확한 객체 분류와 탐지에 적합한 모델로 평가되고 있음
- 본 연구에서는 7종의 바다거북 분류 성능을 높이기 위해 instance segmentation을 적용하였으며, 기존의 모델 성능(object detection)과 비교하고 평가하였음



< Object detection model >




< Instance segmentation model >

# 바다거북 종 분류 모델 성능 향상 연구

〈 본 연구에서 조사된 7종의 바다거북을 포함하는 데이터셋 〉


| Species                       | Training set | Validation set | Test set |
|-------------------------------|--------------|----------------|----------|
| <i>Caretta caretta</i>        | 93           | 23             | 30       |
| <i>Lepidochelys kempii</i>    | 40           | 10             | 13       |
| <i>Lepidochelys olivacea</i>  | 58           | 14             | 20       |
| <i>Chelonia mydas</i>         | 501          | 125            | 158      |
| <i>Eretmochelys imbricata</i> | 149          | 37             | 47       |
| <i>Natator depressus</i>      | 40           | 10             | 14       |
| <i>Dermochelys coriacea</i>   | 156          | 39             | 50       |
| Total                         | 1,037        | 258            | 332      |



〈 YOLOv5와 YOLOv5-seg 모델 구조도 〉

- **Data collection** : iNaturalist와 Google에서 7종의 바다거북과 다양한 배경을 포함하여 수집
- **Data selection** : 형태 특징이 기재된 기재 논문 및 도감, 저품질의 이미지 제거 (Total : 1,627)
- **Data augmentation** : Albumentation, Mosaic augmentation
- **Model training** : Object detection model (YOLOv5)과 Instance segmentation model(YOLOv5-seg), epoch 1000, patience 100, imgsz 640

# 바다거북 종 분류 모델 성능 향상 연구



〈각 모델들의 Loss function 분석〉

(A) Classes loss,  $L_{cls}$ , (B) Objectness loss,  $L_{obj}$ , (C) Complete Intersection over Union (CIoU) loss,  $L_{CIoU}$

- **Overfitting** : object detection model과 instance segmentation model 모두 과적합이 일어나지 않았음
- **Three loss value (class, objectness, and CIoU)**: object detection > instance segmentation
- **Discrepancy between predicted and actual results** : object detection > instance segmentation


# 바다거북 종 분류 모델 성능 향상 연구

〈본 연구에서 비교 모델의 Precision, recall, and mean Average Precision (mAP) 성능 비교〉

| Species                       | Precision |            | Recall |            | mAP0.5 |            | mAP0.5-0.95 |            |
|-------------------------------|-----------|------------|--------|------------|--------|------------|-------------|------------|
|                               | YOLOv5    | YOLOv5-seg | YOLOv5 | YOLOv5-seg | YOLOv5 | YOLOv5-seg | YOLOv5      | YOLOv5-seg |
| <i>Caretta caretta</i>        | 0.933     | 1.000      | 0.922  | 0.892      | 0.982  | 0.987      | 0.842       | 0.926      |
| <i>Lepidochelys kempii</i>    | 0.545     | 0.789      | 0.846  | 0.615      | 0.607  | 0.751      | 0.557       | 0.571      |
| <i>Lepidochelys olivacea</i>  | 0.741     | 0.754      | 0.750  | 0.800      | 0.836  | 0.815      | 0.720       | 0.745      |
| <i>Chelonia mydas</i>         | 0.963     | 0.968      | 0.972  | 0.952      | 0.984  | 0.989      | 0.925       | 0.915      |
| <i>Eretmochelys imbricate</i> | 0.871     | 0.900      | 0.957  | 0.961      | 0.958  | 0.965      | 0.896       | 0.897      |
| <i>Natator depressus</i>      | 0.766     | 0.866      | 0.874  | 0.864      | 0.849  | 0.924      | 0.731       | 0.856      |
| <i>Dermochelys coriacea</i>   | 0.905     | 0.978      | 0.980  | 1.000      | 0.979  | 0.994      | 0.891       | 0.909      |
| Average                       | 0.818     | 0.894      | 0.900  | 0.869      | 0.885  | 0.918      | 0.795       | 0.831      |

- **mAP0.5** : object detection model (0.885) vs. instance segmentation model (0.918)
- **mAP0.5-0.95** : object detection model (0.795) vs. instance segmentation model (0.831)
- **Improvement factors** : mAP0.5와 mAP0.5-0.95에서 성능 모두 instance segmentation model에서 향상되었음

# 바다거북 종 분류 모델 성능 향상 연구



< 7종의 바다거북 분류결과를 보여주는 Confusion matrix >

(A) YOLOv5 model의 Confusion matrix, (B) YOLOv5-seg model의 Confusion matrix

Cc, *Caretta caretta*; Lk, *Lepidochelys kempii*; Lo, *Lepidochelys olivacea*; Cm, *Chelonia mydas*; Ei, *Eretmochelys imbricata*; Nd, *Natator depressus*; Dc, *Dermochelys coriacea*

- **Average correct classification rate** : Object detection model (84.3%) vs instance segmentation model (86.1%)
- **Improvement factors** : 분류정확도 향상, 탐지 성능 향상 (*Natator depressus* 와 배경과의 오분류 개선)
- **Challenge factors** : 데이터 부족(Insufficient data), 형태적 유사성(Morphological similarity)
- **Future studies** : 형태 특징을 잘 보여주는 이미지 추가 수집(Collection of morphology-clear image), 최신 모델 사용 (Adoption of advanced models) (e.g. YOLO11), 모델 구조 디자인(Architecture design)

# 바다거북 종 분류 모델 성능 향상 연구

PLOS ONE

## RESEARCH ARTICLE

### Deep learning-based image classification of sea turtles using object detection and instance segmentation models

Jong-Won Baek\*, Jung-Il Kim\*, Chang-Bae Kim\*

Department of Biotechnology, Sangmyung University, Seoul, Korea

\* These authors contributed equally to this work.  
\* evodevo@smu.ac.kr

## Abstract

Sea turtles exhibit high migratory rates and occupy a broad range of habitats, which in turn makes monitoring these taxa challenging. Applying deep learning (DL) models to vast image datasets collected from citizen science programs can offer promising solutions to overcome the challenge of monitoring the wide habitats of wildlife, particularly sea turtles. Among DL models, object detection models, such as the You Only Look Once (YOLO) series, have been extensively employed for wildlife classification. Despite their successful application in this domain, detecting objects in images with complex backgrounds, including underwater environments, remains a significant challenge. Recently, instance segmentation models have been developed to address this issue by providing more accurate classification of complex images compared to traditional object detection models. This study compared the performance of two state-of-the-art DL methods namely; the object detection model (YOLOv5) and instance segmentation model (YOLOv5-seg), to detect and classify sea turtles. The images were collected from iNaturalist and Google and then divided into 64% for training, 16% for validation, and 20% for test sets. Model performance during and after finishing training was evaluated by loss functions and various indexes, respectively. Based on loss functions, YOLOv5-seg demonstrated a lower error rate in detecting rather than classifying sea turtles than the YOLOv5. According to mean Average Precision (mAP) values, which reflect precision and recall, the YOLOv5-seg model showed superior performance than YOLOv5. The mAP0.5 and mAP0.5:0.95 for the YOLOv5 model were 0.885 and 0.795, respectively, whereas for the YOLOv5-seg, these values were 0.918 and 0.831, respectively. In particular, based on the loss functions and classification results, the YOLOv5-seg showed improved performance for detecting rather than classifying sea turtles compared to the YOLOv5. The results of this study may help improve sea turtle monitoring in the future.

