(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0103172
(43) 공개일자 2025년07월07일

(51) 국제특허분류(Int. Cl.)
G06T 3/40 (2024.01) *G06N 3/0475* (2023.01)
G06T 5/60 (2024.01) *G06T 7/00* (2017.01)
G06T 7/11 (2017.01)
(52) CPC특허분류
G06T 3/4076 (2024.01)
G06N 3/0475 (2023.01)
(21) 출원번호 10-2023-0195595
(22) 출원일자 2023년12월28일
심사청구일자 2023년12월28일

(71) 출원인
국립창원대학교 산학협력단
경상남도 창원시 의창구 창원대학로 20(퇴촌동)
(72) 발명자
권오설
경상남도 창원시 의창구 중동로 78, 411동 2702호 (중동, 창원 중동 유니시티)
최홍림
경상남도 김해시 월산로 112-56, 905동 902호 (부곡동, 월산마을부영아파트)
(74) 대리인
김종선, 이형석

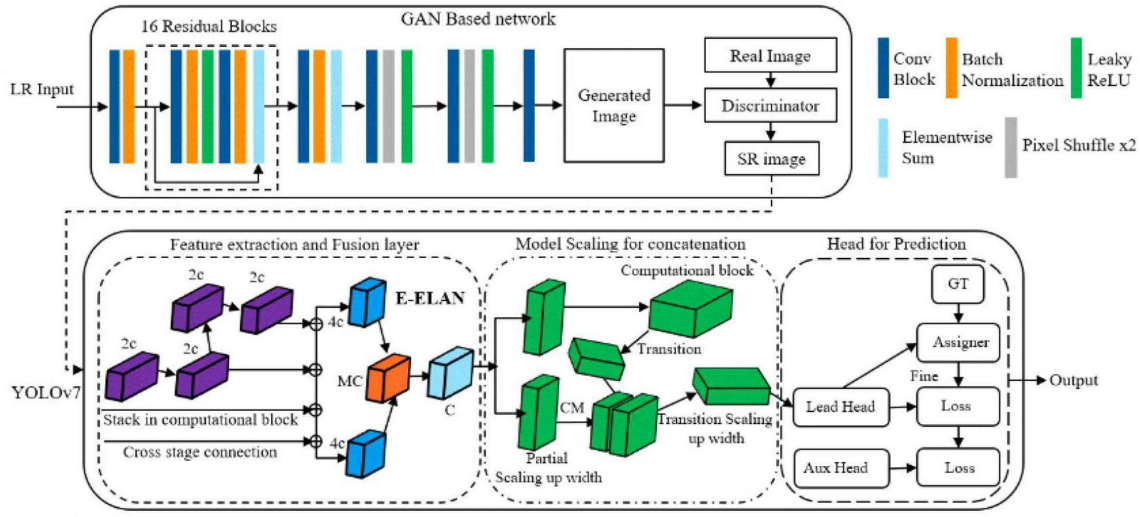
전체 청구항 수 : 총 12 항

(54) 발명의 명칭 **원격 감지 영상에서 초소형 객체 검출 기법 및 장치**

(57) 요 약

본 발명은 객체 검출 장치 및 방법에 관한 것으로, 보다 구체적으로는 입력된 저해상도 영상을 고해상도 영상으로 변환하는 초해상도 적용부; 상기 고해상도 영상에서 객체를 검출하는 객체 검출부; 상기 객체가 포함된 영역을 관심영역으로 선택하는 영역선택부; 및 상기 관심영역을 출력하기 위해 저장하는 출력영상 저장부를 포함하며, 하나의 단계로 초고해상화 및 검출의 기능을 수행할 수 있다.

대 표 도



(52) CPC특허분류
G06T 5/60 (2024.01)
G06T 7/11 (2017.01)
G06T 7/97 (2017.01)
G06T 2207/20081 (2013.01)
G06T 2207/20084 (2013.01)
G06T 2210/12 (2013.01)

이 발명을 지원한 국가연구개발사업
과제고유번호 1345356160
과제번호 LINC3.0-2022-65
부처명 교육부
과제관리(전문)기관명 한국연구재단
연구사업명 3단계산학연협력선도대학육성사업(LINC3.0)
연구과제명 위성영상 관제시스템을 위한 초소형 차량검출 시스템 개발
기 여 율 1/2
과제수행기관명 창원대학교
연구기간 2023.03.01 ~ 2024.02.28
이 발명을 지원한 국가연구개발사업
과제고유번호 3311946000
과제번호 S3311946
부처명 중소벤처기업부
과제관리(전문)기관명 중소기업기술정보진흥원
연구사업명 산학연플랫폼사업
연구과제명 스마트팩토리를 위한 딥러닝 기반의 자율주행 모빌리티 개발
기 여 율 1/2
과제수행기관명 창원대학교 산학협력단
연구기간 2023.01.01 ~ 2023.12.31

명 세 서

청구범위

청구항 1

입력된 저해상도 영상을 고해상도 영상으로 변환하는 초해상도 적용부;

상기 고해상도 영상에서 객체를 검출하는 객체 검출부;

상기 객체가 포함된 영역을 관심영역으로 선택하는 영역선택부; 및

상기 관심영역을 출력하기 위해 저장하는 출력영상 저장부;

를 포함하는 객체 검출 장치.

청구항 2

제1항에 있어서,

상기 초해상도 적용부는 생성적 적대 네트워크(Generative Adversarial Network, GAN)를 이용하여 해상도를 향상시키는 것을 특징으로 하는 객체 검출 장치.

청구항 3

제1항에 있어서,

상기 객체 검출부는,

상기 고해상도 영상을 복수의 그리드로 분할하는 그리드 분할부;

상기 그리드에 대해 합성곱 연산을 기반으로 객체를 검출하는 합성곱 모델 적용부; 및

상기 객체가 포함된 영역에 대해 경계상자(bounding box)를 설정하고, 클래스 확률(class probabilities)을 예측하는 객체예측부;

를 포함하는 것을 특징으로 하는 객체 검출 장치.

청구항 4

제3항에 있어서,

상기 합성곱 모델 적용부는,

사전에 학습된 데이터 세트의 가중치로부터 제1 데이터 세트를 전이학습으로 훈련시키는 전이학습부;

상기 제1 데이터 세트와 동일한 종류의 제2 데이터 세트를 커리큘럼 학습 방법으로 학습하는 커리큘럼 학습부;

상기 제2 데이터 세트에 대한 손실함수를 계산하고, 학습을 완료할지 판단하는 손실함수 판단부; 및

상기 객체를 검출하기 위한 파라미터를 결정하여 상기 객체를 검출하는 파라미터 결정부;

를 포함하는 것을 특징으로 하는 객체 검출 장치.

청구항 5

제4항에 있어서,

상기 전이학습부는,

전이학습을 수행하기 위하여 사전 학습된 데이터 세트 및 가중치를 선택하는 사전 데이터 선택부;

상기 사전 학습된 데이터 세트 및 가중치를 이용하여 상기 제1 데이터 세트를 전이학습 기법으로 학습하는 선행 학습부; 및

상기 전이학습를 기반으로 획득한 가중치를 제1 파라미터로 저장하는 제1 파라미터 저장부;

를 포함하는 것을 특징으로 하는 객체 검출 장치.

청구항 6

제4항에 있어서,

상기 커리큘럼 학습부는,

학습을 위한 상기 제2 데이터 세트를 추가하는 학습데이터 추가부;

커리큘럼 학습 기법을 이용하여 학습을 수행하는 네트워크 학습부;

상기 제1 데이터 세트와 상기 제2 데이터 세트 간의 오차를 판단하는 오차 판단부; 및

상기 커리큘럼 학습에서 도출된 가중치를 제2 파라미터로 저장하는 제2 파라미터 저장부;

를 포함하며,

상기 오차 판단부는 상기 오차가 임계값 이하가 되도록 제3 내지 제 N 데이터 세트를 추가하여 반복 학습을 수행하는 것을 특징으로 하는 객체 검출 장치.

청구항 7

초해상도 적용부에서 입력된 저해상도 영상을 고해상도 영상으로 변환하는 단계;

객체 검출부에서 상기 고해상도 영상에서 객체를 검출하는 단계;

영역선택부에서 상기 객체가 포함된 영역을 관심영역으로 선택하는 단계; 및

출력영상 저장부에서 상기 관심영역을 출력하기 위해 저장하는 단계;

를 포함하는 객체 검출 방법.

청구항 8

제7항에 있어서,

상기 고해상도 영상으로 변환하는 단계는 생성적 적대 네트워크(Generative Adversarial Network, GAN)를 이용하여 해상도를 향상시키는 것을 특징으로 하는 객체 검출 방법.

청구항 9

제7항에 있어서,

상기 객체를 검출하는 단계는,

그리드 분할부에서 상기 고해상도 영상을 복수의 그리드로 분할하는 단계;

합성곱 모델 적용부에서 상기 그리드에 대해 합성곱 연산을 기반으로 객체를 검출하는 단계; 및

객체예측부에서 상기 객체가 포함된 영역에 대해 경계상자(bounding box)를 설정하고, 클래스 확률(class

probabilities)을 예측하는 단계;

를 포함하는 것을 특징으로 하는 객체 검출 방법.

청구항 10

제7항에 있어서,

상기 합성곱 연산을 기반으로 객체를 검출하는 단계는,

전이학습부에서 사전에 학습된 데이터 세트의 가중치로부터 제1 데이터 세트를 전이학습으로 훈련시키는 단계;

커리큘럼 학습부에서 상기 제1 데이터 세트와 동일한 종류의 제2 데이터 세트를 커리큘럼 학습 방법으로 학습하는 단계;

손실함수 판단부에서 상기 제2 데이터 세트에 대한 손실함수를 계산하고, 학습을 완료할지 판단하는 단계; 및

파라미터 결정부에서 상기 객체를 검출하기 위한 파라미터를 결정하여 상기 객체를 검출하는 단계;

를 포함하는 것을 특징으로 하는 객체 검출 방법.

청구항 11

제10항에 있어서,

상기 전이학습으로 훈련시키는 단계는,

사전 데이터 선택부에서 전이학습을 수행하기 위하여 사전 학습된 데이터 세트 및 가중치를 선택하는 단계;

선행 학습부에서 상기 사전 학습된 데이터 세트 및 가중치를 이용하여 상기 제1 데이터 세트를 전이학습 기법으로 학습하는 단계; 및

제1 파라미터 저장부에서 상기 전이학습을 기반으로 획득한 가중치를 제1 파라미터로 저장하는 단계;

를 포함하는 것을 특징으로 하는 객체 검출 방법.

