

센서 모듈과 인공지능망을 활용한 실시간 반려견 행동 분석 및 케어 시스템

(Real-time Dog Behavior Analysis and Care System Using Sensor Module and Artificial Neural Network)

이 희 래¹⁾, 김 선 경²⁾, 이 형 규³⁾*

(Hee Rae Lee, Seon Gyeong Kim, and Hyung Gyu Lee)

요약 본 연구에서는 움직임 센서 모듈과 딥러닝을 활용하여 반려견의 행동을 실시간으로 인식하고 분석하는 방법을 제안한다. 일반적으로 반려견의 행동을 파악하는 홈 CCTV(Closed-Circuit Television)는 개인의 사생활 보호 문제와 보안 이슈가 있어 이를 극복하기 위한 새로운 기술의 필요성이 제기되고 있다. 본 논문에서는 움직임 센서에서 측정되는 데이터를 기반으로 반려견의 행동을 분석하고 케어할 수 있는 시스템을 제안한다. 본 연구에서는 MLP(Multi-Layer Perceptron)와 CNN(Convolutional Neural Network) 모델을 비교하여 반려견 행동 분석에 적합한 모델을 선정하고 최적화를 하였으며, 실험 결과, 제안된 MLP 모델은 평균 82.19%의 정확도를 보이는 것을 확인하였으며, 모델 경량화를 통해 임베디드 환경에서 효율적으로 활용될 수 있음을 확인하였다.

핵심주제어: 반려견 행동 분석, 딥러닝, 센서 모듈, 스마트폰 애플리케이션

Abstract In this study, we propose a method for real-time recognition and analysis of dog behavior using a motion sensor and deep learning technology. The existing home CCTV (Closed-Circuit Television) that recognizes dog behavior has privacy and security issues, so there is a need for new technologies to overcome them. In this paper, we propose a system that can analyze and care for a dog's behavior based on the data measured by the motion sensor. The study compares the MLP (Multi-Layer Perceptron) and CNN (Convolutional Neural Network) models to find the optimal model for dog behavior analysis, and the final model, which has an accuracy of about 82.19%, is selected. The model is lightened to confirm its potential for use in embedded environments.

Keywords: Dog behavior analysis, Deep learning, Sensor module, Smartphone application

* Corresponding Author: hglee@duksung.ac.kr

Manuscript received July 01, 2024 / revised August 21, 2024 / accepted August 21, 2024

1) 덕성여자대학교 소프트웨어전공, 제1저자
2) 덕성여자대학교 소프트웨어전공, 제2저자
3) 덕성여자대학교 소프트웨어전공, 교신저자

1. 서론

개인 건강에 대한 관심이 높아지면서 카메라 기반 영상 처리와 다양한 센서 모듈을 활용한 개인 건강 관리 지원을 위한 연구가 활발히 이

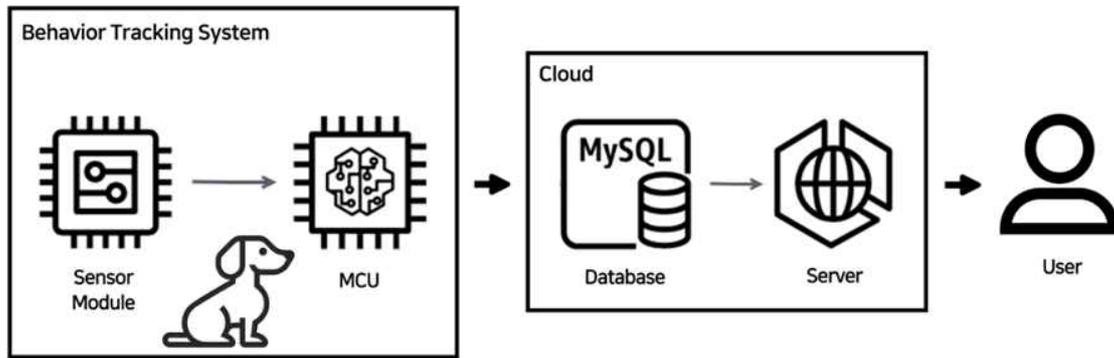


Fig. 1 System Diagram

루어지고 있다(Ha, 2020; Oh and Kim, 2022). 이러한 연구에서는 카메라를 포함한 다양한 센서 모듈을 사용하여 인간의 움직임을 디지털 데이터로 변환하고, 개인의 행동 분석과 교정에 활용하고 있다(Jeong et al., 2007; Park et al., 2023). 이와 같은 신체 데이터를 활용한 연구는 만성 질환 예방뿐 아니라 더 나아가 건강 증진에 긍정적인 영향을 미칠 수 있다(Kim et al., 2011).