## Introduction

Sea turtles, the superfamily Chelonioidae, include the seven species: *Caretta caretta*, *Chelonia mydas*, *Dermochelys coriacea*, *Eretmochelys imbricata*, *Lepidochelys kempii*, *Lepidochelys*

## 관인생략

### 출원번호통지서

출원일자 2025.04.01  
특기사항 심사청구(유) 공개신청(무) 참조번호(APP20250041)  
출원번호 10-2025-0042076 (접수번호 1-1-2025-0365787-74)  
(DAS접근코드 2AD2)  
출원인명칭 상명대학교산학협력단(1-2013-011529-0)  
대리인성명 특허법인 이씨앰(9-2020-100042-5)  
발명자성명 김창배 백종원 김정일 안형은  
발명의명칭 객체 감지 및 인스턴스 분할 모델을 사용한 딥러닝 기반 이미지 분류 방법 및 장치

## 특허청장

<< 안내 >>

1. 귀하의 출원은 위와 같이 정상적으로 접수되었으며, 이후의 심사 진행상황은 출원번호를 이용하여 특허로 홈페이지(www.patent.go.kr)에서 확인하실 수 있습니다.  
2. 출원에 따른 수수료는 접수일로부터 다음날까지 동봉된 납입영수증에 성명, 납부자번호 등을 기재하여 가까운 은행 또는 우체국에 납부하여야 합니다.  
※ 납부자번호 : 0131(기관코드) + 접수번호  
3. 귀하의 주소, 연락처 등의 변경사항이 있을 경우, 즉시 [특허고객번호 정보변경(경정), 정정신고서]를 제출하여야 출원 이후의 각종 통지서를 정상적으로 받을 수 있습니다.  
4. 기타 심사 절차(제도)에 관한 사항은 특허청 홈페이지를 참고하시거나 특허고객상담센터(☎ 1544-8080)에 문의하여 주시기 바랍니다.  
※ 심사제도 안내 : https://www.kipo.go.kr-지식재산제도



보도자료



보도시점 2025. 8. 21.(목) 12:00 (금요일 조간) 배포 2025. 8. 20.(수)

## 인공지능(AI) 기반으로 거북류 13종 판별 기술 개발

- 국립생물자원관, 빠르고 정확한 분류법으로 거북류 종 구별에 도움 기대

환경부 소속 국립생물자원관(관장 유호)은 복잡한 분석 과정을 거치지 않고 늑대거북 등 거북류 13종을 판별하는 인공지능(AI) 기반의 맞춤형 종 분류 기술(하이퍼파라미터 및 인스턴스 분할)을 최근 개발했다고 밝혔다.

\* 해당 기술에 하이퍼파라미터 최적화 기술(학습하려는 데이터셋에 모델이 최고의 성능을 낼 수 있도록 최적의 설정값 조절) 및 인스턴스 분할 기술(각 대상을 정확하게 구분할 수 있도록 대상의 이미지 테두리를 정밀하게 인식)을 적용함

거북류는 전 세계적으로 378여 종이 있는데 형태학적으로 유사\*한 종이 많아 외형만으로 빠르게 구분하기가 힘들어 수출입 관리에 어려움이 많은 것으로 알려졌다.

\* 주요 형태학적 특징이 위치한 등갑이 유사하거나 긴 수명 동안 섭식, 물리적 충격 등으로 변형된 경우가 많음

이에 국립생물자원관은 2021년부터 진행 중인 '생물정보 빅데이터 활용 전문인력양성' 사업을 수행 중인 상명대 김창배 교수팀과 함께 다양한 거북류 사진을 확보하여 빅데이터를 적용한 인공지능(AI) 모델에 거북류를 맞춤형한 종 판별하는 기술을 개발했다.

이 기술을 적용한 거북류 13종\* 중 대표적으로 늑대거북, 악어거북, 중국 줄무늬목거북 등 생태계교란 거북 3종은 하이퍼파라미터 최적화 기술을 적용해 정확도 최대 99%를 달성했다.

\* △붉은귀거북, △리버부터, △중국줄무늬목거북, △악어거북, △플로리다붉은배거북, △늑대거북, △장수거북, △매부리바다거북, △푸른바다거북, △붉은바다거북, △켄프각시바다거북, △올리브바다거북, △납작등바다거북

# 생태계교란 거북 종 분류 모델 성능 향상 연구

## [3. Hyperparameter optimization을 적용한 모델 성능 향상]

- 연구 1의 배경은 침입종(invasive species)의 도입 및 확산 가능성을 보여주며, 이는 거래 과정 뿐만 아니라 자연 서식지에서도 조기 탐지와 관리의 필요성을 강조함
- 특히 거북류는 수명이 길고 다양한 환경에서 생존할 수 있어 생태계에 미치는 영향이 크며, 기온 상승으로 인해 토착종과의 경쟁 가능성도 증가하고 있음
- 따라서 생태계교란 거북류의 확산을 막고 건강한 생태계를 유지하기 위해서는 조기탐지 및 신속대응(Early Detection and Rapid Response, EDRR)을 위한 효과적인 모니터링이 필요함
- 이를 위해서는 고성능의 자동화된 모델이 필요하며, 기존의 모델을 데이터셋에 최적화(Optimization)함으로써 성능을 향상시킬 필요가 있음
- Hyperparameter optimization에는 대표적인 Optimizer selection과 Hyperparameter tuning이 포함되어 있음
- 본 연구에서는 6종의 외래거북을 대상으로 조기 탐지 성능을 높이기 위해 Hyperparameter optimization을 적용하였으며, 적용 전후의 모델 성능을 평가하고 비교하였음

*Chelydra serpentina*



*Macrochelys temminckii*



*Mauremys sinensis*



*Pseudemys concinna*



*Pseudemys nelsoni*



*Trachemys spp.*




〈환경부 지정 생태계교란 거북〉

# 생태계교란 거북 종 분류 모델 성능 향상 연구

< 외래거북 6종의 dataset 구축 결과 >

| Species                       | Training set | Validation set | Test set |
|-------------------------------|--------------|----------------|----------|
| <i>Chelydra serpentina</i>    | 1,543        | 385            | 483      |
| <i>Macrochelys temminckii</i> | 184          | 46             | 59       |
| <i>Mauremys sinensis</i>      | 474          | 118            | 149      |
| <i>Pseudemys concinna</i>     | 539          | 134            | 170      |
| <i>Pseudemys nelsoni</i>      | 643          | 160            | 203      |
| <i>Trachemys scripta</i>      | 1,054        | 263            | 331      |
| Total                         | 4,437        | 1,106          | 1,395    |