청구항 12

제10항에 있어서,

상기 커리큘럼 학습 방법으로 학습하는 단계는,

학습데이터 추가부 학습을 위한 상기 제2 데이터 세트를 추가하는 단계;

네트워크 학습부 커리큘럼 학습 기법을 이용하여 학습을 수행하는 단계;

오차 판단부에서 상기 제1 데이터 세트와 상기 제2 데이터 세트 간의 오차를 판단하는 단계; 및

제2 파라미터 저장부에서 상기 커리큘럼 학습에서 도출된 가중치를 제2 파라미터로 저장하는 단계;

를 포함하며,

상기 오차를 판단하는 단계는 상기 오차가 임계값 이하가 되도록 제3 내지 제 N 데이터 세트를 추가하여 상기 커리큘럼 학습을 반복 수행하는 것을 특징으로 하는 객체 검출 방법.

발명의 설명

기 술 분 야

[0001] 본 발명은 객체 검출 장치 및 방법에 관한 것으로, 구체적으로는 교차 전이학습에 기반한 딥러닝 네트워크 알고

리즘을 이용하여 원격 감지 영상 내에 포함되어 있는 초소형 객체를 검출하는 장치 및 방법에 관한 것이다.

배 경 기 술

[0002] 객체 탐지는 영상 또는 비디오에서 객체를 식별하고 위치를 검출하는 것으로써, 자율주행, 보안 시스템, 산업용 로봇, 원격 감지 및 비디오 감시를 포함한 다양한 분야에서 활용되고 있다. 이 가운데 항공 및 위성 영상에서 초소형의 객체를 인식하는 것은 여전히 해결해야 하는 문제가 많다.

[0003] 이것은 객체에 대한 크기가 일반 영상과 달리 매우 작을 뿐만 아니라 학습에 필요한 데이터의 수가 상대적으로 매우 제한적이기 때문이다. 따라서 위성 영상과 같은 초저해상도 영상에서 객체 인식을 개선하는 데 사용할 수 있는 방법들이 연구되고 있다.

[0004] 일반적인 영상 인식과는 달리 초해상도의 객체 인식은 두 가지 단계가 필요하다. 먼저 초고해상도 기법으로써 이는 영상의 해상도를 높이는 과정이다. 이 방법은 가능한 많은 디테일을 유지하면서 저해상도 영상에서 고해상도 영상을 생성하는 해야 한다. 다음은 객체 인식 과정으로 입력 영상의 정보를 바탕으로 객체를 식별하는 것이다.

[0005] 그러나, 실시간으로 객체를 검출하기 위해서는 초고해상도 기법으로 영상의 해상도를 높임과 동시에 객체를 식별하여야 하기 위한 방법은 아직 제시되고 있지 않다.

선행기술문헌

특허문헌

[0006] (특허문헌 0001) 대한민국 공개특허공보 제10-2021-0089314호 (2021년 7월 16일 공개)

발명의 내용

해결하려는 과제

[0007] 본 발명은 상기 기술적 과제에 대한 문제점을 해결하기 위한 것으로, 초소형객체의 검출 정확도를 향상시키기 위해 최적화된 적대적 생성 네트워크와 객체 인식을 결합하여 하나의 네트워크로 최적화하여 해상도 향상 및 객체 검출을 하나의 네트워크에서 동시에 진행할 수 있는 객체 검출 장치 및 방법을 제공하는데 그 목적이 있다.

[0008] 다른 측면에서 본 발명은 적은 수의 학습 데이터를 가진 조건에서 객체 인식을 위한 네트워크 학습을 진행하는 장치 및 방법을 제공하는데 그 목적이 있다.

과제의 해결 수단

[0009] 상기 기술적 과제를 해결하기 위한 본 발명의 일 실시예에 따른 객체 검출 장치는 입력된 저해상도 영상을 고해상도 영상으로 변환하는 초해상도 적용부; 상기 고해상도 영상에서 객체를 검출하는 객체 검출부; 상기 객체가 포함된 영역을 관심영역으로 선택하는 영역선택부; 및 상기 관심영역을 출력하기 위해 저장하는 출력영상 저장부를 포함할 수 있다.

[0010] 또한, 상기 초해상도 적용부는 생성적 적대 네트워크(Generative Adversarial Network, GAN)를 이용하여 해상도를 향상시킬 수 있다.

[0011] 또한, 상기 객체 검출부는 상기 고해상도 영상을 복수의 그리드로 분할하는 그리드 분할부; 상기 그리드에 대해 합성곱 연산을 기반으로 객체를 검출하는 합성곱 모델 적용부; 및 상기 객체가 포함된 영역에 대해 경계상자(bounding box)를 설정하고, 클래스 확률(class probabilities)을 예측하는 객체예측부를 포함할 수 있다.

[0012] 또한, 상기 합성곱 모델 적용부는 사전에 학습된 데이터 세트의 가중치로부터 제1 데이터 세트를 전이학습으로 훈련시키는 전이학습부; 상기 제1 데이터 세트와 동일한 종류의 제2 데이터 세트를 커리큘럼 학습 방법으로 학습하는 커리큘럼 학습부; 상기 제2 데이터 세트에 대한 손실함수를 계산하고, 학습을 완료할지 판단하는 손실함수 판단부; 및 상기 객체를 검출하기 위한 파라미터를 결정하여 상기 객체를 검출하는 파라미터 결정부를 포함할 수 있다.

[0013] 또한, 상기 전이학습부는 전이학습을 수행하기 위하여 사전 학습된 데이터 세트 및 가중치를 선택하는 사전 데

이터 선택부; 상기 사전 학습된 데이터 세트 및 가중치를 이용하여 상기 제1 데이터 세트를 전이학습 기법으로 학습하는 선행 학습부; 및 상기 전이학습를 기반으로 획득한 가중치를 제1 파라미터로 저장하는 제1 파라미터 저장부를 포함할 수 있다.

[0014] 또한, 상기 커리큘럼 학습부는 학습을 위한 상기 제2 데이터 세트를 추가하는 학습데이터 추가부; 커리큘럼 학습 기법을 이용하여 학습을 수행하는 네트워크 학습부; 상기 제1 데이터 세트와 상기 제2 데이터 세트 간의 오차를 판단하는 오차 판단부; 및 상기 커리큘럼 학습에서 도출된 가중치를 제2 파라미터로 저장하는 제2 파라미터 저장부를 포함하며, 상기 오차 판단부는 상기 오차가 임계값 이하가 되도록 제3 내지 제 N 데이터 세트를 추가하여 반복 학습을 수행할 수 있다.

[0015] 또 다른 측면에서 상기 기술적 과제를 해결하기 위한 본 발명의 일 실시예에 따른 객체 검출 방법은 초해상도 적용부에서 입력된 저해상도 영상을 고해상도 영상으로 변환하는 단계; 객체 검출부에서 상기 고해상도 영상에서 객체를 검출하는 단계; 영역선택부에서 상기 객체가 포함된 영역을 관심영역으로 선택하는 단계; 및 출력영상 저장부에서 상기 관심영역을 출력하기 위해 저장하는 단계를 포함할 수 있다.

[0016] 또한, 상기 고해상도 영상으로 변환하는 단계는 생성적 적대 네트워크(Generative Adversarial Network, GAN)를 이용하여 해상도를 향상시킬 수 있다.

[0017] 또한, 상기 객체를 검출하는 단계는 그리드 분할부에서 상기 고해상도 영상을 복수의 그리드로 분할하는 단계; 합성곱 모델 적용부에서 상기 그리드에 대해 합성곱 연산을 기반으로 객체를 검출하는 단계; 및 객체예측부에서 상기 객체가 포함된 영역에 대해 경계상자(bounding box)를 설정하고, 클래스 확률(class probabilities)을 예측하는 단계를 포함할 수 있다.

[0018] 또한, 상기 합성곱 연산을 기반으로 객체를 검출하는 단계는 전이학습부에서 사전에 학습된 데이터 세트의 가중치로부터 제1 데이터 세트를 전이학습으로 훈련시키는 단계; 커리큘럼 학습부에서 상기 제1 데이터 세트와 동일한 종류의 제2 데이터 세트를 커리큘럼 학습 방법으로 학습하는 단계; 손실함수 판단부에서 상기 제2 데이터 세트에 대한 손실함수를 계산하고, 학습을 완료할지 판단하는 단계; 및 파라미터 결정부에서 상기 객체를 검출하기 위한 파라미터를 결정하여 상기 객체를 검출하는 단계를 포함할 수 있다.

[0019] 또한, 상기 전이학습으로 훈련시키는 단계는 사전 데이터 선택부에서 전이학습을 수행하기 위하여 사전 학습된 데이터 세트 및 가중치를 선택하는 단계; 선행 학습부에서 상기 사전 학습된 데이터 세트 및 가중치를 이용하여 상기 제1 데이터 세트를 전이학습 기법으로 학습하는 단계; 및 제1 파라미터 저장부에서 상기 전이학습을 기반으로 획득한 가중치를 제1 파라미터로 저장하는 단계를 포함할 수 있다.

[0020] 또한, 상기 커리큘럼 학습 방법으로 학습하는 단계는 학습데이터 추가부 학습을 위한 상기 제2 데이터 세트를 추가하는 단계; 네트워크 학습부 커리큘럼 학습 기법을 이용하여 학습을 수행하는 단계; 오차 판단부에서 상기 제1 데이터 세트와 상기 제2 데이터 세트 간의 오차를 판단하는 단계; 및 제2 파라미터 저장부에서 상기 커리큘럼 학습에서 도출된 가중치를 제2 파라미터로 저장하는 단계를 포함하며, 상기 오차를 판단하는 단계는 상기 오차가 임계값 이하가 되도록 제3 내지 제 N 데이터 세트를 추가하여 상기 커리큘럼 학습을 반복 수행할 수 있다.

발명의 효과

[0021] 상기한 본 발명의 일 실시예에 따른 객체 검출 장치 및 방법은 하나의 단계로 초고해상화 및 객체 검출을 수행할 수 있다.

[0022] 또한, 실시간으로 초소형의 객체를 검출할 수 있으며, 적은 양의 학습 데이터만으로도 더 견고한 특징들을 획득할 수 있어 객체를 정확하게 분류함으로써 객체 인식 성능을 향상시킬 수 있다.

