

농업분야 인공지능 모델의 활용성 향상을 위한 AI 모델의 상호호환성 관리 방안 연구[☆]

Study on the method for interoperability of AI model to improve usability of artificial intelligence models in agricultural field

엄정호¹ 김주섭² 정환석^{3*}
Jung-Ho Um Juseop Kim Hwan Suk Cheong

요약

인공지능 기술이 발전하면서 이를 농업에 적용하기 위한 다양한 연구가 활발히 진행되고 있다. 국내에서는 인공지능 기술 연구를 위한 AI 훈련 데이터 세트가 구축되고 있다. 농·축산업 등 다양한 분야의 데이터 셋은 AI 허브 사이트를 통해 게시되고 있다. 하지만 AI 모델의 경우 다양한 인공지능 학습 프레임워크에서 개발될 수 있기 때문에, AI 모델을 제공하는 측면에서 프레임워크 간 상호호환성이 고려되면 더 많은 이용자가 AI 모델을 활용할 수 있다. 본 논문에서는 이를 위해, 시스템에 필요한 요구사항을 도출하고 각 컴포넌트 간 상호호환성을 위해 개방형 뉴럴 네트워크 표현 형식인 ONNX를 활용하였다. 또한 제안하는 방안의 타당성에 대한 입증을 위해 가지 질병 분류 모델을 전이학습을 통해 총 4가지 모델에 대해 학습을 진행했으며, 최고 99%의 정확도를 가지는 모델을 구축하고 이를 ONNX로 변환하여 기존 모델과 성능에 차이가 없음을 확인하였다. 향후 연구로 본 논문에서 검증한 모델 공유 방법을 데이터 플랫폼에 적용할 수 있는 방안을 연구할 예정이다.

☞ 주제어 : 농업 데이터, 인공지능, ONNX, 상호호환성, 데이터 서비스

ABSTRACT

With the development of artificial intelligence technology, various studies are being actively conducted to apply it to agriculture. In South Korea, AI training datasets are being produced for research on artificial intelligence technology. In various fields, including the agricultural and livestock sectors, datasets are posted through the site AI HUB. However, since AI models can be developed in multiple artificial intelligence learning frameworks, more things can interfere with the AI model as framework compatibility is considered in terms of serving the AI model. For system design, we derive requirements and propose the overall structure of the system. In addition, we show examples of the feasibility of implementing each component. To verify the feasibility of the proposed method, we trained a total of four eggplant disease classification models through transfer learning. We built a model with the best accuracy of 99% and converted it to ONNX, confirming that there was no difference in performance compared to the existing model. In future research, we plan to apply the model-sharing method verified in this paper to a data platform.

☞ keyword : agricultural data, Artificial Intelligence, ONNX, interoperability, Data service

1. 서론

인공지능 분석 연구는 농업 분야에서도 다양한 측면

에서 진행되고 있다[1][2][3]. V. Meshram et al. [3]에 따르면, 농업 분야 AI 분석 연구의 선행 연구에서 사용된 인공지능 분석 방법은 수확 전(파종), 수확, 수확 후(저장) 단계로 분류된다. 우리나라 또한 농·축산업 분야 AI 연구 활성화를 위해 2020년부터 농업 분야 AI 학습 데이터 세트를 연속하여 구축해 오고 있다. 농축산분야에서의 인공지능 분석을 위해 구축된 훈련 데이터 세트는 AI 허브 사이트를 통해 서비스되고 있다. AI 허브에는 총 71개의 데이터 세트가 구축되고 있으며, 각 데이터 세트는 수십만에서 최대 백만 건의 학습용 이미지로 구성되어 있다. 이처럼 농업 분야의 인공지능 연구를 지원하기 위해 수많은 훈련 데이터 세트가 구축되고 있다. 하지만, AI 모

1 DataON Development Team, Korea Institute of Science and Technology Information., Daejeon, 34141, Korea.

2 Department of Library and Information Science, Jeonbuk National University., Jeon-ju, 54896, Korea.

3 Rural Development Administration, Jeon-ju, 54875, Korea.

* Corresponding author (xpertstone@korea.kr)

[Received 04 June 2024, Reviewed 20 June 2024(R2 09 August 2024), Accepted 02 September 2024]

☆ 본 논문은 농촌진흥청 연구사업(과제번호: RS-2022-RD010352 (PJ0170742022))의 지원에 의해 이루어진 것임.

