

A Semi-Supervised Learning-Based Pet Behavior Classification System Using Wearable Devices

JunHyeok Go*, Siung Kim*, JeongHyeon Park*, Nammee Moon**

*Student, Dept. of Computer Science and Engineering, Hoseo University, Asan, Korea

**Professor, Dept. of Computer Science and Engineering, Hoseo University, Asan, Korea

[Abstract]

This study proposes a wearable device-based system for classifying pet behaviors. The system incorporates a preprocessing step that effectively removes inactive data from unlabeled datasets using the DeepSVDD (Deep Support Vector Data Description) algorithm, thereby enhancing training performance. Furthermore, the system applies the MPL (Meta Pseudo Labels) method and contrastive learning techniques to extract and utilize meaningful information from unlabeled data during training. Experimental results demonstrated the system's effectiveness, achieving 87% accuracy with a labeled data ratio of 20% and 91% accuracy with a labeled data ratio of 60%. This system is practical for monitoring the health status of pets or detecting abnormal behaviors at an early stage. By integrating wearable technology with semi-supervised learning techniques, it presents new possibilities in the field of pet behavior analysis.

▶ **Key words:** Time Series Data, Semi-Supervised Learning, Meta Pseudo Labels,
Pet Behavior Classification, DeepSVDD

[요 약]

본 연구에서는 웨어러블 디바이스를 활용한 반려동물 행동 분류 시스템을 제안한다. 이 시스템은 DeepSVDD(Deep Support Vector Data Description) 알고리즘을 활용하여 비라벨 데이터에서 비활성 데이터를 효과적으로 제거하는 전처리 과정을 포함하였으며, 이를 통해 학습 성능을 개선하였다. 이후, MPL(Meta Pseudo Labels) 방법과 대조학습 기법을 적용하여 라벨이 없는 데이터에서도 유용한 정보를 추출하여 학습에 반영하였다. 실험 결과, 라벨 비율이 20%일 때 87%의 정확도를, 라벨 비율이 60%일 때 91%의 정확도를 기록하며 제안된 시스템의 유효성을 입증하였다. 이러한 시스템은 반려동물의 행동 데이터를 활용하여 건강 상태를 모니터링하거나 이상 행동을 조기에 감지하는 데 실용적이며, 웨어러블 기술과 반지도 학습 기법의 융합을 통해 반려동물 행동 분석 분야의 새로운 가능성을 제시한다.

▶ **주제어:** 시계열 데이터, 반지도 학습, Meta Pseudo Labels, 반려동물 행동 분류, DeepSVDD

- First Author: JunHyeok Go, Corresponding Author: Nammee Moon
- *JunHyeok Go (junhyeok970306@gmail.com), Dept. of Computer Science and Engineering, Hoseo University
- *Siung Kim (kimsiung990811@gmail.com), Dept. of Computer Science and Engineering, Hoseo University
- *JeongHyeon Park (Jh.park970609@gmail.com), Dept. of Computer Science and Engineering, Hoseo University
- **Nammee Moon (nammee.moon@gmail.com), Dept. of Computer Science and Engineering, Hoseo University
- Received: 2025. 02. 06, Revised: 2025. 03. 03, Accepted: 2025. 03. 07.

I. Introduction

최근 반려동물의 건강에 대한 관심 증가와 웨어러블 디바이스의 발전으로 인해, 웨어러블 디바이스의 사용은 인간을 넘어 동물까지 확장되고 있다[1,2,3]. 특히, AI의 발전으로 행동 분류가 가능해짐에 따라 좀 더 정밀한 반려동물 모니터링 시스템이 개발되고 있다[4,5,6]. 그러나 기존의 행동 분류 시스템은 라벨링된 데이터셋에 의존하여 학습을 진행한다. 이러한 데이터셋을 얻는 것은 어렵고, 시간과 인적 비용도 많이 소모된다. 반면, 반지도 학습 방법을 이용하면 제한된 양의 라벨링된 데이터로도 효과적인 모델 학습을 수행할 수 있다.

따라서, 본 연구에서는 웨어러블 디바이스와 반지도 학습 기법을 활용한 반려동물 행동 분류 시스템을 제안한다. 이 시스템은 가속도계, 자이로스코프, 지자계를 탑재한 웨어러블 디바이스로부터 수집된 센서 데이터를 활용하여 반려동물의 행동을 기록하고 수집한다. 수집된 데이터에 대해 DeepSVDD를 적용하여 '서다', '걷다', '앉다', '눕다'에 속하지 않는 비활성 데이터를 제거함으로써 비라벨 데이터의 품질을 보장한다. 그 다음, MPL 방법을 활용하여 비라벨 데이터에서 유용한 정보를 추출하고 학습에 반영하였다.

실험 결과, 제안된 시스템은 60%의 데이터 비율에서 91%의 정확도와 높은 F1 점수를 달성하여 효과적인 학습 방법임을 입증하였다. 또한, 이 시스템은 반려동물 행동 분류 시스템에서 새로운 가능성을 제시하며, 모니터링 시스템에서 이상 행동을 감지하는 데 높은 활용 가능성을 보여준다. 본 연구는 웨어러블 디바이스의 복잡한 시계열 데이터를 DeepSVDD를 이용하여 정제하고, 반지도 학습 방법을 통해 효율적인 학습 방법을 제시하였다. 이는 향후 관련 분야의 발전에 기여할 수 있을 것이다.

II. Preliminaries

1. Related works

1.1 pet Monitoring System

반려동물의 건강과 복지를 모니터링하는 시스템은 다양한 기술의 발전과 함께 진화해왔다. 초기의 동물 모니터링 시스템은 주로 비디오 카메라를 활용하여 동물의 활동을 시각적으로 기록하고 분석하였다[7,8]. 이러한 방법은 반려동물의 행동을 실시간으로 관찰하는 데 유용하였으나, 비디오 데이터의 저장 및 처리에 많은 자원이 필요하며,

보안에 대해서 취약할 수 있다.

최근 웨어러블 디바이스의 발전은 반려동물 모니터링에 새로운 가능성을 열어주었다. 웨어러블 디바이스는 가속도계, 자이로스코프, 심박수 센서 등을 탑재하여 반려동물의 다양한 생리적 데이터를 실시간으로 수집할 수 있다. 이러한 디바이스는 반려동물의 목걸이나 하네스에 부착되어 사용되며, 반려동물의 움직임 패턴과 활동 수준을 모니터링한다[9,10].

몇몇 연구에서는 웨어러블 디바이스를 이용하여 반려동물의 건강 상태를 모니터링하는 시스템을 개발하였다 [11,12]. 예를 들어, 가속도계를 활용하여 반려동물의 활동 수준을 측정하고, 이를 통해 반려동물이 충분한 운동을 하고 있는지 여부를 판단할 수 있다. 자이로스코프와 함께 사용되는 경우, 반려동물의 자세 변화와 움직임을 보다 정밀하게 감지할 수 있어, 걷기, 뛰기, 앉기, 눕기 등의 다양한 행동을 분류하는 데 활용된다. 또한, 웨어러블 디바이스의 데이터는 머신러닝 알고리즘에 의해 분석된다. 웨어러블 디바이스로부터 수집된 데이터를 기반으로 반려동물의 행동을 분류하는 다양한 연구가 진행되었다. 이러한 시스템은 반려동물의 일상 활동을 모니터링하고, 이상 행동을 조기에 감지하는 데 유용하다.

