

# 반려동물용 자동 사료급식기의 비용효율적 사료 중량 예측을 위한 딥러닝 방법

김희정  
경희대학교 빅데이터응용학과  
(dunhill741@khu.ac.kr)

전예진  
경희대학교 경영학과  
(dunhill741@khu.ac.kr)

이승현  
경희대학교 경영학과  
(dunhill741@khu.ac.kr)

권오병  
경희대학교 경영학과  
(obkwon@khu.ac.kr)

최근 IoT 기술의 발달로 외출 중에도 반려동물에 급여하도록 자동 사료급식기가 유통되고 있다. 그러나 자동급식에서 중요한 중량을 측정하는 저울 방식은 쉽게 고장이 나고, 3D카메라 방식은 비용이 든다는 단점이 있으며, 2D카메라 방식은 중량 측정의 정확도가 떨어진다. 특히 사료가 복합된 경우 중량 측정 문제는 더욱 어려워질 수 있다. 따라서 본 연구의 목적은 2D카메라를 사용하면서도 중량을 정확하게 추정할 수 있는 딥러닝 접근법을 제안하는 것이다. 이를 위해 다양한 합성곱 신경망을 이용하였으며, 그중 ResNet101 기반 모델이 3.06 gram의 평균 절대 오차와 3.40%의 평균 절대비 오차를 기록하며 가장 우수한 성능을 보였다. 본 연구의 결과로 사료와 같이 규격화된 물체의 중량을 확보가 용이한 2D 이미지를 통해서만 예측할 필요가 있을 경우 유용한 정보로 활용될 수 있다.

**주제어** : 사료급식기, 컴퓨터 비전, 중량 예측, 딥러닝, 합성곱 신경망

논문접수일 : 2022년 3월 7일    논문수정일 : 2022년 3월 22일    게재확정일 : 2022년 3월 23일  
원고유형 : Regular Track    교신저자 : 권오병

## 1. 서론

비대면 경제의 활성화와 함께 반려동물을 위한 소비가 증가하고 있다. 동시에 반려동물의 건강 관리에 대한 관심과 함께 펫테크(Pet Tech) 제품에 대한 수요 또한 커지고 있다(American Pet Products Association, 2021; Wadhvani & Gankar, 2021). 펫테크는 반려동물(Pet)과 기술(Tech)의 합성어로, 반려동물을 케어 할 수 있도록 도움을

주는 다양한 IT기술을 말한다(Shin & Kim, 2020). 그 중 자동 사료급식기는 정해진 시간에 일정한 양의 사료를 반려동물에게 자동으로 지급하는 것을 목적으로 하는 기기이다. 적정량의 사료를 지급하는 것은 반려동물의 건강 관리를 위해 중요하다(Kienzle et al., 1998). 하지만 현재 시중에 유통중인 자동 사료급식기 중 정확하게 사료의 중량을 측정해 지급하는 기능이 탑재된 제품은 존재하지 않는다. 대부분의 자동 사료급

\* 이 논문은 2022년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2022-0-00904, 다품종 소량 비건육 사료 생산 스마트팩토리 기반 구축 및 비대면 큐레이팅 중개 시스템 구축 개발). 본 논문은 연구재단 4단계 BK21 사업으로부터 지원받은 연구임.

식기가 사료의 양을 조절하는 방법은 부피로 일회배식량을 설정한 뒤 사료가 배식되는 횟수를 조절해 전체 배식량을 조절하는 방식이다. 앞서 언급한 문제를 해결하기 위해 사료 용기 밑에 로드셀(Loadcell)을 달아 사료의 중량을 측정해 배식을 조절하는 방법이 제시되었으나(Koley et al., 2021), 해당 방식은 추가적인 센서가 필요하고 반려동물이 사료를 먹을 때 사료 용기와 접촉하기 때문에 반려동물의 행동으로 센서에 고장이 발생할 가능성이 존재한다. 이에 대한 대안으로 집 외부에서도 반려동물을 관찰할 수 있도록 개발된 IoT 자동 사료급식기에 있는 카메라를 활용해 중량을 측정하는 방법을 검토할 수 있다.

이미지를 통한 중량 예측은 2D 이미지를 활용하는 방법과 3D 이미지를 활용하는 방법으로 구분할 수 있다. 3D 이미지를 활용하는 방법은 2D 이미지에 비해 많은 정보를 활용할 수 있어서 높은 정확도로 중량을 추정할 수 있지만(Cominotte et al., 2020; Song et al., 2018; Mortensen et al., 2016), 중량 측정을 위해서 자동 사료급식기에 3D 카메라를 설치하는 것은 비용과 효율성을 고려한다면 현실적인 대안이 아니다. 반면 2D 카메라가 장착된 자동 사료급식기는 이미 개발되어 판매되고 있기 때문에 2D 이미지를 이용해 사료의 중량을 측정하는 방안은 검토할 가치가 있다. 이에 따라 본 연구에서는 사료의 2D 이미지를 딥러닝 알고리즘으로 분석해 중량을 측정하는 방안을 제시하고 실현가능성을 검토하려고 한다. 특히 딥러닝 알고리즘 중 합성곱 신경망을 이용한 방안에 대해 중점적으로 탐구한다.

본 연구에서 개발한 모델의 성능을 평가하기 위한 지표로 평균 절대 오차와 평균 절대비 오차를 사용한다. 개발한 모델들을 평가한 결과 모든 모델에서 4 gram 미만의 평균 절대 오차와 5%

미만의 평균 절대비 오차를 기록했다. 그 중에서 ResNet101 기반 모델이 3.06 gram의 평균 절대 오차와 3.40%의 평균 절대비 오차를 기록하며 가장 우수한 성능을 보였다.

