

박사학위논문

AI 기반 반려앵무 행동 패턴 분석
방법에 관한 연구

2026년

한 성 대 학 교 대 학 원

스마트융합건설링학과

스마트융합제품전공

강 대 훈

박사학위논문
지도교수 노광현

AI 기반 반려앵무 행동 패턴 분석
방법에 관한 연구

A Study on AI-Based Behavioral Pattern Analysis
Methods for Companion Parrots

2025년 12월 일

한성대학교 대학원

스마트융합건설링학과

스마트융합제품전공

강대훈

박사학위논문
지도교수 노광현

AI 기반 반려앵무 행동 패턴 분석
방법에 관한 연구

A Study on AI-Based Behavioral Pattern Analysis
Methods for Companion Parrots

위 논문을 공학 박사학위 논문으로 제출함

2025년 12월 일

한성대학교 대학원

스마트융합컨설팅학과

스마트융합제품전공

강대훈

강대훈의 공학 박사학위 논문을 인준함

2025년 12월 일

심사위원장 김 승 천 (인)

심사위원 노 광 현 (인)

심사위원 이 후 진 (인)

심사위원 남 현 우 (인)

심사위원 임 황 용 (인)

국 문 초 록

AI 기반 반려앵무 행동 패턴 분석 방법에 관한 연구

한 성 대 학 교 대 학 원
스 마 트 융 합 컨 설 팅 학 과
스 마 트 융 합 제 품 전 공
강 대 훈

최근 반려동물을 가족 구성원으로 인식하는 경향이 확산되면서, 반려동물의 건강과 정서를 세밀하게 관리하려는 펫 헬스케어 및 관련 기술의 수요가 빠르게 증가하고 있다. 특히 반려조류는 높은 지능과 사회성을 바탕으로 반려종으로서의 선호도가 증가하고 있지만, 스트레스 민감도가 높아 정서 상태를 객관적으로 파악하기 어렵다는 한계가 존재한다. 이에 따라 본 연구는 영상 기반 인공지능을 활용한 행동 패턴 분석 기법을 통해 반려앵무의 스트레스 상태와 심리적 안정 상태를 정량적으로 평가할 수 있는 체계를 구축하고자 하였다.

반려앵무는 풍성한 깃털 구조로 인해 신체 윤곽이 불분명하고, 고개 회전이나 날갯짓, 비행 준비와 같은 비선형적이고 빠른 움직임을 보이며, 케이지 내부의 헛대·먹이통·물통·장난감과 상호작용한다. 이러한 환경적·신체적 특성 때문에 기존 육안 관찰 방식이나 관절 기반 자세 추정 방식만으로는 행동을 안정적으로 분류하기 어렵다. 이를 해결하기 위해 본 연구는 객체 탐지 기반 다단계 구조, 스켈레톤 기반 자세 분석, 케이지 내부 환경정보 인식을 통합한

새로운 행동 패턴 분석 프레임워크를 제안하였다.

먼저 반려앵무의 전신을 탐지한 후 관심 영역 내부에서 머리, 꼬리, 발을 재탐지하는 단계적 Object Detection 구조를 구축하여 복잡한 배경 간섭과 정보 손실을 최소화하였다. 이어서 신체 중심의 기울기 변화, 발 좌표 이동 패턴, 중심점 이동 비율을 활용하여 행동의 특성을 정량화할 수 있도록 Y자형 스켈레톤 구조를 설계하였다. 또한 케이지 내부의 먹이통·물통·햇대 위치를 세그멘테이션으로 분리하여, 동일한 움직임이라도 공간 맥락에 따라 행동의 의미를 정확하게 해석할 수 있도록 하였다.

이러한 기반 위에서 본 연구는 먹이 섭취, 물 마시기, 휴식, 기지개, 목욕, 스트레스성 반복 이동까지 총 여섯 가지 행동을 선정하여 분류하였다. 여섯 가지 행동을 선택한 이유는 인공지능이 실제 영상에서 안정적으로 구분할 수 있는 행동이면서, 동시에 반려앵무의 정서·환경 적응도·건강 상태를 평가하는데 필요한 최소한의 핵심 행동군이기 때문이다. 휴식·기지개·목욕은 심리적 안정 상태를 대표하며, 스트레스성 반복 이동은 불안·과흥분·환경 부적응을 나타내는 주요 스트레스 지표로 기능한다. 반면 먹이 섭취와 물 마시기는 생리적 행동이지만, 공간 기반 세그멘테이션을 이용해 행동의 경계와 조건을 정확하게 판단할 수 있는 기준 행동으로 활용되며, 섭식·음수 패턴의 급감 또는 과다 여부는 건강 이상이나 생애주기적 변화의 초기 징후를 파악하는 데도 유용하다. 나아가 먹이 섭취와 물 마시기를 구분하기 위해 사용된 신체 기울기 기반 탐지는 여섯 가지 행동 전반에서 행동의 시작과 종료를 정밀하게 구분하는 핵심 구조로 재사용되어 행동 분류의 정확도를 높였다.

실험은 실내 사육 환경에서 코뉴어 네 마리를 대상으로 수행되었으며, 두 대의 고해상도 카메라를 활용해 전신과 햇대 주변 행동을 장시간 동시 촬영하였다. 행동별 시작·종료 시점을 기준으로 육안 관찰 자료를 구축하고 인공지능 분석 결과와 비교하여 모델의 타당성을 검증한 결과, 반려앵무의 전신 및 세부 신체 부위 탐지는 매우 높은 정확도를 보였으며, 여섯 가지 행동 모두에서 안정적인 분류 성능을 기록하였다.

전통적으로 조류 및 가금류 분야에서 이루어진 행동 분석은 특정 행동이 얼마나 자주, 얼마나 오래 나타나는지를 개별 지표로 측정하여 해당 시점의

상태를 평가하고, 이를 건강 관리나 사육 환경 개선에 참고하는 데 초점을 두어 왔다. 본 연구에서 의미하는 행동 패턴 분석은 단일 행동의 빈도나 지속시간을 넘어서, 여러 행동 유형의 발생 순서와 반복 양상, 행동 간 전이 구조, 그리고 안정 행동과 스트레스성 행동의 비율을 통합적으로 해석함으로써 개체의 정서 상태와 스트레스 수준을 구조적으로 파악하려는 접근이다.

행동 패턴 분석 결과, 스트레스성 반복 이동 행동은 휴식·목욕·기지개와 뚜렷한 음의 상관관계를 나타냈다. 안정 행동 비율이 높은 개체는 스트레스성 이동이 낮았고, 스트레스 행동이 증가한 개체는 안정 행동이 감소하는 경향을 보여 제안된 분석 체계가 반려앵무의 정서 상태를 신뢰도 있게 반영함을 확인하였다.

결론적으로 본 연구는 객체 탐지 기반 다단계 구조와 스켈레톤 분석, 환경 정보 인식을 통합한 행동 패턴 분석 체계를 통해 반려앵무의 행동 변화와 스트레스 지표를 자동으로 평가할 수 있는 기반을 마련하였다. 본 연구 결과는 실시간 케이지 모니터링, 행동 이상 탐지, 스트레스 조기경보 시스템 등으로 확장될 수 있으며, 반려조류의 복지를 향상시키고 장기 행동 데이터를 활용한 과학적 사육 관리 체계를 구축하는 데 기여할 수 있다.

【주요어】 반려앵무, 행동 패턴 분석, 객체 탐지, 다단계 구조, 펫테크

목 차

I. 서 론	1
1.1 연구 배경	1
1.1.1 반려앵무 시장의 성장과 사회적 수요	2
1.1.2 반려앵무의 스트레스 민감성	3
1.1.3 AI 기반 조류 행동 패턴 분석 연구의 개요와 동향	8
1.2 연구의 필요성	11
1.2.1 AI 기반 행동 패턴 분석 연구의 필요성	11
1.2.2 기존 스트레스 측정 방법의 한계	13
1.2.3 반려앵무 문화에 펫테크(Pet-tech) 필요성	17
1.3 연구의 범위와 목적	21
1.3.1 AI 기반 반려앵무 행동 패턴 분석의 검증 및 평가	21
1.3.2 스트레스와 행동의 상관관계 규명	22
II. 이론적 배경 및 선행연구	25
2.1 인공지능 기반 조류 행동 패턴 분석 연구	25
2.1.1 반려앵무 행동 패턴 분석 연구 동향	25
2.1.2 Keypoint 기반 탐지방식	26
2.1.3 Object Detection 기반 탐지와 행동 분류 연구	29
2.2 스마트 사육환경 및 펫테크 기술	31
2.2.1 반려동물 스마트 사육환경 연구	31
2.2.2 반려조류 분야의 펫테크 기술 개발 시도 사례	35
2.3 반려앵무의 스트레스와 복지 연구 동향	37
2.3.1 스트레스 요인 및 행동 지표	37
2.3.2 코티졸 호르몬 분석기술 활용 스트레스 측정 연구	38
2.3.3 열화상 측정기술 활용 스트레스 측정 연구	41
III. AI 기반 반려앵무 행동 패턴 분석 방법 설계	43

3.1 행동 패턴 분석 연구모형	43
3.2 반려앵무 행동 탐지방법	46
3.2.1 Keypoint 추정을 이용한 반려앵무 행동 탐지	46
3.2.2 단일 Object Detection을 이용한 반려앵무 행동 탐지	51
3.2.3 Object Detection 이용 다단계 방식 설계	54
3.2.4 다단계 AI 행동 패턴 분석방식과 종래 탐지모델 성능비교	58
3.3 행동 패턴 분석 연구 모델	60
3.3.1 행동 기준의 설정	60
3.3.2 반려앵무 행동 탐지를 위한 전체 파이프라인	75
3.4 연구 모델의 실험 환경	78
3.4.1 반려앵무 행동촬영환경	78
3.4.2 연구용 반려앵무 개체 및 실험 시 사육환경	81
3.4.3 데이터 수집 환경 설정	83
3.4.4 데이터셋 구성	84
3.5 행동 패턴 분석 타당성 검증 방법의 설정	87
3.5.1 AI Detection 모델 기반 행동 패턴 분석 정확성 검증방법 설정	87
3.5.2 AI 기반 행동 분류 모델의 정량적 성능 평가기준 설정	88
3.5.3 Resting·Bathing·Stretching과 Pacing의 상대 비율 분석방법 설정	89
IV. 실험 결과 및 분석	91
4.1 AI Detection 모델 기반 행동 패턴 분석 정확성 검증 결과	91
4.2 Resting·Bathing·Stretching과 Pacing의 상대 비율 분석 결과	97
4.3 AI 기반 행동 분류 모델 정량적 성능 평가 결과	100
V. 결 론	109
참 고 문 헌	112
ABSTRACT	119

표 목 차

[표 1-1] 반려앵무의 스트레스 요인과 생리·행동적 반응	4
[표 1-2] 반려앵무의 주요 스트레스 행동	4
[표 1-3] 반려앵무의 심리적 안정 행동 지표 요약	8
[표 1-4] 반려앵무의 정상 및 비정상 행동 구분	9
[표 1-5] 반려앵무 행동 패턴 분석 연구 방식별 비교	12
[표 1-6] 조류 스트레스 측정 주요 방법 비교표	14
[표 1-7] 스트레스 측정 방식의 한계 및 새로운 방식의 필요성	16
[표 1-8] 출시된 반려동물군별 펫테크 제품 기능 분류 및 현황 비교 ...	18
[표 1-9] 반려앵무 펫테크 연구 사례 비교	20
[표 1-10] 본 연구에서 다루려는 반려앵무의 행동 유형별 정의	21
[표 1-11] 정상·비정상 행동 분류 및 심리적 의미	23
[표 2-1] Multi-Chicken Pose (MCP) 모델 구조적 특징	28
[표 2-2] 반려앵무의 스트레스 행동 유형별 AI 분석 용이성	38
[표 2-3] 코터졸 분석을 통한 AI 기반 행동 패턴 분석의 신뢰도 검증 구조	40
[표 3-1] 다단계 AI 행동 패턴 분석 구조 설계	55
[표 3-2] 다단계 AI 행동 패턴 분석방식과 종래 탐지모델 소실률 비교	59
[표 3-3] Front Camera와 Rear Camera에서 촬영한 행동 분류	61
[표 3-4] 실험 시 사용된 카메라의 제원	80
[표 3-5] 실험에 사용된 반려앵무 개체	82
[표 3-6] 실험 시 반려앵무의 공통 사육환경	82
[표 3-7] 각 행동별 AI 분석 결과와 VI 결과 비교 기준	88
[표 3-8] 본 연구 모델 성능 평가 지표별 의미	89
[표 3-9] 정상 개체와 스트레스 개체 간 Pacing 관련 지표 비교	90
[표 4-1] VI-AI Detection Comparison 결과	89
[표 4-2] Resting, Stretching, Bathing 의 일자별 세부결과표	91
[표 4-3] Resting·Bathing·Stretching과 Pacing의 상대 비율 분석 결과	95

그림 목 차

[그림 1-1] 알려진 반려동물들과 반려앵무의 평균수명	2
[그림 1-2] Keypoint + GRU 기반 행동 패턴 분석의 시간적 흐름	10
[그림 1-3] VI(Visual Inspection) 행동연구 방식의 한계	11
[그림 1-4] 코티졸 기반 스트레스 분석의 한계 개념도	15
[그림 1-5] 글로벌 펫테크 시장 규모와 제품별 세부 구성 (2021-2032) ·	17
[그림 2-1] 코티졸 시험시료(좌)와, 흡광도측정(우) 모습	39
[그림 2-2] 열화상 분석을 통한 반려앵무 스트레스 측정	41
[그림 3-1] 반려앵무 행동 패턴 분석을 위한 연구 방법 설계 모형	43
[그림 3-2] Label Studio 이용 라벨링 포인트 설정	46
[그림 3-3] Label Studio 이용 200장의 Keypoint 이미지 라벨링	47
[그림 3-4] 안정적으로 포인트를 인식하지 못하는 Keypoint 단독모델	47
[그림 3-5] Label Studio의 Annotation Task 모듈 병행 커스텀 코드 내용	48
[그림 3-6] ROI 내부 머리·꼬리·발·어깨 Keypoint 라벨링	48
[그림 3-7] ROI 방식을 통한 구조 안정성 확보	49
[그림 3-8] 먹이를 먹을때에 Head 포인트 occlusion 문제	49
[그림 3-9] 새장 내 노이즈로 인한 Keypoint 좌표 혼동 및 손실	50
[그림 3-10] 환경적 요인으로 인해 바운딩박스 손실	52
[그림 3-11] 환경적 요인으로 인한 탐지 성능 저하	53
[그림 3-12] YOLO 계열 모델의 grid-based 구조적 특성	54
[그림 3-13] ROI를 위해 먼저 Parrot 클래스를 전체 프레임에서 탐지	56
[그림 3-14] ROI를 위해 먼저 Parrot 클래스를 전체 프레임에서 탐지	56
[그림 3-15] Keypoint 방식 대비 비교우위인 Object Detection 다단계 방식	57
[그림 3-16] Front Camera(좌)와 Rear Camera(우)의 시야각	58
[그림 3-17] 두 개의 주요 각도(θ_1 , θ_2) 기준 설정	60
[그림 3-18] 스켈레톤 추출 및 θ_1 , θ_2 계산 핵심 코드	61
[그림 3-19] 세그멘테이션 맵 생성 및 각 구조물별 마스크 설정	61
[그림 3-20] Eating 행동 탐지 및 누적횟수 기록 화면	63
[그림 3-21] Eating·Drinking 탐지 위한 피킹이벤트 탐지 알고리즘 핵심 코드 ·	64

[그림 3-22] Drinking 행동 탐지 및 누적횟수 기록 화면	65
[그림 3-23] Resting 행동 탐지 및 누적시간 기록 화면	66
[그림 3-24] Resting 행동 판정 핵심코드	67
[그림 3-25] Bathing 행동 탐지 장면	69
[그림 3-26] Bathing 행동 판정 핵심코드	69
[그림 3-27] 스트레칭 행동 탐지 장면	70
[그림 3-28] Pacing 행동 탐지 장면	72
[그림 3-29] 반려앵무 행동탐지 모델 전체 파이프라인 구조도	73
[그림 3-30] Front Camera와 Rear Camera의 장착 위치	76
[그림 3-31] 카메라 거치용 지그와 카메라 장착 모습	79
[그림 3-32] 데이터 수집 환경 및 방식	81
[그림 3-33] 데이터 수집 및 처리환경 구조도	82
[그림 4-1] Parrot1에 대한 Eat, Drink VI-AI Detection 결과 그래프 ...	90
[그림 4-2] Parrot4에 대한 Eat, Drink VI-AI Detection 결과 그래프 ...	91
[그림 4-3] 차이가 가장 낮았던 Parrot1 3일차의 Resting 발생시간 그래프 ..	92
[그림 4-4] 차이가 가장 높았던 Parrot4 2일차의 Resting 발생시간 그래프 ..	92
[그림 4-5] Parrot2 3일차 Stretching 누적시간의 AI-VI 비교 그래프 ...	93
[그림 4-6] Resting·Bathing·Stretching, Pacing의 상대 비율 분석 (parrot 1,2,3)·	96
[그림 4-7] Resting·Bathing·Stretching, Pacing의 상대 비율 분석 (parrot 4) ...	97
[그림 4-8] Eating, Drinking, Bathing 행동 Confusion Matrix	98
[그림 4-9] Eating, Drinking, Bathing 행동 Training Metrics(훈련 지표) ...	99
[그림 4-10] Eating, Drinking, Bathing 행동 Validation Metrics(검증 지표) ...	99
[그림 4-11] Eating, Drinking, Bathing 행동 Precision-Recall Curve ...	101
[그림 4-12] Stretching 행동 탐지를 위한 Wing 기반 Confusion Matrix ...	102
[그림 4-13] Stretching 행동 Training Metrics(훈련 지표)	103
[그림 4-14] Stretching 행동 Validation Metrics(검증 지표)	104
[그림 4-15] Stretching 행동 Precision-Recall Curve(PR 커브)	105
[그림 4-16] Pacing 행동 Confusion Matrix와 Precision-Recall Curve ...	106

I. 서론

1.1 연구 배경

1.1.1 반려앵무 시장의 성장과 사회적 수요

반려앵무를 포함한 반려조류 시장은 최근 들어 주목할 만한 성장세를 보이고 있으며, 이에 대한 사회적 수요 또한 꾸준히 확대되고 있다. 미국의 경우 반려동물 산업이 이미 성숙 단계에 접어들었고, APPA 2021-2022 National Pet Owners Survey에 따르면 전체 반려동물 가구 중 약 8%인 570만 가구가 조류를 반려동물로 보유하고 있는 것으로 나타났다. 이는 반려앵무를 비롯한 조류가 반려종으로서 상당한 비중을 차지하고 있음을 의미한다. 특히 코로나19 팬데믹 기간 동안 새를 입양한 가구의 절반가량이 팬데믹 상황을 입양의 주요 요인으로 응답하였으며, 이 영향으로 조류 관련 제품 매출은 2020년에만 전년 대비 약 18.5% 증가하여 30억 달러 규모에 도달하였다.¹⁾

반면 국내 반려조류 시장은 아직 신생 단계에 속하지만 성장 잠재력이 크다. 국내 전체 반려동물 산업은 2022년 기준 약 8조 원 규모로 추산되며,²⁾ 이 중 국내 반려앵무 시장은 2021년 1,000억 원에 이르는 규모를 보인다.³⁾ 한국은 인구 대비 반려동물 보유율이 높고, 새로운 반려동물 문화 수용 속도가 빠른 특성을 지닌다. 따라서 향후 시장이 성숙기에 접어든다면, 전체 반려동물 시장 규모의 8% 수준에 해당하는 약 6,400억 원 규모로 확대될 수 있을 것으로 전망된다.

특히 미국에서 반려앵무가 반려동물로 각광받는 이유는 새롭고 특별한 대

1) Beaton, L. (2022). Pet bird segment enjoys growth, faces pandemic challenges. 『Pet Food Industry』, Retrieved from <https://www.petfoodindustry.com/>

2) 농림축산식품부. (2023). 『2023 반려동물 펫푸드, 펫헬스케어 등 국가전략산업으로 육성』. 세종: 농림축산식품부 동물복지환경정책관, 반려산업동물의료팀.

3) 박정수. (2021). 앵무새 시장, 성장가도 위 반려동물 시장의 '다크호스' 될까?. 『내외경제TV』. Retrieved from <https://www.nbntv.co.kr/>

상에 대한 소비자 선호와 관련이 깊다. 실제로 미국 반려조 소비자의 약 76~80%는 새에게 선물을 구매한다고 답하며⁴⁾, 고급 사료와 장난감, 보충제 등 프리미엄 제품에 대한 지출이 증가하고 있다. 희귀성이 높고 입수가 어려운 종일수록 더 큰 가치를 인정받으며, 이는 반려앵무를 고가 반려동물로 자리매김하게 한다. 특히 미국에서 반려앵무가 반려동물로 각광받는 이유는 새롭고 특별한 대상에 주목하는 소비 문화와 관련이 깊다. 희귀성이 높고 입수가 어려운 종일수록 더 큰 가치를 인정받으며, 이는 반려앵무를 고가의 반려동물로 자리매김하게 한다.

이러한 흐름은 한국에서도 나타나고 있다. 인스타그램, 유튜브 등의 SNS를 통해 독창성과 희귀성을 중시하는 문화와 맞물려 앵무새 반려문화가 점차 확산되고 있다. 반려앵무는 평균 30년(8~60년)에 이르는 긴 수명을 가지며, 사람과의 교감 능력이 뛰어나 반려동물로 각광받고 있다. 지능 수준은 약 IQ 30으로 추정되며, 이는 인간의 4~5세 아동과 유사한 수준으로 알려져 있다. 또한 기본적인 먹이 관리만으로도 사육이 가능하여 사료비와 관리비가 비교적 적게 소요되며, 개와 달리 산책이 필수적이지 않아 사육 편의성이 높다는 장점이 있다.⁵⁾

동물	평균수명	동물	평균수명	동물	평균수명
개 (소형~중형) 	13.53년	고양이 	11.18년	앵무새 (중형) 	아마존앵무 등 25~35년
개 (대형) 	12.7년	앵무새 (소형) 	사랑앵무 모란앵무 왕관앵무 8~20년	앵무새 (대형) 	회색앵무 아마존앵무 금강앵무 40~60년

[그림 1-1] 알려진 반려동물들과 반려앵무의 평균수명

[출처] 국민일보(개, 고양이 수명), 아시아경제(반려앵무 수명)

4) The American Pet Products Association(APPA). (2024). 『Releases 2024 Bird, Small Animal & Horse Owner Insight Report』. Stamford, CT: The American Pet Products Association.

5) 이동은. (2024). [사이언스ZOO] 사람과 두뇌 싸움도 가능...똑똑한 새 앵무새. 『YTN 사이언스』

반려앵무는 긴 수명과 높은 지능, 강한 사회성, 발달된 감각 능력, 그리고 다양한 행동 스펙트럼을 통해 독특한 특성을 보여준다. 그러나 이러한 특성은 동시에 스트레스 취약성과 복지 문제로 이어지며, 야생과 사육 환경의 괴리가 문제행동의 주요 원인이 되고 있다.

1.1.2 반려앵무의 스트레스 민감성

반려앵무는 반려동물 중에서도 가장 높은 지능과 사회성을 지닌 조류에 속한다. 그러나 이러한 특성은 역설적으로 환경 변화와 외부 자극에 대한 높은 민감성으로 이어진다. 개나 고양이와 같은 포유류는 오랜 가축화 과정을 거치면서 인간 생활환경에 비교적 안정적으로 적응할 수 있도록 유전적·행동적 변화를 축적해 왔다. 반면 반려앵무는 여전히 야생적 특성을 크게 보존하고 있어, 작은 환경적 변화에도 스트레스 반응을 쉽게 나타낸다. 이는 반려앵무의 반려화가 다른 종에 비해 상대적으로 짧은 기간에 이루어졌고, 인간 환경에 대한 적응력이 제한적이라는 점에서 비롯된 것으로 해석할 수 있다.⁶⁾

반려앵무의 스트레스 요인은 다양하다. 기본적인 온도, 습도, 먹이, 빛과 같은 조건이 기준 범위를 벗어나거나 급격히 변할 경우, 면역력이 약화되고 소화기 장애, 호흡기 질환, 피부질환 등 신체적 이상을 보일 수 있다. 동시에 심리적 불안정성은 행동으로 표출되는데, 사육자를 공격하거나, 무는 행동을 보이거나, 자기 몸을 상해하는 등의 비정상적 스트레스 반응으로 이어질 수 있다. 이러한 반응은 단순한 불편함의 표현을 넘어, 장기적으로는 개체의 생존과 직결되는 스트레스성 질환으로 발전할 수 있다. 실제로 보고된 바에 따르면, 장기간 스트레스에 노출된 반려앵무는 식욕 부진과 체중 감소, 소화기 장애와 호흡기 문제, 자해 행동, 심한 경우 돌연사까지 경험하게 된다.⁷⁾

반려앵무의 스트레스 요인과 생리적 행동적 반응을 [표 1-1]에 정리하였다. [표 1-2]을 보면 반려앵무의 스트레스 민감성은 사회적 환경에서도 쉽게

6) Andrew U. Luescher (Ed.). (2006). 『Manual of Parrot Behavior』. Ames, IA: Blackwell Publishing, pp. 54-55, 302-304.

7) 상계서, pp. 302-304.

드러난다. 반려앵무는 사회적 동물로서 무리 생활에 특화되어 있으며, 풍부한 사회적 교류와 자극을 필요로 한다. 그러나 반려동물로서 길러지는 과정에서 대부분의 반려앵무는 좁은 새장 안에 단독으로 사육되는 경우가 많다. 이는 자연 상태에서 경험하는 다양한 사회적 상호작용의 결핍으로 이어지며, 행동적 문제를 증폭시키는 주요 요인으로 작용한다.⁸⁾

[표 1-1] 반려앵무의 스트레스 요인과 생리·행동적 반응

구분	주요 요인	구체적 사례	생리적 반응	행동적 반응
환경적 요인	온도, 습도, 소음, 진동, 조명	공사장 소음, 조명 주기 불균형	면역력 저하, 호흡기 질환, 소화기 장애	과도한 울음, 날갯짓, 자해, 폐사
사회적 요인	단독 사육, 사회적 자극 부족	좁은 케이지, 사육자 부재	코티졸 상승, 교감신경 활성화	반복행동, 울음, 공격성, 깃털 뽑기
심리적 요인	애착 형성 실패, 분리불안	생후 초기 교감 결핍	불안 호르몬 증가, 체중 감소	자해, 무는 행동, 공격성

[표 1-2] 반려앵무의 주요 스트레스 행동

구분	행동 형태	유발 요인	시각적 특징	관리
자해(Self-mutilation) 	가슴·날개·다리 부위의 깃털이나 피부를 반복적으로 물어뜯음	장기적 사회적 고립, 애착 실패, 환경 변화 후 불안 누적	깃털이 듬성하게 빠지고, 피부가 붉게 드러나 있음. 부리 끝에 피나 털 조각이 묻어 있는 경우도 있음	만성 스트레스의 대표 징후. 즉각적 환경개선(조도·온도·사회 자극 제공)과 행동치료 필요
반복행동(Stereotypic movement) 	같은 경로 왕복 이동, 헛대 위 좌우 흔들기	사회적 결핍, 공간 제약, 단조로움	헛대에서 좌우로 일정한 패턴의 이동. 눈동자 빠르게 움직임	환경 풍부화(장난감, 먹이 찾기, 사회 자극)가 가장 효과적
과도한 날갯짓(Flapping) 	제자리에서 반복적 날갯짓	긴장, 흥분, 구속감	깃털이 부풀며 일정한 간격으로 반복. 소리와 함께 체온 상승	스트레스 해소 혹은 흥분 신호. 장기 지속 시 환경·사회적 자극 개선 필요

8) Andrew U. Luescher (Ed.). 전계서, pp. 179, 183, 302-304.

사회적 자극 부족은 반려앵무가 과도하게 울거나, 반복적으로 날갯짓을 하거나, 일정한 경로를 따라 배회하는 강박적 행동으로 표출되며, 이는 결국 만성적인 스트레스 상태를 반영한다. 이러한 환경적, 사회적 요인 및 심리적 요인에 대한 반려앵무의 스트레스 상황에서 보이는 대표적 행동 유형을 분류하여, 각 행동의 형태, 유발 요인, 시각적 특징 및 관리 방안을 종합적으로 제시한 것이다. 반려앵무의 가장 두드러진 특성 중 하나는 높은 지능 수준이다. 평균적으로 인간의 2~3세 아동에 준하는 인지 능력을 지녔다는 보고가 있으며, 특히 아프리카회색앵무(African Grey Parrot)는 100개 이상의 어휘를 학습하고 의미와 연결하여 사용할 수 있는 능력을 보여왔다. 이들은 단순한 모방을 넘어 개념적 범주화와 문제 해결 능력을 발휘할 수 있으며, 이는 조류 인지 연구에서 대표적인 사례로 활용된다.⁹⁾

또한 앵무류는 환경 탐색과 사회적 학습을 통해 새로운 먹이원이나 도구 사용 방식을 터득하기도 한다. 예컨대 야생의 일부 코카투앵무(Cockatoo Parrot)들은 나무껍질을 벗겨내는 과정에서 협동적 전략을 보이며, 이러한 행위는 단순한 본능적 행동이 아니라 사회적 모방과 학습 과정을 반영한다. 반려앵무는 강한 사회성을 지닌 종으로, 대부분 무리를 이루어 생활하며 무리 내 서열과 상호작용을 통해 사회적 구조를 형성한다. 특히 일부 종은 평생 동안 동일한 배우자와 결속하는 평생 짝짓기(monogamy) 성향을 보이며, 이는 높은 짝 충실성과 번식 성공률로 이어진다. 사회적 유대는 단순히 번식 성공뿐 아니라 스트레스 완화와 행동 안정성에도 기여한다. 반려 환경에서도 반려앵무는 사육자와의 초기 애착 형성이 중요하며, 생후 0~4개월 동안 안정적 애착이 형성되지 못할 경우 이후 폭력성, 자해, 불안 행동 등으로 이어질 수 있음이 보고되었다. 이는 반려조류 관리에서 사회적 교감 훈련과 환경 제공이 필수적임을 뒷받침한다.¹⁰⁾

환경적 요인이 스트레스 반응을 유발한 대표적인 사례는 2023년 5월 발생한 앵무새 집단 폐사 사건에서 확인할 수 있다. 당시 국내 한 지역에서는 대규모 건설 공사장에서 발생한 극심한 소음과 진동으로 인해, 인근에서 사육 중

9) Andrew U. Luescher (Ed.). 전계서, pp. 183, 302-304.

10) Andrew U. Luescher (Ed.). 전계서, pp. 64-66, 141-143, 196, 304.

이던 앵무새 427마리가 단기간에 폐사하였다. 법원은 소음으로 인한 직접적 피해를 인정하여 건설사에 손해배상 책임을 부과하였는데, 이는 환경적 스트레스가 단순한 불편함을 넘어 대규모 폐사와 같은 치명적 결과로 이어질 수 있음을 단적으로 보여준다.¹¹⁾ 이러한 사례는 반려조류 복지의 취약성을 드러내는 동시에, 스트레스 관리 연구가 단순한 학문적 관심을 넘어 사회적 필요성으로 이어진다는 사실을 입증한다.

반려앵무의 발달 단계 역시 스트레스 민감성과 밀접한 연관을 가진다. 특히 생애 초기, 즉 생후 0~4개월은 애착 형성의 결정적 시기로 알려져 있다. 이 시기에 사육자와 안정적인 애착 관계를 맺지 못한 개체는 이후 교감 훈련에 어려움을 겪으며, 성조가 된 후에는 공격성 증가, 폭력적 행동, 혹은 사육자에 대한 지속적인 불신으로 이어질 수 있다. 다시 말해, 초기 발달 단계에서의 심리적 안정이 평생의 행동 패턴을 결정하는 중요한 요인으로 작용하는 것이다. 이러한 특성은 분양 시장에서 아기 반려앵무가 성조보다 온순하다는 일반적 인식으로도 나타나며, 이는 초기 애착 형성이 반려동물로서의 적응성에 얼마나 중요한지를 잘 보여준다. 그러나 현재 반려조류 시장에서는 애착 형성과 심리적 안정감을 증진시킬 수 있는 관리 도구나 체계적 교육 방법이 매우 부족한 상황이다. 이로 인해 관리가 실패한 개체는 주인과의 관계 악화, 문제 행동 발생, 정서적 불안정으로 인해 결국 자연으로 방치되거나 유기되는 사례가 전 세계적으로 보고되고 있다. 유기된 반려앵무는 적절한 보호 없이 방치되면서 심리적·신체적 건강이 심각하게 악화되고, 자해 행동(깃털 뽑기), 우울증, 공격성 등의 형태로 표출되기도 한다. 이러한 문제는 단순히 개인적 차원의 사육 실패를 넘어, 사회적·동물복지적 차원에서 심각한 이슈로 부각되고 있다.¹²⁾

아기 반려앵무는 성조에 비해 온순하고 조용하여 분양이 활발히 이루어지지만, 애착 형성과 심리적 안정감을 증진시킬 수 있는 관리 도구는 여전히 부족하다.¹³⁾ 이러한 관리 부재는 행동 문제와 복지 저하로 이어질 수 있으며,

11) 문현경. (2023). “앵무새 떼죽음 당했다”... 건설사와 5년 싸움, 대법서 반전. 『중앙일보』. Retrieved from <https://www.joongang.co.kr/>

12) Andrew U. Luescher (Ed.). 전계서, pp. 83-89, 95, 179-180.

13) Uehling, J. J., Tallant, J., & Pruett-Jones, S. (2019). Introduced and naturalized parrots in

일부 개체는 사육 실패 후 유기되거나 방사되어 야생 개체군으로 확산되고 있다.

실제로 미국 본토에서는 반려조의 탈출 및 방사로 인해 56종의 앵무류가 관찰되었고, 그중 25종이 23개 주에서 번식 중인 것으로 보고되었다.¹⁴⁾ 이는 방치된 반려 앵무가 지역 사회에서 소음 공해, 농작물 피해, 생태계 교란 등 야생 앵무새는 수km 이상의 영역을 비행하며, 먹이 탐색, 사회적 상호작용, 짝짓기, 포식자 회피 등 다양한 활동을 통해 복합적 행동 레퍼토리를 발휘한다. 그러나 사육 환경에서는 공간적 제약, 사회적 고립, 단조로운 자극 등으로 인해 본래의 행동을 충분히 표현하지 못하는 경우가 많다. 이러한 괴리는 울음소리, 물건 씹기, 잦은 날갯짓과 같은 정상 행동조차 문제 행동으로 오인되게 만들며, 관리 실패 시 유기와 복지 문제로 이어진다. 따라서 반려조류 관리에서는 단순한 먹이 공급과 청결 유지에 그치지 않고, 풍부한 환경 제공과 행동 표현 기회의 보장이 병행되어야 한다.¹⁵⁾

반려앵무의 스트레스 반응은 자극의 강도와 지속 시간에 따라 급성 스트레스와 만성 스트레스로 구분되, 반대로 안정적이고 복지 수준이 높은 상태에서는 특징적인 이완 행동들이 나타난다. 편안한 상태의 반려앵무는 깃털 손질(preening), 부리 갈기(beak grinding), 기지개(stretching), 깃털 털기(fluffing) 등을 반복적으로 수행하며, 이는 근육 이완과 심리적 안정의 지표로 해석된다. 또한 사육 환경에서 사회적 손질(allopreening)과 놀이(play behavior)는 높은 신뢰와 친밀감을 나타내는 행위로 보고되며, 이러한 사회적 상호작용은 개체 간 유대 형성뿐 아니라 스트레스 완화에도 중요한 역할을 한다. 나아가 장난감, 운동 공간 제공과 사육자와의 원활한 상호작용 등의 환경이 제공될 때 이러한 긍정적 행동 빈도가 증가한다고 명시하였다. 따라서 반려앵무의 복지를 평가하기 위해서는 생리적 지표뿐 아니라 행동적 복지 행동(behavioral welfare indicators)을 병행 관찰하는 것이 필수적이다.¹⁶⁾ 이러한 대표적 긍정 행동을 [표 1-3]에 정리하였다.

the contiguous United States. 『Journal of Ornithology』, 160, 907-919

14) Uehling, J. J., Tallant, J., & Pruett-Jones, S. (2019). 전계논문, pp. 907-919.

15) Andrew U. Luescher (Ed.). 전계서, pp. 45-46, 60-61, 313-314.

16) Andrew U. Luescher (Ed.). 전계서, pp. 45-46, 60-61, 313-314.

[표 1-3] 반려앵무의 심리적 안정 행동 지표 요약

구분	대표 행동	행동의 생리적·심리적 의미
이완 행동 (Comfort behaviors)	깃털 손질(Preening) 부리갈기(Beak grinding) 기지개(Stretching)	근육 이완 및 심리적 안정 상태를 나타내며, 스트레스 해소와 수면 준비 단계에서 주로 관찰됨
사회적 행동 (Social behaviors)	사회적손질(Allopreening) 놀이(Play behavior)	신뢰와 애착을 형성하는 상호작용으로, 사회적 유대 강화 및 스트레스 완화에 기여
환경 풍요화 반응 (Environmental enrichment responses)	장난감 탐색, 운동, 사육자와의 교감	환경 자극이 풍부할수록 긍정적 행동 빈도가 증가하며, 복지 수준 향상을 반영

종합하면, 반려앵무는 높은 지능과 사회성으로 인해 인간과 깊은 교감을 형성할 수 있는 종이지만, 동시에 환경 변화와 사회적 결핍에 극도로 취약하다는 특징을 지닌다. 이는 사육 환경의 미세한 차이가 심각한 스트레스 반응으로 이어질 수 있음을 의미하며, 따라서 반려조류의 복지를 위해서는 과학적이고 체계적인 스트레스 평가 및 관리 연구가 절실히 요구된다. 본 연구는 이러한 필요성을 반영하여, 반려앵무의 행동과 스트레스 간 상관관계를 정량적으로 규명하고, 이를 바탕으로 반려조류의 심리적 안정을 과학적으로 평가할 수 있는 새로운 틀을 제시하고자 한다.

1.1.3 AI 기반 조류 행동 패턴 분석 연구의 개요와 동향

반려앵무의 행동은 개체의 심리적 안정 상태를 반영하는 중요한 지표로, 깃털 손질·기지개·줄음과 같은 정상 행동은 안정감을 나타내고, 깃털 뽑기·반복적 이동(pacing)·반복 날갯짓 등은 스트레스 신호로 알려져 있다.¹⁷⁾ 이러한 반려앵무의 정상 행동과 비정상 행동을 [표 1-4]에 구분하였다.

17) Andrew U. Luescher (Ed.). 전계서, pp. 198-200, 210-215, 307-311.