< YOLO11 모델 구조도 >

- **Data collection** : iNaturalist와 Google에서 6종의 외래종 거북 이미지를 수집
- **Data selection** : 형태 특징이 기재된 기재 논문 및 도감, 저품질의 이미지 제거 (Total : 6,934)
- **Data augmentation** : Albumentation, Mosaic augmentation
- **Model training** : YOLO11 모델을 사용하였으며, optimizer selection과 hyperparameter tuning을 적용하여 최적화(Optimization)

# 생태계교란 거북 종 분류 모델 성능 향상 연구

## [Optimizer selection]




〈다양한 optimizer로 학습된 모델들의 loss function 결과 비교〉

(A) Complete Intersection over Union loss,  $LCIoU$ , (B) Classification loss,  $Lcls$ , (C) Distribution focal loss,  $Ldfl$

- AdamW model : 과적합 발생(Overfitting)
- RMSProp model : 수치적 불안정성(numerical instability)으로 인해 학습 실패
- Nadam model : 과적합은 일어나지 않았으나(No Overfitting), 세 가지 loss에서 가장 낮은 성능을 보임 (= highest losses)
- SGD model : 과적합 없이(No Overfitting), 세 가지 loss에서 가장 우수한 성능을 보임 (= lowest losses)

# 생태계교란 거북 종 분류 모델 성능 향상 연구

## [Optimizer selection]




〈다양한 optimizer로 학습된 모델들의 Precision, Recall, mAP0.5-0.95 결과 비교〉

- mAP0.5 : Nadam model (0.904) ~ SGD model (0.959)
- mAP0.5-0.95 : Nadam model (0.725) ~ SGD model (0.815)
- SGD model : 모든 평가 지표(Precision, Recall, mAP0.5, mAP0.5-0.95)에서 가장 우수한 성능을 달성함

# 생태계교란 거북 종 분류 모델 성능 향상 연구

## [Hyperparameter tuning]




〈Hyperparameter tuning 과정에서의 scatters plot〉

〈Default model과 Optimized model의 hyperparameter 값 비교〉

| Hyperparameter      | Description                                                                    | Default model  | Optimized model |
|---------------------|--------------------------------------------------------------------------------|----------------|-----------------|
| <b>lr0</b>          | <b>Initial learning rate</b>                                                   | <b>0.01000</b> | <b>0.00688</b>  |
| lr                  | Final learning rate                                                            | 0.01000        | 0.01122         |
| momentum            | Momentum factor for SGD or beta1 for Adam optimizers                           | 0.93700        | 0.96821         |
| <b>weight_decay</b> | <b>L2 regularization term</b>                                                  | <b>0.00050</b> | <b>0.00076</b>  |
| warmup_epoch        | Number of epochs for learning rate warmup                                      | 3.00000        | 3.45669         |
| warmup_momentum     | Initial momentum for warmup phase                                              | 0.80000        | 0.93534         |
| box                 | Weight of the Complete Intersection over Union loss function                   | 7.50000        | 6.28481         |
| <b>cls</b>          | <b>Weight of the classification loss function</b>                              | <b>0.50000</b> | <b>0.77211</b>  |
| dfl                 | Weight of the distribution focal loss function                                 | 1.50000        | 1.33119         |
| hsv_h               | Adjusting the hue of the image by a color wheel to introduce color variability | 0.01500        | 0.01087         |
| hsv_s               | Altering the saturation of the image                                           | 0.70000        | 0.82473         |
| <b>hsv_v</b>        | <b>Modifying the value (brightness) of the image</b>                           | <b>0.40000</b> | <b>0.27159</b>  |
| translate           | Translating the image horizontally and vertically                              | 0.10000        | 0.12203         |
| scale               | Scaling the image by a gain factor                                             | 0.50000        | 0.57497         |
| fliplr              | Flipping the image left to right with the specified probability                | 0.50000        | 0.39212         |
| <b>mosaic</b>       | <b>Combining four training images into a single image</b>                      | <b>1.00000</b> | <b>0.53319</b>  |

- Random search를 이용하여 SGD model의 16개의 hyperparameter 조정
- Optimal hyperparameter combination : 114<sup>th</sup> iteration
- Training-related hyperparameters : 안정성 및 정확도 향상(Enhance stability and accuracy)
- Augmentation-related hyperparameters : 데이터 왜곡 최소화(Minimize data distortion)

# 생태계교란 거북 종 분류 모델 성능 향상 연구



<Default model과 Optimized model의 Loss function 비교>

A) Complete Intersection over Union loss,  $LCIoU$ , B) Classification loss,  $Lcls$ , C) Distribution focal loss,  $Ldfl$

- **Overfitting** : non-fine-tuned model과 fine-tuned model 모두 과적합이 일어나지 않았음 (No overfitting)
- **Default model** :  $Lcls$ 에서 lower values (=lower error)를 나타냄
- **Optimized model** :  $LCIoU$ ,  $Ldfl$ 에서 lower values (=lower error)를 나타냄

# 생태계교란 거북 종 분류 모델 성능 향상 연구


<Default model과 Optimized model의 Loss

< Hyperparameter tuning 적용 전 후 모델 성능 비교 >

| Species                       | Precision     |                 | Recall        |                 | mAP0.5        |                 | mAP0.5-0.95   |                 |
|-------------------------------|---------------|-----------------|---------------|-----------------|---------------|-----------------|---------------|-----------------|
|                               | Default model | Optimized model | Default model | Optimized model | Default model | Optimized model | Default model | Optimized model |
| <i>Chelydra serpentina</i>    | 0.962         | 0.962           | 0.984         | 0.990           | 0.993         | 0.993           | 0.881         | 0.900           |
| <i>Macrochelys temminckii</i> | 0.975         | 0.976           | 0.853         | 0.889           | 0.960         | 0.975           | 0.793         | 0.816           |
| <i>Mauremys sinensis</i>      | 0.949         | 0.942           | 0.917         | 0.935           | 0.960         | 0.963           | 0.788         | 0.795           |
| <i>Pseudemys concinna</i>     | 0.955         | 0.925           | 0.870         | 0.932           | 0.951         | 0.969           | 0.835         | 0.866           |
| <i>Pseudemys nelsoni</i>      | 0.952         | 0.976           | 0.927         | 0.938           | 0.962         | 0.978           | 0.801         | 0.831           |
| <i>Trachemys scripta</i>      | 0.942         | 0.913           | 0.856         | 0.923           | 0.924         | 0.959           | 0.789         | 0.836           |
| Total                         | 0.956         | 0.949           | 0.901         | 0.934           | 0.959         | 0.973           | 0.815         | 0.841           |

- 기본 설정값을 사용한 모델은 Default model로 나타나며 Hyperparameter tuning을 적용한 모델은 Optimized model로 나타냄
- **mAP0.5** : Default model (0.959) vs. Optimized model (0.973)
- **mAP0.5-0.95** : Default model (0.815) vs. Optimized model (0.841)
- mAP0.5와 mAP0.5-0.95에서 성능 모두 hyperparameter tuning 이후 향상되었음