본 논문의 구성은 다음과 같다. 제2장에서는 자동 사료급식기, 시각적 정보를 이용한 중량 예측, 합성곱 신경망에 대해 살펴보고, 제3장에서는 전체적인 연구 방법에 대해 기술한다. 제4장에서는 모델 평가 과정에서 수집된 데이터를 분석해 연구 결과를 제시한다. 그리고 제5장에서는 본 연구의 시사점 및 한계점, 그리고 미래연구방향에 대해서 기술한다.

## 2. 선행 연구

### 2.1. 자동 사료급식기

반려동물의 건강 문제는 잘못된 식습관에서 기인하는 경우가 많기 때문에 적절한 양의 사료를 지급하는 것은 반려동물 건강 관리를 위해 중요하다(Kienzle et al., 1998). 반려동물의 건강 관리에 대한 수요 증가와 IoT 기술의 발전으로 반려동물의 건강을 고려한 자동 사료급식기와 관련해 다양한 아이디어가 제시됐다 (<Figure 1> 참고). Arduino Mega based PET Feeding Automation (Babu et al., 2019)은 집 외부에서도 모바일 기기를 이용해 반려동물의 식사를 관리할 수 있도록 IoT 기술을 접목시킨 자동 사료급식기에 대해 제안했다. Automated Pet Feeder using IoT (Vrishanka et al., 2021)은 기존 IoT 자동 사료급식기에 거리 측정 센서와 서보 모터(Servo Motor)를 이용해 사료의 양을 대략적으로 측정하고 배식을 제어할 수 있는 기능을 추가하는 방



〈Figure 1〉 Automatic IoT Pet Feeders Equipped with a Camera

안에 대해 제시했다. Smart Pet Feeder(Koley et al., 2021)는 사료 용기 밑에 로드셀을 달아 지급된 사료의 중량을 측정해 배식을 제어하는 방안  
에 대해 제시했다. Koley et al. (2021)가 제시한  
방안은 배식된 사료의 중량을 정확하게 측정할  
수 있으나, 센서가 달린 사료 용기와 반려동물의  
직접적인 접촉이 사료 섭취 시 지속적으로 발생  
하기 때문에 반려동물의 행동으로 로드셀 센서  
에 고장이 발생할 가능성이 존재한다고 가정할  
수 있다. 따라서 반려동물과 직접적인 접촉 빈도  
가 낮은 카메라를 이용해 사료의 중량을 예측하  
는 방안에 대한 연구의 필요성이 존재한다.

## 2.2. 시각적 정보를 이용한 중량 예측

컴퓨터 비전(Computer Vision) 및 딥러닝 기술  
의 발전으로 전통적인 중량 측정 방법에서 탈피  
해 시각적 정보를 이용한 중량 측정 방식이 연구  
되고 있다(Buayai et al., 2019). 특히 가축의 중량  
은 건강 상태 및 매매 시기와 직결되는 중요한  
사항이기 때문에 가축의 중량을 추정하기 위해  
컴퓨터 비전을 이용하는 방법에 대한 연구가 이  
미지를 이용한 중량 예측 연구의 주를 이룬다

(Cominotte et al., 2020; Gjergji et al., 2020;  
Kashiha et al., 2014; Mortensen et al., 2016; Song  
et al., 2018). 가축 외에도 컴퓨터 비전을 이용해  
물고기, 음식에 대한 중량 예측이 시도된 적 있  
다(Subhi et al., 2018; Fernandes et al., 2020).

시각적 정보를 이용한 중량 예측은 3D 이미지  
를 이용하는 방식과 2D 이미지를 이용하는 방식  
으로 구분할 수 있다. 일부 연구에서 3D 이미지  
에서 추출된 특징이 중량과 높은 상관관계를 보  
이는 것으로 나타났다(Cominotte et al., 2020;  
Mortensen et al., 2016; Song et al., 2018). 2D 이  
미지를 이용한 중량 예측은 3D 공간의 물체가  
2D 공간에 표현되면서 정보 손실이 발생하기 때  
문에 비교적 힘든 일이다. 하지만, 최근 딥러닝  
기술의 발전에 힘입어 2D 이미지를 통해 개체  
(Entity)의 중량을 예측하는 방법이 연구되고 있  
다. Fernandes et al.(2020)은 딥러닝 기반 이미지  
분할(Image Segmentation) 기법을 이용해 2D 이  
미지 속 어류의 특징을 추출하고 추출한 특징을  
변수로 이용해 만든 선형 회귀 모형으로 중량을  
예측하는 방법을 연구했다. Gjergji et al. (2020)  
은 별도의 이미지 분할없이 top-view에서 수집한


소의 2D 이미지와 합성곱 신경망을 이용해 중량을 예측하는 방법에 대해 연구했다. 중량 예측에 앞서 이미지 내에서 중량 측정 대상이 되는 개체를 이미지에서 분할하는 것은 별개의 어려운 문제다. 따라서, Gjergji et al. (2020)의 연구와 같이 중량 예측 대상에 대한 이미지 분할 과정을 생략한다면 모델의 전체 훈련 시간 및 예측에 소요되는 시간이 단축시킬 수 있다는 이점이 있다. 단, 이러한 기존 연구는 단일 객체에 대한 이미지 기반 중량 측정으로서 다중 객체에 대한 연구는 수행하지 않았다.