[표 1-4] 반려앵무의 정상 및 비정상 행동 구분

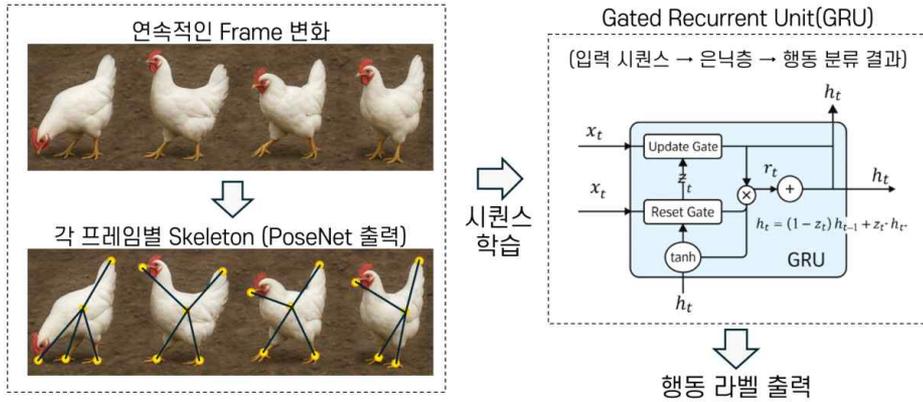
구분	대표 행동	심리상태	주요 특징
정상 행동	깃털 손질 (Preening)	안정	깃 정돈, 체온 유지
	기지개 (Stretching)	안정	양날개 혹은 한쪽 날개 확장
	줄음·수면 (Perching sleep)	안정	눈 반쯤 감음, 한 발로 서 있음
이상 행동	깃털 뽑기 (Feather plucking)	스트레스	특정 부위 털 빠짐, 상처
	스트레스성 반복이동 (pacing)	스트레스	안절부절 못하고 걸어다니는 행동
	반복 날갯짓 (Repetitive flapping)	불안	동일 자세 반복, 과활동
	구석 숨기 (Corner hiding)	공포	어두운 곳으로 숨음

최근에는 이러한 행동을 정량적으로 분석하기 위해 Object Detection과 Keypoint 추정 등 AI 기반 기술이 활용되고 있다. 그러나 조류 대상 연구는 제한적이며, 특히 반려조류는 자연 서식 환경 중심의 선행연구와 특성이 달라 기존 자료의 직접적 활용에 한계가 있다. 반면, 가금류 분야는 조류와 형태·동작 특성이 유사하여 기술적 참고 사례로 유용하다.

가금류를 대상으로 한 Multi-Chicken Pose(MCP) 모델은 YOLO 기반 탐지와 Keypoint 추정을 결합한 다단계 구조를 통해 mAP 0.652, RMSE 17.3px의 성능을 보이며 효율성을 입증하였다.¹⁸⁾ MCP 모델의 구조적 특징을 [표 1-5]에 정리하였다. 해당 모델의 구조는 [표 1-5]에 제시하였다. 그러나 닭의 신체 비율을 전제로 설계되어 있어 소형 조류인 반려앵무에 그대로 적용하기 어렵고, 별도의 최적화가 필요하다.

Keypoint 기반 시계열 분석에서는 PoseNet으로 프레임 단위 Skeleton을 추출하고 GRU를 통해 시간적 변화를 학습하는 방식이 시도되었으며, [그림 1-2]는 이러한 흐름을 나타낸다. 다만, 조류의 빠른 동작 변화나 사육 환경의

18) Fang, C., Wu, Z., Zheng, H., Yang, J., Ma, C., & Zhang, T. (2024). MCP: Multi-chicken pose estimation based on transfer learning. 『Animals』, 14(12), 1774. <https://doi.org/10.3390/ani14121774>



[그림 1-2] Keypoint + GRU 기반 행동 패턴 분석의 시간적 흐름

복잡성, 헛대·먹이통 등 주변 요소와의 상호작용을 충분히 반영하지 못해 행동 구분의 정밀도는 제한적이다.

PoseNet으로 각 프레임 추출 Skeleton 좌표를 GRU 모델에 입력하여, 시간적 시퀀스를 학습함으로써 새의 행동을 분류하는 과정을 도식화한 것을 [그림 1-2]에서 나타낸다. 그러나 기존 연구는 조류의 빠른 날갯짓이나 헛대, 먹이통 및 사육기구 등 환경 요소와의 상호작용을 고려하지 않아, 복잡한 케이지 환경에서의 세밀한 행동 구분에는 명확한 한계가 있다. 주변 환경 요소와의 공간적 관계까지 반영하였다면, 보다 다양한 연계 정보를 활용해 행동 패턴 분석의 정확도를 높일 수 있었을 것으로 판단된다.

YOLO와 같은 객체 탐지 기반 접근법은 Keypoint 방식보다 데이터셋 수요가 적고, 학습 안정성이 높으며, 처리 단위가 프레임 기준으로 작동하므로 실시간 분석에 적합하다. 특히 신체 부위 간 경계가 불분명하고 자세 변화가 큰 조류를 대상으로 할 경우, 객체 탐지 방식이 효과적이다. 실제로 YOLO 및 SSD를 활용한 앵무새 11종 분류 실험에서는 96.6%의 정확도를 달성하였고, 이는 종 분류를 넘어 밀수 및 불법거래 종의 식별 등 응용 가능성을 시사한다. 해당 모델은 낮은 연산량에도 불구하고 높은 정확도를 확보할 수 있어, 실시간 모니터링이 요구되는 상황에서 유용하다.¹⁹⁾

19) Jang, W., & Lee, E. C. (2021). Multi-class parrot image classification including subspecies with similar appearance. 『Biology』, 10(11), 1140. <http://doi.org/10.3390/biology10111140>

1.2 연구의 필요성

1.2.1 AI 기반 행동 패턴 분석 연구의 필요성

AI 기반 행동 패턴 분석 연구의 목적은 기존 관찰 중심 연구의 주관성과 불안정성을 극복하고, 반려앵무의 심리적 안정 상태를 객관적 지표로 정량화하기 위함이다. 전통적으로 조류 및 가금류 분야에서 이루어진 행동 분석은 특정 행동이 얼마나 자주, 얼마나 오래 나타나는지를 개별 지표로 측정하여 해당 시점의 상태를 평가하고, 이를 사육 환경 개선에 참고하는 데 초점을 두어 왔다. 또한 지금까지의 반려앵무의 행동 연구는 대부분 연구자의 시각적 판단(VI: Visual Inspection)에 의존해 왔으며, 이 방식은 관찰자의 주관성에 따른 편차가 크고, 장시간 반복 관찰에 따른 인력·시간 소모가 심하며, 복잡한 행동 패턴이나 다중 개체 간 상호작용을 실시간으로 분석하기 어렵다는 한계가 있다. 또한 동일한 조건에서도 결과의 재현성이 낮아, 객관적 정량 분석 및 대규모 자동화 연구로의 확장이 제한적이다.²⁰⁾ 특히 개체 간 행동 편차가 크고, 환경 자극에 따라 반응이 민감하게 변화하는 반려앵무의 특성상, 이러한 관찰 방식만으로는 스트레스 징후를 조기에 감지하거나 장기적 행동 패턴을 분석하기 어렵다. 따라서 행동을 자동화하고 정량화할 수 있는 AI 기반 분석 체계의 도입이 필수적이다.



[그림 1-3] VI(Visual Inspection) 행동연구 방식의 한계

20) Fazzari, E., Romano, D., Falchi, F., & Stefanini, C. (2025). Animal behavior analysis methods using deep learning: A survey. 『Expert Systems with Applications』, 289, 128330. <https://doi.org/10.1016/j.eswa.2025.128330>

본 연구에서 의미하는 행동 패턴 분석은 단일 행동의 빈도나 지속시간을 넘어서, 여러 행동 유형의 발생 순서와 반복 양상, 행동 간 전이 구조, 그리고 안정 행동과 스트레스성 행동의 비율을 통합적으로 해석함으로써 개체의 정서 상태와 스트레스 수준을 AI 기술을 통해 구조적으로 파악하려는 접근이다.

기존 Keypoint 기반 자세 추정이나 단일 Object Detection 중심의 연구들은 조류의 복잡한 행동 스펙트럼을 충분히 설명하지 못하였다. 반려앵무는 빠르고 불규칙한 움직임, 케이지 내 먹이통·훗대·장난감 등 다양한 배경 요소, 깃털로 인한 윤곽 불명확성 등으로 인해 기존 모델의 탐지 정확도가 저하되는 경향을 보인다. 이는 단순히 기술적 한계에 그치지 않고, 반려앵무의 스트레스 행동을 과학적으로 규명하려는 연구의 신뢰성을 저해한다. 따라서 반려앵무의 형태적·행동적 특성에 특화된 AI 모델을 개발하고, 행동 패턴을 정밀하게 구분할 수 있는 새로운 접근이 필요하다. [표 1-5]는 반려앵무 행동 패턴 분석을 위한 다양한 접근 방식의 특징과 한계를 비교하여, 본 연구의 다단계 분석 방법의 필요성을 제시한 것이다.

또한 기존 조류 연구의 대부분은 자연 서식지 내 생태 관찰이나 가금류를 대상으로 한 산업적 연구에 집중되어 있어, 반려앵무의 사회적 행동 특성이나 복지 환경을 반영하지 못하였다. 가금류와 앵무류는 구조적 유사성을 지니지만, 사회성, 애착 형성, 인지 능력 등에서 근본적 차이를 보인다. 따라서 가금류 행동 패턴 분석 모델을 단순 전이학습으로 적용하는 것은 한계가 명확하며, 반려앵무에 최적화된 AI 기반 행동 패턴 분석 체계 확립이 필요하다. 이러한 차별화된 접근을 통해서만 반려 환경에서의 스트레스 행동을 실시간으로 탐지하고, 복지 지표로 환원할 수 있는 과학적 평가 체계를 구축할 수 있다.

YOLO 계열 탐지기와 스켈레톤 추출을 결합한 다단계 분석 방식은 이러한 요구를 충족시킬 수 있는 효과적인 방법론이다. 반려앵무의 머리·날개·발·꼬리 등 세부 부위를 단계적으로 탐지하고, 케이지 내 물통, 먹이통, 훗대 등의 세그멘테이션 정보를 융합하면, 행동의 공간적 맥락과 시간적 연속성을 동시에 분석할 수 있다. 이는 단순히 ‘행동 발생 여부’를 기록하는 수준을 넘어, 각 행동의 의미와 환경적 배경을 함께 해석함으로써 스트레스 반응의 인과 구조를 밝히는 데 기여한다. 따라서 본 연구와 같은 AI 기반 반려앵무 행동 패턴 분석 연구는

[표 1-5] 반려앵무 행동 패턴 분석 연구 방식별 비교

구분	연구 방식	장점	한계
시각 관찰 VI (VisualInspection)	육안 평가 기록	즉시 반응 관찰 가능	피로, 일관성 부족, 정량화 불가
Keypoint 추정	자세 구조 분석	국소 자세 구분 가능	배경·속도 간섭에 취약
객체 탐지 (YOLO)	실시간 인식	안정적 탐지, 적은 데이터 요구	자세구조분석 취약
다단계 분석 (본 연구)	객체+부위+환경요소 결합	공간·시간 융합, 높은 신뢰도	계산량 증가

반려조류 복지 향상을 위한 실질적 해법으로서 반드시 수행되어야 한다. 더 나아가 실시간 영상 처리와 대규모 데이터 축적을 가능하게 하여, 장기적 관찰이 어려운 반려 환경에서도 자동화된 모니터링을 실현한다. 이는 일시적 관찰에 의존하던 기존 연구의 한계를 극복하고, 개체별 행동 변화의 추이를 연속적으로 기록함으로써 스트레스의 누적 양상을 정밀하게 파악할 수 있게 한다. 특히 반복 날갯짓, 깃털 뽑기, 일정 경로 이동과 같은 비정상 행동의 발생 빈도와 지속 시간을 정량적으로 분석할 수 있다는 점에서, AI 기반 행동 패턴 분석은 반려앵무의 심리적 상태를 실증적으로 규명하는 데 필수적인 연구 방향이다.

AI 기반 행동 패턴 분석 연구는 단순한 기술적 시도가 아니라 반려앵무의 복지와 스트레스 관리 체계를 과학적으로 확립하기 위한 핵심 기반이다. 본 연구는 이러한 필요성을 반영하여, 객체 탐지와 스켈레톤 분석, 세그멘테이션 기반 공간 인식 기술을 융합한 정량적 분석 프레임워크를 제시하고자 한다. 이를 통해 반려앵무의 행동을 자동화된 시각지능 시스템으로 분석함으로써, 반려조류의 심리적 안정과 스트레스 수준을 객관적으로 평가할 수 있는 새로운 연구 패러다임을 확립하고자 한다.

1.2.2 기존 스트레스 측정 방법의 한계

반려앵무는 외부 자극에 민감하게 반응하며, 스트레스 수준은 복지와 직결

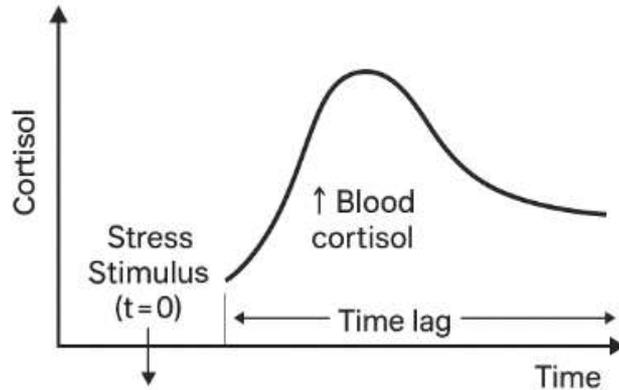
[표 1-6] 조류 스트레스 측정 주요 방법 비교표

구분	이미지	주요 지표	특징
코티졸분석		분변·혈액 내 코티졸 대사물	생리적 지표로 신뢰도 높음
열화상분석 (체표온도)		부위별 체표 온도 변화	비침습·반복측정 가능
행동 관찰 VI(Visual Inspection)		깃털 뽑기, 반복 날갯짓 등	직관적, 비전문장비 가능

되는 핵심 지표로 평가된다. 기존 조류나 앵무새 및 가금류의 연구에서는 이러한 스트레스를 정량적으로 파악하기 위해 코티졸(cortisol) 분석, 열화상(thermal imaging), 심박수 및 체온 측정, 그리고 육안 행동 관찰 등을 활용해 왔다. 그러나 이들 방법은 각각의 장점에도 불구하고, 조류의 복잡한 생리적·행동적 특성을 충분히 반영하지 못하는 한계를 지닌다. 따라서 기존 측정 방법의 한계를 명확히 인식하는 것은 향후 정밀한 스트레스 분석 체계를 구축하기 위한 선행 단계로서 필수적이다. [표 1-6]은 조류 스트레스 측정에 사용되는 주요 방법들의 비교표로, 코티졸분석·열화상분석·VI 각각의 지표와 특징을 요약한 것이다.

코티졸 기반의 생리학적 분석은 대표적인 스트레스 평가 지표로 널리 활용되어 왔으나, 시간 지연성과 개체 간 변동성이 크다는 본질적 한계를 갖는다. 코티졸은 스트레스 자극 후 일정 시간이 지난 뒤에 분변이나 혈액에서 검출되며, 식이 상태·성별·채취 시각 등 다양한 생리 요인에 영향을 받는다.²¹⁾ 또한 스트레스가 해소된 이후에도 일정 시간 높은 수치를 유지할 수 있어, 실시간 상태를 반영하기 어렵다. 조류의 경우 스트레스 자극 후 분변 코티졸 대사까지 수 시간이 소요되어, 급성 스트레스 반응을 즉각적으로 감지하기 어렵다. 따라서 코티졸 단독으로는 단기적 스트레스 변화를 정밀하게 포착하기 어

21) Palme, R., Rettenbacher, S., Touma, C., El-Bahr, S. M., & Möstl, E. (2005). Stress hormones in mammals and birds: Comparative aspects regarding metabolism, excretion, and noninvasive measurement in fecal samples. 『Annals of the New York Academy of Sciences』, 1040, 162-171. <https://doi.org/10.1196/annals.1327.021>



[그림 1-4] 코티졸 기반 스트레스 분석의 한계 개념도

려워, 다른 지표와의 보완적 접근이 필요하다.

[그림 1-4]는 스트레스 자극($t=0$) 이후 일정 시간의 Time lag을 거쳐 혈중 코티졸 농도가 상승하고, 이후 서서히 감소하는 과정을 나타낸 개념도이다. 이는 코티졸 분석이 급성 스트레스 반응을 실시간으로 반영하기 어렵다는 한계를 시각적으로 보여준다.

열화상 분석은 비침습적(non-invasive)이며 반복 측정이 용이하다는 장점으로 주목받고 있으나, 외부 환경 요인에 매우 민감하다는 단점이 있다. 열화상 카메라는 조류의 체표면 온도를 측정하여 스트레스 반응을 추정하지만, 주변 온도·조도·거리·깃털의 밀도 및 방향 등에 따라 측정값이 크게 달라진다.²²⁾²³⁾ 특히 앵무새와 같이 깃털 피복이 조밀하고 머리와 부리 부위만 노출된 종에서는 열화상 측정 부위의 일관성을 확보하기 어렵다. 또한 측정 시 개체의 움직임이 많거나 비행 상태일 경우 열 영상의 왜곡이 발생해, 실제 체온 변화와 스트레스 반응 간의 상관성을 안정적으로 추정하기 어렵다. 따라서 열화상 단독 측정은 보조적 수단으로 제한되는 경향이 있다.

22) Jerem, P., Herborn, K. A., McCafferty, D. J., & Nager, R. G. (2015). Thermal imaging to study stress non-invasively in unrestrained birds. 『Journal of Visualized Experiments』, 105, e53184. <https://doi.org/10.3791/53184>

23) Tabh, J. K. R., Burness, G., Wearing, O. H., Tattersall, G. J., & Mastro Monaco, G. F. (2021). Infrared thermography as a technique to measure physiological stress in birds: Body region and image angle matter. 『Physiological Reports』, 9(11), e14865. <https://doi.org/10.14814/phy2.14865>

행동 기반 평가 방식은 조류 스트레스 연구에서 가장 오래된 방법이지만, 관찰자의 주관성과 정량화의 어려움이라는 한계가 있다. 조류의 깃털뽑기, 반복 날갯짓, 안절부절 못하고 걸어다니기 등의 행동은 스트레스의 대표적 지표로 제시되어 왔으나²⁴⁾, 그 해석은 관찰자의 경험에 의존하는 경우가 많다. 동일한 행동이라도 개체의 성격, 사회적 상황, 환경 자극에 따라 다르게 나타나며, 단시간 관찰로는 누적 스트레스를 반영하기 어렵다. 또한 VI 영상 기반 관찰 역시 수작업 분류가 필요해 장기 모니터링이 제한적이다. 따라서 행동 기반 평가는 실시간성·객관성 측면에서 보완이 필요하다. [표 1-7]은 기존 스트레스 측정 방법의 주요 한계와 이를 보완하기 위한 다른 측정방법의 개발 필요성을 정리한 표이다.

이처럼 코티졸, 열화상, 행동 관찰 등 기존 스트레스 평가 방법은 각각의 접근 방식에 따라 한계를 지니며, 단일 지표만으로는 스트레스의 복합적 양상을 완전하게 설명할 수 없다. 조류의 스트레스 반응은 생리적, 행동적, 환경적 요인이 상호 작용하는 다층적 현상으로 나타나기 때문에, 정확한 평가를 위해서는 다양한 지표를 통합적으로 분석하는 복합적 접근이 필요하다.

[표 1-7] 스트레스 측정 방식의 한계 및 새로운 방식의 필요성

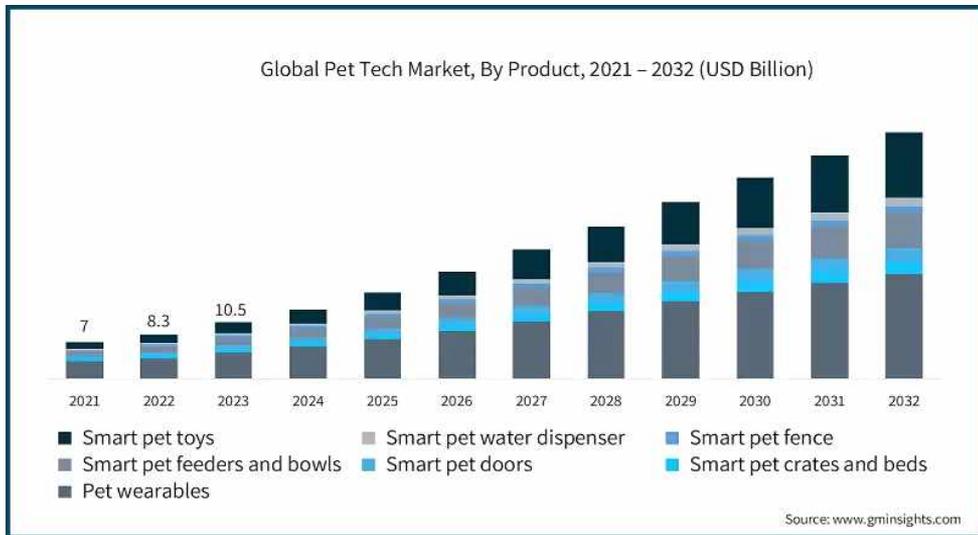
구분	주요 한계	필요성
코티졸 분석	스트레스 자극 후 일정 시간의 지연 발생 → 급성 반응 반영 어려움	실시간성 확보를 위한 다른 필요
열화상 분석	외부 온도·조도·거리·깃털 밀도 등 외부 요인에 민감, 측정 일관성 낮음	환경 변수에 보정 가능한 보조 지표 필요
행동 관찰	관찰자 경험에 따른 주관성이 높음. 모니터링 어렵고, 정량화에 한계를 가짐.	객관적 분석체계 (AI 기반 행동 패턴 분석) 병행 필요

24) van Zeeland, Y. R. A., Spruit, B. M., Rodenburg, T. B., Riedstra, B., van Hierden, Y. M., Buitenhuis, B., Korte, S. M., Lumeij, J. T., & R. A. (2009). Feather damaging behaviour in parrots: A review with consideration of comparative aspects. 『Applied Animal Behaviour Science』, 121(2), 75-95. <https://doi.org/10.1016/j.applanim.2009.09.006>

1.2.3 반려앵무 문화에 펫테크(Pet-tech) 필요성

펫테크는 반려동물 Pet과 기술 Technology를 합성한 용어로, 반려동물을 보다 안전하고 편리하게 돌보는 데 필요한 제품과 서비스에 사물인터넷(IoT), 인공지능(AI), 빅데이터 등의 첨단 기술이 결합된 산업을 의미한다.²⁵⁾ 초기 펫테크 제품은 주인이 집을 비운 동안 반려동물을 관찰하거나 먹이를 제공하고, 실시간으로 음성 및 화상 대화를 통해 교감할 수 있도록 지원하는 IoT 기반 장치에 집중되어 있었다. 그러나 최근에는 반려동물의 음성이나 신체 변화를 분석해 감정 상태를 전달하는 의사소통 기기, 개별 행동 패턴을 학습해 반응하는 인공지능 장난감 등 빅데이터와 AI 기반의 고도화된 제품들이 등장하고 있다.²⁶⁾

펫테크 산업은 본질적으로 반려동물을 키우는 사람을 대상으로 기술을 기반으로 한 솔루션을 제공하는 업종으로, 크게 리테일, 하드웨어, 플랫폼 영역으로 구



[그림 1-5] 글로벌 펫테크 시장 규모와 제품별 세부 구성 (2021-2032)

[출처] Global Market Insights (www.gminsights.com)

25) KB금융지주 경영연구소. (2021). 펫테크, 기술로 반려동물을 널리 이롭게 하다. 서울: 『KB지식비타민』, p. 2.

26) 한국무역협회 신산업연구실. (2022). 성장하는 펫케어 산업 최신 트렌드와 우리 기업 글로벌 경쟁력 강화 방안. 서울: 『한국무역협회』.

분된다. 리테일 분야에는 반려동물 사료와 용품을 다루는 온라인 커머스와 구독 서비스가 포함되며, 하드웨어 분야에는 자동 급식기, 훈련 보조기기, 장난감, 위생 관리, 위치 추적기와 같은 다양한 디바이스가 포함된다. 또한 플랫폼 분야에서는 반려동물 위탁 돌봄 서비스, 산책 대행, 수의사 상담 등을 연결하

[표 1-8] 출시된 반려동물군별 펫테크 제품 기능 분류 및 현황 비교

구분	주요기능	반려견	반려묘	관상어	반려조
급식·급수 관리	자동 급식기, 수분 보충기, 스마트 밥그릇	○	○	○ (자동 피더, 수위 감지)	×
환경 제어	온습도, 향온, 공기질, 조명	△ (공기청정기 일부)	△ (스마트 화장실 포함)	○ (향온기, 디밍기)	×
건강·생체 모니터링	심박·체온·소변·걸음 수 추적	○ (AI 목걸이, 스마트밴드)	○ (AI헬스케어, 체중센서)	△ (수질·온도 센서 중심)	×
위치·활동 추적	GPS, 운동량 측정, 산책 루틴관리	○	△	×	×
교감·놀이	원격 로봇, AI 장난감, 영상 대화	○ (펫로봇, 펫필스)	○ (피트니스봇, 런닝머신)	△ (각종 어항소품)	×
배변·위생 관리	스마트 패드, 자동 화장실, 물교체 시스템	○	○	○ (자동정화·필터)	×
플랫폼 연동 서비스	모바일 모니터링, 데이터 통합, 돌봄 매칭	○	○	△	×
○: 상용화 제품 존재 / △: 제한적 적용 / ×: 제품 전무 → 조류(반려앵무) 대상 펫테크 제품은 전무하며, 기술 적용 공백이 뚜렷함.					

[출처] 네이버스토어. (2025). 반려동물 펫테크 제품 검색결과

는 모바일 애플리케이션과 소프트웨어 기반 서비스가 주를 이룬다.²⁷⁾

미국 소비자기술협회(CTA)는 펫테크 제품을 용도에 따라 다섯 가지로 분류하고 있으며, 이 시장은 펫 휴머니제이션(Pet Humanization) 트렌드의 확산, 1인·2인 가구의 반려동물 양육 증가, 그리고 펫케어 시장의 지속적 성장과 같은 사회적·경제적 요인에 의해 빠르게 성장할 것으로 전망된다. 펫 휴머니제이션은 반려동물을 가족이나 친구와 같은 인간의 대리자로 인식하고, 인간과 동일한 속성을 지닌 인격체로 대우하는 현상을 의미한다. 이러한 인식 변화는 천연 및 유기농 원료를 사용한 자연식 사료, 사람도 먹을 수 있을 만큼 안전한 재료와 공정을 적용한 휴먼그레이드(Human Grade) 사료 등 프리미엄 사료의 수요를 높이고 있다.²⁸⁾

나아가 반려동물의 웰빙을 위한 제품과 의료·건강관리 서비스에 대한 반려인의 관심 역시 점차 증가하면서, 펫테크 산업의 성장 가능성을 더욱 확대시키고 있다.²⁹⁾

관상어는 물을 관리하는 기술이 들어가기 때문에 오래전부터 전자기술이 접목되어 온 분야이며, 최근에 들어서 IT 기술이 접목되어 스마트한 펫테크 제품들이 출시되고 있다.

현재까지 반려앵무를 대상으로 한 펫테크 제품은 세계적으로 출시된 사례가 전무하며, 연구 또한 이제 막 시작되는 단계에 있다. 특히 반려앵무는 다른 반려동물에 비해 각별한 스트레스 관리가 필요한 특성을 지니고 있음에도 불구하고, 관련 펫테크 기술 제품은 거의 개발되지 않은 상태이며, 단순 아이디어를 접목한 상품조차도 찾아보기 힘들고 매우 제한적으로 존재하고 있다.

그러나 2023년 4월을 기점으로 반려앵무 영상통화라는 이색 연구주제로 펫테크 연구가 국제적으로 주목을 받기 시작했다. 실제로 미국 노스이스턴대학교와 매사추세츠공과대학교(MIT) 공동 연구팀은 반려앵무 18마리를 대상으로 한 행태 관찰을 통해, 반려앵무가 영상통화를 통해 다른 무리와 교감하는 것을 즐기며 외로움을 덜 느낀다는 결과를 도출하였다. 해당 연구는 미국

27) KB금융지주 경영연구소, 전게서. p. 2.

28) KB금융지주 경영연구소, 전게서. p. 3.

29) KB금융지주 경영연구소, 전게서. p. 3.

[표 1-9] 반려앵무 펫테크 연구 사례 비교

구분 및 이미지	연구 주요내용	주요결과
<p>[영상통화 연구]</p> 	<p>태블릿을 이용한 앵무새 간 영상통화, (2023, HCI, Hamburg, Germany)</p>	<p>사회적 교감 증가 및 외로움 완화</p>
<p>[터치스크린 상호작용연구]</p> 	<p>태블릿을 터치하며 색상 선택 및 게임. (2023, HCI, North- eastern Univ., USA)</p>	<p>인지 자극 및 상호작용 가능성 확인</p>

컴퓨터협회(ACM)가 주최한 ‘컴퓨터-인간 상호작용 학회 콘퍼런스(CHI 2023)’에서 발표되었으며, 뉴욕타임스(NYT)와 영국 가디언 등 주요 언론에 소개되면서 큰 관심을 끌었다. 최근에는 영상통화 외에도 반려조를 대상으로 한 초기 펫테크 응용 연구가 소규모로 시도되고 있다. Kleinberger 등(2024)은 반려앵무를 대상으로 터치스크린 기반 상호작용 시스템을 개발하여, 조류가 화면 속 시각 자극에 반응하고 간단한 게임인 풍선 터뜨리기, 색상 선택 등에 참여할 수 있음을 확인하였다. 해당 연구는 태블릿 인터페이스를 활용해 반려앵무가 부리와 혀를 이용해 터치 입력을 수행함으로써, 인지 자극과 사회적 반응을 동시에 유도할 수 있는 가능성을 제시하였다. 이러한 시도는 단순 관리형 기기를 넘어, 행동·인지 중심의 반려조 맞춤형 펫테크 연구가 본격화 될 수 있음을 보여준다.³⁰⁾

30) Kleinberger, R., O'Connor, J. T., McMahon, M., & Hirskyj-Douglas, I. (2024). No More Angry Birds: Investigating Touchscreen Ergonomics to Improve Tablet-Based Enrichment for Parrots. 『CHI '24: Proceedings of the 2024 CHI Conference on Human Factors in Computing Systems』. <https://doi.org/10.1145/3613904.3642119>

1.3 연구의 범위와 목적

1.3.1 AI 기반 반려앵무 행동 패턴 분석의 검증 및 평가

본 연구의 범위는 AI 기반 반려앵무 행동 패턴 분석 시스템의 정확성과 신뢰성을 검증하고, 기존 육안 관찰 VI 방식과의 비교를 통해 그 타당성을 평가하는 데 있다. 반려앵무는 개체별 행동 편차가 크고, 환경 변화에 민감하게 반응하는 종으로, 기존의 VI 방식만으로는 세밀한 행동 변화를 정량적으로 파악하기 어렵다. 이에 따라 본 연구는 딥러닝 기반 객체 탐지 모델과 세그멘테이션 기법을 결합하여, 반려앵무의 주요 신체 부위를 자동 탐지하고 행동 패턴을 정량화할 수 있는 AI 기반 분석 체계를 구축하였다. 본 연구는 이 체계를 실제 사육 환경에 적용하고, VI 결과와의 비교를 통해 분석 모델의 신뢰성과 재현성을 평가하고자 한다.

우선, AI 기반 탐지 및 행동 분류 모델의 성능을 정량적으로 검증함으로써, 제안된 시스템이 복잡한 사육 환경에서도 안정적으로 작동하는지를 확인하고자 한다. YOLOv8 기반의 탐지 구조를 적용하여 반려앵무의 머리, 날개, 발, 꼬리 등의 주요 부위를 식별하고, 각 부위의 좌표 변화를 시계열적으로 분석하여 행동 분류의 정확도를 측정한다. [표 1-10]은 본 연구에서 AI 기반

[표 1-10] 본 연구에서 다루려는 반려앵무의 행동 유형별 정의

행동 유형	정의	국문표현
Eating	부리가 먹이통에 닿고 머리 움직임이 반복됨	먹이섭취
Drinking	부리가 물통에 닿고 머리 움직임이 반복됨	음수
Stretching	날개가 외측으로 완전 전개됨	기지개
Resting	움직임이 없음	휴식
Bathing	물통에 몸 전체를 넣는 행동을 함	목욕
Pacing	새장 안을 지속적으로 돌아다니며 안전부절하거나 짧은 시간 내 방향을 반복 전환함	불안성 반복이동

행동 패턴 분석 모델의 학습 및 판정 기준으로 활용된 반려앵무의 주요 행동 유형과 그 운영적 정의를 나타낸 것이다. 먹이섭취(Eating), 음수(Drinking), 휴식(Resting), 목욕(Bathing), 기지개(Stretching), 불안성반복이동(Pacing) 6가지로 구분하였으며, 각 행동은 부위별 움직임의 시계열적 변화를 기반으로 자동 탐지 및 분류가 가능하도록 정의하였다. 이를 통해 행동별 특징을 명확히 규정함으로써, AI 분석 결과와 VI 결과 간의 비교·검증이 가능하도록 하였다.

본 연구는 AI 기반 반려앵무 행동 패턴 분석의 정확성과 타당성을 실험적으로 검증함으로써, 행동 관찰의 자동화와 정량화를 실현하고자 한다. 이를 통해 기존 VI 중심의 주관적 관찰을 보완하고, 행동·환경·생리 정보를 통합한 다층적 평가 체계의 구축 가능성을 제시한다. 궁극적으로 본 연구는 반려조류 복지 평가의 객관적 지표를 확립하고, 펫테크(Pet-Tech) 산업 및 스마트 사육 환경 시스템으로의 응용을 위한 기초를 마련하는 데 그 목적이 있다.

1.3.2 스트레스와 행동의 상관관계 규명

본 연구는 반려앵무가 보이는 다양한 행동이 단순한 습관적 움직임이 아니라, 심리적 안정상태 혹은 스트레스 상태를 반영하는 정량적 지표가 될 수 있음을 과학적으로 규명하고자 한다. 기존 연구에서는 이러한 행동을 주로 관찰자의 시각적 판단에 의존해 해석하였으나, 이 방식은 주관적 오류, 반복 측정의 한계, 장기 데이터 축적의 어려움 등 구조적 제약을 갖고 있었다. 따라서 본 연구에서는 AI 기반 행동 패턴 분석을 통해 이러한 행동의 발생 빈도·지속 시간·패턴 변화를 정량적으로 산출하고 비교함으로써 행동-스트레스 간의 연속적 상관구조를 규명하고자 한다.

반려앵무는 포유류와 달리 언어적 표현이 제한적이지만, 높은 인지 능력과 사회적 성향을 통해 다양한 비언어적 행동으로 정서 상태를 표현한다.³¹⁾ 이들 행동은 단순한 습관이나 반복동작이 아니라, 개체의 심리적 상태를 반영하는 핵심 생태학적 지표로 작용한다.

31) Piseddu, A., van Zeeland, Y. R. A., & Rault, J.-L. (2024). What we (don't) know about parrot welfare: A systematic literature review. 『Animals』, 14(12), 1537. <https://doi.org/10.3390/ani14121537>

[표 1-11] 정상·비정상 행동 분류 및 심리적 의미

구분	대표 행동	심리적상태	생리적 특징
안정 행동	Preening	안정	깃털 관리·체온 유지
안정 행동	Stretching	안정	근육 이완·비행 준비
안정 행동	Perching sleep	안정	수면·호흡 완화
불안/스트레스 행동	Feather plucking	스트레스	코티졸 ↑·피부 손상
불안/스트레스 행동	Repetitive flapping	스트레스	호흡수 증가·체온 ↑
불안/스트레스 행동	Pacing	스트레스	이동 경로 반복
불안/스트레스 행동	Corner hiding	스트레스	회피성 정서

[표 1-11]는 반려앵무의 주요 행동을 심리적 안정 여부에 따라 정상 행동과 비정상인 불안·스트레스 행동으로 구분하고, 각 행동이 나타내는 심리적 상태와 생리적 특징을 정리한 것이다. 안정 행동은 깃털 관리, 근육 이완, 체온 조절 등 생리적 균형 유지와 관련된 반면, 불안·스트레스 행동은 코티졸 상승, 반복 이동, 회피 등 부적응적 반응을 동반한다. 일반적으로 깃털 손질, 기지개, 졸음 및 수면, 장난감 놀이 등은 심리적 안정 상태에서 주로 나타나는 정상 행동이다. 이러한 행동은 깃털 유지, 체온 조절, 근육 이완, 비행 준비 등 생리적 목적과 밀접히 관련되며, 안정된 환경과 정서적 만족감을 반영한다. 반면, 깃털 뽑기, 반복적 날갯짓, 안절부절 못하는 행동, 구석 숨기, 공격적 자세 등은 스트레스가 누적되었거나 환경이 부적절할 때 관찰되는 비정상 행동으로 분류된다. 특히 깃털 뽑기와 반복 이동 행동은 장기적 스트레스의 누적과 환경 부적응을 나타내는 대표적 신호로 보고되며, 선행연구에서도 이러한 행동과 코티졸·코르티코스테론(cortisol·corticosterone) 농도 간의 양의 상관관계가 다수 확인되었다.³²⁾³³⁾ [표 1-10]은 [표 1-11]에서 분류된 행동 중 새장 내에서 관찰 빈도가 높거나, 스트레스 및 심리적 안정 상태를 대표할 수 있는 항목을 관찰자가 선정하여 AI 기반 행동 탐지 및 정량 분석 실험에 적용한 것이다.

32) van Zeeland, Y. R. A., Spruit, B. M., Rodenburg, T. B. 등, 전계논문, pp. 75-95.

33) Costa, P., Macchi, E., Valle, E., De Marco, M., Nucera, D. M., Gasco, L., & Schiavone, A. (2016). An association between feather damaging behavior and corticosterone metabolite excretion in captive African grey parrots (*Psittacus erithacus*). 『PeerJ』, 4, e2462. <https://doi.org/10.7717/peerj.2462>

VI 방식은 연구자의 주관적 판단에 의존하기 때문에 관찰자 경험에 따른 주관성이 높고, 모니터링이 어렵고, 정량화에 한계를 가지며 관찰자의 피로 누적, 해석 편차 등에 따라 결과의 일관성이 저하되는 문제가 있다. 이를 보완하기 위해 본 연구는 YOLO 기반 Object Detection 및 Keypoint 추정 기법을 활용하여, 반려앵무의 행동을 자동 탐지·정량화하는 AI 시스템을 구축하고자 하였다.

이러한 연구 접근은 반려조류 복지 평가를 과학적으로 체계화하는 데 기여할 뿐 아니라, 향후 스마트 사육환경 설계, 동물복지 인증 제도, 펫테크를 이용한 행동 모니터링 기술 개발 등으로의 응용 가능성을 확장시킬 것이며 장기적·실시간 스트레스 모니터링 시스템 구축에도 기여할 것으로 기대된다.

