

스마트 축사내 상황인지 자율이동형 환경센서 개발 및 가축행동 분석에 관한 연구

(A Study on the Development of Autonomous Mobile Environmental Sensors and Livestock Behavior Analysis for Situation Awareness in Smart Barns)

김석훈*, 김남호**

(Suk-Hun Kim, Nam-Ho Kim)

요약

본 연구는 스마트 축사 내에서 자율주행 시스템을 활용하여 가축의 행동 패턴과 환경 데이터를 기반으로 소의 질병 유무를 예측하는 시스템을 개발하는 것을 목표로 한다. 외부 기기(RFID 태그 등) 없이 순수 카메라 영상만을 이용해 각 소의 고유 ID를 유지하는 것이 필수적이며, 이를 통해 소별로 시간대에 따른 서기, 앉기, 누워있기 등의 행동 패턴을 추적할 수 있다. 또한, 온도, 습도와 같은 환경 데이터를 통합하여 소의 건강 상태를 종합적으로 평가한다. 이를 위해 YOLO를 이용한 객체 탐지, Deep SORT를 이용한 추적, 그리고 ReID를 이용한 재식별 알고리즘을 결합한 고유 ID 유지 알고리즘을 제안하였다. 실험 결과, YOLO + Deep SORT + ReID 알고리즘이 고유 ID 유지 성능에서 가장 우수한 결과를 보였으며, LSTM 기반 행동 분석 모델이 행동 패턴 예측에서 높은 정확도를 나타내었다. 본 연구의 시스템은 축사 내부의 환경 데이터와 행동 패턴을 종합적으로 분석하여 가축의 질병이나 스트레스 상태를 실시간으로 예측할 수 있는 효과적인 도구로 활용될 수 있을 것이다.

■ 중심어 : 스마트 축사 ; 고유ID유지 ; 딥-소트 ; 행동패턴분석

Abstract

This study aims to develop a system that predicts the health status of cattle based on behavior patterns and environmental data within a smart barn using an autonomous driving system. Maintaining a unique ID for each cow using only a camera, without external devices (such as RFID tags), is essential. This enables the tracking of behavior patterns such as standing, sitting, and lying for each cow over time. Additionally, environmental data such as temperature and humidity are integrated to comprehensively assess the cows' health conditions. To achieve this, we propose a unique ID retention algorithm that combines object detection using YOLO, tracking with Deep SORT, and re-identification (ReID). Experimental results show that the YOLO + Deep SORT + ReID algorithm delivers the best performance in maintaining unique IDs, and the LSTM-based behavior analysis model demonstrates high accuracy in predicting behavior patterns. This system can serve as an effective tool for real-time prediction of livestock health conditions, such as disease or stress, through comprehensive analysis of environmental data and behavior patterns inside the barn.

■ keywords : Smart Barn ; Unique ID Retention ; Deep SORT ; Behavior Pattern Analysis

I. 서론

스마트 축사 관리 시스템은 가축의 건강을 실시간으로 모니터링하고, 이를 통해 질병을 조기에 감지하여 관리 비용을 줄일 수 있는 역할 수행이 필요하다.

* 학생회원, 호남대학교 컴퓨터공학과

** 정회원, 호남대학교 컴퓨터공학과

본 논문은 2024년도 교육부의 재원으로 한국연구재단의 지원을 받아 수행된 지자체-대학 협력기반 지역혁신사업의 결과입니다. (2021RIS-002)

접수일자 : 2024년 09월 23일

재제확정일 : 2024년 10월 15일

수정일자 : 1차 2024년 10월 07일, 2차 2024년 10월 15일

교신저자 : 김남호 e-mail : nhkim@honam.ac.kr

다. 특히, 가축의 행동 패턴을 정확히 분석하는 기술은 가축의 스트레스 수준, 건강 상태, 그리고 환경에 대한 반응을 파악하는 데 매우 중요한 요소로 기존의 연구들은 주로 RFID와 같은 외부 기기를 사용하여 개체를 식별하고, 가축의 행동을 분석하는 방식을 채택해 왔다. 하지만, 이러한 접근 방식은 설치 비용과 유지 보수에 있어서 한계가 있고, 외부 장치는 가축이 움직이거나 손실될 가능성이 있어, 장치 없이 개체를 정확하게 식별하는 기술의 필요성이 제기되고 있다.

