시민과학자 데이터를 활용한 딥러닝 기반 국내 맞춤 생태계교란 거북 종 분류 모델 개발

백종원[1,2p]

[1]상명대학교 생명과학과 생물정보학연구실, [2]숲과나눔 연구장학생

p: 202234006@sangmyung.kr

Background

생물다양성은 건강한 토양 유지, 영양순환, 기후 조절 등 생태계의 핵심 기능에 기여하며 인간의 생활과 밀접한 연관을 가진다(Brussaard et al., 2007). 그러나 전 세계적으로 생물다양성 감소가 가속화되고 있으며(Pimm et al., 2014), 그 주요 원인 중 하나로 국제 무역 확대에 따른 외래종 침입이 지목되고 있다(Havel et al., 2015). **외래종**은 토착종과의 경쟁, 병원체 확산 등을 통해 생태계 구조와 기능에 부정적인 영향을 미치는 주요 원인이다 (Ricciardi, 2007). 이에 따라 우리나라에서는 "생태계교란생물" 제도를 통해 외래종을 법적으로 지정·관리하고 있다. 생태계교란생물 중 **민물거북**은 특히 긴 수명과 높은 환경 적응력을 지녀 생태계에 미치는 영향이 크다(Spinks et al., 2003). 더불어 최근 기후변화로 인한 기온·수온 상승은 온난한 기후에 적응한 외래 거북의 확산 가능성을 높여 국내 토착종과의 경쟁을 심화시키고 있다(Zhang et al., 2023). 이러한 이유로 외래종 관리의 핵심 전략 중 하나인 '**조기 탐지와 신속 대응**(Early Detection and Rapid Response, EDRR)'을 통해 침입 초기 단계에서 관리를 목표로 하지만, 광범위한 서식지를 제한된 인력으로 모니터링하기에는 현실적 한계가 존재한다. 이에 최근 **시민과학자**들과 협업하여 효율적인 외래종 모니터링을 수행하는 시도가 많아지고 있다 (Suzuki-Ohno et al., 2022). 시민과학자 협력으로 수집된 데이터는 광범위한 공간적 범위와 높은 시의성을 가지나, 종 식별의 정확성이 확보되지 않을 경우 활용도가 제한된다. 이를 완화하기 위해 **딥러닝 기반 이미지 분류 기술**이 활용될 수 있다. 이러한 기술은 이미지 내에서 객체의 탐지와 분류를 동시에 수행할 수 있어(Kim et al., 2022), 시민과학자가 현장에서 촬영한 거북 이미지를 자동으로 식별함으로써 빠르고 정확한 종 분류를 지원할 수 있다. 따라서 본 연구는 시민과학자 데이터를 활용하여 국내 환경에 최적화된 생태계교란 거북 종 분류 모델을 개발함으로써, 조기 탐지 및 신속 대응 체계의 고도화에 기여하고자 한다.