# 생태계교란 거북 종 분류 모델 성능 향상 연구



〈외래거북의 분류 성능을 보여주는 confusion matrix〉

(A) Default model, (B) Optimized model

Cs, *Chelydra serpentina*; Mt, *Macrochelys temminckii*; Ms, *Mauremys sinensis*; Pc, *Pseudemys concinna*; Pn, *Pseudemys nelsoni*; Ts, *Trachemys scripta*

- **Average correct classification rate** : Default model (89.9%) vs Optimized model (92.7%)
- *Pseudemys concinna* : 85.0% → 91.8% (The highest improvement)
- *Macrochelys temminckii* : 80.4% → 87.0% (The second highest improvement)
- 종합적으로 hyperparameter tuning 의 적용은 기본 설정 값을 데이터셋에 최적화(Optimization)함으로써 모델의 성능을 향상에 도움을 줄 수 있음을 확인함

# 생태계교란 거북 종 분류 모델 성능 향상 연구

scientific reports

## OPEN Hyperparameter optimization to enhance the performance of deep learning models for the early detection of invasive turtles in Korea

Jong-Won Baek<sup>1,2</sup>, Jung-Il Kim<sup>2,3</sup>, Min-Ho Mun<sup>2</sup> & Chang-Bae Kim<sup>1,2</sup>

Invasive freshwater turtles are major drivers of biodiversity loss, underscoring the importance of early detection and management. However, it is challenging for experts to manually monitor a broad geographic area, necessitating support tools. Deep learning-based object detection models have displayed high performance in automating wildlife monitoring tasks. Furthermore, hyperparameter optimization, including optimizer selection and hyperparameter tuning, might further enhance performance by optimizing training settings to the dataset. In this study, an optimized model was developed to apply hyperparameter optimization to detect and classify six invasive turtle species in Korea from images. The optimized model was compared to a default model trained using the default optimizer and hyperparameters. The optimized model outperformed the default model, as indicated by the evaluations of mean average precision using a fixed intersection over union threshold of 0.5 (0.973 vs. 0.959) and a range of thresholds ranging from 0.5 to 0.95 (0.841 vs. 0.815). The classification accuracy of the optimized model reached 92.7%, exceeding that of the default model (89.9%). These findings highlight the utility of hyperparameter optimization and suggest that the proposed approach can support the early detection of invasive turtles, thereby enhancing to invasive species management.

**Keywords** Invasive turtle, Early detection, Deep learning, Object detection, Hyperparameter optimization

Invasive species are major drivers of biodiversity decline globally<sup>1</sup>. The introduction and subsequent spread of these species are facilitated primarily by the global wildlife trade, which facilitates these movement across ecosystems<sup>2</sup>. These species adversely affect native species through competition, ecosystem alteration, and pathogen spread, hindering biodiversity conservation<sup>3-5</sup>. Moreover, these species rapidly adapt to new environments and they can spread widely<sup>6</sup>. Among these, invasive freshwater turtles could have particularly profound effects because of these long lifespans and adaptability to suboptimal environments<sup>6,7</sup>. Moreover, climate change is further exacerbating this issue. As ambient and water temperatures increase, heat-tolerant freshwater turtles from temperate and tropical regions are becoming more likely to outcompete native species, increasing the likelihood that invasive turtles will successfully establish themselves in new habitats<sup>8</sup>. For instance, *Trachemys scripta*, a globally invasive freshwater turtle with relatively high thermal tolerance, may gain a competitive advantage over native Chinese species such as *Pelodiscus sinensis* and *Mauremys reevesii* under warmer conditions<sup>9</sup>. Indeed, several Asian countries have reported the establishment of invasive freshwater turtles or the potential for such establishment, highlighting the necessity for effective management<sup>10-12</sup>. *Trachemys scripta* and *Chelydra serpentina* have been reported as established invasive species or identified as having high invasive potential in China, Japan, and Taiwan<sup>11-14</sup>. Additionally, *Macrochelys temminckii* has been detected as an invasive species in China and Taiwan, and *Pseudemys concinna* has been noted as an invasive species in Taiwan<sup>11,15</sup>. Along with these four species, *Mauremys sinensis* and *P. nelsoni* have been managed as invasive species in Korea<sup>16</sup>. Therefore, management is necessary to prevent further establishment of invasive turtles in domestic ecosystems and nationwide spread.

Effective management of invasive species critically relies on early detection through monitoring<sup>17</sup>. Such early detection might minimize ecological and economic damage<sup>18</sup>. Typically, early detection of invasive species

<sup>1</sup>Biotechnology Major, Sangmyung University, Seoul 03016, Korea. <sup>2</sup>Ocean Climate Response and Ecosystem Research Department, Korea Institute of Ocean Science and Technology, Busan 49111, Korea. <sup>3</sup>Jong-Won Baek and Jung-Il Kim contributed equally to this work. <sup>✉</sup>email: evodevo@smu.ac.kr



보도자료



보도시점 2025. 8. 21.(목) 12:00 (금요일 조간) 배포 2025. 8. 20.(수)

## 인공지능(AI) 기반으로 거북류 13종 판별 기술 개발

- 국립생물자원관, 빠르고 정확한 분류법으로 거북류 중 구별에 도움 기대

환경부 소속 국립생물자원관(관장 유호)은 복잡한 분석 과정을 거치지 않고 늑대거북 등 거북류 13종을 판별하는 인공지능(AI) 기반의 맞춤형 중 분류 기술(하이퍼파라미터 및 인스턴스 분할)을 최근 개발했다고 밝혔다.

\* 해당 기술에 하이퍼파라미터 최적화 기술(학습하려는 데이터셋에 모델이 최고의 성능을 낼 수 있도록 최적의 설정값 조절) 및 인스턴스 분할 기술(각 대상을 정확하게 구분할 수 있도록 대상의 이미지 테두리를 경밀하게 인식)을 적용함

거북류는 전 세계적으로 378여 종이 있는데 형태학적으로 유사\*한 종이 많아 외형만으로 빠르게 구분하기가 힘들어 수출입 관리에 어려움이 많은 것으로 알려졌다.

\* 주요 형태학적 특징이 위치한 등갑이 유사하거나 긴 수명 동안 섭식, 물리적 충격 등으로 변형된 경우가 많음

이에 국립생물자원관은 2021년부터 진행 중인 '생물정보 빅데이터 활용 전문인력양성' 사업을 수행 중인 상명대 김강배 교수팀과 함께 다양한 거북류 사진을 확보하여 빅데이터를 적용한 인공지능(AI) 모델에 거북류를 맞춤형한 중 판별하는 기술을 개발했다.

이 기술을 적용한 거북류 13종\* 중 대표적으로 늑대거북, 악어거북, 중국 줄무늬목거북 등 생태계교란 거북 3종은 하이퍼파라미터 최적화 기술을 적용해 정확도 최대 99%를 달성했다.

