

Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization

0. Author



Ramprasaath R. Selvaraju

Explainable AI Researcher
Verified email at apple.com

Explainable AI Computer Vision Machine Learning




GET MY OWN PROFILE

TITLE	CITED BY	YEAR
Grad-cam: Visual explanations from deep networks via gradient-based localization RR Selvaraju, M Cogswell, A Das, R Vedantam, D Parikh, D Batra Proceedings of the IEEE international conference on computer vision, 618-626	32768	2017
Align before fuse: Vision and language representation learning with momentum distillation J Li, R Selvaraju, A Gotmare, S Joty, C Xiong, SCH Hoi Advances in neural information processing systems 34, 9694-9705	2671	2021
Grad-CAM: Why did you say that? RR Selvaraju, A Das, R Vedantam, M Cogswell, D Parikh, D Batra arXiv preprint arXiv:1611.07450	924	2016
Proceedings of the IEEE international conference on computer vision RR Selvaraju, M Cogswell, A Das, R Vedantam, D Parikh, D Batra Proceedings of the IEEE international conference on computer vision [J]	334	2017
Taking a hint: Leveraging explanations to make vision and language models more grounded RR Selvaraju, S Lee, Y Shen, H Jin, S Ghosh, L Heck, D Batra, D Parikh Proceedings of the IEEE/CVF international conference on computer vision ...	319	2019
Diverse beam search for improved description of complex scenes A Vijayakumar, M Cogswell, R Selvaraju, Q Sun, S Lee, D Crandall, ... Proceedings of the AAAI Conference on Artificial Intelligence 32 (1)	296	2018

Cited by

	All	Since 2020
Citations	38150	36294
h-index	15	15
i10-index	18	18



Public access

VIEW ALL

0 articles


7 articles

not available

available

Based on funding mandates

1. Background



• Class Activation Map

$$M_c(x, y) = \sum_k w_k^c f_k(x, y)$$

c : 특정 클래스 ex. 고양이


$f_k(x, y)$: k 번째 Feature map

특정 클래스 c 최종 점수: $S_c = \sum_k w_k^c F_k$

➡ w_k^c : 각 Feature map의 중요도 점수

"왜 CAM은 GAP이 필요했는가?"

1. Background



- 모델이 이미지의 왼쪽 위에 귀가 있다고 학습했을 때,


$$\begin{pmatrix} 10 & 1 \\ 1 & 1 \end{pmatrix} \rightarrow \text{Flatten: } [10, 1, 1, 1]$$

Fully Connected Layer: Dog Class Weight = [0.9, 0.1, 0.1, 0.1]


Dog Class's 최종 점수: $10 * 0.9 + 1 * 0.1 + 1 * 0.1 + 1 * 0.1 = 9.3$

→ 매우 높은 점수로 "강아지"라 확신 및 분류한다.

FC Layer: Flatten(F_k) → 분류할 클래스



1. Background



- 예측을 진행할 새로운 이미지의 강아지 귀가 오른쪽 아래에 있을 때,


$$\begin{pmatrix} 1 & 1 \\ 1 & 10 \end{pmatrix} \rightarrow \text{Flatten: } [1, 1, 1, 10]$$

Fully Connected Layer: Dog Class Weight = [0.9, 0.1, 0.1, 0.1]


→ 학습된 그대로 고정

Dog Class's 최종 점수: $1 * 0.9 + 1 * 0.1 + 1 * 0.1 + 10 * 0.1 = 2.1$


FC Layer: Flatten(F_k) → 분류할 클래스



1. Background



FC Layer: Global Average Pooling(F_k) → 분류할 클래스



- 모델이 이미지의 왼쪽 위에 귀가 있다고 학습했을 때,


$$\begin{pmatrix} 10 & 1 \\ 1 & 1 \end{pmatrix} \rightarrow \text{Global Average Pooling(GAP): } \frac{10+1+1+1}{4} = 3.25$$

Fully Connected Layer: Dog Class Weight = [2.86]


Dog Class's 최종 점수: $3.25 * 2.86 \approx 9.3$

→ 매우 높은 점수로 "강아지"라 확신 및 분류한다.

