

2023 동계 세미나

# Self-attention 경량화

---



*Sogang University*

*Vision & Display Systems Lab, Dept. of Electronic Engineering*



*Presented by*

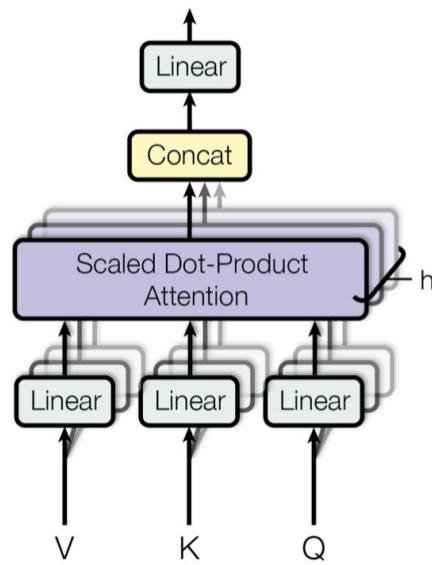
유현우

# Outline

- Background
  - Multi head self attention
  - Self attention 연산량
- Self attention 경량화
  - Efficient Attention: Attention with Linear Complexities
    - WACV 2021 인용 150
  - Hydra Attention : Efficient Attention with Many Heads
    - ECCV workshop 2022
- Conclusion

# Background

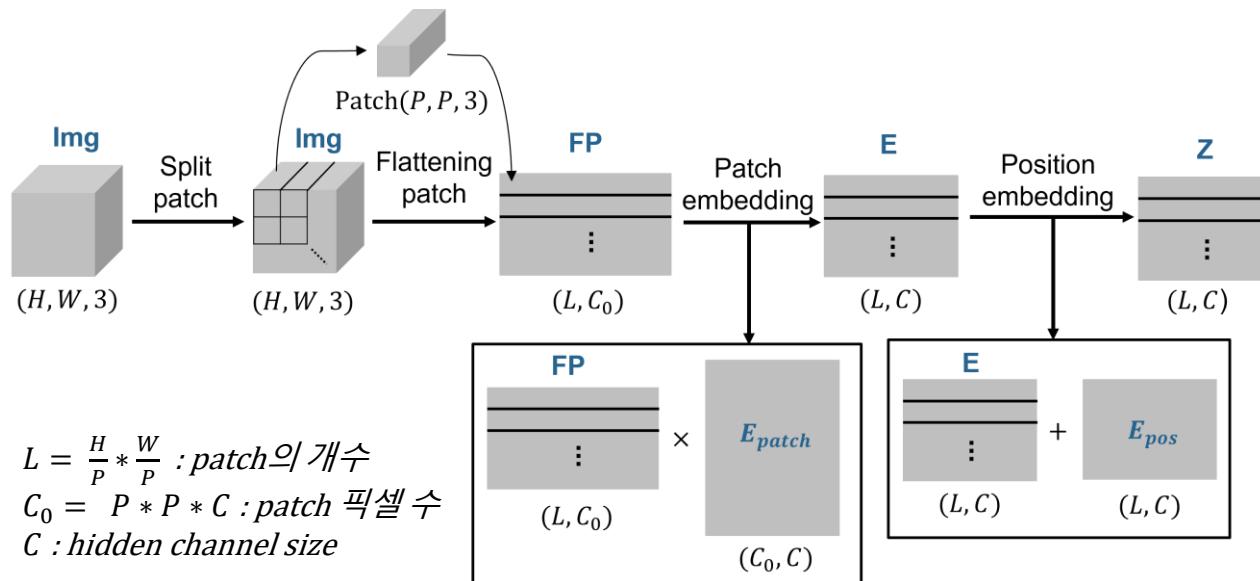
- Transformer
  - Query, key, value 간에 similarity를 기반으로 feature representation을 수행
  - 특정 token과 전역적으로 존재하는 token과의 관계를 고려하므로 global한 특성을 고려하여 feature를 추출할 수 있다는 장점이 있음
    - 자연어 처리 분야에서 처음 제안되었고, vision 분야에서도 다양한 task에서 좋은 성능을 보임