또 다른 연구에서는 심박수를 활용하여 반려동물의 스트레스 수준을 측정하였다. 심박수 변화는 반려동물의 스트레스와 관련이 있으며, 이를 실시간으로 모니터링함으로써 반려동물의 심리적 상태를 파악할 수 있다. 이러한 데이터는 반려동물이 스트레스를 받는 상황을 조기에 인지하고, 적절한 조치를 취하는 데 도움을 준다[13,14].

종합적으로, 웨어러블 디바이스를 활용한 반려동물 모니터링 시스템은 반려동물의 건강과 복지를 개선하는 데 중요한 역할을 한다. 이러한 시스템은 반려동물의 활동과 건강 상태를 실시간으로 모니터링하고, 비정상적인 행동을 조기에 감지하여 반려동물이 최상의 건강 상태를 유지할 수 있도록 돕는다. 하지만, 대부분의 연구는 지도학습에 기반을 두고있으며, 이는 데이터 수집에 라벨링 비용이 지속적으로 발생하며, 모델을 개선하고 성능을 향상시키는 데 방해되는 요소가 된다.

1.2 Semi-supervised learning

반지도 학습(Semi-Supervised Learning)은 제한된 양의 라벨링된 데이터와 대량의 비라벨 데이터를 함께 사용하여 모델을 학습시키는 기법이다. 이는 라벨링 작업의 비용과 시간을 절감하면서도 높은 성능을 유지할 수 있어 많은 주목을 받고 있다. 본 연구에서는 반지도 학습의 대표

적인 기법인 MPL[15] 과 DeepSVDD[16]를 활용하였다.

MPL은 반지도 학습의 한 방법으로, 모델이 예측한 라벨을 사용하여 비라벨 데이터에 임시 라벨을 부여하는 기법이다. 이러한 임시 라벨을 사용하여 모델을 재학습시키고, 이를 반복하는 과정을 통해 모델의 성능을 점진적으로 향상시킨다. 이 방법은 특히 대규모 비라벨 데이터를 효과적으로 활용할 수 있어, 적은 양의 라벨링된 데이터로도 높은 정확도의 모델을 학습할 수 있게 한다.

DeepSVDD는 데이터의 비정상 여부를 판별하는 알고리즘으로, 주로 이상 탐지에 사용된다. DeepSVDD는 정상 데이터를 중심으로 데이터의 분포를 학습하고, 학습된 분포에서 벗어나는 데이터를 비정상적으로 간주한다. 본 연구에서는 DeepSVDD를 사용하여 ‘서다’, ‘걷다’, ‘앉다’, ‘눕다’에 속하지 않는 비활성 데이터를 제거하였다. 이를 통해 비라벨 데이터의 품질을 높이고, 모델의 학습 성능을 향상시켰다.

이와 같은 반지도 학습 기법과 웨어러블 디바이스를 결합함으로써, 본 연구는 반려동물의 행동을 효과적으로 분류하고 모니터링할 수 있는 혁신적인 시스템을 제안한다. 이 시스템은 반려동물의 행동 데이터를 수집하고 분석하여, 특정 행동 패턴과 이상 행동을 감지하는 데 중점을 둔다. 이를 통해 반려동물의 건강 관리와 이상 행동의 조기 발견에 기여할 수 있으며, 반려동물의 삶의 질을 향상시키는 데 실질적인 도움을 제공한다. 또한, 본 연구의 결과는 반려동물 행동 분석 및 모니터링 시스템의 발전에 기여할 수 있는 기초 자료로 활용될 가능성을 제시한다.

III. The Proposed Scheme

1. Pet behavior Data Collection

1.1 Wearable devices

본 연구에서는 반려동물의 행동을 모니터링하고 분류하기 위해 특수 제작된 웨어러블 디바이스를 사용하였다. 이 디바이스는 반려동물이 쉽게 물어뜯거나 제거할 수 없는 부위인 목걸이에 부착될 수 있도록 설계되었으며, 다양한 센서를 통합하여 반려동물의 행동 데이터를 실시간으로 수집한다.

웨어러블 디바이스에는 지자기 센서, 가속도 센서, 자이로 센서가 포함된다. 지자기 센서는 반려동물의 위치와 방향을 감지하여 움직임의 방향성을 파악할 수 있게 해준다. 가속도 센서는 반려동물의 움직임과 활동 수준을 측정하는 데 사용되며, 걷기, 뛰기, 앉기, 눕기와 같은 다양한 행

동을 감지할 수 있다. 자이로 센서는 반려동물의 자세 변화를 감지하고, 움직임의 각속도와 방향을 측정하여 보다 정밀한 행동 분류를 가능하게 한다.

제작한 디바이스는 720mAh 용량의 배터리를 탑재하여 장시간의 연속적인 데이터 수집이 가능하며, 효율적인 전력 관리를 위해 PMU(MAX)를 사용한다. 또한, 센서 데이터를 실시간으로 통합하여 제공하는 IMU(ICM-20948)와 데이터 처리를 담당하는 MCU(MAX32 670GTL)를 탑재하여 최종적으로 100Hz의 센서 데이터를 수집한다. 제작된 디바이스의 무게는 31g이고, 크기는 가로 4.5cm 세로 2.5cm 높이 2cm를 가진다.

수집된 센서 데이터는 블루투스 모듈을 통해 수집용 모바일 어플리케이션으로 전달된다. 제작되고 착용한 웨어러블 디바이스는 Fig 1. 과 같다.




Fig. 1. Wearable device images and wearable images

1.2 Data Collection Process

본 연구에서 제안한 시스템의 데이터 수집 프로세스는 여러 단계를 포함한다. 먼저, 웨어러블 디바이스에 탑재된 지자기, 가속도, 자이로 센서는 반려동물의 행동 데이터를 실시간으로 수집한다. 이러한 데이터는 블루투스를 통해 모바일 디바이스로 전송한다.

모바일 디바이스는 블루투스를 통해 수신한 센서 데이터를 실시간으로 처리한다. 이 과정에서 데이터를 수집하고 관리하기 위해 전용 어플리케이션을 제작하였다. 이 어플리케이션은 센서 데이터와 함께 반려동물의 행동을 영상으로 기록하며, 센서 데이터와 영상 데이터를 동기화하여 보다 정확한 행동 분석을 가능하게 한다.

어플리케이션은 수집된 데이터를 로컬 디바이스에 임시 저장한 후, 네트워크 연결을 통해 NAS(Network Attached Storage) 데이터베이스로 전송한다. 데이터베이스는 대용량의 데이터를 안전하게 저장하고 관리할 수 있는 환경을 제공하며, 수집된 모든 행동 데이터를 보관한다.

본 연구에서는 총 20,000개의 데이터 중 30%의 데이터에 대해 라벨링 작업을 수행하였다. 각 행동에 대한 라벨

링 기준을 정립하여 '서다', '걷다', '앉다', '눕다'와 같은 주요 행동을 구분하였다. 라벨링 기준은 분류에 해당하는 행동이 2초 이상 지속되었을 때 라벨링을 수행하는 것으로 설정하여, 반려동물의 행동이 일시적인 변동이 아닌, 행동 패턴을 반영하도록 하였다. 이후, 데이터베이스에 저장된 데이터는 다양한 분석 알고리즘을 통해 처리된다.

본 연구에서는 Meta Pseudo Labels와 DeepSVDD를 활용한 반지도 학습 방법을 적용하여 비라벨 데이터의 품질을 보장하고, 유용한 정보를 추출하여 학습에 반영하였다. Meta Pseudo Labels 기법은 비라벨 데이터에서 유용한 정보를 추출하여 모델의 학습에 반영하고, DeepSVDD는 라벨 기준에 속하지 않는 비활성 데이터를 제거하여 데이터의 품질을 높인다. 이러한 데이터 수집 및 처리 프로세스를 통해, 본 연구는 반려동물의 행동을 모니터링하고 분석할 수 있는 시스템을 구축하였다. 제작된 어플리케이션과 데이터베이스 수집 프로세스는 Fig. 2와 같다.