텔은 PyTorch, Tensorflow 등 다양한 AI 개발 플랫폼에서 개발될 수 있으며, AI 모델을 활용하는 시스템 또한 서로 다른 플랫폼을 사용할 수 있다. 따라서, 더 많은 다양한 AI 모델을 제공하기 위해서는 이러한 상호호환성을 고려해야 한다. 이러한 문제를 극복하기 위해서 Open Neural Network Exchange(ONNX)라는 개방형 인공지능 상호 호환 모델이 제안되었다[4]. ONNX를 통하면 서로 다른 플랫폼에서 AI 모델을 개발했는지라도 활용 측면에서는 동일한 표준화된 모델을 제공받을 수 있는 장점이 있다. 본 논문에서는 농축산분야에서 구축되는 인공지능 데이터 세트와 모델들을 분석하고, 이러한 개방형 인공지능 모델을 제공하는 플랫폼을 설계하여 ONNX 변환 및 제공 가능 여부에 대한 구현 가능성을 확인해 보고자 한다. 제안하는 시스템의 장점은 다음과 같다. 훈련과 추론에 사용되는 플랫폼 간의 상호호환성을 제공하기 위해 모델을 개방형 신경망 형식인 ONNX로 변환하고, 다양한 개발자 그룹이 AI 모델을 자유롭게 활용할 수 있도록 개방형 신경망 형식으로 ONNX를 제공함으로써 AI 기술개발에 기여 가능하다. 아울러 농축산분야 인공지능 학습용 데이터 세트의 활용도 및 재사용성 향상에도 기여 가능하다. 따라서 본 논문에서는 기존 농·축산업 분야에서 진행한 인공지능 연구 및 모델을 파악하고, 이를 토대로 인공지능 모델의 상호호환성 관리를 위해, 모델의 변환 및 저장 관리하는 시스템 구조를 설계한다. 아울러, 설계한 시스템 구조가 학습 데이터 세트로부터 다른 인공지능 학습 프레임워크와 공유할 수 있고, 추론 시스템에도 적용할 수 있는 상호호환성 포맷으로 변환할 수 있는지와 성능에 문제가 없는지를 3.3절의 평가를 통해 확인한다.

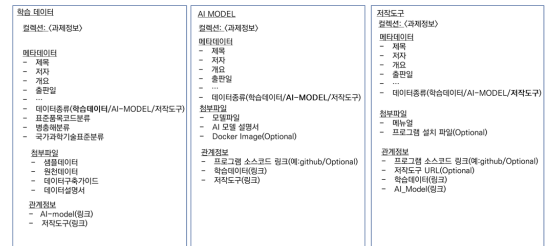
2. 관련 연구

Meshram, V.et al. [3]에서는 농업 분야에서 활용되는 인공지능 연구를 크게 수확 전(파종), 수확, 수확 후(저장)의 3단계로 나누어 데이터 속성을 분석하였다. 수확 전(파종) 단계에서는 토양, 종자 품질, 비료/농약 살포, 가지 치기, 품종 선택, 유전 및 환경 조건, 관개, 작물 부하, 잡초 탐지, 질병 탐지 속성과 관련된 데이터 분석이 필요하다. 수확 단계에서는 과일/작물 크기, 피부색, 단단함, 맛, 품질, 성숙 단계, 마켓 윈도우, 과일 감지 및 분류와 관련된 데이터 분석이 필요하다. 마지막으로 수확 후(즉, 저장) 단계에서는 품질 유지에 위한 온도, 습도, 과일 용기에 사용되는 가스, 수확 후 화학물질 사용 및 과일 취급 과정 등 과일 유통기한에 영향을 미치는 요인에 대한 데

이터 분석이 필요하다.

2021년 AI 허브에 구축 및 공개된 훈련용 농축산 데이터 세트는 다음과 같다. 먼저 농업 분야에서는 작물의 성장, 질병 및 품질을 결정하기 위해 구축된 데이터 세트가 존재한다. 축산분야에서는 소, 돼지, 곤충 사육을 위해 성장 단계별 음성 데이터와 질병 판별을 위한 동작 인식 데이터 세트를 구축하였다. 이 밖에도 드론 촬영을 통한 농지 인식, 농기계 내 잡초 인식 데이터 세트, 독초 감별 데이터 세트도 구축됐다. 데이터의 크기가 매우 크기 때문에 데이터를 활용하려면 수 TB의 공간이 필요하다. 이렇게 큰 용량은 일반 사용자가 쉽게 접근하기 어려운 부분들이 있어, 상호 호환 가능 인공지능 모델로 변환하여, 제공한다면 관련 데이터 분석에서의 활용도를 높일 수 있는 측면이 있다.

한편, J. Um et al. [5]에서는 농업 AI 학습 데이터 세트를 저장하고 공유하기 위한 시스템을 설계하였다. 농업 AI 학습 데이터 세트와 AI 분석에 활용되는 소프트웨어, 그리고 AI 모델을 저장 관리 단위로 하며, 각 저장 객체마다 상호 연결할 수 있는 연관 관계 추가 기능을 통해 데이터의 중복 저장을 예방한다. 그림 1에서는 AI 학습 데이터 세트와 관련 자원을 저장 관리하기 위한 전체 시스템 구조에 대한 개념도를 보여준다.