도면의 간단한 설명

[0023] 도 1은 본 발명의 일 실시예에 따른 객체 검출 네트워크를 도시하는 도면이다.

도 2는 본 발명의 일 실시예에 따른 객체 검출 장치를 나타내는 도면이다.

도 3은 본 발명의 일 실시예에 따른 객체 검출 장치의 객체 검출부를 구체화하는 도면이다.

도 4는 본 발명의 일 실시예에 따른 객체 검출 장치의 합성곱 모델 적용부를 구체화하는 도면이다.

도 5는 본 발명의 일 실시예에 따른 객체 검출 장치의 전이학습부를 구체화하는 도면이다.

도 6은 본 발명의 일 실시예에 따른 객체 검출 장치의 커리큘럼 학습부를 구체화하는 도면이다.

도 7은 본 발명의 일 실시예에 따른 객체 검출 장치의 교차 전이학습 기법을 예시하는 도면이다.

도 8은 본 발명의 일 실시예에 따른 객체 검출 방법을 나타내는 순서도이다.

도 9는 본 발명의 일 실시예에 따른 객체 검출 방법의 객체를 검출하는 단계를 구체화하는 순서도이다.

도 10은 본 발명의 일 실시예에 따른 객체 검출 방법의 특징을 추출하는 단계를 구체화하는 순서도이다.

도 11은 본 발명의 일 실시예에 따른 객체 검출 방법의 전이학습으로 훈련시키는 단계를 구체화하는 순서도이다.

도 12는 본 발명의 일 실시예에 따른 객체 검출 방법의 커리큘럼 학습 방법으로 학습하는 단계를 구체화하는 순서도이다.

발명을 실시하기 위한 구체적인 내용

[0024] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 실시 예를 가질 수 있는 바, 특정 실시 예들을 도면에 예시하고 상세하게 설명하고자 한다.

[0025] 그러나, 이는 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다.

[0026] 본 출원에서 사용한 용어는 단지 특정한 실시 예를 설명하기 위해 사용된 것으로, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 출원에서, "포함하다" 또는 "가지다" 등의 용어는 명세서상에 기재된 특징, 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.

[0027] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가지고 있다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥상 가지는 의미와 일치하는 의미를 가진 것으로 해석되어야 하며, 본 출원에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0028] 이하, 첨부한 도면들을 참조하여, 본 발명의 바람직한 실시 예를 보다 상세하게 설명하고자 한다. 본 발명을 설명함에 있어 전체적인 이해를 용이하게 하기 위하여 도면상의 동일한 구성요소에 대해서는 동일한 참조부호를 사용하고 동일한 구성요소에 대해서 중복된 설명은 생략한다.

[0029] 도 1은 본 발명의 일 실시예에 따른 객체 검출 네트워크를 도시하는 도면이다.

[0030] 본 발명은 원격 감시 시스템에 적용할 수 있는 객체 검출장치로서 무인 기지국 관제 센터에서 각 기지국의 각종 장비 동작 상태를 파악하여 제어하는 시스템에 적용될 수 있으며, 복수의 원격 감시 카메라에서 촬영되는 영상을 실시간으로 분석하여야 하는 동시에 상시적으로 많은 데이터를 획득하는데 한계가 있으므로 효율적인 데이터 활용을 위하여 원격 감시 장비에서 획득한 저해상도 이미지를 단일 네트워크에서 고해상도 변환 및 객체 검출을 수행함으로써 네트워크의 성능 향상 및 시스템의 효율적 자원 이용이 가능할 수 있다.

[0031] 생성적 적대 네트워크는 입력되는 저해상도 이미지를 초고해상도로 변환한 이미지를 생성하는데 이용될 수 있으며, 생성적 적대 네트워크에서 생성된 영상의 시각적 품질을 향상시키는 것을 목표로 하는 인지적 손실함수(perceptual loss function)를 사용하여 사전에 학습을 수행하거나, 기학습된 모델을 가져와 이용할 수 있다.

[0032] 예를 들어, 생성적 적대 네트워크는 고해상도(High Resolution, HR) 원본 이미지를 저해상도(Low Resolution, LR) 이미지로 변환한 후에 저해상도 이미지를 생성적 적대 네트워크에 입력하여 고해상도 이미지를 생성하고, 원본 이미지와 식별자(discriminator)에서 비교한 후, 인지적 손실함수를 이용하여 손실함수가 최소가 되는 방향으로 학습을 수행한 모델일 수 있다.

[0033] 객체 인식 네트워크는 생성적 적대 네트워크에서 출력된 초고해상도 이미지에서 객체를 검출할 수 있으며, 속도와 정확성을 위해 높이기 위해 설계된 것으로 단일 신경망을 사용하여 이미지의 객체에 대한 경계 상자(bounding boxes)와 클래스 확률(class probabilities)을 예측하고 실시간으로 이미지를 처리할 수 있다.

[0034] 상기와 같은 생성적 적대 네트워크(Generative Adversarial Network, GAN)와 객체 인식 네트워크를 결합하여 전체 네트워크를 구성할 수 있으며, 이는 하기의 수학식 1과 같이 표현할 수 있다.

수학식 1

[0035] $$Y_{output} = H_{PN}(I_{SR})$$

[0036] 상기 수학식 1에서 Y_{output}은 초고해상도(Super Resolution, SR) 이미지의 객체를 예측하는 네트워크이고, H_{PN}은 SR 이미지(I_{SR})의 객체를 분류하기 위한 본 발명의 일 실시예에 따른 네트워크일 수 있으며, H_{PN}은 하기의 수학식 2와 같이 표현될 수 있다.

수학식 2

[0037] $$H_{PN} = H_{ESRGAN}(I_{LR}) + H_{ff}((I_{SR}) + \alpha) + H_{YOLO}(I_{SR})$$

[0038] 상기 수학식 2에서 H_{ESRGAN}은 LR 이미지(I_{LR})의 특징(feature)을 추출하기 위한 합성곱(Convolution) 연산으로 연산결과를 ISR로 출력할 수 있고, H_{ff}는 특징 융합, α는 모델 스케일링, H_{YOLO}는 이미지에서 객체를 분류하기 위한 헤드 네트워크의 합성곱을 의미할 수 있다.

[0039] 도 2 내지 도 7에서는 도1의 동작에 대하여 각 영역 별로 설명을 하도록 하며, 이후 수학적 수식을 포함하여 전체 흐름에 대해 구체적으로 설명하도록 한다.

[0040] 도 2는 본 발명의 일 실시예에 따른 객체 검출 장치를 나타내는 도면이다.

[0041] 본 발명의 일 실시예에 따른 객체 검출 장치는 영상입력부(1000), 초해상도 적용부(2000), 객체 검출부(3000), 영역 선택부(4000) 및 출력영상 저장부(5000)를 포함할 수 있다.

[0042] 영상입력부(1000)는 외부 장치로부터 영상을 입력 받을 수 있다.

[0043] 외부 장치로부터 촬영한 영상은 헬기, 비행기, 위성 등의 고도가 높은 상공에서 지상을 촬영하여 미세객체 등을 포함하는 항공 이미지 또는 CCTV와 같이 일정 범위를 지속적으로 촬영하는 저해상도의 이미지일 수 있으며, 특히 본 발명의 일 실시예에서는 위성에서 지상을 촬영한 저해상도 이미지일 수 있다.

[0044] 초해상도 적용부(2000)는 영상입력부(1000)에서 입력되는 영상이 원거리(높은 고도)에서 촬영된 영상으로서 지상의 미세 객체를 검출하기에는 해상도가 매우 낮은 경우가 대다수이며, 이를 해결하기 위하여 입력된 저해상도의 영상에 대해 생성적 적대 네트워크(Generative Adversarial Network, GAN)를 이용하여 (초)고해상도로 변환할 수 있다. 이하의 설명에서는 고해상도 이미지로 설명을 하고 있으나, 이는 초해상도, 초고해상도, 고해상도 이미지를 모두 포함하는 것을 의미하며, 특별한 제한이나 구분을 두지 않고 높은 해상도를 갖는 이미지라면 모두 이용될 수 있음이 당연하다.

[0045] 객체 검출부(3000)는 전이학습과 커리큘럼 학습을 결합하여 학습하는 교차 학습(X-transfer) 방법을 이용하여 고해상도 영상에서 객체를 검출할 수 있으며, 검출된 객체에 대한 경계상자(bounding box) 및 클래스 확률(class probabilities)을 예측할 수 있다.

[0046] 객체 검출부(3000)는 하기의 도 3 내지 6에서 구체적으로 설명하도록 한다.

[0047] 영역 선택부(4000)는 객체 검출부(3000)에서 예측한 경계상자(bounding box)를 관심영역(Region Of Interesting, ROI)로 설정할 수 있다.

[0048] 출력영상 저장부(5000)은 영역 선택부(4000)에서 설정한 관심영역에 대해 사용자가 확인할 수 있도록 출력하기 위하여 영상을 저장할 수 있다.

[0049] 출력영상 저장부(5000)는 고해상도로 변환된 이미지 내의 관심영역에 대해 기설정된 색상 또는 표식으로 객체의 위치를 표시하고, 각 객체의 클래스 확률을 라벨로 부착하여 사용자가 객체를 쉽게 인식할 수 있도록 고해상도

이미지를 저장할 수 있다.

[0050] 예를 들어, 고해상도 이미지 내의 객체에 대한 클래스 확률의 계산 결과 승용차와 트럭이라고 판단되는 경우, 승용차는 하늘색의 라벨을 선택하여 승용차가 포함된 관심영역의 테두리를 따라 파란색의 박스를 설정하고 윗변에 'Car(0.XX)'로 라벨을 부착할 수 있으며, 승용차가 포함된 관심영역의 테두리를 따라 갈색의 박스를 설정하고 윗변에 'Truck(0.XX)'로 라벨을 부착할 수 있다. 상기 라벨에서 (0.XX)는 클래스 확률을 의미할 수 있으며, 인식된 객체가 승용차일 확률이 93%라면 (0.93)으로 표시하여 사용자에게 정보를 제공할 수 있다.

[0051] 도 3은 본 발명의 일 실시예에 따른 객체 검출 장치의 객체 검출부(3000)를 구체화하는 도면으로서 객체 검출부(3000)는 그리드 분할부(3100), 합성곱 모델 적용부(3200) 및 객체 예측부(3300)를 포함할 수 있다.