Fig. 2. Companion Behavior Data Collection Process

2. Pet Behavior Classification System

본 연구에서는 행동 분류의 정확도를 높이기 위한 여러 알고리즘을 적용하였다. 반려동물 행동 분류 시스템 프로세스는 그림 Fig. 3와 같다. 우선 데이터 전처리로 데이터 표준화, 결측치 제거, 비활성화 데이터를 통해 학습 데이터로 변환하고, 일반화 성능을 높이기 위해 비라벨데이터에 대해 Time Reverse, Flip, Jittering, Kep의 데이터 증

강을 적용하였다. 이후 반지도 학습 기반 MPL학습을 통해 반려동물의 행동을 분류하였다.

2.1 Time series data preprocessing

본 연구에서는 반려동물의 행동 데이터를 분석하기 위해 시계열 데이터 전처리 과정을 수행하였다. 전처리 과정은 데이터의 품질을 높이고, 모델의 학습 성능을 최적화하기 위해 중요한 단계이다. 본 연구에서는 표준화와 DeepSVDD를 이용한 전처리 방법을 적용하였다.

2.1.1 Standardize data

시계열 데이터는 각 센서마다 값의 범위가 달라, 특정 센서에 편향될 수 있다. 따라서, 데이터를 동일한 범위로 맞추는 작업이 필요하다. 이를 위해 본 연구에서는 표준화 적용하였다. 표준화는 센서 데이터의 평균을 0, 분산을 1로 조정하여 데이터의 스케일을 맞추는 방법으로, 센서 간의 데이터 차이를 최소화하고, 모델이 특정 센서 값에 편향되지 않도록 한다. 표준화된 데이터는 다음과 같은 수식 (1)으로 계산된다.

$$X' = \frac{X - \mu}{\sigma} \tag{1}$$

여기서 X 는 원본 데이터, μ 는 데이터의 평균, σ 는 데이터의 표준편차이다. 이러한 표준화 과정을 통해 데이터의 분포를 일정하게 유지하며, 모델의 학습 효율성을 높일 수 있다.

2.1.2 Missing value removal

시계열 데이터 분석에서 결측치는 모델의 성능에 부정적인 영향을 미칠 수 있다. 본 연구에서는 결측치를 효과

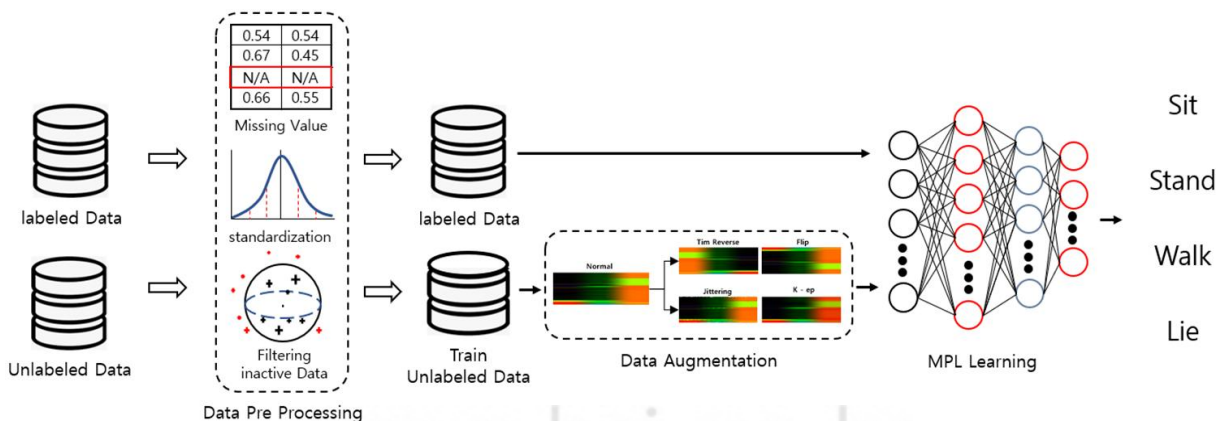


Fig. 3. pet Behavior Classification System Process

적으로 처리하기 위해 특정 기준을 설정하였다. 100Hz로 수집된 데이터 중 처음과 끝 부분에 결측치가 없고, 전체 데이터의 10% 미만의 결측치가 발생한 데이터만을 대상으로 결측치 보간을 수행하였다. 결측치가 10% 미만인 경우, Bicubic 보간법을 적용하여 결측치를 대체하였다. Bicubic 보간은 인접한 데이터 포인트를 이용하여 결측치를 추정하는 방법으로, 데이터의 연속성과 부드러움을 유지하고 일관성을 유지한다.

이와 같은 결측치 제거 및 보간 과정을 통해, 데이터의 연속성과 일관성을 유지하며, 학습에 적합한 고품질의 데이터셋을 확보하였다.

2.1.3 3CH Learning Data Structure Formation

본 연구에서는 웨어러블 디바이스로부터 수집된 다차원 센서 데이터를 효율적으로 처리하기 위해 CNN 구조를 활용하였다. 이를 위해, 가속도, 자이로스코프, 지자계 센서에서 수집된 데이터를 3Ch의 적절한 형태로 변환하는 과정을 거쳤다.

각 센서는 x, y, z의 3축 데이터를 제공하며, 본 연구에서는 이러한 데이터를 CNN 구조에 맞게 3채널 데이터로 변환하였다. 먼저, 각 센서의 x, y, z 축 데이터를 하나의 채널로 구성하여, 총 3채널 데이터를 형성하였다. 이를 통해 각 센서의 데이터를 개별적으로 처리할 수 있도록 하였다.

수집된 데이터는 100Hz로 기록되었으며, 학습 데이터는 2초 간격으로 구성되었다. 즉, 각 학습 데이터는 200Hz의 데이터로 구성된다. 이러한 데이터를 CNN에 적합한 형태로 변환하기 위해, 데이터를 (200, 3, 3) 구조로 reshape하였다. 여기서 200은 시간축을, 3은 센서 종류를, 마지막 3은 각 센서의 x, y, z 축 데이터를 나타낸다. 이와 같은 구조로 변환된 데이터는 CNN의 입력으로 사용되어, 시계열 데이터를 효과적으로 처리할 수 있게 하였다. 이러한 구조는 각 센서의 x, y, z 축 데이터를 개별 채널로 분리함으로써, 센서 간 상호작용을 보다 명확하게 학습할 수 있다.

2.1.4 Remove inactive data

DeepSVDD는 주로 이상 탐지에 사용되는 알고리즘으로, 본 연구에서는 라벨링되지 않은 데이터에서 비활성 데이터를 제거하는 데 사용한다. 이 알고리즘은 정상 데이터의 분포를 학습하고, 학습된 분포에서 벗어나는 데이터를 비정상적으로 간주한다. 초기 라벨링된 데이터를 사용하여 DeepSVDD 모델을 학습시킨다. 자세한 학습과정은 Fig. 4.과 같다.