(그림 1) AI 학습 데이터 세트 관리 시스템의 데이터 구조 (Figure 1) Data Structure of an AI training dataset management system


J. Um et al. [6]에서는 그림 1에서 표현된 설계 구조를 구체화하여 인공지능 학습 데이터 세트, 소프트웨어, 인공지능 모델을 저장하기 위한 메타데이터 구조를 설계하였다. 이같이 설계하여 구현된 시스템은 [7]에서와 같이 운영되고 있다.

본 논문에서는 [5][6]에서 설계 및 구현된 시스템[7]을 확장하여, 인공지능 모델의 상호호환성을 관리하고자 한다.

또한, 인공지능 모델의 상호 호환 포맷 관련하여, ONNX[4]는 인공지능 분야에서 딥러닝과 기계 학습 모델의 호환성과 재활용을 위해 개방형 신경망 형식으로 제안되었다. ONNX는 PyTorch, Tensorflow, MXNet, Caffe 등 다양한 딥러닝 프레임워크에서 모델 호환성을 위해 채택되어 사용되고 있다. 아래의 표 1에서는 ONNX에서 제공하는 딥러닝 프레임워크의 종류를 보여준다.

(표 1) ONNX 변환 제공 인공지능 학습 프레임워크
(Table 1) Artificial intelligent frameworks supporting converting to ONNX

인공지능 학습 프레임워크	
Caffe	MATLAB
Caffe2	ML.NET
Chainer	MXNet (Apache)
Cognitive Toolkit (CNTK)	PyTorch
CoreML (Apple)	SciKit-Learn
Keras	SINGA (Apache)-Github(experimental)
LibSVM	TensorFlow
LightGBM	



(그림 2) MXNET 다중모델 서버의 추론 예제
(Figure 2) An example of inference of MXNET multi model server

인공지능 모델의 추론은 인공지능 기술 활용에 있어 중요한 부분 중 하나이다. ONNX 형식으로 변환된 AI 모델은 다음과 같은 추론 기능을 제공하는 프레임워크에서 활용될 수 있다. 대표적인 프레임워크로는 NVIDIA의 Triton[8]과 MXNET 다중모델 서버[9]가 있다. 해당 프레임워크는 추론 결과를 JSON의 출력 형식을 지니는 REST API 서버를 제공하고 있어, 웹 서비스와 인공지능 추론 결과를 연동할 수 있다. 그림 2는 MXNET 다중모델 서버를 활용하여 이미지의 객체 판별 예제를 보여준다. 예시에서 다중모델 서버는 하나의 사진 파일로부터 추론 결과를 입력으로 반환한다.

3. 농업 AI 모델의 상호호환성 관리 방안

3.1. 요구사항 분석

농업 AI 모델 서비스 시스템을 설계하기 위해 먼저, AI 허브 사이트에서 게시하고 있는 21년도에 구축한 농업 분야 인공지능 학습 데이터 세트별로 활용할 수 있는 인공지능 모델을 파악하였다. 21년도 이전에 구축한 데이터 세트는 활용하는 인공지능 모델에 대한 구체적인 정보가 없었기 때문에, 21년도에 구축된 데이터 세트를 파악하였다. 상세 정보는 표 2와 같다.

(표 2) AI 허브 인공지능 학습 데이터 세트와 모델 종류
(Table 2) Artificial intelligence data set and models in AI HUB

번호	데이터 세트명칭	학습용 모델
1	고품질 과수작물 통합 데이터	ResNet50(10), VGG16(11), DenseNet161(12)
2	제주 주요작물 자동탐지	Xception(13)
3	지능형 스마트축사 통합 데이터(양돈)	Mask R-CNN(14) YOLO(15)
4	동의보감 독초판별이미지	Metric Learning
5	지능형 수직농장 통합 데이터 (엽채류)	Yolov5(15) :생육계측
6	지능형 수직농장 통합 데이터 (딸기)	CNN-LSTM(16) :생산량 예측
7	지능형 스마트 축사 데이터(육계, 산란계)	객체검출: DetectoRS(17) 행동인식: PoseC3D(18)
8	지능형 스마트 축사 (젖소) 데이터	성체카포인트검출: HRNet(19) 음성인식: CNN(20)
9	지능형 곤충 사육 데이터	Mask R-CNN(14)
10	지능형 스마트 축사 통합 데이터(한우)	Mask R-CNN(14), YOLO(15)
11	한우 신체측실자수 등급 데이터	ResNet(10)
12	지능형 스마트팜통합 데이터(파프리카)	환경분석/예측: LSTM(RNN) (21) 객체감지 : YOLOv5(22)
13	지능형 스마트팜통합 데이터(토마토)	
14	정밀농업 농기계 절초 인식 데이터	Mask R-CNN(14)
15	정밀농업 농기계 자율주행	YOLOv4(23)
16	식물 병 유발 통합 데이터	ResNet50(10)
17	식·의약품 자생식물 분석	DenseNet121(12)
18	정밀농업 노지작물 통합 데이터	Mask R-CNN(14)
19	작물 디지털 파노타이핑	YOLOCAT, Mask R-CNN(14)
20	전북 장수 사과 당도 품질 데이터	Mask R-CNN(14)
21	지능형 스마트팜통합 데이터(버섯)	Yolo v4(23), Yolo-v3-tiny(24)