기존 연구의 한계점은 크게 두 가지로 요약될 수 있다. 첫째, RFID나 다른 외부 장치에 의존하는 시스템은 축사 관리 비용을 증가시키며, 대규모 사육 환경에서는 이러한 비용이 더욱 부담으로 작용할 수 있다. 둘째, 외부 장치를 사용하지 않더라도, 카메라 기반의 객체 탐지 기술만으로는 개체 간의 고유 ID를 일관되게 유지하는 것이 어렵다. 소와 같은 가축은 외형적으로 유사한 개체들이 많기 때문에, 프레임 간 일관되게 개체를 추적하는 것은 기술적으로 복잡한 문제다. 기존의 카메라 기반 연구들은 주로 객체 탐지에 중점을 두었으며, 프레임 간 일관된 ID 유지에 대해서는 미흡한 성과를 보였다.

이러한 한계점들을 해결하기 위해 본 연구는 외부 장치 없이도 카메라만을 사용하여 소의 고유 ID를 일관되게 유지하고, 이를 바탕으로 가축의 행동 패턴을 분석 및 건강 상태를 예측하는 시스템을 제안한다. 특히, 비접촉식 시스템으로 외부 장치의 의존성을 없애므로 축사 관리 비용을 줄이고, 효율적인 대규모 축산 관리를 가능하게 하는 실용적인 해결책을 제시한다. 이러한 시스템은 스마트 축사 관리에서 새로운 표준을 제시할 수 있을 것으로 기대된다.

II. 기존 연구 및 이론적 배경

1. Deep SORT 알고리즘

Deep SORT는 YOLO와 같은 객체 탐지 알고리

즘에서 제공하는 Bounding Box 좌표를 기반으로 객체를 지속적으로 추적하는 알고리즘으로 Deep SORT는 Kalman 필터와 Hungarian 알고리즘을 결합하여 객체의 위치와 속도를 예측하고, 각 객체에 고유한 ID를 부여하여 프레임 간 일관된 객체 추적을 가능하게 한다[1-2]. Kalman 필터는 이전 상태를 바탕으로 객체의 현재 위치를 예측하는 수학적 모델로, 객체가 시야에서 벗어났다 다시 등장하더라도 그 움직임을 예측하여 연속적인 추적을 지원한다[3]. 이 필터는 프레임 사이의 객체 이동을 예측하여 객체가 시야를 잠시 벗어날 경우 일관된 추적 성능을 유지할 수 있다. Hungarian 알고리즘은 프레임 간 객체 매칭을 최적화하는 알고리즘으로, 프레임이 변화할 때마다 객체들의 최적의 매칭을 찾아내어 각 객체의 고유 ID를 정확히 유지한다[4]. 이를 통해 여러 객체가 이동하는 다중 객체 추적 상황에서도 안정적인 성능을 발휘한다. 특히, 축사 환경과 같이 객체(가축)가 빈번히 이동하고 시야를 벗어날 가능성이 높은 상황에서는 Deep SORT가 일관된 객체 추적을 위해 고유 ID를 유지하며 추적할 수 있어, 소의 행동 패턴 분석 및 질병 예측과 같은 응용에 중요한 역할을 할 수 있다.

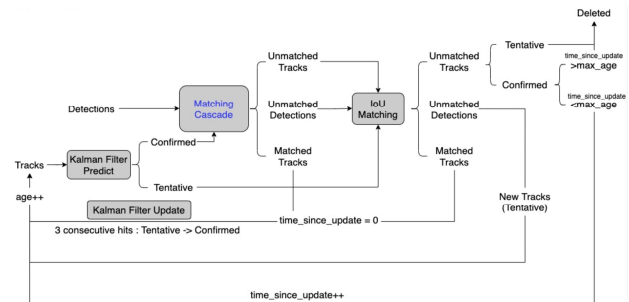


그림 1. Deep-SROT 알고리즘

2. ReID 알고리즘

ReID는 객체가 프레임 간 사라졌다가 다시 등장할 때, 동일한 객체임을 인식하는 기술로 ReID는 딥러닝 기반으로 각 객체의 고유한 시각적 특징을 학습한 후, 추적 알고리즘이 일관된 고유 ID를 유지할 수 있도록 돕는다[5]. 이는 객체가 다양한 각도와 조명 변화에서 다시 나타나더라도 동일한 객체로 인식

