

지역 중첩 신뢰도가 적용된 삼 네트워크 기반 객체 추적 알고리즘

임수창* · 김종찬**

Object Tracking Algorithm based on Siamese Network
with Local Overlap Confidence

Su-Chang Lim* · Jong-Chan Kim**

요약

객체 추적은 영상의 첫 번째 프레임에서 annotation으로 제공되는 좌표 정보를 활용하여 비디오 시퀀스의 목표 추적에 활용된다. 본 논문에서는 객체 추적 정확도 향상을 위해 심층 특징과 영역 추론 모듈을 결합한 추적 알고리즘을 제안한다. 충분한 객체 정보를 획득하기 위해 Convolution Neural Network를 Siamese Network 구조로 네트워크를 설계하였다. 객체의 영역 추론을 위해 지역 제안 네트워크와 중첩 신뢰도 모듈을 적용하여 추적에 활용하였다. 제안한 추적 알고리즘은 Object Tracking Benchmark 데이터셋을 사용하여 성능 검증을 수행하였고, Success 지표에서 69.1%, Precision 지표에서 89.3%를 달성하였다.

ABSTRACT

Object tracking is used to track a goal in a video sequence by using coordinate information provided as annotation in the first frame of the video. In this paper, we propose a tracking algorithm that combines deep features and region inference modules to improve object tracking accuracy. In order to obtain sufficient object information, a convolution neural network was designed with a Siamese network structure. For object region inference, the region proposal network and overlapping confidence module were applied and used for tracking. The performance of the proposed tracking algorithm was evaluated using the Object Tracking Benchmark dataset, and it achieved 69.1% in the Success index and 89.3% in the Precision Metrics.

키워드

AI, CNN, Computer Vision, Object Tracking, Siamese Network
인공 지능, 컨볼루션 신경망, 컴퓨터 비전, 객체 추적, 삼 네트워크

1. 서론

비디오 시퀀스에서 목표(Target)의 궤적 및 영역을

추정하는 데 널리 사용되는 시각적 객체 추적(Visual Object Tracking, VOT)은 컴퓨터 비전의 기본 연구 분야 중 하나이며, 지능형 감시 등과 같은 카메라를

* 순천대학교 컴퓨터공학과(suchanglim@scnu.ac.kr)

** 교신저자 : 순천대학교 컴퓨터공학과

• 접수일 : 2023. 10. 16

• 수정완료일 : 2023. 11. 13

• 게재확정일 : 2023. 12. 27

• Received : Oct. 16, 2023, Revised : Nov. 13, 2023, Accepted : Dec. 27, 2023

• Corresponding Author : Jong-Chan Kim

Dept. of Computer Engineering, Suncheon National University

Email : seaghost@scnu.ac.kr

사용한 애플리케이션의 전반 분야에서 활용된다[1]. 정확하게 목표를 추적하기 위해서는 영상 프레임에 존재한 객체의 위치를 명확하게 추정하는 것이 필수적이다. 객체 추적은 통상적으로 초기 프레임의 주석(Annotation)에 기입된 좌표 정보를 사용하여 획득된 영역 정보를 초기 영역으로 사용한다[2].

트래커(Tracker)는 4차원 벡터인 경계 상자(Bounding Box)로 구성된 목표 정보를 기준으로 프레임 내부에서 객체를 찾고 연속 영상 시퀀스에서 새로운 위치를 추정해 나간다. 하지만, 제한된 정보만 포함하고 있는 초기 영역은 비디오 프레임에서 충분한 객체 정보를 제공하는 것이 한계점이다. 외형 변형, 조명 변화, 크기 변화, 장애물에 의한 가려짐, 배경 잡음 등과 같은 실제 세계에 나타나는 문제로 인해 목표가 이동하거나 모양이 변경될 때 배경과 혼동하여 경계 상자가 표류하는 문제가 발생한다[3].