Multi head self attention

# Background

- Embedding
  - Input patch를 flatten한 후 linear projection을 이용해 patch embedding 수행
    - Patch를 대표하는 feature를 1d token의 형태로 표현
  - Linear projection 연산은 MLP layer 또는 1x1 convolution으로 수행 가능



Embedding overview

# Background

- Self attention

- Learnable parameter로 linear projection을 수행하여 query, key, value 생성
- Query, key간의 연산(Key · Query.transpose)을 통해 얻은 가중치를 value에 적용

$$[\mathbf{q}, \mathbf{k}, \mathbf{v}] = \mathbf{z} \mathbf{U}_{qkv}$$

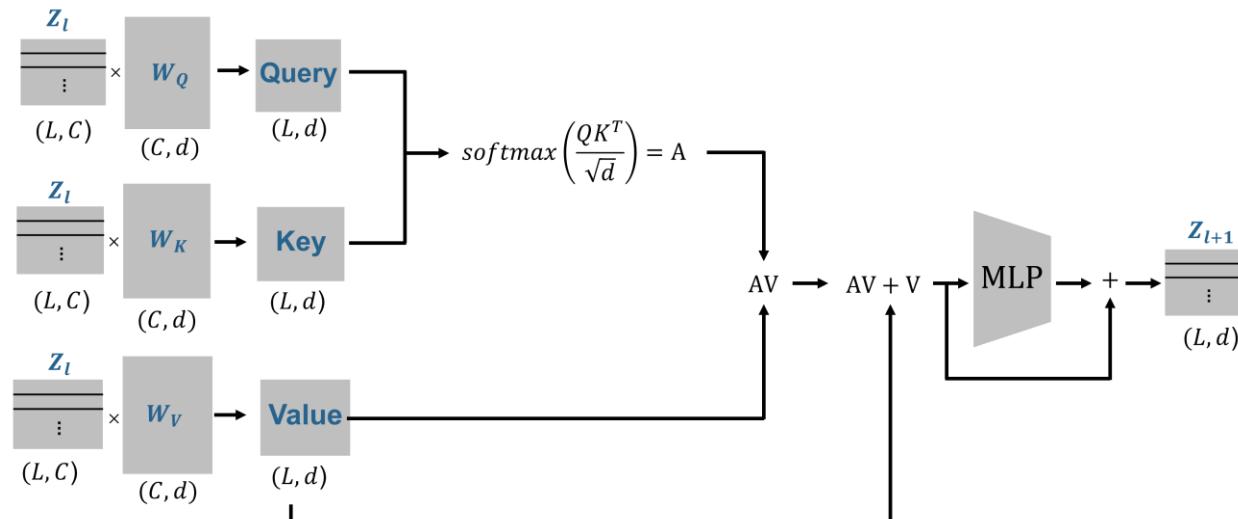
$$\mathbf{U}_{qkv} \in \mathbb{R}^{D \times 3D_h},$$