II. 이론적 배경 및 선행연구

2.1 인공지능 기반 조류 행동 패턴 분석 연구

2.1.1 반려앵무 행동 패턴 분석 연구 동향

최근 인공지능(AI)을 활용한 반려동물 행동 패턴 분석 연구는 반려견과 반려묘를 중심으로 빠르게 발전하고 있으나, 조류 특히 반려앵무를 대상으로 한 시도는 아직 초기 단계에 머물러 있다. 이는 단순히 연구 관심의 부족 때문만이 아니라, 반려앵무 고유의 형태적·행동적 특성으로 인한 기술적 난점이 복합적으로 작용하기 때문이다. 선행된 행동 패턴 분석 관련 연구는 반려조류의 인지적 복잡성과 사회적 상호작용 특성이 다른 반려동물과 본질적으로 다르기 때문에, 일반화된 행동 패턴 분석 모델이 동일한 수준의 정확도를 보장하기 어렵다고 지적하였다.³⁴⁾ 또한 조류 복지 연구가 개·고양이에 비해 구조적 데이터 기반이 부족하며, 행동 관찰의 자동화 수준이 현저히 낮다고 보고된 바 있다.³⁵⁾

반려앵무는 포유류와 달리 전신이 깃털로 덮여 있으며, 날개와 꼬리가 끊임없이 진동하거나 진폭을 달리하는 등 움직임이 매우 불규칙하다. 또한 대부분의 행동이 좁은 케이지 내부에서 이루어지기 때문에, 햇대·먹이통·장난감 등 다양한 배경 요소가 영상 내 노이즈로 작용하여 객체 탐지 및 자세 인식의 신뢰도를 저하시킨다. 이러한 복잡한 사육 환경에서의 반사광·그림자·움직임 혼선은 HRNet이나 Faster R-CNN 같은 전통적 비전 네트워크에서도 탐지 불안정성을 초래하는 요인으로 지적되어 왔다.³⁶⁾³⁷⁾

34) Mellor, R., Owen, R., Mason, G. J., & Lambert, H. (2021). Nature calls: Intelligence and natural foraging style predict poor welfare in captive parrots. 『Proceedings of the Royal Society B: Biological Sciences』, 288(1964). October 6.

35) Piseddu, A., van Zeeland, Y. R. A., & Rault, J.-L., 전계논문.

36) Wang, J., Sun, K., Cheng, T., Jiang, B., Deng, C., Zhao, Y., Liu, D., Mu, Y., Tan, M., Wang, X., Liu, W. & Xiao, B. (2020). Deep High-Resolution Representation Learning for Visual Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 43(10),

기존 반려동물 행동 패턴 분석 연구들은 주로 개체의 중심 이동이나 전신 윤곽 변화를 기준으로 행동을 구분하지만, 반려앵무의 경우 머리·날개·꼬리의 미세한 부분 움직임이 전체 행동의 의미를 결정하는 경우가 많다. 예를 들어, 기지개와 공격적 자세(aggressive posture)는 전신의 위치 변화가 미미하더라도 날개의 각도나 목의 긴장도에 따라 구별된다. 이러한 세밀한 차이는 단순한 Bounding Box 단위의 탐지로는 포착하기 어렵다. 또한 깃털의 반사광, 비정형적 윤곽선, 빠른 날갯짓은 프레임 단위의 영상처리 과정에서 위치 좌표의 불연속성을 초래하며, 이는 딥러닝 모델의 학습 안정성을 저해한다.³⁸⁾

특히 반려앵무의 행동은 단일 패턴으로 정형화하기 어려운 행동 스펙트럼 형태를 보인다. 동일한 행동이 스트레스 상황과 안정된 상황에서 전혀 다른 의미를 가지기도 한다. 예를 들어, 깃털 손질은 안정 상태에서는 위생 행동이지만, 스트레스 상황에서는 과도한 반복을 통해 깃털 뽑기로 전환되며 이는 만성 스트레스의 지표로 간주된다.³⁹⁾ 따라서 행동의 빈도, 강도, 지속 시간을 정량적으로 분석하지 않으면 스트레스 여부를 과학적으로 탐지하기 어렵다.

결국 반려앵무 행동의 복잡성, 깃털 구조로 인한 시각적 한계, 그리고 복잡한 케이지 환경이 맞물려 기존 포유류 중심의 AI 행동 패턴 분석 기법이 그대로 적용되기 어렵다. 이러한 기술적 난점은 단순히 인식률의 문제를 넘어, 반려조류의 복지와 스트레스 평가를 위한 정량적 근거 확보를 어렵게 만든다.⁴⁰⁾

2.1.2 Keypoint 기반 탐지방식

3349-3364.

37) Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. 『Advances in Neural Information Processing Systems』, 28, 91-99.

38) Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. 『arXiv preprint』 arXiv:1804.02767. <https://doi.org/10.48550/arXiv.1804.02767>

39) Andrew U. Luescher (Ed.). 전계서, pp. 60-61, 198-200.

40) Ritchie, B. W., Harrison, G. J., & Harrison, L. R. (1994). 『Avian Medicine: Principles and Application』. Lake Worth, FL: Wingers Publishing, Inc.

조류 행동 패턴 분석에 Keypoint 기반 자세 추정 기술을 적용하려는 시도는 최근 활발히 이루어지고 있으나, 대부분의 프레임워크가 인간 또는 포유류의 신체 구조를 전제로 설계되어 있어 조류 적용 시 성능 저하가 발생한다. HRNet, PoseNet 등은 인간의 관절 구조를 기반으로 한 고정형 네트워크 구조를 채택하고 있으며, 조류의 체형과 동작 자유도를 충분히 반영하지 못한다.⁴¹⁾⁴²⁾

특히 조류는 깃털로 인해 신체 경계가 불분명하고, 빠른 머리 회전 및 비행 동작이 연속 프레임 간 좌표 불연속성을 유발하여 Keypoint 탐지 오차를 증폭시킨다. 이러한 한계는 BirdNet, iWildCam 등 기존 데이터셋에서도 조류의 포즈를 정밀하게 학습하지 못한 원인으로 보고된 바 있다. 기존에 구축된 조류 데이터셋인 BirdNet, iWildCam, CUB-200-2011 등은 대부분 종 분류를 목적으로 설계된 자료이기 때문에, 포즈나 관절에 해당하는 Keypoints 라벨이 존재하지 않아 정밀한 포즈 학습에 직접적으로 활용하기 어렵다. 특히 CUB-200-2011은 200종의 조류를 대상으로 약 1만여 장의 이미지로 구성되어 있는 데이터셋이지만, 깃털 피복으로 인해 신체 윤곽이 불분명하고, 빠른 머리 회전이나 비행 중 발생하는 모션 블러로 인해 신체 경계가 안정적으로 추출되지 않는다는 점이 여러 후속 연구에서 반복적으로 지적되었다. 조류는 포유류와 달리 관절 구조가 외형적으로 뚜렷하게 드러나지 않으며, 동일 종이라도 자세와 각도 변화가 매우 다양하게 나타나기 때문에 Keypoint 기반 모델이 일관된 좌표 회귀를 수행하기 어렵다는 점도 데이터셋 분석 과정에서 확인되었다. BirdNet과 iWildCam과 같은 생태 및 야생 기반 대규모 조류 데이터셋에서도 마찬가지로 관절 레이블의 부재, 촬영 각도와 조명, 배경의 극단적 다양성, 빠른 움직임에 따른 좌표 불연속성 등이 복합적으로 작용하여 포즈 추정 성능에 뚜렷한 한계가 존재하는 것으로 나타났다.⁴³⁾

41) Wang, J., Sun, K., Cheng, T., Jiang, B., Deng, C., Zhao, Y. 등, 전계논문, pp. 3349-3364.

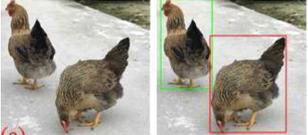
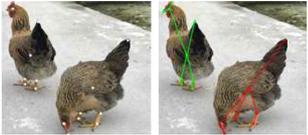
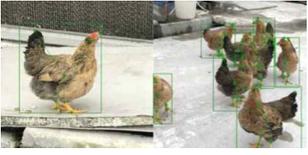
42) Charles, J., Pfister, T., Magee, D., Hogg, D., & Zisserman, A. (2016). 『Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016)』, Personalizing human video pose estimation. arXiv:1511.06676.

43) Wah, C., Branson, S., Welinder, P., Perona, P., & Belongie, S. (2011). 『The Caltech-UCSD Birds-200-2011 Dataset (CUB-200-2011)』. California Institute of Technology. <https://doi.org/10.22002/D1.20098>

또한 Vision Transformer를 결합하여 VHR-BirdPose 모델을 제안한 연구가 있었는데 조류의 포즈 탐지를 시도하였으나, 공개 조류 데이터셋의 부족과 깃털 피복으로 인한 윤곽 왜곡 문제로 세밀한 관절 예측의 일반화에 실패했다고 보고하였다.⁴⁴⁾ 마찬가지로 Dual-task CNN 기반 Bird Posture Recognition 연구에서도 Keypoint 탐지의 정밀도는 개선되었으나, 다양한 배경과 조명 조건에서의 강건성(robustness)은 확보되지 않았다.⁴⁵⁾

한편, 가금류를 대상으로 한 MCP 모델(Kang et al., 2024)은 YOLO를 활용한 다단계 구조로 개체 단위 탐지 후 세부 관절을 탐지하여 성능 향상을

[표 2-1] Multi-Chicken Pose (MCP) 모델 구조적 특징

구분	단계별 구성 및 내용	이미지
1단계: 객체 탐지 (Detection)	YOLO 기반으로 개체(닭)를 탐지하고 Bounding Box 생성	
2단계: 자세 추정 (Pose Estimation)	탐지된 ROI(Region of Interest) 내부에 Keypoint 추정 네트워크(PoseNet 등) 적용하여 Skeleton 생성	
3단계: 성능 평가	Skeleton map으로 RMSE, mAP 계산 (mAP=0.652, RMSE=17.3px)	

[출처] C. Fang, Z. Wu, H. Zheng, J. Yang, C. Ma, and T. Zhang, (2024), MCP:Multi-chicken pose estimation based on transfer learning

44) He, R., Wang, X., Chen, H., & Liu, C. (2023). VHR-BirdPose: Vision transformer-based HRNet for bird pose estimation with attention mechanism. 『Electronics』, 12(17), 3643. <https://doi.org/10.3390/electronics12173643>

45) Lin, C. W., Hong, S., Lin, M., Huang, X., & Liu, J. (2022). Bird posture recognition based on target keypoints estimation in dual-task convolutional neural networks. 『Ecological Indicators』, 135, 108506. <https://doi.org/10.1016/j.ecolind.2021.108506>

보였다.⁴⁶⁾ MCP는 닭의 신체 비율과 움직임을 기반으로 설계되어 mAP 0.652 및 RMSE 17.3px의 성능을 기록했으나, 이는 동일한 체형 비율을 갖지 않은 반려앵무에 직접 적용하기에는 한계가 있다. 또한 MCP 연구는 군집형 집단 사육 환경을 전제로 하기 때문에, 반려조류처럼 개체 중심의 행동 특성을 정밀하게 반영하지 못한다.⁴⁷⁾ 즉, Keypoint 기반 방식은 조류의 복잡한 깃털 구조, 다자유도 움직임, 비행 동작, 환경 노이즈 등으로 인해 탐지 안정성과 정확도가 크게 저하된다. 또한 조류 전용 데이터셋 부재로 인해 학습 효율이 낮고, 신뢰도 높은 행동 분류 모델 구축이 어렵다. 따라서 조류 행동 패턴 분석에는 Keypoint 중심의 전통적 접근보다, 개체의 형태적 특징을 먼저 인식하고 세부 부위를 단계적으로 분석하는 Object Detection 기반 다단계 탐지 구조가 필요하다는 견해가 확산되고 있다.⁴⁸⁾⁴⁹⁾

2.1.3 Object Detection 기반 탐지와 행동 분류 연구

Keypoint 기반 접근의 한계를 극복하기 위해, 최근 조류 행동 패턴 분석에서는 Object Detection 기반 접근이 활발히 시도되고 있다. YOLO, SSD, Faster R-CNN 등의 알고리즘은 Keypoint 방식보다 데이터셋 요구량이 적고, 연산 효율과 실시간성이 높다는 장점이 있다.⁵⁰⁾

특히 YOLO 계열 모델은 이미지 전체를 격자형 grid로 분할해 각 셀의 객체 존재 확률을 예측함으로써, 빠르고 안정적인 탐지가 가능하다. 이러한 구조는 빠른 날갯짓, 먹이 섭취, 이동 등 프레임 단위 변화가 큰 조류 행동 패턴을 실시간으로 분석하기에 적합하다는 연구가 있었다. YOLOv5를 활용해 11종의 반려앵무를 분류하는 연구가 수행되었는데, 96.6%의 정확도를 달성하였다. 이 연구는 단순 종 분류를 넘어 밀수·불법거래 개체의 식별 등 응용 가능성을 제시했다.⁵¹⁾ 한편, YOLOv10을 기반으로 조류의 제스처를 다섯

46) Fang, C., Wu, Z., Zheng, H., Yang, J., Ma, C., & Zhang, T. 전계논문, p.1774.

47) Piseddu, A., van Zeeland, Y. R. A., & Rault, J.-L., 전계논문.

48) He, R., Wang, X., Chen, H., & Liu, C. 전계논문, p.3643.

49) Lin, C. W., Hong, S., Lin, M., Huang, X., & Liu, J. 전계논문, p.108506.

50) Redmon, J. and Farhadi, A. 등, 전계논문, arXiv:1804.02767.

가지로 분류하는 실험을 통해, 실시간 영상에서도 높은 정확도와 빠른 추론 속도를 달성하였다는 보고가 있었다. YOLO는 특히 순간적인 움직임이 많은 조류 영상 환경에서 특히 큰 장점으로 작용할 수 있다.⁵²⁾

그러나 이러한 연구들 역시 탐지된 객체의 위치 정보만을 이용하고, 행동의 시간적 변화나 환경적 상호작용을 반영하지 못한다는 한계가 있다. 조류 행동 패턴은 시간의 흐름 속에서 연속적으로 변화하며, 주변 환경 요소인 물통·웁대·장난감 등과 밀접하게 관련되어 있기 때문이다. 따라서 행동을 보다 정밀하게 이해하기 위해서는 공간정보와 시계열정보를 융합한 다단계 분석 구조가 필요하다. YOLO 기반 다단계 탐지 구조를 적용하여 반려앵무의 머리·날개·발·꼬리 부위를 단계적으로 탐지하고, 케이지 내 세그멘테이션 정보와 결합하여 행동을 정량적으로 분석하였다.

그 결과, Eating, Drinking, Stretching, Resting 행동을 높은 정확도로 분류하였으며, VI와 비교 시 $\pm 15\%$ 이내의 오차율을 기록하였다. 이러한 결과는 AI 분석이 실제 행동학적 관찰과 높은 일치도를 보일 수 있음을 실증적으로 보여준다.⁵³⁾ 이와 같은 연구는 조류 행동 패턴 분석을 단순한 탐지 수준에서 행동의 공간적 맥락 해석 단계로 확장한 사례로 평가된다. YOLO 기반 탐지 기법은 반려앵무처럼 불규칙한 움직임과 복잡한 배경을 가진 조류에서도 안정적인 성능을 보이며, 향후 반려조류 복지 평가와 펫테크 산업에서 핵심 기반 기술로 발전할 가능성이 높다.

51) Jang, W., & Lee, E. C. (2021). Multi-class parrot image classification including subspecies with similar appearance. 『Biology』, 10(11), 1140.

52) Yayla, R. (2024). A prototype study on YOLOv10-based bird gesture recognition. 『International Journal of Multidisciplinary Studies and Innovative Technologies』, 8(2), 76-80.

53) 강대훈, 송성은, 노광현 (2026). AI 기반 반려앵무 자세 추정 및 행동 분석 연구. 한국정보기술학회, 24(1)

2.2 스마트 사육환경 및 펫테크 기술

2.2.1 반려동물 스마트 사육환경 연구

2.2.1.1 펫테크의 부상과 주요 대상

최근 5년간 반려동물 산업은 펫테크(Pet Tech)의 부상을 통해 큰 변화를 겪었다. 펫테크란 AI, IoT, 빅데이터 등 첨단기술을 활용하여 반려동물의 돌봄과 관리를 지원하는 제품 및 서비스를 뜻한다. 2020년대 들어 반려동물을 가족으로 여기는 인식이 확산되면서, 반려견·반려묘 등 반려동물의 웰빙을 향상시키는 다양한 기술이 빠르게 개발·상용화되었다.

글로벌 시장에서도 펫테크는 급성장 분야로 주목받아 2020년 약 50억 달러 규모였던 세계 펫테크 시장이 2027년에는 200억 달러까지 성장할 것으로 전망된다. 이러한 성장의 중심에는 주로 반려견과 반려묘가 있다. 반려동물 기술·서비스는 대부분 이들 포유류 동반자를 겨냥하여 설계되었으며, 훈련용 AI 장난감, 건강 모니터링 웨어러블, 스마트 급식기 등 다양한 제품이 쏟아졌다. 관상어를 비롯한 어류를 위한 스마트 어항, 수질 모니터링 등 솔루션도 등장하여 취미 아쿠아리움 시장이 성장하는 추세다.⁵⁴⁾⁵⁵⁾⁵⁶⁾

2.2.1.2 글로벌 펫테크 시장의 성장

2020년대 들어 글로벌 펫케어 시장은 지속 성장하여 2021년 기준 약 1500억 달러 규모에 달했으며, 이 중 펫테크 분야도 급속한 성장세를 보였다.⁵⁷⁾ 미국은 세계 최대의 펫테크 시장 중 하나로, 2017년 한 해에 펫테크

54) 한경비즈니스. (2021). 6조원 반려동물 시장 두드리는 펫테크 전성시대. 『한국경제매거진』, December 8. Retrieved from <https://magazine.hankyung.com/>

55) Global Market Insights. (2025). How AI and wearables are changing pet parenting. 『Global Market Insights』, June 4. Retrieved from <https://www.gminsights.com/>

56) 김현민. (2018). 미국에서 펫 테크 인기...1년 사이에 두배 커져. 『오피니언뉴스』, October 6. Retrieved from <https://www.opinionnews.co.kr/news/articleView.html?idxno=11598>

관련 기기 출하액이 전년 대비 113% 성장한 1억9700만 달러를 기록했고 이후로도 꾸준한 확대가 예상되었다. 한국 역시 펫코노미 규모 증가와 함께 ICT 강점을 살려 펫테크 스타트업 투자와 제품 출시에 속도가 붙었다. 이러한 시장 성장의 중심에는 반려견과 반려묘가 있다. 이는 전 세계 반려동물 양육 현황을 보아도 알 수 있는데, 미국 가정의 68%가 반려동물을 키우고 있으며 이 중 가장 많은 비중을 차지하는 동물은 개와 고양이이다. 2018년 기준 미국에서는 약 6천만 가구가 개를, 4천7백만 가구가 고양이를 키우는 것으로 조사되었다.⁵⁸⁾⁵⁹⁾

반면 다른 종의 비중은 훨씬 낮다. 예를 들어 관상조, 애완조류는 미국 약 600만 가구 미만에서만 기르는 것으로 추산되어, 개·고양이에 비해 절대 수가 한 자릿수 이상 적다. 이러한 반려동물 분포는 펫테크 산업의 개발 초점에도 그대로 반영되었다. 기업들은 시장 규모가 큰 견·묘 용품에 집중하여 기술을 투입하고, 웨어러블 기기나 AI 모니터링 서비스도 주로 개의 활동량 추적, 고양이 급식 관리 등에 맞춰 출시되고 있다. 관상어 분야에서는 자동 여과장치나 스마트 어항처럼 전문화된 제품군이 형성되어 있다. 반면 조류용 펫테크 제품은 찾아보기 어려운 실정이다. 2020년대 중반까지 펫테크 기기들은 대부분 개와 고양이 대상으로 의도되었다고 평가될 정도이며, 조류나 파충류, 소동물 등은 부차적인 관심만 받는 상황이었다.⁶⁰⁾⁶¹⁾

2.2.1.3 견·묘 중심의 펫테크 제품들 및 반려조류의 비중

57) Grand View Research. (2022). 『Pet care market size, share & trends analysis report (2022-2030)』. San Francisco: Grand View Research. Retrieved from <https://www.grandviewresearch.com/industry-analysis/pet-care-market>

58) 한경비즈니스. (2021). 6조원 반려동물 시장 두드리는 펫테크 전성시대. 『한국경제매거진』, December 8. Retrieved from <https://magazine.hankyung.com/>

59) 김현민. (2018). 미국에서 펫 테크 인기...1년 사이에 두배 커져. 『오피니언뉴스』, October 6. Retrieved from <https://www.opinionnews.co.kr/news/articleView.html?idxno=11598>

60) Dormehl, L. (2016, March 22). World's first smart bird cage. 『New Atlas』. Retrieved from <https://newatlas.com/pets/worlds-first-smart-bird-cage/>

61) Global Market Insights. (2025). How AI and wearables are changing pet parenting. 『Global Market Insights』, June 4. Retrieved from <https://www.gminsights.com/>

한국과 미국 모두 반려견·반려묘 가구가 절대다수이며, 조류를 포함한 기타 반려동물은 소수에 그친다. 한국은 2024년 기준 전체 가구의 26.7%에 해당하는 591만 가구가 반려동물을 키우고 있는데, 이 중 반려견 가구 455만(77%), 반려묘 가구 137만(23%)으로 집계되었다.⁶²⁾

그 외 금붕어, 햄스터, 새 등 기타 동물 가구는 극히 적어 통계에 별도 항목으로 나타나지 않을 정도이다. 미국의 경우도 반려조류나 소동물의 비중은 낮아서, 2017년 미국소비자기술회(CTA) 보고서 등에서는 주로 개·고양이 관련 시장 지표만 강조된다. 이러한 반려동물 중 분포의 차이는 펫테크 제품의 대상 중에도 영향을 미친다. 기업 입장에서는 수요층이 두터운 개·고양이용 기술을 우선 개발하기 때문에, 양국 모두 펫테크 제품은 견·묘 중심으로 다양화되어 왔다. ⁶³⁾⁶⁴⁾

한국에서는 통신사와 전자기업들이 일찍부터 반려견용 IoT 기기를 내놓았다. SKT는 AI 기반 동물병원 영상진단 보조서비스를, LG유플러스는 반려견 원격놀이 장난감 ‘펫토이’를 출시했고, KT는 반려견 활동량계+자동급식기 패키지를 선보였다. 모두 개나 고양이를 주요 타겟으로 한 제품들이다. 반면 반려조류를 위한 상용 제품은 전무하며, 산업계의 관심도 아직 낮다. 미국에서도 상황은 유사하다. 글로벌 펫테크 선도 기업들을 보면 Rover(펫시터 플랫폼), Tractive·Fi(펫 위치추적기), Petcube(펫 카메라), PetPace(스마트목걸이) 등으로, 모두 견·묘용 서비스만을 제공하고 있다. CTA가 분류한 펫테크 제품 카테고리에도 훈련용 전자목줄, GPS 추적기, 스마트 급식기, 양방향 장난감 등 주로 견·묘를 염두에 둔 아이템들이 나열된다.⁶⁵⁾

관상어 영역은 전통적으로 어항용품 업체들이 담당해왔으며, 2020년대에 들어 자동 여과·급이 장치나 수질센서 등의 첨단 아쿠아리움 솔루션이 발전

62) KB Think. (2025). 한국 반려동물 현황. 『2025 한국 반려동물 보고서』, June 29. Retrieved from <https://kbthink.com/investment/deepdive/research/250629-2.html>

63) 김현민. (2018). 미국에서 펫 테크 인기...1년 사이에 두배 커져. 『오피니언뉴스』, October 6. Retrieved from <https://www.opinionnews.co.kr/news/articleView.html?idxno=11598>

64) Global Market Insights. (2025). How AI and wearables are changing pet parenting. 『Global Market Insights』, June 4. Retrieved from <https://www.gminsights.com/>

65) 우은정. (2022). 펫 테크에 주목하는 미국 반려동물 산업. 『해외시장뉴스』, KOTRA 로스앤젤레스무역관. Retrieved from <https://news.kotra.or.kr/>

중이다. 조류 영역은 사실상 공백으로, 2025년 CES 등에서 간혹 야생조류용 스마트 모이통이나 스마트 새장 시제품이 등장했을 뿐, 반려조류 전용의 상용 기술은 찾아보기 어려웠다.⁶⁶⁾

2.2.1.4 견·묘 중심의 연구 동향 및 반려조류 연구 비중

학계에서도 펫테크 관련 연구는 개와 고양이를 주로 대상으로 이루어졌다. 2020~2025년 사이 발표된 논문들을 보면, 반려동물 웨어러블이나 행동인식에 관한 리뷰 및 실험 연구의 대부분이 견·묘에 집중되어 있다. 예를 들어 2025년 발표된 동물용 바이오센싱 웨어러블 설계 프레임워크 연구에서는 체계적 문헌조사 시 개와 고양이에 초점을 맞추고, 기준에 맞지 않는 조류, 파충류, 어류 등의 기타 동물은 모두 제외하여 분석했다고 명시한다. 이는 해당 분야 선행연구의 대부분이 견·묘 대상이어서 다른 종은 연구 사례가 부족하거나 범주상 이질적임을 시사한다. 실제로 펫테크 관련 학술 데이터베이스를 종별로 분석해보면, 반려견과 반려묘에 관한 연구가 압도적 비중을 차지하고 조류를 비롯한 기타 반려동물 관련 논문은 소수에 불과하다. Siguín, M., Casas, R., Casas, O., & Blanco, T. (2025)는 반려동물 웨어러블 디자인을 위한 20가지 핵심 요소를 제시하면서, 기존 연구가 특정 동물군에 편중되어 있다는 문제를 명확히 지적한다. 연구진은 체계적 문헌조사 단계에서 확보된 1차 논문 대부분이 견·묘 대상 실험으로 구성되어 있었고, 조류·파충류·설치류·어류에 관한 연구는 검색 단계에서부터 극히 제한적이었다고 보고하였다. 특히 조류의 경우, 착용형 장비의 고정 방식 자체가 쉽지 않고, 체구가 작은 종이 많아 센서 부착에 따른 스트레스·행동 교란 가능성이 높아 연구 사례가 더욱 희소하다고 분석하였다.⁶⁷⁾

AI 기반 반려동물 의료/헬스케어 연구에서도 조류 언급은 드물고, 주로

66) 임종현. (2024). CES에서 주목받은 펫테크, AI와 로봇이 바꾸는 반려동물 케어. 『더프론티어』. Retrieved from <https://www.thefrontier.co.kr/>

67) Siguín, M., Casas, R., Casas, O., & Blanco, T. (2025). Towards effective wearable design: 20 key factors for monitoring physiological health in animals. 『Results in Engineering』, 27, 106001. <https://doi.org/10.1016/j.rineng.2025.106001>

개·고양이 임상 데이터에 머신러닝을 적용한 사례들이 보고되었다. 이런 배경에는 시장 규모의 차이와 데이터 수집의 한계 등이 있다. 반려조류는 표준화된 행동 데이터 축적이 어려운데다, 대상 표본도 적어 AI 학습이나 기기 검증에 한계가 있다.⁶⁸⁾ 학술적 관심도 역시 반려견의 행동심리나 반려묘의 건강 이상징후 탐지 등에 쏠려 있고, 조류의 행동특성에 맞춘 센싱 및 분석 기법 연구는 초기 단계다.

2.2.2 반려조류 분야의 펫테크 기술 개발 시도 사례

그렇다고 조류 분야에서 전혀 연구개발이 없는 것은 아니다. 2020년대 중반에 들어 조류도 중요한 반려동물의 한 축으로 인식하려는 움직임이 일부 학계와 스타트업에서 포착된다. 학술 분야에서는 2023~2025년 사이 반려앵무의 사회적 욕구 충족을 위한 기술 실험이 화제가 되었다. 미국 Northeastern 대학 글라스고대학 연구진은 반려앵무들끼리 영상통화를 할 수 있는 시스템을 개발하여, 18마리 반려앵무가 태블릿을 스스로 조작해 다른 새와 영상 대화를 나누도록 한 연구를 진행했다. 이 Birds of a Feather Video-Flock Together 라는 실험에서 3개월간 147회의 앵무새와 앵무새 간의 영상통화가 이루어졌으며, 모든 앵무들이 자발적으로 참여하고 화면 속 다른 새의 행동을 따라 학습하는 등 긍정적 결과가 관찰되었다. 보호자들 역시 영상통화를 통해 반려앵무가 먹이찾기 놓이나 날기 등 새로운 사회적 행동을 배우는 등 큰 이득을 보았다고 응답하여, 해당 연구는 반려조류의 복지를 향상시킬 기술 잠재성을 입증한 사례로 평가받았다.⁶⁹⁾ 이처럼 조류의 행동 패턴 분석 및 상호작용 기술은 이제 막 학술 연구 단계에서 가능성을 타진하고 있으며, 상용화 단계까지 진입한 예는 거의 없다.

한편 산업 기술 개발 측면에서는 스마트 새장 개념이 등장한 것이 주목된

68) Gobinath, V. M., & Kathirvel Ayyaswamy, A. (2024). AI-based healthcare systems for pets and birds. 『Biomedical Journal of Scientific & Technical Research』, 58(5). <https://doi.org/10.26717/BJSTR.2024.58.009202>

69) Seymour, K. G. (2025, June 30). Squawk of the town: Parrot study reveals how technology can enrich the lives of pet parrots. 『American Animal Hospital Association (AAHA) - Trends Magazine』. Retrieved from <https://www.aaha.org/>

다. 2024년 말, 미국의 스타트업 Reli는 세계 최초의 스마트 버드케이지 Birddy를 공개하며 크라우드펀딩을 진행했다. 이 첨단 새장은 자동 급이·급수 장치, 배설물 자동청소 및 UV살균 시스템, 온습도 조절 및 조명제어 등을 갖춘 올인원 사육환경 관리 기기로 소개되었다. 사람의 부재 시에도 새장의 센서와 IoT 장치가 내부 환경을 일정하게 유지하고, 정해진 시각에 먹이와 물을 제공하며, 바닥의 새분(排糞)을 로봇팔로 쓸어 담아 살균 처리하는 등 대부분의 사육 관리 작업을 자동화한 것이 특징이다. 스마트폰 앱을 통해 실시간으로 새장 상태를 모니터링하고 제어할 수도 있어, 반려조류를 기르는 초보 사육자나 장기 부재자에게 유용한 솔루션으로 홍보되었다.⁷⁰⁾ 이 제품은 세계 최초의 조류 전용 스마트케이지를 표방했는데, 이는 그만큼 기존에 상용화된 반려조류용 스마트 기기가 없었다는 방증이기도 하다. 케이지의 등장은 조류 사육에도 첨단기술 수요가 존재함을 보여주지만, 아직까지는 소규모 스타트업의 시범적 제품일 뿐 대중화 단계는 아니다.

이외에도 CES 2025 등에서 야생조류 관찰용 AI 카메라 모이통이나 조류 행동 패턴 분석 알고리즘이 간혹 소개되었으나,⁷¹⁾ 이들 역시 반려동물보다는 조류 애호가 또는 조류학 연구 측면의 기술로 볼 수 있다. 요컨대 반려조류 분야의 펫테크 개발은 2025년 현재 학술 시연 또는 초기 제품화 단계의 몇몇 사례를 제외하면 뚜렷한 성과를 찾기 어려운 상황이다.

70) Thompson, B. (2024, December 22). World's first smart bird cage does all the cleaning and feeding for you. 『New Atlas』. Retrieved from <https://newatlas.com/pets/worlds-first-smart-bird-cage/>

71) 임종현. (2024). CES에서 주목받은 펫테크, AI와 로봇이 바꾸는 반려동물 케어. 『더프론티어』. Retrieved from <https://www.thefrontier.co.kr/>

2.3 반려앵무의 스트레스와 복지 연구 동향

2.3.1 스트레스 요인 및 행동 지표

반려조류의 복지 연구는 최근 행동 양상을 심리적 안정 또는 스트레스 수준을 평가하는 핵심 지표로 활용하려는 방향으로 발전하고 있다. 특히 반려앵무는 높은 지능과 사회적 상호작용 능력을 갖추었음에도 불구하고, 포획 또는 사육 환경 적응 과정에서 심리적 스트레스가 누적될 경향이 있다고 보고되었다.⁷²⁾ 이러한 스트레스는 깃털 뽑기, 반복적 날갯짓, 안절부절 못하는 행동 등의 비정상 행동으로 표출되며, 행동 빈도와 형태가 개체의 정서 상태를 간접적으로 반영한다.⁷³⁾⁷⁴⁾

기존 연구에서는 행동 관찰을 통해 복지를 평가하였으나, 이 방법은 관찰자의 주관적 판단과 반복 측정의 제한으로 인해 객관성과 재현성이 낮았다. 이에 따라 본 연구는 앞서 [표 1-10]에서 제시된 여섯 가지 주요 행동인 Eating, Drinking, Stretching, Resting, Bathing, Pacing을 분석 대상으로 선정하였다. 이 행동들은 모두 영상 기반 Object Detection 알고리즘으로 자동 탐지가 가능하며, 행동 발생 양상에 따라 반려앵무의 정서적 상태를 구분할 수 있다.

Resting, Stretching, Bathing은 심리적 안정 상태에서 주로 나타나는 행동으로, 깃털 관리, 근육 이완, 체온 조절 등 생리적 균형 유지에 기여한다. 반면, 새장 내를 빠르게 오가며 안절부절 못하고 걸어다니는 행동인 Pacing은 불안과 스트레스를 반영하는 대표적 지표로, 환경 적응 부족 또는 사회적 자극 결핍 상황에서 자주 관찰된다. 반려앵무는 포유류와 달리 언어적 의사표현이 제한적이지만, 높은 인지 능력과 사회적 교감 행동을 통해 정서 상태를 비언어적으로 표출한다.⁷⁵⁾ 따라서 휴식 시간 단축, 반복 이동 증가 등의 행동의

72) Piseddu, A., van Zeeland, Y. R. A., & Rault, J.-L., 전계논문.

73) van Zeeland, Y. R. A., Spruit, B. M., Rodenburg, T. B. 등, 전계논문, pp. 75-95.

74) Costa, P., Macchi, E., Valle, E., De Marco, M. 등, 전계논문, e2462.

75) Piseddu, A., van Zeeland, Y. R. A., & Rault, J.-L., 상계논문.

[표 2-2] 반려앵무의 스트레스 행동 유형별 AI 분석 용이성

스트레스 행동	정의 / 특징	심리 상태	AI 분석 용이성	비고
Pacing (스트레스성 반복 이동)	방향성 없이 걷고 오가는 반복 이동, 안절부절 못함	스트레스 · 불안	매우 높음	본 연구 주요 분석 대상
Repetitive flapping (반복 날갯짓)	동일한 날갯짓 자세의 반복, 과활동	불안	중간	프레임 누락 가능
Corner hiding (구석 숨기)	어두운 구석에 장시간 숨어 있음	공포 · 회피	중간	위치분석 쉬우나 '숨기' 의 의도 해석 어려움
Feather plucking (깃털 뽑기)	특정 부위의 털을 뽑거나 훼손	스트레스 · 강박	낮음	영상에서 미세 동작 탐지 어려움
Feather damaging preening (과도한 그루밍)	정상 범위를 넘는 잦은 찌기·정리	불안·강박	낮음	동작이 미세하고 분간 어려움

미세한 변화는 정서적 불안정과 직결되며, AI 기반 정량분석은 이러한 미묘한 행동 패턴을 객관적으로 탐지할 수 있는 도구로 작용한다. 따라서 본 절에서는 이들 행동을 기초로 반려앵무의 복지 수준을 판단할 수 있는 행동 지표를 정립하고, 기존 문헌을 근거로 그 타당성을 검토한다.⁷⁶⁾⁷⁷⁾

반려앵무의 행동 중에서 AI 분석이 용이하며 스트레스를 나타내는 행동으로 Pacing 동작을 선정하였으며, 각 스트레스 행동별 용이성을 [표 2-2]에 나타내었다.

2.3.2 코티졸 호르몬 분석기술 활용 스트레스 측정 연구

반려앵무가 보이는 특정 행동이 스트레스 상황에서 나타나는 반응인지, 혹은 심리적 안정 상태에서의 자연스러운 행동인지를 과학적으로 규명하기 위해 여러가지 검사방법을 활용하여 신뢰도를 높이는 시도가 진행된 바 있다. 그 중 코티졸 호르몬 분석은 개체가 경험하는 심리적·생리적 스트레스 수준을

76) van Zeeland, Y. R. A., Spruit, B. M., Rodenburg, T. B. 등, 전계논문, pp. 75-95.

77) Costa, P., Macchi, E., Valle, E., De Marco, M. 등, 전계논문, e2462.

직접적으로 반영하는 대표적 생리학적 지표이다. 코티졸은 척추동물의 부신피질에서 분비되는 스트레스 호르몬으로, 면역 반응, 대사 조절, 행동 변화 등과 밀접히 관련된다. 조류 연구에서는 비침습적 접근이 중요한데, 이에 따라 분변 시료를 활용한 코티졸 대사산물(Fecal Cortisol Metabolites, FCMs) 분석이 널리 이용된다.⁷⁸⁾

특히 ELISA (Enzyme-Linked Immunosorbent Assay) 키트를 통해 조류나 가금류의 분변 속 코티졸 농도를 정량화함으로써, 개체가 장기적으로 경험하는 스트레스 수준을 평가할 수 있다.

[표 2-3]은 코티졸 농도 분석을 통해 AI 기반 행동 패턴 분석의 생리학적 신뢰도를 검증하는 절차를 단계별로 정리한 표이다. 분변 시료 채취부터 행동-호르몬 상관성 분석에 이르는 과정을 요약하여, AI 분석 결과의 타당성을 평가하는 구조를 한눈에 보여준다.

반려앵무의 분변 내에서 코티졸 분석을 통해 스트레스 지수를 평가한 연구가 선행되었다. 이 연구에서는 실험군과 대조군 개체의 분변을 일정 기간 반복 채취하여 ELISA 방식으로 코티졸 농도를 정량화하였다. 분변은 개체의 스트레스 상태가 혈중보다 장기적으로 반영된다는 점에서 비침습적 생리지표로 널리 활용된다. 시료 준비-배양-세척-기질 반응-흡광도(OD) 측정까지의 과정을 통해 코티졸 농도를 산출하게 되는데, 표준곡선(Standard Curve)에 기반하여 ng/ml 단위의 절대 농도를 도출하여 측정이 되었다.⁷⁹⁾



[그림 2-1] 코티졸 시험시료(좌)와, 흡광도측정(우) 모습

78) Palme, R., Rettenbacher, S., Touma, C., El-Bahr, S. M. 등, 전계논문, pp. 162-171.