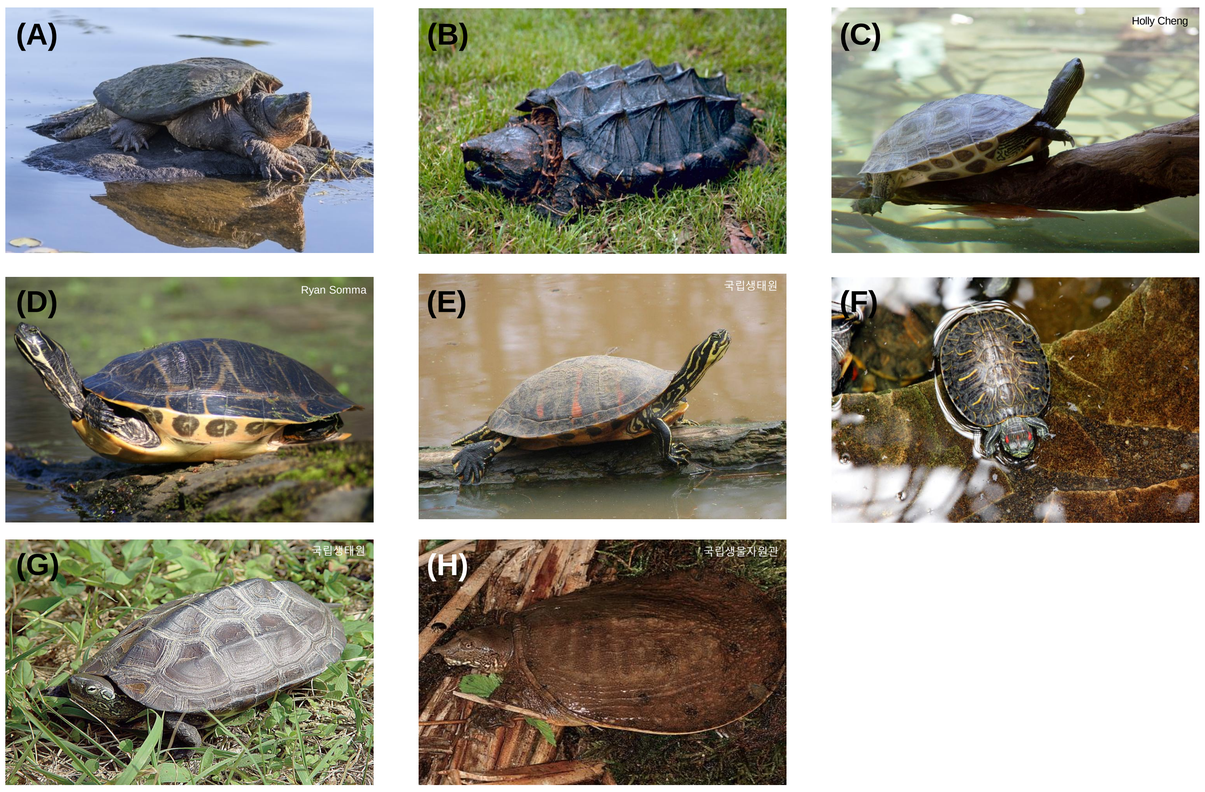


그림 1. 생태계교란거북 6종과 자생거북 2종 사진. (A) *Chelydra serpentina*(늑대거북); (B) *Macrochelys temminckii*(악어거북); (C) *Mauremys sinensis*(중국줄무늬목거북); (D) *Pseudemys concinna*(리버쿠터); (E) *Pseudemys nelsoni*(플로리다붉은배거북); (F) *Trachemys scripta*(붉은귀거북); (G) *Mauremys reevesii*(남생이); (H) *Pelodiscus maackii*(자라).

Materials and Methods

본 연구에서는 민물거북 종 분류를 위한 표준화된 데이터세트가 존재하지 않기 때문에, 8종의 민물거북 이미지를 **iNaturalist**에서 수집하였다. 수집된 이미지는 학술 서적과 형태학 기재 논문에 기술된 종별 **형태학적 특징을 참고**하여 선별하였다. 민물거북의 종 판별에 활용되는 주요 형태학적 특징은 신체 전반에 걸쳐 분포하므로, 이미지 내 거북의 전체 영역을 객체 탐지 대상으로 지정하였다. 최종적으로 라벨링된 데이터세트는 총 **7,417장**의 이미지로 구성되었으며, 무작위로 training set (64%), validation set (16%), test set (20%)으로 분할하여 학습용 데이터세트를 구축하였다. 모델 학습에는 객체 탐지 기반의 **You Only Look Once (YOLO) 11 모델**을 사용하였다. 모델의 성능 최적화를 위해 **6개의 optimizer**를 **비교** 실험하였으며, 이 중 가장 우수한 성능의 optimizer를 최종 학습에 적용하였다. 학습 과정의 설정값은 batch size 16, image size 640, epoch 300, patience 100으로 설정하였다. 또한 모델의 overfitting을 방지하고 데이터 다양성을 확보하기 위해 스케일 변환, 색공간 조정, Mosaic augmentation 등을 포함한 Albumentations 기반 데이터 증강 기법을 적용하였다.