[0052] 그리드 분할부(3100)는 객체를 검출하기 위하여 고해상도 이미지에 대해 복수의 영역으로 분할할 수 있으며, 복수의 영역으로 분할한다는 의미는 고해상도 이미지에 대해 기설정된 간격으로 가상의 선을 그어 복수의 그리드(Grid) 셀을 생성한다는 것을 의미할 수 있다.

[0053] 합성곱 모델 적용부(3200)는 교차 학습(X-transfer) 방법을 기반으로 고해상도 이미지의 특징 추출, 융합, 모델 스케일링 및 객체 분류를 위한 헤드 네트워크의 합성곱(convolution)을 이용하여 객체를 검출할 수 있다.

[0054] 합성곱 모델 적용부(3200)의 상세한 구성은 하기의 도 4 내지 도 6에서 설명하도록 한다.

[0055] 객체 예측부(3300)는 합성곱 모델 적용부(3200)에서 검출한 객체에 대하여 경계상자(bounding box)를 설정하고. 클래스 확률(class probabilities)을 예측할 수 있다. 객체가 검출되면 검출되는 객체가 포함되도록 객체를 중심으로 기설정된 비율의 크기를 갖는 경계상자를 생성할 수 있으며, 클래스 확률은 객체의 종류를 구분하여 객체가 어떠한 종류에 속하는지 확률을 예측할 수 있다.

[0056] 예를 들어, 경계상자는 객체가 검출된 영역을 기준으로 사각형의 영역을 경계상자로 설정할 수 있으며, 경계상자는 객체의 중심을 기준으로 가장 먼 거리의 픽셀이 사각형의 일측면에 접하는 형태로 형성하고 경계상자의 각 변은 이미지의 최외각과 평행하도록 설정할 수 있다.

[0057] 또한, 클래스 확률은 위성에서 지상을 촬영하는 도로 이미지의 경우 도로 상에서 이동할 수 있는 사람, 오토바이, 승용차, 트럭, 보트, 요트 등의 종류에 대해 검출된 객체가 어떤 종류에 속할 수 있는지 확률을 계산하고 가장 높은 확률을 갖는 종류를 클래스 확률로 제시할 수 있다.

[0058] 도 4는 본 발명의 일 실시예에 따른 객체 검출 장치의 합성곱 모델 적용부(3200)를 구체화하는 도면으로 합성곱 모델 적용부(3200)는 전이학습부(3210), 커리큘럼 학습부(3220), 손실함수 판단부(3230) 및 파라미터 결정부(3240)을 포함할 수 있다.

[0059] 전이학습부(3210)는 사전에 학습된 데이터 세트의 가중치를 기반으로 제1 데이터 세트를 전이학습으로 훈련시킬 수 있다.

[0060] 전이학습(transfer learning)은 사전 훈련된 모델과 관련되거나 다른 작업을 해결하기 위한 사전 훈련된 모델로부터의 지식 전이(transferring knowledge)를 통한 학습 방법으로 다음과 같은 요구 사항이 충족되어야 한다. 먼저, 분포의 엔트로피는 다음 셋으로 점차 증가해야 하고, 학습 데이터의 크기는 증가하여야 하며, 각 셋의 모든 샘플을 누적하여 최종 세트를 구성하고 셋의 모든 샘플에 대한 가중치는 균등하게 배정되어야 한다.

[0061] 커리큘럼 학습부(3220)는 전이학습이 완료된 제1 데이터 세트에 대하여 제1 데이터 세트와 동일한 종류의 제2 데이터 세트에 대하여 커리큘럼 학습 방법을 기반으로 학습을 수행할 수 있다.

[0062] 커리큘럼 학습(Curriculum learning)은 동일한 종류의 데이터 셋에서 크기와 수를 변형함으로써 학습의 효율성을 높이는 방법으로서 학습과정(learning system)에서 어떤 예제들이 제공되고, 어떤 순서로 제공될 것인가에 대한 선택은 학습을 가이드해 줄 수 있으면서 학습의 속도를 증가시킬 수 있는 동물학습(Animal training) 방법을 기반으로 작은 것부터 시작해서 task의 쉬운 부분이나 쉬운 subtask를 학습하고, 점차 어려운 부분을 학습하는 방식을 적용하여 랜덤하게 예제를 주는 것이 아닌 점차 복잡하고 어려운 내용을 포함하는 의미 있는 순서로 데이터를 주는 학습 전략을 기계학습(Machine learning) 또는 딥러닝(Deep learning) 등의 학습용 인공지능에 적용시켜 학습하는 알고리즘을 의미할 수 있으며, 학습의 속도를 향상시킬 수 있으며, 일반화를 수행함에 있어 상당한 성능 향상을 가져올 수 있다는 장점을 가지고 있다.

[0063] 손실함수 판단부(3230)는 전이학습부(3210) 및 커리큘럼 학습부(3220)의 학습결과에 대하여 손실함수를 계산할 수 있다.

[0064] 손실함수 판단부(3230)는 계산된 손실함수 출력값을 기반으로 추가 학습 여부를 결정할 수 있으며, 손실함수의 값이 기설정된 임계값 이내일 경우에는 학습을 완료하지만 기설정된 임계값을 초기화는 경우에는 추가적인 학습 데이터를 불러와 전이학습부(3210) 및 커리큘럼 학습부(3220)를 거치며 추가 학습을 수행할 수 있다.

[0065] 파라미터 결정부(3240)는 객체를 검출하기 위한 파라미터를 결정하고, 객체를 검출할 수 있다.

[0066] 도 5는 본 발명의 일 실시예에 따른 객체 검출 장치의 전이학습부(3210)를 구체화하는 도면으로 전이학습부(3210)는 사전 데이터 선택부(3211), 선행학습부(3212) 및 제1 파라미터 저장부(3213)을 포함할 수 있다.

[0067] 사전 데이터 선택부(3211)는 전이학습을 수행하기 위하여 COCO 데이터 세트 등의 사전 학습된 데이터 세트를 선택할 수 있다.

[0068] COCO(Common Objects in COntext) 데이터셋은 객체 탐지 (object detection), 세그먼테이션 (segmentation), 키포인트 탐지 (keypoint detection) 등의 컴퓨터 비전(computer vision) 분야의 task를 목적으로 만들어진 데이터 세트로서 객체 검출 관련 발명에서 성능 평가 목적으로 많이 사용되는 데이터 세트이다.

[0069] 선행 학습부(3212)는 사전 데이터 선택부(3211)에서 선택한 사전 학습된 데이터 세트 및 가중치를 이용하여 제1 데이터 세트를 전이학습으로 학습을 수행할 수 있다.

[0070] 제1 파라미터 저장부(3213)는 선행 학습부(3212)에서 학습을 진행하며 획득한 가중치 등의 파라미터를 저장할 수 있다.

[0071] 도 6은 본 발명의 일 실시예에 따른 객체 검출 장치의 커리큘럼 학습부를 구체화하는 도면으로 커리큘럼 학습부(3220)는 학습 데이터 추가부(3221), 네트워크 학습부(3222), 오차 판단부(3223) 및 제2 파라미터 저장부(3224)를 포함할 수 있다.

[0072] 학습 데이터 추가부(3221)는 전이학습부(3210)에서 학습이 완료된 제1 데이터 세트에 대해 동일한 종류의 제2 데이터 세트를 추가할 수 있다.

[0073] 네트워크 학습부(3222)는 제1 데이터 세트 및 제2 데이터 세트를 이용하여 커리큘럼 학습 기법을 이용하여 학습을 수행할 수 있다.

[0074] 오차 판단부(3223)는 네트워크 학습부(3222)에서 학습된 제2 데이터 세트에 대하여 제1 데이터 세트와의 오차를 판단할 수 있다.

[0075] 학습 결과에 대한 오차가 기설정된 기준(임계값) 이하가 되야 하며, 오차 판단부(3223)에서 판단한 오차가 기설정된 기준을 초과하는 경우 학습데이터 추가부(3221)에서 제3 데이터 세트를 추가하고, 네트워크 학습부(3222)에서 반복 학습을 수행하며, 오차 판단부(3223)에서 다시 오차를 측정한 뒤 오차가 기준값 이하가 될때까지 제4, 제5 내지 제N 데이터 세트를 이용하여 반복 학습을 지속적으로 수행할 수 있다.

[0076] 재2 파라미터 저장부(3224)는 오차 판단부(3223)에서 측정한 오차가 기준값 이하가 되는 데이터 세트의 파라미터(가중치)를 저장할 수 있다.

[0077] 이상에서와 같이 도 2 내지 도 6을 이용하여 본 발명의 일 실시예에 따르는 객체 검출 장치를 구성할 수 있으나, 상기 도 1에서 설명한 바와 같이 본 발명의 일 실시예에 따르는 객체 검출 장치는 해상도 향상을 위한 GAN과 전이학습 및 커리큘럼 학습 기법을 포함하는 교차 전이학습 기법(X-transfer learning algorithm)을 하나의 네트워크에서 동작할 수 있으며, 이에 대하여 하기에서는 수학적 수식을 포함하여 종합적으로 설명하고자 한다.

[0078] 우선하여 교차 전이학습 기법(X-transfer learning algorithm)에 대해 설명하고자 하며, 도 7은 본 발명의 일 실시예에 따른 객체 검출 장치의 교차 전이학습 기법을 예시하는 도면이다.

[0079] 전체 데이터 세트(Data Set)은 커리큘럼 학습 방법을 이용하기 위하여 기설정된 기준에 따라 간단한 구조의 데이터(Easy Data)부터 복잡한 구조의 데이터(Hard Data)로 제1 내지 제N 데이터 세트(Set A 내지 Set N)(이하, 셋A 내지 셋N)를 생성할 수 있다. 셋 A가 가장 간단한 구조의 데이터 세트이며 숫자가 N으로 점차 커질수록 점진적으로 복잡한 구조의 데이터 세트일 수 있다.

[0080] 또한, 셋A 내지 셋N는 주석을 포함할 수 있으며, 주석은 정확성을 위하여 수동으로 부착할 수도 있고, 자동 라벨링 장치를 이용하여 자동으로 부착할 수도 있으며, 주석을 부착할 수 있다면 방법을 제한하지 않는다. 더하여 셋A 내지 셋N의 복잡도는 각 데이터 별로 부착된 주석을 기준으로 분류할 수 있다.

