

**(19) 대한민국특허청(KR)**
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0072559

(43) 공개일자 2021년06월17일

(51) 국제특허분류(Int. Cl.)
G06N 3/04 (2006.01) *G06N 3/08* (2006.01)(52) CPC특허분류
G06N 3/04 (2013.01)
G06N 3/08 (2013.01)

(21) 출원번호 10-2019-0162982

(22) 출원일자 2019년12월09일

심사청구일자 없음

(71) 출원인

인하대학교 산학협력단

인천광역시 미추홀구 인하로 100(용현동, 인하대 학교)

(72) 발명자

강상길

서울특별시 용산구 새창로 70 (도원동, 도원동삼 성래미안) 108동 1203호

김현석

인천광역시 남동구 장승남로 82 (만수동, 현대아 파트) 101동 204호

허청환

인천광역시 미추홀구 인하로77번길 28 (용현동, 새한아파트) 다동 405호

(74) 대리인

이원희

전체 청구항 수 : 총 2 항

(54) 발명의 명칭 **글로버 풀링이 적용된 CNN을 위한 추가적인 다운샘플링 된 이미지를 이용한 효과적인 필터 프 루닝 방법****(57) 요약**

본 발명의 목적은 네트워크의 프루닝에 있어서 기존의 방법들보다 효율적으로 네트워크의 크기를 줄일 수 있는 방법으로, 기존에 사용된 데이터에 추가적으로 다운샘플링된 데이터를 사용하여 네트워크의 크기를 효과적으로 줄일 수 있는 방법에 관한 것이다

이 발명을 지원한 국가연구개발사업

과제고유번호	18-CM-SW-19
부처명	산업통상자원부, 방위사업청
과제관리(전문)기관명	국방과학연구소 민군협력진흥원
연구사업명	민군겸용기술개발사업/민군기술적용연구사업
연구과제명	소음 및 영상신호 결합기반 무인기 검출기술 개발
기 여 율	1/1
과제수행기관명	한국전자통신연구원
연구기간	2018.10.31 ~ 2021.10.30

명세서

청구범위

청구항 1

CNN의 네트워크 구조의 크기를 감소시키는 동시에 해당 네트워크의 성능을 보존하는 방법에 있어서,
원본 이미지와 해당 이미지를 다운샘플링한 이미지를 모두 이용해 컨벌루션 필터의 중요도를 계산하는 방법.

청구항 2

제 1항에 있어서,
컨벌루션 필터의 중요도를 계산하는 방법은
원본 이미지와 다운샘플링된 이미지를 이용한 경우의 각 컨벌루션 필터가 갖는 그라디언트의 차이를 이용해 계산하는 방법.

발명의 설명

기술 분야

[0001] 본 발명은 글로벌 풀링이 적용된 Convolutional Neural Network (CNN)에 적용될 수 있는 프루닝 방법에 관한 것으로, 기존에 사용된 데이터에 추가적으로 다운샘플링된 데이터를 사용하여 네트워크의 크기를 효과적으로 줄일 수 있는 방법에 관한 것이다.

배경 기술

[0002] CNN의 기술적인 발전으로 물체 분류 및 탐지와 같은 분야의 성능 향상이 이루어지고 있다. 하지만 대부분의 경우, 이러한 deep CNN의 작동을 위해서는 고용량의 메모리를 탑재한 고성능의 GPU가 필요하다. 이러한 방대한 메모리 사용량과 계산 요구량을 줄이기 위해서, 네트워크의 크기를 줄이는 동시에 성능을 유지시키는 다양한 방법들이 연구되어 왔다.

[0003] VGG-16 [Simonyan and Zisserman, 14]와 같은 딥 네트워크의 경우 Fully connected 층이 네트워크 파라미터의 대부분을 차지하고 있으나, 해당 층의 파라미터들의 대부분은 글로벌 풀링이 적용될 경우 제거될 수 있기에 컨벌루션 층의 파라미터를 제거하는 방법의 효율성에 따라 네트워크의 크기를 줄이는 것에 의한 네트워크 성능 하락을 최소화할 수 있다.

발명의 내용

해결하려는 과제

[0004] 본 발명의 목적은 네트워크의 프루닝에 있어서 기존의 방법들보다 효율적으로 네트워크의 크기를 줄일 수 있는 방법을 제공하는 것이다.

