

# 감시 시스템에서 궤적 분류를 이용한 이상 탐지 방법

<sup>1</sup>서정훈, <sup>2</sup>황지인, <sup>3</sup>팔 아비셱, <sup>4</sup>이하은, <sup>5</sup>고대식, <sup>6\*</sup>송석일

## Anomaly Detection Method Based on Trajectory Classification in Surveillance Systems

<sup>10</sup>Jeonghun Seo, <sup>2</sup>Jiin Hwang, <sup>3</sup>Pal Abhishek, <sup>4</sup>Haeun Lee and <sup>5</sup>Daesik Ko, <sup>6\*</sup>Seokil Song

### 요약

최근의 감시 시스템은 카메라, 레이더 등 다양한 센서를 중복 사용하여 침입 탐지의 정확도를 향상시키려는 노력을 기울이고 있다. 그러나 야간, 악천후, 침입자의 위장 등으로 인해 카메라(RGB, Thermal) 센서를 통한 객체 인식이 정확하지 않을 때도 있다. 이러한 상황에서는 카메라나 레이더 센서를 통해 추출된 객체의 궤적을 활용하여 침입자를 탐지할 수 있다. 본 논문에서는 객체 인식이 어려운 환경에서 궤적 정보만을 이용하여 침입자를 탐지하는 방법을 제안한다. 제안하는 방법은 동물, 사람의 정상 및 비정상(침입, 배회) 궤적 데이터를 이용하여 LSTM-Attention 기반 궤적 분류 모델을 학습하고, 이 모델을 이용해서 사람의 비정상 궤적을 찾아내서 침입 탐지를 수행한다. 마지막으로, 제안하는 방법의 타당성을 실 데이터를 이용한 실험을 통해 입증한다.

### Abstract

Recent surveillance systems employ multiple sensors, such as cameras and radars, to enhance the accuracy of intrusion detection. However, object recognition through camera (RGB, Thermal) sensors may not always be accurate during nighttime, in adverse weather conditions, or when the intruder is camouflaged. In such situations, it is possible to detect intruders by utilizing the trajectories of objects extracted from camera or radar sensors. This paper proposes a method to detect intruders using only trajectory information in environments where object recognition is challenging. The proposed method involves training an LSTM-Attention based trajectory classification model using normal and abnormal (intrusion, loitering) trajectory data of animals and humans. This model is then used to identify abnormal human trajectories and perform intrusion detection. Finally, the validity of the proposed method is demonstrated through experiments using real data.

**Keywords:** Trajectory Classification, Surveillance System, LSTM, Attention, Deep Learning

<sup>1</sup> 한국교통대학교 컴퓨터공학과 학부과정(nne7741@naver.com)

<sup>2</sup> 한국교통대학교 컴퓨터공학과 학부과정(mf0d070208@gmail.com)

<sup>3</sup> 한국교통대학교 컴퓨터공학과 석사과정(abhi.palmain92@gmail.com)

<sup>4</sup> 한국교통대학교 컴퓨터공학과 석사과정(lhe\_97@a.ut.ac.kr)

<sup>5</sup> 목원대학교 전기전자공학과 교수(kds@mokwon.ac.kr)

<sup>6\*</sup> 교신저자 한국교통대학교 컴퓨터공학과 교수(sisong@ut.ac.kr)

Received: May. 31, 2024, Revised: Jun. 11, 2024, Accepted: Jun. 29, 2024

## I. 서론

보안 감시 시스템은 범죄 예방, 공공 안전, 이상행동 탐지를 위해 거리, 은행, 쇼핑몰, 공공기관, 군부대 등에서 사용이 증가하고 있다. 최근의 보안 감시 시스템은 카메라, 레이더, 열화상 카메라, 음향 등 다양한 센서를 통합하여 침입 탐지 성능을 높이려는 시도를 하고 있다. 이 시스템들은 불법 행위나 이상행동 같은 이벤트를 감지하기 위해 인간의 개입이 필요하다. 일반적으로 정상적인 활동에 비해 이상 이벤트는 드물게 발생하므로, 노동력과 시간을 절약할 수 있는 지능형 탐지 기법이 요구된다.