AI 허브에서 구축한 인공지능 학습 데이터 세트는 주로 작물의 생육, 질병, 품질, 또는 논, 밭은 재배 면적 등에 관한 인공지능 학습을 위한 데이터 세트를 구축하고 있으며, 데이터 분석을 위해 활용한 인공지능 모델은 주로 이미지 분류, 객체 탐지, 시계열 분석 모델이 활용되었다. 이를 모델별로 요약하면 표 3과 같다.

(표 3) AI 허브에서의 인공지능 학습 모델별 분류
(Table 3) Classification of artificial intelligence models in AI HUB

Deep Learning Model	Problem type
ResNet50 [10]	Image Classification
VGG16 [11]	Image Classification
DenseNet161 [12]	Image Classification
Xception (eXtream Inception) [13]	Image Classification
Mask R-CNN [14]	Object detection
Metric Learning	Object recognition
YOLO [15]	Object detection
CNN-LSTM [16]	Time series Prediction
DetectorS [17]	Object detection
PoseC3D [18]	Action recognition
HRNet [19]	Object detection
CNN [20]	Speech recognition
LSTM [21]	Time series Prediction

V. Meshram et al.[3]의 연구에서는 농사 시기별로 필요한 인공지능 모델을 분류했으며, 이는 표 4와 같다. 표에서 볼 수 있듯이 주요 대상 모델은 분류와 객체 감지이다.

AI 허브와 V. Meshram et al.의 연구에서 분류한 인공지능 모델의 종류를 파악해 보면, 이미지에 대한 분류, 이미지에서의 객체 탐지 모델이 대부분을 차지한다. 인공지능 모델의 상호호환성 관리를 위해 ONNX가 다양한 종류의 인공지능 모델을 지원하지만, 앞의 인공지능 모델 비교에서 봤듯이 이미지의 객체 판별 모델이 대다수를 차지하고 있기에, 본 논문에서는 본 장의 3.3절에서 가지 질병의 이미지 분류 모델의 ONNX 변환 및 호환성 평가를 통해, 가지 이미지에 대한 질병 식별 데이터 세트를 인공지능 모델로 학습 및 상호 호환 가능 모델로 변환하여, 모델 변환 이후의 성능 또한 측정하여 이전과 비교한다.


3.2. 인공지능 모델의 상호호환성 관리 방안

제안하는 인공지능 모델의 상호호환성 관리를 위해 설계하는 방안에서는 크게 두 가지 목적이 있다. 첫째, 다양

(표 4) 농업 시기별 필요한 인공지능 모델의 분류
(Table 4) Classification of artificial intelligence models required by agricultural season

Growing Phase	Property	AI Models
Pre-harvesting	Soil	ELM, LS-SVM, Neural Network with Auto-regressive error function (AREF)
	Seed	GoogleNet, CNN, multilayer perceptron and binary logistic regression, DeepSort
	Pesticides and disease detection	PlantDiseaseNet, GoogLeNet CNN, ResNet50 model and SVM classifier, AlexNet Precursor, Fuzzy Rule-Based Approach for Disease Detection (FRADD)
Harvesting	Real-Time Fruit Detection within tree	YOLO
	Fruit classification	VGG-16
	Outdoor Fruit Detection	Combined model with Feature PyramidNetworks, Residual Neural Networks and RetinaNet
	Date Fruit Classification	VGG-16
Post-harvesting	Fruit harvesting robot	YOLO
	discrimination and grading in tomatoes	SVM, decision tree, random forest
	classification of banana (Musa acuminata)	Artificial Neural Network (ANN), SVM
	Automatic apple sorting system	K-means, decision tree
	Date fruit grading	back propagation neural network

한 인공지능 학습 프레임워크로부터 생성된 학습 모델을 ONNX로 변환하여 상호 호환 가능 포맷으로 사용자에게 제공한다. 둘째, ONNX 모델을 활용하여 모델 서빙 또는



(그림 3) 농업용 AI 모델 상호호환성 관리 시스템의 전체 아키텍처

(Figure 3) Overall system architecture of management for interoperability of agricultural AI models