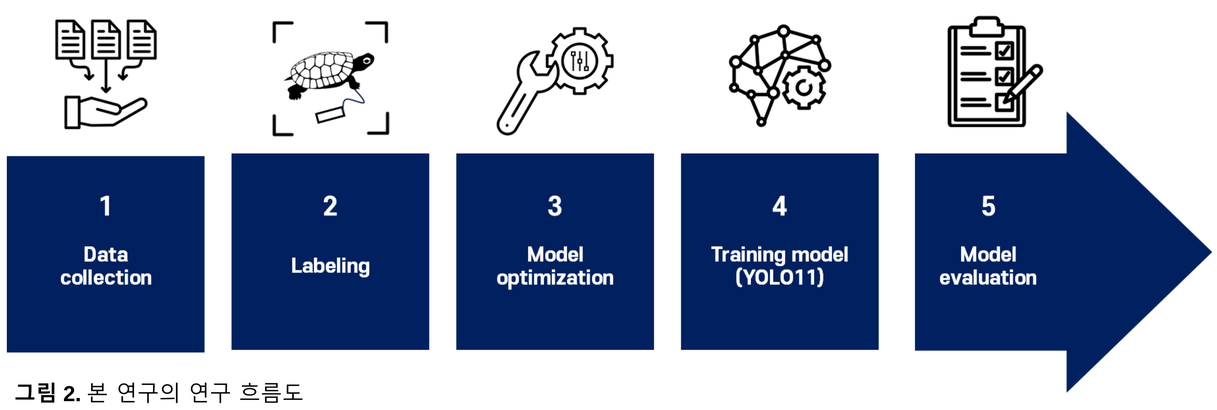


그림 2. 본 연구의 연구 흐름도

Results and Discussion

훈련된 모델의 성능은 mean Average Precision (mAP) 및 inference time을 기준으로 평가하였다. Loss function 분석 결과, 학습 과정에서 overfitting이 발생하지 않았음을 확인하였다. 평가 결과, 모델의 **mAP0.5**는 **0.965**로 mAP0.5-0.95는 0.851로 나타났다. 또한 **Inference time**은 **9.1 ms** (=0.091 s)로 측정되었다. 모델의 분류 정확도는 confusion matrix로 제시하였다(그림 3).

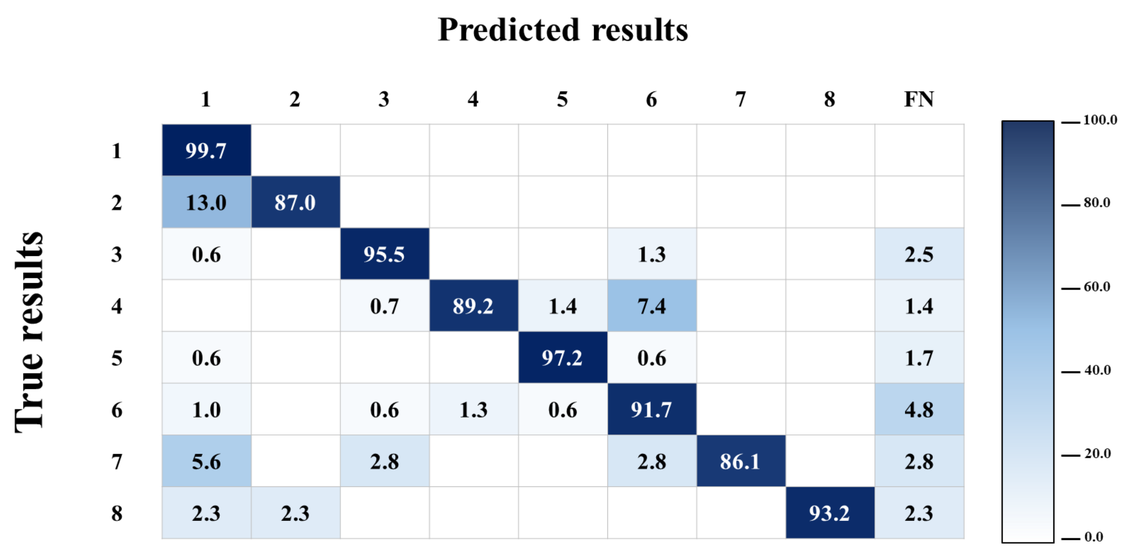


그림 3. 모델의 분류 결과를 나타낸 confusion matrix. 1: 늑대거북, 2: 악어거북, 3: 중국줄무늬목거북, 4: 리버쿠터, 5: 플로리다붉은배거북, 6: 붉은귀거북, 7: 남생이, 8: 자라. FN은 거북류가 배경으로 잘못 분류한 경우의 확률을 나타낸다. 행은 실제 종을 나타내며, 열은 모델이 예측한 종을 나타낸다. 예측 결과는 백분율 값으로 표시된다. 대각선 값은 정확한 예측을 나타내며, 대각선 외의 값은 잘못된 예측을 나타낸다.