$$A = \text{softmax}\left(\mathbf{q}\mathbf{k}^\top / \sqrt{D_h}\right)$$

$$A \in \mathbb{R}^{N \times N},$$

$$\text{SA}(\mathbf{z}) = A\mathbf{v}.$$

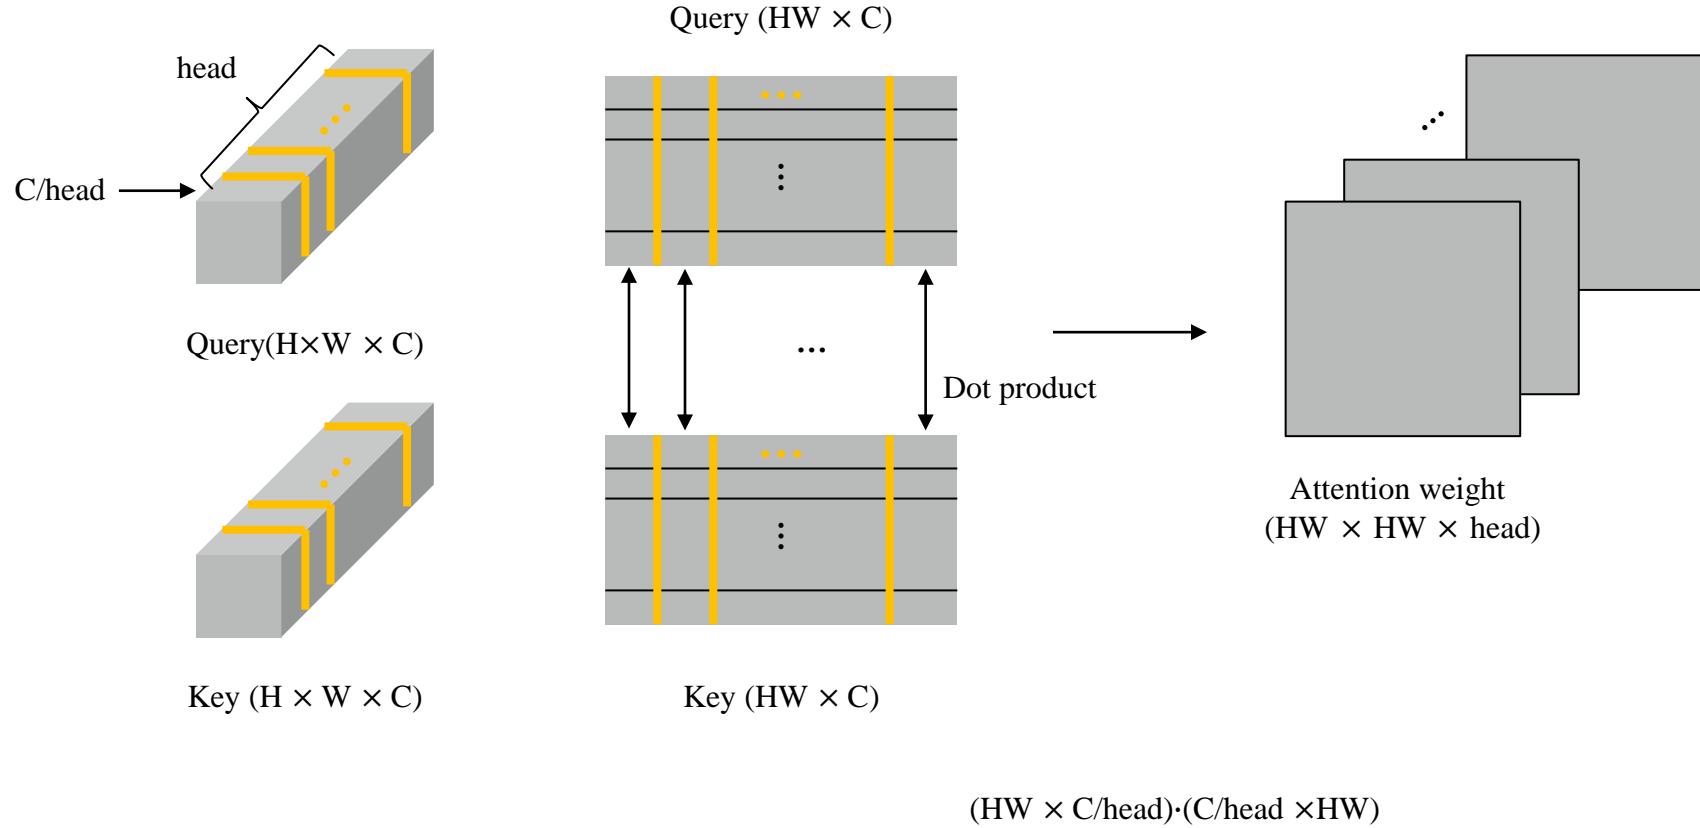
$$\text{MSA}(\mathbf{z}) = [\text{SA}_1(z); \text{SA}_2(z); \dots; \text{SA}_k(z)] \mathbf{U}_{msa} \quad \mathbf{U}_{msa} \in \mathbb{R}^{k \cdot D_h \times D}$$