79) 강대훈, 송성은, 신은송, 이경복, 노광현 (2025). 스트레스 저감 기능을 가진 스마트 앵무새장. Asia-Pacific Journal of Convergent Research Interchange, 11(3), 843-859. <https://doi.org/10.47116/apjcri.2025.03.58>

[표 2-3] 코티졸 분석을 통한 AI 기반 행동 패턴 분석의 신뢰도 검증 구조

구분	측정·분석 항목	검증 기준	검증 목적
시료 수집	일정 기간 동안의 반려앵무 분변 시료 채취	동일 개체·동일 시간대 반복 수집	생리적 변동의 정량적 기록
코티졸 정량화	ELISA 분석을 통한 분변 내 코티졸 농도 측정	OD 값 (Standard Curve) 기반 농도 산출	비침습적 스트레스 지표 확보
행동 데이터 대응 분석	AI가 탐지한 행동 (안정상태/스트레스) 빈도·지속시간	행동별 코티졸 농도 평균 비교 (r, p값 계산)	행동-호르몬 간 상관성 검증
정상·비정상 행동 비교	휴식·섭식vs 반복행동 구간의 코티졸 차이 분석	정상구간: 낮은수치 / 비정상구간: 높은수치	AI 분류의 생리학적 타당성 평가
종합 해석	행동 패턴과 코티졸 변동의 상관관계 분석	유의미한 상관 ($r > 0.6$ 등) 도출 여부	AI 분석 결과의 신뢰도·타당성 확보

코티졸 분석을 이용한 선행실험에서 실험군은 스마트 새장을 통해 온도·습도·먹이·물·조명이 모두 일정하게 유지되는 규칙적 환경에서 사육하였으며, 대조군은 일반 가정과 유사하게 급이·급수 주기가 불규칙하고, 온습도와 조명 역시 수동 관리로 변동성이 큰 환경에서 사육하였다. 두 그룹의 분변을 입식 첫날, 15일차, 30일차 시점에 채취하여 코티졸 농도를 비교함으로써, 규칙적 관리가 조류 스트레스 수준에 미치는 영향을 평가하였다. 이러한 결과는 환경 관리의 규칙성과 예측 가능성이 조류의 생리적 스트레스 반응을 실질적으로 완화할 수 있음을 보여준다. 특히 일정한 온·습도 유지, 계획된 급이·급수, 안정적인 광환경과 같은 요소들은 분변 코티졸 농도의 감소로 직접 확인된 바와 같이 개체의 장기적 스트레스 부담을 줄이는 핵심 요인으로 작용하였다. 반면, 급수·급이가 불규칙하거나 온습도 변동이 큰 환경에서는 코티졸 저감 폭이 상대적으로 제한되는 경향을 보였으며, 이는 사육 환경의 일관성 부족이 실제 스트레스 회복을 방해할 수 있음을 시사한다.⁸⁰⁾

80) 강대훈, 송성은, 신은송, 노광현 등, 전계논문, pp. 843-859.

2.3.3 열화상 측정기술 활용 스트레스 측정 연구

열화상 분석은 고해상도 열화상 카메라를 이용하여 개체의 체표 온도 변화를 측정함으로써, 스트레스 반응에 따른 실시간 생리적 변화를 비침습적(non-invasive)으로 추적할 수 있는 방법이다.⁸¹⁾ 교감신경계가 활성화되면 혈류 분포가 달라지면서 체온이 국소적으로 상승하거나 불균형하게 나타나는데, 이는 스트레스 반응의 중요한 물리적 지표가 된다.⁸²⁾ 이러한 분석기술의 연구는 본 연구에서 수행하는 AI 행동 패턴 분석과 코티졸 호르몬분석의 신뢰성 증진을 위해 사용될 수 있다.

열화상 분석을 통하여 반려앵무의 스트레스를 정량적으로 평가하려는 연구도 선행되었다. 이 연구에서는 고해상도 열화상 카메라를 이용해 다양한 환경 자극에 노출된 반려앵무의 체표 온도 변화를 실시간으로 측정하고, 고온 영역(R·W 픽셀 비율)의 확대 여부를 스트레스 지표로 활용하였다.⁸³⁾

Day	min.	img.	R	W	R+W
1	0		17.42	2.18	19.60
	5		19.56	3.70	23.27
	10		16.30	2.52	18.82
	15		16.12	0.77	16.89
	20		10.11	1.13	11.24
2	0		7.46	1.67	9.13
	5		9.49	2.28	11.77
	10		13.08	3.20	16.29
	15		13.73	1.50	15.23
	20		12.33	-0.70	11.62
3	0		7.59	0.57	8.16
	5		5.37	2.60	7.97
	10		3.59	3.56	7.15
	15		2.38	3.14	5.52
	20		2.56	0.47	3.03
4	0		3.80	-0.35	3.45
	0		29.13	4.67	33.80
	5		28.46	5.21	33.67
	10		30.83	2.67	33.50
	15		23.21	6.14	29.35
2	20		18.93	8.50	27.44
	0		23.16	2.25	25.41
	5		16.38	4.22	20.60
	10		18.62	2.76	21.38
	15		18.72	1.02	19.73
3	20		17.07	0.63	17.70
	0		15.16	1.86	17.02
	5		13.66	3.60	17.26
	10		11.26	4.86	16.12
	15		12.21	3.64	15.85
4	20		13.98	1.36	15.34
	0		9.99	4.90	14.89

[그림 2-2] 열화상 분석을 통한 반려앵무 스트레스 측정

[출처] 강대훈(2024), 반려앵무의 심리적 안녕감과 스트레스 스펙트럼 연구

81) Jerem, P., Herborn, K. A., McCafferty, D. J., & Nager, R. G. 전계논문, e53184.

82) Tabh, J. K. R., Burness, G., Wearing, O. H., Tattersall, G. J. 등, 전계논문, e14865.

83) 강대훈, 송성은, 신은송, 노광현 (2024). 반려앵무의 심리적 안녕감과 스트레스 스펙트럼 연구. Asia-Pacific Journal of Convergent Research Interchange, 10(2), 305-326. <https://doi.org/10.47116/apicri.2024.02.26>

강대훈, 송성은, 신은송, 노광현(2024)은 체표 온도의 절대값만을 단순 비교한 것이 아니라, 눈 주변·부리 기저부·안면부의 열 분포를 세분화하여 분석함으로써 스트레스 강도에 따라 고온 픽셀 영역이 어떻게 공간적으로 확산되는지를 정량적으로 비교하였다. 분석 결과, 급성 스트레스 자극을 받은 개체에서는 눈 주변의 온도 상승이 가장 빠르게 나타났으며, 이는 포유류에서 보고된 안면부 열 반응과 유사한 생리적 패턴임이 확인되었다. 또한 제한공간 이동, 소음, 수면 제한, 빛 색상 변화, 리드줄 속박의 다섯 가지 자극을 단계적으로 부여한 결과, 활동 제한이나 강한 소음처럼 급성이 높은 자극에서는 체표 열 분포 면적이 빠르게 넓어져 스트레스 지수가 상승함을 나타내었고, 반면 백색 LED나 수면 방해처럼 지속적이며 회피가 어려운 자극에서는 시간 경과에도 불구하고 스트레스 지수가 감소하지 않는 양상이 관찰되었다.

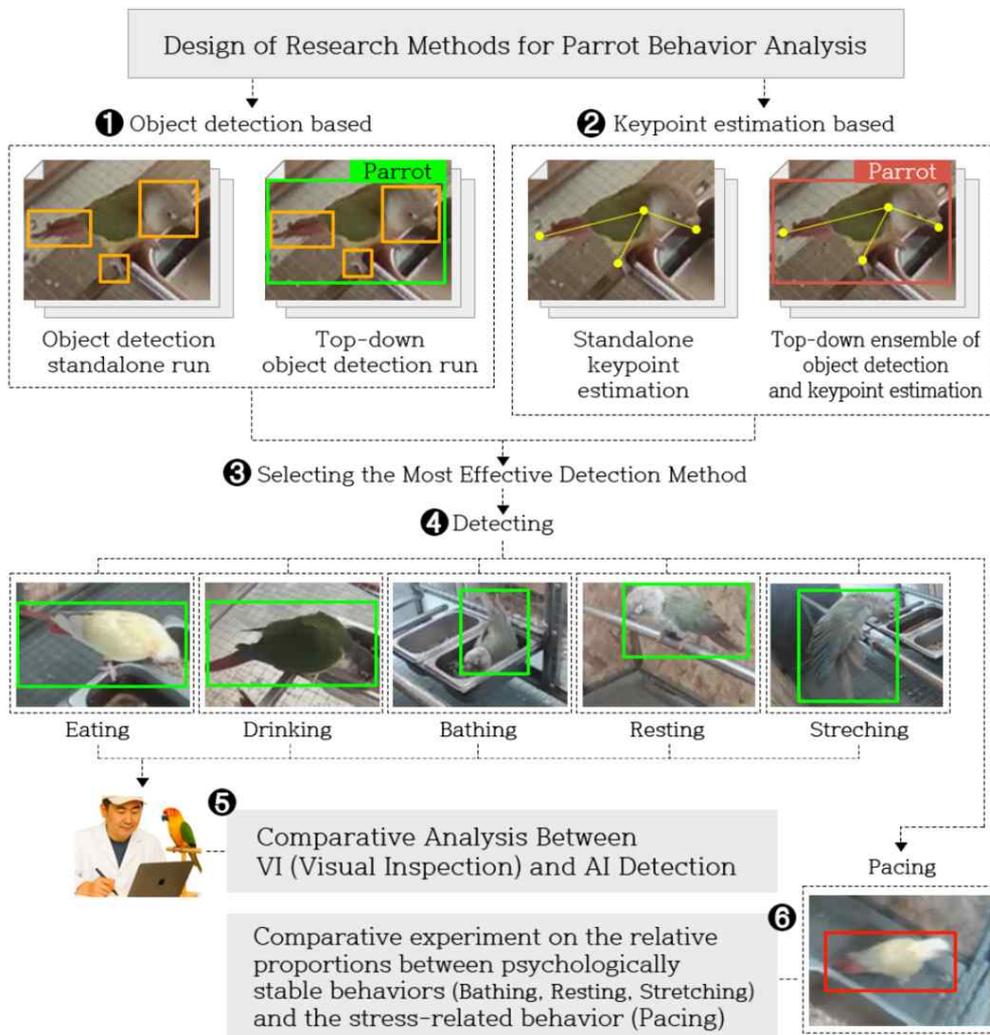
또한 열화상 지표와 스트레스 행동 지표의 상관 구조를 비교하여, 온도 상승 패턴이 행동 이상 발생 전 단계에서 먼저 관찰되는 조기 예측 신호로 활용될 가능성을 보고하였다. 마지막으로, 코티졸 농도 변화와의 비교에서도 단기 스트레스는 열반응이 더 민감하게 나타났고, 장기 누적 스트레스는 코티졸과의 상관성이 높아 두 지표의 상호보완적 활용 가능성을 강조하였다. 반면 제한공간 이동이나 반복 소음과 같은 단기 자극에서는 일정 수준의 적응 반응이 나타났다. 이러한 열화상 기반 분석은 스트레스 반응의 즉각적 생리 변화를 직관적으로 포착할 수 있어, 코티졸 농도와 같은 장기적 스트레스 지표와 상호 보완적으로 활용될 수 있다.⁸⁴⁾

84) 강대훈, 송성은, 신은송, 이경복 등, 전계논문, pp. 305-326.

III. AI 기반 반려앵무 행동 패턴 분석 방법 설계

3.1 행동 패턴 분석 연구모형

본 연구는 반려앵무의 다양한 행동을 정밀하게 분석하기 위해, 먼저 개체의 주요 신체 부위를 안정적으로 탐지하는 기술적 기반을 확립하는 것에서



[그림 3-1] 반려앵무 행동 패턴 분석을 위한 연구 방법 설계 모형

출발하였다. 행동 패턴 분석의 정확도는 부리, 다리, 꼬리, 몸통과 같은 핵심 부위의 탐지 정확성에 직접적으로 의존하므로, 다양한 환경과 개체 차이가 존재하는 실제 사육 데이터를 대상으로 가장 적합한 탐지 방식을 선정하는 과정이 필수적이었다. 이에 따라 연구 초기 단계에서는 서로 다른 구조적 특성을 가진 네 가지 탐지 전략을 설정하고, 각 방식의 일관성과 견고성을 비교하는 절차를 수행하였다.

먼저 두 가지의 객체 탐지 기반 접근법을 사용해 보았다. 이 접근에서는 하나의 모델이 부리, 다리, 꼬리 등 모든 신체 부위를 직접 예측하는 단일 Object Detection 방식과, 반려앵무의 전체 윤곽을 먼저 탐지한 후 그 내부에서 다시 세부 부위를 탐지하는 방식과 함께 비교 검토되었다. 이러한 방식은 구조가 단순하고 계산 효율이 높다는 장점을 가지지만, 개체의 회전이나 자세 변화가 심한 영상에서는 부위가 일부 가려지는 문제가 발생할 수 있어, 이를 실제 데이터에서 어떻게 보완할 수 있는지를 중점적으로 확인하였다. 또한 객체 탐지 기반 방식에서는 부위별 바운딩박스가 시간에 따라 흔들리거나 일관성이 저하되는 문제가 일부 관찰되었기 때문에, 장시간 연속 영상에서의 추적 안정성, 바운딩박스 중심 이동의 스무딩 효과, 프레임 손실 시의 복원 가능성과 같은 실사용 측면의 성능도 함께 평가하였다. 특히 헛대, 밥통, 물통 등의 케이지 내 구조물의 간섭이나 앵무새의 빠른 이동 및 환경과 객체를 혼동할 수 있는 환경적 요인을 모델이 얼마나 견고하게 처리할 수 있는지도 주요 검토 항목으로 설정하였다. 이를 통해 단순 정지 영상에서는 충분히 높은 성능을 보이지만, 실제 사육 환경의 복잡성을 반영한 장시간 기록에서는 추가적인 위치 보정 기법이나 추적 알고리즘의 결합이 필요함을 확인하였다.

다음으로 Keypoint 추정 기반 접근법을 고려해 보았다. 이 방식은 신체의 관절과 부위를 점 형태로 예측하여 각 점을 연결함으로써 자세를 재구성하는 기법으로, 개별 관절의 위치 변화를 세밀하게 추적할 수 있다는 장점이 있다. 신체 전체를 직접 추정하는 독립 Keypoint 추정 방식과, 전체 바운딩박스를 먼저 탐지한 뒤 그 내부에서 머리, 어깨, 다리, 꼬리 등의 Keypoint를 재구성하는 상위 단계 추정 방식을 포함하여 두 가지가 검토되었다. 두 방식의 비교를 통해, 실험 환경의 조명 변화나 카메라 시야각에 따라 발생할 수 있는 오

작동을 최소화할 수 있는 구조를 확인하였다. 특히 Keypoint 기반 방식은 부위가 부분적으로 가려져도 남아 있는 관절 위치로 자세를 유추할 수 있어, 객체 탐지 기반 방식보다 회전·비틀림 동작에 대해 높은 복원력을 보였다. 또한 장시간 영상에서 점의 위치 일관성이 유지되는지, 빠른 머리 움직임에서 좌표가 튀는 현상이 억제되는지 등 시간적 안정성을 중점적으로 검토하였다. 더불어 케이지 내부 구조물에 의해 일부 관절이 가려지는 상황에서도 모델이 어떤 보정 패턴을 학습하는지 분석하여 실제 적용 가능성을 평가하였다.

총 네 가지 탐지 전략을 종합적으로 비교하였을 때, 실제 행동 패턴 분석 단계에서 가장 안정적인 성능을 보이는 방식을 최종적으로 선택하였다. 이 과정에서는 단순 정확도뿐 아니라 장시간 영상에서의 누적 오차, 부위 상실 시의 복원 가능성, 개체 간 차이에 대한 민감도 등 다양한 요소가 함께 고려되었다. 이러한 다각적 검토를 통해 행동 분류와 시간 패턴 분석을 수행하기에 적합한 형태의 탐지 체계를 확립하였다.

가장 적합한 형태로 선택된 방식을 통한 반려앵무 행동 AI 탐지 결과가 실제 사람이 관찰한 결과와 얼마나 일치하는지를 확인하기 위해 두 분석 방식의 비교 실험을 수행하였다. Eating, Drinking, Bathing, Resting, Stretching으로 구성된 행동을 동일한 영상 구간 안에서 AI가 분류한 행동과 관찰자가 기록한 행동을 대조함으로써, AI 기반 분석의 타당성과 활용 가능성을 검증하였다. 이러한 검증 절차는 이후 행동별 지속시간 분석과 비율 산출 과정이 신뢰성을 갖추기 위한 중요한 과정으로 작용하였다.

마지막 단계에서는 Bathing, Resting, Stretching으로 구성된 심리적으로 안정된 상태의 행동들과, 스트레스 반응으로 알려진 Pacing 행동을 비교하여 개체의 정서적 상태를 평가하였다. 안정 행동은 주로 편안한 환경에서 나타나는 특성이 있으며, 그 비율이 감소할수록 공간 내 반복 이동과 같은 스트레스 행동이 증가하는 양상이 확인된다. 이에 따라 각 행동의 발생 빈도와 지속시간을 정량적으로 분석하고, 두 행동군 간의 상대적 비율을 바탕으로 개체의 스트레스 수준을 평가하였다. 이러한 과정은 AI 기반 행동 패턴 분석 결과를 실제 정서 지표와 연결하는 핵심 단계로 기능하였다.

3.2 반려앵무 행동 탐지방법

3.2.1 Keypoint 추정을 이용한 반려앵무 행동 탐지

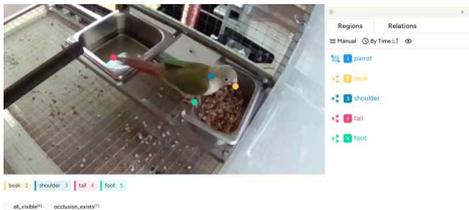
반려앵무 행동 패턴 분석의 정확도와 안정성을 향상시키기 위해, 먼저 Keypoint 방식과 본 연구에서 제안한 객체 탐지 기반 방식을 동일 영상 데이터로 비교하기로 하였고, 그를 위해 먼저 Keypoint를 통한 개체분석모델을 수립해 보았다.

3.2.1.1 Keypoint 추정 단독 방식

Keypoint 기반 자세 추정의 적용 가능성을 검증하기 위하여, 본 연구에서는 반려앵무의 행동 영상을 대상으로 데이터 라벨링부터 모델 학습까지의 절차를 수행하였다.

우선, Label Studio를 이용하여 영상으로부터 추출한 프레임 이미지를 프레임 단위로 라벨링하였다. 라벨링 클래스는 머리(Head), 꼬리(Tail), 발(Foot), 어깨(shoulder)의 네 부위로 설정하였으며, 초기에는 Keypoint(point)만을 정의하여 각 부위를 점 형태로 지정하였다.

라벨링된 데이터는 200장의 이미지를 기반으로 구성되었으며, 학습(train), 검증(val), 시험(test) 세트로 구분하였다.



라벨스튜디오 라벨링 화면



Keypoint 라벨링 포인트

[그림 3-2] Label Studio 이용 라벨링 포인트 설정

<input type="checkbox"/>	83	Oct 31, 22:04:18	1	0	0	GO		<>	
<input type="checkbox"/>	84	Oct 31, 22:05:35	1	0	0	GO		<>	
⋮									
<input type="checkbox"/>	199	Oct 31, 22:30:18	1	0	0	GO		<>	
<input type="checkbox"/>	200	Oct 31, 22:30:36	1	0	0	GO		<>	

[그림 3-3] Label Studio 이용 200장의 Keypoint 이미지 라벨링

그러나 이 초기 모델은 Keypoint 한가지 모델만으로는 반려앵무의 어떤 부위도 안정적으로 인식하지 못하였으며, [그림 3-4]이 그 결과이다.

이는 조류 특유의 곡선형 체형과 깃털 질감, 그리고 좁은 케이지 내부의 복잡한 배경이 점 단위 좌표 추정의 신뢰도를 급격히 저하시켰기 때문이다. 머리·꼬리·발 중 어느 부위도 일관된 좌표를 형성하지 못하였고, Heatmap 상의 확률 분포 역시 불규칙하게 퍼지며 실제 신체 구조와 대응되지 않았다. 특히 부리와 눈의 경계가 명확하지 않은 경우, 머리의 좌표가 전혀 탐지되지 않아 스켈레톤이 형성되지 않았으며, 학습 반복(epoch)을 늘려도 학습 손실은 수렴하지 않았다.

3.2.1.2 Keypoint와 Object Detection Ensemble 다단계 방식

이 한계를 극복하기 위해, Label Studio의 Annotation Task에 Object Detection 모듈을 병행하도록 커스텀 코드를 삽입하였다.



[그림 3-4] 안정적으로 포인트를 인식하지 못하는 Keypoint 단독모델

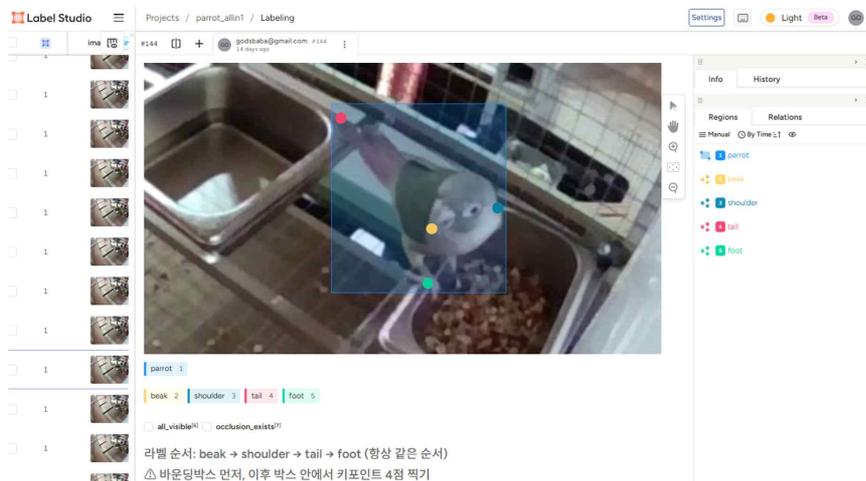
[그림 3-5] 코드는 실제 Label Studio 인터페이스에 추가된 설정 일부로, 반려앵무 전체 바운딩박스를 먼저 탐지한 후, 탐지된 바운딩박스 내부에서만 Keypoint를 수행하도록 구성하였다. 이 코드를 적용함으로써, Label Studio는 프레임 전체에서 반려앵무를 객체 단위로 먼저 탐지한 후, 탐지된 ROI(Region of Interest) 내부에서만 머리·꼬리·발·어깨 Keypoint를 추정하도록 동작하였다. 이 방식은 Keypoint만으로 전신을 분석하는 Bottom-up 구조보다 계산 효율이 높고, GPU 리소스 사용량이 약 35~40% 절감되었다. 또한 꼬리와 발 부위에서는 안정적인 점 좌표가 형성되었으며, 머리-몸-발의 중심을 연결한 Y자형 스켈레톤의 연속성이 확보되어 각도 계산 및 BC 산출이 가능하였다.

```

<View>
  <Image name="image" value="$image"/>
  <RectangleLabels name="bbox" toName="image">
    <Label value="Parrot" background="#32a852"/>
  </RectangleLabels>
  <KeypointLabels name="keypoints" toName="image">
    <Label value="Head" background="#ff5959"/> <Label value="Tail" background="#4b7bec"/>
    <Label value="Foot" background="#f5cd79"/>
  </KeypointLabels>
</View>

```

[그림 3-5] Label Studio의 Annotation Task 모듈 병행 커스텀 코드 내용



[그림 3-6] ROI 내부 머리·꼬리·발·어깨 Keypoint 라벨링



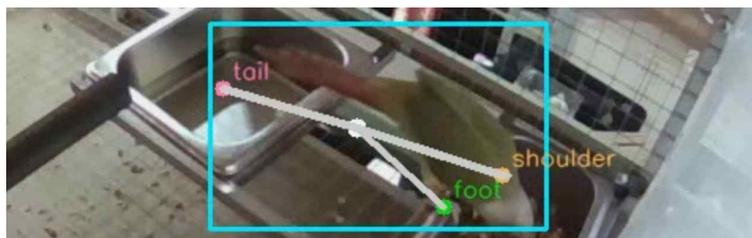
[그림 3-7] ROI 방식을 통한 구조 안정성 확보

이로써, 탐지 실패라고 볼 수 있는 초기의 상태에서 부분적으로 구조적 안정성이 확보되는 성과를 얻었다.

그러나 이러한 개선에도 불구하고, 먹이 섭취 행동 구간에서는 여전히 부리(머리) 좌표가 정확히 인식되지 않았다. 반려앵무가 먹이통 내부로 머리를 숙이거나 부리를 넣는 순간, 머리 객체는 부분 가림(occlusion)으로 인해 bounding box 내에서 사라졌고, Heatmap의 confidence가 0에 수렴하거나 점 위치가 프레임마다 불규칙하게 튀는 현상이 지속되었다.

결과적으로 먹이 섭취 장면에서 머리-몸-발의 스켈레톤이 자주 끊겨, 행동 전환 시점을 안정적으로 판단할 수 없었다. 이때 꼬리와 발은 여전히 정상적으로 추정되었으나, 부리 좌표의 손실로 인해 스켈레톤의 중심각 $\theta(H-BC-F)$ 가 계산되지 않아 행동 탐지가 중단되었다. 이 문제는 조류의 해부학적 구조에 있어서 Keypoint 방식의 적합성이 부족한 결과였다.

반려앵무의 머리는 짧고 둥근 곡면 구조를 가지며, 먹이통의 금속 테두리나 그늘과 픽셀 명암이 유사하여 모델이 혼동을 일으킬 수 있다. 또한, 부리의 크기가 전체 체형 대비 2~3%에 불과해 작은 움직임에도 Keypoint의 좌표가



[그림 3-8] 먹이를 먹을때에 Head 포인트 occlusion 문제



a. 금속 테두리나 그늘 등에 포인트를 혼동 b. 부리의 좌표가 자주 손실되는 문제

[그림 3-9] 새장 내 노이즈로 인한 Keypoint 좌표 혼동 및 손실

손실되었고, 이로 인해 시간축 상의 연속 프레임에서도 좌표의 불연속성이 심화되었다. 결국, Keypoint 방식은 객체의 윤곽이 불명확하거나 가림이 발생하는 환경에서는 구조적으로 불안정한 결과를 초래하였다.

3.2.1.3 실험적 의의와 전환의 필요성

이 실험 과정을 통해, Keypoint 방식이 반려앵무 행동 패턴 분석에 단독으로 적용되기에는 여러 제약이 존재함이 확인되었다. 객체 탐지와 병행할 경우 일정 수준의 구조적 안정성과 학습 효율성을 확보할 수 있었으나, 부리와 같이 작고 가려지는 부위의 신뢰도(confidence)가 낮아 행동 분류 정확도가 한계에 도달하였다.

특히, 먹이 섭취 행동에서 부리의 위치는 행동 탐지의 핵심 지표로 작용하지만, Keypoint 방식은 이 좌표의 지속적 추적이 불가능하여 정량적 분석에 실패하였다.

따라서 본 연구에서는 이러한 결과를 바탕으로 Keypoint 기반 구조가 가진 공간적 제약과 부위별 탐지 불안정성을 보완하고, 케이지 내부의 복잡한 환경에서도 안정적으로 부위를 인식할 수 있도록 Object Detection 기반 다단계 탐지 구조를 새롭게 설계하고자 하였다. 이 구조는 반려앵무 전체를 우선 탐지한 후, ROI 내부에서 머리, 꼬리, 발, 날개를 재탐지하여 스켈레톤을 구성하고, 이를 각도·위치 정보와 결합하여 행동을 분류하는 방식으로 발전하였다.

결과적으로, Keypoint 실험은 단순한 실패 사례가 아니라, 조류의 형태적 특성과 행동 패턴을 고려한 효율적 탐지 구조로의 전환을 이끈 검증 단계로서 의미를 가진다. 이 과정에서 도출된 부리 인식 실패, Heatmap 불안정성, 좌표 불연속성 등의 문제는 이후 다단계 객체 탐지 설계의 핵심 개선 요소로 반영되었다.

3.2.2 단일 Object Detection을 이용한 반려앵무 행동 탐지

본 연구에서는 Keypoint 방식의 한계를 확인한 이후, 반려앵무의 행동 인식에 있어 Object Detection 만으로도 일정 수준의 행동 구분이 가능한지를 검증하기 위해 단일 탐지 기반 실험을 수행하였다. 이는 각 프레임에서 반려앵무의 전체 형상을 탐지하고, 탐지된 객체의 위치 변화를 시간축으로 분석함으로써 행동을 분류하는 접근이다. 이를 통해 단일 탐지 방식의 구조적 제약과 노이즈에 따른 성능 저하를 평가하고, 이후 제안된 다단계 탐지 구조의 필요성을 입증하고자 하였다.

3.2.2.1 단일 Object Detection 실행

본 실험에서는 Label Studio를 이용해 반려앵무의 전체 형상을 Parrot 클래스 하나로 라벨링하였다. 이전의 Keypoint 실험과 달리, 세부 부위 라벨 없이 반려앵무 전체 윤곽을 바운딩박스로 표시하였으며, 총 약 250장의 이미지를 train 180장, val 40장, test 30장 세트로 분할하였다. YOLO 학습 환경은 다음과 같다.

학습 초기에는 mAP@0.5 값이 빠르게 상승하였으며, Precision 0.97, Recall 0.95 수준으로 반려앵무 전체 객체를 안정적으로 탐지하였다. 그러나 단일 객체 탐지 구조는 머리와 발과 같은 소형 부위가 전체 프레임 내에서 차지하는 비율이 극히 작기 때문에, 조명, 철망, 먹이통, 그림자 등 배경 노이즈에 의해 신체 일부가 탐지되지 않거나 잘못 탐지되는 구간이 빈번하게 발생하였다. 그 결과, 전체 객체 탐지는 유지되었으나 실제 행동과 관련된 세부

부위의 위치 정보가 손실되어 정확한 행동 판단이나 자세 변화를 포착하기 어려웠다.

3.2.2.2 단일 탐지 방식의 문제점과 노이즈 영향

단일 객체 탐지 방식은 구조적으로 세부 부위 정보를 인식하지 못하기 때문에, 행동 구분을 오직 전체 객체의 위치 변화에만 의존하게 된다. 이러한 구조적 단순화는 조류처럼 작은 신체 부위를 가진 대상에서는 여러 형태의 탐지 오류를 유발시킬 수 있다. 특히 프레임 간의 미세한 움직임, 그림자, 조명 변화, 또는 카메라 자체의 노이즈가 탐지 결과에 직접적인 영향을 미쳤을 것으로 보이며, 이로 인해 동일한 개체임에도 불구하고 탐지 경계가 불안정하게 변동되는 현상이 빈번하게 발생하였다.

배경 노이즈의 영향이 가장 두드러졌다. 케이지의 철망, 금속 먹이통의 반사, 또는 실내 조명 변화 등 환경적 요인으로 인해 바운딩 박스가 순간적으로 끊기거나 확장되는 장면이 다수 관찰되었다. 이때 YOLO 모델은 동일한 반려앵무임에도 프레임마다 Bounding Box의 크기를 10~20픽셀 단위로 달리 예측하는 경향을 보였다. 그 결과, 실제로는 움직이지 않고 정지해 있는 구간에서도 탐지 영역이 불필요하게 흔들리며, 이를 객체의 이동으로 잘못 해석하는 오류가 발생하였다. 즉, 배경 노이즈가 모델의 객체 경계 인식에 직접적인 영향을 미쳐, 탐지 안정도가 저하되는 문제가 확인되었다.



a. Head와 Foot만 탐지된 경우



b. 아무것도 탐지되지 않은 경우

[그림 3-10] 환경적 요인으로 인해 바운딩박스 손실

다중 객체 간 간섭 현상도 탐지 성능을 저하시키는 주요 원인이었다. 케이지 내부의 먹이통과 헛대는 반려앵무의 깃털 색상이나 질감과 유사한 부분이 많아, 모델이 이들을 실제 객체로 혼동하거나 비객체를 반려앵무로 잘못 탐지하는 사례가 다수 발생하였다. 특히 반려앵무가 헛대 위에 앉아 있을 때 몸통과 헛대의 경계가 흐려지며 하나의 덩어리로 인식되는 경우가 많았고, 이 경우 Bounding Box가 실제보다 두 배 이상 확장되어 탐지 결과가 왜곡되었다. 이러한 문제는 주변 환경의 질감·색상과 신체 윤곽이 겹칠 때 모델의 구분 능력이 급격히 떨어진다는 점을 보여준다.

이는 단일 객체 탐지 구조가 조류의 미세한 신체 변화를 반영하기 어렵다는 것을 의미한다. 이러한 현상은 YOLO 계열 모델의 grid-based 구조적 특성에도 관련이 있다. YOLO는 이미지를 일정한 grid로 분할한 뒤 각 셀에서 객체 존재 여부를 예측하는 방식으로 작동한다. 따라서 부리나 발처럼 작고 빠르게 움직이는 부위는 하나의 셀 단위보다 작게 표현되는 경우가 많으며, 이로 인해 탐지 누락이나 경계 불안정이 발생한다.

이와 같은 결과는 단일 탐지 방식이 반려앵무 행동 패턴 분석에서 발생하는 환경적 노이즈와 미세한 신체 움직임에 취약하다는 점을 명확히 보여준다.

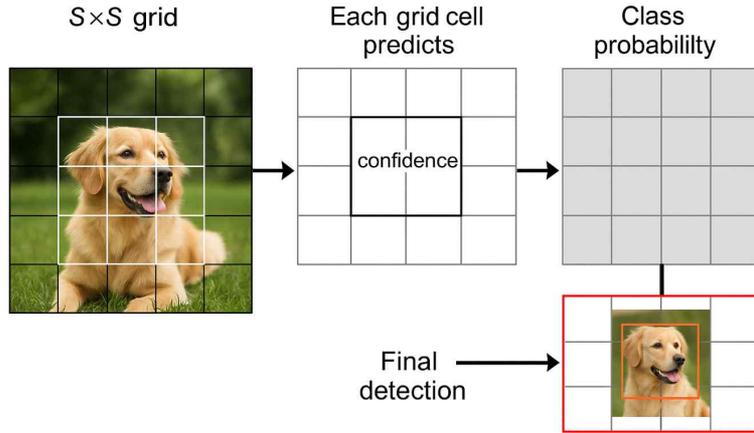
즉, 단일 탐지 구조만으로는 반려앵무의 실제 행동을 정밀하게 구분하기 어렵고, 객체 내부의 세부 부위를 함께 분석할 수 있는 다단계 탐지 방식로의 전환이 필수적임을 시사한다.



a. 새장 구조물을 Head로 오탐

b. 먹이찌거기를 Foot으로 오탐

[그림 3-11] 환경적 요인으로 인한 탐지 성능 저하



[그림 3-12] YOLO 계열 모델의 grid-based 구조적 특성

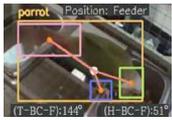
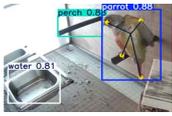
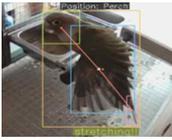
3.2.3 Object Detection 이용 다단계 방식 설계

앞서 수행된 Keypoint 방식과 단일 객체 탐지 방식의 실험을 통해, 반려앵무 행동 패턴 분석에서 가장 큰 문제는, 작은 부위인 머리와 발의 인식 불안정, 케이지 내부의 복잡한 배경 노이즈, 행동 구분에 필요한 세부 부위 정보의 결손이라는 점이 확인되었다.

이에 본 연구에서는 이러한 문제를 동시에 해결하기 위해, Object Detection과 부위별 재탐지를 결합한 다단계(Top-down) 탐지 구조를 설계하였다. 이 방식은 전체 이미지를 한 번에 처리하는 Bottom-up 구조와 달리, 먼저 반려앵무 전체를 하나의 객체로 탐지한 뒤, 탐지된 관심영역인 ROI 내부에서 머리, 꼬리, 발, 날개로 구성된 주요 부위를 개별적으로 다시 탐지하는 순차적 구조를 가진다. 즉, 전신 → 부위 → 행동 으로 이어지는 단계적 탐지 체계를 구성함으로써, 반려앵무의 형태적 복잡성과 환경 노이즈를 최소화하고 세부 부위의 정밀도를 동시에 확보하였다. [표 3-1]은 본 연구에서 제안하는 다단계 AI 기반 반려앵무 행동 패턴 분석 구조를 단계별로 정리한 것이다.

구체적으로, 1단계에서는 YOLO 모델을 사용하여 Parrot 클래스를 전체 프레임에서 탐지한다. 이때 탐지된 바운딩박스의 좌표값은 이후 단계의 ROI 설정에 활용된다.

[표 3-1] 다단계 AI 행동 패턴 분석 구조 설계

단계	주요 처리 내용	분석 목적	예시 이미지
1단계 반려앵무 객체 탐지	영상 내 반려앵무 전체 개체를 탐지하고 Bounding Box 설정	분석 대상 자동 인식 및 ROI 구분	
2단계 부위 세분화 탐지	ROI 내부에서 머리·날개·발·꼬리 등 세부 부위를 개별적으로 탐지	신체 구조 기반 스켈레톤(Y-shape) 구성 및 자세 판단	
3단계 환경 요소 세그멘테이션	케이지 내 주요 환경 요소 (물통·먹이통·횃대·이동 경로 등) 분리 및 라벨링	행동-환경 간 공간적 상호작용 분석	
4단계 각도·움직임·공간 정보 융합 분석	부위 간 각도(H-BC-F) 변화, 위치 이동, 환경 레이어를 시간축으로 계산	행동 시작·정점·종결 구간 정량화 및 움직임 패턴 분석	
5단계 행동 분류	각도·공간·시간 변화를 기반으로 Eating, Drinking, Resting, Bathing, Stretching, Pacing 행동 자동 탐지	반복성·지속시간·전환주기 등 행동 스펙트럼 통계화	
6단계 안정 행동-스트레스 행동 비교 분석	Resting, Bathing, Stretching과 Pacing의 상대적 비율을 비교	개체의 심리적 안정도와 스트레스 수준을 평가	

2단계에서는 ROI 내부를 대상으로 새로운 YOLO 서브모델이 작동하여, 머리·꼬리·발·날개를 각각의 클래스인 Head, Tail, Foot, Wing 으로 재탐지한다. 이 단계에서는 배경 영역이 전체 이미지 대비 약 70% 이상 제거되기 때문에, 단일 객체 탐지 시 발생하던 케이지 철망, 반사광, 그림자 등의 노이즈



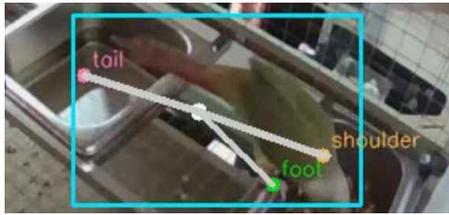
[그림 3-13] ROI를 위해 먼저 Parrot 클래스를 전체 프레임에서 탐지

간섭을 근본적으로 차단할 수 있었다. ROI 기반 탐지는 작은 부위에 대한 검출 안정성을 향상시켰다. 또한 같은 개체라도 자세 변화에 따라 부위 크기가 크게 달라지는 문제를 완화하여, 부리·다리와 같이 면적이 작은 클래스의 오검출 빈도를 감소시키는 효과가 확인되었다. 이러한 구조는 최종 행동 분류 단계에서 부위 좌표의 시간적 연속성을 확보하는 데 중요한 기반으로 작용하였다.