최근에는 객체 추적이 지닌 어려움을 해결하기 위해 딥러닝(Deep Learning)을 사용한 연구가 활발히 진행되고 있다. 딥러닝 알고리즘중 하나인 CNN(Convolution Neural Networks)은 이미지 분류, 객체 검출, 의미론적 분할과 같은 컴퓨터 비전 분야에 핵심 기능으로 자리 잡고 있다[4-6]. CNN은 복잡한 이미지에서 강건한 특징을 추출하는 능력을 지니고 있고, 각 특징은 의미론적 정보와 공간적 정보를 지니고 있으므로 더 다양한 특징 표현이 가능하다.

CNN을 활용한 추적 알고리즘 중 두 이미지 사이의 유사성을 상호 상관관계(Cross-Correlation)를 기반으로 학습하고 목표 객체와 유사한 영역을 찾는 Siamese 구조의 추적 방법론이 연구되고 있다. 삼 네트워크기반 객체 추적은 정확도와 속도 측면에서 적절한 트레이드 오프로 인해 관심이 집중되고 있다. SiamFC는 객체 추적 작업을 유사성 일치 문제로 모델링하고 Fully CNN을 하위 네트워크로 채택하였다[7]. 이 네트워크는 추적 속도와 정확도 측면에서 우수한 결과를 보여주었다. SiamFC 이후로 Siamese 구조를 차용한 다양한 추적 알고리즘이 제안되었다. CFNet은 CF(Correlation Filter)와 FC(Fully Connected) Layer를 결합하여 정확도를 저하시키지 않으며 추적속도를 향상시켰다[8]. DSiam은 목표의 외형 변화와 이전 프레임의 배경 정보를 제한하는 프로세스를 반영한 온라인 학습 방식을 도입하였다[9].

Siam-RPN은 특징 추출을 위한 Backbone 네트워크와 영역 추정을 위한 RPN(Region Proposal Network)로 구성되어 있고, 오버랩 정확도 측면에서 기존 Siamese 기반 알고리즘보다 우수한 성능을 달성하였다[10].

기존 추적알고리즘은 객체의 위치 추정에 초점을 맞추고 있다. 객체 추적 성능 향상을 위해서는 영역(Area) 추정이 중요하다. 객체 위치 추정 및 회귀에 주로 사용하는 RPN은 고정된 가로, 세로 비율로 정의된 앙카 박스에 의존한다. 이 방식은 효율적인 계산이 가능하지만 다양한 크기, 외형, 가변적인 비율을 지닌 객체를 처리하는데 충분치 않은 정보를 제공한다. 부족한 정보는 사전 정의된 앙카 박스 크기를 벗어난 객체를 정확하게 지역화(Localization)할 수 없는 상황을 발생시키며, 경계 상자(Bounding Box)가 부정확해지므로 추적의 정확도가 하락하는 상황이 발생한다.

본 논문에서는 개체 추적 정확도 향상을 위해 객체 정보를 보존하면서 객체 영역에 집중하고 지역 중첩 신뢰도 개념을 도입한 객체 추적 알고리즘을 제안한다. 객체의 의미론적 특징 정보를 추출하기 위해 사전 학습된 CNN을 사용하고, 유사도 비교에 특화된 삼 네트워크(Siamese Network) 구조로 구성한다. 특징맵은 중첩 신뢰도 모듈과 RPN을 통과하며 목표 객체의 관심 영역이 집중된 특징맵이 추출된다. 마지막 단계로 해당 특징맵의 집중된 목표 객체 영역을 기준으로 최종 객체 영역의 바운딩 박스를 추론한다.

논문의 구성은 다음과 같다. 2장에서 추적 관련 연구를 기술했다. 3장에서 제안한 알고리즘을 서술하며, 4장에서 OTB 평가 데이터 셋을 사용하여 제안한 알고리즘의 성능평가를 진행한다. 마지막 5장에서 결론을 맺는다.

II. 관련연구

2.1 전통적인 상관관계 추적 알고리즘

상관 필터링 기반 추적알고리즘은 반복 갱신 특성을 사용하여 필터의 가중치를 업데이트함으로써 온라인 객체 추적을 수행한다. MOSSE 추적 알고리즘은 상관 필터와 필터 업데이트라는 개념을 최초로 도입하였다. 첫 번째 프레임의 목표 객체 영역을 사용하여

흐림, 객체 외형 변환, 빠른 움직임과 같은 다양한 실세계 환경변화 문제에 적용하며 추적하는 필터를 생성한다[11].