할 수 있는 성능을 제공한다. 예를 들어, 축사 환경에서 소가 움직여 시야를 벗어났다가 다시 등장할 때, ReID는 해당 소의 고유 시각적 특징을 바탕으로 동일한 소임을 정확하게 인식한다. ReID의 작동 원리는 주로 CNN(Convolutional Neural Network)을 기반으로 하며, 객체의 색상, 형태, 텍스처 등의 시각적 정보를 학습하여 이를 특징 벡터(Feature Vector)로 변환한다. 이러한 특징 벡터는 각 객체의 시각적 특징을 수치화한 데이터로, ReID 알고리즘은 새로운 프레임에서 등장한 객체의 특징 벡터와 이전에 저장된 벡터를 비교하여 유사도(Similarity)를 계산한다. 만약 유사도가 높으면 동일 객체로 인식하고, 그렇지 않으면 새로운 객체로 인식하게 된다.




그림 2. ReID 알고리즘

(1) 특징 벡터 생성

ReID 모델은 각 객체의 시각적 특징을 벡터로 변환한다. 이 벡터는 객체의 모양, 크기, 색상 등을 수치화하여 객체를 인식할 수 있는 기반 데이터를 제공한다.

(2) 유사도 매칭

새로운 프레임에서 등장한 객체의 특징 벡터를 이전 프레임에서 저장된 객체의 벡터와 비교한다. 유사도가 높으면 동일 객체로 인식하고, 유사도가 낮으면 새로운 객체로 간주한다.

본 연구에서는 소의 행동 패턴을 실시간으로 추적하고 분석하기 위해 Deep SORT와 ResNet50 기반 ReID를 선택하였다. Deep SORT는 시각적 특징을 반영하여 ID 전환을 최소화할 수 있었고, ResNet50은 상대적으로 가벼운 구조와 높은 정확도를 제공하면서도 실시간 성능을 보장할 수 있다. 이러한 이유로 Deep SORT와 ResNet50 기반 ReID는 본 연구에 가장 적합한 방법으로 판단되었다.

3. 행동 패턴 분석

(1) CNN(Convolutional Neural Network)

이미지 데이터를 처리하는 데 매우 적합한 딥러닝 모델로, 소의 행동 패턴을 분석하는 데 널리 사용되고 있다. CNN 기반 연구는 주로 영상 데이터에서 객체의 특징을 학습하는 데 사용되며, 국내 연구에서는 CCTV 영상 분석에서 보행자의 동작을 분류하거나 스포츠 경기에서 선수들의 움직임을 분석하는 데 사용되고 있다. 해외에서는 의료 영상 분석이나 자율주행 차량의 환경 인식에 CNN이 활용되고 있다[6].

(2) RNN/LSTM

시간적 데이터, 즉 시계열 데이터를 분석하는 데 적합한 모델로 RNN(Recurrent Neural Network)은 연속된 프레임에서의 행동 변화를 학습할 수 있으며, LSTM(Long Short Time Memory)은 긴 시간 동안의 행동 패턴을 기억할 수 있는 장점이 있다. 국내 연구에서는 스마트 헬스케어 시스템에서 환자의 행동 패턴을 분석하는 데 RNN과 LSTM을 활용한 사례가 있으며, 해외에서는 스마트 축사나 스마트 홈에서 가축이나 사람의 장기적인 행동 패턴을 학습하고 예측하는 연구가 활발히 진행되고 있다.

이러한 알고리즘들을 결합하여 소의 행동 패턴을 예측하고, 고유 ID를 일관되게 유지하는 시스템을 개발함으로써 국내외에서 다양한 분야에서 활용된 객체 탐지, 추적, 그리고 행동 분석 알고리즘을 스마트 축사 환경에 맞춰 적용함으로써, 본 연구는 기존 연구들과 차별화된 성과를 제시하고자 한다.

III. 실험설계 및 방법론

1. 데이터 수집

본 연구에서는 축사 내부 CCTV 영상을 통해 소의 행동 패턴을 분석하기 위한 데이터를 수집하였다. 각 CCTV 카메라는 축사 내에서 소의 다양한

움직임을 포착할 수 있도록 설치되었으며, 데이터는 24시간 동안 연속적으로 기록되었다. 주로 소의 서기(standing), 앉기(sitting), 누워있기(lying)와 같은 기본적인 행동 패턴을 수집하였고, 축사 환경의 다양한 조명 조건과 다양한 카메라 각도에서 데이터를 확보하였다. 이러한 다양한 환경 조건은 모델이 보다 일관된 성능을 낼 수 있도록 훈련 데이터를 풍부하게 만들기 위함이다.