기존의 보안 감시 방법은 주로 카메라 센서를 중심으로 발전해왔으며, 컴퓨터 비전 및 딥러닝 기술을 활용하여 객체의 움직임을 감지하거나 인식하는 방식이 일반적이다. 예를 들어, CNN(Convolutional Neural Network)을 활용한 객체 검출 및 추적 기법은 많은 연구에서 사용되었으나, 악천후, 야간, 조명 문제, 침입자의 위장 등 여러 상황에서 객체 탐지 및 인식의 정확도가 감소하는 한계를 지닌다.

이를 극복하기 위해 궤적 분류를 통한 이상 탐지 기법이 제안되었다. 기존 연구들은 객체의 이동 궤적을 분석하여 배회, 도주 등 이상행동을 탐지하는 방법을 다루었다. 예를 들어, Hidden Markov Model(HMM)을 이용한 궤적 분석 기법은 정상 행동과 이상 행동을 구분하는 데 사용되었으나, 복잡한 환경에서의 실시간 처리에 어려움이 있었다[1]. 또한, SVM(Support Vector Machine) 기반 궤적 분류 방법은 궤적 패턴을 학습하여 비정상적인 행동을 탐지하는 데 활용되었으나, 데이터의 양과 질에 따라 성능이 크게 좌우되는 문제점이 있었다[2].

최근 제안된 딥러닝 기반 이상 탐지 방법으로 [3][4]가 제안된 바 있다. [3]에서는 열화상 카메라를 통해 수집한 궤적 데이터를 분석하여 배회 행동을 감지하는 방법을 제안하고 있다. 이 논문에서 제안한 방법은 궤적의 방향성, 속도, 머무름 시간을 이용하여 궤적의 기하학적 특징을 추출하고 이를 이용해 배회를 탐지한다. 하지만, 이 방법은 궤적의 전체적인 기하학적 특징을 이용하기 때문에 사람과 동물의 이동 패턴에서 발생하는 작은 차이를 구분하기 어려운 측면이 있다. [4]에서는 CNN 과 LSTM(Long Short-Term Memory)을 결합하여 비디오 프레임에서 배회 행동을 탐지하는 방법을 제안하고 있다. 이 방법은 궤적 데이터만 이용하는 것이 아니라 비디오 데이터를 이용하는 방법으로 궤적 데이터만 가능한 상황에서는 적용이 어렵다.

본 논문에서는 이러한 기존 연구들의 한계를 극복하고자, 객체 인식이 어려운 환경에서 카메라나 레이더를 통해 추출한 객체의 궤적을 분석하여 침입자를 탐지하는 방법을 제안한다. 카메라를 통해 객체의 종류를 정확하게 인식하지 못하더라도, 객체의 궤적을 추출할 수 있다. 또한, 카메라 사용이 어려운 경우 레이더와 같은 보조 센서를 이용하여 객체의 궤적을 추출할 수 있다. 궤적을 활용하는 방법은 보다 안정적이고 일관된 정보를 제공하며, 환경 요소의 변화에 덜 민감하고 저비용으로 감시 시스템을 구축할 수 있다는 장점이 있다. 또한, 제안하는 방법은 궤적 데이터를 구성하는 각 포인트 간의 가속도를 정규화하고 상대적 좌표 변화 계산 등의 전처리를 수행하여 객체의 이동 특성을 보다 분명히 하여 궤적 분류 정확도를 높인다.

본 논문에서는 공개된 사람의 이상행동 영상 데이터와 YouTube 등으로부터 동물 및 사람의 정상 및 이상(침입, 배회) 궤적 데이터를 생성하고 이미 기술한 바와 같이 객체의 이동특성을 분명하게 하는 전처리를 수행한다. 전처리를 수행한 학습 데이터를 LSTM-Attention[5] 기반의 궤적 분류 모델을 학습시킨다. LSTM 모델은 시계열 데이터의 장기 의존성을 처리하는 데 강점을 지니며, 어텐션(Attention) 메커니즘은 중요한 궤적 특징을 강조하여 모델의 성능을 향상시킨다. 학습된 모델을 통해 카메라 또는 레이더로 생성된 궤적을 실시간으로 분류하여 이상 궤적 탐지 성능을 측정한다.