최근 인구 고령화와 1인 가구 증가로 인해 반려견 시장이 확대되면서 반려견 케어 시스템에 대한 관심이 증가하고 있다(Park et al., 2022). 그에 따라 인간 행동 분석 연구와 비슷한 양상으로 반려견 행동을 분석하는 연구들이 등장하였다. 영상 분석을 활용한 반려견 케어 시스템 연구는 활발하지만, 센서 모듈을 활용하여 반려견의 행동 데이터를 분석하는 연구는 저조한 상황이다(Moon and Jung, 2023).

더불어 반려견의 행동을 집에서 파악하고자 하는 견주들이 증가하는 추세에 따라 반려견의 행동을 확인할 수 있는 홈 CCTV(Closed-Circuit Television)의 수요도 증가하고 있다. 그러나 홈 CCTV는 한정된 공간만 촬영할 수 있어 행동반경이 넓은 반려견의 행동을 파악하기에는 어려움이 존재한다. 또한, 홈 CCTV의 보안 문제가 존재한다. Park and Kim(2017)에 따르면 CCTV, 스마트 가전기기 등 홈케어 서비스들의 보안 문제는 다양한 기법으로 진화된 악성코드로 인하여 지속해서 발생 횟수 및 피해 규모가 증가하고 있다고 밝혔다. 여러 홈 CCTV 피해 사례를 통해 홈 CCTV의 신뢰성에 대한 의문이

끊임없이 제기되고 있다.

반려견의 생활 범위가 견주와 동일하기 때문에 사생활 보호 및 보안 문제 등이 중요한 이슈로 고려되는 인간의 신체 데이터 관련 연구 동향을(Jung and Lee, 2020; Kosar and Barshan, 2023) 참고하여 센서 모듈을 활용한 반려견의 행동 분석 연구를 확대하는 것이 필요하다.

따라서 본 연구는 센서 모듈을 활용하여 반려견 행동 분석 및 케어 시스템을 구축하는 것을 목표로 한다. 반려견의 행동을 분석하기 위해 가속도 센서와 자세(Gyroscope) 센서를 활용하여 진행하였다. 또한, 임베디드 환경에서 실행될 수 있는 딥러닝 모델을 개발하기 위해 모델 경량화를 진행하였다. 개발된 모델의 학습 및 성능을 검증하기 위해 반려견의 행동을 8가지로 분류하고, 다양한 견종의 반려견으로부터 데이터를 직접 수집하였다. 수집된 데이터셋을 통해 모델을 학습하고 검증한 결과 8가지 행동에 대해서 82.19%의 정확도를 보였다. 경량화된 딥러닝 모델은 소형 임베디드 프로세서에서 성공적으로 구현하여 센서 모듈만을 활용한 반려견 행동 데이터 연구의 실용성을 확인하였다.

본 논문의 구성은 다음과 같다. 2장에서는 반려견 행동 분석을 위한 시스템의 구성, 사용된 딥러닝 모델, 그리고 이를 위한 학습 및 성능 평가를 위한 데이터셋 수집에 대해 설명한다. 3장에는 제시된 방법의 효용성을 증명하기 위한 실험 결과, 그리고 4장에서는 본 연구의 결론 및 향후 과제에 관해 기술하였다.