(서기) (앉기) (누워있기)

그림 3. 데이터 수집

2. 데이터 전처리

표 1. 데이터 전처리 순서

| 작업 | 설명 |
|-----------|--|
| 프레임 추출 | - CCTV 영상을 프레임 단위로 분할 - 초당 5~10 프레임 |
| 프레임 크기 조절 | - 해상도를 640x480 또는 512x512로 조정 - 계산량을 줄임 |
| 프레임 정제 | - 중복 프레임, 노이즈 있는 프레임 제거 |

수집된 CCTV 영상은 프레임 단위로 나누어 전처리하였다. 1초당 5~10프레임으로 영상을 분할하여 각 프레임에서 소의 행동을 정확히 분석할 수 있도록 하였다. 각 프레임은 RGB 이미지로 변환되어 딥러닝 모델의 입력 데이터로 사용되었으며, 모델 학습 속도를 향상시키기 위해 프레임 해상도를 640x480으로 조정하였다.

중복된 프레임이나 노이즈가 있는 프레임은 제거하였으며, 이를 통해 의미 있는 행동 데이터만을 학습 데이터로 남겼다. 특히, 라벨링 작업을 통해 소의 행동 패턴(서기, 앉기, 누워있기)을 키포인트(Keypoint) 형식으로 저장하였다.

각 키포인트는 소의 머리, 목, 다리 등 주요 관절의

x, y 좌표로 기록되었으며, 이러한 정보는 딥러닝 모델이 소의 행동을 시각적으로 분석하는 데 중요한 입력값으로 사용되었다.

3. 데이터 라벨링

(1) 키포인트

영상에서 소의 행동 패턴을 분석하기 위해, 각 소의 몸의 주요 관절(머리, 목, 다리, 허리 등)을 키포인트로 표시한다. 키포인트들은 자세를 인식하는 데 중요한 역할을 하며, 객체의 자세 변화를 감지하는데 유용하다.

(2) 세가지 행동 패턴

표 2. 세가지 행동 패턴 라벨링

| 행동구분 | 설명 |
|------|--------------------|
| 서기 | 소가 직립한 자세로 있을 때 |
| 앉기 | 소가 다리를 굽히고 앉은 자세 |
| 누워있기 | 소가 완전히 바닥에 누워있는 자세 |

4. 데이터 분할

학습/검증/테스트 데이터 분할을 통하여 전체 데이터를 학습(Train), 검증(Validation), 테스트(Test) 데이터로 나누어 각 단계에서 모델 성능을 평가할 수 있도록 한다.

표 3. 모델 파라미터

| 모델 | YOLOv8 | ResNet50(ReID) | Deep SROT |
|------------------|---------|--------------------|-------------------|
| 이미지크기 | 640*480 | 224*224 | N/A |
| Batch Size | 16 | 43 | N/A |
| Learning Rate | 0.001 | 0.0001 | N/A |
| Optimizer | Adam | Adam | N/A |
| Loss Function | N/A | Cross Entropy Loss | N/A |
| Epoch | 100 | 50 | N/A |
| Kalman 필터 매개변수 | N/A | N/A | 상태전이 행렬, 관측 오차 행렬 |
| Matching Cascade | N/A | N/A | 0.7 |

일반적으로 70%는 학습 데이터, 15%는 검증 데

이터, 15%는 테스트 데이터로 사용한다. 데이터는 무작위로 추출하되, 소의 행동 패턴이 고르게 포함 되도록 분할한다.

5. 알고리즘 설계

(1) YOLOv8 단독모델

YOLOv8은 실시간 객체 탐지에 매우 적합한 딥러닝 모델로, 소와 같은 객체를 빠르고 정확하게 탐지가 가능하다.

YOLOv8 단독 모델은 각 프레임에서 객체를 탐지하고 Bounding Box를 생성하여 소의 위치를 기록한다[7][8]. 그러나 YOLOv8 단독 모델은 객체 추적 기능이 없어, 프레임 간에 동일한 객체를 식별하고 고유 ID를 유지할 수 없다. 즉, 소가 프레임에서 사라졌다가 다시 등장할 경우, 같은 소라도 다른 ID로 인식될 가능성이 크기 때문에, YOLOv8만으로는 소의 일관된 추적이 어려워 고유 ID 유지에 한계를 보인다. 따라서, Deep SORT와 ReID를 추가하여 ID를 지속적으로 유지하는 것이 필수적이다.