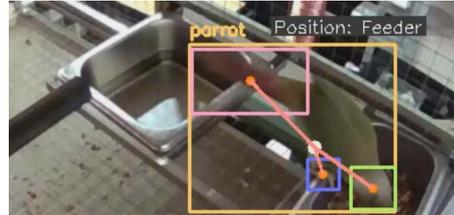
이 다단계 구조의 핵심은, 단순히 부위를 추가로 탐지하는 것이 아니라, 1 단계에서 얻은 공간적 맥락(Contextual Localization)을 기반으로 2단계 모델의 탐지 확률(confidence)을 정규화(normalization)하는 점에 있다. 즉, 반려앵무가 실제로 존재하는 영역인 ROI 내에서만 세부 탐지가 이루어지므로, 비객체 오탐지 확률이 급격히 낮아졌다. 또한 ROI 내부는 상대적으로 해상도가 높고 노이즈가 적어, 머리카락이나 발처럼 작고 세밀한 부위도 안정적으로 인식할 수 있었다. 탐지된 부위 좌표를 기반으로, 본 연구에서는 Y자형 스켈레톤을 구성하였다. 머리-몸중심-발을 잇는 선분으로 상체의 기울기를, 꼬리-몸중



[그림 3-14] Parrot 클래스 탐지 후 ROI 내에서 Head, Tail, Foot 탐지



a. 다단계 방식이어도 머리가 소실된 Keypoint 탐지



b. 머리를 먹이통에 넣은 상황에서도 탐지되는 본 제안 방식

[그림 3-15] Keypoint 방식 대비 비교우위인 Object Detection 다단계 방식

심-발을 잇는 선분으로 하체의 균형을 정의하여, 각도의 변화를 행동 판단의 기준으로 사용하였다. 이때 각도 변화량은 프레임 간 이동량보다 노이즈의 영향을 덜 받기 때문에, 조명 변화나 미세한 흔들림에도 안정적인 분석이 가능하였다. 반려앵무가 머리를 숙이거나 날개를 펼치는 등 국소적 행동 변화를 정량적으로 해석할 수 있는 정확하고 재현성 높은 행동 패턴 분석 모델임이 확인되었다.

또한 다단계 구조는 계산 효율성 측면에서도 장점을 보였다. 전체 프레임을 전신 단위로 지속 탐지하는 Bottom-up 방식과 달리, 1단계에서 ROI를 한정하면 2단계 연산 범위가 약 20~30% 수준으로 축소된다. 이로써 GPU 메모리 사용량이 감소하였고, 실시간 추론(inference)에서도 평균 18~22fps의 처리 속도를 유지할 수 있었다. 이는 향후 실시간 행동 모니터링 시스템 적용에 필수적인 속도 안정성을 확보한 결과이다.

3.2.4 다단계 AI 행동 패턴 분석방식과 종래 탐지모델 성능비교

앞서 제시한 네 가지 탐지모델인 Keypoint 추정 단독 방식, Keypoint-Object Detection Ensemble 방식, 단일 Object Detection 방식, 그리고 본 연구에서 제안한 Object Detection Top-down 방식은 각각 구조적 특성과 처리 절차가 다르며, 실제 반려앵무 행동 분석에서는 머리, 꼬리, 발과 같은 핵심 부위가 시간축 전반에서 안정적으로 탐지되는지가 행동 분류의 정확도와 재현성을 결정한다. 이에 본 연구는 네 모델의 정량적 성능을 비교하기 위해

[표 3-2] 다단계 AI 행동 패턴 분석방식과 종래 탐지모델 소실률 비교

Detection Model	Head Missing Ratio (%)	Tail Missing Ratio (%)	Foot Missing Ratio (%)
Keypoint Only	62.4	41.7	55.3
Keypoint-Detection Ensemble	38.9	19.6	24.1
Single Object Detection	27.5	14.2	18.9
Object Detection Top-down	0.0	1.2	3.4

먹이 섭취 및 음수 행동이 포함된 1분 영상 두 개를 활용하여 총 2분, 약 1800프레임에 대해 Head, Tail, Foot의 탐지 여부를 점검하고 소실률을 산정하였다.

그 결과, 제안한 Object Detection 다단계 방식은 ROI 기반 탐지 구조에 의해 세 부위 모두에서 가장 낮은 소실률을 보였으며, 특히 Head 소실률이 0으로 나타난 점은 Eating과 Drinking 행동의 시작·정점·종료를 일관되게 구분할 수 있다는 측면에서 매우 중요한 성과이다. 반려앵무의 먹이 및 물 섭취는 머리 위치가 행동 전환의 핵심 지표로 작용하기 때문에, 안정적인 Head 탐지는 전체 행동 분석의 정확도를 좌우하는 주요 요인이다.

이와 같은 성능 차이는 Top-down 구조 자체에서 기인한다. 전신 탐지를 통해 탐지 영역을 한정함으로써 케이지 철망, 반사광, 먹이통 테두리와 같은 배경 노이즈가 사전에 차단되고, 이어지는 세부 부위 전용 탐지 모델이 작고 빠르게 움직이는 신체 부위를 정밀하게 인식하게 된다. 또한 ROI 기반 탐지가 부위 좌표의 시간적 연속성을 유지시켜 각도 변화와 위치 변화 계산의 정확도를 향상시키며, 이는 최종 행동 판별의 신뢰도 증대로 이어진다.

종합적으로, 네 모델의 정량적 비교 결과는 Object Detection 사용자 정의 다단계 top-down 방식이 반려앵무 행동 분석에 가장 적합한 탐지 구조임을 명확히 보여준다.

3.3 행동 패턴 분석 연구 모델

3.3.1 행동 기준의 설정

3.3.1.1 카메라 위치에 따른 탐지항목 설정

본 연구의 데이터셋은 두 개의 상이한 시야 특성을 갖는 Front Camera와 Rear Camera에서 획득한 영상 데이터를 기반으로 구축되었다. 두 카메라는 동일 시간대에 동일 개체를 촬영하지만 서로 다른 공간적 역할을 수행하도록 의도적으로 배치되었다.

Front Camera는 새장 전면에서 반려앵무의 전신이 모두 포함되도록 설치하여, 이동·위치·자세 변화를 종합적으로 파악할 수 있도록 구성하였다. 이 카메라는 전신의 위치 변화, 좌표 이동량, 자세 앵글의 변화와 같은 거시적 행동 특징을 포착하는 데 최적화되어 있으며, 반려앵무의 주요 행동들을 포괄적으로 감지하는 기반 데이터를 제공한다.

Rear Camera는 상반신 중심의 정밀한 근접 시야를 제공함으로써 전신 카메라에서 인식이 불가능한 미세 행동의 특징을 보완하는 역할을 수행한다. Rear Camera는 전신보다 작은 움직임을 고해상도로 포착할 수 있기 때문에, 상체 중심 동작에 대한 정밀 탐지가 요구되는 행동 패턴 분석에 적합한 시야를 제공한다. 본 연구에서는 이러한 Rear Camera의 시야 특성을 활용하여 Stretching과 pacing 행동을 독립적 분석하였다.

Pacing 행동은 Front Camera의 시야 제약으로 인해 Rear Camera에서



[그림 3-16] Front Camera(좌)와 Rear Camera(우)의 시야각

[표 3-3] Front Camera와 Rear Camera에서 촬영한 행동 분류

카메라	시야 특성	탐지/분석 행동
Front Camera	전신 전체 촬영	먹이섭취(Eating) 음수(Drinking) 휴식(Resting) 목욕(Bathing)
Rear Camera	상반신 근접 촬영	기지개(Stretching) 불안성반복이동(Pacing)

분석하였다. Front Camera는 먹이통과 물통을 정밀하게 관찰하기 위해 하향 각도로 설치되어 있어, 케이지 내부를 좌우로 반복 이동하는 Pacing의 전신 움직임 및 Stretching에서의 날개의 펼친 모습을 충분히 포착하기 어렵다. 반면 Rear Camera는 개체의 이동 경로 전반을 포함하는 수평 시야를 제공하므로, 반복 이동의 거리와 리듬을 안정적으로 기록할 수 있어 Pacing 분석에 적합하며 뒷모습을 관측하여 날개의 펼침을 포착하기 수월하다. 이러한 이중 시야 기반 데이터셋 구성 방식은 단일 시야 기반 행동 패턴 분석의 한계를 극복하기 위한 핵심 전략으로, 본 연구에서는 이 두 장면 정보를 독립적으로 처리한 후 다단계 구조에 통합하는 방식으로 행동 분류 체계를 확립하였다.

Front Camera에서는 Eating, Drinking, Resting, Bathing을 탐지하도록 구성했으며, Rear Camera에서는 Stretching, Pacing 행동을 분석하였다.

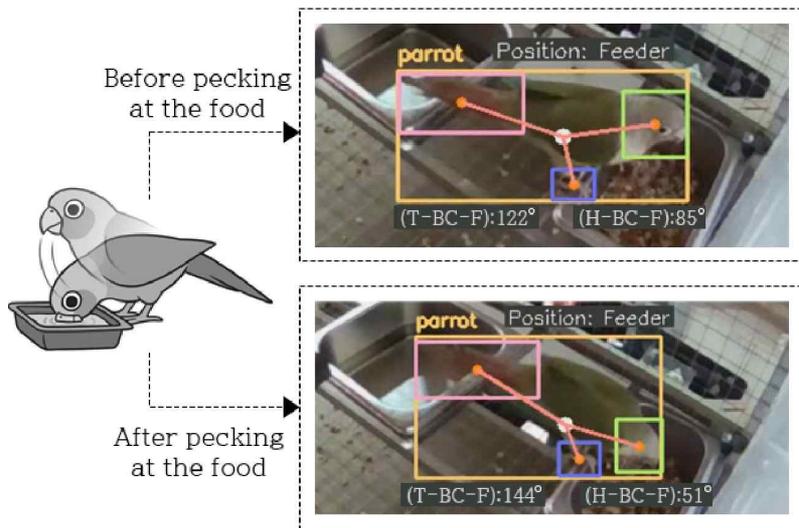
3.3.1.2 스켈레톤 추출 및 각도 설정

행동 분류의 핵심 지표로 활용되는 스켈레톤 정보는 Head, Tail, Foot의 중심점을 기반으로 BC를 산출한 뒤, 두 개의 주요 각도(θ_1 , θ_2)를 계산하는 방식으로 구축하였다. BC는 Tail과 Foot 혹은 Head와 Foot의 기하학적 중심을 이용해 산출되며, 반려앵무 신체의 중심축을 나타내는 기준점 역할을 수행한다. 이를 바탕으로 Head-BC-Foot으로 이루어지는 상체 기울기 각도(θ_1)와 Tail-BC-Foot으로 이루어지는 하체 중심각(θ_2)을 프레임 단위로 계산하였다. θ_1 은 Eating과 Drinking과 같이 상체가 전방으로 기울어지는

행동을 판단하는 데 핵심적인 역할을 하며, θ_2 는 Resting 상태에서 나타나는 하체 안정 여부를 판단하는 데 사용된다. Bathing 행동은 Water 영역에서 θ_1 변동이 나타나고 Wing 움직임이 결합되는 형태로 구분하였다. Pacing 행동은 θ_1 변화와 더불어 Foot 좌표의 급격한 위치 이동이 지속적으로 나타나는 패턴을 기반으로 분류하였다.

Stretching은 Rear Camera에서 Wing이 직접 탐지되는 경우로 판단하여, 각도 계산과 독립적으로 처리하였다. 이렇게 구축된 스켈레톤 및 각도 정보는 프레임 단위의 자세 변화를 정량적으로 표현할 수 있는 데이터로서, 이후 행동 분류 모델의 주요 판단 기준으로 활용되었다.

이러한 스켈레톤 기반 각도 정보는 이후 행동 판단 단계에서 피킹 패턴, 위치 기반 Feeder와 Water 마스크 정보, Foot의 이동 궤적 등을 함께 통합하여 최종 행동 레이블을 결정하는 데 사용되었다. 특히 θ_1 은 프레임 간 변화량을 이동평균으로 안정화한 뒤 급격한 하강 구간을 추적함으로써 Eating과 Drinking의 피킹 동작을 정량적으로 탐지하는 핵심 지표로 활용되었으며, θ_2 는 Resting의 장기적 안정 패턴을 구분하는 기준으로 적용되었다. 최종적으로 본 연구에서 구축된 스켈레톤-각도 기반 구조는 행동 분류 전 과정에서 공통적으로 참조되는 기본 피쳐(feature)로 기능하며, 뒷따른 연구에서 다양하



[그림 3-17] 두 개의 주요 각도(θ_1 , θ_2) 기준 설정

```

# BC(center): Head-Tail-Foot 중 유효한 두 점의 중간점 사용
BC_x = (head[0] + foot[0]) / 2
BC_y = (head[1] + foot[1]) / 2
BC = (BC_x, BC_y)

#  $\theta_1$ : Head-BC-Foot 상체 기울기 (Eating-Drinking 판단 핵심)
theta1 = tri_angle(head, BC, foot)

#  $\theta_2$ : Tail-BC-Foot 하체 중심 안장각 (Resting 판단 핵심)
theta2 = tri_angle(tail, BC, foot)

# 시각화용 스켈레톤 연결
cv2.line(frame, head, BC, color, 2)
cv2.line(frame, tail, BC, color, 2)
cv2.line(frame, foot, BC, color, 2)

# 프레임마다  $\theta_1, \theta_2$  기록 → 행동 판별 알고리즘에 전달
theta1_hist.append(theta1)
theta2_hist.append(theta2)

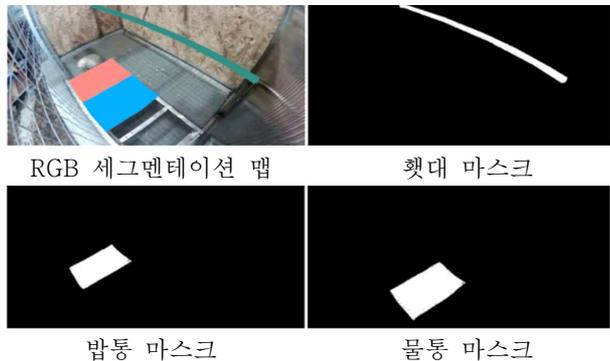
```

[그림 3-18] 스켈레톤 추출 및 θ_1, θ_2 계산 핵심 코드

게 다루어질 행동 유형에 대해 일관된 방식으로 정량적 탐지가 가능하도록 설계되었다.

3.3.1.3 세그멘테이션 기반 위치 정보 고려 설정

행동의 맥락을 정확하게 파악하기 위해서는 특정 행동이 케이지 내 어느 위치에서 발생했는지에 대한 정보가 필수적이다. 이를 위해 본 연구에서는 케이지 내부의 주요 구조물인 Feeder, Water, Perch를 RGB 색상 기반 세그멘



[그림 3-19] 세그멘테이션 맵 생성 및 각 구조물별 마스크 설정

테이션 마스크로 제작하여 위치 정보를 체계적으로 분류하였다.

세그멘테이션 마스크는 고정된 기준 프레임을 기반으로 각 위치 영역에 고유한 RGB 값을 부여하는 방식으로 구성되었다. 이후 각 프레임에서 Foot 중심점 좌표가 해당 마스크의 어느 색상 픽셀에 위치하는지를 탐지함으로써 행동 발생 위치를 자동 탐지하였다. 예를 들어 Foot 중심점이 빨간색 픽셀에 위치하면 Feeder 영역에 있는 것으로, 파란색 픽셀에 위치하면 Water 영역, 초록색 픽셀은 Perch 영역에 있는 것으로 판단하였다.

이러한 세그멘테이션 기반 위치 정보는 일관된 위치 탐지를 가능하게 하므로 Front Camera 기반 행동 패턴 분석의 신뢰도를 높이는 중요한 요소로 작용하였다.

3.3.1.4 Eating 행동 탐지기준

Front Camera에서 구축된 행동 데이터는 총 다섯 가지이다. Eating, Drinking, Resting, Bathing 네가지 행동은 모두 전신 수준에서 머리·몸통·발 좌표의 상호 관계와 이동 패턴을 통해 구분 가능하며, 각 행동의 정의는 다음과 같은 형태로 정밀하게 구성되었다.

Eating은 반려앵무가 부리를 먹이통 쪽으로 직접 진입시키며 사료를 향해 머리의 기울기를 감소시키는 동작이 확인될 때로 정의하였다. 단순히 머리 좌표가 먹이통 방향으로 이동하는 것만으로는 Eating으로 판단하지 않고, 부리가 실제 먹이에 닿기 위해 사선 또는 수직 방향으로 꺾여 들어가는 형태의 자세 변화가 나타나야 한다. 이를 정량적으로 구분하기 위해 본 연구에서는 Head 중심점이 먹이통 마스크 내부로 진입하고 θ_1 이 직전 상태 대비 20° 이상 감소한 후 일정 시간 유지되는 구간을 Eating으로 분류하였다. 이러한 정의는 식이 행동이 단순한 방향 이동이 아닌 실제 섭취 동작에서 비롯된 정교한 자세 변화를 수반한다는 특징을 반영하며, 시각적 관찰을 AI 기반 스켈레톤 분석으로 정량화하는 과정에서 행동 탐지의 신뢰도를 높이는 데 중요한 역할을 한다. 이러한 기준은 단순 위치 정보에만 의존하지 않고, 부리의 실제 피킹 동작과 스켈레톤 기반의 기울기 변화를 함께 반영함으로써 Eating 행동



Eating 장면 (Peaking 직전)



Eating 장면 (Peaking 직후)

[그림 3-20] Eating 행동 탐지 및 누적횟수 기록 화면

의 특성을 보다 정확하게 반영한다. 이 행동은 누적횟수를 기록하여 데이터로 활용하였다.

산출되는 수평 기울기 θ_1 을 프레임 단위로 계산하고, 이동평균을 적용하여 단기적인 흔들림을 제거하였다. 이후 직전 상태와 최근 1초 구간의 최대 기울기 값을 기준으로 감소량을 비교하여, 피킹 동작의 발생 여부를 정량적으로 판단하였다. 이는 단순히 θ_1 이 작아지는 상황을 모두 Eating으로 분류하는 것이 아니라, 기울기 감소가 설정된 임계치(Drop threshold)를 초과하여 급격하게 이루어지고, 그러한 패턴이 약 0.3초 이상 유지될 때에만 Eating 이벤트가 발생하도록 하기 위함이다.

추가적으로 Head 좌표가 Feeder 마스크 내부로 진입하는지를 1차 조건으로 활용하여 Eating과 Drinking 후보 구간을 보정함으로써 오분류를 최소화하였다. 이 위치 기반 판단은 θ_1 감소 패턴이 Drinking과 유사하게 나타나는 경우에도 마스크 정보를 통해 정확도를 유지할 수 있도록 돕는다. 실제 구현 과정에서는 특정 시간 동안 동일 이벤트가 반복적으로 탐지되는 것을 방지하기 위해 쿨다운 메커니즘을 도입하여, 노이즈로 인한 과탐지를 효과적으로 억제하였다.

Eating 이벤트가 발생하면 즉시 누적 횟수를 증가시키고, SessionTracker를 통해 동일 구간 내의 이벤트를 하나의 식사 세션으로 통합하여 관리하였다. 이로써 Eating 동작은 머리의 기울기 변화 기반 동작 패턴, Feeder 진입 여부, 시간적 지속성, 중복 방지를 위한 쿨다운이 결합된 형태로 본 연구의

```

ht_raw = ht_angle_horizontal(head, tail) # HT 각도 계산
ht_smooth_hist.append(ht_raw); ht_smooth = sum(ht_smooth_hist)/len(ht_smooth_hist) # 스무딩
ht_roll_hist.append(ht_smooth); peak = max(ht_roll_hist) # 최근 최대값(peak)
drop_prev = (prev_ht_smooth - ht_smooth) if prev_ht_smooth else 0.0 # 직전 대비 드롭
drop_from_peak = peak - ht_smooth # peak 대비 드롭

label_head = in_label(head) # Head 위치(Feeder/Water)
if label_head=="Feeder" or position=="Feeder": cls="Eating" # 위치 기반 Eating
elif label_head=="Water" or position=="Water": cls="Drinking" # 위치 기반 Drinking
else: cls=None

th = DROP_DRINK if cls=="Drinking" else DROP_EAT # 행동별 드롭 임계값 선택

if cooldown > 0: cooldown -= 1 # 중복 방지 클다운
else:
    trigger = (drop_prev >= th) or (drop_from_peak >= th) # 드롭 조건 충족 여부
    if USE_LOW_ANGLE_GUARD: trigger &= (ht_smooth <= LOW_ANGLE) # 낮은 각도 조건(선택)

    if trigger and cls=="Eating":
        eating_count += 1
        eat_tracker.on_event(t_sec) # Eating 이벤트

    elif trigger and cls=="Drinking":
        drinking_count += 1
        drink_tracker.on_event(t_sec) # Drinking 이벤트

    if trigger: # 이벤트 후 초기화
        cooldown = COOLDOWN
        ht_roll_hist.clear(); ht_smooth_hist.clear()
        ht_smooth_hist.append(ht_raw)

prev_ht_smooth = ht_smooth # 다음 프레임 대비 저장

```

[그림 3-21] Eating·Drinking 탐지 위한 피킹이벤트 탐지 알고리즘 핵심 코드

행동 패턴 분석 시스템이 단순 좌표 이동이 아닌 실제 섭취 행동을 정밀하게 포착하도록 구현되었다. Eating·Drinking 탐지 위한 피킹이벤트 탐지 알고리즘 핵심 코드를 [그림 3-21]에 나타내었다.

3.3.1.5 Drinking 행동 탐지기준

Drinking은 Eating과 매우 유사한 머리 기울기 변화를 보이지만, 부리의 진입 위치가 물통이라는 점에서 구분된다. Drinking 행동은 부리가 물 표면



Drinking 장면 (Peaking 직전)



Drinking 장면 (Peaking 직후)

[그림 3-22] Drinking 행동 탐지 및 누적횟수 기록 화면

쪽으로 반복적으로 짧게 내려가며 물을 뜨는 특유의 움직임이 나타나는 것이 특징이며, θ_1 의 감소 역시 Eating과 동일하게 관찰된다. 본 연구에서는 Head 중심점이 물통 영역으로 진입하고, θ_1 이 약 20° 이상 감소하는 기울기 변화가 발생하되, 이 변화가 짧고 반복적으로 나타나며 BC와 Foot이 물통 가장자리에서 유지되는 형태의 시간적 패턴을 보일 때를 Drinking 행동으로 정의하였다. 즉, Eating과 Drinking은 동일한 관절 각도 변화가 나타나지만, 부리가 들어가는 대상과 공간 맥락의 차이를 통해 구분된다. 이 행동도 누적횟수를 기록하여 데이터로 활용하였다.

Drinking 행동의 최종 탐지는 Eating과 동일하게 Head-Tail 축의 수평 기울기(θ_1)를 이용한 ‘드롭(drop)’ 패턴 기반으로 이뤄지지만, 코드 레벨에서는 먼저 Head 혹은 Foot의 진입 위치를 세그멘테이션 마스크(Feeder/Water)로 판단하여 선행적으로 행동 후보를 결정한다. 즉, θ_1 의 감소량이 Eating에서 사용된 드롭 임계치와 동일하게 계산되더라도, Head가 Water 영역에 위치하거나 Foot이 물통 가장자리에 머무르는 경우에는 Drinking으로 우선 분류된다.

이후 드롭 크기가 Drinking 임계값을 초과하면 Drinking 이벤트가 발생하며, 중복 탐지 방지를 위해 일정 쿨다운 기간 동안 재탐지를 제한한다. 이러한 구조는 θ_1 의 급격한 기울기 변화가 Eating과 동일하게 나타나는 상황에서도, 머리가 들어가는 공간이라는 문맥적 조건을 이용하여 Drinking을 안정적으로 탐지할 수 있게 한다. 이벤트가 발생하면 drinking count가 증가하며, Session Tracker가 해당 시점을 Drinking 세션으로 기록한다.

3.3.1.6 Resting 행동 탐지기준

Resting은 장시간에 걸쳐 Head, Foot, BC 좌표의 상대적 이동 비율이 매우 낮게 유지되고, θ_1 과 θ_2 가 일정 범위 내에서 안정적으로 유지되는 정적 행동으로 정의하였다. 이는 반려앵무가 헛대 위에서 신체를 거의 움직이지 않은 채 휴식하는 실제 행동 특성을 반영한 것으로, 본 연구에서는 좌표 변화량을 절대 픽셀 값이 아닌 객체 크기 대비 이동 비율(%)로 산정하였다.

구체적으로 약 10초 동안 전체 객체 기준 5% 이하의 이동 비율과 θ_1 · θ_2 의 $\pm 3^\circ \sim \pm 5^\circ$ 범위 내 안정 유지 조건을 Resting의 판단 기준으로 설정하였다. Resting은 특정 행동의 횟수로 측정할 수 있는 유형이 아니기 때문에, 개체가 안정적으로 머무른 지속 시간을 중심으로 탐지하는 것이 적합하며 본 연구에서도 이러한 시간 기반 기준을 적용하였다.

상대적 기준을 도입한 이유는 카메라의 거리, 각도, 개체 크기, 프레임 간 위치 편차 등에 따라 절대 픽셀 단위 변화는 동일한 움직임이라도 전혀 다르게 인식될 수 있기 때문이다. 예를 들어 동일한 5px 이동이 Rear Camera 같은 근접 촬영에서는 큰 움직임으로 보이지만, Front Camera의 원거리 촬영에서는 미세 움직임으로 인식되는 스케일 차이가 존재한다. 이를 해결하기 위해 좌표 변화를 객체 바운딩박스 길이에 대한 상대적 변화량으로 환산하여 평가하였으며, 이 방식은 촬영 조건과 개체 크기의 차이에도 불구하고 Resting 상태를 일관된 기준으로 탐지할 수 있다는 장점을 제공한다.



Resting 탐지장면 5초경과시



Resting 탐지장면 10초경과시

[그림 3-23] Resting 행동 탐지 및 누적시간 기록 화면

```

# 최근 WINDOW_SEC 구간의 움직임 비율 계산
def motion_ratio(self, win):
    t_now = self.history[-1][0]
    win_h = [h for h in self.history if t_now-h[0] <= win]
    if len(win_h) < 2: return 1.0, None

    disp, darea = 0.0, 0.0
    for i in range(1, len(win_h)):
        _, x0,y0,a0,_ = win_h[i-1]
        _, x1,y1,a1,_ = win_h[i]
        step = math.hypot(x1-x0, y1-y0)
        if step < PIX_EPS: step = 0.0
        disp += step
        da = abs(a1 - a0)
        if da/max(a0,1e-6) < AREA_EPS: da = 0.0
        darea += da

    avg_diag = sum(h[4] for h in win_h)/len(win_h)
    ratio = max(disp/avg_diag, darea/max(a1,1e-6))
    return ratio, win_h[0][0]

# RESTING 진입/이탈 갱신
def update_state(self, ratio, win_start, t):
    if win_start and not self.resting and ratio <= MOTION_THR:
        self.resting, self.rest_start = True, win_start

    if self.resting and ratio > MOTION_THR:
        self.episodes.append((self.rest_start, t))
        self.resting, self.rest_start = False, None

```

[그림 3-24] Resting 행동 판정 핵심코드

이러한 Resting 정의를 실제 분석 단계에 적용하기 위해, 본 연구에서는 IoU 기반 단순 트래커에 EMA(Exponential Moving Average) 스무딩을 결합하여 바운딩박스의 중심 좌표와 면적 변화를 안정적으로 탐지하였다. 매 프레임에서 얻어진 중심점·면적 정보를 일정 길이의 히스토리에 저장한 뒤, 최근 약 10초 구간을 슬라이딩 윈도우로 평가하여 중심 이동량과 면적 변화를 계산하였다. 이후 이 두 값은 객체의 평균 대각선 길이와 평균 면적에 대해 정

규화되어 이동 ratio로 변환되며, 이 값이 사전에 설정된 임계값 이하로 유지되는 경우 해당 구간을 Resting 상태로 판정하도록 구현하였다.

특히 EMA 스무딩은 프레임 간 탐지 흔들림을 효과적으로 완화하며, 픽셀 단위의 미세 움직임이나 단기적인 면적 변화는 일정 비율 이하일 경우 0으로 처리함으로써, 실제 휴식과 무관한 잡음이 Resting 판정에 영향을 주지 않도록 하였다. 이러한 방식은 장시간의 안정 구간을 자동으로 탐지하면서도, 순간적인 카메라 튕 현상이나 부분적 탐지 누락을 자연스럽게 흡수할 수 있어, Resting 상태를 보다 신뢰성 있게 포착할 수 있다는 장점을 제공한다.

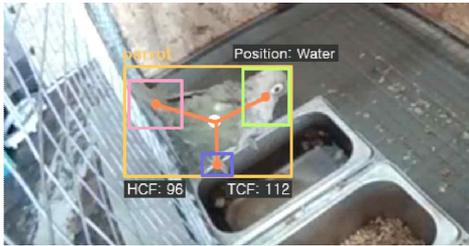
3.3.1.7 Bathing 행동 탐지기준

Bathing은 외형적으로 Drinking과 매우 유사한 자세 패턴을 보이기 때문에 단일 프레임 기반 스켈레톤 분석만으로는 높은 오판 가능성을 가진다. 실제로 Foot과 BC 좌표가 Water 영역 내부로 진입하고 상체가 전방으로 기울어지는 Bathing 초기 동작은 Drinking에서 Head가 물 표면으로 접근하는 움직임과 시각적으로 거의 동일하다. 또한 Bathing 중에는 Foot이 물속에 잠겨 탐지가 되지 않거나, Wing을 펼치고 상체를 흔드는 동작이 매우 짧은 순간에만 나타나기 때문에 기존의 각도 기반 패턴만으로 두 행동을 명확히 구분하기 어렵다.

이러한 한계를 보완하기 위해 본 연구에서는 4마리 개체에서 획득한 Bathing 장면을 가능한 한 다수 확보하여 별도의 Bathing 전용 데이터셋을 구축하였다. 이를 기반으로 단순한 Water 영역 진입 여부가 아닌, Bathing 영상에서 학습된 전신 시각 특징이 YOLO 모델에서 연속적으로 탐지되는 경우에만 Bathing으로 판정하는 전신 기반 Bathing 분류 방식을 채택하였다.

또한 Bathing은 짧은 물 튀김이나 Head-only 접근과 혼동될 수 있기 때문에 최소 1.5초 이상 연속적으로 탐지되는 구간만 Bathing episode로 인정하였다. 이 시간 조건은 불확실한 순간적 행동을 배제하고 실제 Bathing 패턴을 안정적으로 구분하기 위한 완충 장치로 작동하였다.

Bathing episode는 IoU 기반 트래커를 통해 단기 탐지 누락이나 박스 혼



Bathing 탐지 장면 (진입직전)



Bathing 탐지 장면 (진입)

[그림 3-25] Bathing 행동 탐지 장면

들림의 영향을 최소화하여 기록되었으며, Bathing box가 연속적으로 유지되고 중심점 및 크기 변화가 안정된 상태에서 Bathing confidence가 지속적으로 유지된 경우에 최종 Bathing으로 판단하였다.

한편 Bathing은 개체 간 행동 방식의 차이가 특히 크게 나타나는 행동으로, 동일한 시간 동안에도 전혀 다른 목욕 패턴이 관찰된다. 일부 개체는 1~2분 동안 물통 내부에서 반복적으로 움직이며 전신을 적시는 반면, 또 다

```
def iou(a, b):
    x1, y1 = max(a[0], b[0]), max(a[1], b[1])
    x2, y2 = min(a[2], b[2]), min(a[3], b[3])
    inter = max(0, x2 - x1) * max(0, y2 - y1)
    area = (a[2]-a[0])*(a[3]-a[1]) + (b[2]-b[0])*(b[3]-b[1]) - inter
    return inter / (area + 1e-6)

class Track:
    def __init__(self, box): self.box, self.miss = box, 0
    def update(self, box, a=0.4): # EMA로 박스 흔들림 완화
        cx = a*((box[0]+box[2])/2) + (1-a)*((self.box[0]+self.box[2])/2)
        cy = a*((box[1]+box[3])/2) + (1-a)*((self.box[1]+self.box[3])/2)
        w = a*(box[2]-box[0]) + (1-a)*(self.box[2]-self.box[0])
        h = a*(box[3]-box[1]) + (1-a)*(self.box[3]-self.box[1])
        self.box = (cx-w/2, cy-h/2, cx+w/2, cy+h/2)

    def update_tracks(dets, tracks, thr=0.3):
        for t in tracks:
            best = max(dets, key=lambda d: iou(t.box, d), default=None)
            if best and iou(t.box, best) > thr: t.update(best)
            else: t.miss += 1
        tracks[:] = [t for t in tracks if t.miss <= 5] # 단기 누락 허용
```

[그림 3-26] Bathing 행동 판정 핵심코드

큰 개체는 물통에 1~2회만 잠깐 진입하고 대부분의 시간을 부리를 이용해 전신을 preening 하는 데 사용할 수 있다. 이러한 개체별 Bathing 방식과 지속시간의 변이로 인해, 본 연구에서는 Bathing 행동이 얼마나 오래 지속되었는가보다 Bathing을 수행했는지의 여부를 더 중요한 분석 기준으로 설정하였다. Bathing은 심리적 안정 상태에서 발현되는 행동이므로, 방법이나 지속시간의 차이보다 Bathing의 ‘발생’ 자체가 행동학적으로 더 큰 의미를 갖기 때문이다.

추가적으로 Bathing episode 간의 독립성을 확보하기 위해, Bathing이 발생하고 난 이후 3분 이내에 다시 탐지된 Bathing은 동일한 episode로 간주하였으며, 3분의 간격을 초과한 시점 이후 새롭게 탐지되는 Bathing에 대해서만 별도의 episode로 계산하도록 하였다. 이는 Bathing 행동 전후에 나타나는 짧은 물기 털기나 반복 진입을 하나의 연속된 행동 흐름으로 처리하고, 시간적으로 구분되는 Bathing 시도를 독립 episode로 분석하기 위한 조치이다.

3.3.1.8 Stretching 행동 탐지기준

기지개 행동은 날개가 한쪽 또는 양쪽으로 펼쳐지는 동작을 기반으로 정의하였으며, Wing 클래스가 명확하게 탐지되는 프레임만을 대상으로 데이터셋을 구성하였다. 해당 행동은 헛대 위에서 주로 발생하며, 상체가 뒤로 젖혀지거나 날개가 좌우로 크게 펼쳐지는 형태로 나타난다. Rear Camera는 이와



스트레칭 탐지 장면(스트레칭 직전) 스트레칭 탐지 장면(스트레칭 탐지)

[그림 3-27] 스트레칭 행동 탐지 장면

같은 동작의 전개 과정에서 머리, 날개 끝단, 몸통의 움직임을 근접 시야에서 확보할 수 있어 Stretching 행동의 식별이 Front Camera보다 훨씬 안정적이다. 이 행동은 누적횟수를 기록하여 데이터로 활용하였다. 스트레칭은 표 [1-12]에서 ‘안정 행동’으로 분류된 대표적 긍정행동에 해당하며, 심리적 안정 상태에서 주로 관찰되는 동작이다.

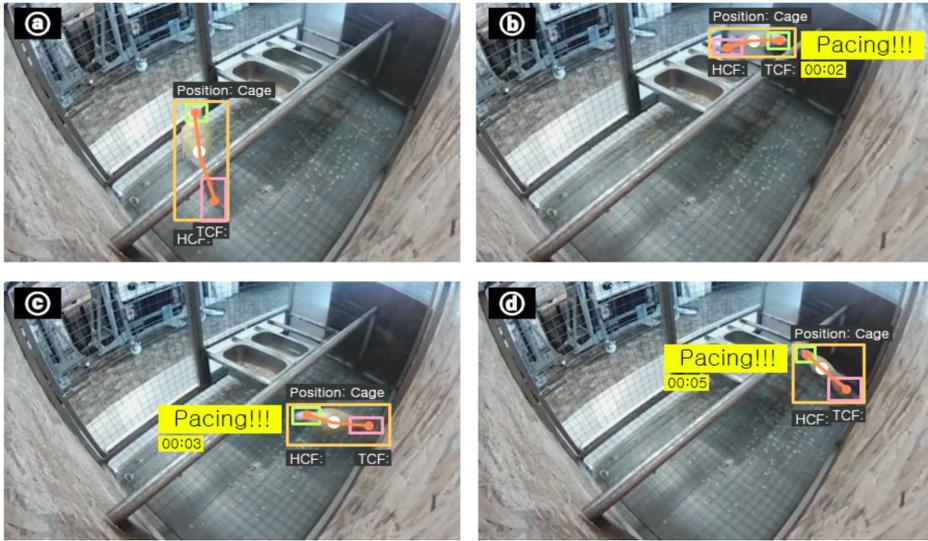
날개와 상체를 길게 펴거나 한쪽으로 늘리는 Stretching은 근육을 이완하고 관절을 부드럽게 하여 비행을 준비하는 생리적 기능을 가지며, 주변 환경이 안전하고 위협이 없을 때 나타나는 전형적인 이완 행동이다.

Stretching 행동은 자연 발생 빈도가 낮아 하루 단위의 촬영만으로는 충분한 수의 프레임을 확보하기 어렵기 때문에, 3일간의 촬영 데이터를 누적하여 학습·검증·시험 세트를 구성하였다. 이러한 방식은 미세 행동의 데이터 부족 문제를 해결하고, 행동 패턴의 다양성을 확보하는 데 효과적이었다. 한편 프리닝(Preening) 행동은 Rear Camera 시야에서도 관찰이 가능하지만, 본 연구의 분석 범위에 포함되지 않아 데이터셋 구축 대상에서 제외하였다.

Rear Camera 기반 데이터는 전신 시야에서 관찰하기 어려운 소형 부위의 움직임을 명확하게 반영할 수 있으며, Front Camera 데이터와 결합하여 다단계 구조의 행동 패턴 분석 모델을 더욱 정밀하게 구성 활용되었다.