Confusion matrix 분석 결과, **전체 평균 분류 정확도**는 **92.5%**로 나타났다(그림 3). 종별 정확도는 늑대거북이 99.7%로 가장 높았으며, 남생이는 86.1%로 가장 낮았다. 남생이의 낮은 정확도는 이미지 수가 제한적(168장)으로 학습 **데이터 불균형**이 발생했기 때문으로 해석된다(Baek et al., 2023). 주요 오분류 사례는 악어거북이 늑대거북으로 분류된 경우(13%)로, 두 종은 등갑의 keels 구조와 scute 배열이 **형태학적**으로 **유사**하여 구분이 어렵다(Charette, 1999). 이에 따라 두 종의 분류정확도 향상을 위해 형태학적 특징이 뚜렷한 이미지의 추가 확보가 필요하다. 시민과학자 데이터 적용 결과(그림 4), 관측 빈도가 높은 **5종**은 라벨 정보와 모델 예측이 **일치**하였으며, **미동정 사례** 또한 모델 예측 기반의 추가 검증 결과 실제 종과 **일치**하였다. 반면, 원거리 촬영, 저해상도, 형태 특징 가림 이미지에서 탐지 및 분류 정확도가 저하되는 경향을 보였다. 따라서 향후에는 모델 성능 향상 기법(Isa et al., 2022;Ye et al., 2024)을 적용하고, 시민과학자 대상 촬영 가이드라인을 병행한다면 생태계교란 거북 모니터링의 효율성을 높일 수 있을 것으로 기대된다. 종합적으로, 본 모델은 국내 자생 및 생태계교란 거북 8종에 대해 높은 실용적 분류 성능을 보였으며, 향후 모바일 기기에 탑재·배포함으로써 생태계교란종의 조기 탐지 및 신속 대응 체계 구축에 기여할 것으로 기대된다.