기존 상관 필터 알고리즘은 수작업 특징(Hand-crafted Feature)을 추출하여 객체 추적에 사용하였다. 이러한 특징은 특징 추출에 사용된 알고리즘 및 해당 수학적 수식에 의존하기 때문에 추출된 특징에 포함된 정보가 한정되어 객체 세밀한 객체 표현이 불가능하다는 단점을 지니고 있다. 객체 표현이 충분하지 않을 경우 유사도 비교 문제에 낮은 성능을 보여주어 추적 정확도 성능에 영향을 준다.

심층 네트워크 모델을 사용한 다양한 방법론들이 제시되었다[12]. 심층 특징을 사용하여 추적 과정 중에 필터 또는 모델에 대해 온라인 업데이트의 필요성이 상대적으로 감소하였다. 심층 특징 기반 상관 필터 알고리즘은 네트워크 모델의 견고성을 향상시키는 결과를 보여주었다. 상관 필터링 알고리즘과 심층 특징의 결합은 수작업 특징 방식보다 더 우수한 추적 정확도를 보여주었다. C-COT[13] 알고리즘은 DCF 알고리즘이 정적 기반 단일 해상도 특징 매핑에만 초점을 맞추고 있어 외형이 가변적인 상황에는 적용하기 어려운 점을 해결하기 위해 연구되었다. C-COT는 DCF를 기반으로 연속 컨볼루션 필터를 훈련하는 새로운 방법론을 도입하였다. ECO[14] 알고리즘은 C-COT를 개선하여 속도 문제를 해결하였다. 기존 수작업 특징을 결합한 추적 알고리즘보다 우수한 성능을 얻었지만 네트워크 모델을 사용함에 따라 추적 정확도와 속도 측면에서 상충이 발생하였다. 이를 해결하기 위해 삼 네트워크 추적 알고리즘이 제안되었다. 목표 객체의 영역과 찾기 영역 사이에 대해 유사성 비교로 추적이 이루어지며, 유사성 비교에 최적화된 모듈로 학습하기 위해 대형 데이터 세트를 사용하여 네트워크를 교육하는 방식으로 연구가 진행되었다.

2.2 Siamese Network 추적

삼 네트워크를 기본 아키텍처로 구성한 객체 추적 모델은 목표 영역과 검색 영역 간의 매칭 방법에 다양한 방법론이 적용되었다[15]. 초기 SiamFC는 추적 문제에 가중치가 공유되는 분기 구조를 적용하여 입력된 이미지에서 특징을 추출한다. 각각의 이미지에서 추출된 특징은 공유된 가중치를 통과하므로 이미지

유사도에 따라 특징의 형태가 서로 비슷하다. 이러한 개념을 차용하여 상호 상관 작업을 통해 유사성 맵을 구성한다. SiamFC는 별도의 모델 업데이트 없이 데이터셋을 통해 학습된 모델로 전체 프레임에서 추적이 진행된다. 추적 과정에서 초기에 주어진 목표 객체의 이미지를 템플릿으로 사용하기 때문에 연속된 프레임에서 목표 객체의 외형이 크게 변할 때 낮은 성능을 보여준다. SiamFC의 구조가 고전적인 추적 방법보다 정확도와 속도측면에서 더 높은 효율성을 보여주므로 삼 구조의 방법론이 주류가 되고 있다.