### 3. 연구방법

#### 3.1. 데이터 수집

사료의 종류와 상관없이 중량을 예측할 수 있는 모델을 만들기 위해 시중에 유통 중인 사료 중 10 종의 사료를 이미지 데이터셋을 구축하기 위해 선택했다. 한 종류의 사료만 있는 단일사료 10 종과 서로 다른 2 종의 사료를 50 대 50의 비율로 섞은 혼합사료 10 종으로 사료 이미지 데이터셋을 구성했다. 사료 이미지는 2021년 7월 24

〈Table 1〉 List of Feeds

Name	Producer	Sample Image
Scottish Salmon	Canagan	
Grain Free New Zealand Lamb	Wishbone	
Grain Free Chicken Formula	Natural Balance	
Healthy Skin	Nutrena	
Recipe for Small Breed Adult Dogs	Now	
Free-run Duck	Acana	
Poodle Adult	Royal Canin	
ECO 1 Organic Lamb	Natural Core	
Healthy 6 years old +	Nutrena	
Bene M32	Natural Core	

〈Table 2〉 Image Dataset Composition

Category	Number of Images	Total Number of Images
Single feed	2,800	5,880
Mixed feed	2,800	
Non-feed	280	



〈Figure 2〉 Data Collection Process and Examples of The Collected Feed Images.

일부터 8월 10일에 걸쳐 수집되었으며, Figure 2에서 보는 바와 같이 SM-A530N의 카메라를 이용해 3264 x 1836의 해상도로 사진을 촬영했다. 사료급식기에서 촬영되는 것과 유사한 구도에서 사진을 촬영하기 위해 거치대를 사용해 촬영 각도를 설정했다. 시간에 따른 조도 변화를 고려하기 위해 조명 장치로 이미지의 밝기를 조절해 다양한 밝기의 이미지를 수집할 수 있도록 했다. 사료 이미지를 촬영할 때 10 gram부터 200 gram까지 10 gram 단위마다 14 장의 이미지를 수집했다(예: <Table 1>). 결과적으로 각 종마다 280장의 이미지를 수집해 총 5,600장의 사료 이미지 데이터셋을 구축했으며, 그 예는 <Table 2>와 같다. 사료가 아닌 물체를 모델이 구분할 수 있도록 사료가 아닌 이미지로 빈 사료 용기, 개, 고양이

이, 빈 사료 용기와 개 또는 고양이가 같이 존재하는 이미지를 280장 수집했다. 사료가 아닌 이미지의 중량은 모두 0 gram으로 설정했다.

### 3.2. 이미지 전처리 및 증강

수집한 이미지는 각 모델의 입력 규격에 맞는 사이즈로 리사이징 하고 평균 0.5, 표준편차 0.5의 값으로 픽셀 값을 정규화(Normalize)했다. 모델 훈련 시 다양한 이미지를 학습할 수 있도록 무작위 수평 반전(Random Horizontal Flip), 밝기 조정(Brightness Adjustment), 무작위 회전(Random Rotation)과 같은 이미지 증강(Image Augmentation) 기법을 적용했다. 검증 및 평가 단계에서는 이미지 증강 기법을 적용하지 않았다.

### 3.3. 모델 구조


본 연구에서는 합성곱 신경망 모델을 고려했다. 합성곱 신경망 모델에 의한 이미지 판별은 의학분야 (LeCun et al., 2015; Rajpurkar et al., 2017; Razzaki et al., 2018), 생물학분야(Pyo et al., 2019; Xue et al., 2016; Zhou et al., 2016), 비즈니스분야(Seo, 2018) 에서도 인간의 능력을 능가하는 등 우수한 성능을 보이고 있다. 앞서 언급한 이유들을 근거로 연속적인 값인 중량을 예측하는 문제에 대해서도 합성곱 신경망을 사용한 모델이 좋은 성능을 보일 것이라고 기대하였다.

모델은 기능적으로 두 부분으로 나눌 수 있다. 첫번째 부분은 이미지 특징을 추출하기 위해 합성곱 신경망으로 구성된 특징 추출 네트워크 (Feature Extraction Network)이고, 두번째 부분은 추출된 특징을 바탕으로 이미지 속 사료의 중량을 예측하는 완전연결층(Fully Connected Layer) 기반의 중량 예측 네트워크(Weight Prediction Network)이다.

이미지 특징을 추출하기 위한 합성곱 신경망 모델로 EfficientNet과 ResNet을 사용했다. EfficientNet은 합성곱 신경망의 성능에 영향을 미치는 요소인 합성곱 신경망의 필터의 수, 레이어의 수, 입력 이미지의 화질을 조화롭게 스케일링 할 수 있는 compounding scaling method를 적용한 합성곱 신경망이다(Tan et al., 2019). ResNet은 잔차 학습(Residual Learning)을 통해 깊은 신경망에서도 훈련이 효율적으로 수행될 수 있도록 설계된 합성곱 신경망이다(He et al., 2015). 본 연구에서 두 모델을 사용한 이유는 다음과 같다. 첫째, PyTorch 프레임워크를 통해 쉽게 사용할 수 있다. 모델 개발을 위한 프레임워크로 PyTorch를 사용했기 때문에 복잡한 과정 없이 모델에 통합

할 수 있는 합성곱 신경망 모델들이 우선적으로 고려됐다. 둘째, 파라미터 수가 다른 여러 버전의 모델이 존재한다. EfficientNet은 파라미터 수에 따라 EfficientNetB0부터 EfficientNetB7까지 8개의 모델이 존재하며, ResNet은 ResNet18부터 ResNet152까지 5개의 모델이 존재한다. 따라서, 파라미터의 수가 모델의 성능에 미치는 영향을 관찰할 수 있다. 셋째, 이미지 분류 문제에서 두 모델 모두 파라미터 수 대비 훌륭한 성능을 기록했다(He et al., 2015; Tan et al., 2019). 주어진 파라미터를 효율적으로 활용해 이미지를 높은 수준의 정확도로 분류하는 데 성공했기 때문에 다른 문제 또한 효율적인 방법으로 효과적으로 해결할 수 있을 것이라 가정했다.

