

객체 감지기의 효율적 반복 학습 알고리즘

이상수, 강현호, 정홍배, 이동훈, 양현민, 안춘기
 고려대학교 전기전자공학과
 e-mail:physism@korea.ac.kr

Intelligent Iterative Learning Algorithm for Object Detector

Sang-Su Lee, Hyun-Ho Kang, Hong-Bae Jeong, Dhong-Hun Lee,
 Hyun-Min Yang, Choon-Ki Ahn
 Dept of Electrical and Computer Engineering, Korea University

요 약

본 논문에서는 기계학습으로 설계된 객체 감지기(object detector)가 주어진 환경에서 객체 검출 작업을 할 때 오인식을 줄이는 방법을 시간, 전력 효율 면에서 고려한다. 먼저 감지해야 하는 객체의 정보를 나타내기 알맞은 이미지 feature를 설정한다. 그리고 AdaBoost를 적용하여 감지기를 설계한 후, 감지기가 주어진 환경에 특화되도록 하는 성능 개선 방법을 제시한다.

1. 서론

널리 상용화된 객체 인식 기술은 이미지 정보를 입력으로 하는 기계학습 분류 문제로 생각할 수 있다[1-3]. 객체 감지기는 주어진 영상에 찾고자 하는 객체가 있는 위치에서 논리적 참 값을 반환하고 아닐 경우 거짓 값을 반환하는 분류기이다. 이 분류기는 feature를 선별하는 작업인 Boosting을 통해 설계한다[4].

본 논문에서는 감지기 구성에 필요한 negative sample을 효율적으로 수집함으로써, 감지기의 오인식을 줄이면서도 학습 시간을 단축하는 저전력 반복 학습 방법에 대하여 알아본다.

2. 본론


2.1 이미지 features

이미지 feature는 영상의 특정 부분에서의 특성을 고려한다. 감지하고자 하는 객체의 성질에 따라 사용하기 적합한 이미지 feature는 다르다. 이미지 feature 중 하나인 Haar feature는 이미지 내부의 일정 구간에서 영역 간의 밝기 차이를 고려한다[5]. 밝기 차이를 나타내는 각 기본적인 형태들은 이미지 내부에서 다양한 크기와 다양한 위치에서 존재할 수 있다. 검출하고자 하는 객체가 특징적인 밝기 차이를 가진다면, Haar feature는 해당 영역에서 일관된 값을 가지는 점에서 용이한 이미지 feature라고 볼 수 있다.

2.2 Boosting

다양한 feature를 고려하여 분류기를 설계할 때 제안되는 다른 방법은 예측 성능이 비교적 낮은 약분류기(weak classifier)들을 결합하여 하나의 강분류기(strong

classifier)를 만드는 Boosting이다.



(그림 1) Boosting의 구성

그림 1은 Boosting의 구성 시 약분류기와 강분류기의 연산 관계를 나타낸다. 강분류기의 출력은 각 약분류기가 추론한 가설 h_n 을 선형 결합하여 정해진다. 약분류기의 가설은 강분류기에서 feature로서 적용된다. 훈련 데이터 집합은 positive 데이터에 대해 출력이 1, negative 데이터에 대해 출력이 -1로 labeling 되었고, 함수 f 는 0 이상의 가설에 대해 +1을, 0보다 작은 가설에 대해 -1을 반환하는 함수이다.