기존 얇은 AlexNet을 대체하여 더 깊은 ResNet을 Siamese 기반 추적기의 백본 추출 네트워크로 도입하기 시작했다. 삼 네트워크를 사용한 추적알고리즘의 정확도를 높이기 위해 다양한 모듈을 적용한 연구가 진행되었다. 목표 영역 추론을 위해 삼 네트워크 데이터 결합 부분에 RPN(Region Proposal Network) 모듈을 추가한 SiamRPN이 제안되었다. 목표 객체 존재 여부 및 영역을 추론하기 위해 상향 채널 교차 상관 방법이 적용됐다. 하지만, 상향 채널 교차 상관 모듈은 많은 매개변수가 포함되어 성능 하락 문제가 발생한다. 단일 매칭 접근 방식은 복잡한 실제 환경에서 안정적인 추적을 보장하기 어렵기 때문에 전통적인 상호 상관 연산을 대체하기 위해 6개의 서로 다른 매칭 연산자를 제안했다[16]. 연산자를 결합하여 상호 보완적인 특징을 탐색하고, 구조적 검색 방법을 사용하여 가장 적합한 연산자 조합을 선택한다.

III. 제안하는 추적 알고리즘

3.1 제안하는 Siamese Network 아키텍처

그림 1은 객체 추적을 위해 구성한 삼 네트워크를 보여준다. 특징 추출에 사용한 백본(Backbone) 네트워크는 100만장 이상의 이미지로 구성된 ImageNet 1000 class 분류 데이터셋으로 학습된 Resnet-52를 사용했다[17]. 대량의 이미지로 사전 학습된 네트워크를 사용함으로써 최적화된 컨볼루션 레이어의 가중치 파라미터를 사용한다. 네트워크의 입력으로 목표 객체(Target Object) 이미지와 찾기 영역(Search Region) 두장의 이미지가 사용된다. 각 이미지는 백본 네트워크를 통과하며 특징맵으로 변환된다. 각 특징맵은 동

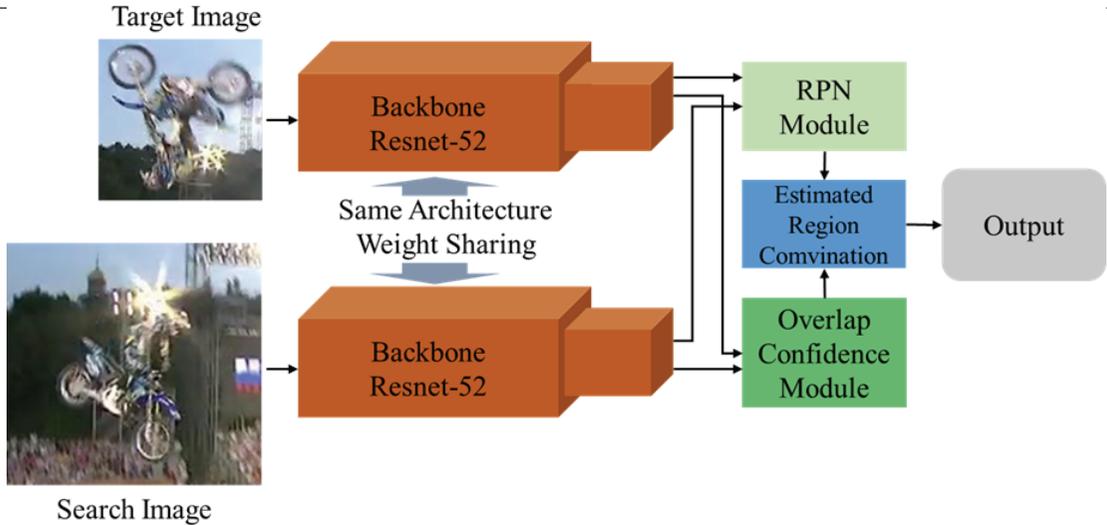


그림 1. 제안하는 추적 알고리즘 구조도
 Fig. 1 Architecture of proposed tracking algorithm

일한 구조 네트워크의 동일한 컨볼루션 레이어를 통과하며 동일한 가중치 값으로 계산되기 때문에 유사한 이미지 또는 유사한 객체가 포함된 이미지일 경우 출력된 특징맵의 형태 또한 유사성이 높은 값으로 구성된다.