1. Background



FC Layer: Global Average Pooling(F_k) → 분류할 클래스



- 예측을 진행할 새로운 이미지의 강아지 귀가 오른쪽 아래에 있을 때,
 $\begin{pmatrix} 1 & 1 \\ 1 & 10 \end{pmatrix} \rightarrow \text{Global Average Pooling(GAP): } \frac{10+1+1+1}{4} = 3.25$

Fully Connected Layer: Dog Class Weight = [2.86]

→ 학습된 그대로 고정

Dog Class's 최종 점수: $3.25 * 2.86 \approx 9.3$

1. Background

• Class Activation Map

$$M_c(x, y) = \sum_k w_k^c f_k(x, y)$$

c : 특정 클래스 ex. 고양이

$f_k(x, y)$: k 번째 Feature map

특정 클래스 c 최종 점수: $S_c = \sum_k w_k^c F_k$

➡ w_k^c : 각 Feature map의 중요도 점수

- 모델의 마지막 Convolution Layer 4개의 Filter

$k_1 \rightarrow F_1$: "뾰족한 귀" 특징을 추출하는 Filter 및 결과 Feature map₁

$k_2 \rightarrow F_2$: "수염/코" 특징을 추출하는 Filter 및 결과 Feature map₂

$k_3 \rightarrow F_3$: "날름거리는 혀" 특징을 추출하는 Filter 및 결과 Feature map₃

$k_4 \rightarrow F_4$: "바퀴 모양" 특징을 추출하는 Filter 및 결과 Feature map₄


- 모델이 학습을 마친 후 최종 클래스 "고양이, 강아지"를 판단하기 위해 중요도 점수

$$W_{cat} = [0.9, 0.7, 0.3, -0.1], W_{dog} = [0.2, 0.8, 0.9, -0.1]$$

- CAM 시각화

$$M_{cat} = f_1(x, y) * 0.9 + f_2(x, y) * 0.7 + f_3(x, y) * 0.3 + f_4(x, y) * (-0.1)$$

2. Grad-CAM



$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \rightarrow L_{Grad-CAM}^c = ReLU(\sum_k \alpha_k^c A^k)$$

2. Grad-CAM

- 모델 구조:

마지막 Convolution Layer → Global Average Pooling → Fully-Connected Layer → 최종 점수

- 마지막 Convolutional Layer의 출력 특징 맵 A

각 채널별 특징 맵 A^1, A^2, A^3

$$A^1 = \begin{pmatrix} 1 & 3 \\ 4 & 2 \end{pmatrix}, A^2 = \begin{pmatrix} 2 & 1 \\ 1 & 5 \end{pmatrix}, A^3 = \begin{pmatrix} 0 & 2 \\ 3 & 1 \end{pmatrix}$$

- Fully-Connected Layer의 가중치 W

클래스는 "고양이"와 "개" 두 가지가 있다고 가정할 때, "고양이" 클래스 예측을 위한 가중치 벡터 w^{cat}

$$w^{cat} = \begin{pmatrix} w_1^{cat} \\ w_2^{cat} \\ w_3^{cat} \end{pmatrix} = \begin{pmatrix} 0.5 \\ 0.8 \\ -0.2 \end{pmatrix} \quad \text{참고 : } w^{dog} = \begin{pmatrix} -0.3 \\ 0.1 \\ 0.9 \end{pmatrix}$$

2. Grad-CAM

$$f^1 = \text{Average}(A^1) = \frac{1+3+4+2}{4} = 2.5, f^2 = \text{Average}(A^2) = 2.25,$$

$$f^3 = \text{Average}(A^3) = 1.5$$

$$y^{\text{cat}} = w_1^{\text{cat}} f^1 + w_2^{\text{cat}} f^2 + w_3^{\text{cat}} f^3 = 2.5 \cdot 0.5 + 2.25 \cdot 0.8 + 1.5 \cdot (-0.2) = 2.75$$

$$y^{\text{dog}} = 1.1, y^{\text{car}} = -0.5$$

→ 고양이 의 점수인 2.75가 가장 높기 때문에 모델은 이 이미지를 '고양이'일 가능성이 가장 높다고 판단

$$[y^{\text{cat}}, y^{\text{dog}}, y^{\text{car}}] = [2.75, 1.1, -0.5]$$

$$P(\text{class}_i) = \frac{e^{y_i}}{\sum_j e^{y_j}}$$

$$P(\text{cat}) = \frac{e^{2.75}}{e^{2.75} + e^{1.1} + e^{-0.5}} \approx 0.83$$

$$P(\text{dog}) = \frac{e^{1.1}}{e^{2.75} + e^{1.1} + e^{-0.5}} \approx 0.16$$

$$P(\text{car}) = \frac{e^{-0.5}}{e^{2.75} + e^{1.1} + e^{-0.5}} \approx 0.01$$

2. Grad-CAM

“고양이” 클래스 점수 y^{cat} 에 대한 마지막 합성곱 레이어의 각 픽셀별 Gradient, 즉 Gradient map $\frac{\partial y^{cat}}{\partial A_{ij}^k}$ 를

- 연쇄 법칙을 이용하여 계산하기

$$\text{Gradient map} \rightarrow \frac{\partial y^{cat}}{\partial A_{ij}^k} = \frac{\partial y^{cat}}{\partial f^k} \times \frac{\partial f^k}{\partial A_{ij}^k}$$

$$\frac{\partial y^{cat}}{\partial f^1} = \frac{\partial}{\partial f^1} (0.5f^1 + 0.8f^2 - 0.2f^3) = 0.5, \quad \frac{\partial y^{cat}}{\partial f^2} = 0.8, \quad \frac{\partial y^{cat}}{\partial f^3} = -0.2$$