AdaBoost(Adaptive Boosting)는 어떠한 약분류기에 어느 정도의 가중치 α_n 을 부여할 것인지를 결정하는 알고리즘이다. 약분류기를 쌓아나감에 따라, 이전의 분류기들이 오분류 한 데이터에 집중하여 다음 약분류기를 선택하고 가중치를 정한다 [4]. 그림 2에서 처음 t 개의 분류기가 결합되어 만들어진 강분류기의 가설 $H_t(x) = \sum_{k=1}^t \alpha_k h_k(x)$ 이라고 할 때, AdaBoost 알고리즘에서 분류기의 오류 정도를 나타내는 Loss function은 다음 식 (1)과 같이 정의된다.

$$L(H_t) = \sum_i \exp(-y_i H_t(x_i)). \tag{1}$$

식 (1)에서 y_i 는 1 또는 -1의 값을 가지며, 올바른 분류를

위하여 강분류기의 가설 $H_t(\mathbf{x}_i)$ 는 y_i 와 같은 부호의 값을 가지는 것이 바람직하다. 전체 강분류기의 성능을 강화하기 위해 $t+1$ 번째의 약분류기를 채택할 때, 해당 약분류기는 t 번째까지의 약분류기로 구성된 강분류기의 Loss function이 컸던 데이터 \mathbf{x}_i 에 대해 Loss function이 최소한으로 증가하도록 하는 약분류기이어야 한다. $t+1$ 번째 약분류기 h_{t+1} 과 그의 가중치 α_{t+1} 을 구하는 과정은 다음과 같다.

$$\begin{aligned} (h_{t+1}, \alpha_{t+1}) &= \arg \min_{h, \alpha} L(H_t + \alpha h) \\ &= \arg \min_{h, \alpha} \sum_{i=1}^n \exp(-y_i (H_t(\mathbf{x}_i) + \alpha h(\mathbf{x}_i))) \\ &= \arg \min_{h, \alpha} \sum_{i=1}^n w_t(i) \exp(-y_i \alpha h(\mathbf{x}_i)). \end{aligned}$$

위의 전개과정에서 $w_t(i)$ 는 $L(H_t)$ 와 같다. h_{t+1} 과 α_{t+1} 을 따로 고려하면 각각 다음과 같이 전개됨을 보일 수 있다.

$$h_{t+1} = \arg \min_h \epsilon_t, \tag{2}$$


$$\alpha_{t+1} = \arg \min_{\alpha} (e^{\alpha} - e^{-\alpha}) \epsilon_t + e^{-\alpha}. \tag{3}$$

식 (2)과 (3)에서 $\epsilon_t = \sum_{i=1}^n w_t(i) \mathbf{1}(y_i \neq h(\mathbf{x}_i))$ 이다. AdaBoost를 통해 효용성 높은 이미지 feature들을 고른 후 각각의 가중치를 고려하면 최종적으로 객체 감지기를 구현할 수 있다.

2.3 오인식의 개선

완전한 학습이 이루어지지 않은 객체 감지기는 특정한 물체에 대해서 반복적으로 오인식을 하는 경향이 나타난다. negative sample을 추가하여 감지기를 재학습하면 오인식이 줄어들지만, 지나치게 많은 negative sample 추가는 감지 자체를 위축한다.

인식하고자 하는 객체가 존재하지 않는 환경에서 촬영된 영상에서 감지기가 감지하는 객체는 오인식이 명백하다. 이 명백한 오인식을 추가적인 negative sample로 활용한다면, 같은 수의 다른 임의의 negative sample을 추가하는 것보다 큰 성능 변화를 기대할 수 있다. 그림 2는 이러한 피드백 과정을 통해 감지기가 강화되는 순서도를 나타낸다.



(그림 2) Negative video를 이용한 감지기 강화

positive와 negative 훈련 데이터를 직접 수집하는 기존의 감지기 설계 방법과는 달리, 위와 같이 negative video를 활용하면 negative 훈련 데이터를 자동으로 생성할 수 있다는 장점이 있다. 특히 영상에서 오인식 부분만

을 취하여 저장하면 식 (1)에서 AdaBoost를 통해 선정된 기존의 feature를 적용할 경우 Loss function이 크게 증가하게 되므로, 재학습 시 기존 오인식을 줄이는 방향으로 이미지 feature가 선정될 것임을 기대할 수 있다.