중량 예측 네트워크는 두 개의 완전연결층으로 구성되어 있다. 모델의 과적합을 방지하기 위해서 특징 추출 네트워크와 중량 예측 네트워크 사이에서 드롭아웃(Dropout)을 적용했다(Srivastava et al., 2014). 비선형성(Nonlinearity)을 부여하기 위해 첫번째 완전연결층과 두번째 완전연결층 사이에 ReLu 활성화 함수를 적용했으며, 모델이 최종 중량을 음으로 예측하는 것을 방지하기 위해 중량 예측 네트워크의 출력값에 다시 ReLu 활성화함수를 적용했다. 단, 중량값을 -1 ~ 1 사이의 값으로 표준화한다면 Sigmoid 활성화함수를 활용하는 것도 가능할 수 있겠으나, Sigmoid 활성화 함수는 함수의 출력값에 상한이 있어서 추후 실험에 사용된 이미지보다 더 높은 중량의 사료를 포함하고 있는 이미지를 모델의 입력으로 사용할 경우 중량 예측이 제대로 이루어지지 않을 가능성이 있다고 판단했기 때문에 ReLu를 사용했다. 전체 모델의 구조는 <Figure 3>을 통해 확인할 수 있다.



〈Figure 3〉 Model Architecture

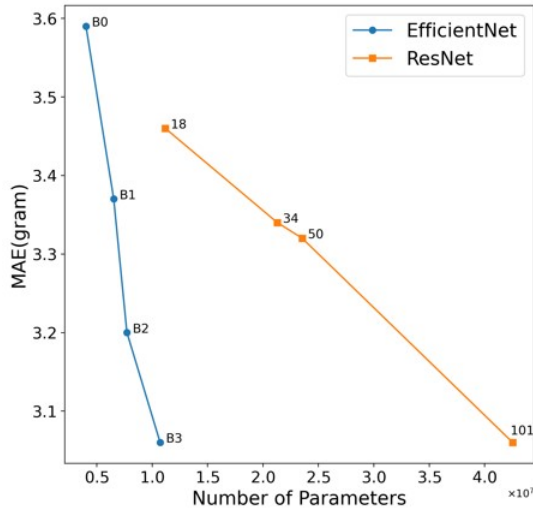
### 3.4. 모델 훈련, 검증, 평가

계층별 5겹 교차 검증 기법(Stratified 5-fold Cross Validation)을 이용해 모델의 훈련과 검증, 그리고 평가를 실시했다. 각 겹마다 500 회(Epoch)의 훈련과 검증을 수행한 뒤 평가를 실시한다. 이는 RMSE loss값이 평균적으로 400 epoch 이후 성능의 큰 개선이 없는 것을 확인했기 때문이다. 또한 훈련과 검증 시 사용되는 데이터의 배치(Batch) 사이즈는 32로 설정했으며


모델 훈련을 위한 손실 함수(Loss Function) 및 검증 지표로 평균 제곱근 오차(Root Mean Square Error)를 사용했다. 이때 배치 사이즈를 32로 설정한 이유는 다양한 사이즈의 이미지에 대해 gpu 메모리 문제를 발생시키지 않는 공통적인 최대값이었기 때문이었다. 한편, 평균 제곱근 오차를 손실 함수로 사용하는 이유는 평균 제곱 오차보다 작은 규모의 손실값을 계산해 학습 과정에서 기울기 폭주(Gradient Exploding)가 발생할 가능성을 낮추면서 오차가 클수록 모델에 더 많은 패널티를 부과하기 위함이다. 검증 단계에서 가장 낮은 평균 제곱근 오차를 달성한 모델의 파라미터를 평가에 사용했다. 평가에 사용하는 데이터셋은 배치 사이즈가 1이란 점을 제외하면 검증에 사용하는 데이터셋과 동일하다.

모델 평가를 위한 지표로 평균 절대 오차와 평균 절대비 오차를 사용했다. 모델의 성능을 평가하기 위해 전체 평가 데이터셋에 대한 평균 절대 오차와 평균 절대비 오차, 사료 혼합 여부에 따른 평균 절대 오차와 평균 절대비 오차, 사료 중량 별 평균 절대 오차와 평균 절대비 오차를 측정했다. 평균 절대비 오차로 모델의 성능을 추가적으로 평가하는 이유는 사료 중량 별 오차의 상대적인 크기를 고려해 모델을 평가하기 위함이다. 모델의 최종 평가 점수는 각 겹마다 측정된 평가 점수의 평균으로 측정한다. 파라미터 수의 변화에 따른 모델 성능의 변화는 <Figure 4>를 통해 확인할 수 있다.





(a) Mean Absolute Error



(b) Mean Absolute Percentage Error

〈Figure 4〉 Performance by Number of Parameters

〈Table 3〉 Model Performances

Model	Number of Parameters (m)	MAE(g)	MAPE(%)
EfficientNetB0	4.03	3.59 ± 0.12	4.61 ± 0.16
EfficientNetB1	6.53	3.37 ± 0.32	4.27 ± 0.42
EfficientNetB2	7.72	3.20 ± 0.22	3.90 ± 0.36
EfficientNetB3	10.72	3.06 ± 0.28	3.86 ± 0.62
ResNet18	11.18	3.46 ± 0.06	3.91 ± 0.12
ResNet34	21.29	3.34 ± 0.09	3.76 ± 0.18
ResNet50	23.54	3.32 ± 0.08	3.66 ± 0.12
ResNet101	<b>42.54</b>	<b>3.06 ± 0.06</b>	<b>3.40 ± 0.11</b>