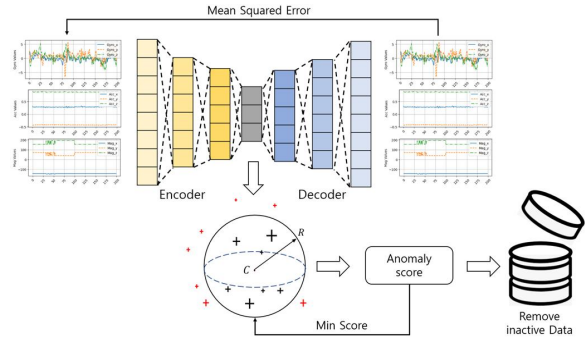


Fig. 4. DeepSVDD learning process

DeepSVDD는 인코더-디코더 구조를 통해 정상 데이터의 주요 패턴을 학습한다. 입력된 시계열 데이터는 인코더를 통해 저차원 공간으로 매핑되고, 디코더를 통해 다시 원래의 차원으로 복원된다. 인코더와 디코더의 자세한 구조는 Fig. 5.와 같다. 이 과정에서 원본 데이터와 복원된 데이터 간의 차이를 최소화하기 위해 평균 제곱 오차 (Mean Squared Error)를 사용하여 모델을 학습한다.

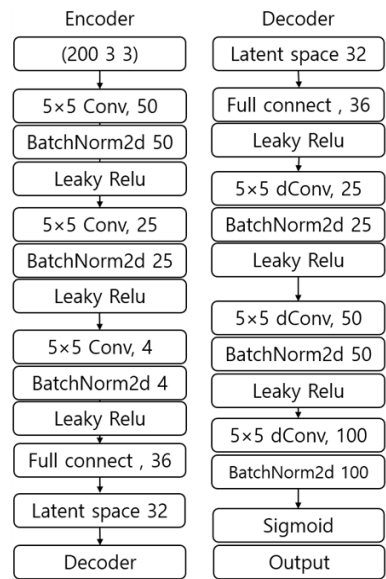


Fig. 5. DeepSVDD model structure

학습된 인코더-디코더 구조를 이용하여 각 데이터 포인트에 대한 anomaly score를 계산한다. Anomaly score는 데이터 포인트가 정상 데이터 분포에서 얼마나 벗어나는지를 나타내는 지표로, 이를 최소화하는 방향으로 DeepSVDD 임베딩 공간이 학습된다. 이는 데이터 포인트가 저차원 공간에서 학습된 중심점(C) 주위에 분포하게 된다. 분류 데이터는 이 중심점 근처에 위치하며, 비활성 데이터는 중심점에서 멀리 위치하게 된다. anomaly score가 임계치보다 높은 데이터는 최종적으로 데이터셋에서 제거된다.

이상치탐지 기법의 모델인 DeepSVDD을 이용하여 데이터의 노이즈와 분류 이외의 센서 데이터를 효과적으로 제거하였으며, 비활성 데이터의 신뢰성을 높이고 비지도 학습과정에서 안정적인 학습을 가능하게 한다.

2.2 Data augmentation

본 연구에서는 다양한 데이터 증강 기법을 적용하여 모델의 일반화 성능을 향상시켰다. 특히 MPL에서 UDA(Unsupervised Data Augmentation)는 비라벨 데이터의 활용을 극대화하여 모델의 성능을 향상시키는 기법으로, 데이터 증강을 통해 모델이 다양한 변형된 데이터를 학습할 수 있도록 한다. 이는 모델이 데이터의 다양한 변형에 대해 더 잘 대응하고, 일반화 성능을 높이는 데 중요한 역할을 한다.

데이터 증강은 모델이 학습 데이터의 작은 변형이나 잡음에 덜 민감하도록 하여, 실제 환경에서 발생할 수 있는 다양한 상황에 대해 더 강건한 성능을 발휘할 수 있게 한다. 특히, 시계열 데이터의 경우 시간적 패턴이나 값의 변동에 대한 다양한 변형을 통해 모델이 더욱 유연하게 학습할 수 있도록 돕는다.

본 논문에서 사용된 데이터 증강 기법은 타임 리버스, 플립, 지터링, Kep(K-Equidistant Partitioning)로 총 4가지 방법을 사용하였으며, 각 증강법은 데이터를 불러올 때 50% 확률로 적용하도록 하였다.

2.2.1 Time Reverse

Time Reverse는 시계열 데이터의 시간을 뒤집는 증강 기법이다. 이 방법은 시계열 데이터의 순서를 역순으로 배열하여 시간 축을 반전시킨다. 이를 통해 모델이 시계열 데이터의 패턴을 다양한 순서에서 학습할 수 있도록 도와 특정 행동이 시간적으로 어떻게 변화하는지에 대한 패턴을 모델이 보다 포괄적으로 이해할 수 있게 한다. Time Reverse를 통해 모델은 데이터의 시간적 패턴에 대한 다양한 시나리오를 학습하게 되며, 이는 모델이 시간의 흐름에 따른 데이터의 다양한 변형에 대해 보다 유연하게 대처할 수 있도록 한다.

2.2.2 Flip

시계열 데이터를 x축으로 뒤집는 증강 기법이다. 이러한 방법은 시계열 데이터의 값들을 x축 기준으로 반전시켜 데이터의 패턴을 다양화 하였다. 이를 통해 모델이 다양한 변형에 대해 더 잘 일반화 할 수 있도록 하여 대칭적인 패턴 인식 능력을 더욱 향상시킬 수 있다.

2.2.3 Jittering

Jittering은 시계열 데이터에 가우시안 노이즈를 추가하는 증강 기법이다. 이 방법은 데이터에 무작위적인 노이즈를 더하여, 모델이 노이즈에 강건한 특성을 가지도록 학습할 수 있게 한다. 특히, 실제 환경에서 발생할 수 있는 다양한 잡음에 대한 대응력을 높인다. 특히, 웨어러블 디바이스로부터 수집되는 센서 데이터는 종종 외부 요인으로 인한 잡음을 포함할 수 있는데, Jittering을 통해 모델이 이러한 잡음에 더 잘 적응할 수 있도록 한다.

2.2.4 K-EP(K-equeament Partitioning)

K-EP는 양적 한계를 극복하기 위해 원본의 시간적 및 주파수 특성을 유지하며 데이터를 증강하는 접근법이다. K-Ep는 센서 데이터를 K등 간격으로 분할하여 각 부분에서 정보를 추출하여 데이터를 증강하는 방식이다. 본 논문에서는 100Hz의 데이터를 50Hz로 분리하는 2-EP를 진행하였다.

K-ep에서 일반적으로 사용되는 보간법으로는 cubic 보간과 linear 보간이 있다. cubic보간은 결측치 주변 값을 이용하여 새로운 값을 계산하며, 데이터의 부드러운 변환을 제공한다. Linear 보간은 인접한 두 값을 직선적으로 연결하여 새로운 값을 계산하는 방법으로, 연산이 간단하고 빠른 장점이 있다. 그러나 이러한 전통적인 보간법들은 인접한 값만을 이용해서 복원하기 때문에 데이터의 복잡한 패턴을 충분히 반영하지 못하는 경우가 있다. 따라서, 본 논문에서는 시계열 데이터의 다양한 특성을 고려하여 GAN(Generative Adversarial Network)을 이용한 방법을 사용해 데이터를 증강하였다. GAN을 이용한 시계열 데이터 증강 방법은 보다 정교하고 다양한 패턴을 생성할 수 있다.