- “특징 맵의 특정 픽셀 A_{ij}^k 값이 변할 때, 그 채널의 평균값 f^k 이 얼마나 변하는가?”를 계산

$$f^k = \frac{1}{z} \sum_i \sum_j A_{ij}^k = \frac{1}{4} (A_{11}^k + A_{12}^k + A_{21}^k + A_{22}^k) \rightarrow \frac{\partial f^k}{\partial A_{ij}^k} = \frac{1}{4} = 0.25$$

→ 채널 내의 모든 픽셀에 대해 동일

$$\frac{\partial y^{cat}}{\partial A_{ij}^1} = 0.5 \times 0.25 = 0.125, \quad \frac{\partial y^{cat}}{\partial A_{ij}^2} = 0.8 \times 0.25 = 0.2, \quad \frac{\partial y^{cat}}{\partial A_{ij}^3} = -0.2 \times 0.25 = -0.05$$

$$\text{채널 1의 Gradient map} \rightarrow \nabla A^1 = \begin{pmatrix} 0.125 & 0.125 \\ 0.125 & 0.125 \end{pmatrix}, \quad \nabla A^2 = \begin{pmatrix} 0.2 & 0.2 \\ 0.2 & 0.2 \end{pmatrix}$$

→ 해당 값은 각 특징 맵의 픽셀 활성화 값이 “고양이” 점수에 얼마나 큰 영향을 미치는지를 나타낸다.

2. Grad-CAM

1. 필터 중요도 가중치 α_l^{cat} 계산:

Grad-CAM은 각 Gradient 맵에 대해 GAP을 다시 적용하여 채널별 최종 중요도 가중치 α_k^{cat} 구한다.

$$\alpha_1^{cat} = Average(\nabla A^1) = 0.125, \alpha_2^{cat} = Average(\nabla A^2) = 0.2,$$

$$\alpha_3^{cat} = Average(\nabla A^3) = -0.05$$


2. 히트맵 생성:

이 가중치들을 원본 특정 맵 A^k 에 곱하여 더한 후, ReLU 함수를 적용하여 최종 Grad-CAM 히트맵을 만든다.

$$L_{Grad-CAM}^{cat} = ReLU(\sum_k \alpha_k^{cat} A^k) = ReLU(0.125 \cdot A^1 + 0.2 \cdot A^2 - 0.05 \cdot A^3)$$

ReLU 함수: "고양이"일 확률을 높이는 증거들을 보고 싶은 것이지, "고양이"일 확률을 낮추는 증거에는 관심 X


3. Result




(a) Original Image



(c) Grad-CAM 'Cat'




(f) ResNet Grad-CAM 'Cat'



(g) Original Image




(i) Grad-CAM 'Dog'



(l) ResNet Grad-CAM 'Dog'

3. Result



3. Result




A group of people flying kites on a beach

A man is sitting at a table with a pizza

(a) Image captioning explanations



What color is the firehydrant?



(a) Visualizing VQA model from [38]