Table 1 Dog Behavior Classification

Category	Motion
Normal	Standing
	Lying down
	Sitting
	Walking
	Slow walking
	Running
	Eating
Abnormal	Eating outside of mealtime
	Digging

2. 반려견 행동 분석 및 케어 시스템

2.1 시스템 구성

Fig. 1은 본 논문에서 제안된 반려견 행동 분석 및 케어 시스템 구성을 나타내며, 센서 모듈과 마이크로프로세서로 구성된 행동 추적 시스템, 반려견의 행동을 기록하고 사용자가 관리할 수 있도록 하는 클라우드 환경, 그리고 사용자로 구성된다. 센서 모듈은 목줄(또는 목걸이)의 형태로 반려견에 부착되어 반려견의 움직임을 관찰하게 된다. 움직임 센서로부터 수집된 데이터는 행동 인식을 위해 클라우드 서버로 바로 보내는 것이 아닌 센서 모듈에 내장된 마이크로프로세서에서 실행되는 딥러닝 모델을 통해 반려견의 행동을 바로 인식한다. 마지막으로 인식된 반려견의 행동은 클라우드 서버로 전송하여 견주가 실시간으로 반려견의 행동을 볼 수 있도록 제공한다.

반려견의 행동 분류는 Kim(2018)의 반려견 행동 양식 정의를 토대로 반려견 행동을 관찰하여 Table 1과 같이 9개의 행동으로 분류하였다. 초기 행동 분류를 정의할 당시 걷기와 느리게 걷기를 구분하지 않았지만, 반려견의 행동을 관찰한 결과 집에서 걷는 속도와 산책을 위해 걷는 속도가 현저히 다르다는 것을 발견하였다. 추가로, 산책하며 걷는 속도와 뛰는 속도 또한 달랐기에 걷기, 느리게 걷기, 뛰기를 구분하여 행동

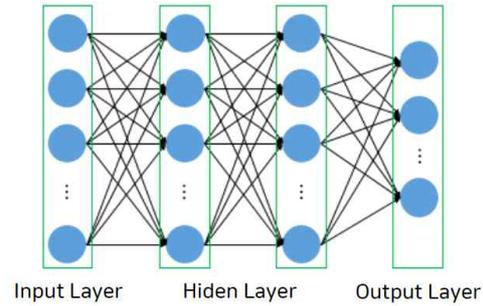


Fig. 2 MLP Architecture

을 분류하도록 수정하였다. 이상행동의 경우, 견주와의 인터뷰 결과 반려견의 행동 중 가장 말리고 싶은 행동이 집에서 장판이나 벽지를 뜯거나 반려견에게 좋지 않은 음식을 견주 모르게 먹는 것이기에 이를 이상행동으로 선정하였다. 최종적으로 서 있기, 눕기, 앉기, 걷기, 느리게 걷기, 뛰기, 먹기를 정상 행동으로, 이상행동으로는 정해진 시간 외에 먹기, 파기를 선정하였다. 다만 정상 행동의 먹기와 정해진 시간 외에 먹기는 ‘먹는다’는 행동이 같지만, 해당 행동을 하는 시간에 따라 이상행동으로 분류하는 것이기에 학습 데이터를 수집 시에는 두 행동 분류를 ‘먹기’로 통합하여 수집하였다.

2.2 행동 분석을 위한 딥러닝 모델 설계 및 최적화

본 연구에서는 반려견 행동 인식에 적합한 모델을 찾기 위해 경량화에 적합한 MLP(Multi-Layer Perceptron) 모델과 상대적으로 인식 정확도가 높을 것으로 예상되는 CNN(Convolutional Neural Network) 모델을 비교하였다. MLP 모델은 입력되는 데이터의 수와 인식되는 행동(클래스)의 수를 고려하여 은닉층이 1개인 경우와 2개인 구조를 주요 탐색 대상으로 하였으며, 각 은닉층 당 노드의 수는 학습 과정을 통해 성능을 비교한 결과 1개 은닉층의 경우 500개의 노드를, 2개인 경우 각 400개, 120개로 구성하였다. (Fig. 2 참조)

CNN 모델의 경우 유사한 최적화 과정을 통해 Fig. 3과 같이 커널크기 3x3, 64개의 필터를

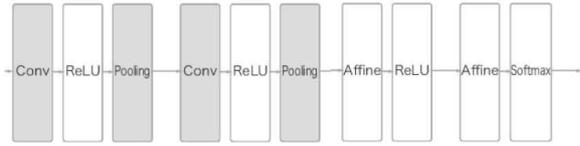


Fig. 3 CNN Architecture

사용하는 합성곱 계층(Convolutional Layer)과 2x2 크기의 윈도우를 사용하는 최대 풀링 계층(Max Pooling Layer)으로 구성하였다. 입력 데이터를 합성곱 연산을 통해 처리하고, 최대 풀링 계층을 통해 데이터를 압축한 후 완전연결 계층(Affine Layer)를 통해 최종 분류를 수행하도록 구성하였다.