본 논문은 다음과 같이 구성된다. 2장에서는 본 논문에서 제안하는 궤적 분류 기반 이상 탐지 방법을 데이터 수집, 분류모델, 학습 순서로 설명한다. 3장에서는 학습된 궤적 분류 모델에 대한 테스트를 통해 성능을 검증하고 4장에서 결론을 맺는다.

## II. 제안하는 궤적 분류기반 이상 탐지 방법

## 2.1 데이터 수집

본 논문에서는 AI Hub의 ‘이상행동 CCTV 영상[6]’ 데이터에서 사람의 정상 궤적과 이상행동(침입, 배회) 궤적을 추출한다. AI Hub의 ‘이상행동 CCTV 영상’ 데이터는 총 700시간 분량의 12가지의 이상행동(배회, 침입, 주취행동 등)이 포함된 영상 데이터를 제공한다. 이 논문에서는 경계 지역 감시 시스템을 가정하여 약 30시간 분량의 영상 데이터에서 배회 및 침투를 하는 사람의 궤적과, 정상적인 보행을 하는 사람의 궤적을 추출한다. 궤적 추출을 위해서 사전 학습된 객체 인식 모델인 YOLO v9[7]과 객체 추적 도구인 Bot-Sort[8]를 이용한다.

해당 영상에서 사람 객체를 인식하고 추적하여 생성한 객체의 궤적은 [frame\_no, timestamp, id, x, y, w, h, heading, speed, acceleration, macro\_class] 형식을 가진다. frame\_no는 영상에서 추출한 각 이미지의 프레임 번호를 의미하며, id는 Bot-Sort를 통해 추적하는 객체의 식별자이다. x와 y는 인식한 객체 바운딩 박스의 중심점으로 이미지의 가로 세로 픽셀(Pixel)로 표현된다. w와 h는 객체의 가로 세로 크기로 역시 픽셀 단위로 표현된다. 이 외에도 객체의 이동 방향을 의미하는 heading, 이동 속도를 의미하는 speed, 해당 객체의 이상행동 클래스를 의미하는 macro\_class가 궤적을 구성한다.

그림 1은 비디오 데이터에서 사람 궤적을 추출하는 예시를 보여준다. 그림에서 검은색 상하의 입을 사람이 배회하고 있으며 배회 궤적은 빨간색 점으로 표시된다. 나머지 사람들은 정상 궤적을 보이는 사람들이며 역시 빨간색 점으로 표시된다. 비디오 데이터에서 추출하는 배회와 침투 궤적은 모두 비정상(Abnormal)로 레이블링(Labeling)하였다.



Figure 1. Example of extracting human trajectories (Normal, Abnormal)

본 논문에서는 경계지역에 나타날 수 있는 동물을 분류하기 위해서 동물 궤적 데이터를 수집한다. 동물 궤적은 YouTube에서 다운로드한 10시간 분량 영상에서 경계지역에 나타날 수 있는 동물들(고라니, 멧돼지 등)에 한정해서 궤적을 추출하였다. 하지만, 사전 학습된 Yolo v9으로는 동물 객체 인식 정확도가 저하되는 문제가 있어 동물 데이터를 추가로 레이블링하여 Yolo v9에 대한 학습을 수행한다. 추가 학습을 통해서 미세 조정(Fine Tuning)된 Yolo v9 모델을 이용하여 Youtube 영상에서 동물 궤적을 추출한다.

동물 객체 인식 정확도 향상을 위해 Yolo v9모델 추가 학습에 사용된 데이터는 Florida Wildlife Camera Trap 데이터 집합[9]과 AI Hub “야생동물 활동 영상 데이터”[10]이다. 다음 표1은 각 데이터 집합에 대한 설명이다. 그림 2는 YouTube 데이터에서 동물을 추적하여 궤적을 생성하는 예시를 보여준다.

Table 1. Used data for fine tuning Yolo v9

Data Set	Description
Florida wildlife camera trap dataset [9]	Wildlife Camera Trap Classification Dataset Collected from Two Locations in Southwestern Florida This dataset comprises 104,495 images featuring visually similar species under various lighting conditions, including mammals, birds, and reptiles.
AI-Hub Wildlife Activity Video Dataset [10]	For nine mammal species (Chinese water deer, wild boar, Eurasian red squirrel, chipmunk, raccoon dog, Asiatic black bear, roe deer, mountain hare, weasel) and two bird species (grey heron, great egret), a total of 500 hours of raw data (videos) have been collected for both day and night, and across different types of equipment. Additionally, over 270,000 images have been annotated.