## 4. 연구 결과

### 4.1. 중량 예측 성능

모델을 평가한 결과 <Table 3>에서 보인 대로 EfficientNet과 ResNet을 기반으로 한 모델 모두

4 gram 미만의 평균 절대 오차와 5% 미만의 평균 절대비 오차를 기록했다. 그 중에서 ResNet101 기반 모델이 가장 낮은 평균 절대 오차인 3.06 gram과 가장 낮은 평균 절대비 오차인 3.40%를 기록했다. 이 수준은 자동 사료급식기 제작 업체에서 상용화 가능 수준으로 인정하는



〈Table 4〉 Model Performances on Single Feed and Mixed Feed

Model	Single		Mixed		t(p)	
	MAE(g)	MAPE(%)	MAE(g)	MAPE(%)	MAE(g)	MAPE(%)
EfficientNetB0	3.80 ± 0.14	4.76 ± 0.24	3.72 ± 0.13	4.45 ± 0.18	0.80(.446)	1.80(.113)
EfficientNetB1	3.53 ± 0.30	4.35 ± 0.44	3.53 ± 0.39	4.19 ± 0.46	0.03(.979)	0.44(.674)
EfficientNetB2	3.45 ± 0.24	4.05 ± 0.36	3.26 ± 0.25	3.74 ± 0.39	0.92(.384)	1.01(.344)
EfficientNetB3	3.24 ± 0.27	3.91 ± 0.66	3.18 ± 0.31	3.91 ± 0.66	0.23(.827)	0.21(.839)
ResNet18	3.46 ± 0.06	3.91 ± 0.12	3.28 ± 0.05	3.67 ± 0.12	3.96(.004)**	2.45(.040)*
ResNet34	3.34 ± 0.09	3.76 ± 0.18	3.26 ± 0.13	3.63 ± 0.16	0.94(.380)	0.92(.383)
ResNet50	3.32 ± 0.08	3.66 ± 0.12	3.15 ± 0.05	3.51 ± 0.15	3.34(.013)*	1.37(.210)
ResNet101	3.31 ± 0.13	3.52 ± 0.14	3.10 ± 0.08	3.29 ± 0.11	2.41(.049) *	2.26(.055)

$p^* < 0.05$ ,  $p^{**} < 0.01$

수준이어서 의미 있는 성과가 도출되었다고 볼 수 있다.

한편, 두 기반 모델 모두 파라미터 수가 증가할수록 오차가 감소했으나 감소치가 크진 않았다. 평균 절대 오차로 모델을 평가했을 때 EfficientNet 기반 모델이 ResNet 기반 모델보다 파라미터 수 대비 우수한 성능을 보였다. 평균 절대비 오차로 평가했을 때는 기반 모델에 상관 없이 모델 파라미터 수에 반비례해 오차가 지속적으로 낮아지는 것을 확인할 수 있었다.


#### 4.2. 단일 사료와 혼합 사료에 대한 예측 성능

단일 사료에 대한 중량 예측 성능과 혼합 사료에 대한 중량 예측 성능 간 차이가 있는지 확인하기 위한 평가를 수행했다. 평가 결과는 <Table 4>에서 보이는 대로 예상과 달리 모든 모델에서 혼합 사료에 대한 중량 예측 성능이 단일 사료에 대한 중량 예측 성능에 비해 통계적으로 유의한 차이가 없거나 일부 모델에서는 오히려 더 우수


(ResNet18)한 것으로 나타났다. 이로써 여러 사료가 혼합되는 경우라고 하더라도 본 연구에서 제안한 방법이 유효하며, 일반화가 가능하다는 결론을 얻었다.

#### 4.3. 중량 별 예측 성능

사료의 중량에 따라 모델의 중량 예측 성능에 편차가 있는지 확인하기 위해 사료 중량 별로 모델의 중량 예측 성능을 평가했다. 평가 결과 Figure 5에서 보이는 대로 EfficientNet과 ResNet 등 모든 모델에서 이미지 속 사료의 중량이 증가할수록 평균 절대 오차는 증가하고 평균 절대비 오차는 감소하는 경향을 발견할 수 있었다. 이미지 속 사료의 중량이 증가할수록 평균 절대 오차가 증가하는 현상은 깊이 정보의 부재로 인해 발생하는 것으로 현재는 가정하고 있다. 용기 내 사료의 중량이 무거울수록 사료 간 겹치는 정도가 증가하기 때문에 전체 사료 중 2D 공간에 투사되는 사료의 비율은 용기 내 사료의 중량과 반비례 관계를 가진다고 예상할 수 있다. 결과적으로




(a) EfficientNet-based Model




(b) ResNet-based Model

〈Figure 5〉 Performance Evaluation (Mean Absolute Error by Gram)



(a) EfficientNet-based Model



(b) ResNet-based Model

〈Figure 6〉 Performance Evaluation (Mean Absolute Percentage Error by Gram)

로 이미지 속 사료가 증가할수록 사료가 2D 공간에 투사될 때 손실되는 정보의 크기가 커질 것이라 예상할 수 있다. 그럼에도 불구하고 사료 중량이 늘어날수록 증가하는 정보 손실의 크기가 크지 않았기 때문에 평균 절대비 오차는 오히려 감소하는 경향을 나타낸 것으로 판단하고 있다. 한편, y 축의 값을 MAPE로 변경하여 중량의 변화에 따른 성과비교가 가능하게 시각화한 것을 Figure 6에 표시하였다.

## 5. 결론

### 5.1. 시사점

최근 코로나 19로 인한 비대면 소비 트렌드 확산과 함께 성장한 반려동물 시장은 반려동물이 과거 어느 때보다 인간에게 중요한 의미를 가지게 됐다는 것을 나타낸다(Deloitte Insights, 2021; American Pet Products Association, 2021). 따라서 현재는 인간과 반려동물의 웰빙을 함께 추구할 수 있는 기술의 개발이 중요한 때라고 말할 수

있다. 본 연구는 단순한 사료 배식기능 뿐 아니라 반려동물의 건강관리에 도움을 줄 수 있는 자동 사료급식기 기능을 제시하며 동물복지를 향상시키고자 했다.