2.3 학습을 위한 데이터 수집

인공신경망을 이용한 반려견의 행동 분석을 위해서는 대량의 데이터 수집이 필수적이다. 본 연구의 주요 대상인 반려견을 대상으로 하는 공개된 데이터셋은 존재하지 않기 때문에, 본 연구에서는 반려견 행동에 대한 데이터셋을 직접 수집하였다. 이를 위해 스마트폰용 태깅(Tagging) 애플리케이션을 제작하였다. 태깅 애플리케이션

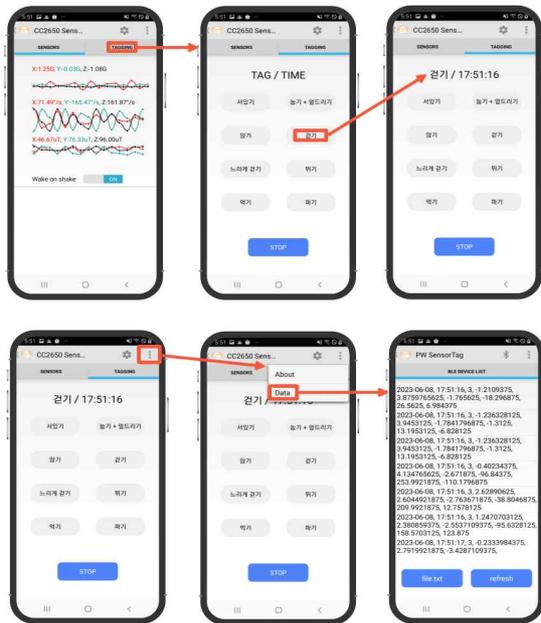


Fig. 4 Tagging Application

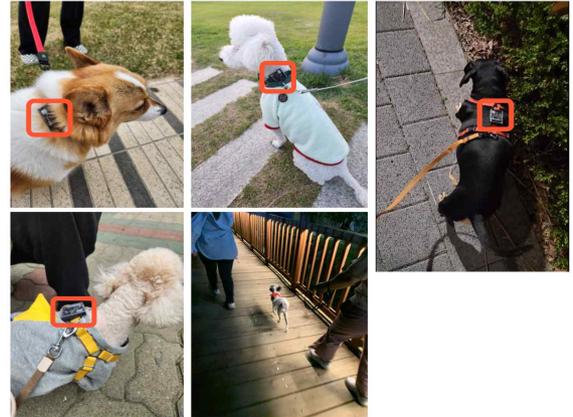


Fig. 5 Collection of Dataset from 5 dogs

은 움직임 센서로부터 수집되는 데이터를 저장하며, 동시에 데이터 라벨링을 위해 시간과 행동 라벨을 기록할 수 있는 페이지를 추가하였다. 또한, 라벨링 된 데이터를 확인하는 데이터 리스트 페이지도 추가하였다.

Fig. 4는 데이터 수집을 위해 구축한 태깅 애플리케이션 페이지와 데이터를 수집하는 일련의 과정을 나타낸다. 태깅 애플리케이션은 블루투스 통신을 통해 움직임 센서 모듈을 연결한다. 반려견이 행동을 하게 되면 TAGGING 탭에 들어가 현재 반려견의 행동이 부합하는 행동 라벨을 클릭하여 데이터 라벨링을 진행한다. 라벨링 된 데이터 정보는 리스트 페이지에서 확인할 수 있다. 이때 분류 행동으로 선정하지 않은 행동을 했을 때 stop 버튼을 눌러 불필요한 데이터가 기록되지 않도록 하였다.