3.3.1.9 pacing 행동 탐지기준

Pacing 행동은 스트레스 상황에서 나타나는 지속적·반복적 이동 패턴으로, Head나 Foot처럼 작은 부위의 좌표는 케이지 철망 가림이나 프레임 손실로 인해 안정적으로 확보되기 어렵기 때문에, 본 연구에서는 반려앵무의 전체 바운딩박스를 기반으로 판단하였다. 구체적으로는 바운딩박스 중심점의 프레임 간 이동량을 화면 대각선 길이에 대해 정규화하여(speed_norm), 이 값이 움직임 화면상에서 1% 이상을 초과하는 상태가 약 3초 이상 연속될 때 Pacing이 시작된 것으로 판단하였다. 이는 특정 방향으로 동일하게 이동하는 것이 아니라 좌우·상하로 불규칙하게 반복이동하는 전체 패턴을 포착하기 위한 것으로, 순간적인 급가속이나 단발성 이동이 아니라 ‘지속된 이동성’을 기준으로



① Pacing 탐지 직전, ② 탐지 2초후, ③ 탐지 3초후, ④ 탐지 5초후

[그림 3-28] Pacing 행동 탐지 장면

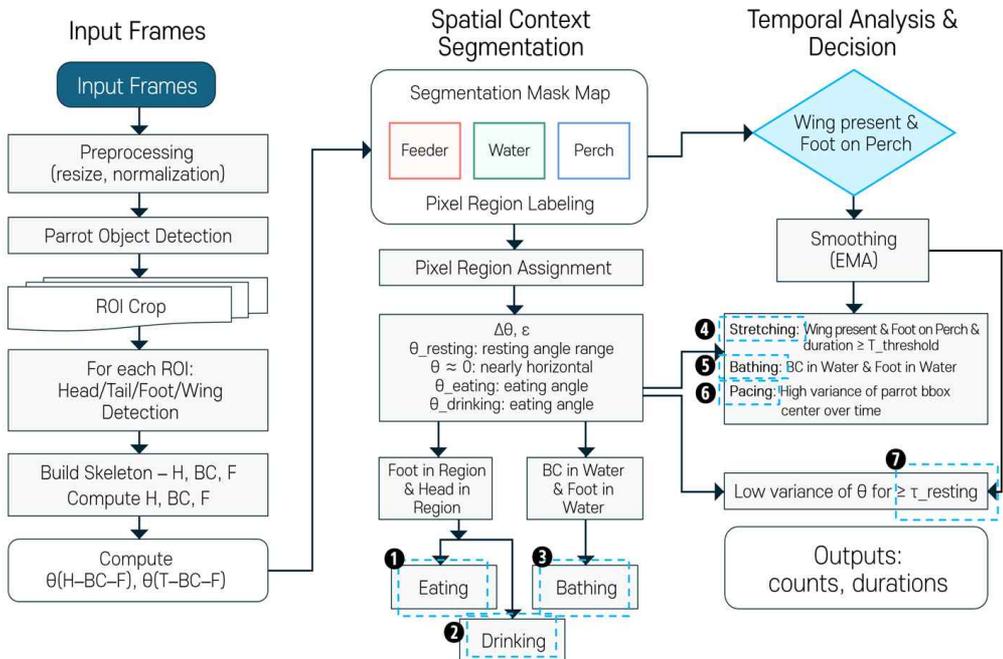
분류하는 방식이다.

Pacing 상태가 시작된 이후에는 반대로 일정 시간(2초) 이상 speed_norm 이 임계값 이하로 떨어져 ‘정지 상태’가 유지될 때 이를 종료로 간주한다. 본 연구에서 사용한 FSM(finite-state machine) 기반 로직은 YOLO가 일시적으로 대상을 놓치는 프레임이 있어도 이전 프레임과의 시간 간격을 고려해 갭을 자동 보정하도록 설계되었으며, 탐지 누락 직후 다시 등장한 경우에도 실제 이동 시작 시점 prev_t까지 근사적으로 되돌려 판정한다. 이 구조는 빠른 움직임으로 인해 발생하는 ROI 불안정성을 보완하고, 불필요한 단기 오탐을 억제하여 지속적 이동만을 선별적으로 탐지할 수 있다는 장점을 제공한다. 또한 Pacing은 Resting과 달리 $\theta_1 \cdot \theta_2$ 같은 각도 기반 지표를 사용하지 않고, Foot 좌표가 먹이통·물통·햇대 등 특정 사물에 고정되지 않고 계속 위치를 바꾸는 패턴과도 일치한다. 이는 스트레스 상태에서 흔히 나타나는 비정형적인 왕복 이동 특성과 동일하며, [표 1-12]에서 분류한 대표적인 스트레스 행동 범주에 속한다. 본 연구에서는 이러한 특징을 반영하여 ‘횟수’가 아니라 ‘지속 시간’을 핵심 지표로 채택하였으며, 장시간 유지된 이동 패턴을 바탕으로 개체의 불안 수준을 정량적으로 평가하였다.

3.3.2 반려앵무 행동 탐지를 위한 전체 파이프라인

본 연구에서 구축한 반려앵무 행동 탐지 파이프라인은 입력 영상으로부터 객체를 탐지하고, 주요 신체 부위를 추출한 뒤, 스켈레톤과 각도 정보를 계산하고, 마지막으로 공간적 맥락과 시간 패턴을 통합하여 최종 행동을 분류하는 다단계 구조로 이루어져 있다. 이 파이프라인은 단일 프레임의 정적 정보뿐 아니라 자세의 변화, 영역 간 위치 이동, 반복 동작의 지속 패턴 등 시공간적 정보를 모두 고려함으로써, 기존 단일 시야 기반 접근보다 높은 해석력과 정밀도를 제공한다.

Input Frames 단계는 본 연구의 파이프라인이 입력된 영상 프레임으로부터 시작된다는 점을 명확히 보여준다. 본 연구에서는 Front Camera와 Rear Camera에서 획득한 영상 데이터를 전처리하여, 해상도와 밝기 편차를 보정한 뒤 분석에 적합한 정규화된 영상으로 변환하였다.



[그림 3-29] 반려앵무 행동탐지 모델 전체 파이프라인 구조도

Parrot Object Detection 단계는 입력 프레임에서 반려앵무의 전신을 먼저 탐지한 후, 객체 내부에서 Head, Tail, Foot, Wing을 세부적으로 탐지하는 과정으로 구성되어 있다. 이러한 계층적 탐지 방식은 케이지 배열, 조명 반사, 개체의 회전으로 인해 신체 일부가 가려지는 상황에서도 Head-Tail-Foot 축을 안정적으로 추출할 수 있게 한다. 각 신체 부위를 정확히 탐지하는 과정은 이후 스켈레톤 구축의 기반이 되며, 각 부위가 누락될 경우 행동 탐지 자체가 왜곡될 수 있기 때문에 신뢰도 확보 차원에서 매우 중요하다. 특히 PDF 원문에서 밝힌 바와 같이, Rear Camera 기반 Stretching 분석은 Wing 탐지의 안정성에 크게 의존하기 때문에, 이 탐지 과정은 전체 파이프라인의 정밀도에 핵심적으로 기여한다.

Build Skeleton 단계는 Head, Tail, Foot 좌표를 기반으로 스켈레톤을 구성하고, 상체 기울기 θ_1 과 하체 중심각 θ_2 를 계산하는 단계이다. θ_1 은 Eating과 Drinking 같은 피킹 동작의 발생 여부를 구분하는 핵심 지표이며, θ_2 는 Resting 상태에서의 자세 안정성을 판단하는 기준으로 사용된다. 스켈레톤 기반 각도 정보는 단순한 관절 정보가 아니라 행동 분류 전 과정에서 공통적으로 참조되는 기본 피처로 기능하도록 설계되었다. 다만 각도는 프레임 간 흔들림에 매우 민감하기 때문에, EMA(Exponential Moving Average)를 적용하여 변화량을 안정화하고, 최근 구간을 rolling window 방식으로 누적 평가함으로써 행동별 시계열 패턴을 정량적으로 해석할 수 있게 구성하였다. 그 결과 θ_1 이 위치 변화만으로는 구분하기 어려운 Eating-Drinking과 Drinking-Bathing 간 행동 차이를 효과적으로 반영할 수 있도록 설계되었다.

Segmentation Mask Map 단계는 본 연구의 행동 탐지에서 중요한 역할을 수행한다. 케이지 내부의 Feeder, Water, Perch는 RGB 기반 세그멘테이션 맵으로 생성되며, 각 구조물은 고유한 색상 값을 갖는 마스크 영역으로 정의된다. 이 마스크는 분석 단계에서 반려앵무가 어느 영역에 위치하는지를 자동 탐지하는 데 활용되며, 행동 정의에 공간적 맥락을 부여함으로써 단순 자세 변화로는 구분 불가능한 행동들을 명확하게 분리할 수 있게 한다. 예를 들어 θ_1 감소는 Eating, Drinking 초기 동작에서 동일하게 나타나지만, Foot과 Head가 진입한 영역이 Feeder인지 Water인지에 따라 행동이 완전히 달라지

므로, 마스크 정보는 행동 분류의 1차 필터로 기능하였다. 이러한 공간 기반 판단 구조는 Bathing 행동에서도 동일하게 적용되며, Bathing이 단순한 Water 영역 접근이 아니라 전신 특징이 일정 시간 연속적으로 나타나는 경우로만 정의될 수 있도록 하는 데 기여한다.

Temporal Analysis & Decision 단계는, 본 연구의 행동 탐지가 단일 프레임의 순간적 특징이 아니라 시간 기반 패턴을 종합적으로 평가하는 방식임을 보여준다. Eating과 Drinking은 θ_1 감소량이 임계치를 초과할 때 발생하며, 이 변화가 약 0.3초 이상 유지되어야만 실제 피킹 이벤트로 인정되었다. Resting은 약 10초간 Foot-BC-Head 좌표의 상대적 이동 비율이 일정 수준 이하로 유지될 때에만 안정 구간으로 판정되었다. Bathing은 Water 영역 진입뿐 아니라 YOLO가 Bathing 특징을 연속적으로 탐지하는 시간이 최소 1.5초 이상일 때만 episode로 인정되었다. Stretching은 Rear Camera에서 Wing이 명확히 탐지되는 구간을 중심으로 판정되었다. Pacing은 speed_norm이 일정 임계값을 초과한 상태가 약 3.5초 이상 유지될 때 시작되며, 반대로 일정 시간 이동이 감소할 때 종료되는 형태로 finite-state machine(FSM) 구조에 기반하여 구현되었다. 이러한 시간 기반 구조는 짧은 노이즈 움직임이나 단발성 자세 변화가 행동으로 잘못 분류되는 문제를 원천적으로 차단한다.

본 연구에서는 각 행동의 발생 횟수, 지속 시간, 에피소드 단위의 독립성 등을 모두 정량화한다. Eating, Drinking, Stretching과 같은 이벤트 기반 행동은 발생 횟수가 기록되며, Resting과 Pacing처럼 장기적 상태를 반영하는 행동은 지속 시간이 핵심 지표로 사용되었다. Bathing은 개체 간 방식의 차이가 매우 크기 때문에 지속 시간보다 발생 여부를 중심으로 분석하도록 설계되었다. 이처럼 행동별 특성에 맞춰 서로 다른 정량적 기준을 적용함으로써, 단순 분류를 넘어 행동 구조 전체를 해석하는 분석이 가능하게 되었다.

전체적으로 이 파이프라인은 자세·위치·시간이라는 세 가지 차원을 결합하여 행동의 맥락을 평가하는 방식으로 구성되었다는 점에서 중요한 의의를 갖는다. Front와 Rear의 이중 시야가 공간적 제약을 보완하고, YOLO, 스켈레톤, 세그멘테이션이 각기 다른 수준의 정보를 제공하며, EMA, 슬라이딩 윈도우, FSM 구조가 시간적 일관성을 보정하였다.

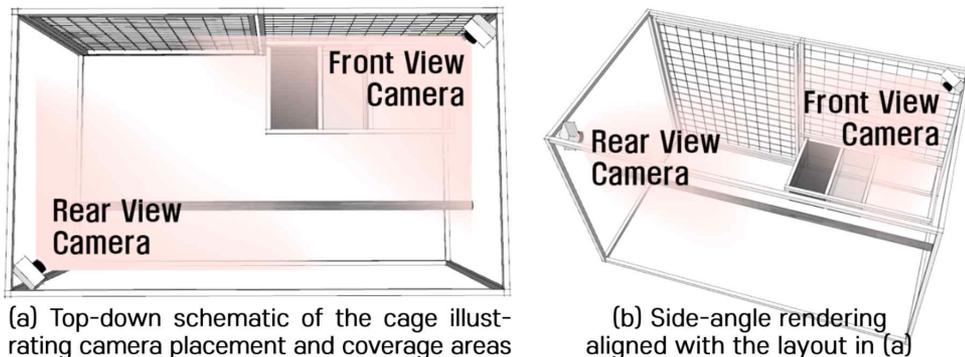
3.4 연구 모델의 실험 환경

3.4.1 반려앵무 행동촬영환경

행동 인식 정확도를 확보하기 위해, 본 연구에서는 2대의 고정식 카메라를 사용하여 새장을 서로 다른 시점에서 동시에 촬영하였다. 두 카메라의 설치 위치는 행동별 특성을 고려하여 배치하였는데, 배치 앵글에 따라서 Front Camera와 Rear Camera 두가지로 정의하였다.

먼저 Front Camera는 새장 전면의 먹이급이부에 상단 구석에 설치하여, 반려앵무 전신이 항상 프레임 내에 안정적으로 포함되도록 구성하였다. 이를 통해 Eating, Drinking, Resting, Bathing 등 자세 변화가 요구되는 행동을 광각 시야에서 일관되게 기록할 수 있었으며, 개체의 위치 변화와 행동 시작 시점, 행동 종료 시점을 명확하게 구분하는 데 중요한 역할을 수행한다. 또한 Front Camera는 좌표 기반 행동 패턴 분석에서 가장 핵심적으로 활용되는 Head, BC(Body Center), Foot 등 주요 부위의 상대적 위치 변화를 장기적으로 추적할 수 있는 기반 데이터를 제공하여, 행동분류 모델 1차 탐지 단계에서 높은 신뢰도로 전 객체를 인식할 수 있도록 한다.

전신 시야가 확보된 Front Camera의 영상은 세그멘테이션 기반 위치 정보와 결합하여 Feeder 영역, Drinking 영역, Perch 영역을 자동으로 구분하는데 활용된다. 특히 Eating, Drinking 행동은 머리 좌표가 특정 위치 영역에



[그림 3-30] Front Camera와 Rear Camera의 장착 위치

진입하는 순간이 행동 판단의 핵심이므로, Front Camera는 이와 같은 공간 기반 행동 패턴 분석에 있어 필수적이다.

또한 조류는 머리와 몸통이 빠르게 움직이기 때문에 전체 객체의 bounding box 안정성이 행동 분류 정확도에 직접적으로 영향을 미친다. Front Camera는 전신을 충분한 거리에서 촬영하기 때문에 bounding box가 프레임 간 안정적으로 유지되어, 행동 전환 시의 위치 이동을 정밀하게 파악할 수 있다.

Front Camera는 프레임 전체를 장기적으로 균일하게 촬영함으로써 조명 변화, 그림자, 케이지 철망에 의한 패턴 노이즈 등 환경적 요인을 포함한 실제 사육 환경의 변화를 그대로 반영한 데이터를 제공한다. 이는 행동 패턴 분석 모델이 실제 반려 환경에서 발생할 수 있는 다양한 물리적 변수를 학습하도록 도와주며, 모델의 일반화 능력을 높이는 중요한 기반이 된다. 결과적으로 Front Camera는 전신 행동의 연속적 관찰과 공간·자세 기반 행동 탐지를 위한 핵심 역할을 수행하며, Rear Camera가 제공하는 근접 후면 시야 정보와 결합될 때 다단계 구조의 안정성과 행동 분류의 정밀도가 크게 강화될 수 있다.

반면 Rear Camera는 헛대 상단부를 정밀하게 관찰하기 위해 새장의 후면 구석에 배치하고, 수평 또는 약간 하향 하도록 조정하여 설치하였다. Rear Camera의 설치 위치는 날개 펼침, 깃털손질, 부리긋기와 같이 반려앵무 상반신 중심으로 이루어지는 미세 행동을 근접 촬영할 수 있도록 최적화된 구도이다. 이러한 미세 행동의 정확한 탐지는 단순히 행동을 구분하는 수준을 넘어, 개체의 건강 상태, 정서적 안정도, 스트레스 수준 등을 평가할 수 있는 핵심 지표이기 때문에 학술적으로 중요한 의미를 갖는다. 특히 프리닝과 부리긋기와 같은 자기관리 행동은 정상적이고 편안한 상태에서 주기적으로 나타나는 긍정적 행동으로 알려져 있으며, 스트레스나 질병, 우울 행동이 증가할 때 가장 먼저 감소하거나 비정상적 패턴을 보이는 것으로 보고된다. 따라서 이러한 미세 행동을 장기적으로 안정적으로 탐지하는 것은 조류의 정서적 복지를 추적하고 건강 악화의 전조를 조기에 파악하기 위한 필수 요소이다.

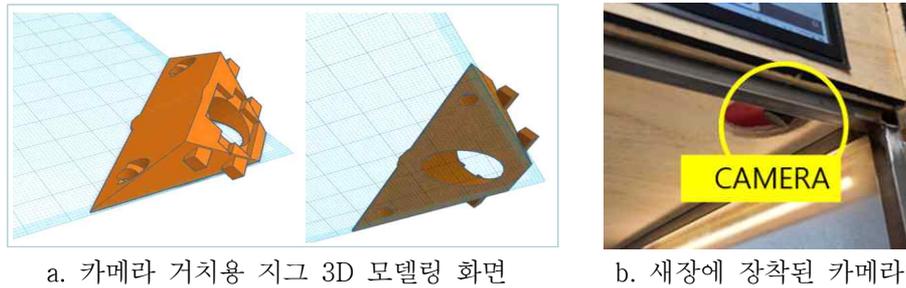
부리긋기는 부리의 각질 상태, 부리 사용 빈도, 스트레스에 의한 과도한

문지름 여부 등을 직접적으로 반영하는 정밀한 지표이므로, 정서적 불안, 영양 결핍, 피부질환 등 이상 징후를 조기에 발견하는 데 활용 가치가 높다. 그러나 이러한 미세 행동은 움직임 범위가 매우 작고 동작 속도가 빠르며 머리, 부리, 날개 부위 간 가림이 빈번하게 발생하는 특성 때문에 전신을 촬영하는 Front Camera만으로는 안정적인 추적이 사실상 불가능하다. 이 문제를 해결하기 위해 설치된 Rear Camera는 근접 시야 확보가 가능한 위치에서 촬영함으로써 머리, 부리, 날개 끝단 등 소형 부위를 고해상도로 인식할 수 있는 영역 제한형 ROI 제공자로 기능하며, 다단계 탐지 구조에서 세부 클래스 탐지 정확도를 결정하는 핵심 요소로 작동한다.

결국 Rear Camera의 근접 배치는 전신 행동 탐지뿐 아니라 정서와 건강 상태를 반영하는 미세 행동까지 연속적이고 정량적으로 분석할 수 있는 기반을 제공하여, 본 연구의 행동 패턴 분석 체계를 보다 정교하고 생체지표 기반의 고도화된 모델로 확장할 수 있는 기술적·학술적 의의를 가진다. 이러한 구조는 향후 프리닝, 부리긋기, 깃털 관리 행동, 미세떨림나 머리털기 등의 경미한 스트레스 신호까지 포착할 수 있는 확장성 높은 행동 패턴 분석 플랫폼 구축으로 이어질 수 있다.

[표 3-4] 실험 시 사용된 카메라의 제원

항목	사양	이미지
센서 모델	HSK_IMX291 (Starlight CMOS)	
센서 크기	1/2.8 inch	
픽셀 크기	1.12 μm \times 1.12 μm	
최저조도	0.001 lux	
해상도	320 \times 240 ~ 1920 \times 1080	
프레임레이트	30fps	
SNR (신호대잡음비)	41 dB	
전원/전류	5V / 80mA	
동작온도	-20 $^{\circ}\text{C}$ ~ 70 $^{\circ}\text{C}$	
렌즈 옵션	130 $^{\circ}$ Degree	
포커스 방식	Fixed focus / Manual focus	
연결 방식	USB2.0 UVC	



[그림 3-31] 카메라 거치용 지그와 카메라 장착 모습

이와 같은 Front-Rear dual-view 구조는 행동 패턴 분석 범위의 확장을 가능하게 할 뿐 아니라, 두 시야에서 수집되는 영상을 시간적으로 정렬하여 행동 발생의 전후 맥락을 보다 세밀하게 파악할 수 있게 한다.

두 카메라 모두 약 130°FOV(Field of View)를 가진 렌즈를 사용하여, 전신 관찰이 필요한 광각 장면과 근거리 정밀 촬영이 필요한 장면을 모두 안정적으로 포착할 수 있었다. 이러한 배치는 행동 전반과 미세 동작을 동시에 다각도로 분석할 수 있는 구조적 기반을 제공한다.

카메라는 UVC(Video Class) 기반으로 Windows·Linux·Raspberry Pi 등 대부분의 OS에서 사용되어 범용성이 높으며 장기간 녹화에서 신뢰성이 높은 모듈을 활용하였다. 카메라 모듈은 PCB 형태 단품이기 때문에, 등을 다층적으로 검증할 수 있어 행동 이상 징후의 조기 탐지가 한층 수월해진다. 더 나아가 이러한 다각도 정보는 향후 3차원 행동 복원이나 다중 카메라 융합 기반의 행동 특성 분석으로의 확장 가능성을 제공하며, 반려앵무의 정서·생체 변화를 정량적으로 추적하는 차세대 행동 패턴 분석 모델의 기반을 형성한다.

본 실험에서는 [그림 3-31]과 같이 전용 지그를 제작하여 새장 구조물에 안정적으로 고정하였다. 지그는 3D 프린터를 활용하여 PETG 재질로 인쇄하여 사용하였다.

3.4.2 연구용 반려앵무 개체 및 실험 시 사육환경

본 연구는 실제 반려 환경과 유사한 조건에서 반려앵무의 자연스러운 행

[표 3-5] 실험에 사용된 반려앵무 개체

개체명 : Parrot1 Pineapple	개체명 : Parrot2 Blue-Cinnamon	개체명 : Parrot3 Yellowside	개체명 : Parrot4 Suncheek
			

동을 확보하기 위해, 코뉴어 계열 반려앵무의 아종인 Pineapple Conure 1개체, Blue-Cinnamon Conure 1개체, Yellowside Conure 1개체, Suncheek Conure 1개체를 대상 개체로 선정하였다. 대상 개체들은 모두 생후 1년이 지난 성조이며, 환경 적응을 위해 실험 전 1개월간 동일한 사육 조건에서 사전 사육을 진행하여 외부 스트레스 요인을 최소화하였다. 모든 실험은 실내 사육실 25 ± 2 °C, 350-400 lux 환경에서 수행되었고, 물과 사료는 매일 11시 30분에 동일하게 교체하여 개체 간 급이·급수 조건의 변수를 제거하였다. 실험 데이터는 개체 간 행동 특성이 가장 뚜렷하게 드러나는 오전 8시 30분부터 오후 7시까지 총 11시간 30분간 촬영하였으며, 영상 분석에 사용된 행동은 모두 개체의 자발적 행동만을 대상으로 하였다. 연구 과정에서 연구자는 어떠한 외부 자극도 가하지 않았으며, 각 개체는 동일 조건에서 실험이 진행되어 행동 차이가 개체 특성에 의한 것으로 드러날 수 있도록 통제하였다.

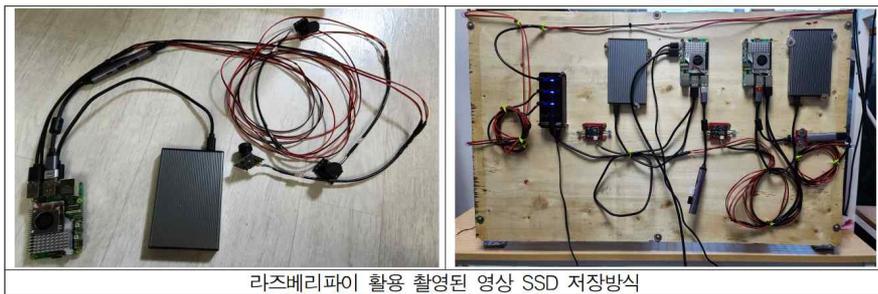
[표 3-6] 실험 시 반려앵무의 공통 사육환경

구분	내용
온·습도	25 ± 2 °C, 상대습도 45-55%
광주기	12L:12D(실내 LED 조명), Flicker-Free 조명 유지
사료 및 급수	동일한 알곡 사료(귀리·황기장·해바라기씨 혼합), 신선한 음용수 상시 제공
환경 풍부화 요소	헛대 1개, 장난감 1종
일일 활동시간	오전·오후 각 1시간의 실내 방사 시간 제공

3.4.3 데이터 수집 환경 설정

본 연구에서는 촬영된 영상을 안정적으로 저장하고, 대량의 데이터를 효율적으로 처리하기 위하여 카메라 입력부터 클라우드 저장, 이후 GPU 기반 모델 학습 및 추론에 이르기까지 전체 환경을 체계적으로 구성하였다. 먼저 Front Camera와 Rear Camera에서 입력된 영상 스트림은 RaspberryPi 5에 연결된 고속 SSD에 실시간으로 기록되도록 설정하였다. 라즈베리파이는 카메라로부터 들어오는 영상을 H.264 방식으로 인코딩하여 저장 공간을 효율적으로 관리하였으며, 저장된 데이터는 일정 용량 단위로 자동 분할되어 파일 손실 없이 장기간 수집할 수 있도록 구성하였다.

라즈베리파이에 연결된 SSD는 일일 촬영 데이터가 누적됨에 따라 자동 백업 스크립트에 의해 클라우드 저장소(Google Drive)로 업로드되도록 설정하였다. 업로드는 새벽 시간대에 배치 방식으로 수행되며, 네트워크 불안정 상황에서도 중단된 지점부터 재개할 수 있도록 rsync 기반 동기화 방식을 적용하였다. 이러한 구조는 대규모 영상 데이터를 장기간 안정적으로 수집하기 위한 필수 요소로, 실제 실험 기간 동안 데이터 손실 발생을 최소화 하였다.

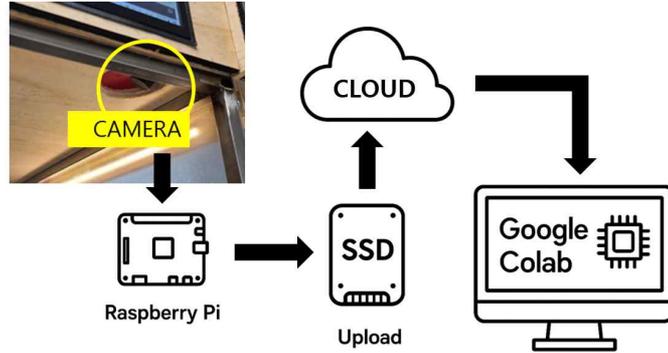


라즈베리파이 활용 촬영된 영상 SSD 저장방식



임베디드pc(윈도우운영체제) 활용 촬영된 영상 SSD 저장방식

[그림 3-32] 데이터 수집 환경 및 방식



[그림 3-33] 데이터 수집 및 처리환경 구조도

클라우드에 업로드된 데이터는 Google Colab의 GPU 연산 환경에서 처리되었다. Colab의 런타임은 UltraRAM 기반의 고사양 인스턴스를 사용하여, 대규모 영상 프레임 로딩과 데이터 전처리에 필요한 메모리 요건을 충족하였다. 영상 프레임 추출, 라벨링 데이터 확인, YOLO 기반 다단계 모델 학습 및 추론, 그리고 스켈레톤 생성 및 각도 계산 등의 모든 프로세스는 Colab 환경에서 수행되었으며, Python 기반으로 구축한 일련의 자동화 스크립트에 의해 처리되었다. 또한 Colab 환경과 Google Drive 저장소는 자동으로 마운트되어 학습된 가중치 파일과 분석 결과가 즉시 저장·백업되도록 구성하였다.

이와 같은 환경 구성은 실험 데이터의 수집, 저장, 백업, 분석에 이르기까지 전체 파이프라인을 일관되게 유지하면서도, 실제 반려 환경에서 장기간 촬영되는 대용량 영상 데이터를 안정적으로 처리할 수 있는 기반을 제공하였다. 특히 라즈베리파이 기반 엣지 디바이스에서 촬영·저장을 맡고, GPU 클라우드 환경에서 후처리를 담당하는 구조는 향후 실시간 행동 패턴 분석 시스템으로 확장하기 위한 기술적 토대를 마련한다는 점에서 의미가 크다.

3.4.4 데이터셋 구성

3.4.4.1 라벨링 기준 및 세부 클래스 구성

본 연구의 데이터셋 구축을 위해 수행된 라벨링 작업은 LabelImg 도구를

사용하여 YOLO 형식의 바운딩 박스로 생성하였다. 라벨링 클래스는 Parrot, Head, Tail, Foot, Wing의 다섯 가지로 정의하였다. Parrot은 반려앵무 전체 객체에 해당하며, Head는 눈과 부리가 포함되는 상단부, Tail은 후방 깃털 중심 위치, Foot은 발과 발가락 영역, Wing은 날개 깃털이 명확히 드러나는 구간을 기준으로 설정하였다.

Front Camera와 Rear Camera를 통해 수집된 프레임에 대해 모든 객체가 명확히 인식되는 경우에만 라벨링을 수행하였다. 특히 Head와 Foot처럼 크기가 매우 작은 부위는 조명 변화, 철망 패턴, 가림 현상에 의해 탐지 안정성이 저하될 수 있으므로, 형태가 분명하게 구분되는 프레임을 중심으로 선별하여 라벨링하였다. Wing 클래스는 Stretching 행동 패턴 분석에서만 사용되며, Rear Camera의 고해상도 근접 촬영을 기반으로 명확한 윤곽을 가진 프레임에 한해 라벨링하였다.

행동 자체에 대한 라벨은 이미지에 직접 포함하지 않았다. 대신 라벨링된 객체 좌표를 기반으로 산출되는 위치 세그멘테이션 정보, 스켈레톤 각도 정보, Wing 탐지 여부를 결합하여 행동별 규칙 기반 분류 체계를 구성하였다. 이를 통해 행동 라벨의 일관성을 유지함과 동시에 프레임 단위의 판단 기준을 명확하게 정의할 수 있었다.

3.4.4.2 행동 유형별 데이터셋 구성

Eating 데이터셋은 Cam1에서 상체 기울기 θ_1 의 명확한 감소와 먹이통 진입이 동시에 확인되는 프레임을 기준으로 구축하였고, 가림이 없는 이미지를 선별하여 train 92장, val 27장, test 17장(총 136장)으로 구성하였다. 이어지는 Drinking 데이터셋은 부리가 물 표면을 향해 반복적으로 내려가는 짧은 기울기 변화 패턴을 기준으로 선별하여 train 92장, val 27장, test 17장(총 136장) 규모로 확보하였다.

Bathing 데이터셋은 Water 영역에서 Wing 움직임과 침수 패턴이 함께 나타나는 구간을 중심으로 라벨링하여 train 92장, val 27장, test 17장, 총 136장으로 구성하였으며, Resting 데이터셋은 헛대에서 바운딩박스 중심 이동을

이 매우 낮고 $\theta_1 \cdot \theta_2$ 가 안정 구간에 위치하는 장면을 기준으로 동일하게 train 92장, val 27장, test 17장, 총 136장을 확보하였다.

Rear Camera 기반의 Stretching 데이터셋은 Wing이 완전히 펼쳐진 순간을 중심으로 윤곽이 가장 명확한 프레임을 선별하여 train 45장, val 14장, test 9장, 총 68장으로 구축하였다. 마지막으로 Pacing 데이터셋은 Front Camera에서 바운딩박스 중심점이 좌우·상하로 반복 이동하며 일정 시간 이상 지속되는 장면을 기반으로 선별하여 train 48장, val 15장, test 10장, 총 73장 규모로 구성하였다.

이와 같이 여섯 가지 주요 행동 유형에 대해 독립적인 데이터셋을 확보한 뒤, 모델 학습은 Google Colab 환경의 NVIDIA A100 GPU에서 수행하였다. YOLO 기반 탐지 모델은 총 200 epoch 동안 학습을 반복하였고, 입력 이미지 해상도는 720×720 , batch size는 32로 고정하여 모든 행동 유형이 균일한 조건에서 학습될 수 있도록 하였다.

3.5 행동 패턴 분석 타당성 검증 방법의 설정

3.5.1 AI Detection 모델 기반 행동 패턴 분석 정확성 검증방법 설정

본 연구에서는 인간 관찰 기반 VI(Visual Inspection) 자료와 AI 분석 결과를 비교함으로써 행동 분류 모델의 타당성을 검증하였다. VI 분석은 Eating, Drinking, Resting, Bathing, Stretching의 다섯 가지 행동에 대하여 수행되었으며, 각 행동의 발생 여부, 발생 횟수, 행동 시작·종료 시점을 초 단위로 기록하여 AI 분석의 정확성을 판단하기 위한 기준 자료로 구축하였다. 이러한 VI-AI 비교는 장시간 영상을 분석하는 과정에서 발생할 수 있는 관찰자 간 편차와 피로도에 따른 정확도 저하와 같은 인간 관찰 방식의 한계를 AI 분석이 어느 정도 보완할 수 있는지를 확인하기 위해 수행되었다.

Pacing 행동은 VI로 판단하기 어려운 구조적 특성을 가진 행동이기 때문에 비교 대상에서 제외하였다. 일반적인 먹이 또는 물 섭취를 위한 이동은 평균적으로 3초 이내에 종료되는 목적 행동이며, 반면 스트레스 상황에서 나타나는 Pacing은 목적 없이 반복적으로 지속되는 이동이라는 것이 조류 행동학 전문가의 판단이다. 전문가 의견에 따르면, 이러한 목적 없는 반복 이동은 영상 관찰만으로는 일시적 이동과 명확하게 구분하기 어려운 경우가 많기 때문에 VI 방식으로 Pacing을 신뢰성 있게 구분할 수 없다. 이러한 판단을 바탕으로 본 연구에서는 Pacing을 VI 비교에서 제외하고, AI 기반 연속 이동 분석을 통해 독립적으로 평가하였다.

비교 방식은 행동의 구조적 특성에 따라 차별적으로 설계하였다. Eating, Drinking, Bathing, Stretching과 같은 순간 행동은 발생 횟수의 일치도를 중심으로 VI 자료와 AI 분석 결과를 비교하였다. 반면 Resting은 상대적으로 긴 시간 동안 지속되는 안정 행동이므로 행동의 총 지속 시간을 중심으로 VI와 AI 분석의 정합성을 평가하였다. Bathing과 Stretching은 하루 단위에서는 발생 빈도가 충분하지 않을 수 있기 때문에 전문가의 검토를 반영하여 최소 3일 이상의 분석 기간을 설정하였으며, 이를 통해 행동 간 양적 차이를 신뢰성 있게 비교할 수 있도록 하였다.

[표 3-7] 각 행동별 AI 분석 결과와 VI 결과 비교 기준

Behavior Metric	분석방식	기간
Eating Count	발생횟수를 중심으로 AI 분석 결과와 VI 결과를 비교	1days
Drinking Count	발생횟수를 중심으로 AI 분석 결과와 VI 결과를 비교	1days
Bathing Count	발생횟수를 중심으로 AI 분석 결과와 VI 결과를 비교	3days
Stretching Count	발생횟수를 중심으로 AI 분석 결과와 VI 결과를 비교	3days
Resting Time(min)	총 발생시간을 중심으로 AI 분석 결과와 VI 결과를 비교	3days

이러한 VI-AI Detection Comparison은 AI 분석이 관찰자의 판단을 대체하거나 보조할 수 있을 정도의 정확성을 확보하고 있는지를 검증하는 데 중요한 절차이며, 장시간 기록을 자동 처리할 수 있는 AI 시스템이 현장에서 활용될 수 있는 가능성을 평가하는 근거를 제공한다.

3.5.2 AI 기반 행동 분류 모델의 정량적 성능 평가기준 설정

AI 기반 행동 분류 모델의 신뢰성을 정량적으로 평가하기 위해 Precision, Recall, mAP@0.5의 세 가지 지표와 함께 Confusion Matrix를 활용하였다. Precision은 AI가 탐지한 행동 중 실제 정탐된 행동의 비율로, 잘못된 탐지를 얼마나 효과적으로 억제하는지를 평가한다. Recall은 실제 발생한 행동을 AI가 놓치지 않고 탐지했는지를 나타내는 지표로, 행동 누락 여부를 판단하는데 중요하게 사용된다. mAP@0.5는 Parrot, Head, Tail, Foot, Bath와 같은 핵심 신체 부위를 다양한 조건에서 정확하게 탐지하는 능력을 평가하는 지표로, 안정적인 행동 분류 모델 구축을 위한 기반 신뢰도를 나타낸다.

또한 행동 분류 모델의 오인식 및 누락 패턴을 직관적으로 확인하기 위해 정규화 혼동행렬(Confusion Matrix Normalized)을 분석하였다. Confusion Matrix는 실제 클래스(True)와 예측 클래스(Predicted)의 분포를 시각적으로 제시하여, 클래스별 탐지 정확도를 한눈에 파악할 수 있다. Eating과 Drinking처럼 짧고 순간적으로 이루어지는 행동은 Head와 Foot의 위치 편차

[표 3-8] 본 연구 모델 성능 평가 지표별 의미

지표명	지표 의미	평가 단위
Precision (정확도)	모델이 탐지한 행동 중 실제 정탐된 비율. 오탐(잘못된 탐지)을 얼마나 억제했는지 평가	행동별
Recall (재현율)	실제 발생한 행동을 AI가 놓치지 않고 탐지한 비율. 행동 누락 여부를 평가	행동별
mAP@0.5	IoU 0.5 이상 기준 평균 정밀도. Parrot·Head·Tail·Foot·Bath 등 객체 탐지 정확성을 평가	전체 모델
Confusion Matrix (혼동행렬)	실제 행동과 예측 행동 간의 일치/오류 패턴을 시각적으로 보여주는 지표. 클래스별 오탐·누락 분석에 활용	행동별
VI-AI Detection Comparison	VI 관찰 결과와 AI 탐지 결과 간의 일치도 평가. 순간 행동은 발생 횟수, 지속 행동은 총 시간으로 비교	횟수/시간

가 작아 오탐 가능성이 존재하므로 Precision과 Recall의 균형이 중요하다. Bathing과 Resting은 수면 반사나 가려짐 등으로 인해 누락이 발생할 수 있어 Recall이 더욱 중요한 지표가 된다. Stretching은 발생 빈도가 낮고 프레임 단위의 변동성이 높아, 일정 기간 이상 누적된 자료를 기반으로 검증해야 하며 이는 전문가 의견을 반영한 3일 단위 분석 기준과도 일치한다. 이러한 정량적·정성적 평가는 이후 단계에서 수행하는 안정 행동과 Pacing의 상대 비교 분석에서도 AI가 신뢰성 있는 행동 데이터를 제공할 수 있음을 보증하는 역할을 한다.