Self-attention overview

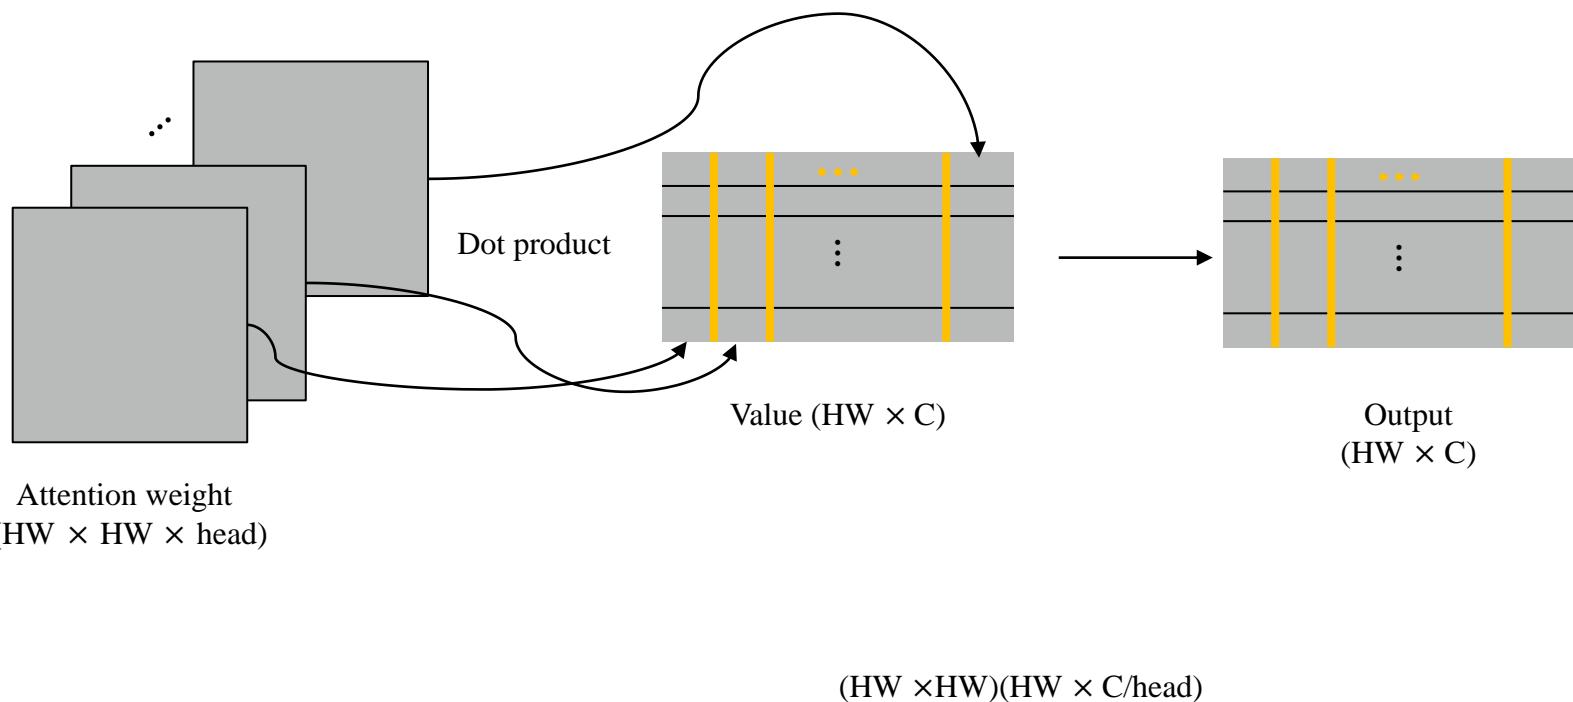
# Background

- Multi head self attention



# Background

- Multi head self attention



# Background

- Vision transformer(ViT) 연산량

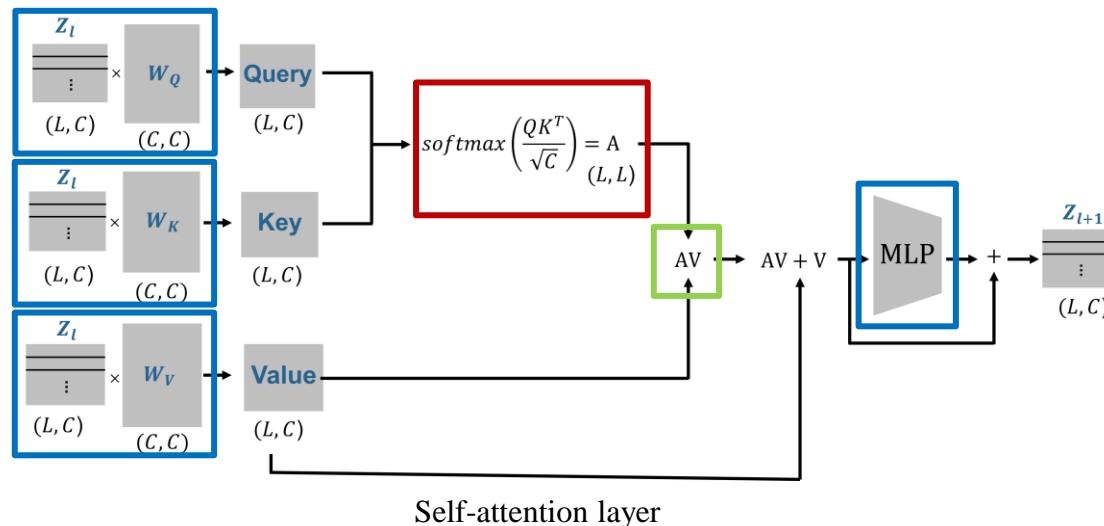
- Self attention computational complexity of ViT :  $2(hw)^2C \rightarrow O((hw)^2C)$