백본 네트워크에서 출력된 목표 객체 및 찾기 영역의 특징맵은 객체의 영역을 추론하기 위해 RPN 모듈과 중첩 신뢰도 모듈(Overlap Confidence Module)로 각각 입력된다. RPN 모듈은 Fster R-CNN에서 객체 검출에 사용하기 위해 제안된 모듈이다[18]. RPN은 목표 특징맵과 목표를 찾을 영역 특징맵을 입력으로 받는다. 목표 객체의 특징맵은 컨볼루션 필터로 사용되어 찾기 영역에서 객체의 영역을 추론한다. RPN은 객체의 영역을 나타내는 바운딩 박스(Bounding Box)의 좌표를 추론하고, 각 박스내부에 객체가 존재하는지를 판별한다. 도출되는 각 박스 값은 중점 X, Y 좌표와 넓이 높이 값으로 정의된다. RPN은 레이블이 지정된 데이터로 기준 좌표와의 에러를 감소하는 방향으로 학습되어진다. 박스에 지정된 레이블은 1, 0, -1로 구성된다. 1은 객체와 상당부분 중첩됨을 의미하고, 0은 객체와 거의 중첩되지 않음을 의미한다. -1은 1 또는 0에 속하지 않으며 네트워크 학습에 혼란을 주는 레이블로서 학습 과정에서 제외된다. 각 박스는 객체가 존재여부를 판별하기 위해 0과 1사이의 확률 값이 도출된다. 0에 근접할수록 배경을 의미하고 1에

근접할수록 객체가 상당부분 포함되어 있다고 판별한다. 중첩 신뢰도 모듈은 특징맵 내부에서 객체 영역을 추론하는데 사용되는 서브 모듈로 사용된다.

3.2 중첩 신뢰도 모듈

네트워크를 통과한 이미지는 그림 2와 같이 특징맵으로 변환되고 원본 이미지와 크기가 상이하다.

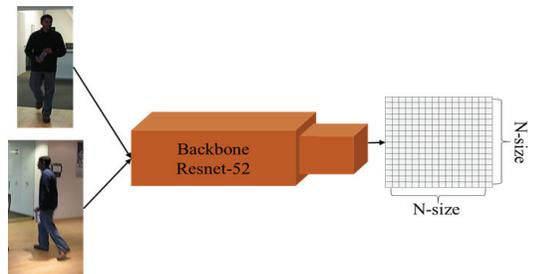


그림 2. 네트워크를 통과하며 양자화된 좌표
 Fig. 2 Quantized coordinates passed through network

입력 이미지의 사이즈가 255×255이고 출력 특징맵의 사이즈가 16×16일 때, 출력 특징맵의 사이즈는 입력 이미지보다 약 16배 작아진 것을 알 수 있다. 또한, 특징맵의 한 셀(Cell)이 포함하는 입력 이미지의 범위는 약 30픽셀의 범위를 포함한다. 각 좌표는 양자화(Quantization)되어 있으므로 특징맵의 정보를 기준으로 원본 이미지의 객체 영역의 좌표와 매핑 작업이

필수적이다. 따라서 지역화(Localization) 객체 영역의 신뢰도를 획득하여 정확하게 객체의 영역을 보존하기 위한 작업이 수행된다.

중첩 신뢰도 모듈을 통해 도출된 각 지역화 영역의 신뢰도를 최대화하는 방식으로 모듈을 학습함으로써 최종 객체 영역을 결정할 수 있다. 모듈은 Precise ROI Pooling[19] 레이어를 사용하여 지역화를 위한 특징맵으로 변환한다. 추출된 특징맵에 쌍선형 보간을 적용하여 영역 좌표를 도출한다. 도출된 좌표와 레이블 좌표와의 비교를 통해 중첩도 신뢰도를 계산하고 신뢰도를 상승시키는 방식으로 모듈을 훈련한다.

IV. 실험

4.1 실험 환경

본 논문에서 제안한 추적 알고리즘의 성능을 검증하였다. 실험이 수행된 하드웨어 및 소프트웨어 환경은 표 1에서 보여준다. 네트워크의 설계, 학습, 검증 과정은 Python 언어로 구성된 Pytorch 프레임워크를 사용하여 수행되었다. 알고리즘은 ILSVRC(ImageNet Large Scale Visual Recognition) Video 데이터셋을 사용하여 객체 영역 추론을 위해 RPN 모듈과 중첩 신뢰도 모듈을 학습하였다.