모델 추론 시스템에 연결함으로써 사용자가 인공지능 모델의 결과를 바로 확인할 수 있도록 지원한다. 그림 3은 이러한 시스템의 목적을 고려한 전체 시스템 구조를 보여준다. 먼저 첫 번째 목적을 만족하기 위해, 크게 두 가지의 인공지능 학습 모델 저장 방법을 고려한다. 첫 번째는 시스템 내부에 이미 적재된 인공지능 학습 데이터 세트를 활용하여 인공지능 모델을 직접 학습하는 경우이다. 해당하는 부분에서는 시스템에서 관리되는 데이터 세트는 크게 학습용 데이터 세트와 검증용 데이터 세트로 분류될 수 있으며, 학습용 데이터 세트를 활용하여 학습을 수행할 수 있다. 주로 이미지 데이터 분류에 대한 학습은 기존 개발된 AI 모델로부터 단말 노드만을 재학습하는 전이 학습 기법을 주로 활용하며, 전이 학습을 통해 생성된 모델은 향후, ONNX로 변환될 수 있다. 생성된 모델은 시스템에 저장되어 관리된다. 두 번째로, 사용자가 인공지능 모델을 직접 업로드하는 경우이다. 인공지능 분석을 위해서는 다양한 딥러닝 프레임워크가 존재하고, 이를 기반으로 다양한 모델을 생성하게 될 것이다. ONNX는 2장에서 소개한 바와 같이 잘 활용되고 있는 인공지능 학습 프레임워크를 지원한다. 따라서, 사용자는 농축산업분야 연구를 위한 AI 모델 업로드 시, 프레임워크 종류를 입력하며, 시스템에서는 해당 변환 라이브러리를 ONNX에서 호출하여 ONNX로 변환 및 적재한다. 만일 ONNX가 지원하지 않는 프레임워크라면 ONNX 변환 라이브러리를 사용자가 직접 개발할 수 있다.

마지막으로, 사용자가 인공지능 모델을 추론하는 부분에 대해서는, ONNX로 변환된 모델을 활용하여 모델 추론/서빙 시스템을 호출하여 지원한다. 예를 들어, MXNET의 Multi-Model Server와 같은 시스템을 통해 결과를 웹 서비스에 제공할 수 있다. 예측값은 JSON 파일 형태로 제공되며, 그 결과는 Restful API 방식으로 전달된다. 즉,

ONNX를 import 하여 모델 결과를 추론할 수 있으므로 이러한 서빙 시스템을 설치하여 확장함으로써 사용자가 모델을 직접 실행할 수 있도록 지원하는 구조로 인공지능 모델의 상호호환성 관리 방안을 제안한다.

3.3. 가지 질병의 이미지 분류 모델의 ONNX 변환 및 호환성 평가

제안한 관리 방안의 실제 동작 가능성을 검증하기 위해, 가지 질병을 지닌 이미지를 분류하는 데이터 세트[25]를 활용하여 표 3에서 분류한 모델 중 이미지 분류 모델에 해당하는 Resnet50, VGG16, DenseNet, Xception 모델을 대상으로 전이 학습을 통해 해당 데이터 세트의 가지 질병 유무를 판단하는 모델을 구축한다. 아울러, 모델별로 ONNX 변환 시 판별 성능 저하가 없는지를 확인한다. DenseNet161은 Pre-trained model의 제공에 제약이 있어 DenseNet121[12]를 대체 활용하였다. Xception 또한 마찬가지로 Pre-trained model을 제공하지 않아 Inception V3 모델[26]을 활용하였다. AI 허브에 구축된 가지 질병 데이터 세트는 가지잎곰팡이병 및 가지흰가루병의 두 질병을 분류하지만, 본 연구에서는 인공지능 모델의 학습 및 변환 과정을 확인하기 위한 목적으로 수행하였기에, 질병의 유무만을 판단하는 두 가지 카테고리 분류하는 학습 모델로 단순화하여 진행하였다. 본 연구에서는 해당 데이터 세트 중에서 학습을 위해 3,600개의 이미지를 임의 추출하여 학습을 수행하였으며, 검증을 위해 400개의 이미지를 임의 추출하였다. 인공지능 모델 구축을 위해 pytorch 1.10.1, CUDA 10.2를 활용하였으며, 하드웨어는 DataON Canvas[27]에서 제공하는 컨테이너 기반의 가상 주피터 환경을 활용하였다. 해당 환경은 Intel(R) Xeon(R) Gold 6136 CPU @ 3.00GHz의 6 core CPU와 16GB 메모리, 500GB의 디스크로 구성된다. 4개의 학습 모델에서 공통으로 학습률(learning rate)은 0.01, Optimizer는 SGD로 설정하였다. 그리고 10개의 에포크(epoch)로 훈련하였다. 배치 크기는 8, worker의 개수는 4개, 이미지 크기는 3(RGB 채널값)*244*244로 입력한다. Inception V3는 커널의 크기가 5*5이지만, 기존 세 가지 모델에서는 3*3이다. 해당 커널의 크기로 인해 입력 이미지 크기는 3*299*299로 하고 메모리 할당 문제로 배치 크기를 4개로 줄였다.