Fig. 6.은 보간을 위한 GAN 학습 프로세스를 시각화하였다. GAN은 두 개의 신경망으로 구성된다. 하나는 실제와 유사한 데이터를 생성하는 생성자이고, 다른 하나는 생성된 데이터가 실제 데이터인지 생성된 데이터인지를 구분하는 판별자이다. 이 두 신경망은 서로 경쟁적으로 학습하여, 생성자는 점점 더 실제와 유사한 데이터를 생성하게 된다. K-EP를 GAN 보간 방법으로 이용하여 단순히 인접한 데이터 포인트 기반으로 값을 계산하는 것이 아닌, 데이터 전체에 대한 특성을 고려하여 복원할 수 있다. 추후 MPL학습시에 생성자만을 이용하여 시계열 데이터를 보간하여 MPL모델이 더욱 다양한 데이터에 노출 되도록 한다. 이러한 방식은 비라벨 데이터의 전체 부분을 참고하여 데이터를 보간해 일반화 성능을 높인다.

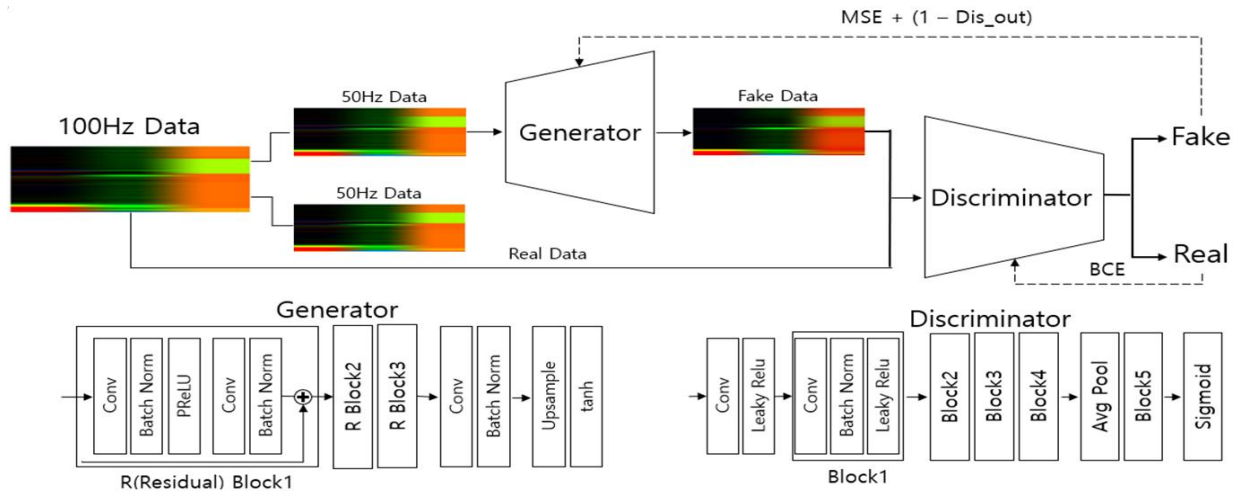


Fig. 6. GAN Process for K-EP Learning

2.3 MPL based model learning

본 연구에서는 반려동물 행동 분류 모델을 학습하기 위해 MPL 기법을 활용하였다. MPL 기법은 반지도 학습 방법 중 하나로, 비라벨 데이터의 활용을 극대화하여 모델의 성능을 향상시키는 데 중요한 역할을 한다. 이 방법은 라벨링된 데이터와 라벨링되지 않은 데이터를 함께 사용하여 모델을 학습시키며, 특히 비라벨 데이터의 잠재적인 정보를 효과적으로 활용할 수 있다. MPL 기법의 핵심 아이디어는 teacher 모델과 student 모델 간의 피드백을 통해 학습을 진행하는 것이다. 이 과정에서 teacher 모델은 비라벨 데이터에 대해 예측을 수행하고, 그 예측값을 pseudo label로 사용하여 student 모델을 학습시킨다. 자세한 학습 프로세스는 Fig. 7와 같다.

초기에는 teacher 모델을 라벨링된 데이터를 사용하여 학습한다. 이 모델은 비라벨 데이터에 pseudo label을 부여한다. 다음으로, student 모델은 teacher 모델이 생성한 pseudo label을 이용하여 지도학습을 진행한다. 이 과

정에서 student 모델은 pseudo label을 통해 비라벨 데이터의 정보를 학습하게 된다. pseudo label의 품질은 student 모델 학습의 효율성에 크게 영향을 미치므로, 높은 신뢰도를 가진 예측만을 사용하여 학습을 진행한다. 또한, pseudo label의 전체적인 신뢰성을 향상시키기 위해 피드백을 진행한다. student 모델의 예측을 피드백으로 이용하여 teacher 모델의 파라미터를 업데이트한다. 이러한 과정을 반복함으로써 teacher 모델은 더 높은 품질의 pseudo label을 생성하고, student 모델은 지속적으로 성능을 개선하게 된다.

MPL 기법은 다양한 데이터 증강 기법과 함께 사용되어 모델의 일반화 성능을 더욱 향상시킨다. 비라벨 데이터 증강을 통해 다양한 형태의 데이터를 학습한 모델은 더욱 강건한 특성을 가지며, 실제 환경에서 발생할 수 있는 다양한 변형에 대해 더 잘 대응할 수 있다.

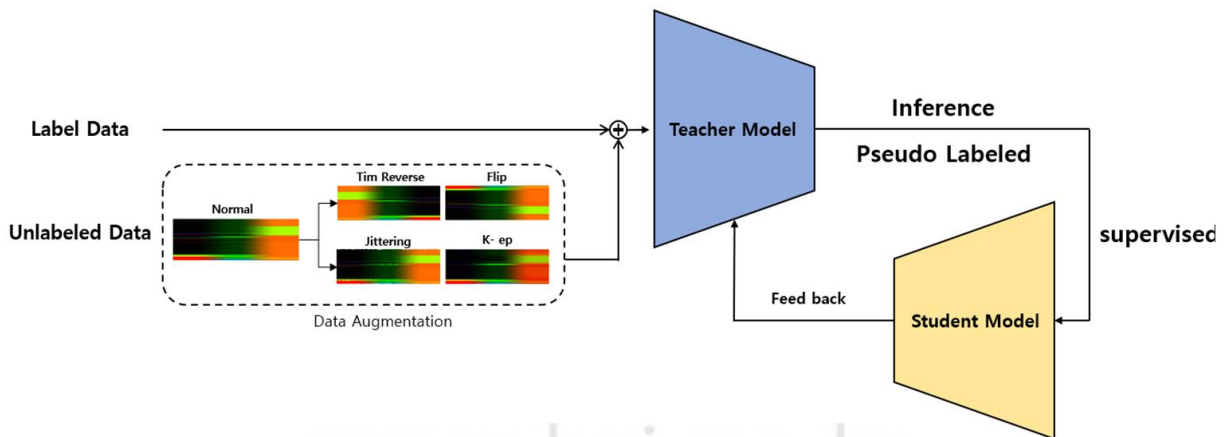


Fig. 7. MPL Learning Process for pet Behavior Classification Learning

3. Experiment

3.1 Experimental environment

모든 실험은 Pytorch를 이용하여 구현하였다. Table 1. 은 실험의 세부 사양을 나타낸다.

Table 1. Experimental Specifications

Metric	Description
CPU	AMD Ryzen 5800X
GPU	NVIDIA RTX 3090
RAM	64GB
CUDA	11.8
cuDNN	8.1
Torch	2.2.1
python	3.8.6

3.2 Data set

수집한 데이터는 Label Data로 활용하고 나머지는 UnLabeled Data로 활용한다. 모든 실험에서 사용한 데이터수는 Tabel 2.와 같다.