Figure 2. Example of extracting animal trajectories

표 2는 지금까지 설명한 궤적 추출 과정을 통해 생성한 사람의 Normal, Abnormal (침입, 배회), Animal 궤적의 수량과 길이를 보여준다. 상대적으로 Animal의 궤적이 많았다. 사람의 궤적의 경우 Normal 궤적 수량이 더 많았으나 길이는 Abnormal 궤적이 더 긴 것을 볼 수 있다. 본 논문에서는 이 궤적들로부터 객체의 이동 특성을 명확하게 할 수 있는 전처리 과정을 수행하고 특정 크기의 궤적단위로 분할하는 과정을 거쳐 학습을 진행한다.

Table 2. Number of extracted trajectories (Normal, Abnormal, Animal)

	Normal	Abnormal	Animal
Trajectory Count	151	101	286
Median Length	294	548	652
Avg Length	377.8	1081.02	949.26

## 2.2 수집한 사람 및 동물 궤적 데이터에 대한 전처리

추출한 궤적은 2차원 이미지 내의 픽셀 단위 위치를 기반으로 하고 있다. 서로 다른 비디오 데이터에서 추출한 궤적을 그대로 LSTM-Attention 분류 모델에 입력하는 것은 궤적의 이동 특징을 추출하는 데 한계가 있다. 이 과제에서는 궤적을 구성하는 포인트 데이터 간의 상대적 위치 변화(X, Y 축 Offset)를 계산하여 객체의 이동성 특징으로 변환하여 학습 데이터로 이용한다. 또한, 이 궤적 데이터의 각 포인트의 가속도를 최대 가속도로 나누어 정규화를 수행한다. 그림 3은 전처리된 궤적 데이터의 정규화된 가속도를 Abnormal, Normal 궤적들에 대해 색을 달리하고 가속도 크기에 따라 색의 농도를 다르게 표현한 것을 보여준다. 이 그림을 통해서 정상 보행하는 궤적과 배회 또는 침입을 하는 궤적의 가속도 변화가 다르게 나타남을 볼 수 있다.

그림 4는 전처리된 궤적 데이터의 위치를 포인트간 상대적 변위로 변환하여 표현한 것을 Abnormal과 Normal 궤적들에 대해 색을 달리하여 표현한 것이다. 그림에서 보는 것처럼 느린 보행과 배회가 유사한 특징을 보였으며 침입 궤적의 특징은 다른 궤적들과 다른 특성을 보이는

것을 확인할 수 있다. 이렇게 전처리를 수행하면 객체의 이동 특징을 명확히 할 수 있고 이를 이용해 궤적 분류 모델을 학습하면 분류 모델의 정확도를 높일 수 있다.

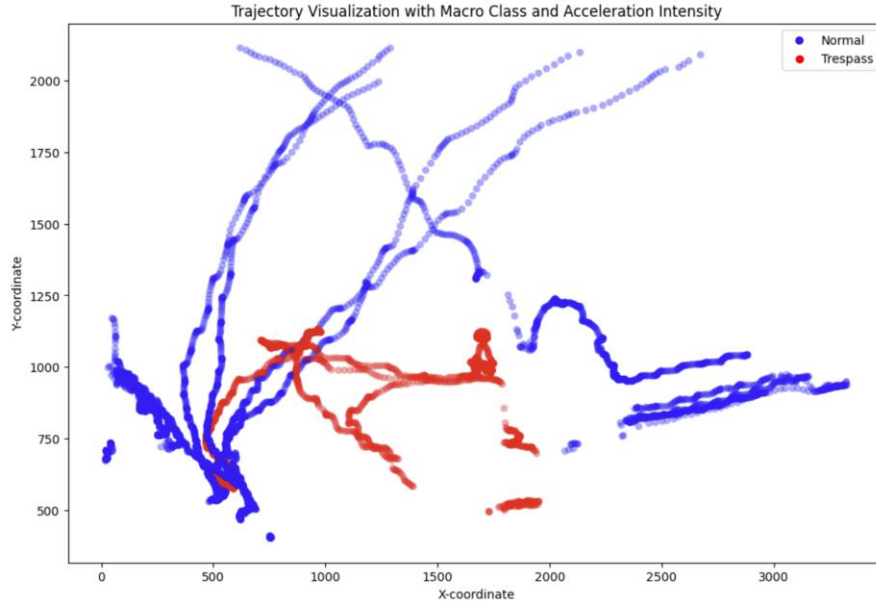


Figure 3. The preprocessed trajectory data is visualized with varying color intensities based on the magnitude of the acceleration