가지 질병 이미지 분류를 위한 학습 및 ONNX 모델의 변환 과정은 그림 4와 같다. 먼저 학습용 데이터 세트에서 표본 추출하여, 질병 및 정상 상태의 이미지를 확인했다. 두 번째로, ONNX로의 변환 성능 확인을 위해 Pre-trained

된 총 4개의 이미지 분류 인공지능 모델을 활용하여 모델마다 전이 학습을 수행했으며, 학습 데이터 세트에 대하여 추론을 실행하여 예측 결과를 확인하였다. 그림에서는 네 개의 모델 중 Inception V3를 통해 모델의 예측값과 해당 이미지를 세 번째 단계에서 보여준다. 마지막으로, 구축된 모델은 ONNX로 변환하고, 변환된 ONNX 모델에 대하여 학습 데이터 세트에서 ONNX 런타임을 활용하여 추론을 진행함으로써, 기존 성능과 동일함을 비교하였다. 그림의 하단 부분의 네 번째 단계에서는 Inception V3에 대해 ONNX로 변환하여 얻어진 모델의 구조도를 보여준다.




(그림 4) 가지 질병 분류 모델 구축 및 ONNX 변환 예시
(Figure 4) Example for creating a model of detecting eggplant disease and converting ONNX model


모델마다 학습을 진행하였으며, 해당 평가는 구축된 모델의 ONNX 변환 후, 성능이 동일함을 확인하는 목적이기 때문에 에포크를 많이 설정하지 않았다. 또한, 전이 학습의 특성상, 해당 데이터 세트를 학습할 때 평균 95% 이상의 높은 정확도를 지니고 있어, 많은 에포크를 실행하지 않았다. 학습용 데이터 세트는 8:2 비율로 학습과 검증 데이터 세트를 나누었으며, Inception V3를 제외한 나머지 모델에서는 검증 정확도 100%를 달성했다.

Inception V3에서는 마지막 에포크에서 99.75%를 달성했다. Inception V3의 성능 차이는 미세하지만, 커널의 크기와 입력 이미지 크기의 변화 등 다른 모델과 입력 데이터 처리의 차이가 있기 때문에 판단된다. 그림 5는 에포크 별로 각 모델에서 측정된 학습 데이터 세트에 대한 정확도를 보여준다. 세 가지 인공지능 모델에서는 99%를, Inception V3는 90%의 정확도를 달성했다. 그림 6은 학습 소요 시간을 보여준다. 그림에서와 같이, 평균 30분 정도의 학습 시간이 소요되었으며, 네 가지 모델 중에서는 DenseNet이 학습 속도도 빠르고, 정확도도 다른 모델에 비해 0.3% 정도 높다. 모든 모델은 ONNX로 변환되고, 변환된 모델은 ONNX Runtime 실행을 통해 기존 모델과 동일한 가지 질병 진단 데이터 세트 중에서 학습 데이터 세트를 활용하여 정확도를 측정하였다. 측정 결과 그림 7과 같이 4개의 모든 인공지능 모델의 성능과 ONNX로 변환 후 모델에서도 동일한 정확도 성능을 보인다.


즉, 가지 질병 진단 모델 구축 및 ONNX 변환 후, 성능 비교 등을 통해, 인공지능 학습 또는 추론 서비스 시스템에 활용될 수 있는 ONNX 모델의 변환이 성공적으로 작동하고, 성능이 기존 모델과 동일함을 확인하였다.



(그림 5) 가지 질병 분류 학습 성능 비교
(Figure 5) Comparison of models for detecting eggplant disease



(그림 6) 가지 질병 전이 학습 시간 비교
(Figure 6) Comparison of transfer learning time for detecting eggplant disease