표 1. 실험 환경 상세
Table 1. Specification of experiment environment

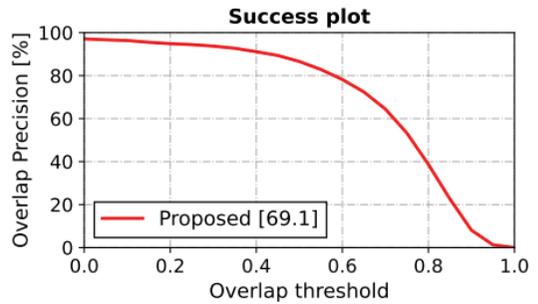
Item		Version
Hardware	O/S	Ubuntu 18.04
	CPU	impossible
	RAM	32G
	GPU	Nvidia 4090GTX
Software	Framework	Pytorch 1.8

4.2 실험 결과

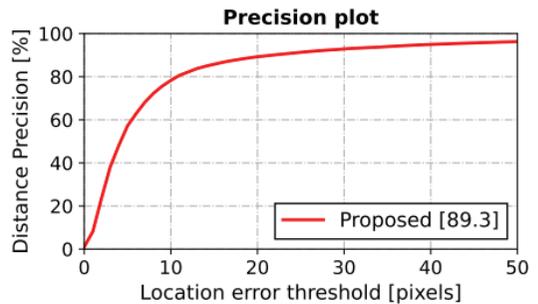
추적 알고리즘의 성능평가는 SV(Scale Variation), LR(Low Resolution), OPR(Out-of-Plane Rotation), MB(Motion Blur), OV(Out of View), OCC(Occlusion), BC(Background Cluttered), IV(Illumination Variation), IPR(In-plane Rotation), FM(Fast Motion), DEF(Deformation)과 같이 11가지 속성으로 구성된 OTB(Object Tracking Benchmark) 데이터셋을 사용하였다[20]. 데이터셋은 50개의 비디오로 구성되어 있고 개별

프레임으로 분리되어 있다. 각 비디오에는 1가지 이상의 속성이 포함되어 있다. 평가를 위해 사용된 비교 대상 추적 알고리즘은 동일한 데이터셋을 사용한 알고리즘을 대상으로 검증을 진행하였다.

알고리즘 성능 평가는 정량적, 정성적 지표를 사용하여 진행하였다. 정량적 평가는 Precision과 Success로 구성된 OPE(One Passe Evaluation) 지표를 사용하였다. Precision은 중첩 좌표 에러를 나타내는 지표로 추론된 객체의 영역과 레이블인 GT(Ground Truth)영역 사이의 중심 좌표 사이의 픽셀 거리를 나타낸다. Success는 추론된 객체의 영역과 GT영역 사이의 중첩 정확도를 나타낸다.



(a) Result of success plot



(b) Result of precision plot

그림 3. 추적 알고리즘 성능 평가 그래프
Fig. 3 Results of graph of tracking performance evaluation

그림 3은 OTB 데이터셋을 사용한 제안한 추적 알고리즘의 정량적 평가 결과를 보여준다. 그림 3(a)은 중첩률 결과이고, 그림 3(b)은 중첩 에러율을 나타낸다. 중첩률 그래프의 X축은 0.0~1.0 사이로 중첩도를 나타내며, Y축은 해당 중첩 도에 따른 비율을 나타낸다. 중첩 에러율 그래프의 X축은 0~50 사이의 임계

값을 나타낸다. Y축은 각 임계값에 포함된 비율을 나타낸다. 제안하는 알고리즘은 중첩률에서 69.1, 중첩 에러율에서 89.3을 달성하였다.