(2) YOLOv8 + Deep SORT

YOLOv8과 Deep SORT의 결합은 객체 탐지와 추적을 결합하여, 축사 환경에서 소의 행동을 일관되게 분석하고 추적하는 데 사용된다.

YOLOv8은 축사 내부에서 소를 탐지하기 위해 사용되며, 각 프레임에서 소의 위치를 Bounding Box 형태로 표시한다.

Kalman 필터는 각 프레임에서 소의 현재 위치를 바탕으로 다음 프레임에서 소의 위치를 예측한다. Kalman 필터는 객체의 위치와 속도를 기반으로 상태전이 행렬과 관측오차 행렬을 사용해 객체의 움직임을 예측하며, 이를 통해 소가 시야에서 잠시 벗어났다가 다시 나타나더라도 연속적인 추적이 가능하다.




그림 4. Kalman 필터

Hungarian 알고리즘은 각 프레임 간에 탐지된 소와 이전 프레임에서 추적 중인 소를 매칭 후 Kalman 필터가 예측한 위치와 현재 프레임에서 탐지된 Bounding Box 좌표 간의 매칭을 최적화하여 객체의 고유 ID를 유지한다. 매칭이 이루어지지 않는 객체는 새로운 객체로 간주되며, 새로운 ID가 부여된다. Deep SORT는 매 프레임마다 소의 ID를 일관되게 유지할 수 있도록 소가 시야를 벗어났다 다시 등장할 때도 동일한 ID를 부여받아 객체 추적의 일관성을 유지한다.

(3) YOLOv8 + Deep SORT + ReID

YOLOv8 + Deep SORT는 객체의 움직임에 기반한 추적을 잘 수행하지만, 외형이 비슷한 소들이 있는 경우 ID 전환이 발생할 수 있다. 이를 보완하기 위해 ResNet50 기반 ReID가 추가되며, 소의 시각적 특징을 학습하여 프레임 간 일관된 ID를 유지하는 알고리즘이 설계되었다.

ResNet50은 CNN을 기반으로 동작하며, 각 소의 시각적 특징(크기, 모양, 색상 등)을 학습한다. ResNet50은 소의 시각적 정보를 특징 벡터로 변환하여, 프레임 간의 객체 인식을 강화한다. 각 소는 ResNet50을 통해 특징 벡터(Feature Vector)로 표현되며, 이는 소가 다른 프레임에서 다시 등장하더라도 일관된 ID를 유지할 수 있게 도와준다.

YOLOv8 + Deep SORT + ResNet50 기반 ReID는 객체의 시각적 특징을 추가적으로 학습하여, 객체 간 혼동을 줄이고 ID 전환을 최소화하는데 매우 효과적이다. 특히, 소와 같은 외형이 비슷한 객체들을 일관되게 추적하는 데 매우 유리하다.

6. 행동 패턴 분석 모델 설계

(1) CNN 기반 행동 패턴 분석

각 프레임에서 소의 이미지를 분석후 행동(서기, 앉기, 누워있기)을 예측한다.

(2) RNN 기반 행동 패턴 분석

시계열 데이터를 분석하여 소의 행동 변화를 예측한다[9][10].

(3) LSTM 기반 행동 패턴 분석

장기적인 행동 변화를 학습하는 모델로, 이전 행동과의 연관성을 고려하여 행동을 예측한다 [12,13].

IV. 실험 결과 및 분석

1. ReID 알고리즘

| ReID알고리즘 | 정확도 | ID 유지율 | 처리속도 |
|--------------|-------|--------|--------|
| ResNet50 | 92.8% | 95.2% | 30 FPS |
| ResNet101 | 94.1% | 96.5% | 25 FPS |
| DenseNet | 89.4% | 92.7% | 20 FPS |
| Triplet Loss | 87.6% | 91.3% | 22 FPS |
| Inception | 85.2% | 90.5% | 35 FPS |
| ViT | 88.7% | 93.1% | 18 FPS |
| SPGAN | 83.5% | 88.9% | 15 FPS |