과제의 해결 수단

[0005] 원본 이미지와 다운샘플링된 이미지는 그 구조에 있어서 유사성이 있다. 다운샘플링 비율이 너무 높아 물체의 분류를 가능케 하는 특징을 보존할 수 없는 한 인간의 뇌는 해상도와 상관없이 이미지의 물체를 인식할 수 있으며 CNN 또한 비슷한 특징을 보인다. 다른 해상도의 이미지들 사이의 유사성은 효과적인 프루닝을 위해 사용될 수 있다. 글로벌 풀링은 네트워크가 다양한 해상도의 이미지를 처리할 수 있도록 하기 때문에 다운샘플링된 이미지를 이용한 프루닝 방법은 글로벌 풀링이 적용된 네트워크에 대해서 적용 가능하다.

[0006] 개체의 특징은 인접한 픽셀 사이의 관계로 표현될 수 있다. 일단 CNN이 특정 해상도의 이미지를 위해 훈련을 받은 후, 각 경사진 필터는 특정 해상도의 기능에 최적화된다. 다운샘플링 절차 중에 모든 형상이 동일한 비율로

함께 축소된다. 하지만 정보를 잃지 않고 이미지 크기를 줄이는 것은 불가능하다. 이러한 정보 손실 때문에, 원래 해상도를 위한 훈련된 필터는 다른 해상도의 이미지에서 특징을 완벽하게 추출할 수 없다.

[0007] 훈련된 네트워크의 분류 정확도 하락은 테스트 이미지와 훈련 이미지 간의 해상도 차이에 비례한다. 그 차이가 클수록 정확도는 점차 감소하여 훈련되지 않은 네트워크의 정확도에 수렴하게 된다.

[0008] 이러한 점진적인 정확도 감소는 각 정보가 손실되는 시점의 차이에서 기인한다. 이미지에서 세부적인 특징은 그 형상을 구성하는 픽셀의 수가 다른 특징에 비해 상대적으로 적다. 따라서 다운샘플링 과정에서 물체의 특징들은 세부적인 특징일수록 먼저 소실된다. 본 특허는 이러한 특징들의 소실 시점의 차이를 이용한다.

발명의 효과

[0009] 상기에 설명한 대로 각 훈련된 컨벌루션 필터가 반영하는 특징들의 다운샘플링 민감도가 다른 점을 이용하여 상대적으로 분류 정확도에 영향이 적은 필터를 우선적으로 잘라냄으로써 정확도 감소를 최소화한 채 네트워크의 크기를 줄일 수 있다.

발명을 실시하기 위한 구체적인 내용

[0011] 앞 절에서 기술한 바와 같이, 각각의 필터에 의해 추출된 특징의 세부성에 따라 각 컨벌루션 필터는 다운샘플링에 다른 영향을 받게 되는데, 이를 본 특허에서는 다운샘플링 민감도라고 언급한다. 개체의 세부 특징을 반영하는 다운샘플링 민감도가 높은 중요한 필터는 다른 필터보다 다운샘플링에 영향을 크게 받게 되어 정확도 감소에 큰 영향을 준다. 따라서 필터의 중요성은 각 필터가 언제 전체 네트워크 성능에 부정적인 영향을 주는지를 조사하여 판단할 수 있다. 이러한 필터의 다운샘플링 민감도를 평가하기 위해 본 특허에서는 원본 이미지와 다운샘플링된 이미지를 사용하였을 경우의 필터의 그라디언트 차이를 이용한다.

[0012] 소프트맥스를 이용한 CNN의 그라디언트는 최종 출력값인 소프트맥스 값과 분류 라벨을 이용해 계산한다. 적절하게 훈련된 네트워크는 하나의 주요 값과 다른 작은 값으로 구성된 소프트맥스 값 분포를 보여주며 이 관계는 다음과 같이 표현된다.

$$S^j \gg \sum_{k=j} S^k \text{ for } j = \arg \max_k (S^k) \quad (1)$$

[0013] 여기서 S^k 는 k 번째 출력 클래스의 소프트맥스 값을 나타낸다. 식 (1)이 만족되고 네트워크가 다운샘플링된 영상이 아닌 원래 이미지를 이용한 경우 올바르게 분류할 수 있을 때, 임의의 클래스 x에 대한 소프트맥스 값의 그라디언트 차이는 다음과 같이 나타낼 수 있다.

$$\left\| \frac{\delta L_O}{\delta S_O^x} - \frac{\delta L_D}{\delta S_D^x} \right\| \approx \begin{cases} 0, & \arg \max_k (S_D^k) \neq x \\ 1, & \arg \max_k (S_D^k) = x \text{ OR } x = Y \end{cases} \quad (2)$$

[0014] 다.