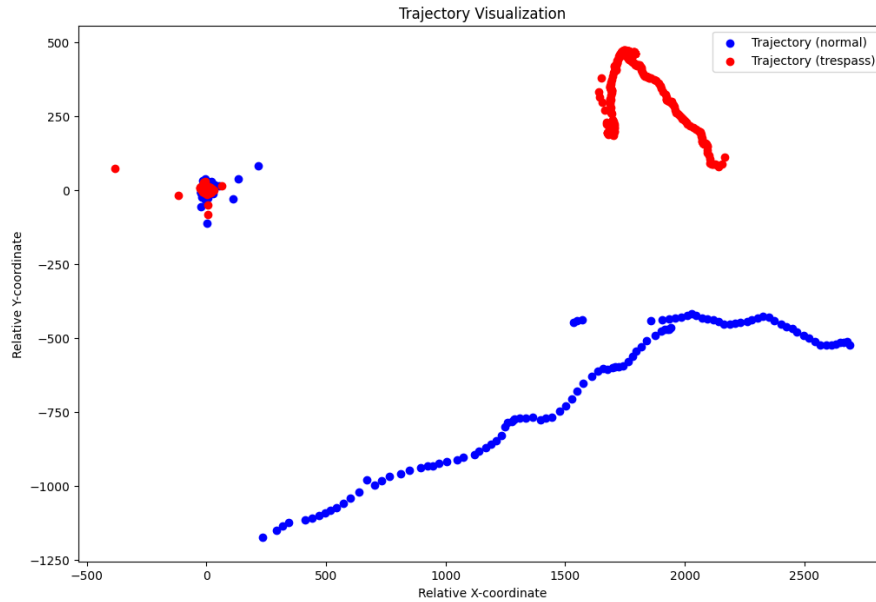


Figure 4. Visualization results of converting absolute positions to relative displacements of each point

### 2.3 궤적 분류 모델

본 논문에서는 궤적 분류를 위해 LSTM-Attention 모델을 사용하였다. 모델의 입력층은 (500, 6)의 형태를 가지며, 이는 각 궤적이 500개의 시퀀스로 구성되어 있고, 각 시퀀스가 6개의 특징 (x\_offset, y\_offset, heading, speed, norm\_acceleration, distance) 으로 구성됨을 의미한다. 궤적 시퀀스의 크기는 분류를 하는 단위이며 변경될 수 있다. 첫 번째 LSTM 층은 64개의 유닛을 가지며, 시퀀스를 유지하도록 설정되어 있다(return\_sequences=True). 이 층은 입력 데이터를



처리하고, 결과를 드롭 아웃(drop out) 층으로 전달하여 20%의 드롭 아웃을 적용한다. 이는 모델의 과적합을 방지하기 위한 것이며 변경이 가능한 파라미터이다. 두 번째 LSTM 층도 64개의 유닛을 가지며, 동일하게 시퀀스를 유지한다. 이 층의 출력 역시 드롭 아웃 층으로 전달되어 20%의 드롭 아웃이 적용된다.

Attention 층은 드롭 아웃 된 출력과 두 번째 LSTM 층의 출력을 입력으로 받아, 중요한 시퀀스 특징을 강조하는 역할을 한다. 이 Attention 층의 출력은 드롭 아웃 된 출력과 결합되어 (Concatenate) 다음 층으로 전달된다. 결합된 출력은 TimeDistributed(Dense(128, activation='relu')) 층을 거쳐 각 시퀀스에 대해 128개의 은닉 유닛을 가진 Dense 층을 적용한다. 마지막 출력층은 3개의 클래스(Normal, Abnormal, Animal) 를 분류하기 위해 소프트맥스 (Softmax) 활성화 함수를 사용하는 Dense 층으로 구성되어 있다. 모델은 Adam 옵티마이저와 categorical\_crossentropy 손실 함수를 사용하여 컴파일 되었으며, 정확도를 평가 지표로 사용한다.