[0081] 사전 학습이 완료된 태스크(Pre-trained Task)는 사전 학습된 모델(Pre-trained model) 및 학습에 이용된 데이터 세트를 포함하며, 사전 학습이 완료된 테스크는 대표적으로 COCO 데이터 세트일 수 있다.

[0082] 본 발명의 일 실시예에서의 교차 전이학습 기법은 사전 학습이 완료된 태스크로부터 사전학습 가중치를 가져오고, 전체 데이터 세트에서 셋A를 가져와 교차 전이학습 모델을 학습할 수 있다.

[0083] 셋A의 학습이 완료되면 손실함수를 이용하여 손실을 계산하고, 손실이 임계값 이상일 경우, 셋B를 불러오고 셋A의 학습 결과로 생성된 가중치를 이용하여 학습을 수행할 수 있다.

[0084] 이러한 방식으로 손실이 임계값 이하가 될 때까지 셋B 내지 셋N을 기반으로 가중치를 전달하며 반복학습을 수행할 수 있다.

[0085] 상기와 같은 교차 전이 학습은 하기와 같은 단계로 진행될 수 있으며, 학습 단계는 하기의 수학식 3과 같이 표현될 수 있다.

수학식 3

[0086] $$S = \langle R_1, R_2, \ldots, R_L \rangle$$

[0087] 상기 수학식 3은 일련의 훈련 데이터 집합으로서 하기의 수학식 4와 같이 각 데이터 셋 R_l은 목표 학습 분포 P(z)의 가중치를 다시 조정할 수 있다.

수학식 4

[0088] $$R_l(z) \propto W_l(z)P(z) \qquad \forall z \in training\ set \quad \mathrm{T}$$

[0089] 데이터세트 간의 전이를 위해서는 분포의 엔트로피는 다음 세트로 점차 증가해야 하고, 학습 데이터의 크기는 증가해야 하며, 각 세트의 모든 샘플을 누적하여 최종 세트를 구성하고 세트의 모든 샘플에 대한 가중치는 균등하게 배정되어야 한다.

[0090] 교차 전이 학습을 진행하기 위해서는 VEDAI-VISIBLE, VEDAI-IR 및 DOTA와 같은 공개적으로 사용 가능한 데이터가 필요하며, 각 세트는 66개의 이미지와 해당 레이블로 구성될 수 있다. 영상의 난이도는 후속 세트로 갈수록 높아져야 하며, 이때 저해상도 입력 영상의 크기는 128x128이며, 최종적으로는 512x512 크기로 초해상도화 될 수 있다. 모델이 학습을 중지한 경우, 영상의 해상도나 난이도를 점차 높여 모델이 학습하도록 할 수 있다.

[0091] 우선 사전 학습된 COCO 데이터 세트의 가중치로부터 셋A를 전이학습으로 훈련시킬 수 있으며, 이때 전이학습(transfer learning)은 사전 훈련된 모델과 관련되거나 다른 작업을 해결하기 위한 사전 훈련된 모델로부터 지식 전이(transferring knowledge)방법을 이용할 수 있다.

[0092] 다음으로 셋A에서 사전 훈련된 가중치는 셋B를 커리큘럼 학습 방법으로 학습하는데 이용될 수 있다. 커리큘럼 학습(Curriculum learning)은 동일한 종류의 데이터 세트에서 크기와 수를 변형함으로써 학습의 효율을 높이는 방법으로서 상기 전이된 학습 방법을 통해 교차 전이 학습은 하기의 수학식 5와 같이 표현될 수 있다.

수학식 5

[0093] $$\hat{P}_{XY}^{(i)}(x,y) = \frac{1}{n_i}\sum_{l=1}^{n_i} N\{x_l^{(i)} = x, y_l^{(i)} = y\}$$

[0094] 상기 수학식 5에서 N은 교차전이학습을 위한 데이터 함수로 정의될 수 있으며, X와 Y는 데이터 및 레이블을 나타내는 임의의 변수일 수 있다. n_i는 목표 데이터 세트 $\{(x_l^{(i)}, y_l^{(i)})\}_{l=1}^{n_i}$의 훈련 샘플의 개수일 수 있다. $\hat{P}_{XY}^{(i)}$는 경험적 분포일 수 있으며, 사전 훈련된 작업에서 모델을 학습한 결과일 수 있다. 또한, 가중치는 하기의 수학식

6에서와 같이 다음 데이터 세트로 전이될 수 있다.

[0095] 사전 훈련된 모델은 두 부분으로 나눌 수 있으며, 데이터 변수 x에서 d-차원 특징 $f(x)=[f_1(x), \cdots, f_d(x)]^T$을 추출하기 위한 이전 레이어들과 선형 분류를 위한 최상위 레이어, 가중치 $g(y)=[g_1(y), \cdots, g_d(y)]^T$는 라벨 y로 색인화될 수 있다.

[0096] f(x)가 주어지고 고정되면, 다양한 작업에서 학습된 모델을 유한한 매개변수(g(1), …, g(|y|))로 효과적으로 표현할 수 있다.

수학식 6

[0097] $$\hat{P}_{Y/X}^{(f,g)}(y/x) = P_Y^{(0)}(y)\left(1 + f^T(x)g(y)\right)$$

[0098] 상기 수학식 6에서 $\hat{P}_{XY}^{(i)}$, $P_X^{(0)}$, $\hat{P}_{Y/X}^{(f,g)}$는 각각 경험적 및 결합 분포이고, f, g는 사전 훈련된 모델에서 해당 레이블의 특징일 수 있다. 학습이 완료되면 하기의 수학식 7과 같이 모델의 가중치를 다시 조정할 수 있다.

수학식 7

[0099] $$\hat{g}_i \triangleq \underset{g}{\operatorname{argmin}} \; X^2_{R_{XY}}\left(\hat{P}_{XY}^{(i)},\; P_X^{(0)}\hat{P}_{Y/X}^{(f,g)}\right)$$

[0100] 이어서 셋 C는 셋 B의 가중치를 사용하여 학습할 수 있다. 셋D는 셋C의 사전 훈련된 가중치를 사용하여 학습한다. 전체 과정은 순차적으로 실행되며 네트워 크가 완벽하게 학습하지 않으므로 학습 중에 약간의 손실(loss)이 발생한다. 본 발명에서는 이를 다중 손실 함수(multiple loss functions)와 인지적 손실 함수 (perceptual loss functions)로 하기의 수학식 8 및 수학식 9와 같이 표현할 수 있다. 손실에 대한 목적 함수는 재구성된 이미지 $G(I^{LR})$가 실제 고해상도(HR) 이미지인가 판별하는 $D(G(I^{LR}))$의 확률로 정의되는 L_{adv}일 수 있다.

수학식 8

[0101] $$L_{adv} = \underset{G}{\min}\underset{D}{\max}\left[E_{I^{HR}\sim P_{train}}(I^{HR})[\log D(I^{HR})]\right] + E_{I^{LR}\sim P_G}(I^{LR})\left[\left[\log(1 - D(G(I^{LR})))\right]\right]$$

[0102] 상기 수학식 8에서 $P_{train}(I^{HR})$ 및 $P_G(I^{LR})$는 저해상도 영상에 대한 실제 초고해상도 영상의 확률 분포로 정의할 수 있으며, 훈련에서 지각 손실(perceptual loss)을 나타내는 네트워크를 최적화하기 위해 널리 사용되는 방법으로 하기의 수학식 9와 같이 표현될 수 있다.

수학식 9

[0103] $$L_{per} = \frac{1}{N}\sum_{n=1}^{N}\frac{1}{C_j W_j H_j}\sum_{c=1}^{C_j}\sum_{x=1}^{W_j}\sum_{y=1}^{H_j}\left(\Phi_j(I_n^{HR})_{c,x,y} - \Phi_j\left(G(I_n^{LR})\right)_{c,x,y}\right)^2$$

[0104] 상기의 수학식 9에서 Φ_j는 j^{th} 컨볼루션 레이어 특징 맵일 수 있고, C_j, W_j, H_j는 네트워크의 특징 맵일 수 있다. 네트워크의 전체 손실은 저해상도 원격 감지 이미지에서의 더 나은 객체 인식을 위한 고주파수 디테일을 검색하기 위해 네트워크를 최적화하는 적대적 및 지각전이 손실의 합으로 정의될 수 있다.

[0105] 상기와 같은 본 발명의 일 실시예에 따른 객체 인식 방법에 대하여 하기에서는 원격 감지용 공개 데이터인 VEDAIVISIBLE, VEDAI-IR 및 DOTA 데이터 셋을 기반으로 종래의 기술과의 대비를 통한 성능 검증을 수행한 실험 결과를 예시하도록 한다.

[0106] 실험은 은 객체의 인식률을 나타내는 mAP @0.5와 모델의 정확도를 나타내는 F1 scores를 기반으로 객체 인식의 정확도를 확인할 수 있으며, VEDAI-VISIBLE, VEDAI-IR 데이터 세트에는 자동차와 트럭을 포함한 600개의 영상이 포함되어 있어 객관적인 인식 성능 검증을 수행할 수 있다.

[0107] DOTA는 800×800에서 20,000×20,000 화소로 구성되어 있으며, 본 발명의일 실시예에서는 DOTA 1.0을 채택할 수 있다. DOTA 1.0에는 2,806개의 영상과 188,282개의 인스턴스가 있고, 원본 이미지는 512×512 패치로 나누어져 있으며 대형 차량과 소형 차량을 나타내는 두 가지 클래스를 포함할 수 있다. 초고해상도 모델은 4배로 축소 샘플링되고 초해상도화된 128×128 저해상도 영상을 사용하여 테스트할 수 있다. 훈련 파라미터는 0.937의 모멘텀 값과 0.0005의 가중치 감쇠 함수를 사용하여 손실 함수를 최소화하기 위해 통계적 경사 하강법 알고리즘 사용하였으며, 초기 학습률은 0.01로 설정했고, 배치 크기는 16으로 사용할 수 있다. IoU 임계값은 0.25이고, 입력 영상 크기는 512×512일 수 있으며, 예측 상자(prediction box)에 대한 신뢰도 임계값은 0.001인 반면, 비최대 억제에 대한 IoU 임계값은 0.65일 수 있고, 모델은 300 에포크 동안 학습을 수행할 수 있다.