본 연구에서는 Fig. 5와 같이 총 다섯 마리 반려견의 행동 데이터 수집을 진행하였다. 움직임 센서는 그림에서 보는 바와 같이 몸 전체의 움직임을 효율적으로 측정할 수 있도록 각 반려견 목줄의 상단에 부착하였다. 반려견의 크기별 특징을 일반화하기 위해 소형견에서 중형견까지 다양한 견종으로부터 데이터를 수집하였다. Table 2는 각 반려견으로부터 수집된 데이터를 행동별로 분류한 데이터의 수를 보여주며, 8개의 행동에 걸쳐, 총 15,611개의 데이터셋을 수집하였다. 반려견의 행동 분석 데이터 수집의 경우 대상 반려견이 행동을 정확하게 유도하기 어려운 점이 있어 행동 별 데이터의 수가 고르지 못하였

Table 2 Dog Behavior Classification

No.	Motion	Number of datasets
0	Standing	1,639
1	Lying down	2,067
2	Sitting	1,041
3	Walking	5,223
4	Slow walking	1,399
5	Running	967
6	Eating	1,937
7	Digging	1,338
Total		15,611

다. 수집된 데이터의 75%는 학습을 위해 25%는 개발된 모델의 평가를 위해 사용하였다.

3. 실험결과

3.1 실험 환경

본 연구에서 사용한 센서 모듈은 TI CC2650 Sensor Tag(이하 CC2650STK)로 블루투스 통신을 지원하며 내장된 자이로스코프, 가속도 센서를 사용하였다. 데이터 수집의 경우 센서 모듈에 내장된 움직임 센서로부터 초당 10개의 데이터 샘플을 수집한 후, 블루투스 통신을 통해 스마트폰으로 전송되었으며, 스마트폰으로 전송된 데이터는 실시간 라벨링 과정을 거쳐 저장되었다. 이렇게 저장된 데이터를 2초씩 묶어 총 20개의 움직임 데이터를 하나의 입력 데이터로 만들었고 이를 신경망 모델 학습 과정에서 사용하였다. 반려견의 실제 행동 인식의 경우 움직임 센서에서 수집된 데이터는 자체 내장된 마이크로프로세서에서 실행되는 딥러닝 모델을 통해 행동 인식 후 인식된 결과만을 인터넷에 연결된 스마트폰 또는 중계 모듈을 통해 클라우드 서버로 그 결과를 전달하게 된다.

딥러닝 모델은 Google Colab 환경에서 개발을 진행하였다. TensorFlow 2.11.0 버전을 활용하여 딥러닝 모델을 개발하였다.

Table 3 Comparison of MLP and CNN

AI Models	Params.	Acc. (%)	Size (KB)
MLP: 1 Hidden Layer	64,508	78.40	-
MLP: 2 Hidden Layer	109,758	82.19	430
CNN: 3 Conv. 2 Affine	30,542	74.69	23

3.2 공간 탐색을 통한 모델 선정 및 경량화

딥러닝 모델에 대한 최적의 하이퍼파라미터를 설정하기 위해 케라스 튜너(Keras Tuner)를 사용하였다. MLP 모델의 에폭(Epoch)수는 1000, 배치크기(Batch size)는 32, 옵티마이저(Optimizer)는 모멘텀(Momentum)을 사용하였다. CNN 모델의 경우 에폭수는 1000, 배치 크기는 32, 옵티마이저로 아담(Adam)을 사용하였다.

추가로, 인공신경망 모델의 공간 탐색을 통해 경량화된 최적의 모델을 선정하기 위하여 하이퍼파라미터와 함께 MLP모델의 히든 노드 수와 CNN모델의 완전연결계층 노드 수 또한 케라스 튜너를 통해 설정하였다. Table 3은 MLP 모델과 CNN 모델의 파라미터 수와 정확도를 보여주며, 은닉층의 수가 2개인 MLP 모델의 정확도가 82.19%로 가장 높게 나왔기 때문에 해당 모델을 반려견의 행동 인식을 위한 인공 신경망 모델로 최종 선정하였다. 이때 CNN모델이 MLP 모델보다 정확도가 더 낮은 이유는 본 연구에서 사용한 시계열 특성을 포함하는 센서 데이터의 특성이 CNN모델이 강점을 보이는 이미지 데이터와 다른 특성을 가지고 있기 때문으로 추정된다.

선정된 MLP 모델의 인식 실패 유형을 분석해 보면 걷기와 느리게 걷기가 다른 행동에 비해, 서로 혼동하여 인식하는 경우가 높게 관찰되었다. 걷기와 느리게 걷기 행동의 경우 움직임 센서로부터 얻어지는 신호들의 패턴이 유사할 뿐 아니라 데이터 수집과정에서 수집 대상인 반려견이 느리게 걷다가 일상적 걷기 행동(또는 반대순서)으로 변환되는 경계가 명확하지 않아 데이터 수집 및 라벨링 과정에서 다소 부정확한 데이터가 수집된 것이 주요 원인으로 분석된다.