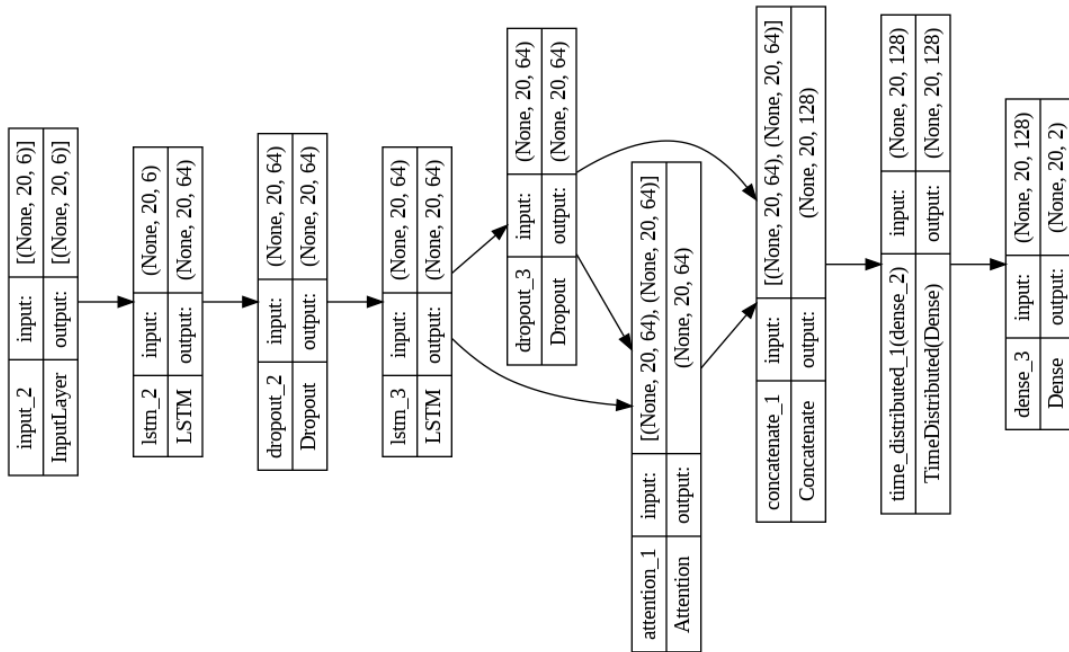


Figure 5. Architecture of LSTM-Attention model for trajectory classification

### III. 제안하는 궤적 분류 기반의 이상탐지 성능

#### 3.1 실험 환경

본 논문의 성능평가에 사용된 사용된 하드웨어 및 소프트웨어 환경은 표 3과 같다. 실험에 사용된 하드웨어는 Intel i5 14600K 프로세서, DDR5 32GB 메모리, Nvidia RTX 3060 12GB 그래픽 카드, 그리고 Samsung 980 Pro 2TB SSD 이다. 소프트웨어로는 Ubuntu 22.04 LTS 운영 체제, Python 3.11.7, Cuda 12.2 및 cudnn 8.9.7, 그리고 Tensorflow 2.15.0이 사용되었다.

Table 3. Experimental environments

H/W	S/W
Intel i5 14600K	Ubuntu 22.04 LTS
DDR5 32GB	Python 3.11.7
Nvidia RTX 3060 12GB	Cuda 12.2 + cudnn 8.9.7
Samsung 980 Pro 2TB	Tensorflow 2.15.0

표 4는 본 논문에서 학습에 사용된 하이퍼 파라미터(Hyper Parameter)를 보여준다. 학습은 500 에포크(epoch) 동안 수행되었으며, 배치 크기는 32로 설정되었다. 활성화 함수로는 ReLU(Rectified Linear Unit)와 Softmax 가 사용되었다. 옵티마이저는 Adam 을 사용하였으며, 손실 함수로는 categorical crossentropy 가 적용되었다. 모델의 과적합을 방지하기 위해 드롭아웃(dropout) 비율은 0.2로 설정되었다. 모델의 성능 평가는 정확도(Accuracy)를 기준으로 하였다.