[0108] 셋 A에 대한 mAP @ 0.5 및 F1 값의 초기 성능 지표는 15.40, 0.250, 12.23, 0.210, 15.61 및 0.253이며, 이전 학습으로부터 사전 훈련된 모델의 가중치를 활용한 후 정확도가 향상되는 것을 확인할 수 있다. 구체적으로 전이학습을 완료한 셋 A(셋 A_TL)의 가중치는 셋 B로 전이 되어 각각 62.50, 0.617, 78.13, 0.738, 80.27 및 0.769의 성능을 나타낼 수 있으며, 셋 B 가중치는 정확도로 표시된 대로 모델이 다시 학습한 셋 C에 적용할 수 있다. 마지막으로 셋 C 가중치가 셋 D로 전이되어 학습을 수행한 결과, 거의 최대 정확도를 달성했으며, 이는 모델이 교차 전이 학습을 최종적으로 학습이 중지될 수 있다.

[0109] 상기와 같은 과정을 통하여 학습이 완료된 객체 검출 장치에 대하여 종래의 기술들과 검출 결과를 비교한 결과, 다른 조건이 동일한 상황에서 교차 전이 학습을 한 경우에는 기존 모든 방법에 비해 급 격하게 성능이 향상되는 것을 확인할 수 있으며, 구체적으로 본 발명의 일 실시예에서의 교차 전이 학습 장치의 mAP(99.21%, 98.57%, 93.71%)와 F1 score(0.971, 0.971, 0.911)로서 하기의 표 1에서와 같이 종래의 방법에 대비하여 우수한 성능을 가지고 있음을 확인할 수 있다.

표 1

[0110]

S. No	Algorithms	VEDAI-VISIBLE		VEDAI-IR		DOTA	
		mAP @ 0.5	F1 Score	mAP @ 0.5	F1 Score	mAP @ 0.5	F1 Score
1	YOLOv3_SRGAN [1]	62.45	0.591	70.10	0.687	86.18	0.837
2	YOLOv3_MSRGAN [1]	66.74	0.643	74.61	0.723	87.02	0.859
3	YOLOv3_EDSR [13]	74.32	0.754	70.62	0.727	91.47	0.889
4	YOLOv7_ESRGAN	62.50	0.617	78.13	0.738	80.27	0.769
5	Proposed method	99.21	0.971	98.57	0.971	93.71	0.911

[0111] 도 8은 본 발명의 일 실시예에 따른 객체 검출 방법을 나타내는 순서도이다.

[0112] 영상입력부(1000)에서 원격 시스템과 같은 저해상도로 촬영되는 영상에 대하여 이미지 또는 단일 프레임 영상을 획득할 수 있다(S1000).

[0113] 초해상도 적용부(2000)에서 획득된 저해상도 영상에 대해 생성적 적대 네트워크(Generative Adversarial Network, GAN)를 이용하여 고해상도 영상으로 변환할 수 있다(S200).

[0114] 객체 검출부(3000)에서 전이학습(transfer leraning)과 커리큘럼 학습(Curriculum learning)을 결합한 교차 학습(X-transfer) 방법을 이용하여 고해상도 영상에서 객체를 검출할 수 있으며, 검출된 객체에 대한 경계상자(bounding box) 및 클래스 확률(class probabilities)을 예측할 수 있다(S3000).

[0115] 영역 선택부(4000)에서 객체 검출부(3000)에서 예측한 경계상자(bounding box)를 관심영역(Region Of Interesting, ROI)로 설정할 수 있다(S4000).

[0116] 출력영상 저장부(5000)에서 고해상도로 변환된 이미지 내의 관심영역에 대해 기설정된 색상 또는 표식으로 객체의 위치를 표시하고, 각 객체의 클래스 확률을 라벨로 부착하여 사용자가 객체를 쉽게 인식할 수 있도록 고해상도 이미지를 저장할 수 있다(S5000).

[0117] 도 9는 본 발명의 일 실시예에 따른 객체 검출 방법의 객체를 검출하는 단계(S3000)를 구체화하는 순서도이다.

[0118] 그리드 분할부(3100)에서 객체를 검출하기 위하여 고해상도 이미지에 대해 복수의 영역으로 분할할 수 있다(S3100). 복수의 영역으로 분할한다는 의미는 고해상도 이미지에 대해 기설정된 간격으로 가상의 선을 그어 복수의 그리드(Grid) 셀을 생성하는 것을 의미할 수 있다.

[0119] 합성곱 모델 적용부(3200)에서 교차 학습(X-transfer) 방법을 기반으로 고해상도 이미지의 특징 추출, 융합, 모델 스케일링 및 객체 분류를 위한 헤드 네트워크의 합성곱(convolution)을 이용하여 객체를 검출할 수 있다(S3200).

[0120] 객체 예측부(3300)에서 검출한 객체에 대해 경계상자(bounding box)를 설정하고. 객체의 클래스 확률(class probabilities)을 예측할 수 있다(S3300).

[0121] 객체가 검출되면 검출되는 객체가 포함되도록 객체를 중심으로 기설정된 비율의 크기를 갖는 경계상자를 생성할 수 있으며, 클래스 확률은 객체의 종류를 구분하여 객체가 어떠한 종류에 속하는지 확률을 예측할 수 있다.

[0122] 도 10은 본 발명의 일 실시예에 따른 객체 검출 방법의 특징을 추출하는 단계(S3200)를 구체화하는 순서도이다.

[0123] 전이학습부(3210)에서 사전에 학습된 데이터 세트의 가중치를 기반으로 로부터 제1 데이터 세트를 전이학습으로 훈련시킬 수 있다(S3210).

[0124] 커리큘럼 학습부(3220)에서 전이학습이 완료된 제1 데이터 세트에 대하여 제1 데이터 세트와 동일한 종류의 제2 데이터 세트에 대하여 커리큘럼 학습 방법을 기반으로 학습을 수행할 수 있다(S3220).

[0125] 손실함수 판단부(3230)에서 전이학습 및 커리큘럼 학습(교차 학습)의 학습결과에 대하여 손실함수를 계산할 수 있다(S3230).

[0126] 상기 손실함수는 다중 손실 함수(multiple loss functions)와 인지적 손실 함수(perceptual loss functions)를 기반으로 손실함수의 손실을 계산할 수 있으며, 손실이 기설정된 값 이상(S3230 단계의 No)일 경우에는 상기 S3210 단계 및 상기 S3220 단계의 교차 학습을 추가로 실시할 수 있다.

[0127] 파라미터 결정부(3240)에서 객체를 검출하기 위한 파라미터(가중치)를 결정하고, 결정된 파라미터를 이용하여 고해상도 이미지 내의 객체를 검출할 수 있다(S3240).

[0128] 도 11은 본 발명의 일 실시예에 따른 객체 검출 방법의 전이학습으로 훈련시키는 단계(S3210)를 구체화하는 순서도이다.

[0129] 사전 데이터 선택부(3211)에서 전이학습을 수행하기 위하여 사전 학습된 데이터 세트를 선택할 수 있다(S3211).

[0130] 선행 학습부(3212)에서 선택된 사전 학습이 완료된 데이터 세트 및 가중치를 이용하여 제1 데이터 세트를 전이학습으로 학습을 수행할 수 있다(S3212).

[0131] 제1 파라미터 저장부(3213)에 전이 학습을 진행하며 획득한 가중치 파라미터를 저장할 수 있다(S3213).

[0132] 도 12는 본 발명의 일 실시예에 따른 객체 검출 방법의 커리큘럼 학습 방법으로 학습하는 단계(S3220)를 구체화하는 순서도이다.

[0133] 학습 데이터 추가부(3221)에서는 상기 S3210 단계에서 전이학습이 완료된 제1 데이터 세트에 대해 제1 데이터 세트와 동일한 종류의 제2 데이터 세트를 추가할 수 있다(S3221).

[0134] 네트워크 학습부(3222)에서 커리큘럼 학습 기법을 이용하여 제1 데이터 세트를 기반으로 제2 데이터 세트를 학습할 수 있다(S3222).

[0135] 오차 판단부(3223)에서 커리큘럼 학습이 완료된 제2 데이터 세트에 대하여 제1 데이터 세트와의 오차를 판단할 수 있다(S3223).

[0136] 학습 결과에 대한 오차가 기설정된 기준(임계값) 이하가 되야 하며, 상기 S3223 단계에서 판단된 오차가 기설정된 기준을 초과하는 경우(S3223 단계의 No)에는 상기 S3221 단계로 회귀하여 제2 데이터 세트와 동일한 종류의 제3 데이터 세트를 추가한 후에 커리큘럼 학습을 반복 수행하며, 제3 데이터 세트에 대한 커리큘럼 학습 수행 후에 오차를 다시 측정하여 오차가 기준값 이하가 될 때까지 제4, 제5 내지 제N 데이터 세트를 이용하여 반복 학습을 지속적으로 수행할 수 있다.

[0137] 상기 제1 내지 제N 데이터 세트는 단일 데이터 세트를 분할한 분할 데이터 세트일 수 있으며, 커리큘럼 학습의 효율을 향상시키기 위하여 숫자가 커질수록 데이터 세트의 크기(엔트로피)가 점차 증가하여야 하며, 모든 샘플

에 대한 가중치는 균등하게 배정될 수 있다.

[0138] 상기 S3223 단계에서 오차가 기준값 이하가 되는 경우(S3223 단계의 Yes) 제2 파라미터 저장부(3224)에 데이터 세트의 파라미터(가중치)를 저장할 수 있다(S3224).

[0139] 이상에서와 같이 상기한 본 발명의 일 실시예에 따른 객체 검출 장치 및 방법은 하나의 단계로 초고해상화 및 검출의 기능을 수행할 수 있다.

[0140] 또한, 실시간으로 초소형의 객체를 검출할 수 있으며, 적은 양의 학습 데이터만으로도 더 견고한 특징들을 획득할 수 있어 객체를 정확하게 분류함으로써 객체 인식 성능을 향상시킬 수 있다.

[0141] 상술한 실시 예에 설명된 특징, 구조, 효과 등은 본 발명의 적어도 하나의 실시 예에 포함되며, 반드시 하나의 실시 예에 만 한정되는 것은 아니다. 나아가, 각 실시 예에 서 예시된 특징, 구조, 효과 등은 실시예들이 속하는 분야의 통상의 지식을 가지는 자에 의하여 다른 실시예들에 대해서도 조합 또는 변형되어 실시 가능하다.