Table 2. Configuration Dataset

Behavior	N	Number of Data	proportion of data	Train Data	Test Data
Stand	0	2,007	25.62%	6264	1566
Walk	1	1,414	18.05%		
Sit	2	2,309	29.48%		
Lying	3	2,101	26.82%		
label Data		7,831	100%	80%	20%
Unlabeled		11,328	100%	100%	0%

3.3 Removing Inactive Data Using DeepSVDD

DeepSVDD를 이용한 실험은 라벨링된 데이터를 기준으로 학습을 진행한 후, 비라벨 데이터의 anomaly score를 계산하여 진행하였다. 이 과정에서 라벨링된 데이터를 이용해 정상 데이터의 분포를 학습하고, 비라벨 데이터에서 이상치를 탐지하였다. 테스트를 위해 라벨링된 데이터 영역에 비활성 데이터를 일부 추가하여 실험을 설계하였다. 정상 데이터는 7,831개의 라벨링된 데이터로 이루어졌으며, 여기에 1,656개의 비활성 데이터를 추가하여 이상치를 포함한 데이터셋을 만들었다. 비활성 데이터는 실제로 반려동물의 정상적인 행동 범주에 속하지 않는 데이터로 간주되며, 이를 통해 모델이 비정상적인 패턴을 얼마나 잘 식별할 수 있는지를 평가한다. DeepSVDD 모델은 정상 데이터의 분포를 학습하고, 학습된 모델을 사용하여 비활성 데이터에 대한 anomaly score를 계산한다. anomaly score는 각 데이터 포인트가 정상 데이터 분포에서 얼마

나 벗어나는지를 나타내는 지표로, 높은 anomaly score를 가진 데이터는 비활성데이터로 간주하고 제거한다.

실험 결과, Roc Auc score는 86.69%를 기록하였다. 실험 결과를 시각화하여 모델의 성능을 직관적으로 이해할 수 있도록 하였다. Fig. 9는 Roc Auc score를 시각화한 그래프이며, Fig. 10은 anomaly score의 분포를 밀도 그래프로 나타낸 시각화 자료이다.




Fig. 8. DeepSVDD Roc Auc Score Graph

Fig. 8는 Roc Auc score를 시각화한 그래프이다. 이 그래프는 False Positive Rate(FPR)와 True Positive Rate(TPR)의 관계를 나타내며, 곡선 아래의 면적(AUC)이 모델의 분류 성능을 나타낸다. 본 실험에서는 AUC가 0.87로 나타나, 모델의 분류 성능이 우수함을 보여준다.




Fig. 9. DeepSVDD density graph

Fig. 9은 anomaly score의 분포를 밀도 그래프로 나타낸 시각화 자료이다. 이 그래프는 정상 데이터(inliers)와 비활성 데이터(outliers)의 분포 차이를 명확히 보여준다. 그래프에서 파란색은 정상 데이터의 밀도를, 주황색은 비활성 데이터의 밀도를 나타낸다. 정상 데이터의 anomaly score는 주로 0에 가깝게 분포하며, 비활성 데이터의 anomaly score는 상대적으로 높은 값을 가지는 것을 확

인할 수 있다. 이는 DeepSVDD 모델이 정상 데이터와 비활성 데이터를 효과적으로 구분하고 있음을 알 수 있다.

DeepSVDD 밀도 그래프를 이용하여 추출한 임계값을 이용하여 비라벨 데이터를 분리하였다. Fig. 11은 임계치 값을 기준으로 비라벨 데이터를 inlier와 outlier로 분리한 결과를 보여준다.

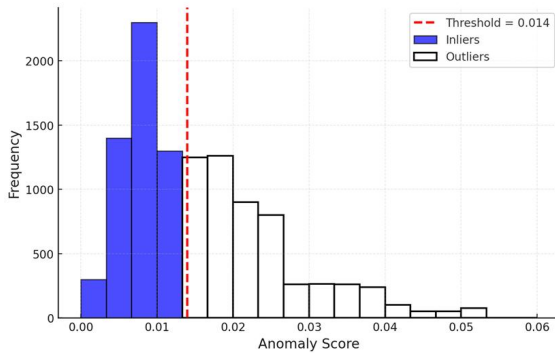


Fig. 10. DeepSVDD Distribution Graph

Fig. 10에서 점선은 임계값을 나타내며, 0.014로 설정되었다. 이 임계값은 정상 데이터와 비활성 데이터를 구분하는 기준으로 사용되었다. 임계치 값보다 작은 anomaly score의 막대그래프는 활성 데이터로, 임계치 값 보다 높은 anomaly score는 비활성 데이터로 제거되었다.

실험 결과, 총 11,328개의 비라벨 데이터 중에서 7,065개의 활성 데이터와 4,263개의 비활성 데이터를 추출할 수 있었다. 이 임계값을 통해 비활성 데이터는 이후의 학습 과정에서 제거되었으며, 이는 모델이 정상 데이터에 더 집중하여 학습할 수 있도록 하였다.

3.4 MPL Learning for Behavior Classification

3.4.1 MPL learning using Label Data only

본 연구에서는 반려동물 행동 인식을 위한 센서 데이터에서 MPL 방법이 유효한지 알아보기 위한 실험을 진행하였다. 실험의 첫 단계에서는 라벨링된 데이터만을 이용하여 모델을 학습시켰다. 이후, 라벨링된 데이터 집합 중 일정 비율을 임의로 선택하여 비라벨 데이터로 가정하고, 해당 데이터를 활용하여 추가 실험을 진행하였다. 실험 결과는 Table. 3과 같다.

Table 3. MPL Learning Results by Label Ratio

label Ratio	Aug	Test Loss	Acc (%)	F1_Score (%)
20 %	O	0.58	86.92	85.48
	X	0.51	85.62	83.97
40 %	O	0.43	89.03	88.12
	X	0.47	87.90	86.35
60 %	O	0.35	91.21	90.58
	X	0.43	90.12	89.19
80 %	O	0.37	90.39	89.56
	X	0.39	90.12	89.36
supervised	O	0.46	88.28	87.35
	X	0.58	86.92	85.48

실험 결과, 라벨링된 데이터의 비율이 증가함에 따라 모델의 성능이 전반적으로 향상되었다. 이는 라벨링된 데이터가 많을수록 모델이 더 정확하게 학습할 수 있음을 보여준다. 그러나, 일정 수준 이상의 라벨링 데이터를 추가하더라도 성능 향상은 이루어지지 않았으며, 60%의 라벨링 비율을 사용했을 때 가장 높은 성능을 보였다. 이는 모델이 일정 수준 이상의 라벨 데이터가 주어졌을 때 이미 충분한 학습을 하게 되어, 추가적인 라벨이 성능에 큰 영향을 미치지 않음을 의미한다.

또한, 라벨링된 데이터가 제한된 경우에도 MPL 기법은 효과적인 학습을 가능하게 했다. 예를 들어, 20%의 라벨링된 데이터만 사용한 경우에도 데이터 증강과 MPL 기법을 적용한 모델은 상대적으로 높은 성능을 보였다. 이는 MPL이 단순한 지도 학습 방식보다 효율적인 데이터 활용이 가능하며, 제한된 라벨 데이터만으로도 충분한 성능을 발휘할 수 있는 가능성을 보여준다. 특히, MPL은 교사 모델이 지속적으로 학생 모델을 최적화하는 방식으로 작동하기 때문에, 적은 라벨 데이터에서도 강력한 일반화 성능을 유지할 수 있었다.