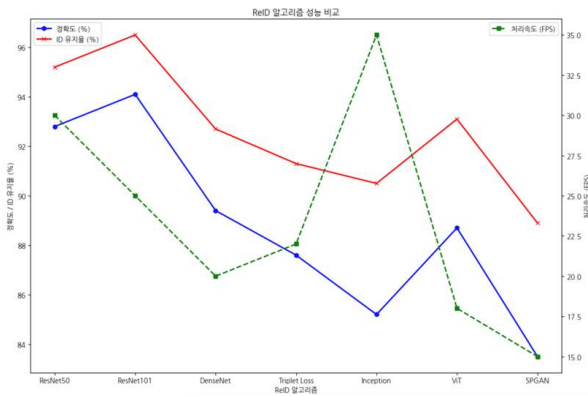


그림 5. ReID 알고리즘 비교 결과

(1) 정확도

객체를 재식별할 때 정확하게 동일 객체로 인식할 확률로서 높을수록 정확하게 재식별을 나타낸다.

(2) ID유지율

객체가 시간이 지나도 일관되게 같은 ID를 유

지할 확률로서 높을수록 객체가 재등장해도 ID를 잘 유지한다.

(3) 처리속도(FPS)

FPS(Frames Per Second)가 높을수록 실시간 처리가 가능하다.

본 연구에서는 다양한 ReID 알고리즘을 비교하여 정확도, ID 유지율, 처리 속도를 평가하였다.

이 비교는 각 알고리즘이 소와 같은 객체를 얼마나 정확하게 식별하고, 프레임 간에 일관된 ID를 유지하는지, 그리고 실시간 시스템에서 얼마나 빠르게 처리할 수 있는지를 측정하는 데 중점을 두었다.

그림 5에서와 같이 ResNet50은 정확도 92.8%, ID 유지율 95.2%, 처리 속도 30 FPS로 비교적 높은 정확도와 ID 유지율을 보였으며, 처리 속도도 우수한 편이었다. ResNet50은 적당한 속도와 정확도, ID 유지 능력에서 전반적으로 가장 균형 잡힌 성능을 보여주었다.

ResNet50과 ResNet101을 비교한 결과, ResNet101이 정확도(Accuracy)와 ID 유지 비율에서 ResNet50보다 더 우수한 성능을 보였다. 그러나 최종적으로 ResNet50이 선택된 이유는 모델의 처리 속도와 자원 효율성이 주요 고려 요소였기 때문이다. 실험 결과, ResNet50은 30 FPS를 유지하며 안정적인 성능을 보였지만, ResNet101은 25 FPS로 다소 느린 처리 속도를 보였다. 이는 대규모 축사에서 다수의 소를 동시에 추적할 때 실시간 추적의 효율성을 저하시킬 수 있다.

ResNet101은 더 복잡한 네트워크 구조로 인해 메모리 사용량과 연산 비용이 높다. 반면, ResNet50은 더 적은 자원으로도 높은 정확도를 제공하여, 하드웨어 자원이 제한된 환경에서 더 적합하다.

특히, 축사 내부의 시스템은 전력 사용량과 GPU 메모리 사용량을 고려해야 하므로, 경량화된 모델인 ResNet50이 더 실용적인 선택이다.

2. 고유 ID 유지 성능분석

본 연구에서는 YOLO 단독 모델, YOLO+Deep

SORT, YOLO+DeepSORT+ResNet50 기반 ReID 세 가지 알고리즘을 사용하여, 각 알고리즘이 고유 ID를 얼마나 일관되게 유지하는지를 평가하였다

표 4. 모델별 유지 성능 분석 및 비교 결과

| 모델 | 정확도 | 유지율 | 전환 횟수 | 처리 속도 | FN | FP | 유사도 |
|-------------------------------|-------|-------|-------|-------|-----|-----|-------|
| YOLOv8 | 88% | 50.5% | 950 | 50 | 300 | 200 | N/A |
| YOLOv8 + Deep SORT | 90.2% | 82.3% | 340 | 45 | 150 | 100 | N/A |
| YOLOv8 + Deep SORT + ResNet50 | 94.5% | 95.8% | 50 | 30 | 50 | 30 | 98.5% |