표 2. OTB 데이터셋을 사용한 알고리즘 비교
Table 2. Comparison with tracking algorithm on the OTB Dataset

	Proposed	SiamRPN	ECO
Success	69.1%	63.7%	68.6%
Precision	89.3%	85.1%	90.2%

표 2는 동일한 평가 데이터셋을 사용한 알고리즘과의 정량적 평가 결과를 보여준다. 제안하는 알고리즘은 중첩률 지표에서는 69.1%를 달성하며 63.7%를 달성한 SiamRPN, 68.6%를 달성한 ECO보다 각각 5.4%, 0.5% 높은 결과를 보여주었다. 중첩 에러율에서는 SiamRPN보다 4.2% 큰 89.3%를 달성했지만, ECO 알고리즘이 0.9% 높은 90.2%를 달성하였다. 이러한 결과로 단순히 RPN만 적용된 방법보다 추가 모듈을 통해 추론된 객체 영역을 보정하는 방법이 더 좋은 성능을 보여줌을 알 수 있었다.

V. 결 론

본 논문에서는 RPN 모듈과 중첩 신뢰도 모듈을 결합한 CNN 기반 삼 네트워크 추적 알고리즘을 제안하였다. 제안한 알고리즘의 핵심은 객체 영역 추론 정확도를 향상하기 위해 RPN의 추론된 객체 영역과 학습을 통해 중첩률을 향상시키는 중첩 신뢰도 모듈이다. 이러한 결과를 통해 목표 객체 영역 추론에 단순히 객체가 존재 여부 값에 의존하지 않고 중첩률이 높은 영역과의 교차 결합을 통해 최종 영역을 결정함으로써 추적 정확도를 향상할 수 있었다. OTB 데이터셋을 사용한 정량적 평가 결과로 Success에서 69.1%, Precision에서 89.3%를 달성하였다. 향후 연구로 배경과 목표 객체 영역 구분을 위한 집중(Attention) 모듈을 도입하여 정확도를 향상하는 방법에 관한 연구를 진행하고자 한다.

감사의 글

본 논문은 2022년도 순천대학교 학술연구비 공모프로젝트로 연구되었음.

References

- [1] S. Kim, S. Lim, and D. Kim, "Intelligent Intrusion Detection System Featuring a Virtual Fence, Active Intruder Detection, Classification, Tracking, and Action Recognition," *Annals of Nuclear Energy*, vol. 112, Feb. 2018, pp. 845-855.
- [2] C. Ma, J. B. Huang, X. Yang, and M. H. Yang, "Hierarchical Convolutional Features for Visual Tracking," In *Proc. IEEE Int. Conf. on Computer Vision*, Santiago, Chile, Dec. 2015, pp. 3074-3082.
- [3] P. Li, D. Wang, L. Wang, and H. Lu, "Deep visual tracking: review and experimental comparison," *Pattern Recognition*, vol. 76, Apr. 2018, pp. 323-338.
- [4] S. Lim and D. Kim, "Semantic Segmentation using Convolutional Neural Network with Conditional Random Field," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 12, no. 3, June 2017, pp. 451-456.
- [5] O. Khin and S. Lee, "Feature Extraction and Recognition of Myanmar Characters Based on Deep Learning," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 17, no. 5, 2023, pp. 977-984.
- [6] M. Choi and M. Moon, "Analysis System for Public Interest Report Video of Traffic Law Violation based on Deep Learning Algorithms," *J. of the Korea Institute of Electronic Communication Sciences*, vol. 18, no. 1, 2023, pp. 63-70.
- [7] L. Bertinetto, J. Valmadre, J. F. Henriques, A. Vedaldi, and P.-H. Torr, "Fully-Convolutional Siamese Networks for Object Tracking," In *European Conf. on Computer Vision*, Amsterdam, Netherlands, Oct 2016, pp. 850-865.
- [8] J. Valmadre, L. Bertinetto, J. F. Henriques, A. Vedaldi, and P.H. Torr, "End-to-end representation learning for correlation filter based tracking," In *Proc. IEEE conf. on computer vision and pattern recognition*, Honolulu, Hawaii, July 2017, pp. 2805-2813.