본 연구의 주요 시사점은 세 가지로 요약할 수 있다. 첫째, 딥러닝 기술을 활용해 2D 이미지에 나타난 사료의 중량을 높은 수준의 정확도로 예측했다. 기존 연구인 Fernandes et al.(2020)와 Gjergji et al. (2020)에 비해 2D 이미지와 CNN 계열(CNN, EfficientNet)을 사용한 것은 동일하나 기존 연구들은 단일 단수 개체에 대한 이미지 인식 및 중량 측정이었다. 그에 비해 본 연구는 단일 다수 개체 및 다중 다수 개체의 이미지 판별 및 중량추정이라는 점이 다르며, 정확도도 상대적으로 높았다. 따라서 기존 사료 자동급식기에 해당 기술을 접목하는 방안에 대해 긍정적으로 검토해볼 수 있을 것이다. 딥러닝 기술이 각종 의사결정 문제에서 성과를 냄에 따라 (Lee et al., 2021), 본 연구의 결과는 다양한 농축산 의사결정에 도움이 될 것으로 기대한다. 둘째, 반려동물이 식사 이후에 남긴 사료의 양을 추정하기 위해서도 연구에서 사용된 모델을 활용할 수 있다. 반려동물의 식욕 저하와 같은 식습관 변화는 주요한 건강 이상 징후다(Malmanger, 2021). 반려동물이 먹고 남긴 사료의 양의 변화를 자동으로 기록한다면 식습관 변화에 대한 징후를 포착해 조기에 건강 문제를 해결할 가능성을 높일 수 있을 것이다. 본 연구의 마지막 시사점은 규격화된 개체의 중량 예측을 시도했다는 점이다. 딥러닝 기술과 2D 이미지를 이용해 중량 예측을 시도한 선행 연구는 생물을 대상으로 한 경우가 대부분이다. 하지만 생물에서 근육량 또는 체지방률과 같이 외관상으로 드러나지는 않지만 체중과 상관있는 요소들의 수치가 각 생물 개체 별로 상이

하다는 점은 이미지 상에 드러나는 생물의 중량과 관련한 정보의 편차를 발생시키기 때문에 중량 예측을 한층 더 어렵게 만든다. 반면 본 연구에서 사용된 사료는 제조공정을 거쳐 생산된 제품이기 때문에 동일 종류 개체 간 특성 차이는 미미한 수준이다. 따라서 중량에 대한 시각적 정보를 큰 편차 없이 2D 이미지 속에 나타냈을 것이기 때문에 본 연구의 결과는 제조공정과 같이 규격화된 개체를 다루는 과정 속에서 컴퓨터 비전을 이용한 중량 예측이 필요한 경우 참고될 수 있을 것이다.

## 5.2. 연구의 한계점 및 향후 연구 방향

본 연구는 2D 카메라라는 비용 효율적이면서 널리 보급된 기술과 합성곱 신경망 기반의 딥러닝 알고리즘을 활용해 이미지 속에 나타난 사료의 중량을 높은 정확도로 예측했다는 의의가 있으나 다음과 같은 한계점이 있어 추가적인 연구가 필요하다. 첫째, 사료의 레이블(Label) 정보로 모델 학습에 사용하지 않았다. 사료를 구성하는 원재료가 사료마다 다르기 때문에 각 사료의 비중량(specific weight)에 차이가 존재할 것이다. 사료 간 텍스처 차이를 통해 비중량과 관계된 정보를 간접적으로 학습했을 가능성이 존재하지만 (Geirhos et al., 2018), 명시적으로 사료의 레이블 정보를 제공하지 않았기 때문에 불완전한 학습이 이루어졌을 가능성이 높다. 따라서 보다 정확한 중량 예측을 위해 모델이 중량 정보와 더불어 사료 레이블 정보를 함께 학습할 필요가 있다. 둘째, 최선의 상황을 가정하고 모델을 학습시켰다. 실제 자동급식기를 사용하는 경우 반려동물의 행동으로 인해 배식된 사료가 용기 밖을 벗어나는 경우가 발생할 수 있다. 본 연구에서는 사

료가 용기 밖으로 벗어날 가능성은 배제하고 이미지를 수집하고 모델을 훈련했기 때문에 사료가 용기 밖으로 벗어난 경우 중량을 정확하게 예측하지 못할 가능성이 있다. Gjergji et al. (2020)의 연구 결과에 의하면 이미지 속에서 중량 측정 대상이 구분되지 않는 경우 모델의 중량 예측 성능이 감소하는 것으로 나타났다. 따라서 모델이 용기 안에 있는 사료와 용기 밖에 있는 사료를 구분할 수 있도록 하는 것은 예상가능한 돌발 상황에 대처하고 정확하게 중량을 예측하기 위해 중요하다. 향후에 객체 탐지(Object Detection) 알고리즘을 사용해 이미지 속에서 사료 용기 영역 안에 있는 사료에 대해서만 중량을 예측하는 방법에 대해 추가 연구할 예정이다.