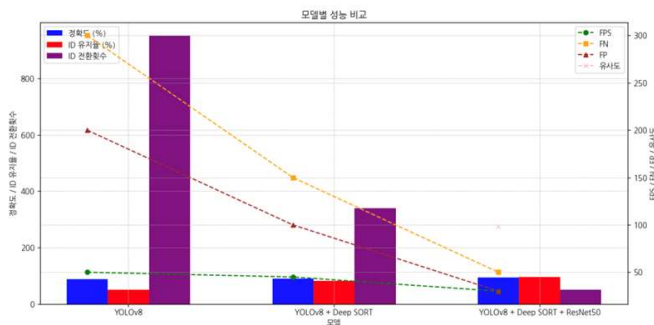


그림 6. 모델별 유지 성능 분석 및 비교 결과

(1) FN(False Negatives)

YOLOv8 단독 모델은 많은 객체를 놓치고, 특히 빠르게 이동하거나 시야에서 벗어난 객체는 재탐지에 어려움을 겪고 Deep SORT와 ResNet50이 추가될수록 FN이 감소한다.

(2) FP(False Positive)

YOLOv8만 사용했을 때 잘못된 객체 탐지가 자주 발생할 수 있었다. 하지만 Deep SORT와 ReID를 추가하면, 잘못된 탐지를 줄이고 더욱 정확한 ID 추적이 가능하다.

(3) ReID 유사도 매칭

ResNet50 기반 ReID[2]는 유사한 객체 간에도 ID를 일관되게 유지할 수 있으며, 이로 인해 매우 높은 유사도 매칭 성능을 보인다.

이 추가 지표들은 모델 비교를 더욱 구체적이고 명확하게 만들어준다. 특히 ID 전환 횟수, 놓친 객체 비율(FN), 잘못된 객체 탐지(FP) 등의 지표는 시스

템이 얼마나 신뢰성 있게 작동하는지를 평가하는 데 중요한 요소로 YOLOv8+Deep SORT+ResNet50은 ID 전환을 최소화하면서 정확하게 가측을 추적할 수 있는 가장 신뢰성 높은 모델임을 강조할 수 있다.

3. 행동 패턴 분석 성능 평가

소의 행동 패턴(서기, 앉기, 누워있기)을 분석하기 위해 CNN, RNN, LSTM 세 가지 모델의 성능을 비교 평가하였다.

표 5. 모델별 성능평가표

| 행동패턴 | CNN(%) | RNN(%) | LSTM(%) |
|------|--------|--------|---------|
| 서기 | 90.5 | 88.0 | 93.0 |
| 앉기 | 91.2 | 88.7 | 93.3 |
| 누워있기 | 91.3 | 88.8 | 93.4 |

표 5는 각 모델이 서기, 앉기, 누워있기 행동 패턴을 얼마나 정확하게 예측하는지 보여준다.

LSTM 모델이 전반적으로 가장 높은 정확도를 기록하였으며, CNN 모델은 단일 프레임에서의 행동 분석에 탁월한 성능을 보였다.

RNN 모델은 시간적 정보를 고려했으나, 정확도에서는 상대적으로 낮은 성능을 보였다.

V. 결론

본 연구에서는 YOLO 단독 모델, YOLO + Deep SORT, 그리고 YOLO+Deep SORT+ResNet50 기반 ReID 세 가지 모델을 비교 분석하여 고유 ID 유지 성능을 평가하였다.

실험 결과, YOLOv8+Deep SORT+ResNet50이 가장 일관되게 고유 ID를 유지하며, ID 전환을 최소화하는 것으로 나타났다. 또한, 다양한 딥러닝 모델(CNN, RNN, LSTM)을 활용하여 소의 행동 패턴 분석 성능을 평가한 결과, LSTM[14][15] 기반 모델이 가장 높은 정확도를 보였다.

이 연구는 외부 장치 없이 카메라 영상만을 사용하여 축사 내부에서 소의 행동 패턴 분석 및 고유 ID 유지를 위한 시스템을 개발, 다양한 알고리즘을

평가하여 실질적인 스마트 측사 관리 시스템의 기여를 입증하였다. 특히, 고유 ID 유지 알고리즘과 행동 패턴 분석 모델의 성능이 입증됨에 따라, 향후 질병 예측 및 측사 관리 자동화에 적용될 수 있는 가능성을 보여주었다.

본 연구는 서기, 앉기, 누워있기라는 기본적인 행동 패턴을 분석하는 데 중점을 두었다. 하지만 소의 복잡한 행동 패턴(예: 먹이 섭취, 머리 흔들기 등)을 포괄적으로 분석하지는 않았기 때문에, 이를 통해 질병이나 스트레스 상태를 더욱 정밀하게 예측하는데 한계가 있을 수 있었다. 아울러 실험에 사용된 데이터는 하나의 측사에서만 수집되었으며, 다양한 측사 환경에서 수집된 데이터가 부족하다. 이는 시스템의 일반화 능력에 한계를 가져올 수 있다.