Table 4. Hyper parameters

Parameters	Value
epoch	500
batch size	32
Activation Function	Relu, Softmax
Optimizer	adam
Loss Function	categorical crossentropy
Dropout	0.2
Test Method	Accuracy

### 3.1 궤적 분류 모델 테스트 결과

궤적 분류 기반 이상탐지 모델은 표 2에서와 같은 Normal(사람), Abnormal(사람), Animal 클래스가 부여된 궤적 데이터로 학습된다. 이 궤적 데이터는 객체 인식이 불가능한 환경에서 객체 유형이 없는 궤적 데이터를 의미한다. 이러한 데이터를 이용해 궤적 데이터 분류 실험을 수행한 결과, 표 5와 같은 혼동행렬(Confusion Matrix)를 보였다. 분류는 3개 클래스(Normal, Abnormal, Animal)에 대해서 수행했지만, 이 시스템의 목적은 Abnormal 사람 궤적을 찾는 것이므로 Abnormal 을 True, 나머지 Class 를 False 로 하여 계산을 수행하였다.

표 6은 Abnormal 과 Others(Normal, Animal)에 대한 혼동 행렬을 보여준다. 표 6의 혼동 행렬로부터 표 7에서 보는 바와 같이, 궤적 분류를 통해 Abnormal(침입, 배회) 궤적을 탐지하는 성능을 측정하였다. 이 표에서 보는 바와 같이 F1-Score 가 0.96로 매우 높은 정확도를 보였다. 다만 Precision 이 Recall 에 비해 다소 낮은 것을 볼 수 있는데, 이는 False Negative 가 상대적으로 높다는 것을 의미한다. 특히, 표 5를 보면 Abnormal 궤적을 Normal 궤적으로 탐지하는 경우가 전체에서 549건임을 알 수 있다. 이는 Abnormal 궤적을 놓치는 사례가 상대적으로 높음을 의미한다.

Table 5. Confusion matrix ((Normal, Abnormal, Animal)

	Normal	Abnormal	Animal	Total
Normal	4,422	549	1	4,972
Abnormal	178	9,041	1	9,220
Animal	3	23	7,126	7,152
Total	4,603	9,613	7,128	21,344

Table 6. Confusion matrix (Abnormal, Others : Normal&amp;Animal)

	Abnormal	Others	Total
Abnormal	9041	179	9220
Others	572	11552	12124
Total	9613	11731	21344

Table 7. Test results

Metrics	Value
Accuracy	0.9648
Recall	0.9806
Precision	0.9405
F1-Score	0.9601

## IV. 결론

본 논문에서는 객체 인식이 어려운 환경에서 카메라나 레이더를 통해 추출한 객체의 궤적을 분석하여 침입자를 탐지하는 방법을 제안하였다. 제안하는 방법은 궤적 데이터를 구성하는 각 포인트 간의 가속도를 정규화하고 상대적 좌표 변화 계산 등의 전처리를 수행하여 객체의 이동 특성을 보다 분명히 하여 궤적 분류 정확도를 높인다. 본 논문에서는 직접 수집한 사람 Normal, 사람 Abnormal, Animal. 3개 클래스의 궤적 데이터를 이용해서 LSTM-Attention 을 학습하고 테스트를 수행하여 성능을 확인하였다. 성능평가 결과 F1-Score.기준으로 0.9601의 높은 정확도를 보였다.

실험 결과를 보면 제안하는 방법은 동물과 사람이 혼재하는 경우에 사람의 이상행동을 탐지하는 감시시스템에 충분히 적용 가능함을 확인할 수 있다. 향후 연구에서는 궤적에서 배회와 같은 이상을 탐지하는 기존 방법과의 비교를 통해서 제안하는 방법의 상대적인 우수성을 보여줄 계획이다.

## V. 감사의 글

방위사업청에서 지원한 23년 국방벤처지원사업(V230009)의 연구결과로 작성된 논문입니다.