4. Code

```
# Grad-CAM 구현: 특정 레이어의 Feature Map(Activation)과 Gradient를 모두 얻어오기
class GradCAM:
    def __init__(self, model, target_layer):
        self.model = model
        self.target_layer = target_layer
        self.feature_map = None
        self.gradient = None

        self.target_layer.register_forward_hook(self.save_feature_map) #
        self.target_layer.register_full_backward_hook(self.save_gradient) #

    def save_feature_map(self, module, input, output):
        self.feature_map = output.detach()

    def save_gradient(self, module, gradient_input, gradient_output):
        self.gradient = gradient_output[0].detach()

    def generate_grad_cam(self, x, class_idx):
        # 목표 class 점수를 각 Feature Map으로 미분한 값을 모든 Feature map에 대해 구하는 과정 -> Grad-CAM을 그리기 위해
        self.model.zero_grad() # 이전 계산에서 남아있을 수 있는 그라디언트를 모두 0으로 초기화
        output = self.model(x)

        one_hot = torch.zeros_like(output) # output 텐서와 완전히 동일한 모양(shape)을 가지지만, 모든 요소가 0으로 채워진 새로운 텐서 생성 ex. [1, 1000] (배치크기 1, 클래스 1000개)
        one_hot[0][class_idx] = 1
        output.backward(gradient=one_hot, retain_graph=True) # 클래스 c에 대해 각 feature map으로 미분한 것이 self.gradient에 저장 -> Gradient map

        # GAP: gradient shape = [1, C, H, W] -> [1, C, 1, 1]
        weights = F.adaptive_avg_pool2d(self.gradient, 1)

        # Grad-CAM 생성
        # weights * self.feature_map: 각 채널에 해당하는 가중치가 곱해져서 [1, C, 1, 1] * [1, C, H, W] = [1, C, H, W]
        grad_cam = torch.sum(weights * self.feature_map, dim=1, keepdim=True) # C개의 모든 Feature Map을 더해서 하나의 Feature Map으로 압축: [1, C, H, W] -> [1, 1, H, W]
        grad_cam = F.relu(grad_cam)



        # 히트맵 시각화를 위해 크기 조정 및 정규화
        # 텐서에서 크기가 1인 차원을 모두 제거: [1, 1, H, W] -> [H, W] 후 텐서가 GPU(CUDA) 메모리에 올라가 있다면, CPU 메모리로 이동 및 pytorch 텐서를 numpy 배열로 변환한다.
        grad_cam = grad_cam.squeeze().cpu().numpy()
        # (x.shape[3], x.shape[2])는 크기를 조절할 목표 해상도로, OpenCV는 (너비, 높이) 순서로 인자를 받으며, 이를 통해 이미지 크기 조절
        grad_cam = cv2.resize(grad_cam, (x.shape[3], x.shape[2]))
        # 히트맵의 모든 픽셀 값을 0과 1 사이의 값으로 정규화(Normalization), Min-Max 정규화 적용
        # 0~1 사이로 값을 통일하면, 가장 낮은 활성화 영역은 0(파란색 계열), 가장 높은 활성화 영역은 1(붉은색 계열)로 일관되게 매핑 가능
        grad_cam = (grad_cam - np.min(grad_cam)) / (np.max(grad_cam) - np.min(grad_cam))

        return grad_cam
```


5. Code Results




5. Code Results



5. Code Results





5. Code Results



5. Code Results



5. Code Results



6. Code - points to consider

```
# 모델이 예측을 수행하고 Grad-CAM 히트맵을 생성하는 데 사용한 데이터는 원본 이미지가 아니라 전처리(transforms)가 모두 완료된 input_tensor이기 때문에,  
# input_tensor를 역으로 변환하여 사용하면, 모델이 본 정확히 그 224x224 영역의 이미지 위에 히트맵을 완벽하게 겹칠거라 판단  
def tensor_to_image(tensor):  
    mean = np.array([0.485, 0.456, 0.406])  
    std = np.array([0.229, 0.224, 0.225])  
    """  
    모델이 보는 이미지 (정규화된 텐서):  
    transforms.Normalize를 거친 input_tensor의 픽셀 값은 우리가 흔히 아는 0~255 범위가 아니고,  
    평균이 0, 표준편차가 1에 가깝게 분포하며, 음수 값도 포함된 특이한 숫자들의 집합이다.  
    컴퓨터(모델)는 이 상태의 데이터를 학습하고 예측하는 데 익숙하다.  
  
    사람이 보는 이미지:  
    우리의 눈과 모니터는 픽셀 값이 0(검은색)~255(흰색/컬러) 범위에 있는 이미지를 정상적으로 보여준다.  
    만약 정규화된 텐서를 그대로 이미지로 표시하려고 하면, 색이 완전히 틀어지고 이상하게 보일 것이다.  
  
    역정규화 후 유지되는 것:  
    이미지 크기: 224x224 사이즈가 그대로 유지된다.  
    잘린 영역 (Content): CenterCrop으로 잘려나간 정확히 그 이미지 영역이 그대로 유지되며, 이미지 속 고양이의 귀 모양, 건물의 창문 위치 등 모든 공간적 정보가 동일하다.  
    """  
    img_np = tensor.squeeze(0).cpu().numpy() # 배치 차원 제거  
    img_np = np.transpose(img_np, (1, 2, 0)) # (C, H, W) -> (H, W, C)  
    img_np = std * img_np + mean  
    # img_np는 이론적으로는 0.0 ~ 1.0 사이의 값을 가져야 하지만 부동 소수점 연산 시 발생하는 미세한 오차 때문에 간혹 -0.0001처럼 0보다 약간 작거나 1.0002처럼 1보다 약간 큰 값이 생길 수 있다.  
    # np.clip(array, min, max) 함수는 배열의 모든 값들을 확인해서 min 값보다 작으면 min 값으로, max 값보다 크면 max 값으로 만든다.  
    img_np = np.clip(img_np, 0, 1)  
    # JPG, PNG 같은 이미지 파일 형식은 각 색상 채널을 0부터 255까지의 정수로 표현하기 때문에,  
    # 0 ~ 255 범위의 값으로 스케일링 후 스케일링된 소수점 값들을 uint8 자료형으로 변환 ex. 127.5 -> 127  
    img_np = (img_np * 255).astype(np.uint8)  
    return img_np
```


7. Recent Advances