[0015] 여기서 0, D는 동일한 임의 객체의 원본 이미지 및 다운샘플링된 이미지를 의미하며, L_O 와 L_D 는 각 이미지를 이용한 경우의 loss 값을, Y는 분류 라벨을 나타낸다. 영상 O와 D가 모두 식 (1)을 동일하게 만족하는 동일한 네트워크에 의해 올바르게 분류되는 경우, 임의의 클래스 x에 대한 분류 결과의 그라디언트 차이는 다음과 같이 나타낼 수 있다.

$$\left\| \frac{\delta L_O}{\delta S_O^x} - \frac{\delta L_D}{\delta S_D^x} \right\| \approx 0 \quad (3)$$

[0016]

[0017] 또한 원본 이미지를 올바르게 분류하는 것에 실패하지만 다운샘플링된 이미지에 대해 정확한 분류를 달성한 경우가 있을 수 있으며 이 경우의 그라디언트 차이도 1에 가깝다. 그러나 다운샘플링된 이미지를 사용한 경우의 분류 정확도는 원본 이미지를 사용한 경우보다 확실하게 낮으며, 이는 곧 이러한 경우들의 수가 절대적으로 적다는 것을 의미한다. 또한, 네트워크가 이미지 O와 D에 대해 모두 잘못 분류하였을 경우, 일반적으로 훈련용 데이터셋에 복수의 클래스를 포함하는 복수의 이미지를 이용하는 것을 고려한다면 각 출력 클래스들에 대해 그라디언트 차이가 균등하게 분포되어 궁극적으로 상쇄되게 되므로 이 경우의 그라디언트 차이는 무시할 수 있게 된다. 요약하자면, CNN의 소프트맥스 층에서는 원본 이미지를 사용한 경우 정답이었던 분류 결과가 다운샘플링된

이미지를 사용하여 오답으로 변할 때만 원래 영상의 소프트맥스 값과 다운샘플링된 영상의 소프트맥스 값에 대해 의미 있는 그라디언트 차이가 발생하며, 이는 다음과 같이 표현할 수 있다.

$$\left\| \frac{\delta L_O}{\delta S_O^x} - \frac{\delta L_D}{\delta S_D^x} \right\| \approx \begin{cases} 0, & \arg \max_k (S_O^k) = \arg \max_k (S_D^k) \\ 1, & \arg \max_k (S_O^k) \neq \arg \max_k (S_D^k) \text{ and } x = Y \end{cases} \quad (4)$$

이러한 소프트맥스 값에서 계산된 초기 그라디언트는 네트워크의 역전과 과정 동안 다른 컨벌루션 층들에 전달된다. 그라디언트 차이 또한 동시에 유지되며, 각 필터가 다운샘플링의 영향을 많이 받을수록 이러한 그라디언트의 차이는 더 커진다. 따라서 그라디언트 차이가 큰 필터를 보존하는 것이 곧 상세한 특징을 추출하는 필터를 보존하는 것이며 이를 통해 효과적인 프루닝이 가능하다.

각 필터의 중요도는 이러한 그라디언트 차이의 누적 합계를 사용하여 평가한다. 각 필터는 모든 특징들에 대해 최적화되지 않기 때문에 이 누적 처리 과정은 가능한 한 적은 출력 클래스에 영향을 주는 필터를 우선적으로 제거하기 위해 필요하다. x^i 는 특정 컨벌루션 층에서 피쳐맵의 출력 채널을 나타낸다. 총 K Minibatch로 구성된 데이터 세트의 경우, 각 피쳐맵의 중요성은 다음과 같이 서로 다른 분해능의 영상 사이에 누적 그라디언트 차이를 사용하여 계산한다.

$$\theta_{GD}(x^i) = \sum_{k=1}^K \left(\frac{\delta L_{O,k}}{\delta x^i} - \frac{\delta L_{D,k}}{\delta x^i} \right)^2 \quad (5)$$

식 (5)를 통해 계산된 각 필터의 중요도가 가장 작은 필터를 먼저 잘라내고 다운샘플링에 민감한 필터를 보존함으로써, 네트워크의 성능을 유지한 채 그 크기를 줄일 수 있다.