## VI. 참고문헌

- [1] L. Kratz and K. Nishino, "Anomaly detection in extremely crowded scenes using spatio-temporal motion pattern models," in Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), Miami, FL, 2009, pp. 1446-1453.
- [2] H. Fu, S. Zhou, Z. Li, and D. Y. Yeung, "Robust Anomaly Detection in Videos Using Multilevel Representations," in Proc. of the 28th AAAI Conf. on Artificial Intelligence, Québec, Canada, 2014, pp. 1717-1723.
- [3] J. Núñez, Z. Li, S. Escalera, and K. Nasrollahi, "Identifying Loitering Behavior With Trajectory Analysis," in Proc. of the IEEE/CVF Winter Conf. on Applications of Computer Vision (WACV) Workshops, 2024, pp. 251-259. Available: [https://openaccess.thecvf.com/content/WACV2024W/RWS/html/Nunez\\_Identifying\\_Loitering\\_Behavior\\_With\\_Trajectory\\_Analysis\\_WACVW\\_2024\\_paper.html](https://openaccess.thecvf.com/content/WACV2024W/RWS/html/Nunez_Identifying_Loitering_Behavior_With_Trajectory_Analysis_WACVW_2024_paper.html)
- [4] M. Hasan, J. Choi, J. Neumann, A. K. Roy-Chowdhury, and L. S. Davis, "Learning Temporal 4Regularity in Video Sequences," in Proc. of the IEEE Conf. on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, 2016, pp. 733-742.
- [5] . Wang, C. Ma, Y. Qiao, X. Lu, W. Hao, and S. Dong, "A hybrid deep learning model with 1DCNN-LSTM-Attention networks for short-term traffic flow prediction," Physica A: Statistical Mechanics and its Applications, vol. 583, p. 126293, 2021.
- [6] AI-Hub, "AI-Hub Data," Available: <https://www.aihub.or.kr/aihubdata/data/view.do?dataSetSn=171>. [Accessed: Apr. 20, 2024].
- [7] C.-Y. Wang, I.-H. Yeh, and H.-Y. M. Liao, "YOLOv9: Learning What You Want to Learn Using Programmable Gradient Information," arXiv preprint arXiv:2402.13616, 2024.
- [8] N. Aharon, R. Orfaig, and B.-Z. Bobrovsky, "BoT-SORT: Robust associations multi-pedestrian tracking," arXiv preprint arXiv:2206.14651, 2022.
- [9] AI-Hub, "AI-Hub Data," Available: <https://www.aihub.or.kr/aihubdata/data/view.do?dataSetSn=171>. [Accessed: Apr. 20, 2024].
- [10] Florida Wildlife Camera Trap Dataset, Available: <https://www.crcv.ucf.edu/research/projects/florida-wildlife-camera-trap-dataset/>. [Accessed: Apr. 20, 2024].



## 저자소개



**서정훈 (Jeonghun Seo)**

2019년 2월 ~ 현재 : 한국교통대학교 컴퓨터공학과 학사과정

관심분야 : 인공지능, 컴퓨터 비전



**황지인 (Jiin Hwang)**

2021년 2월 ~ 현재 : 한국교통대학교 컴퓨터공학과 학사과정

관심분야 : 인공지능, 데이터 사이언스



**팔 아비셴 (Pal Abhishel)**

2018년 2월 Sabita Devi Education Trust 컴퓨터공학과(공학사)

2022년 8월 ~ 현재 : 한국교통대학교 대학원 컴퓨터공학과(공학석사)

관심분야 : 인공지능



**이하은 (Haeun Lee)**

2022년 8월 : 한국교통대학교 컴퓨터공학과(공학사)

2022년 8월 ~ 현재 : 한국교통대학교 대학원 컴퓨터공학과 석사과정

관심분야 : 인공지능, GNN, 자연어처리



**고대식 (Daesik Ko)**

1991년 2월 : 경희대학교 전자 공학과(공학박사)

1989년 ~ 2022 : 목원대학교 전자공학과 · 지능정보융합과 교수

2023 ~ 현재 : 토탈시스 대표

관심분야 : ICT 융합, 사물인터넷, 신호처



**송석일 (Seokil Song)**

2000년 2월 : 충북대학교 정보통신공학과(공학석사)

2003년 2월 : 충북대학교 정보통신공학과(공학박사)

2003년 7월 ~ 현재 : 한국교통대학교 컴퓨터공학과 교수

관심분야 : 데이터베이스, 센서 네트워크, 스토리지 시스템 등