\* △붉은귀거북, △리버부터, △중국줄무늬목거북, △악어거북, △플로리다붉은배거북, △늑대거북, △장수거북, △매부리바다거북, △푸른바다거북, △붉은바다거북, △켄프각시바다거북, △올리브바다거북, △납작등바다거북



SK하이닉스 2025-4942호

17336 경기도 이천시 부발읍 경춘대로 2091  
2091, Gyeongchung-daero, Bubal-eub, Icheon-si, Gyeonggi-do, Korea  
tel 031 5185 4114 [www.skhyunix.com](http://www.skhyunix.com)

문서번호 : SK하이닉스 제2025- 호

수 신 : 상명대학교 생물정보학연구소

참 조 : 백종원

발 신 : 2025.09.18/ SV담당 SV커뮤니케이션팀 남경수 팀장

제 목 : SK하이닉스 <AI for Impact> 우수 사례 선정 확인 및 제2회 사회적가치 페스타 SK하이닉스 전시 부스 중 'AI for Impact' 전시 부스 참여 확인 함

- 귀 기관의 무궁한 발전을 기원합니다.
- 백종원님 (상명대 박사과정)은 2025년 SK하이닉스가 주최한 <AI for Impact> 온·오프라인 교육을 이수하고 생물다양성 분야에 AI기술 활용 방안으로 <시민과학자와 함께하는 기후변화 대응을 위한 AI기반 생물 모니터링 지원 서비스>를 제안하고 딜러님 기반 중 분류 모델을 개발하여 우수 사례로 선정 되었음을 확인합니다.
- 또한, 우수 사례를 바탕으로 제2회 사회적 가치 페스타 SK하이닉스 전시 부스 중 <생물다양성 AI 모니터링> 전시에 참여하였음을 확인합니다.

- 아 래 -

가) 온·오프라인 교육 이수 : 2025년 5월 13일 ~ 2025년 6월 30일

나) AI전문가 멘토링과정 이수 : 2025년 7월1일 ~ 2025년 8월 24일

다) 발표 및 전시일시 : 2025년 8월 25일 ~ 2025년 8월 26일

라) 장소 : 코엑스 Conference Room (327호) 및 전시장 B홀

마) 주제 : AI기술로 사회적 가치 창출을 돕는 <AI for Impact>

바) 내용 : 백종원님은 기후지표종 3종, 생태교란종 6종, 자생종 2종

총 11종의 생물 이미지를 AI로 판독하는 기술을 제안해


우수사례로 선정되어 SK하이닉스 포럼 발표 및 전시 부스에 참여 함.

SK하이닉스주식회사  
대표이사 

# Hyperparameter tuning 가속화를 위한 LLM 기반 에이전트 활용 연구

## [4. Hyperparameter tuning 시간 절감을 위한 에이전트 모델 활용]

- 연구 2의 배경에서는 바다거북(sea turtles) 보전의 중요성을 강조하며, 연구 3에서는 Hyperparameter tuning이 모델의 성능 향상에 효과적임을 입증하였음
- 기존의 Hyperparameter tuning은 Grid Search, Random Search, Genetic Algorithm 등을 사용하지만, 이러한 방법들은 많은 학습 시간과 GPU 자원을 요구한다는 한계가 있음
- 최근에는 Large Language Models(LLM) 기반의 AI 에이전트가 논문과 선행연구를 분석하여 적절한 hyperparameter를 추천할 수 있는 가능성이 제시되고 있음
- 본 연구에서는 BioNexus사의 Nexus Science 기반 연구 에이전트를 활용하여 YOLO 모델 별 추천 hyperparameter를 생성하고 성능을 비교하였음
- 이를 통해 비전문가도 복잡한 튜닝 과정 없이 탐지 성능을 향상시키고, 기존 HPO 대비 수십~수백 배 수준의 시간 절감 효과를 얻을 수 있음을 확인하고자 함



< 기존 하이퍼파라미터 최적화(HPO)를 위한 다양한 알고리즘 원리 >

(a) Random search, (b) Grid search, (c) Genetic algorithm

# Hyperparameter tuning 가속화를 위한 LLM 기반 에이전트 활용 연구



〈 본 연구에서 활용한 Nexus Science 화면 예시〉

```
# ROLE
You are a Senior Computer Vision Researcher specializing in YOLO-based object
detection, underwater detection, literature-driven hyperparameter optimization,
mAP-based performance back-reasoning, and HW-aware training optimization.

# TASK
Analyse the trained <MODEL> result on the sea-turtle dataset and produce a
literature-grounded recommendation that improves mAP. Follow the 13 STEPS
below in strict order; do not skip stages or short-cut to a summary.

# TEXT-ONLY EXECUTION RULE
Never perform pixel-level vision analysis. Use only: annotations, bbox
statistics, image resolution metadata, dataset structure, training logs,
results.csv, confusion-matrix numbers, and paper metadata.

# SYSTEM ENVIRONMENT
OS: Rocky Linux 8 | CPU: Intel Xeon Gold 6326 x2 | RAM: 512GB ECC DDR4
GPU: NVIDIA RTX A5000 24GB
Stack: Python 3.8.2 | CUDA 12.2 | cuDNN 8.9.3 | PyTorch 2.0.1

# INPUT PATHS
Dataset: /Users/Desktop/<Dataset>
Baseline run: /Users/Desktop/<MODEL>/

# GLOBAL CONSTRAINTS
- At least 500 surveyed papers (single recommendation only)
- Performance-weighted analysis (higher-mAP papers carry higher weight)
- Reject paper-only or default-only justifications
- Recommend only hyperparameters that exist in <MODEL>
- All values must be executable under the listed HW

# STEPS (each STEP must be produced in order)
STEP 1. Dataset state analysis
STEP 2. Baseline <MODEL> result analysis (mAP, P, R, loss curves, bottleneck)
STEP 3. <MODEL> hyperparameter inventory (only parameters that exist)
STEP 4. Paper collection and metadata audit (>=500 papers)
STEP 5. Per-parameter HP <-> mAP relationship (weighted, not frequency)
STEP 6. Link dataset issues + baseline bottlenecks + paper patterns
STEP 7. HW-aware feasibility (imgsz/batch ranges, workers, cache mode)
STEP 8. Final recommended values (one value per HP)
STEP 9. Per-parameter detailed justification
STEP 10. Final YAML
STEP 11. Predicted mAP improvement (single number)
STEP 12. Confidence assessment per HP
STEP 13. References (>=500 entries)
```

〈 Nexus Science 입력 프롬프트 〉

- **Agent model** : glm 기반의 Nexus Science (glm-5.1-fp8)
- **Prompt** : 13 stage (Dataset analysis, Paper collection, Result analysis, Result summary, Reference)
- **The number of papers to collect** : 최소 500편 이상 ( $\geq 500$  papers)
- **Output** : Default 값과 Recommended 값 비교 분석 및 추천

# Hyperparameter tuning 가속화를 위한 LLM 기반 에이전트 활용 연구

〈 Hyperparameter 값 추천 소요 시간 비교표〉



| Model    | Nexus Science (ours) | Baek et al., 2026 | Ultralytics | Reduction (vs Baek/ Ultralytics) |
|----------|----------------------|-------------------|-------------|----------------------------------|
| YOLOv8x  | 18m 9s               | 1,379 h           | ≈100 h      | 99.98% / 99.70%                  |
| YOLOv9e  | 35m 13s              |                   |             | 99.96% / 99.41%                  |
| YOLOv10x | 42m 20s              |                   |             | 99.95% / 99.29%                  |
| YOLOv11x | 25m 55s              |                   |             | 99.97% / 99.57%                  |
| YOLOv12x | 24m 17s              |                   |             | 99.97% / 99.60%                  |
| YOLO26x  | 37m 49s              |                   |             | 99.95% / 99.37%                  |