- hw : patch 개수(L), C : hidden dimension

- Computational complexity 계산

↳  $(hw \times C) \cdot (C \times hw)$  연산 1번  $\rightarrow (hw)^2C$

↳  $(hw \times hw) \cdot (hw \times C)$  연산 1번  $\rightarrow (hw)^2C$

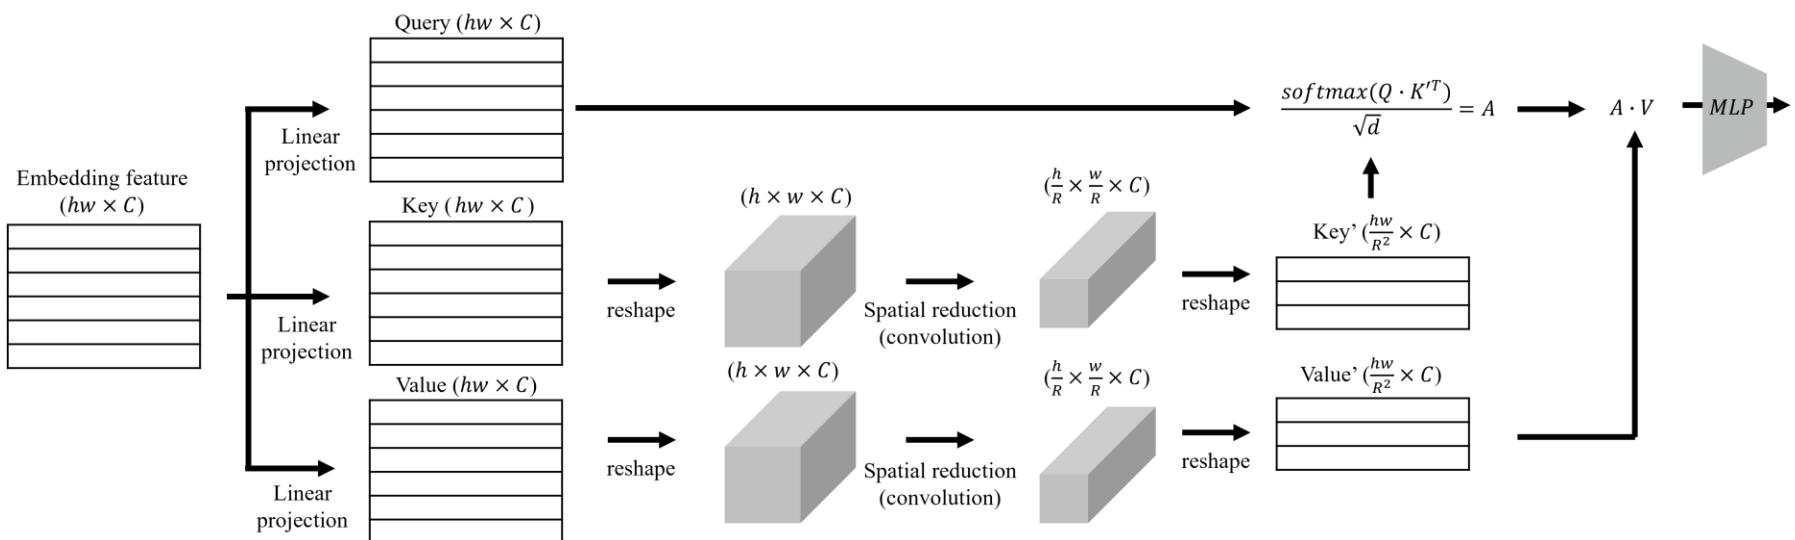
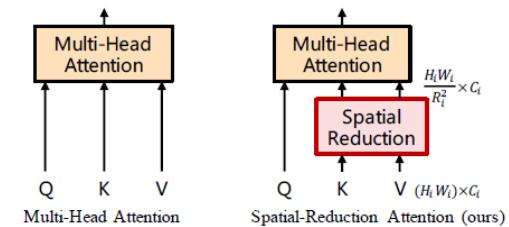