Fig. 6 Care System Application

걷기와 느리게 걷기 다음으로 뛰기와 파기 행동의 경우 인식율이 낮게 관찰되며, 주요 이유로 다른 행동들에 비해 복잡한 패턴을 보이지만 수집된 해당 행동에 대한 학습용 데이터의 수가 적은 것이 주요 요인으로 분석된다.

개발된 모델을 임베디드 환경에서 사용하기 위해 모델 경량화가 필수적이다. 본 연구에서는 모델 경량화를 위해 텐서플로 라이트(TensorFlow-lite) 2.5.0을 사용하여 TFlite 모델로 변환하였다. TFLiteConverter를 사용하여 모델 데이터의 자료형을 float32에서 float16으로 변환하도록 값을 설정하였다. 그 결과 Table 3의 마지막 열에 표현된 것 같이 109,758개의 파라미터를 가진 2개의 은닉층을 갖는 MLP모델의 크기는 887KB에서 430KB로 50.5% 절감이 되었고, 30,542개의 파라미터를 가진 CNN 모델의 크기는 109KB에서 23KB로 78.9% 절감되었다.

3.3 반려견 케어 시스템 구현

지금까지 진행한 데이터 수집과 딥러닝 모델 연구를 기반으로 반려견의 행동을 실시간으로 인식하고 이상행동 알림을 제공하는 반려견 케어 시스템을 구현하였다. 시스템의 핵심 기능은 다음과 같다.

첫째, 반려견의 행동을 실시간으로 모니터링할 수 있는 수단으로 제공한다. 센서 모듈에서 수집된 움직임 정보는 모듈 자체에 내장된 인공신경망 모델인 MLP 모델이 추론한 결과를 실시간으로 서버에 전송하며, 시스템 성능을 고려하여 반려견의 행동은 매 5초마다 갱신된다.

Fig. 6의 (A)는 실시간으로 반려견의 행동을 모니터링할 수 있는 앱 화면을 나타낸다.

둘째, 실시간으로 인식된 정보를 기반으로, 일별 반려견 행동 데이터 통계를 제공한다. 행동 추적 시스템으로부터 수신된 반려견의 행동 데이터를 활용하여 가시성이 좋은 일별 통계를 제공한다. 이러한 기능을 통해 사용자는 반려동물의 행동과 건강 상태를 종합적으로 이해하고 관리할 수 있다. Fig. 6의 (B)는 일별 통계를 확인하는 앱 화면을 나타낸다.

마지막으로, 반려견의 이상행동 기록을 제공한다. 추론된 데이터가 이상행동으로 분류될 경우, 이상행동 로그에 기록하고 동시에 사용자에게 알림을 전송한다. 이를 통해 사용자는 반려견의 이상행동을 신속하게 파악하고 적절한 훈련과 행동 교정을 시행하여 반려동물의 행동 개선과 건강 증진에 기여할 수 있다. Fig. 6의 (C)는 이상행동 로그를 확인하는 앱 화면을 나타낸다.

4. 결론

본 연구에서는 센서를 활용해 반려견의 행동 데이터를 인식하고 분석하여 사용자에게 제공하기 위해 딥러닝 기반의 반려견 행동 인식 기술을 개발하였다. 전형적인 홈 카메라나 홈 CCTV와 같은 외부 감시 시스템은 개인의 사생활 노출 우려로 인해 보안 문제가 제기되고 있어 이를 극복할 수 있는 기술 개발이 필요하다.

이에 본 연구에서는 움직임 센서 모듈을 활용하여 반려견의 행동 데이터를 수집하였으며, 이를 통해 임베디드 기반 프로세서에서 실행될 수 있는 430KB의 크기를 갖는 경량 MLP 모델을 설계하였으며 82.19%의 정확도를 달성하였다. 개발된 모델은 반려견의 행동을 실시간으로 인식 가능하며, 인식된 반려견의 행동 데이터를 사용자에게 실시간으로 제공할 수 있는 애플리케이션을 구현하였다.