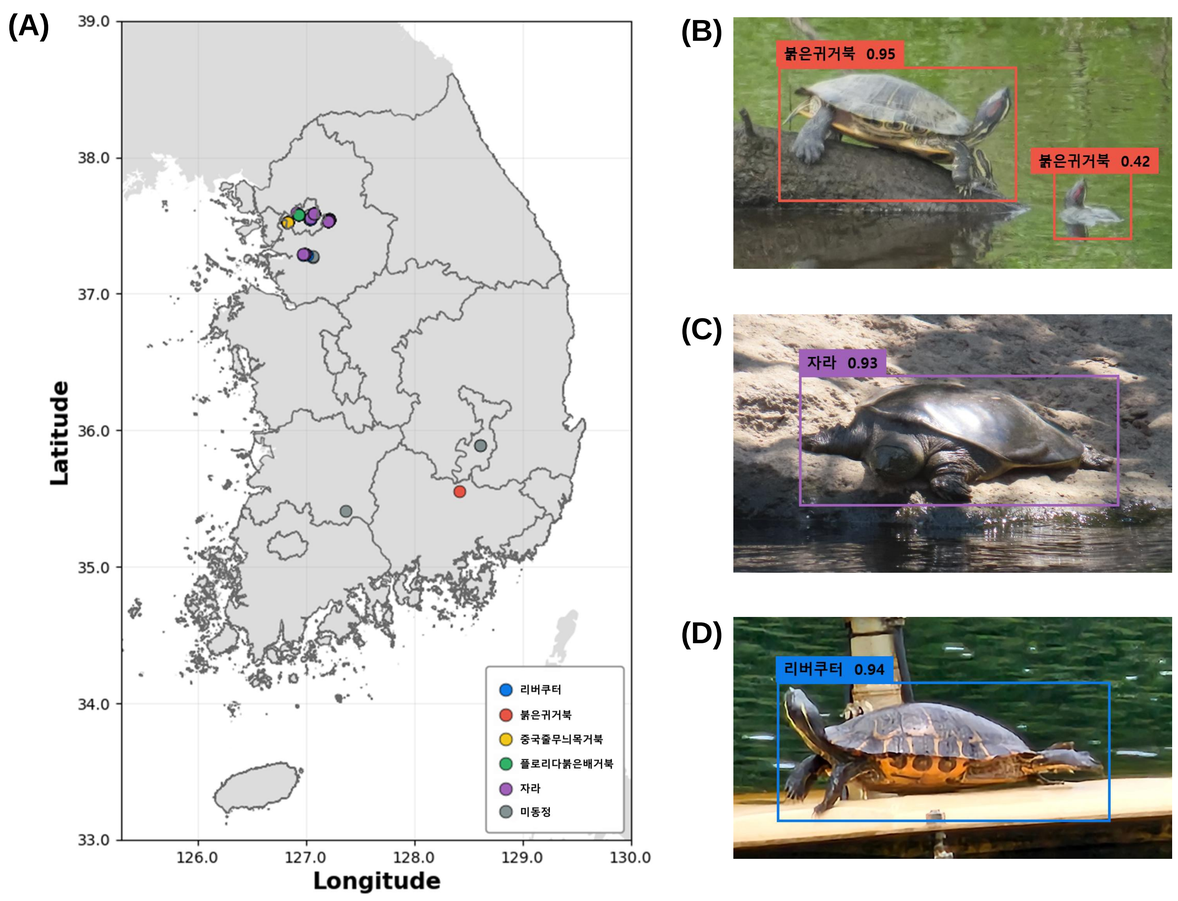


그림 4. 개발된 모델을 활용한 시민과학자 이미지 분류 결과. (A) 시민과학자에 의해 수집된 이미지의 종 정보 및 위치 분포; (B) 동정된 붉은귀거북의 분류 결과; (C) 동정된 자라의 분류 결과; (D) 미동정 개체의 분류 결과. 예측된 종명 옆의 숫자는 해당 종으로 분류한 모델의 신뢰도(confidence score)를 나타낸다.

Acknowledgments

본 연구는 숲과나눔 장학생 지원을 받아 연구를 진행하고 있습니다. 현장 적용성 평가에 동아사이언스 지구사랑탐사대의 리버쉘[시민과학풀씨4기] 팀의 위치 데이터와 이미지가 사용되었습니다. 이원재 팀장님, 임형제가족팀, 과학초보팀, 넓적이를 찾아서 팀의 기여에 감사드립니다.

References

Baek, J. W., Kim, J. I., & Kim, C. B. (2023). Deep learning-based image classification of turtles imported into Korea. Scientific Reports, 13(1), 21677.

Brussaard, L., De Ruiter, P. C., & Brown, G. G. (2007). Soil biodiversity for agricultural sustainability. Agriculture, Ecosystems & Environment, 121(3), 233–244.

Charette, R. (1999). CITES identification guide – Turtles & tortoises. Blue section "Introduction"-8, Yellow section "Introduction"-60. Environment Canada.

Havel, J. E., Kovalenko, K. E., Thomaz, S. M., Amalfitano, S., & Kats, L. B. (2015). Aquatic invasive species: Challenges for the future. Hydrobiologia, 750, 147–170.

Kim, J. I., Baek, J. W., & Kim, C. B. (2022). Image classification of Amazon parrots by deep learning: A potentially useful tool for wildlife conservation. Biology, 11(9), 1303.

Pimm, S. L., et al. (2014). The biodiversity of species and their rates of extinction, distribution, and protection. Science, 344(6187), 1246752.

Ricciardi, A. (2007). Are modern biological invasions an unprecedented form of global change? Conservation Biology, 21, 329–336.

Spinks, P. Q., Pauly, G. B., Crayon, J. J., & Shaffer, H. B. (2003). Survival of the western pond turtle (Emys marmorata) in an urban California environment. Conservation Biology, 113, 257–267.

Suzuki-Ohno, Y., et al. (2022). Deep learning increases the availability of organism photographs taken by citizens in citizen science programs. Scientific Reports, 12(1), 1210.

Isa, I. S., Rosli, M. S. A., Yusof, U. K., Maruzuki, M. I. F., & Sulaiman, S. N. (2022). Optimizing the hyperparameter tuning of YOLOv5 for underwater detection. Ieee Access, 10, 52818-52831.

Ye, J., Wu, Y., & Peng, D. (2024). Low-quality image object detection based on reinforcement learning adaptive enhancement. Pattern Recognition Letters, 182, 67–75.

Zhang, C., et al. (2023). Greater physiological resistance to heat may favour an invasive freshwater turtle, enabling it to outcompete native species in a changing climate. Freshwater Biology, 68(9), 1588–1601.