[0142] 따라서 이러한 조합과 변형에 관계된 내용들은 본 발명의 범위에 포함되는 것으로 해석되어야 할 것이다. 또한, 이상에서 실시 예들을 중심으로 설명하였으나 이는 단지 예시일 뿐 본 발명을 한정하는 것이 아니며, 본 발명이 속하는 분야의 통상의 지식을 가진 자라면 본 실시예의 본질적인 특성을 벗어나지 않는 범위에서 이상에 예시되지 않은 여러 가지의 변형과 응용이 가능함을 알 수 있을 것이다. 예를 들어, 실시 예들에 구체적으로 나타난 각 구성 요소는 변형하여 실시할 수 있는 것이다. 그리고 이러한 변형과 응용에 관계된 차이점들은 첨부한 청구 범위에서 규정하는 본 발명의 범위에 포함되는 것으로 해석되어야 할 것이다.

부호의 설명

[0143] 1000: 영상입력부

2000: 초해상도 적용부

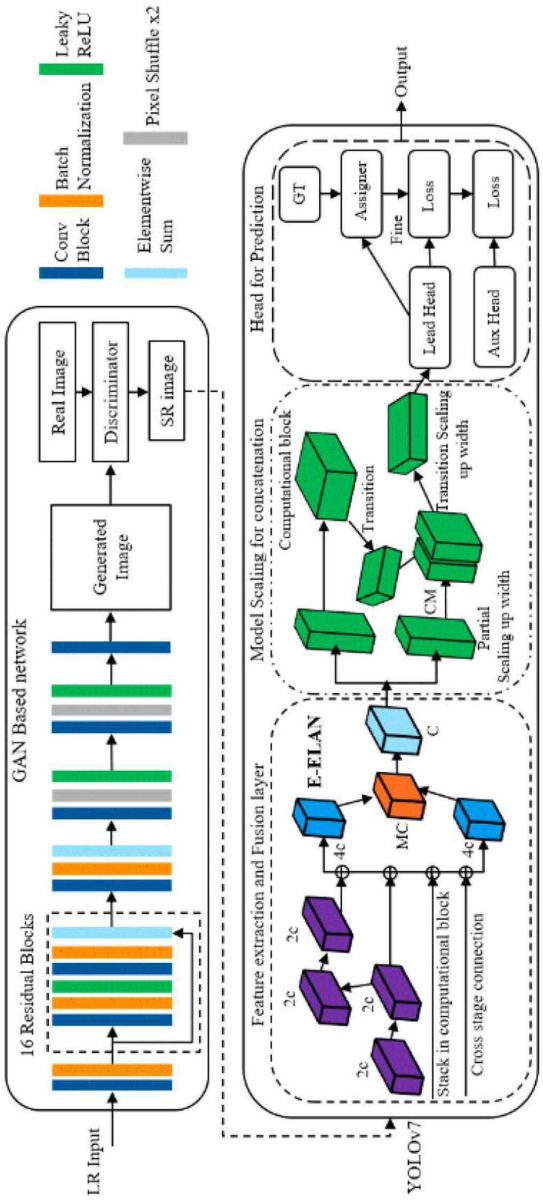
3000: 객체 검출부

4000: 영역 선택부

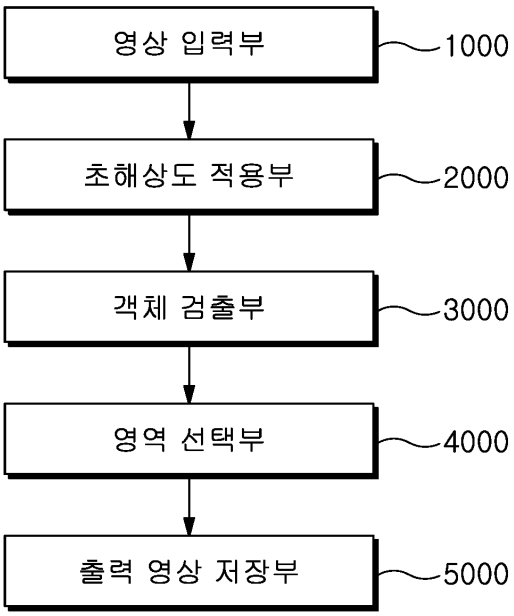
5000: 출력영상 저장부

도면

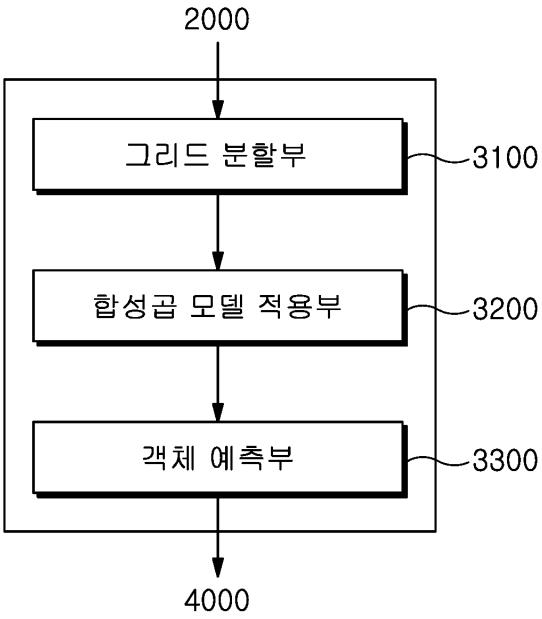
도면1


Leaky ReLU
Batch Normalization
Pixel Shuffle x2
Conv Block
Elementwise Sum
GAN Based network
16 Residual Blocks
Real Image
Discriminator
SR image
Generated Image
LR Input
YOLOv7
Feature extraction and Fusion layer
E-ELAN
2c
4c
MC
C
Stack in computational block
Cross stage connection
Model Scaling for concatenation
Computational block
Transition
Transition Scaling up width
CM
Partial Scaling up width
Head for Prediction
GT
Assigner
Fine
Lead Head
Aux Head
Loss
Output