〈 Hyperparameter optimization 성능 비교표〉

| Model    | Default | Tuned | mAP     |
|----------|---------|-------|---------|
| YOLOv8x  | 0.680   | 0.802 | + 0.122 |
| YOLOv9e  | 0.665   | 0.820 | + 0.155 |
| YOLOv10x | 0.688   | 0.727 | + 0.039 |
| YOLO11x  | 0.752   | 0.806 | + 0.054 |
| YOLO12x  | 0.738   | 0.773 | + 0.035 |
| YOLO26x  | 0.670   | 0.798 | + 0.128 |
| Mean     | 0.699   | 0.788 | + 0.089 |

- Tuning time : 18m 9s ~ 42m 20s (기존 tuning에 걸리는 시간에 약 99% 단축)
- Model performance : 최소 YOLO11의 +0.039 ~ 최대 YOLOv9e의 +0.155

# Hyperparameter tuning 가속화를 위한 LLM 기반 에이전트 활용 연구



〈Hyperparameter optimization 성능 비교 그래프〉

(a) 모델 버전 별 업그레이드 성능 비교, (b) Nexus Science 적용 Hyperparameter optimization 후 성능 비교

- Improvement factors : 6개의 모델 mAP 성능 향상 (평균 +0.089)
- Challenge factors : 선행 연구와의 1대 1 성능 비교
- Future studies : Retrieval Augmented Generation(RAG)을 활용한 대규모 문서 활용, 1대 1 성능 비교를 위한 실험 설계

# Hyperparameter tuning 가속화를 위한 LLM 기반 에이전트 활용 연구

## Accelerating Hyperparameter Tuning for YOLO-Based Endangered Sea Turtle Classification via an LLM-Agent Recommendation

Jong Won Baek<sup>1</sup> Gwon Yul Jo<sup>1</sup> Tae Wan Goo<sup>1</sup>

### Abstract

Hyperparameter tuning for object detection is a time-consuming cognitive task that ML researchers face repeatedly: every candidate configuration demands a full training run, and conventional search algorithms routinely consume hundreds to thousands of hours per tuned model. We share a simple AI-assisted workflow that collapses this inner loop into a one-shot literature-driven recommendation from an LLM-based research agent (Nexus Science): given a task description, dataset properties, and a target model variant, the agent surveys  $\geq 500$  published papers and returns a single hyperparameter configuration in under one hour. Applied to six YOLO variants (v8x, v9e, v10x, 11x, 12x, and 26x) on a seven-species sea turtle classification task, the workflow yields an average mAP@0.5 improvement of  $+0.089$  over Ultralytics defaults—larger than the gain from any architectural upgrade within the same family. Each per-model recommendation completes in 18–42 minutes, eliminating over 99% of the wall-clock cost reported for hyperparameter optimization (HPO) approaches studied in prior work on YOLO models. We release the full 13-step prompt, recommended configurations, and verification scripts so that other practitioners can reproduce or adapt the methodology with their preferred LLM-based research agent. Together, this work offers a concrete, reproducible case for accelerating hyperparameter tuning by replacing search-based HPO with a one-shot literature-driven LLM recommendation.

<sup>1</sup>BioNexus, 11F, Gwanggyo Business Center, 156 Gwanggyo-ro, Yeongtong-gu, Suwon-si, Gyeonggi-do, Republic of Korea. Correspondence to: Jong Won Baek <jong-won.baek@bionexus.kr>.

Proceedings of the 43<sup>rd</sup> International Conference on Machine Learning, Seoul, South Korea. PMLR 306, 2026. Copyright 2026 by the author(s).

### 1. Introduction

Sea turtles are among the most threatened marine taxa, with all seven extant species—*Caretta caretta*, *Chelonia mydas*, *Eretmochelys imbricata*, *Lepidochelys olivacea*, *Lepidochelys kempii*, *Natator depressus*, and *Dermochelys coriacea*—listed on the IUCN Red List (IUCN, 2024). Reliable, scalable identification from imagery is essential for population monitoring, by-catch reduction, and anti-poaching enforcement. Deep object detectors of the YOLO family have rapidly become the de facto standard for such tasks, owing to their favorable accuracy–latency trade-off and the steady release of improved variants from v8 through the recently announced v26.

Default hyperparameters for each new YOLO release are calibrated against general-purpose benchmarks such as COCO and are therefore frequently sub-optimal for fine-grained ecological datasets. Practitioners consequently rely on hyperparameter optimization (HPO) methods, which typically consume budgets one to two orders of magnitude larger than the cost of a single training run, regularly observed across YOLO-targeted HPO studies (Baek et al., 2026). Recent progress in large language model (LLM) agents suggests an alternative: rather than searching the hyperparameter space empirically, an agent can reason over the published literature to extract configurations that worked for similar models on analogous tasks, and propose a small set of high-quality candidates. Unlike fixed search algorithms, such a workflow also improves naturally over time at no additional algorithmic cost, as the literature grows richer and LLM-based research agents become more accurate and robust. In this paper, we use Nexus Science, an LLM-based research agent, to produce such recommendations, and we benchmark them across six YOLO variants on the seven-species sea turtle dataset.

Our contributions are as follows:

- A step-by-step methodology applicable across LLM-based research agents. We replace the conventional HPO inner loop—one full training run per candidate—with a single literature-driven recommendation, structured as a 13-step prompt that other practitioners can reproduce or adapt with their preferred agent (we use

## Accelerating Hyperparameter Tuning for YOLO- Based Endangered Sea Turtle Classification via an LLM-Agent Recommendation



Jong-Won Baek<sup>1</sup>, Gwon Yul Jo, Tae Wan Goo  
BioNexus, Gwanggyo Business Center, Suwon 16606  
P. C. jongwon.baek@bionexus.kr



### Background

- Endangered-species detection. All seven extant sea-turtle species are IUCN-listed, so reliable image-based identification underpins population monitoring, by-catch reduction, and anti-poaching. YOLO detectors have become the de facto tool for this task, with a strong accuracy–latency trade-off and rapid releases from v8 through v26.
- Sub-optimal defaults, expensive tuning. Each release ships default hyperparameters calibrated on general benchmarks such as COCO that are often sub-optimal for fine-grained ecological data, yet conventional hyperparameter optimization (HPO) costs one to two orders of magnitude more than a single training run — e.g., 1,379 GPU-hours for a 300-iteration random search.
- One-shot, literature-driven recommendation. We replace this empirical search with a single recommendation from an LLM research agent, Nexus Science, which surveys  $\geq 500$  published papers and returns one configuration per model in under an hour, improving naturally as the literature grows.