(그림 7) ONNX 변환 성능 비교

(Figure 7) Comparison of converting ONNX models for detecting eggplant disease

4. 결 론

본 논문에서는 인공지능 데이터 분석 연구를 수행하는 연구자 또는 개발자가 서로 다른 인공지능 분석 환경에서도 학습을 통해 생성된 학습 모델을 기반으로 연구를 수행할 수 있도록 상호 호환할 수 있는 인공지능 모델 개방 포맷인 ONNX를 지원하고, 이를 관리하는 방안을 제시하였다. 아울러, 제시한 방안이 실제로 동작하는지를 판단하기 위해, 실제 인공지능 학습 프레임워크인 pytorch에 설계한 방안을 실제 데이터 세트에 적용하여 ONNX 포맷으로의 변환 및 정확도 성능 측정을 ResNet, DenseNet, Inception V3 그리고 VGG16 이미지 분류 모델을 통해 검증하였다. 성능 비교 결과, 해당 가지 질병 진단 모델 구축 사례에서는 약 99% 정확도를 가지는 가지 질병 이미지 분류 모델이 구축되었으며, ONNX로 변환하여도 성능이 잘 유지됨을 확인하였다. 향후 연구로는, 본 논문에서 설계 및 사례 연구를 통해 검증한 시스템 구조를 웹 서비스 형태로 개발하는 것이다. 또한, 사례 연구에서는 주로 이미지 분류 모델을 확인하였지만, 인공지능 데이터 분석은 분류 모델뿐만 아니라 객체 검출, LSTM 등 시계열 예측 분석모델 등 다양한 형태의 분석이 존재하기 때문에 이에 대한 적용 및 검증을 진행할 예정이다.

참고문헌(Reference)

[1] J. Zha, "Artificial Intelligence in Agriculture," Journal of Physics: Conference Series, Vol. 1693, 012058, 2020. <https://doi.org/10.1088/1742-6596/1693/1/012058>
 [2] E. Elbasi, N. Mostafa, Z. AlArnaout, A. I. Zreikat, E.

Cina, G. Varghese, A. Shdefat, A. E. Topcu, W. Abdelbaki, S.Mathew, and C. Zaki, "Artificial Intelligence Technology in the Agricultural Sector: A Systematic Literature Review," IEEE Access, Vol. 11, pp.171-202, 2023.

<https://doi.org/10.1109/ACCESS.2022.3232485>

[3] V. Meshram, K. Patil, V.Meshram, D. Hanchate, and S. D. Ramkteke, "Machine learning in agriculture domain: A state-of-art survey," Artificial Intelligence in the Life Sciences, Vol. 1, 2021.

<https://doi.org/10.1016/j.aills.2021.100010>.

[4] <https://github.com/onnx/onnx>, 2023.11.27.

[5] J. Um, M. Hwang and Youngho Shin, "A Study on Development of Artificial Intelligence Big Data Storing and Sharing System in Agricultural Science," Korea Contents Association General Conference Proceedings, pp.175-176, 2022.

[6] J. Um, Mi. Hwang, Y. Shin, J. Kim, S. Kim, Y. Jo, and H. S. Cheong, "Design and Implementation of Platform for Managing Artificial Intelligent Training DataSet in Agriculture and LiveStock," 2023 KSII FALL Conference, Vol. 24, No 2, pp.351-352, 2023.

[7] <https://www.rdaidata.kr/>, 2023.11.27.

[8] M. Morales-Hernández, M. B. Sharif, A. Kalyanapu, S. K. Ghafoor, T. T. Dullo, S. Gangrade, S. Kao, M.R. Norman, and K. J. Evans, "TRITON: A Multi-GPU open source 2D hydrodynamic flood model," Environmental Modelling & Software, Vol. 141, 2021. <https://doi.org/10.1016/j.envsoft.2021.105034>

[9] <https://github.com/aws-labs/multi-model-server>, 2023.11.27.

[10] K. He, X. Zhang, S. Ren and J. Sun, "Deep residual learning for image recognition," IEEE Conference on Computer Vision and Pattern Recognition, pp.770 - 778, 2016.

https://openaccess.thecvf.com/content_cvpr_2016/html/He_Deep_Residual_Learning_CVPR_2016_paper.html

[11] K. Simonyan and A. Zisserman, "Very deep convolutional networks for large-scale image recognition," CoRR abs/1409.1556, <http://arxiv.org/abs/1409.1556>, 2014.

[12] G. Huang, Z. Liu, L. Van Der Maaten and K. Q. Weinberger, "Densely connected convolutional networks,"