특히, 라벨링 비용이 높은 상황에서 MPL 기법은 매우 유용한 접근 방식이 될 수 있다. 많은 도메인에서는 라벨링 작업이 시간과 비용이 많이 드는 과정이므로, 적은 양의 라벨 데이터를 효과적으로 활용할 수 있는 방법이 중요하다. MPL 기법은 이러한 문제를 해결할 수 있는 방법으로, 비교적 적은 라벨 데이터만으로도 지도 학습 수준의 성능을 낼 수 있음을 보여주었다. 이러한 결과는 MPL이 다양한 데이터셋과 환경에서 강력한 성능을 발휘할 수 있는 가능성을 시사하며, 실제 응용에서도 매우 유용한 기술이 될 수 있음을 의미한다.

데이터 증강을 적용한 경우 대부분의 라벨링 비율에서 Test Loss가 낮아지고, 정확도와 F1 Score가 높아졌다. 이는 데이터 증강이 모델의 일반화 성능을 향상시키는 데 중요한 역할을 한다는 것을 의미한다. 데이터 증강을 통해

모델은 다양한 데이터 변형을 학습할 수 있으며, 이는 실제 환경에서 발생할 수 있는 다양한 상황에 대한 대응력을 높이는 데 기여한다.

결론적으로, 본 연구의 실험 결과는 MPL 기법과 데이터 증강 기법을 함께 적용할 때, 반려동물 행동 분류 모델의 성능을 크게 향상시킬 수 있음을 나타낸다. 특히, 제한된 라벨링 데이터 환경에서도 MPL 기법이 효과적으로 작동하며, 기존의 지도 학습 방식보다 더 높은 일반화 성능을 보일 수 있음을 확인하였다. 이는 라벨링 비용과 시간이 중요한 실제 응용 환경에서 매우 유용한 접근 방식이 될 수 있으며, 라벨 데이터가 부족한 상황에서도 높은 성능을 유지할 수 있는 가능성을 보여준다. 또한, 향후 반려동물 행동 분석뿐만 아니라 다른 영상 기반 행동 분석 과제에도 활용될 수 있는 가능성을 제시한다.

3.4.2 MPL Learning for pet Behavior Classification

본 연구에서는 반려동물 행동 분류를 위해 MPL 학습 방법을 적용하였다. 이 과정에서 사용된 비라벨 데이터는 DeepSVDD에서 선택된 활성 데이터를 기반으로 하였다. 실험의 목적은 MPL 기법이 비라벨 데이터를 효과적으로 활용하여 모델 성능을 향상시키는지 평가하는 것이다.

실험에서는 DeepSVDD anomaly score를 기준으로 여러 배수를 설정하여 비라벨 데이터를 선택하였다. 구체적으로, train 데이터의 anomaly score에 대해 1.5배, 2.0배, 5.0배, 10.0배의 값으로 비라벨 데이터를 분류하고, 각 경우에 대해 MPL 학습을 진행하였다. 이 방법은 다양한 anomaly score 기준에서 비라벨 데이터를 선택하여 모델이 얼마나 효과적으로 학습할 수 있는지를 평가하는데 도움이 된다.

Table 4. MPL Learning Results on Anomaly Scores

Anomaly Score	Augmentation	Test Loss	Acc (%)	F1_Score (%)
x 1	○	0.41	90.25	89.45
	X	0.37	89.35	88.12
x 3.0	○	0.34	91.14	90.53
	X	0.41	90.87	90.09
x 5.0	○	0.35	91.28	90.65
	X	0.38	90.39	89.56
x 7.0	○	0.35	91.41	90.69
	X	0.35	90.66	89.88
x 10.0	○	0.36	89.57	88.66
	X	0.36	89.37	88.39
All UnLabeld	○	0.38	89.57	88.56
	X	0.47	88.82	87.81
Supervised	None	0.58	82.93	80.47

또한, 데이터 증강의 영향을 평가하기 위해 데이터 증강을 적용한 경우와 적용하지 않은 경우를 비교하였다. 데이터 증강은 모델의 일반화 성능을 향상시키기 위한 중요한 기법으로, 다양한 데이터 변형을 통해 모델이 더 넓은 범위의 패턴을 학습할 수 있도록 한다.

다양한 anomaly score 기준에서 비라벨 데이터를 선택하여 MPL 학습을 진행한 결과, 모델의 성능은 전반적으로 향상되었다. 특히, 데이터 증강을 적용한 경우 대부분의 anomaly score 배수에서 Test Loss가 낮아지고, 정확도와 F1 Score가 높아졌다.

Anomaly score 배수가 1.0배에서 7.0배 사이일 때, 데이터 증강을 적용한 모델은 가장 높은 성능을 보였다. 이 구간에서 Test Loss는 0.34에서 0.41 사이, 정확도는 89.57%에서 91.41% 사이, F1 Score는 88.66%에서 90.69% 사이의 값을 기록하였다. 이는 모델이 비라벨 데이터의 잠재적인 정보를 효과적으로 활용할 수 있음을 나타낸다. 특히, 7.0배 anomaly score에서는 비라벨 데이터가 적절한 수준의 변화와 다양성을 유지하면서도 학습 가능한 범위 내에 있었기 때문에, 모델이 기존에 보지 못한 패턴을 효과적으로 학습할 수 있도록 도와주었다. 이를 통해 일반화 성능을 향상시키는 데 기여한 것으로 나타났다.

또한, 데이터 증강을 적용한 경우와 적용하지 않은 경우의 성능 차이는 모델이 다양한 데이터 변형을 통해 더 넓은 범위의 패턴을 학습할 수 있음을 보여준다. Anomaly score 배수가 10.0배 이상인 경우와 모든 비라벨 데이터를 사용한 경우, 성능이 다소 감소하는 경향을 보였다. 이는 비라벨 데이터 중 일부가 모델 학습에 방해가 될 수 있는 노이즈 데이터를 포함할 가능성이 있음을 시사한다. 따라서, 적절한 anomaly score 기준을 설정하는 것이 중요하다.

지도 학습의 경우, MPL 기법과 데이터 증강을 적용한 모델에 비해 성능이 낮았다. 이는 비라벨 데이터의 활용과 데이터 증강이 모델의 성능 향상에 중요한 역할을 한다는 것을 의미한다. 결론적으로, MPL 기법과 데이터 증강 기법을 함께 적용함으로써, 반려동물 행동 분류 모델의 성능을 크게 향상시킬 수 있음을 확인할 수 있었다. 이러한 접근은 제한된 라벨링 데이터만으로도 높은 성능을 달성할 수 있는 가능성을 보여주며, 실제 응용 환경에서의 실용성을 뒷받침한다.

IV. Conclusions

본 연구에서는 반려동물 행동 분류를 위해 웨어러블 디바이스를 이용한 데이터 수집과 DeepSVDD를 이용한 데

이터 전처리를하여 MPL 기법을 결합한 새로운 접근 방식을 제안하고 그 유효성을 검증하였다. 웨어러블 디바이스를 통해 수집된 센서 데이터는 DeepSVDD를 활용하여 비활성 데이터를 제거하고, 나머지 데이터를 MPL 기법을 사용하여 학습함으로써 반려동물의 행동을 정확하게 분류할 수 있도록 하였다. 웨어러블 디바이스를 통해 다양한 반려동물 행동 데이터를 수집하고, 이를 기반으로 DeepSVDD를 사용하여 비활성 데이터를 제거하였다. 이 과정에서 anomaly score를 활용하여 정상 데이터와 비활성 데이터를 효과적으로 분리할 수 있었다. 이로써 학습 데이터의 품질을 향상시키고, 모델의 성능을 최적화할 수 있었다. 이후, 라벨링된 데이터와 DeepSVDD를 통해 활성 데이터로 분류된 비라벨 데이터를 MPL 기법을 통해 학습하였다. 실험 결과, MPL 기법은 라벨링된 데이터와 비라벨 데이터를 효과적으로 활용하여 모델의 성능을 향상시키는 데 크게 기여하였다. 특히, 데이터 증강을 함께 적용함으로써 모델의 일반화 성능이 더욱 향상되었음을 확인하였다.