### Contributions

- 1 Reproducible methodology. A 13-step prompt usable with any LLM research agent; the full prompt, recommended configurations, and verification scripts are released.
- 2 Gains for domain experts. Meaningful improvements over the official defaults for ecologists and conservation researchers without designing or running a search.
- 3 Orders-of-magnitude speed-up. Every recommendation finishes in under an hour per model (18–42 min), eliminating  $\sim 99\%$  of search-based HPO wall-clock cost.

### Materials & Methods

#### Workflow overview

- Dataset : 7 species sea turtles / 1,627 images
- Models : 6 YOLO series models (YOLOv8, YOLOv9, YOLOv10, YOLOv11, YOLOv12, YOLOv26)
- Condition :
  - Ready Linux 8 with two Intel Xeon Gold 6330 CPUs / 1536GB ECC DDR5 RAM / RTX A6000 GPU (48GB)
  - Python 3.11 / CUDA 12.1 / PyTorch 2.2.1



### Results & Discussion

Table 1. Per-model accuracy and tuning cost under Nexus Science-recommended hyperparameters

| Model   | Model performance |       | Times                       |                                             |                 |
|---------|-------------------|-------|-----------------------------|---------------------------------------------|-----------------|
|         | Default           | Tuned | mAP@0.5 (mAP@0.5 / mAP@0.5) | Reduction (Baek et al., 2026) (Ultralytics) |                 |
| YOLOv8  | 0.680             | 0.802 | +0.122 (+17.8%)             | 18x 0%                                      | 99.96% / 99.75% |
| YOLOv9  | 0.685             | 0.800 | +0.115 (+16.8%)             | 26x 1%                                      | 99.96% / 99.84% |
| YOLOv10 | 0.686             | 0.737 | +0.051 (+7.4%)              | 42x 2%                                      | 99.95% / 99.92% |
| YOLOv11 | 0.752             | 0.866 | +0.114 (+15.1%)             | 26x 5%                                      | 99.97% / 99.97% |
| YOLOv12 | 0.738             | 0.773 | +0.035 (+4.7%)              | 26x 4%                                      | 99.97% / 99.80% |
| YOLOv26 | 0.870             | 0.768 | +0.128 (+15.1%)             | 27x 4%                                      | 99.95% / 99.97% |

- Largest gains where defaults are weakest. The three lowest defaults (v9e, v26x, v8x) receive the three largest gains, mainly recovering dataset-specific headroom the generic defaults left unused.

- 99% less wall-clock cost. Every recommendation finishes in 18–42 min in a single pass, cutting tuning time by 99.95–99.98% versus the prior random search and by 99.25–99.75% versus Ultralytics, reducing a  $\sim 1,379$  GPU-hour search to under an hour per model.

(A) Architectural upgrade (vs. YOLOv8 default) (B) Recommended hyperparameters (per model)




Figure 1. Tuning vs. architectural upgrade. (A) Default mAP@0.5 of newer variants relative to YOLOv8. (B) Per-model gain from recommended hyperparameters.

- Tuning > architecture. Hyperparameter tuning improves mAP more than YOLO version upgrades, with a mean gain of  $+0.089$  versus only  $+0.023$  from generation upgrades.
- Improves naturally over time. The agent learns from accumulated empirical and HPO studies without repeating compute for every new dataset and architecture pair, becoming more robust as the literature grows.
- Transfers without redesign. By changing only the task, dataset, and target model in the prompt, the same workflow can be applied to new models, datasets, and detection problems.

### Future work

- Future validation across broader settings. Subsequent studies can extend this workflow to additional datasets, model families, and agents to further assess its generalizability.
- Same-condition HPO comparison. A valuable next step is to compare conventional HPO algorithms on the same dataset and hardware with repeated seeds.
- Workflow refinement. Future work can systematically analyze recommendation sensitivity and non-improving cases to improve the stability of agent-guided HPO.
- Agent expansion. Beyond Nexus Science, testing other research agents can help evaluate how broadly this framework can support efficient model optimization.

### Reference

- [1] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [2] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [3] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [4] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [5] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [6] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [7] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [8] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [9] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.
- [10] Baek, J. W., Jo, G. Y., & Goo, T. W. (2026). Accelerating hyperparameter tuning for yolo-based endangered sea turtle classification via an llm-agent recommendation. *arXiv preprint arXiv:2605.18811*, 2026.

03

# 에이전트 시연

---



# 백종원

- BioNexus 개발연구부 / 책임연구원 / 팀장
- 이학박사 / 생물정보학 전공



## 현장 조사 및 실험 기반 생물 데이터 발굴



## 이미지, 음성, DNA 데이터를 활용한 딥러닝 기반의 생물 모니터링 모델 개발


사진촬영을 이용한 생물종 검색 모델 개발 과정



사진 데이터베이스 구축



객체 영역 지정



모델 학습



모델 성능 평가


음성소리를 이용한 생물종 검색 모델 개발 과정



소리 데이터베이스 구축



객체 영역 지정




모델 학습



모델 성능 평가

## 멀티모달 데이터 기반 지능형 에이전트 개발 및 활용 연구



# NexusRAG, Nexus Co-Scientist

First

## NexusRAG 서비스 : 정확한 검색 서비스

바이오 도메인 특화 Agentic-RAG

Customize 고객 맞춤 문헌 DB 구성

|    |                   |          |
|----|-------------------|----------|
| 01 | UK Biobank        | 46,700편  |
| 02 | KoGES             | 1,800편   |
| 03 | 농촌진흥청/산림청         | N편       |
| 04 | Dementia          | 15,500 편 |
| 05 | Aging             | 49,000편  |
| 06 | Frailty           | 2,300 편  |
| 07 | Cognitive Reserve | 4,500 편  |




지식그래프 연동  
하이브리드 벡터DB



바이오 도메인 특화  
컨텍스트 엔지니어링




멀티에이전트 시스템



- UKB-RAG, KoGES-RAG, Dementia-RAG 등 -

Second

## Nexus Co-Scientist : AI 공동 연구 플랫폼



# 에이전트 시연

## [야생동물거래 관리 에이전트 구축]

- 연구 1, 3의 배경에서는 외래종의 침입 및 확산 가능성과, 거래 과정 및 자연 서식지에서의 외래종 조기 탐지와 관리의 필요성을 강조함
- 현재 야생동물종합관리시스템은 사용자가 대상 생물종의 이름이나 분류군을 사전에 알고 있어야 검색이 가능한 구조임
- 그러나 일반 시민이나 현장 조사자는 형태가 유사한 종, 생활사 단계가 다른 개체, 촬영 품질이 낮은 자료에서 정확한 종명을 판단하기 어려움
- 이로 인해 미동정 생물의 신속한 검색과 정보 연계에 한계가 있으며, 생태계교란종·멸종위기종 등 주요 관리 대상의 조기 탐지와 대응이 지연될 수 있음
- 따라서 다양한 입력데이터를 기반으로 생물종을 추정하고 관련 정보를 자동으로 연결하는 멀티모달 기반 에이전트(Multimodal-based Agent) 시스템 도입이 필요함