3.5.3 Resting·Bathing·Stretching과 Pacing의 상대 비율 분석방법 설정

반려앵무는 케이지 환경에서 심리적으로 안정적일 때 대부분 헛대에 머무르며 Resting이나 Stretching과 같은 행동을 수행하고, 필요할 때만 먹이 섭취나 음수, 목욕을 위해 짧은 이동을 보인다. 이러한 상태에서는 목적 없는 이동이 거의 나타나지 않으며, 전체 행동 시간의 상당 부분이 정적 상태 또는 자가 관리 중심의 패턴으로 구성된다.

반면 스트레스 수준이 증가하면 특정 목적 없이 산발적이거나 반복적으로

[표 3-9] 정상 개체와 스트레스 개체 간 Pacing 관련 지표 비교

지표	비교 의미
Resting 총 시간	Resting 시간이 길수록 심리적 안정 상태를 의미하며, Pacing 수준이 낮은 개체에서 더 높게 나타남
Bathing 발생 횟수	Bathing은 안정적이고 긍정적 정서 상태에서 주로 발생하므로, Pacing이 적은 개체에서 더 많이 관측됨
Stretching 발생 횟수	Stretching은 신체적·심리적 여유가 있을 때 나타나는 행동으로, 스트레스가 낮을수록 발생 빈도가 높음
이동 횟수/머문 시간 비율	Stretching은 신체적·심리적 여유가 있을 때 나타나는 행동으로, 스트레스가 낮을수록 발생 빈도가 높음
안정 행동 전체 비율	전체 행동 중 Resting·Bathing·Stretching이 차지하는 비율이 높을수록 안정 상태, 낮을수록 스트레스 상태를 의미함

이동하는 Pacing이 뚜렷하게 증가하며, 이는 Resting, Bathing, Stretching과 같은 안정 행동의 감소와 함께 전반적으로 분주하고 산만한 이동 패턴이 나타나는 것이 특징이다. 이러한 행동 특성을 고려하여, 본 연구에서는 동물 행동학 전문가의 자문을 반영해 Pacing을 3초 이상 지속되는 연속 이동으로 운영적으로 정의하였다.

일반적인 먹이·물 섭취 목적의 이동은 대부분 3초 이내에 종료되므로, 이 기준은 목적 이동과 스트레스 유발 이동을 구분하는 데 적합하다고 판단하였다. 이에 따라 AI는 전체 관찰 영상에서 3초 이상 지속되는 이동의 빈도와 누적 시간을 산출하도록 설계하였으며, 이러한 정량 지표를 Resting, Bathing, Stretching과 같은 심리적 안정시 행동의 발생 비율과 비교하는 분석 절차를 구성하였다. 안정 행동의 비중과 Pacing 지표 간의 상관성을 확인하기 위해, 단위 시간당 이동 횟수, 머문 시간, 3초 이상 이동 구간의 총량 등을 주요 비교 항목으로 포함하였다. 또한 동물 행동학 전문가가 사전에 정상 개체와 스트레스 개체로 분류한 두 집단 간 행동 패턴을 AI 분석 결과와 대조하여, 본 연구에서 정의한 Pacing 기준이 전문가의 행동학적 판단과 어떤 관계를 갖는지 검증할 수 있도록 분석 구조를 마련하였다.

이와 같은 연구 설계를 통해 AI 분석이 반려앵무의 심리적 스트레스 여부를 자동으로 판단할 수 있는지 평가하고, 케이지 환경에서 실시간 스트레스 모니터링 시스템으로의 확장 가능성을 검토할 수 있도록 실험을 구성하였다.

IV. 실험 결과 및 분석

4.1 AI Detection 모델 기반 행동 패턴 분석 정확성 검증 결과

본 연구에서는 AI 기반 반려앵무 행동 인식 모델이 실제 행동 관찰과 어느 정도의 일치도를 보이는지를 검증하기 위해 VI(Visual Inspection)와 AI Detection 결과를 정량적으로 비교하여 [표 4-1]에 나타내었다.

[표 4-1] VI-AI Detection Comparison 결과

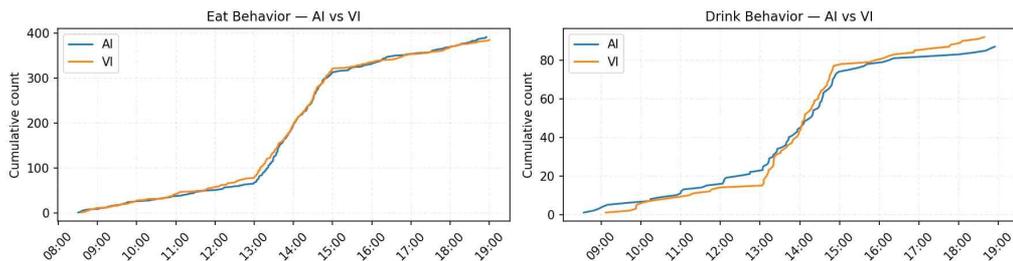
Behavior Metric		Eating Count	Drinking Count	Resting Time(min)	Stretching Count	Bathing Count
day		1	1	3	3	3
Parrot1	AI	391	87	723	24	4
	VI	385	92	716	23	4
	Relative Error(%)	391/385 (+1.5%)	87/92 (-5.4%)	723/716 (+1.0%)	23/24 (-4.2%)	4/4 (0%)
Parrot2	AI	325	105	207	46	2
	VI	332	99	215	44	2
	Relative Error(%)	325/332 (-2.1%)	105/99 (+6.1%)	207/215 (-3.7%)	44/46 (+4.6%)	2/2 (0%)
Parrot3	AI	362	69	156	7	0
	VI	368	72	164	7	0
	Relative Error(%)	362/368 (-1.8%)	69/72 (-4.2%)	156/164 (-4.9%)	7/7 (0%)	0/0 (0%)
Parrot4	AI	388	76	84	0	0
	VI	380	70	79	0	0
	Relative Error(%)	388/380 (+2.1%)	76/70 (+8.6%)	84/79 (+6.3%)	0/0 (0%)	0/0 (0%)

이 비교 실험의 목적은 개발된 모델이 행동학적 분석의 대체 도구로 활용될 수 있을 만큼의 신뢰성과 정확도를 확보하고 있는지를 확인하는 데 있으며, 이후 스트레스 행동 패턴 분석 및 실시간 모니터링 시스템으로의 확장 가능성을 평가하기 위한 핵심적인 기초 검증 단계이다.

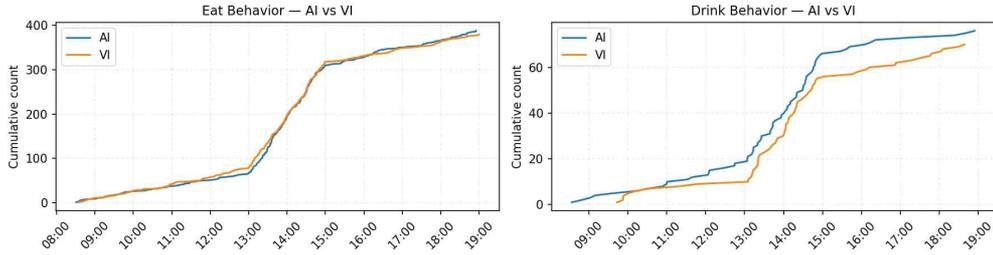
VI는 동물행동학 전문가에게 행동학적 훈련을 받은 관찰자와 동물행동학 전문가가 함께 동일한 원본 영상을 공동 분석하여 구축되었다. 이 과정을 통해 행동의 발생 횟수와 지속 시간, 시작 및 종료 지점을 면밀하게 기록함으로써 비교 기준으로 사용할 Ground Truth를 마련하였다. 반면 AI Detection은 영상 내 Parrot, Head, BC, Foot 등의 탐지 결과와 먹이통·물통 위치에 대한 세그멘테이션 마스크, 바운딩박스 중심 이동량, 움직임 비율, 시간 패턴을 결합하여 각 행동을 자동 분류하였다. 이후 두 방식의 결과를 항목별로 대응시키고 상대오차 Relative Error를 산출하여 VI 대비 AI 모델의 정확도를 평가하였다.

Eating과 Drinking과 같이 공간적 진입 여부가 비교적 명확한 행동에서는 개체별로 대체로 $\pm 1\sim 8\%$ 범위의 오차가 관찰되었다. 이러한 차이는 주로 먹이통 또는 물통 주변에서 짧은 시간 동안 반복적으로 머무르는 움직임이나 순간적인 Head 각도 변화에 따라 VI와 AI가 행동의 시작 또는 종료 지점을 약간 다르게 판단한 데서 기인한다. 그럼에도 불구하고 해당 오차 범위는 행동 패턴 분석 분야에서 충분히 허용 가능한 수준으로, AI가 사람 관찰자의 판단과 거의 동일한 기준으로 행동을 인식하고 있음을 확인할 수 있다.

Parrot1의 Eating과 Drinking 결과를 보면, [그림 4-1]에서 확인되듯 Eating은 +1.5%의 Relative Error를 보여 AI와 VI의 누적 패턴이 거의 동일



[그림 4-1] Parrot1에 대한 Eat, Drink VI-AI Detection 결과 그래프



[그림 4-2] Parrot4에 대한 Eat, Drink VI-AI Detection 결과 그래프

하게 나타났다. Drinking 또한 -5.4%의 오차가 관찰되었으나, 그래프의 기울기와 변화 추이를 비교하면 두 방식 간 편차가 크지 않아 전체적인 탐지 경향은 매우 유사한 것으로 판단된다.

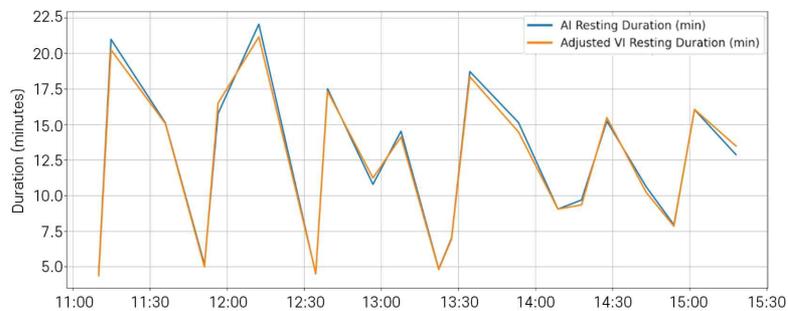
반면, 가장 큰 차이를 보인 개체는 Parrot4로, [그림 4-2]에서 Drinking 행동의 Relative Error가 +8.6%로 나타났다. 그럼에도 불구하고 그래프의 선형적 변화 흐름은 AI와 VI가 거의 동일한 형태를 유지하였으며, 전체적인 행동 발생 패턴 역시 안정적으로 일치하여 분석 가능한 수준의 신뢰도를 확보한 것으로 볼 수 있다.

[표 4-2] Resting, Stretching, Bathing 의 일자별 세부결과표

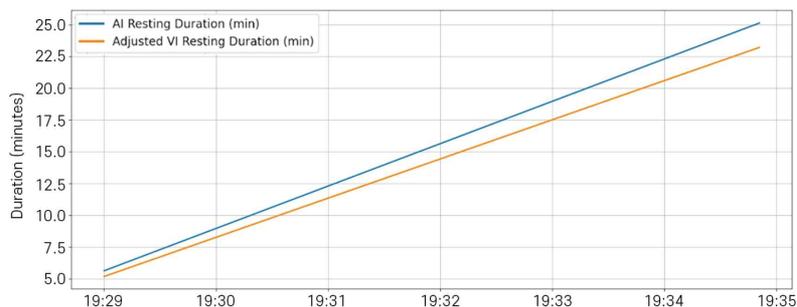
Behavior Metric	Resting Time(min)			Stretching Count			Bathing Count			
	1	2	3	1	2	3	1	2	3	
day										
Parrot1	AI	244	233	246	7	8	9	1	2	1
	VI	241	231	244	7	7	9	1	2	1
	total	AI(723) / VI(716)			AI(23) / VI(24)			4		
Parrot2	AI	67	71	69	14	15	17	0	1	1
	VI	70	74	71	13	14	17	0	1	1
	total	AI(207) / VI(215)			AI(46) / VI(44)			2		
Parrot3	AI	52	50	54	2	2	3	0	0	0
	VI	55	52	57	2	2	3	0	0	0
	total	AI(156) / VI(164)			7			0		
Parrot4	AI	27	26	31	0	0	0	0	0	0
	VI	25	24	30	0	0	0	0	0	0
	total	AI(84) / VI(79)			0			0		

Resting은 발생 횟수가 아니라 행동이 지속된 시간의 누적값을 기준으로 탐지하는 행동군이기 때문에, 일별 편차를 보다 안정적으로 평가하기 위해 3일간의 데이터를 수집하였다. 이러한 시간 기반 행동은 하루 동안의 활동량이나 컨디션에 따라 변동폭이 커질 수 있어, 단일 일자만으로는 실제 패턴을 충분히 설명하기 어렵다. 따라서 3일 동안 측정된 누적 Resting Time 총합을 비교함으로써, 행동 패턴 해석의 신뢰도를 높이고자 하였다.

Resting Time의 경우에는 전 개체에서 $\pm 1\sim 6\%$ 범위의 매우 낮은 오차만이 나타났다. Resting은 일정 시간 동안 신체 전체의 움직임이 거의 일어나지 않는 구간을 의미하는데, 본 연구에서 설정한 정적 판단 기준은 객체의 이동량을 절대 픽셀 값으로 판단하지 않고 객체의 실제 크기 대비 이동 비율이 매우 낮은 상태가 일정 시간 이상 유지되는 경우를 Resting으로 간주하는 방식이다. 이러한 상대적 기준은 촬영 거리나 각도에 따른 픽셀 크기 차이를 보정하여 VI의 판단과 높은 일치도를 확보하는 데 효과적이었다.



[그림 4-3] 차이가 가장 낮았던 Parrot1 3일차의 Resting 발생시간 그래프

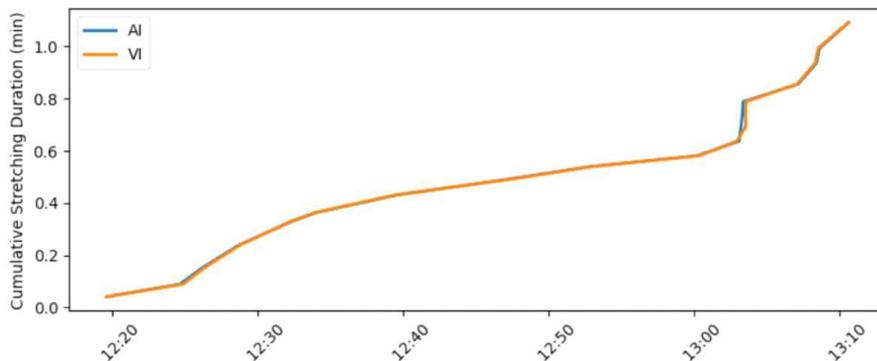


[그림 4-4] 차이가 가장 높았던 Parrot4 2일차의 Resting 발생시간 그래프

Parrot4의 2일차 Resting 발생시간은 하루 기준 상대오차가 약 8%대로 다른 개체보다 큰 편에 속하는 것으로 [그림 4-4]에서 확인된다. 그러나 그래프에서 나타나는 시간적 증가 패턴은 AI와 VI가 동일한 방향성을 유지하며, 구간별 기울기와 단계적 상승 구조가 거의 일치한다. 이는 절대적인 수치 차이는 존재하더라도, 행동의 흐름과 변화 양상은 올바르게 전달되었음을 의미하며, 실험 데이터의 신뢰성에는 큰 문제가 없음을 시사한다.

반면, Parrot1의 3일차 Resting 발생시간은 [그림 4-3]에서 알 수 있듯 상대오차가 +1.0%로 가장 낮아 두 방식의 선형 패턴이 거의 겹쳐 나타난다. 시간별 증감 구조 역시 완전히 유사하게 나타나기 때문에, 가장 오차가 낮은 경우는 물론, 가장 높은 오차가 발생한 경우에도 그래프를 통한 행동 패턴의 해석과 전달에는 충분한 정확성이 확보된다는 점을 확인할 수 있다. 두 그래프 모두 올바른 정보를 전달할 수 있다.

Stretching 행동은 다른 행동에 비해 발생 빈도가 낮고 지속 시간이 짧아 상대적으로 탐지 난이도가 높지만, 모든 개체에서 $\pm 5\sim 7\%$ 내외의 안정적인 오차 범위를 나타냈다. 행동 구간이 짧음에도 불구하고 AI가 VI와 거의 동일한 패턴을 재현한 것은 동작 기반 조건과 시간 기반 조건이 균형 있게 작동했음을 보여준다. Bathing은 모든 개체에서 오차가 0%로 나타났으며, 이는 Bathing이 물통 세그멘테이션 마스크 내부에 Head와 BC가 명확하게 진입하고 일정 시간 동안 체류하는 구조적 특성 때문에 행동 경계가 AI에 의해 명확히 포착되었기 때문이다.



[그림 4-5] Parrot2 3일차 Stretching 누적시간의 AI-VI 비교 그래프

Parrot2의 3일차 Stretching 행동에서 AI와 VI의 탐지 결과는 모든 에피소드의 발생 횟수가 정확하게 일치하여 계산된 Relative Error가 0%로 나타났다. 그러나 시간 정보는 프레임 처리 방식과 기록 시점의 미세한 차이로 인해 수초 단위의 오차가 발생할 수 있으며, 이러한 변동은 누적 시간 그래프에서 두 선이 완전히 겹치지 않고 부분적으로 어긋나 보이게 만든다.

이는 행동의 발생 여부와 지속시간의 총합이 동일하더라도 시간 스탬프의 정렬까지 완전히 일치시키는 것은 현실적으로 어렵다는 점을 보여준다. 따라서 본 연구에서는 Stretching의 탐지 정확성을 해석할 때 시간 기반 지표보다는 상대적으로 신뢰도가 높은 행동 발생 횟수를 중심 지표로 활용하였다. 실제로 그림 4-5에서도 두 선은 거의 동일한 증가 패턴을 보이지만, 특정 구간에서는 미세한 시차로 인해 선형이 약간 어긋나는 모습이 확인된다.

종합하면 본 연구의 AI 행동 인식 모델은 Eating, Drinking, Resting, Stretching, Bathing 등 주요 행동군 전반에서 VI 대비 $\pm 7\%$ 이내의 낮은 오차 범위를 유지하고 있으며, 이는 본 모델이 행동학적 분석에 활용할 수 있을 만큼 충분한 정확도와 신뢰성을 갖추었음을 시사한다. 특히 Resting과 Bathing처럼 행동 지속시간이 길고 구조적 특징이 명확한 행동은 AI가 VI의 판단을 거의 완벽하게 재현하였다. 또한 짧고 단발적인 Stretching에서도 안정적인 일치도를 보임으로써 행동 구간의 길이와 빈도에 관계없이 시간 기반 행동 분류 기준이 효과적으로 작동하고 있음을 확인하였다.

4.2 Resting·Bathing·Stretching과 Pacing의 상대 비율 분석 결과

반려앵무의 일상 행동은 크게 심리적 안정 상태에서 주로 나타나는 안정 행동군(Resting, Bathing, Stretching) 과 스트레스 상태에서 증가하는 비정상 이동 행동(Pacing) 으로 구분된다. 이 두 행동군은 발생 맥락과 생리적 의미가 뚜렷하게 대비되기 때문에, Pacing의 증가 여부를 스트레스 지표로 활용하기 위해서는 안정 행동군과의 상대적 비교가 필수적이다.

Pacing 행동은 동물행동학 전문가의 자문을 바탕으로 3초 이상 지속되는 연속 이동인 것으로 운영적으로 정의하였다. 그러나 3초 이상 이동했다고 해서 모든 이동을 Pacing으로 간주할 수 있는 것은 아니다. 정상적인 일상 행동인 먹이 섭취, 음수, 목욕과 같은 명확한 목적을 가진 이동도 일시적으로 3초 이상 지속될 수 있다.

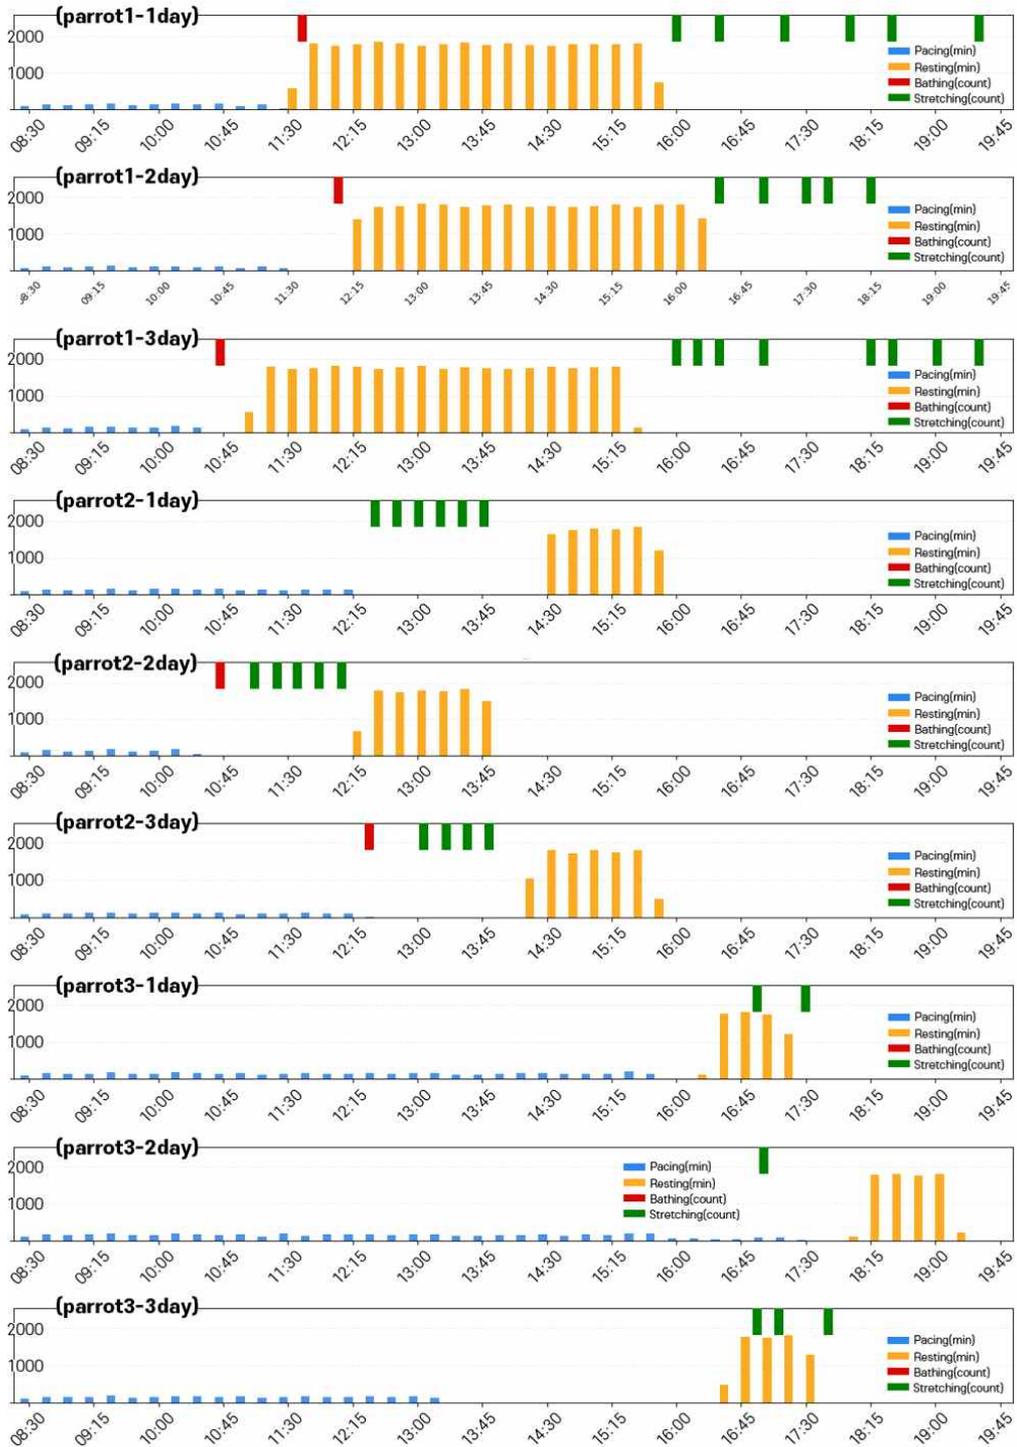
따라서 본 연구에서는 단일 이동의 지속시간이 아니라 일일 관찰 구간 전체에서 나타나는 3초 이상 연속 이동의 총량을 중심 지표로 활용하였다. 이는 Pacing이 나타나는 개체가 하루 동안 특정 목적이 없고 산발적이거나 반복적인 이동에 상당한 시간을 소모한다는 전문가의 소견으로 관측한 행동학적 특징을 반영한 것이다.

타임라인 그래프인 [그림 4-6]과 [그림 4-7]은 안정 행동군인 Resting, Bathing, Stretching과 Pacing 행동을 두 가지 차원에서 동시에 해석할 수 있도록 구성하였다. [그림 4-6]의 그래프 상단에서 내려오는 붉은색과 초록색

[표 4-3] Resting·Bathing·Stretching과 Pacing의 상대 비율 분석 결과

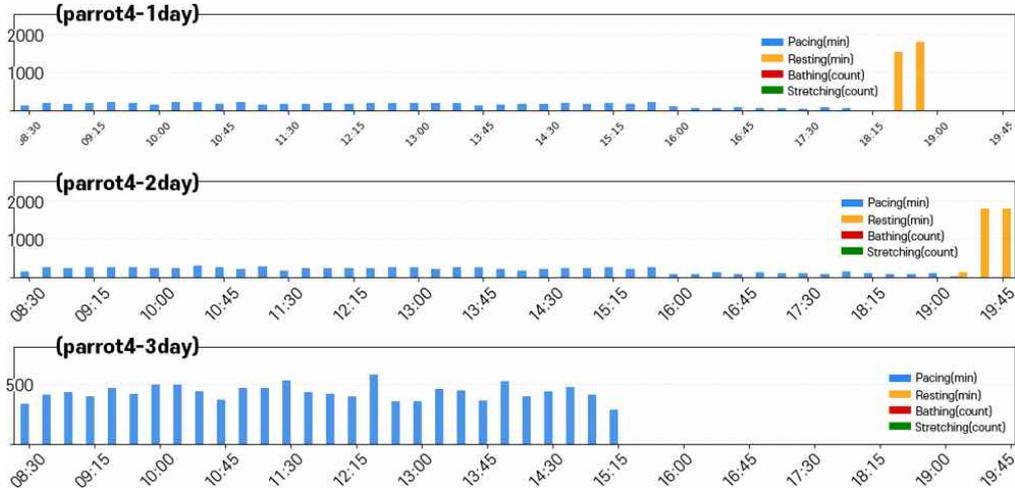
Behavior Metric	Pacing Time(min)	Resting Time(min)	Stretching Count	Bathing Count
day	3	3	3	3
Parrot1	67	723	24	4
Parrot2	82	207	46	2
Parrot3	216	156	7	0
Parrot4	517	84	0	0

Relative Ratio Analysis of Resting, Bathing, Stretching, and Pacing (Parrot 1, 2, and 3)



[그림 4-6] Resting·Bathing·Stretching, Pacing의 상대 비율 분석 (parrot 1,2,3)

Relative Ratio Analysis of Resting, Bathing, Stretching, and Pacing (Parrot 4)



[그림 4-7] Resting·Bathing·Stretching, Pacing의 상대 비율 분석 (parrot 4)

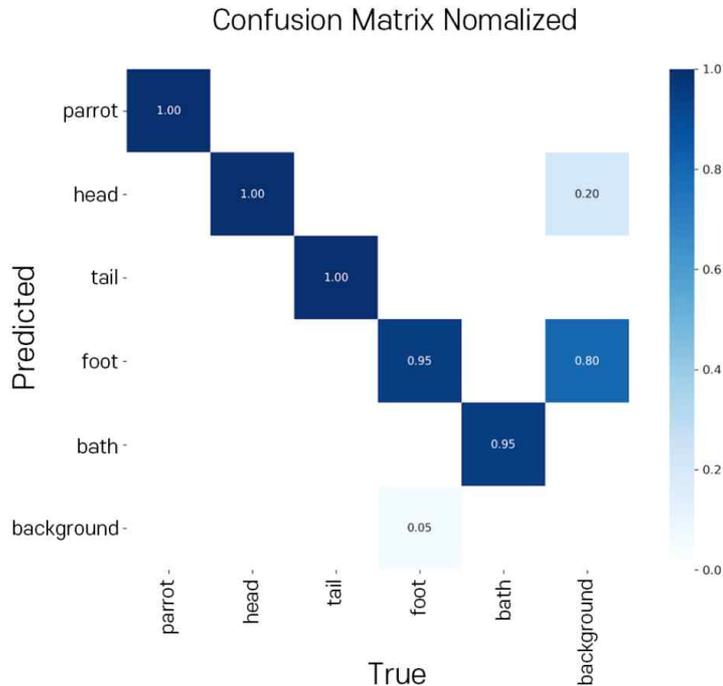
막대는 각 행동이 발생한 순간을 단일 이벤트 단위로 나타낸 것을 표기한 것이며, 해당 시점에서 행동이 시작되었음을 의미한다. 이러한 표기 방식은 행동의 발생 횟수와 시간적 분포를 직관적으로 파악하도록 돕기 위한 것이다.

반면 그래프 하단의 막대는 시간 축에 따라 누적되는 행동의 지속시간을 정량적으로 표현한 것이다. Resting과 Pacing처럼 지속성이 있는 행동의 경우, 해당 구간에서 행동이 얼마나 오래 유지되었는지를 막대의 길이로 나타내어 행동의 시간적 강도를 평가할 수 있도록 하였다. 이는 단순히 행동이 존재했는지를 넘어서 하루 중 어떤 구간에 어느 정도 비중을 차지했는지를 분석하는 데 목적이 있다.

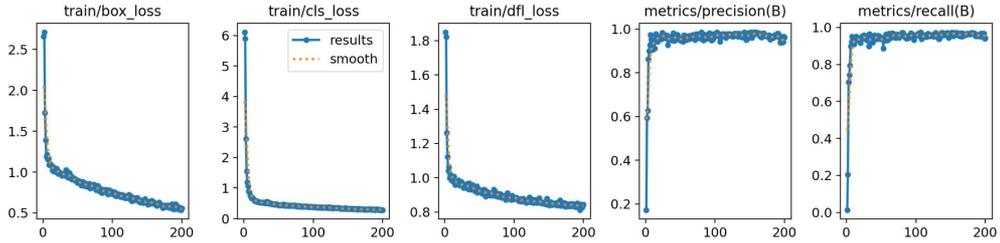
실제 분석 결과, Resting, Bathing, Stretching과 같은 심리적 안정 상태에서 발견되는 행동의 비중이 높은 개체에서는 3초 이상 지속 이동의 총량이 매우 낮게 나타났다. 반대로 이러한 안정 행동이 적거나 거의 관측되지 않은 개체에서는 3초 이상 이동의 총량이 크게 증가하여, 스트레스 상황에 특유한 목적없는 이동 패턴이 명확하게 확인되었다. 이러한 결과는 본 연구에서 설정한 Pacing의 운영적 정의가 실제 행동학적 특징과 일치하며, 안정 행동 대비 Pacing 총량 분석이 개체의 심리적 상태를 구분하는 데 유효한 지표임을 보여준다.

4.3 AI 기반 행동 분류 모델 정량적 성능 평가 결과

[그림 4-8]은 본 연구에서 구축한 Eating, Drinking, Bathing 행동에서의 AI 기반 Object Detection 모델의 정규화 혼동행렬(Confusion Matrix Normalized) 결과를 제시한 것이다. Parrot, Head, Tail 클래스는 각각 1.00의 정확도를 보여 단 한 건의 오분류도 발생하지 않았다. Foot와 Bath 클래스는 각각 0.95의 정확도를 나타내었으며, 나머지 5%는 모두 background로 분류되어 가려짐·반사 등으로 인한 소규모 누락이 존재함을 확인하였다. Background 클래스는 0.80의 정확도를 보였고, 약 20%는 head로 오인식되어 머리 주변의 미세한 움직임이 배경 노이즈와 혼동되는 경향이 관찰되었다. 전반적으로 주요 행동/부위 클래스는 95-100%의 높은 정확도를 확보하고 있어, 본 모델이 행동 패턴 분석의 기초 객체 탐지 단계에서 충분한 신뢰성을 갖추고 있음을 보여준다.



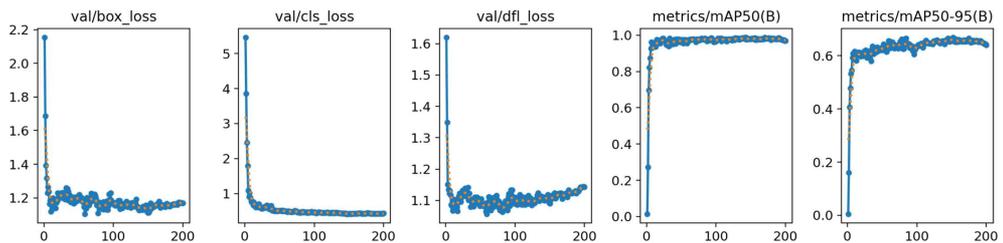
[그림 4-8] Eating, Drinking, Bathing 행동 Confusion Matrix



[그림 4-9] Eating, Drinking, Bathing 행동 Training Metrics(훈련 지표)

[그림 4-9]에서 제시된 훈련 지표는 핵심 행동인 Eating, Drinking, Bathing을 탐지하기 위해 필요한 Head, Foot, Bath 영역 등의 객체를 모델이 얼마나 안정적으로 학습되었는지를 보여준다. Training Metrics를 살펴보는 이유는 모델의 성능을 평가해 볼 수 있는 Validation Metrics(검증 지표)와 결합하여 학습이 실제로 일반화되었는지를 알 수 있기 때문이다.

우선 train/box_loss는 Bounding Box Loss로서 모델이 예측한 박스 좌표와 실제 좌표의 차이를 의미하며, 학습 초기 약 2.7에서 출발하여 에폭 증가에 따라 0.55 수준까지 꾸준히 감소하였다. 이를 통해 모델의 박스 위치 예측 오차가 지속적으로 줄어들어 객체 경계 탐지 능력이 안정적으로 향상되었음을 확인할 수 있었다. train/cls_loss는 Classification Loss로서 객체가 속하는 클래스를 구분하는 과정의 오류를 나타내며, 초기 약 6.0에서 0.5 수준까지 급격히 감소하였다. 이는 행동 판단에 필요한 신체 부위의 분류 정확도가 빠르게 향상되었음을 보여준다. train/df_l_loss는YOLO v8에서 사용하는 Distribution Focal Loss로 박스 경계의 정밀도를 보정하는 역할을 하며, 1.85에서 0.8까지 감소하였다. 이는 박스 중심점과 경계 예측의 세밀도가 전반적



[그림 4-10] Eating, Drinking, Bathing 행동 Validation Metrics(검증 지표)

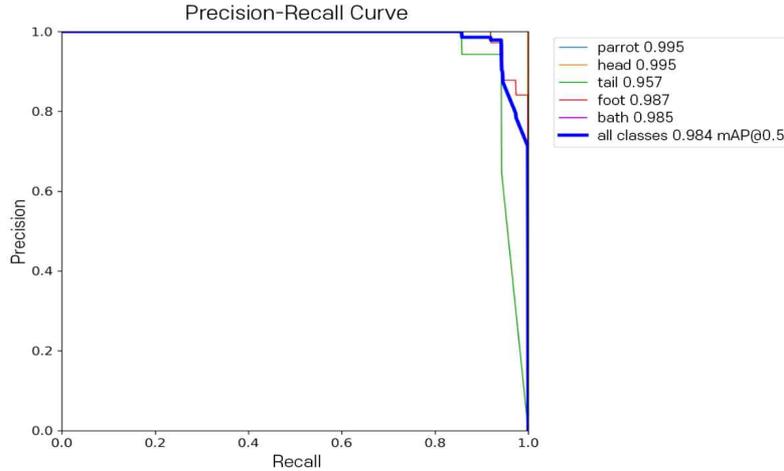
으로 개선되었음을 의미한다. Precision(B)은 훈련 초반의 변동 이후 0.95~1.0 범위에서 안정적으로 유지되어 오탐이 거의 발생하지 않았음을 나타냈으며, Recall(B)은 0에서 빠르게 상승하여 0.90~0.95 구간에서 수렴함으로써 실제 행동을 놓치지 않고 탐지하는 능력이 충분히 확보되었음을 보여주었다.

[그림 4-10] 검증 지표는 Eating, Drinking, Bathing 행동 탐지가 새로운 데이터에서도 안정적으로 수행될 수 있는지를 평가한 결과이다. val/box_loss는 2.15에서 1.15로 감소하여 박스 위치 예측 성능이 검증 데이터에서도 유지되었음을 보여주었으며, 과적합이 발생하지 않았음을 시사하였다. val/cls_loss는 5.0에서 0.7 수준으로 감소하여 검증 데이터셋에서도 분류 성능이 안정적으로 확보되었음을 나타냈다. val/df_l_loss 또한 1.6에서 1.1로 수렴하여 박스 경계 정밀도가 보지 않은 데이터에서도 일관되게 유지되었음을 확인할 수 있었다. mAP@0.5(B)는 0에서 약 0.97 수준까지 상승하여 IoU 0.5 조건에서 거의 완벽한 행동 관련 부위 탐지가 가능하였음을 보여주었으며, mAP@0.5-0.95(B)는 0.65~0.70 수준으로 수렴하여 다양한 IoU 기준에서도 안정적인 탐지 성능이 확보되었음을 확인하였다.

종합하면 모든 훈련·검증 지표는 안정적으로 감소하거나 수렴하였으며 Precision과 Recall은 전반적으로 0.9 이상에서 유지되었다. 또한 mAP 계열 지표가 높은 수준으로 수렴함으로써 본 모델은 Eating, Drinking, Bathing 행동 패턴 분석의 기반이 되는 객체 탐지 단계에서 충분한 정확성과 일반화 능력을 확보하였음을 보여준다. 이러한 결과는 이후 행동 기반 분석에서 모델이 신뢰도 높은 데이터를 안정적으로 제공할 수 있음을 뒷받침한다.

[그림 4-11]는 본 연구에서 구축된 모델의 Precision-Recall 관계를 시각화한 것으로, 핵심 행동인 Eating, Drinking, Bathing을 탐지하기 위해 필요한 Head, Foot, Bath 영역 등의 객체를 얼마나 정확하게 식별하였는지를 평가한 결과이다. 각 클래스별 Precision-Recall 곡선은 confidence threshold 변화에 따라 탐지된 객체가 실제로 올바른지와 실제 객체를 얼마나 놓치지 않고 탐지하였는지를 동시에 보여준다.