- [9] Q. Guo, W. Feng, C. Zhou, R. Huang, L. Wan, and S. Wang, "Learning dynamic siamese network for visual object tracking," In *Proc. IEEE Int. Conf. on Computer Vision*, Venice, Italy, Oct 2017, pp. 1763-1771.
- [10] B. Li, J. Yan, W. Wu, Z. Zhu, and X. Hu, "High performance visual tracking with siamese region proposal network," In *Proc. IEEE Conf. on computer vision and pattern recognition*, Salt Lake City, USA, June 2018, pp. 8971-8980.
- [11] D. S. Bolme, J. R. Beveridge, B. A. Draper, and Y. M. Lui, "Visual object tracking using adaptive correlation filters," In *Proc. IEEE Computer Society Conf. on Computer Vision and Pattern Recognition*, San Francisco, CA, USA, June 2010, pp. 2544-2550.
- [12] S. Lim and D. Kim, "Object Tracking Using Feature Map from Convolutional Neural Network," *J. of Korea Multimedia Society*, Feb. 2017, vol. 20, no. 2, pp. 126-133.
- [13] M. Danelljan, A. Robinson, F. Shahbaz Khan, and M. Felsberg, "Beyond correlation filters: Learning continuous convolution operators for visual tracking," In *European Conf. on Computer Vision*, Amsterdam, Netherlands, Oct 2016, pp. 472-488.
- [14] M. Danelljan, G. Bhat, F. Shahbaz Khan, and M. Felsberg, "Eco: Efficient convolution operators for tracking," In *Proc. IEEE conf. on computer vision and pattern recognition*, Honolulu, Hawaii, July 2017, pp. 6638-6646.
- [15] S. Lim and D. Kim, "Object Tracking Using Feature Map from Convolutional Neural Network," *J. of Korea Multimedia Society*, Feb. 2022, vol. 25, no. 2, pp. 247-256.
- [16] Z. Zhang, Y. Liu, X. Wang, B. Li, and W. Hu, "Learn to match: Automatic matching network design for visual tracking," In *Proc. IEEE/CVF Int. Conf. on Computer Vision*, Montreal, BC, Canada, Oct. 2021, pp. 13339-13348.
- [17] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," In *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*, June 2016, Las Vegas, NV, USA, pp. 770-778.
- [18] S. Ren, K. He, R. Girshick, and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *Advances in Neural Information Processing Systems*, Montreal, Canada, Dec. 2015, pp. 91-99.
- [19] B. Jiang, R. Luo, J. Mao, T. Xiao, and Y. Jiang, "Acquisition of localization confidence for accurate object detection," In *Proc. European Conf. on Computer Vision*, Munich, Germany, Sept. 2018, pp. 784-799.
- [20] Y. Wu, J. Lim, and M. H. Yang, "Online object tracking: A benchmark," In *Proc. IEEE Conf. on Computer Vision and Pattern Recognition*, Portland, OR, USA, June 2013, pp. 2411 - 2418.

저자 소개

임수창(Su-Chang Lim)



2015년 순천대학교 컴퓨터공학과 졸업(공학사)

2017년 순천대학교 대학원 컴퓨터공학과 졸업(공학석사)

2022년 순천대학교 대학원 컴퓨터공학과 졸업(공학박사)

2020년 ~ 현재 ㈜티이에프 기업부설연구소 연구소장

※ 관심분야 : 인공지능, 컴퓨터비전, 딥러닝, 객체 추적, 시계열 데이터 분석 및 예측

김종찬(Jong-Chan Kim)



2000년 순천대학교 컴퓨터공학과 졸업(이학사)

2002년 순천대학교 대학원 컴퓨터공학과 졸업(이학석사)

2007년 순천대학교 대학원 컴퓨터공학과 졸업(이학박사)

2013년 서울대학교 자동차 시스템 연구소 선임연구원

2021년 ~ 현재 순천대학교 컴퓨터공학과 조교수

※ 관심분야 : 영상처리, HCI, 콘텐츠, 컴퓨터그래픽스, 기계학습, 객체추적, 컴퓨터비전, 데이터 분석 및 예측