이러한 기술은 사생활 보호를 비롯하여 반려견의 행동 데이터 분석과 강아지의 건강 및 행복 관리에 기여할 것으로 기대되며, 또한 동물

행동 연구 분야에서도 새로운 가능성을 제시할 수 있을 것으로 기대된다.

본 연구의 향후 과제는 반려견 행동 판별 딥러닝 모델의 정확도 향상을 위해 혼동을 주는 걷기와 느리게 걷기 데이터를 명확히 라벨링하고 부족한 뛰기와 파기 행동 데이터를 수집하는 것이다. 또한, 모델 계층 수를 추가하여 더 높은 정확도를 보이는 모델을 확보하고 더 나아가 다양한 견종에서 적용될 수 있는 범용성 있는 딥러닝 모델의 개발을 진행함으로써 반려견의 행동을 실시간으로 확인하는 것뿐만 아니라 다양한 응용 분야에서의 활용 가능성을 더욱 확장할 것으로 기대된다.

References

- Ha, T. Y. (2020). *A Study on the Smart Healthcare through Human Pose Estimation Based on Artificial Intelligence*, Dissertation, Graduate School of Hanseong University, Seoul, Korea.
- Jung, W. and Lee, H. G. (2020). Design and Performance Analysis of ML Techniques for Finger Motion Recognition, *Journal of Korea Society of Industrial Information Systems*, 25(2), 129-136.
- Jeong, T. M., Choi, W. K., Kim, S. J., Kim, Y. M., Ha, S. H. and Jeon, H. T. (2007). Study for Human Behavior Classification using Soft-Computing Method, *Proceedings of the Korean Institute of Intelligent Systems Conference*, Apr. 20 - 21, Mokpo, Korea, pp. 257-260.
- Kim, D. Y., Jeon, S. H., Kang, S. Y. and Kim, N. H. (2011). Customized Estimating Algorithm of Physical Activities Energy Expenditure using a Tri-axial Accelerometer, *Journal of the Korea Contents Association*, 11(12), 103 - 111.
- Kim, H. J. (2018). *A Study on Behavior Classification Enhancement of Dogs for Human-Dog Communication*, Thesis, Graduate School of Konkuk University, Seoul, Korea.
- Kosar, E. and Barshan, B. (2023). A New CNN-LSTM Architecture for Activity Recognition Employing Wearable Motion Sensor Data: Enabling Diverse Feature Extraction, *Engineering Applications of Artificial Intelligence*, 124, 106259.
- Moon, H. W. and Jeong, H. C. (2023). Dog Detection and Behavior Classification Using Deep Learning, *The Korea Institute of Communications and Information Sciences*, Feb. 8-10, Pyeongchang, Korea. pp. 1041-1042.
- Oh, H. W and Kim, W. S. (2022). A Study on the Small Motion Classification Model based on Time Serial Data, *Proceedings of the Korea Institute of Communications and Information Sciences Conference*, Feb. 9-11, Pyeongchang, Korea, pp. 949-950.
- Park, J. S., Ha, G. S. and Kwon, H. D. (2022) Total Care System for Pets with Two-Way Communication, *Proceedings of the Korean Society of Manufacturing Technology Engineers*, Dec. 11-14, Jeju, Korea, pp. 2.
- Park, J. S., Cha, K. and Choi, A. (2023), 3D ResNet-based Children's Behavior Recognition Method Using Video Image Sequence, *Journal of Korea Society of Industrial Information Systems*, 28(3), 1-10.
- Park, M. S. and Kim, J. S. (2017). Research on Testing Methods for Malicious Process Execution Control Products for IoT Devices, *Journal of Information Security*. 27(6), 29-32.



이 희 래 (Hee Rae Lee)

- 정회원
- 덕성여자대학교 소프트웨어 전공 학사
- 관심분야: AIoT, 머신러닝



김 선 경 (Seon Gyeong Kim)

- 학생회원
- 덕성여자대학교 소프트웨어 전공 학사
- 관심분야: Embedded Software, AIoT



이 형 규 (Hyung Gyu Lee)

- 정회원
- 서울대학교 전기컴퓨터공학부 석사/박사
- 덕성여자대학교 소프트웨어 전공 부교수
- 관심분야: 저전력 임베디드시스템 설계, 에너지 하베스팅, 엣지 컴퓨팅/AI, 메모리/스토리지 시스템