## 참고문헌(References)

1. *Pet Industry Market Size, Trends Ownership Statistics*, American Pet Products Association, 2021. Available at [https://www.americanpetproducts.org/press\\_industrytrends.asp](https://www.americanpetproducts.org/press_industrytrends.asp) (Accessed 2022.03.02)
2. Babu, B. R., P.P Kumar., P.G Kuppusamy., "Arduino Mega based PET feeding automation", *IOSR Journal of Electronics and Communication Engineering*, Vol.14, No.4, (2019), 13-16
3. Buayai, P., P, Kullapapruk., L, Carson., K.R. Saikaew., "Semi-automatic pig weight estimation using digital image analysis", *Applied Engineering in Agriculture*, Vol. 35, No.4, (2019), 521-534
4. Cominotte, A., A. F. A, Fernandes., J. R. R, Dorea., G. J. M, Rosa., M. M, Ladeira., E. H. C. B, van Cleef., O. M, Neto., "Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases", *Livestock Science*, Vol.232, No.103904, (2020)
5. Dehais, J., M, Anthimopoulos., S, Shevchik., S, Mougiakakou., "Two-view 3D reconstruction for food volume estimation", *IEEE*, Vol.19, No.5, (2017), 1090-1099
6. Deloitte., "Consumption Trends Driven by COVID-19", *Deloitte Insights*, No.17, (2021), 50-54
7. Fernandes, A. F., E. M, Turra., É. R. de Alvarenga., T. L. Passafaro., F. B, Lopes., G. F, Alves., G. J, Rosa., "Deep Learning image segmentation for extraction of fish body measurements and prediction of body weight and carcass traits in Nile tilapia", *Computers and electronics in agriculture*, Vol. 170, No.105274, (2020)
8. Geirhos, R., P, Rubisch., C, Michaelis., M, Bethge., F. A, Wichmann., W, Brendel., "ImageNet-trained CNNs are biased towards texture; increasing shape bias improves accuracy and robustness", *arXiv preprint arXiv, 1811.12231*, (2018)
9. Gjergji, M., V, de Moraes Weber., L. O. C, Silva., R, da Costa Gomes., T. L. A. C, De Araújo., H, Pistori., M, Alvarez., "Deep learning techniques for beef cattle body weight prediction", *International Joint Conference on Neural Networks (IJCNN)*, (2020), 1-8
10. HosseinNia, S.H., I, Tejado., B.M, Vinagre., "Fractional-order reset control: Application to a servomotor", *Mechatronics*, Vol.23, No.7, (2013), 781-788
11. Jiang, M., G, Guo., "Body weight analysis

- from human body images”, *IEEE Transactions on Information Forensics and Security*, Vol.14, No.10, (2019), 2676-2688
12. Kashiha, M., C. Bahr., S. Ott., C. P. Moons., T. A. Niewold., F. O. Ödberg., D. Berckmans., “Automatic weight estimation of individual pigs using image analysis”, *Computers and Electronics in Agriculture*, Vol.107, (2014), 38-44
  13. Kienzle, E., R. Bergler., A. Mandernach., “A comparison of the feeding behavior and the human-animal relationship in owners of normal and obese dogs”, *The Journal of nutrition*, Vol.128, No.12, (1998), 2779S-2782S
  14. Koley, S., S. Srimani., D. Nandy., P. Pal., S. Biswas., I. Sarkar., “Smart Pet Feeder”, *In Journal of Physics: Conference Series*, Vol.1797, No.1, (2021), 12018
  15. Konovalov, D. A., A. Saleh., D. B. Efremova., J. A. Domingos., D. R. Jerry., “Automatic weight estimation of harvested fish from images”, *Digital Image Computing: Techniques and Applications(DICTA)*, (2019), 1-7
  16. Lee, M. S., H. Ahn, “A time series graph based convolutional neural network model for effective input variable pattern learning: Application to the prediction of stock market.” *Journal of Intelligence and Information Systems*, Vol. 24, No. 1, (2018) 167-181.
  17. Lee, J., Suh, B., Y. Kwon, “A Study on the impact of artificial intelligence on decision making: focusing on human-AI collaboration and decision-maker's personality trait.” *Journal of Intelligence and Information Systems*, Vol. 27, No. 3, (2021), 231-252.
  18. Liu, R., “Automatic Pet Feeder based on Single Chip Microcomputer”, *In Journal of Physics: Conference Series*, Vol. 2037, No. 1, (2021), 12104
  19. Malmanger, E., *Why Is My Dog Not Eating?*, PetMD, 2021, Available at <https://www.petmd.com/dog/symptoms/why-my-dog-not-eating> (Accessed 2022.03.02)
  20. Pouladzadeh, P., S. Shirmohammadi., R. Al-Maghrabi., “Measuring calorie and nutrition from food image”, *IEEE Trans. Instrum. Meas*, Vol.63, No.8, (2014), 1947-1956
  21. Puri, M., Z. Zhu., Q. Yu., A. Divakaran., H. Sawhney., “Recognition and volume estimation of food intake using a mobile device”, *Workshop on Applications of Computer Vision (WACV)*, (2009), 1-8
  22. Pyo, J., H. Duan., S. Baek., M.S. Kim., T. Jeon., Y.S. Kwon., K.H. Cho., “A convolutional neural network regression for quantifying cyanobacteria using hyperspectral imagery”, *Remote Sensing of Environment*, Vol.233, No. 111350, (2019)
  23. Rajpurkar, P., J. Irvin., K. Zhu., B. Yang., H. Mehta., T. Duan., A.Y. Ng., “Chexnet: Radiologist-level pneumonia detection on chest x-rays with deep learning”, *arXiv preprint arXiv, 1711.05225*, (2017)
  24. Razzaki, S., A. Baker., Y. Perov., K. Middleton., J. Baxter., D. Mullarkey., S. Johri., “A comparative study of artificial intelligence and human doctors for the purpose of triage and diagnosis”, *arXiv preprint arXiv, 1806.10698*,