- IEEE conference on computer vision and pattern recognition, pp.4700-4708, 2017.
- [13] F. Chollet, "Xception: Deep learning with depthwise separable convolutions," IEEE conference on computer vision and pattern recognition, pp.1251-1258, 2017.
https://openaccess.thecvf.com/content_cvpr_2017/html/Chollet_Xception_Deep_Learning_CVPR_2017_paper.html
- [14] K. He, G. Gkioxari, P. Dollár, and R. Girshick, "Mask r-cnn," IEEE international conference on computer vision, pp.2961-2969, 2017.
https://openaccess.thecvf.com/content_iccv_2017/html/He_Mask_R-CNN_ICCV_2017_paper.html
- [15] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You only look once: Unified, real-time object detection," IEEE Conference on Computer Vision and Pattern Recognition, pp.779-788, 2016.
https://www.cv-foundation.org/openaccess/content_cvpr_2016/html/Redmon_You_Only_Look_CVPR_2016_paper.html
- [16] S. Vosoughi, P. Vijayaraghavan and D. Roy "Tweet2Vec: learning Tweet embeddings using character-level CNN-LSTM encoder-decoder," The 39th International ACM SIGIR Conference on Research and Development in Information Retrieval, pp.1041-1044, 2016.
<https://doi.org/10.1145/2911451.2914762>
- [17] S. Qiao, L. C. Chen and A. Yuille, "Detectors: Detecting objects with recursive feature pyramid and switchable atrous convolution," IEEE/CVF conference on computer vision and pattern recognition, pp.10213-10224, 2021.
https://openaccess.thecvf.com/content/CVPR2021/html/Qiao_DetectorRS_Detecting_Objects_With_Recursive_Feature_Pyramid_and_Switchable_Atrous_CVPR_2021_paper.html
- [18] H. Duan, Y. Zhao, K. Chen, D. Lin and B. Dai, "Revisiting skeleton-based action recognition," IEEE/CVF Conference on Computer Vision and Pattern Recognition, pp.2969-2978, 2022.
https://openaccess.thecvf.com/content/CVPR2022/html/Duan_Revisiting_Skeleton-Based_Action_Recognition_CVPR_2022_paper.html
- [19] C. Yu, B. Xiao, C. Gao, L. Yuan, L. Zhang, N. Sang, and J. Wang, "Lite-hmet: A lightweight high-resolution network," IEEE/CVF conference on computer vision and pattern recognition, pp.10440-10450, 2021.
- [20] A. Karpathy, G. Toderici, S. Shetty, T. Leung, R. Sukthankar and L. Fei-Fei, "Largescale video classification with convolutional neural networks," IEEE Conference on Computer Vision and Pattern Recognition, pp.1725-1732, 2014.
https://www.cv-foundation.org/openaccess/content_cvpr_2014/html/Karpathy_Large-scale_Video_Classification_2014_CVPR_paper.html
- [21] X. Li and X. Wu, "Constructing long short-term memory based deep recurrent neural networks for large vocabulary speech recognition," IEEE International Conference on Acoustics, Speech and Signal Processing, pp.4520-4524, 2015.
<https://doi.org/10.1109/ICASSP.2015.7178826>
- [22] <https://github.com/ultralytics/yolov5>, 2023.11.27.
- [23] Bochkovskiy, Alexey, Chien-Yao Wang, and Hong-Yuan Mark Liao, "Yolov4: Optimal speed and accuracy of object detection," arXiv preprint arXiv:2004.10934, 2020.
<https://doi.org/10.48550/arXiv.2004.10934>
- [24] P. Adarsh, P. Rathi and M. Kumar, "YOLO v3-Tiny: Object Detection and Recognition using one stage improved model," 6th International Conference on Advanced Computing and Communication Systems (ICACCS), Coimbatore, India, pp.687-694, 2020.
<https://doi.org/10.1109/ICACCS48705.2020.9074315>
- [25] <https://www.aihub.or.kr/aihubdata/data/view.do?currMenu=115&topMenu=100&aihubDataSe=data&dataSetSn=153>, 2023.11.27.
- [26] C. Szegedy, V. Vanhoucke, S. Ioffe, J. Shlens and Z. Wojna, "Rethinking the Inception Architecture for Computer Vision," IEEE conference on computer vision and pattern recognition, pp. 2818-2826, 2016.
https://www.cv-foundation.org/openaccess/content_cvpr_2016/html/Szegedy_Rethinking_the_Inception_CVPR_2016_paper.html
- [27] <https://https://dataon.kisti.re.kr/canvas/intro.do>, 2024.08.09.

● 저 자 소 개 ●



엄 정 호(Jung-Ho Um)

2011년 전북대학교 컴퓨터공학과(공학박사)

2011년~현재 한국과학기술정보연구원 책임연구원

관심분야 : 데이터베이스, 빅데이터, 인공지능, 연구데이터 etc.

E-mail : jhum@kisti.re.kr



김 주 섭(Juseop Kim)

2020년 전북대학교 문헌정보학과(문헌정보학 박사)

2022년~현재 전북대학교 부설 연구데이터 융복합연구소 전임연구원

관심분야 : 연구데이터, 메타데이터, 영구식별자

E-mail : kimjuseop@jbnu.ac.kr



정 환 석(Hwan Suk Cheong)

2017년 전남대학교 정보보안학과 (이학박사)

2019년 7월~현재 농촌진흥청 전산사무관(데이터관리)

관심분야 : 빅데이터, AI, (개인)정보보호, 스마트팜, 스마트시티, etc.

E-mail : xpertstone@korea.kr / xpertstone@hanmail.net