The first screenshot shows the main menu of the WMS. The '생물종 검색' (Species Search) button is highlighted with a red box. The second screenshot shows the search results page. A red box highlights the '국립생물자원관' (National Institute of Biological Resources) link. The third screenshot shows the detailed view of a species, including its distribution map and related information.

| 순번 | 분류군 | 학명               | 국명 | 비고 | 신고대상종 구분       | 양도양수<br>폐사정령<br>신고제외 | 사육시설<br>등록대상 | 인공증식<br>허가대상 |
|----|-----|------------------|----|----|----------------|----------------------|--------------|--------------|
| 1  | 식물  | Aa achalensis    | II |    | 국립생물자원관(CITES) |                      |              |              |
| 2  | 식물  | Aa argenteolepis | II |    | 국립생물자원관(CITES) |                      |              |              |
| 3  | 식물  | Aa aurantiaca    | II |    | 국립생물자원관(CITES) |                      |              |              |
| 4  | 식물  | Aa calceata      | II |    | 국립생물자원관(CITES) |                      |              |              |
| 5  | 식물  | Aa colombiana    | II |    | 국립생물자원관(CITES) |                      |              |              |
| 6  | 식물  | Aa denticulata   | II |    | 국립생물자원관(CITES) |                      |              |              |
| 7  | 식물  | Aa erosa         | II |    | 국립생물자원관(CITES) |                      |              |              |
| 8  | 식물  | Aa fiebrigii     | II |    | 국립생물자원관(CITES) |                      |              |              |

<야생동물종합관리 시스템 검색 흐름 예시>


# 에이전트 시연

[에이전트 구축]



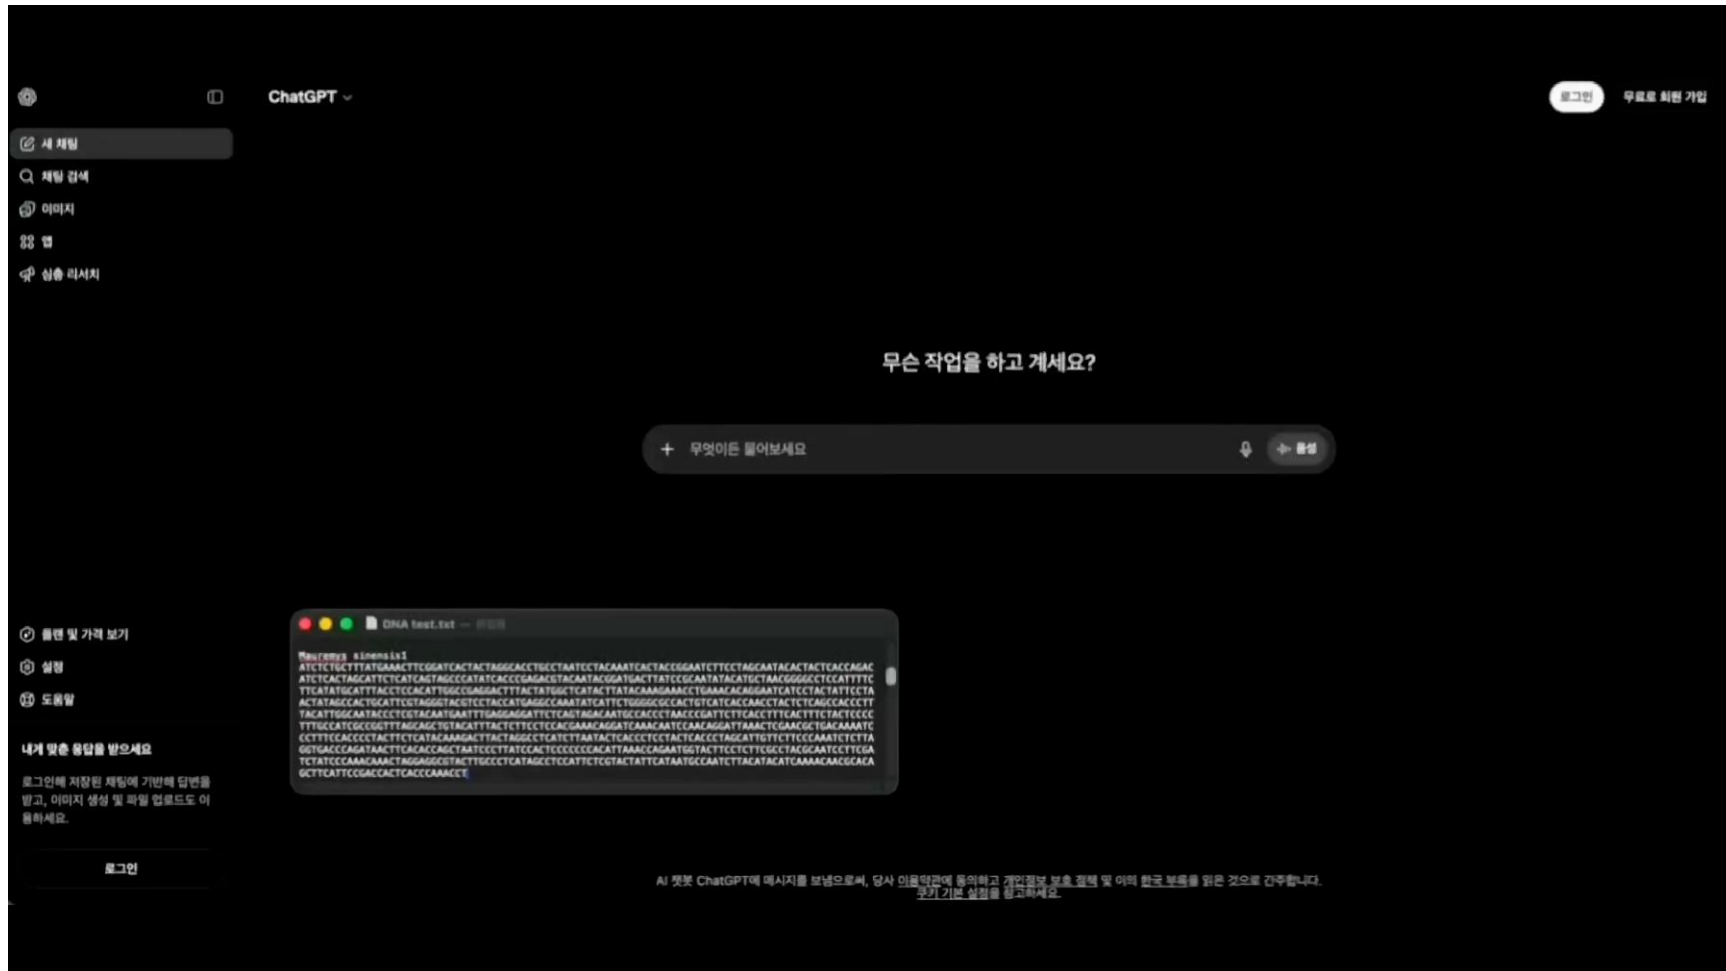
# 에이전트 시연

[결과 (Image input)]




# 에이전트 시연

[결과 (DNA input)]



# 에이전트 시연

[결과 (TXT input)]



감사합니다.