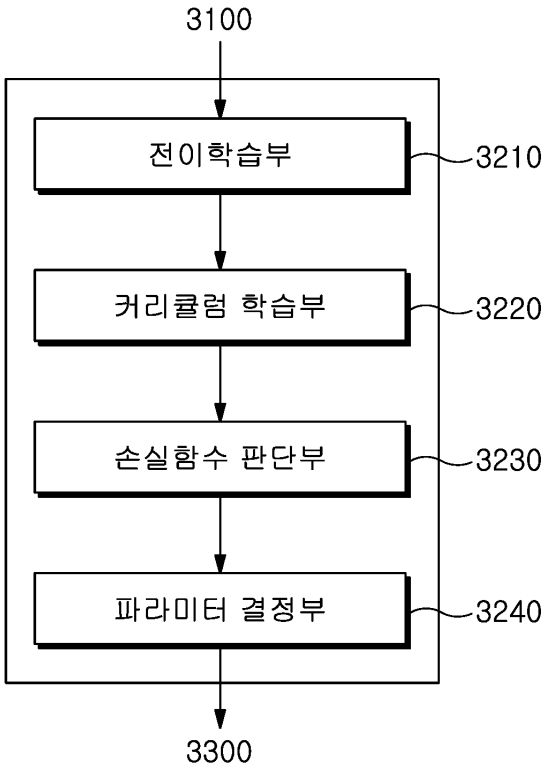
도면2


영상 입력부
1000
초해상도 적용부
2000
객체 검출부
3000
영역 선택부
4000
출력 영상 저장부
5000

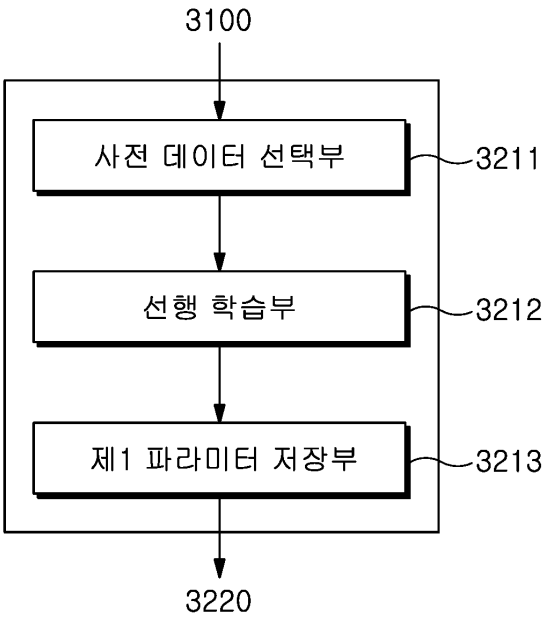
도면3


2000
그리드 분할부
3100
합성곱 모델 적용부
3200
객체 예측부
3300
4000

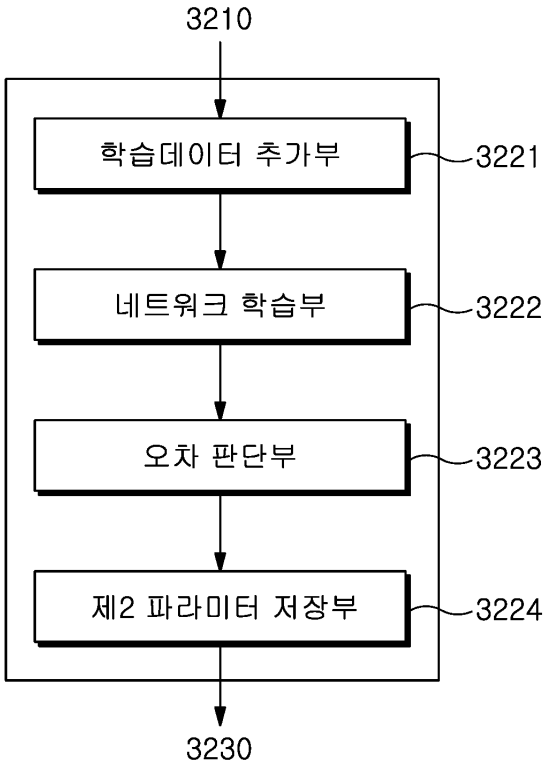
도면4


3100
전이학습부
3210
커리큘럼 학습부
3220
손실함수 판단부
3230
파라미터 결정부
3240
3300

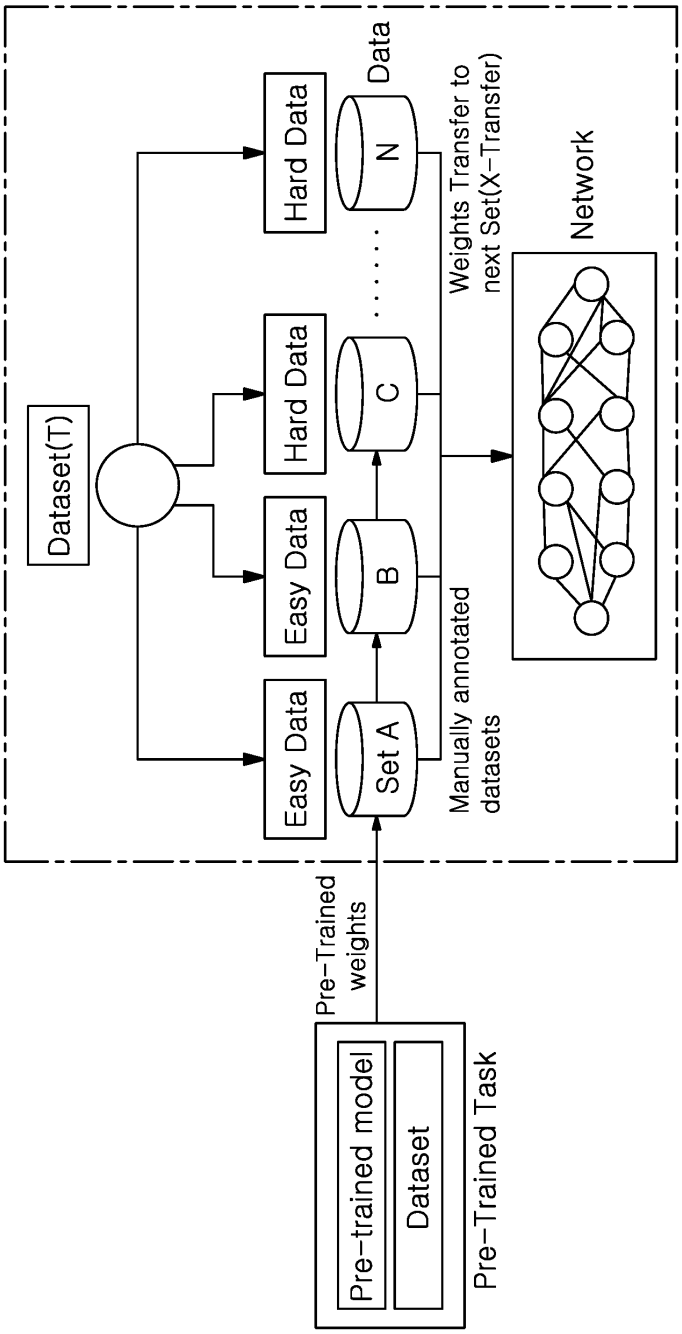
도면5


3100
사전 데이터 선택부
3211
선행 학습부
3212
제1 파라미터 저장부
3213
3220

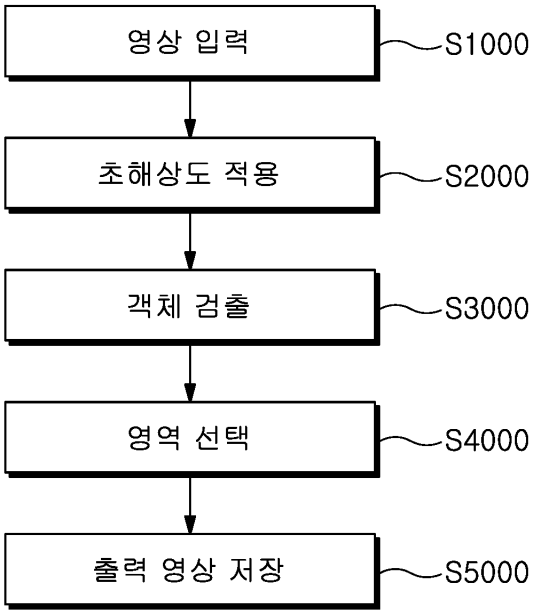
도면6


3210
학습데이터 추가부
3221
네트워크 학습부
3222
오차 판단부
3223
제2 파라미터 저장부
3224
3230

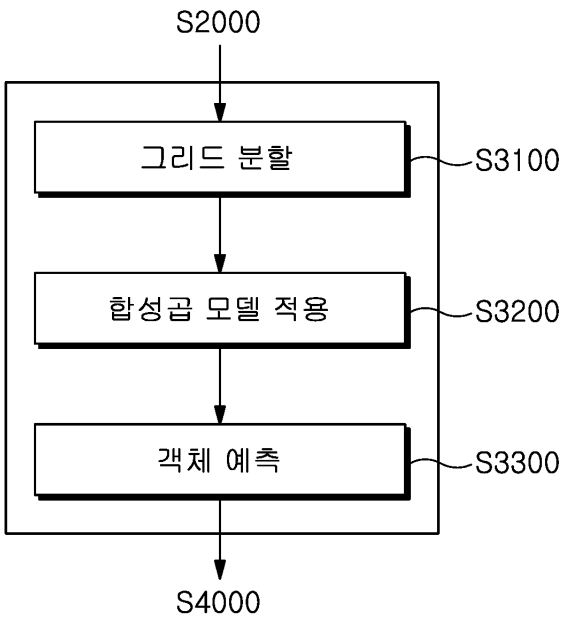
도면7


Dataset(T)
Easy Data
Easy Data
Hard Data
Hard Data
Set A
B
C
N
Data
Manually annotated datasets
Weights Transfer to next Set(X-Transfer)
Network
Pre-Trained weights
Pre-trained model
Dataset
Pre-Trained Task

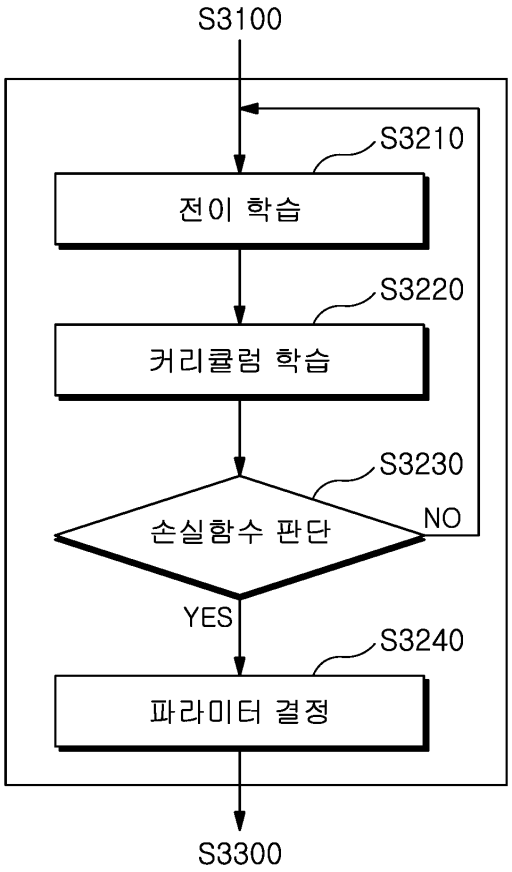
도면8


영상 입력
S1000
초해상도 적용
S2000
객체 검출
S3000
영역 선택
S4000
출력 영상 저장
S5000

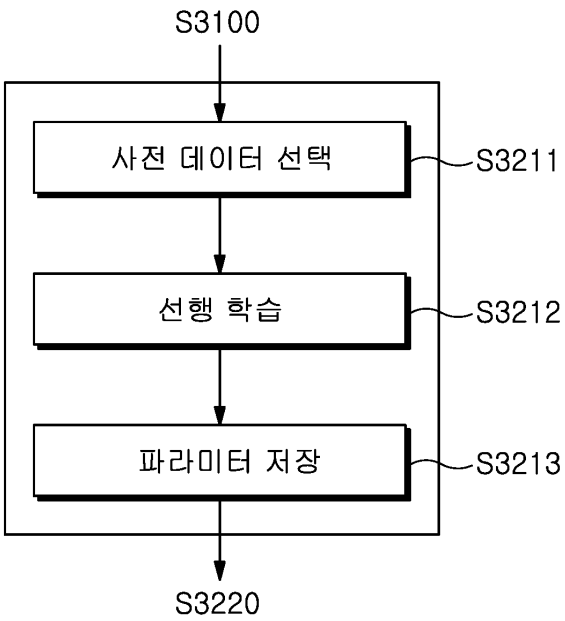
도면9


S2000
그리드 분할
S3100
합성곱 모델 적용
S3200
객체 예측
S3300
S4000

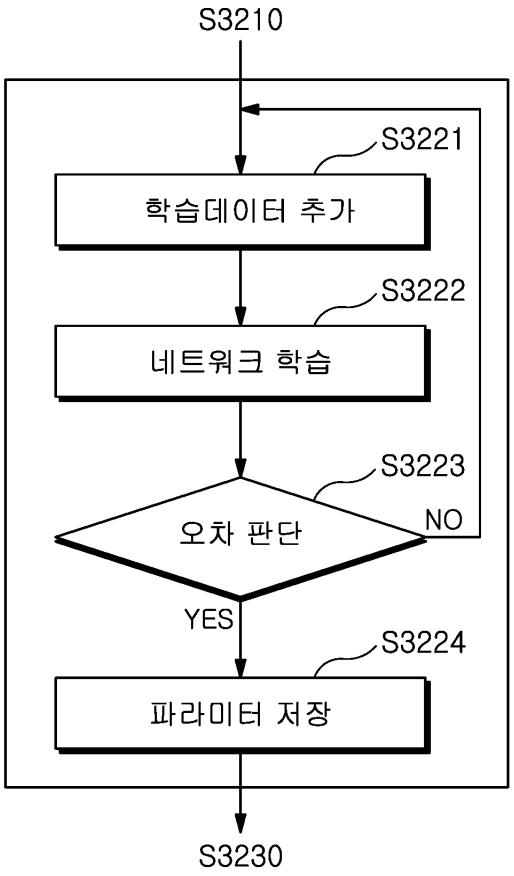
도면10


S3100
S3210
전이 학습
S3220
커리큘럼 학습
S3230
손실함수 판단
NO
YES
S3240
파라미터 결정
S3300

도면11


S3100
사전 데이터 선택
S3211
선행 학습
S3212
파라미터 저장
S3213
S3220

도면12


S3210
S3221
학습데이터 추가
S3222
네트워크 학습
S3223
오차 판단
NO
YES
S3224
파라미터 저장
S3230