향후 연구에서는 이와 같은 다양한 데이터 수집과 학습 데이터셋 확장을 통한 성능개선의 노력이 필요하다.

REFERENCES

- [1] Wojke, Nicolai, Alex Bewley, and Dietrich Paulus. "Simple Online and Realtime Tracking with a Deep Association Metric," *Beijing: IEEE*, pp. 3645-49, 2017.
- [2] Wojke et al., SIMPLE ONLINE AND REALTIME TRACKING WITH A DEEP ASSOCIATION METRIC, May 2017.
- [3] Understanding Kalman Filters with MATLAB, MATLAB Korea, Feb. 2022.
- [4] Munkres, J.(1957). "Algorithms for the Assignment and Transportation Problems," *Journal of the Society for Industrial and Applied Mathematics*, vol. 5, no. 1, pp. 32-38.
- [5] Zheng, Liang, Liyue Shen, Lu Tian, Shengjin Wang, Jingdong Wang, and Qi Tian, "Scalable Person Re-identification: A Benchmark," Santiago, Chile:IEEE, pp. 1116-24, 2015.
- [6] Avola et al., MS-Faster R-CNN: Multi-Stream Backbone for Improved Faster R-CNN Object Detection and Aerial Tracking from UAV Images, Apr. 2021.
- [7] S. Liang, H. Wu, L. Zhen, Q. Hua, S. Garg, G. Kaddoum, et al., "Edge YOLO: Real-time intelligent object detection system based on edge-cloud cooperation in autonomous vehicles," ,vol. 23, no. 12, pp. 25345-25360, Dec. 2022.
- [8] Marwa Chacha Andrea, Choong Kwon Lee, Mi

Jin Noh, 이충권, (2023), "Detection of Traditional Costumes: A Computer Vision Approach," *스마트미디어저널*, 제12권 제11호, 125-133쪽

- [9] 이희준, 이충권, (2020), "딥러닝을 이용한 시퀀스 기반의 여행경로 추천시스템 - 제주도 사례-" *스마트미디어저널*, 제9권, 제1호, 45-50쪽
- [10] Syamsul Rizal, Dong-Seong Kim, (2024-01-31), "RNN for Non-Invasive Blood Pressure Prediction Based on PPG Signals," *한국통신학회 학술대회논문집*, 강원.
- [11] 김영석, "머신러닝 기술의 재료·가공문제에 적용III - RNN, LSTM," *CNN. 소성·가공*, 제33권, 제3호, 214-230쪽, 2024년
- [12] 유하영, 조영완, "LSTM을 활용한 자연어 응답 기반 성격유형 예측," *한국지능시스템학회 논문지*, 제34권, 제4호, 356-363쪽, 2024년
- [13] 김원태, 이해연, "뇌 MRI를 이용한 LSTM 딥러닝 모델 기반의 산소추출물 예측," *한국정보기술학회 논문지*, 제22권, 제6호, 143-151쪽, 2024년
- [14] 김원태, 이해연, "뇌 MRI를 이용한 LSTM 딥러닝 모델 기반의 산소추출물 예측," *한국정보기술학회 논문지*, 제22권, 제6호, 143-151쪽, 2024년
- [15] 김민주, 고진환, "3D CNN-LSTM 알고리즘을 이용한 손동작 비디오 영상 분류," *한국산학기술학회 논문지*, 제25권, 제9호, 878-885쪽, 2024년

저자 소개



김석훈(정회원)

2023~현재 호남대학교 컴퓨터공학과 박사과정

2021년 호남대학교 소프트웨어공학과 석사졸업

2018년~현재 (주)아르고AI 대표

2018년~현재 (주)전남4차산업협동조합 개발이사

<주관심분야 : AI, 컴퓨터비전, 응용 SW, 3D 모델링>



김남호(정회원)

1997년 포항공과대학교 정보통신학과 석사졸업

2013년 전남대학교 전산통계 박사졸업

1991년~1997년 포스코DX 연구원

1998년~현재 호남대학교 컴퓨터공학과 부교수

<주관심분야 : 인공지능, 정보통신, 응용 SW>