구체적인 실험 결과를 통해, MPL 기법과 데이터 증강 기법을 함께 적용한 모델은 높은 정확도와 F1 스코어를 달성하였으며, 이는 반려동물 행동 분류에서의 실용성을 입증하였다. 특히, 제한된 양의 라벨링 데이터만으로도 우수한 성능을 발휘할 수 있는 가능성을 보여주어, 라벨링 비용이 높은 상황에서 매우 유용한 접근 방식임을 시사한다.

결론적으로, 본 연구는 웨어러블 디바이스와 반지도 학습 기법을 융합하여 반려동물 행동 분류의 새로운 가능성을 제시하였다. 이러한 접근 방식은 반려동물의 행동 모니터링 및 이상 행동 감지와 같은 실제 응용 분야에서 높은 활용 가치를 지니며, 향후 관련 연구 분야의 발전에 기여할 수 있을 것이다. 추후 연구에서는 다양한 반려동물 종류와 행동에 대한 데이터를 수집하고, 체온 센서나 심박 센서를 추가로 장착하여 더 폭넓은 헬스 모니터링 연구를 진행할 계획이다. 또한, 실시간 데이터 처리 및 분석 시스템을 구축하여 반려동물 모니터링 시스템의 실용성을 더욱 높일 예정이다.

ACKNOWLEDGEMENT

This research was supported by the Hoseo University research grant in 2025. This paper was supported by the National Research Foundation of Korea (NRF) grant funded by the Korea government (MSIT) (No. 2021R1A2C2011966).

REFERENCES

- [1] C. A. Aguilar-Lazcano, et al., "Machine learning-based sensor data fusion for animal monitoring: Scoping review," *Sensors*, Vol.23, No.12, pp.5732, 2023. DOI:10.3390/s23125732
- [2] S. J. Ikurior, et al., "What are sheep doing? Tri-axial accelerometer sensor data identify the diel activity pattern of ewe lambs on pasture," *Sensors*, Vol.21, No.20, pp.6816, 2021. DOI:10.3390/s21206816
- [3] R. Antanaitis, et al., "Preliminary experiment using sensors for cow health monitoring after surgical treatment for the left displacement of the abomasum," *Sensors*, Vol.20, No.16, pp.4416, 2020. DOI:10.3390/s20164416
- [4] R. Brugarolas, M. Ma, A. Tognetti, R. Bartalesi, F. Lorussi, and D. De Rossi, "Wearable heart rate sensor systems for wireless canine health monitoring," *IEEE Sensors Journal*, Vol.16, No.10, pp.3454-3464, 2015. DOI:10.1109/JSEN.2015.2485210
- [5] J. Ahn, Y. Lee, S. Park, and M. Lee, "Pet Buddy: A wearable device for canine behavior recognition using a single IMU," 2016 International Conference on Big Data and Smart Computing (BigComp), IEEE, pp.419-422, 2016. DOI:10.1109/BIGCOMP.2016.7425961
- [6] L. Alibrandi, F. Pelliccia, C. Guglielmini, and B. Contiero, "Smartphone-based six-lead ECG: A new device for electrocardiographic recording in dogs," *The Veterinary Journal*, Vol.303, pp.106043, 2024. doi:10.1016/j.tvjl.2023.106043
- [7] B. Hayden, H. S. Park, and J. Zimmermann, "Automated tracking of primate behavior," *arXiv preprint*, arXiv:2108.13486, 2021.
- [8] R. Vogg, et al., "Computer vision for primate behavior analysis in the wild," *arXiv preprint*, arXiv:2401.16424, 2024.
- [9] W. Kim, S. Kim, and H. Kwak, "Pet monitoring system using low-power protocol wearable devices," *Journal of the Korea Society of Computer and Information*, Vol.25, No.12, pp.17-23, 2020. DOI:10.9708/jksci.2020.25.12.017
- [10] B. Or, "Transformer-based dog behavior classification with motion sensors," *IEEE Sensors Journal*, Vol.24, No.20, pp.33816-33825, October 2024. DOI:10.1109/JSEN.2024.3454544
- [11] Y. Na, C. Choi, T. R. Han, and D. H. Kim, "Enhancing the convenience of pet health monitoring: A study on the design of unrestrained vital signal monitoring system," *Journal of Next-generation Computing and Communication*, Vol.19, No.3, pp.52-61, 2023. DOI:http://dx.doi.org/10.23019/kingpc.19.3.2023.06.005
- [12] Y. Seo, H. Kim, J. Moon, S. Lee, and K. Kim, "A study on the artificial intelligence-based wearable sensor data for pet behavior analysis," *Journal of the Korea Institute of Information Technology*, Vol.21, No.2, pp.33-41, 2023. DOI:10.14801/jkiit.2023.21.2.33
- [13] D. Wormald, et al., "Reduced heart rate variability in pet dogs

affected by anxiety-related behaviour problems," *Physiology & Behavior*, Vol.168, pp.122-127, 2017. DOI:10.1016/j.physbeh.2016.11.003

- [14] R. Brugarolas, et al., "Wearable heart rate sensor systems for wireless canine health monitoring," *IEEE Sensors Journal*, Vol.16, No.10, pp.3454-3464, 2015. DOI:10.1109/JSEN.2015.2485210
- [15] H. Pham, et al., "Meta pseudo labels," *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.1150-1159, 2021. DOI:10.1109/CVPR46437.2021.01150
- [16] L. Ruff, R. Vandermeulen, N. Goemitz, L. Deecke, S. A. Siddiqui, A. Binder, E. Müller, and M. Kloft, "Deep one-class classification," *Proceedings of the 35th International Conference on Machine Learning, Proceedings of Machine Learning Research*, Vol.80, pp.4393-4402, July 2018. Available: <https://proceedings.mlr.press/v80/ruff18a.html>

Authors



JunHyeok Go received the B.S. degrees in Computer Science and Engineering from Hoseo University, in 2023. B.S Go joined the Department of computer science at Hoseo University, asan, korea in 2023.

He is currently a Master in the Department of Computer Science, Hoseo University He is interested in Computer Vision, Object Detection, Image Generation.



Siung Kim received the B.S. degrees in Computer Science and Engineering from Hoseo University, in 2023. B.S Kim joined the Department of computer science at Hoseo University, asan, korea in 2023.

He is currently a Master in the Department of Computer Science, Hoseo University He is interested in Computer Vision, Object Detection, Image Generation.



JeongHyeon Park received the B.S. degrees in Computer Engineering from Hoseo University, Korea, in 2023. Park joined the Department of computer science at Hoseo University, asan, korea in 2023.

He is currently a Master in the Department of Computer Science, Hoseo Graduate School Asan, Korea, in 2023. He is interested in Data analysis and BigData.



Namme Moon received B.S, M.S., and ph.D. degrees in School of Computer Science and Engineering from Ewha Womans University in 1985, 1987 and 1998, respectively.

She served as an assistant professor at Ewha Womans University from 1999 to 2003. From 2003 to 2008, she is a professor of Department Digital Media, Graduate School of Seoul Venture Information. Since 2008, she is currently a professor in the Department of Computer Science and Engineering, Hoseo University. She is current research interests include Social Learning, HCI and User Centric Data, Big-data Processing and Analysis.