분석 결과 parrot 0.995, head 0.995, tail 0.957, foot 0.987, bath 0.985



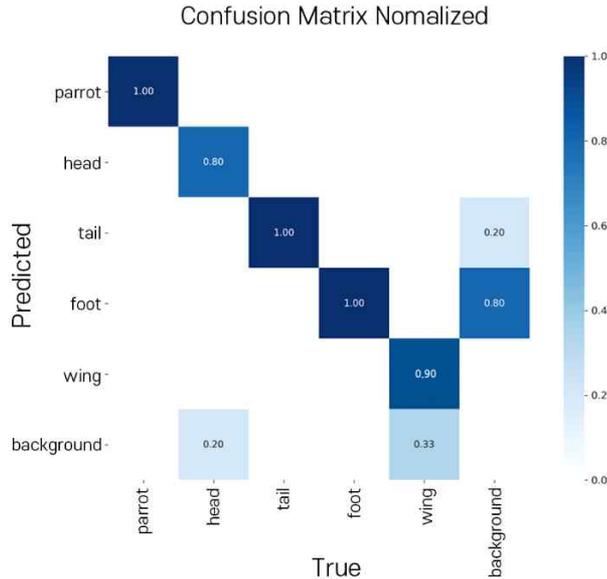
[그림 4-11] Eating, Drinking, Bathing 행동 Precision-Recall Curve

로 나타났으며 전체 평균은 0.984이었다. 이러한 성능은 Eating 행동 시 Head의 먹이통 진입, Drinking 행동 시 Head와 Foot의 물통 접근, Bathing 행동 시 Bath 영역 진입과 같은 세부 움직임을 판단하는 데 필요한 주요 신체 부위가 높은 정확도로 탐지되었음을 의미하였다.

대부분의 클래스는 Recall이 0.9 수준까지 증가하였을 때도 Precision이 0.95 이상으로 유지되었으며, 이는 모델이 탐지한 객체 대부분이 실제 객체였고 누락 또한 거의 발생하지 않았음을 보여주었다. 특히 parrot, head, foot, bath 클래스는 confidence threshold가 변하더라도 곡선이 상단에 밀집하여 탐지 성능이 안정적으로 유지되었음을 확인할 수 있었다.

반면 tail 클래스는 Recall이 높은 구간에서 Precision 감소가 다소 크게 나타났는데, 이는 꼬리가 작고 가려질 가능성이 높아 탐지 난도가 상대적으로 높았기 때문으로 해석되었다. 그럼에도 tail의 성능 역시 0.957을 기록하여 충분히 높은 정확성을 확보하였음을 보여주었다.

종합하면 Precision-Recall Curve는 Eating, Drinking, Bathing 행동 탐지의 기반이 되는 객체들이 다양한 threshold 조건에서 높은 Precision과 Recall을 유지하였음을 보여주었으며, 이는 실제 사육 환경에서 발생하는 조도 변화, 움직임 속도 차이, 부분 가림 등의 상황에서도 본 모델이 신뢰도 높은 탐지 결과를 제공할 수 있음을 뒷받침하였다.

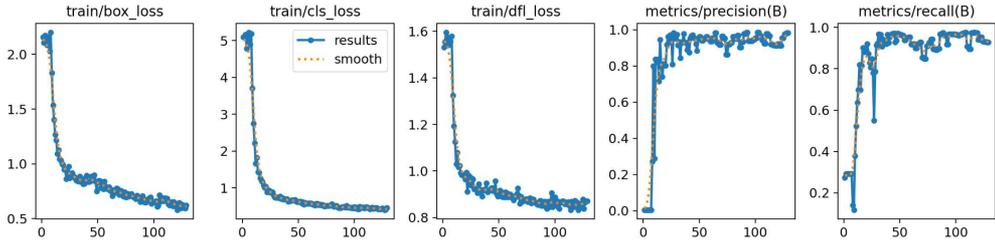


[그림 4-12] Stretching 행동 탐지를 위한 Wing 기반 Confusion Matrix

[그림 4-12]는 Stretching 행동을 탐지하기 위해 Wing 객체를 기반으로 탐지한 결과를 정규화된 혼동행렬 형태로 나타낸 것이다. 분석 결과, parrot 과 tail, foot 클래스는 각각 1.00의 정확도를 보였으며, 이는 해당 객체들이 Stretching 여부와 무관하게 안정적으로 탐지되었음을 의미하였다. Head 클래스는 0.80의 정확도를 나타냈고, 나머지 20%는 background로 분류되어 일부 프레임에서 Head가 가려지거나 작게 나타나는 경우 누락이 발생하였음을 보여주었다.

Stretching 행동의 핵심 지표인 Wing 클래스는 0.90의 정확도를 기록하였으며, 나머지 10%는 background로 분류되었다. 이는 Wing이 Stretching 시에 크게 펼쳐져 잘 탐지되지만, 날개가 반쯤만 보이거나 몸통에 일부 가려진 상태에서는 소수의 누락이 발생하였음을 의미하였다. 반면 background는 0.80의 정확도로 분류되었으며, 20%는 wing으로 오인식되었다. 이 값은 배경 영역에 날개 패턴과 유사한 밝기나 움직임이 나타날 때 wing으로 잘못 탐지되는 경향이 존재함을 시사하였다.

종합적으로, 본 모델은 Stretching 행동을 특징짓는 Wing 객체에 대해 0.90의 높은 정확도를 확보하였으며, 대부분의 클래스가 0.80~1.00 수준에서

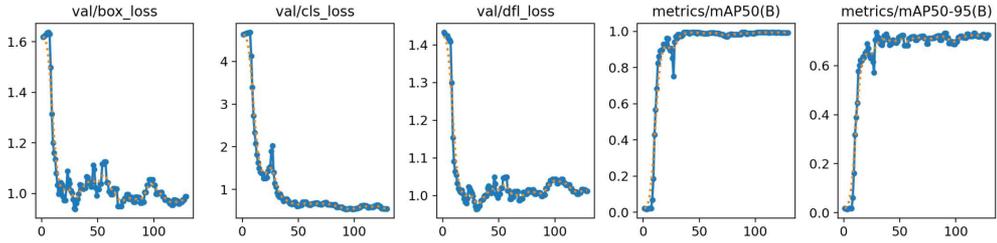


[그림 4-13] Stretching 행동 Training Metrics(훈련 지표)

안정적으로 탐지되었다. 다만 Head와 background에서 일부 오인식이 발생하여 Stretching 판단 시 간헐적인 누락 또는 오탐이 있을 수 있으나, 전반적인 성능은 행동 분류 모델로서 활용 가능할 만큼 견고한 수준임을 확인할 수 있었다.

[그림 4-13]은 Stretching 행동 탐지를 위해 구축된 모델의 학습 및 검증 과정을 나타내는 지표를 시각화한 것으로, 각 지표는 모델이 Wing을 중심으로 한 Stretching 특징을 얼마나 안정적으로 학습하고 일반화하였는지를 보여준다. 우선 훈련 지표에서는 train/box_loss가 꾸준히 감소하는 양상을 보였으며, 이를 통해 모델이 Stretching 판단에 필요한 Wing과 주요 신체 부위의 위치 정보를 점진적으로 정확하게 학습하였음을 확인할 수 있었다. train/cls_loss 역시 지속적인 감소를 보이며 Wing 클래스와 기타 부위 간의 분류 경계가 명확하게 학습되었음을 보여주었고, train/df_l_loss 또한 안정적으로 하락하여 Stretching 시 펼쳐지는 Wing 형태의 세밀한 경계 정보를 모델이 효과적으로 습득하였음을 의미하였다. Precision(B)은 훈련 초반 변동 이후 높은 수준에서 유지됨으로써 모델이 탐지한 Wing 신호의 대부분이 실제 Stretching 관련 객체였음을 보여주었고, Recall(B)은 빠르게 상승하여 실제 등장한 Wing을 놓치지 않고 탐지하는 능력이 확보되었음을 확인할 수 있었다.

[그림 4-14] 검증 지표 또한 훈련과 유사한 형태의 수렴 경향을 보였다. val/box_loss는 새로운 데이터에서도 안정적으로 감소하여 Stretching 동작에서 나타나는 Wing 위치를 일관되게 예측할 수 있음을 보여주었으며, val/cls_loss 역시 감소하여 Wing 클래스 분류가 검증 데이터에서도 성공적으

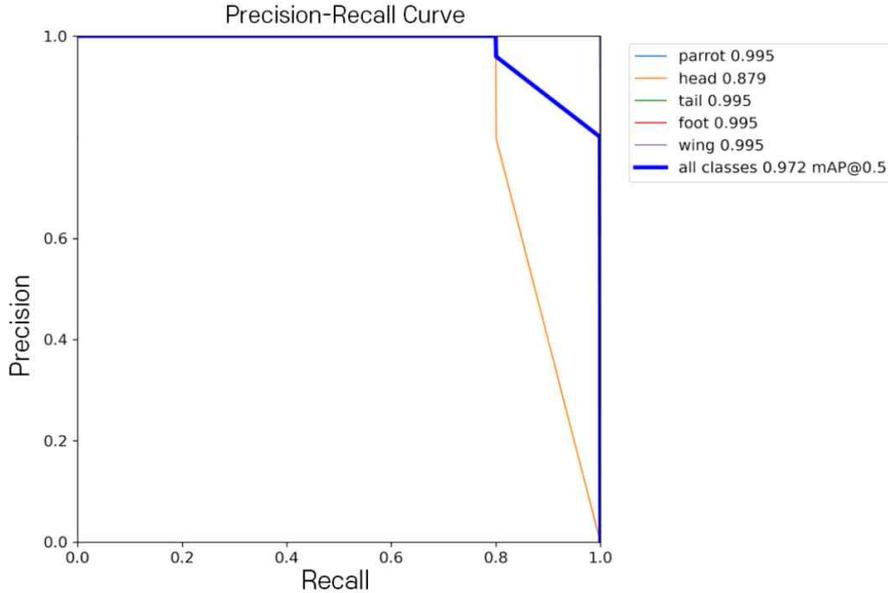


[그림 4-14] Stretching 행동 Validation Metrics(검증 지표)

로 유지되었음을 나타내었다. val/df_l_loss는 점진적으로 수렴하여 모델이 Stretching 과정에서 나타나는 다양한 Wing 형태를 세밀하게 인식할 수 있음을 확인시켜주었다. mAP@0.5(B)는 높은 값으로 수렴하여 Wing의 존재 여부를 기준으로 한 Stretching 탐지가 매우 높은 정확도로 수행되었음을 의미하였으며, mAP@0.5-95(B) 역시 안정적인 값으로 수렴하여 다양한 IoU 조건에서도 Stretching 관련 객체를 견고하게 탐지할 수 있음을 보여주었다.

[그림 4-13] 과 [그림 4-14]를 종합하면, 훈련 및 검증 전 과정에서 모든 손실 지표는 안정적으로 감소하거나 수렴하였으며 Precision과 Recall은 높은 수준에서 유지되었다. 이러한 결과는 본 Stretching 행동 탐지 모델이 Wing을 중심으로 한 동작 특징을 충분히 학습하였을 뿐 아니라 새로운 데이터에서도 안정적으로 일반화될 수 있음을 보여주는 주요 근거가 된다.

[그림 4-15]는 Stretching 행동 탐지를 위해 학습된 모델의 Precision-Recall Curve로, 전반적으로 높은 정밀도와 재현율을 확보하였음을 보여준다. Parrot, Tail, Foot, Wing과 같이 Stretching 판단에 필요한 주요 객체들은 모두 0.99 내외의 높은 AP 값을 기록하였으며, 이는 해당 부위들이 Stretching 동작 시 안정적으로 탐지되었음을 의미한다. 특히 Tail, Foot, Wing의 곡선은 거의 수평에 가깝게 유지되며 초기에 높은 Precision을 확보한 뒤 Recall이 증가하더라도 성능 저하가 거의 발생하지 않는 형태를 보였다. 반면 Head는 0.879 수준으로 다른 부위 대비 다소 낮은 AP 값을 보였는데, 이는 Stretching이 발생할 때 머리 움직임이 상대적으로 빠르거나 가려지는 구간이 존재하여 탐지가 일부 불안정했기 때문으로 해석된다. 전체 클래스 기준 mAP@0.5는 0.972로 매우 높게 수렴하여 다양한 Stretching 구간에서도 모델

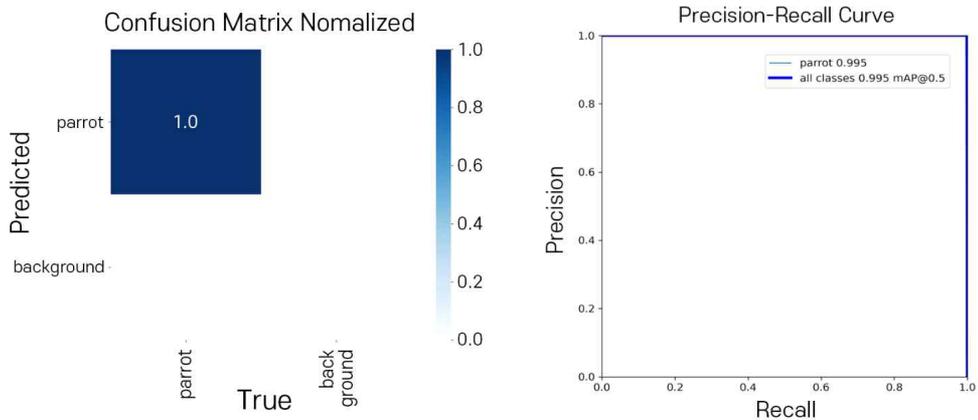


[그림 4-15] Stretching 행동 Precision-Recall Curve(PR 커브)

이 안정적으로 주요 신체 부위를 식별하였음을 확인할 수 있었다. 이러한 결과는 Stretching 행동의 판단 근거가 되는 객체 수준 탐지 정확도가 충분히 확보되었음을 보여주며, 이후 Stretching 행동 패턴 분석 단계에서 신뢰도 높은 입력값을 제공할 수 있음을 시사한다.

Pacing 행동의 탐지 성능은 Confusion Matrix와 Precision-Recall Curve 두 가지로 정량적으로 평가되었다. 먼저 Confusion Matrix에서는 Pacing 탐지를 위해 사용된 Parrot 클래스가 모든 사례에서 1.00의 정답 비율을 기록하여, 모델이 Pacing 구간에서 등장한 Parrot 객체를 단 한 번도 놓치지 않고 모두 정확하게 탐지하였음을 보여주었다. 또한 Background로 잘못 분류된 사례가 존재하지 않아, Pacing 구간에서의 객체 누락이나 오탐지 없이 매우 안정적인 탐지 성능이 확보되었음을 확인하였다.

Precision-Recall Curve 역시 모델의 높은 신뢰도를 뒷받침하였다. Parrot 클래스는 Precision과 Recall 모두 1.0에 근접한 곡선을 나타내어, Pacing 행동이 발생한 모든 프레임에서 탐지 누락 없이 정확하게 객체를 탐지하였음을 보여주었다. 특히 Precision이 거의 1.0 수준으로 유지되었다는 점은 모델이 Pacing과 무관한 오탐지를 생성하지 않았음을 의미하며, Recall이 1.0에 수렴



[그림 4-16] Pacing 행동 Confusion Matrix와 Precision-Recall Curve

하였다는 점은 실제 Pacing 구간에 존재하는 Parrot 객체를 완전히 놓치지 않고 탐지하였음을 시사한다. 전체 클래스 기준 mAP@0.5가 0.995로 나타난 점 또한 모델의 Pacing 행동 탐지 기반이 충분히 견고하였음을 보여주었다. 그렇지만 3초 이상 이동의 지속은 먹이 섭취, 음수, 목욕과 같은 목적 있는 정상 행동에서도 일시적으로 나타날 수 있다. 따라서 본 연구에서는 단일 이동의 지속시간이 아니라 일일 관찰 구간 전체에서 나타나는 3초 이상 연속 이동의 총량을 중심 지표로 활용하였다. 이는 목적 없이 반복적으로 이동하는 Pacing의 행동학적 특성을 전문가 관찰 결과에 따라 반영한 것이다.

V. 결 론

반려앵무의 심리적 안정감을 보다 정확히 이해하고 향상시키기 위해서는 그 정서 상태를 객관적으로 탐지할 수 있는 방법이 필요하며, 본 연구는 이러한 목표 아래 AI를 활용한 행동 패턴 분석을 통해 스트레스와 안정 행동을 정량적으로 평가하는 체계를 구축하고자 하였다.

본 연구에서 구축한 행동 패턴 분석 체계는 먹이 섭취, 물 마시기, 휴식, 목욕, 기지개, 스트레스성 반복 이동의 여섯 가지 행동을 독립적으로 탐지하였으며, 여섯 가지 행동 간의 상대적 비율은 개체별 심리 상태를 분명하게 반영하는 패턴을 보였다. 휴식과 목욕과 기지개로 구성된 안정 행동의 비중이 낮은 개체에서는 스트레스성 반복 이동의 지속 시간이 증가하였고, 이는 기존 연구에서 보고된 안정 행동 감소와 스트레스 행동 증가의 상관 구조와 일치하였다.

먹이 섭취와 물 마시기는 케이지 내부에서 기능하여 다른 행동의 구간을 명확히 분리하고 오분류를 방지하는 데 기여하였으며, 섭식과 음수 행동의 지나친 증가나 감소는 일부 개체에서 건강 이상이나 스트레스 누적의 초기 신호로 나타나 행동 패턴 분석 과정에서 중요한 참고자료로 활용되었다. 또한 두 행동을 구분하기 위해 적용한 머리와 꼬리 축 기울기 기반 탐지 방식은 목욕과 음수의 초기 자세를 비롯해 기지개와 휴식의 경계 탐지 등에서도 유효하게 작동하여 전체 행동 분류의 정밀도를 높이는 핵심 요소로 기능하였다.

여섯 가지 행동을 선정한 이유는 인공지능이 영상에서 안정적으로 탐지할 수 있을 뿐 아니라, 정서 상태와 생리적 상태를 함께 반영하는 행동군으로 구성되어 있기 때문이다. 휴식과 목욕과 기지개는 심리적 안정 상태를 평가하는 핵심 행동이며, 스트레스성 반복 이동은 불안과 환경 부적응을 나타내는 대표적인 행동으로 개체의 정서적 복지 수준을 정량화하는 기준이 된다. 먹이 섭취와 물 마시기는 행동 경계를 정의하는 기준선 역할을 할 뿐 아니라 생애주기 변화나 질병 전조처럼 건강 이상 상태가 가장 먼저 나타나는 영역이기 때문에 장기 행동 모니터링 체계를 구축하는 데 중요한 기반이 된다. 이처럼 스켈

레톤 기반 기율기 판단과 공간 정보 결합을 중심으로 한 여섯 가지 행동 분류 체계는 반려앵무의 행동 변화를 세밀하게 해석하고 정서 상태를 정량적으로 평가하는 데 필요한 구조적 토대를 제공하였다.

기존 인간 중심의 Keypoint 기반 자세 추정 기술은 조류와 같이 관절의 명확한 분리가 어렵고 깃털 구조로 인해 신체 윤곽이 불분명한 동물에게 적용될 경우 탐지 안정성이 급격히 저하된다는 한계가 있었으며, 이를 극복하기 위해, YOLO 기반 객체 탐지 기술과 다단계 분석 구조를 결합한 새로운 반려앵무 행동 패턴 분석 시스템을 제안하였다. 제안한 방안은 반려앵무의 전신 바운딩박스를 먼저 안정적으로 탐지한 뒤 해당 ROI 내부에서 Head, Tail, Foot, Wing을 재탐지하는 방식으로 이루어지며, 이를 통해 조류 특유의 빠른 움직임과 복잡한 깃털 패턴에도 관절 기반 스켈레톤 구조를 일관되게 구성할 수 있었다. 나아가 각 부위 간 상대적 위치와 각도 변화를 기반으로 Eating, Drinking, Resting, Bathing, Stretching, Pacing 등 주요 행동을 정량적으로 분류할 수 있었고, RGB 세그멘테이션 기반 위치 판별을 병행함으로써 머리나 발의 일시적 가림이 발생하더라도 구조적 제약 조건을 활용해 행동을 지속적으로 추적할 수 있음을 확인하였다. 실험 결과 YOLO 기반 모델은 Parrot, Head, Tail, Foot 클래스에서 mAP@0.5 약 0.995의 매우 높은 성능을 보였고, Wing과 Bath의 탐지 역시 shortcut rule 및 세그멘테이션 기반 보조 판단을 통해 안정적으로 수행되었다.

또한 장시간 영상 전체를 대상으로 인간 관찰자 VI와 AI 분석 결과를 직접 비교한 VI-AI Detection Comparison에서는 Eating, Drinking과 같은 목적 행동뿐만 아니라 Resting, Bathing, Stretching 등 안정 행동에서도 두 방식 간 행동의 시작·종료 시점과 지속 시간 분포가 높은 일치도를 보였으며, AI는 프레임 단위 좌표 정보를 기반으로 미세한 전환 시점을 인간보다 더 빠르게 포착하는 경우도 나타났다. 이는 인간이 관찰하면서 간헐적으로 놓칠 수 있는 작은 자세 변화들을 AI가 지속적으로 추적하고 누적 패턴을 분석함으로써 가능한 결과이며, 제안한 모델이 단순 탐지를 넘어서 행동의 연속성과 목적성을 정교하게 반영하고 있음을 의미한다. 특히 Pacing과 같이 조류 스트레스의 대표적 지표로 알려진 반복 이동 행동에서는 AI가 EMA 기반 중심점

스무딩을 통해 이동의 왕복성, 연속성, 진폭 변화를 일관되게 측정하여 관찰자 사이에서 발생할 수 있는 주관적 편차를 크게 줄이는 효과가 확인되었다.

안정 행동인 Resting, Bathing, Stretching과 Pacing 간의 상대 비율 분석에서도 뚜렷한 음의 상관관계가 나타났다. 안정 행동 비율이 높았던 개체는 하루 동안의 3초 이상 Pacing 행동의 총량이 낮게 유지되었으며, 반대로 반복 이동이 증가한 개체에서는 Resting과 Bathing이 급격히 감소하고 Stretching의 발생량이 감소하였다. 이는 스트레스 상황에서 안정 행동이 붕괴되는 기존 동물행동학적 지식과 정확히 일치하는 결과이며, 모델이 실제 스트레스 관련 행동적 패턴을 정확하게 포착하고 있음을 보여준다. 전문가가 사전에 정상군과 스트레스군으로 분류한 집단 간 비교에서도 동일한 경향이 관찰되어, Resting 지속시간과 Bathing 빈도가 안정적으로 유지된 정상군에 비해 스트레스군은 Pacing 비율이 높고 안정 행동이 현저히 감소하는 양상을 보였다. 이러한 결과는 본 연구의 AI 분석 체계가 전문가의 행동학적 판단을 높은 수준에서 재현함과 동시에, 장시간 관찰에서 발생할 수 있는 인간의 누락·피로·편차를 보완할 수 있는 정량적 분석 도구로 기능할 수 있음을 시사한다.

궁극적으로 본 연구는 반려앵무 행동 패턴 분석에서 Object Detection 기반 다단계 분석 구조가 실시간성과 정밀성을 동시에 확보할 수 있는 효과적인 기술적 대안임을 실증하였으며, 특히 스트레스성 행동의 자동 탐지와 안정 행동의 정량적 추적을 통해 반려조류의 심리적 안정 상태를 평가하는 데 활용될 수 있는 가능성을 제시하였다. 다만 본 연구는 단일 케이지 환경과 코뉴어의 한 아종을 중심으로 수행되었다. 다양한 종의 비교실험, 조도 조건의 변화, 케이지 배치의 변화, 배경의 변화 등에 대한 일반화에 제한적이었으며, 향후에는 더 다양한 반려조류 종을 포함하고 실제 사육환경 변동성을 확장한 실험을 통해 모델의 범용성을 강화할 필요가 있다. 더불어 행동 데이터와 생리적 스트레스 지표(코티졸, 심박 변동성 등)를 연계한 다중모달 분석을 도입한다면 AI 기반 행동 패턴 분석이 단순한 행동 분류를 넘어 객관적 건강 지표 모델로 확장될 수 있을 것이다. 이러한 연구 방향은 장기적으로 반려조류의 실시간 행동 모니터링, 스트레스 조기 감지, 행동 풍부화 효과 검증, 스마트 케이지 자동화 시스템 구축 등으로 이어질 수 있으며, 반려조류 복지 개선

뿐만 아니라 연구·산업·교육 영역 전반에서 활용될 수 있는 핵심 기술로 발전할 가능성을 제시한다.

참 고 문 헌

1. 국내문헌

- 강대훈, 송성은, 노광현 (2026). AI 기반 반려앵무 자세 추정 및 행동 분석 연구. 한국정보기술학회, 24(1)
- 강대훈, 송성은, 신은송, 이경복, 노광현 (2025). 스트레스 저감 기능을 가진 스마트 앵무새장. Asia-Pacific Journal of Convergent Research Interchange, 11(3), 843-859. <https://doi.org/10.47116/apjcri.2025.03.58>
- 강대훈, 송성은, 신은송, 노광현 (2024). 반려앵무의 심리적 안녕감과 스트레스 스펙트럼 연구. Asia-Pacific Journal of Convergent Research Interchange, 10(2), 305-326. <https://doi.org/10.47116/apjcri.2024.02.26>
- KB Think. (2025). 한국 반려동물 현황. 2025 한국 반려동물 보고서, June 29. Retrieved from <https://kbthink.com/investment/deepdive/research/250629-2.html>
- KB금융지주 경영연구소. (2021). 펫테크, 기술로 반려동물을 널리 이롭게 하다. 서울: KB지식비타민.
- 김현민. (2018). 미국에서 펫 테크 인기...1년 사이에 두배 커져. 오피니언뉴스, October 6. Retrieved from <https://www.opinionnews.co.kr/news/articleView.html?idxno=11598>
- 농림축산식품부. (2023). 2023 반려동물 펫푸드, 펫헬스케어 등 국가전략산업으로 육성. 세종: 농림축산식품부 동물복지환경정책관, 반려산업동물의료팀.
- 문현경. (2023). “앵무새 떼죽음 당했다”... 건설사와 5년 싸움, 대법서 반전. 중앙일보. Retrieved from <https://www.joongang.co.kr/>
- 박정수. (2021). 앵무새 시장, 성장가도 위 반려동물 시장의 ‘다크호스’ 될까?.

- 내외경제TV. Retrieved from <https://www.nbntv.co.kr/>
- 우은정. (2022). 펫 테크에 주목하는 미국 반려동물 산업. 해외시장뉴스, KOTRA 로스앤젤레스무역관. Retrieved from <https://news.kotra.or.kr/>
- 이동은. (2024). [사이언스ZOO] 사람과 두뇌 싸움도 가능...똑똑한 새 앵무새. YTN 사이언스.
- 임종현. (2024). CES에서 주목받은 펫테크, AI와 로봇이 바꾸는 반려동물 케어. 더프론티어. Retrieved from <https://www.thefrontier.co.kr/>
- 한경비즈니스. (2021). 6조원 반려동물 시장 두드리는 펫테크 전성시대. 한국경제 매거진, December 8. Retrieved from <https://magazine.hankyung.com/>
- 한국무역협회 신산업연구실. (2022). 성장하는 펫케어 산업 최신 트렌드와 우리 기업 글로벌 경쟁력 강화 방안. 서울: 한국무역협회.

2. 국외문헌

- Andrew U. Luescher (Ed.). (2006). 『Manual of Parrot Behavior』. Ames, IA: Blackwell Publishing.
- Beaton, L. (2022). Pet bird segment enjoys growth, faces pandemic challenges. 『Pet Food Industry』, Retrieved from <https://www.petfoodindustry.com/>
- Charles, J., Pfister, T., Magee, D., Hogg, D., & Zisserman, A. (2016). 『Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2016)』, Personalizing human video pose estimation. arXiv:1511.06676.
- Costa, P., Macchi, E., Valle, E., De Marco, M., Nucera, D. M., Gasco, L., & Schiavone, A. (2016). An association between feather damaging behavior and corticosterone metabolite excretion in captive African grey parrots (*Psittacus erithacus*). 『PeerJ』, 4, e2462. <https://doi.org/10.7717/peerj.2462>
- Dormehl, L. (2016, March 22). World's first smart bird cage. 『New Atlas』. Retrieved from <https://newatlas.com/pets/worlds-first-smart-bird-cage/>
- Fang, C., Wu, Z., Zheng, H., Yang, J., Ma, C., & Zhang, T. (2024). MCP: Multi-chicken pose estimation based on transfer learning. 『Animals』, 14(12), 1774. <https://doi.org/10.3390/ani14121774>
- Fazzari, E., Romano, D., Falchi, F., & Stefanini, C. (2025). Animal behavior analysis methods using deep learning: A survey. 『Expert Systems with Applications』, 289, 128330. <https://doi.org/10.1016/j.eswa.2025.128330>
- Gobinath, V. M., & Kathirvel Ayyaswamy, A. (2024). AI-based healthcare systems for pets and birds. 『Biomedical Journal of Scientific & Technical Research』, 58(5). <https://doi.org/10.26717/BJSTR.2024.58.009202>

- Global Market Insights. (2025). How AI and wearables are changing pet parenting. 『Global Market Insights』, June 4. Retrieved from <https://www.gminsights.com/>
- Grand View Research. (2022). 『Pet care market size, share & trends analysis report (2022-2030)』. San Francisco: Grand View Research. Retrieved from <https://www.grandviewresearch.com/industry-analysis/pet-care-market>
- He, R., Wang, X., Chen, H., & Liu, C. (2023). VHR-BirdPose: Vision transformer-based HRNet for bird pose estimation with attention mechanism. 『Electronics』, 12(17), 3643. <https://doi.org/10.3390/electronics12173643>
- Jang, W., & Lee, E. C. (2021). Multi-class parrot image classification including subspecies with similar appearance. 『Biology』, 10(11), 1140. <http://doi.org/10.3390/biology10111140>
- Jerem, P., Herborn, K. A., McCafferty, D. J., & Nager, R. G. (2015). Thermal imaging to study stress non-invasively in unrestrained birds. 『Journal of Visualized Experiments』, 105, e53184. <https://doi.org/10.3791/53184>
- Kleinberger, R., O'Connor, J. T., McMahon, M., & Hirschyj-Douglas, I. (2024). No More Angry Birds: Investigating Touchscreen Ergonomics to Improve Tablet-Based Enrichment for Parrots. 『CHI '24: Proceedings of the 2024 CHI Conference on Human Factors in Computing Systems』. <https://doi.org/10.1145/3613904.3642119>
- Lin, C. W., Hong, S., Lin, M., Huang, X., & Liu, J. (2022). Bird posture recognition based on target keypoints estimation in dual-task convolutional neural networks. 『Ecological Indicators』, 135, 108506. <https://doi.org/10.1016/j.ecolind.2021.108506>

- Mellor, R., Owen, R., Mason, G. J., & Lambert, H. (2021). Nature calls: Intelligence and natural foraging style predict poor welfare in captive parrots. 『Proceedings of the Royal Society B: Biological Sciences』, 288(1964). October 6.
- Palme, R., Rettenbacher, S., Touma, C., El-Bahr, S. M., & Möstl, E. (2005). Stress hormones in mammals and birds: Comparative aspects regarding metabolism, excretion, and noninvasive measurement in fecal samples. 『Annals of the New York Academy of Sciences』, 1040, 162-171. <https://doi.org/10.1196/annals.1327.021>
- Piseddu, A., van Zeeland, Y. R. A., & Rault, J.-L. (2024). What we (don't) know about parrot welfare: A systematic literature review. 『Animals』, 14(12), 1537. <https://doi.org/10.3390/ani14121537>
- Redmon, J., & Farhadi, A. (2018). YOLOv3: An incremental improvement. 『arXiv preprint』 arXiv:1804.02767. <https://doi.org/10.48550/arXiv.1804.02767>
- Ren, S., He, K., Girshick, R., & Sun, J. (2015). Faster R-CNN: Towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems*, 28, 91-99.
- Ritchie, B. W., Harrison, G. J., & Harrison, L. R. (1994). 『Avian Medicine: Principles and Application』. Lake Worth, FL: Wingers Publishing, Inc.
- Seymour, K. G. (2025, June 30). Squawk of the town: Parrot study reveals how technology can enrich the lives of pet parrots. 『American Animal Hospital Association (AAHA) - Trends Magazine』. Retrieved from <https://www.aaha.org/>
- Siguín, M., Casas, R., Casas, O., & Blanco, T. (2025). Towards effective wearable design: 20 key factors for monitoring physiological health in

- animals. 『Results in Engineering』, 27, 106001. <https://doi.org/10.1016/j.rineng.2025.106001>
- Tabh, J. K. R., Burness, G., Wearing, O. H., Tattersall, G. J., & Mastromonaco, G. F. (2021). Infrared thermography as a technique to measure physiological stress in birds: Body region and image angle matter. 『Physiological Reports』, 9(11), e14865. <https://doi.org/10.14814/phy2.14865>
- The American Pet Products Association(APPA). (2024). 『Releases 2024 Bird, Small Animal & Horse Owner Insight Report』. Stamford, CT: The American Pet Products Association.
- Thompson, B. (2024, December 22). World's first smart bird cage does all the cleaning and feeding for you. 『New Atlas』. Retrieved from <https://newatlas.com/pets/worlds-first-smart-bird-cage/>
- Uehling, J. J., Tallant, J., & Pruett-Jones, S. (2019). Introduced and naturalized parrots in the contiguous United States. *Journal of Ornithology*, 160, 907-919
- van Zeeland, Y. R. A., Spruit, B. M., Rodenburg, T. B., Riedstra, B., van Hierden, Y. M., Buitenhuis, B., Korte, S. M., Lumeij, J. T., & R. A. (2009). Feather damaging behaviour in parrots: A review with consideration of comparative aspects. *Applied Animal Behaviour Science*, 121(2), 75-95. <https://doi.org/10.1016/j.applanim.2009.09.006>
- Wah, C., Branson, S., Welinder, P., Perona, P., & Belongie, S. (2011). 『The Caltech-UCSD Birds-200-2011 Dataset (CUB-200-2011)』. California Institute of Technology. <https://doi.org/10.22002/D1.20098>
- Wang, J., Sun, K., Cheng, T., Jiang, B., Deng, C., Zhao, Y., Liu, D., Mu, Y., Tan, M., Wang, X., Liu, W. & Xiao, B. (2020). Deep

High-Resolution Representation Learning for Visual Recognition, IEEE Transactions on Pattern Analysis and Machine Intelligence, 43(10), 3349-3364.

Yayla, R. (2024). A prototype study on YOLOv10-based bird gesture recognition. *International Journal of Multidisciplinary Studies and Innovative Technologies*, 8(2), 76-80.

ABSTRACT

A Study on AI-Based Behavioral Pattern Analysis Methods for Companion Parrots

Kang, Dae-Hun

Major in Smart Convergence Product

Dept. of Smart Convergence Consulting

The Graduate School

Hansung University

As companion animals are increasingly recognized as members of the family, demand for pet healthcare and related technologies that enable detailed monitoring of animal health and emotional well-being has rapidly grown. Companion parrots, in particular, are becoming increasingly popular due to their high intelligence and sociality; however, their heightened sensitivity to stress makes it difficult to objectively assess their emotional states. This study aims to establish a system capable of quantitatively evaluating stress states and psychological stability in companion parrots by applying video-based artificial intelligence behavioral-pattern analysis techniques.

Parrots possess dense feather structures that obscure body contours, demonstrate nonlinear and rapidly changing movements such as head rotations, wing flapping, and pre-flight postures, and frequently interact

with cage components including perches, feeders, water bowls, and toys. Due to these environmental and anatomical characteristics, traditional visual inspection or joint-based pose estimation alone is insufficient for reliable behavior classification. To address these challenges, this study proposes a new behavioral-pattern analysis framework that integrates a multi-stage object-detection structure, skeleton-based pose analysis, and cage-environment recognition.

The framework first detects the entire body of the parrot and then re-detects the head, tail, and feet within the region of interest to minimize background interference and information loss. A Y-shaped skeleton model was designed to quantify behavioral features such as body-tilt variation, foot-coordinate movement patterns, and center-point displacement ratios. In addition, the spatial locations of feeders, water bowls, and perches were segmented from the cage environment to ensure that visually similar movements could be interpreted accurately based on their contextual meaning.

Building on this foundation, six behaviors were selected and classified: Eating, Drinking, Resting, Stretching, Bathing, and Pacing (stress-induced repetitive movement). These behaviors were chosen because they are both reliably distinguishable by AI in real-world footage and represent the minimum essential behavioral set necessary to assess emotional state, environmental adaptation, and health. Resting, Stretching, and Bathing represent psychological stability, while Pacing serves as a primary stress indicator reflecting anxiety, hyperarousal, or maladaptation. Eating and Drinking, although physiological behaviors, serve as reference actions for defining behavioral boundaries using spatial segmentation; abnormal increases or decreases in eating and drinking patterns may also signal early signs of health issues or life-cycle changes. Furthermore, the body-tilt-based detection mechanism used for distinguishing eating from

drinking is reused across all behaviors to precisely determine behavioral onset and offset, improving classification accuracy.

Experiments were conducted indoors with four conures, and long-duration videos were recorded simultaneously using two high-resolution cameras capturing full-body views and perch-area interactions. Behavioral episodes annotated through visual inspection were compared with AI-derived results to validate the model's performance. High detection accuracy was observed for both the full body and specific body parts, and stable classification performance was achieved across all six behaviors.

Traditionally, behavioral analysis in avian and poultry research has focused on measuring how frequently and how long a specific behavior occurs, using these values as isolated indicators for managing health or improving husbandry conditions. In contrast, the behavioral-pattern analysis proposed in this study aims to structurally understand emotional state and stress level by interpreting not only the frequency and duration of individual behaviors but also the sequence of behavioral events, repetition patterns, transition structures, and the relative ratio between stable and stress-related behaviors.

The analysis revealed a clear negative correlation between Pacing and stable behaviors such as Resting, Bathing, and Stretching. Parrots exhibiting a high ratio of stable behavior showed low levels of stress-related movement, while individuals with increased stress behavior exhibited a corresponding reduction in stable behavior. These findings confirm that the proposed analytical framework reliably reflects the emotional states of companion parrots.

In conclusion, this study presents an integrated behavioral-pattern analysis system combining multi-stage object detection, skeleton modeling, and environmental-context recognition to automatically evaluate

behavioral changes and stress indicators in companion parrots. The results demonstrate strong potential for application in real-time cage monitoring, abnormal-behavior detection, and early stress-warning systems, ultimately contributing to improved welfare and the establishment of data-driven husbandry practices through long-term behavioral data analysis.

【Key words】 Companion parrots, Behavioral pattern analysis, Object detection, Multi-stage framework, Pet-tech