- (2018)
25. Rahman, M.H., "Food volume estimation in a mobile phone based dietary assessment system", *Conf. on Signal Image Technology and Internet Based Systems (SITIS)*, (2012), 988-995
  26. Seo, Y., K.S. Shin, "Business application of convolutional neural networks for apparel classification using runway image.", *Journal of Intelligence and Information Systems*, Vol. 24, No. 3, (2018), 1-19.
  27. Srivastava, N., G. Hinton., A. Krizhevsky., I. Sutskever., R. Salakhutdinov., "Dropout: a simple way to prevent neural networks from overfitting", *The journal of machine learning research*, Vol.15, No.1, (2014), 1929-1958
  28. Shin, H., J. Kim., "A Study on the Development of Wearable Products Applied to PetTech Service Using IoT and AI Technolog", *The Journal of Korean Society of Design Culture*, Vol.26, No.1, (2020), 261-272
  29. Subhi, M. A., S. H. M, Ali., A. G, Ismail., M, Othman., "Food volume estimation based on stereo image analysis", *IEEE Instrumentation & Measurement Magazine*, Vol.21, No.6, (2018), 36-43
  30. Tessema, G.B., T.A, Worku., Z.B, Tessema., "Programmable Pet Feeder", *International Journal of Scientific Engineering and Research (IJSER)*, Vol.3, No.11, (2015), 99-104
  31. Vania, K. Karyono., I.H.T, Nugroho., "Smart dog feeder design using wireless communication, MQTT and Android client", *International Conference on Computer, Control, Informatics and its Applications (IC3INA)*, (2016), 191-196
  32. Wadhawani, P., S, Ganka., *Pet Tech Market*, Global Market Insights, 2021, Available at <https://www.gminsights.com/industry-analysis/pet-tech-market> (Accessed 2022.03.02)
  33. Xu, C., Y.K.N, He., A, Parra., C, Boushey., E, Delp., "Image-based food volume estimation", *5th Int. Workshop on Multimedia for Cooking and Eating Activities*, (2013), 75-80
  34. Zhu, F., M, Bosch., C.J, Boushey., E.J, Delp., "An image analysis system for dietary assessment and evaluation", *IEEE Int. Conf. on Image Processing*, (2010), 1853-1856
  35. Mortensen, A. K., P, Lisouski., P, Ahrendt., "Weight prediction of broiler chickens using 3D computer vision", *Computers and Electronics in Agriculture*, Vol.123, (2016), 319-326
  36. Song, X., E. A. M, Bokkers., P. P. J, van der Tol., P. G, Koerkamp., S, Van Mourik., "Automated body weight prediction of dairy cows using 3-dimensional vision", *Journal of Dairy Science*, Vol.101, No.5, (2018), 4448-4459
  37. Zhou, J., X, Hong., F, Su., G, Zhao., "Recurrent convolutional neural network regression for continuous pain intensity estimation in video", *IEEE conference on computer vision and pattern recognition workshops*, (2016), 84-92
  38. Xue, Y., N, Ray., J, Hugh., G, Bigras., "Cell counting by regression using convolutional neural network", *In European Conference on Computer Vision*, (2016), 274-290

Abstract

## A Deep Learning Method for Cost-Effective Feed Weight Prediction of Automatic Feeder for Companion Animals

Hoejung Kim\* · Yejin Jeon\*\* · Seunghyun Yi\*\* · Ohbyung Kwon\*\*\*

With the recent advent of IoT technology, automatic pet feeders are being distributed so that owners can feed their companion animals while they are out. However, due to behaviors of pets, the method of measuring weight, which is important in automatic feeding, can be easily damaged and broken when using the scale. The 3D camera method has disadvantages due to its cost, and the 2D camera method has relatively poor accuracy when compared to 3D camera method. Hence, the purpose of this study is to propose a deep learning approach that can accurately estimate weight while simply using a 2D camera. For this, various convolutional neural networks were used, and among them, the ResNet101-based model showed the best performance: an average absolute error of 3.06 grams and an average absolute ratio error of 3.40%, which could be used commercially in terms of technical and financial viability. The result of this study can be useful for the practitioners to predict the weight of a standardized object such as feed only through an easy 2D image.

**Key Words** : pet feeder, computer vision, weight prediction, deep learning, convolutional neural network

Received : March 7, 2022 Revised : March 22, 2022 Accepted : March 23, 2022

Corresponding Author : Ohbyung Kwon

---

\* Department of Big Data Analytics, Kyung Hee University

\*\* School of Management, Kyung Hee University

\*\*\* Corresponding author: Ohbyung Kwon

School of Management, Kyung Hee University

26 Kyungheedae-ro, Dongdaemun-gu, Seoul 02447, Korea

Tel: +82-2-961-2148, Fax: +82-2-961-0515, E-mail: obkwon@khu.ac.kr



## 저자 소개



**김희정**

현재 경희대학교 빅데이터응용학과 석사과정 재학 중이다. 경희대학교 경영학과에서 학사학위를 취득하였고, 주요 관심 분야는 Machine Learning in Finance, Computer Vision 등이다.



**전예진**

현재 경희대학교 경영학과 학사과정 재학 중이다. 주요 관심 분야는 Marketing, Data Analysis 등이다.



**이승현**

현재 경희대학교 경영학과 학사과정 재학 중이다. 주요 관심 분야는 Data Analysis, Machine Learning 등이다.



**권오병**

현재 경희대학교 경영학과 교수로 재직 중이다. 서울대학교 경영학과에서 학사학위를 한국과학기술원에서 석사 및 박사학위를 취득하였고, 카네기멜론대학 ISRI연구소에서 유비쿼터스 컴퓨팅 프로젝트를 수행한 바 있다. 관심분야는 텍스트 분석, AI비즈니스, 의사결정지원시스템 등이다.