3. 실험

3.1 표적 인식

이 절에서는 실제로 감지하고자 하는 객체를 설정하고 감지기 학습 및 감지 작업을 하고자 한다. positive sample과 negative sample 수집은 실험 환경에서 다양한 위치와 방향에서 촬영하였다. 총 629개의 positive sample과 2,334개의 negative sample을 수집하였다. 감지하고자 하는 표적지로는 다음의 표적지를 사용하였다.




(그림 3) 실험에 사용한 표적지



(그림 4) Haar feature로 학습한 감지기의 인식


3.2 성능 강화

감지기의 객체에 대한 인식률이 충분히 보장된 후, 성능 향상에서 유의해야 할 점은 오인식을 개선하는 것이다. 기존 감지기에서 오인식한 정보를 negative sample에 추가함으로써 개선해보도록 한다.



(그림 5) 오인식 정보 수집 및 저장

그림 5는 객체가 없는 실험 환경에서 촬영한 영상을 바탕으로 오인식한 부분의 이미지만을 취하여 저장하는 모습을 나타낸다. 이와 같은 과정으로 161개의 오인식 이미지를 저장하였다.



(그림 6) 감지기 개선 전후의 성능 비교

그림 6은 앞에서 저장한 이미지들을 사용하여 오인식을 개선한 후, 기존 감지기와의 성능을 비교한 것이다. 개선 이후에는 실제 객체에 대한 감지율이 조금 감소하나, 오인식 했던 대상은 대부분 negative class로 성공적으로 분류하는 것을 확인하였다. 기존의 negative sample의 수인 2,334개에 비해 매우 적은 수인 161개만을 추가했음에도 고정된 실험 환경에 대한 오인식을 크게 줄여준다는 점을 확인하였다.

4. 결론

본 논문에서는 이미지 feature라는 선형 분류기들을 AdaBoost 알고리즘을 사용하여, 객체 감지기를 구현하고 성능을 확인해 보았다. 설계된 감지기는 감지하고자 하는 객체가 없는 환경에서 오인식만을 검출한다는 점을 이용하여, 오인식 정보를 negative sample로서 수집하여 감지기를 재학습해보았다. 재학습된 감지기는 해당 오인식을 크게 줄이는 점을 확인하였다. 목표물 추적과 같이 단 한번의 오인식조차도 큰 위험이 될 수 있는 객체 인식의 문제에서, 이와 같은 집중적인 negative 학습은 큰 도움을 줄 수 있다. 성능 개선과 더불어 negative sample의 효율적인 선택은 감지기의 학습 시간과 소요 전력 면에서 이점을 준다.

감사의 글

본 연구는 2015년도 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 에너지인력양성사업으로 지원 받아 수행한 인력양성 성과이며(No. 20154030200610), 2014년도 산업통상자원부의 재원으로 한국에너지기술평가원(KETEP)의 지원(No. 20142010102390)을 받아 수행하였습니다.

참고문헌

[1] Alpaydin, Ethem (2010). Introduction to Machine

Learning. MIT Press. p. 9.
 [2] Guo-Xun Yuan; Chia-Hua Ho; Chih-Jen Lin (2012). "Recent Advances of Large-Scale Linear Classification". Proc. IEEE.
 [3] Cortes, C.; Vapnik, V. (1995). "Support-vector networks". 《Machine Learning》 20 (3): 273. doi:10.1007/BF00994018.
 [4] Boris Babenko, Note: A Derivation of Discrete AdaBoost [Internet]. Available: http://vision.ucsd.edu/~bbabenco/data/boosting_note.pdf.
 [5] P. Viola and M. J. Jones, "Rapid Object Detection using a Boosted Cascade of Simple Features", CVPR 2001.
 [6] N. Dalal and B. Triggs, "Histograms of oriented gradients for human detection", CVPR 2005.
 [7] Nishii, R. & S. Eguchi, Supervised Image Classification based on AdaBoost with Contextual Weak Classifiers[C].//Proc. of 2004 IEEE International Geoscience and Remote Sensing Symposium II, 2004, pp. 1467-1470.