Self-attention layer

# Background

- Pyramid vision transformer(PVT) [1]

- Key, value의 resolution을 감소시켜 self attention을 수행하는 spatial reduction attention (SRA) 제안



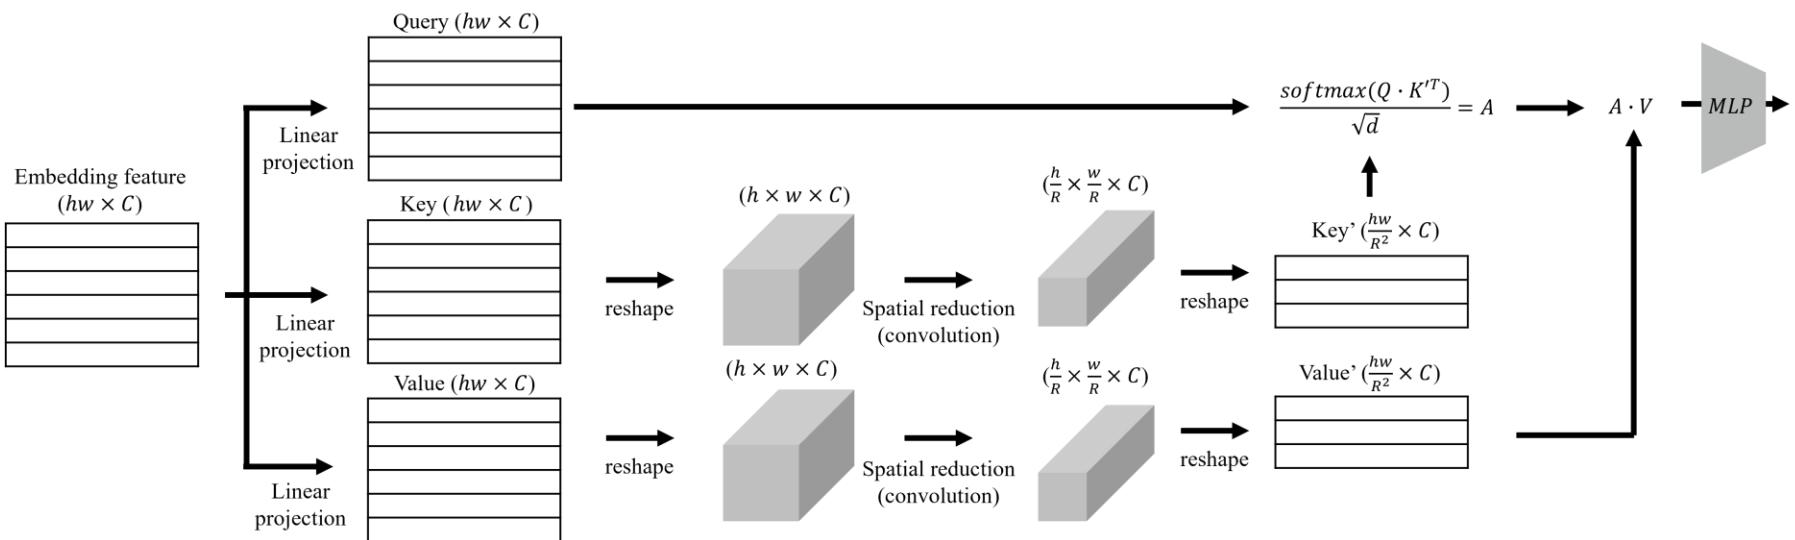
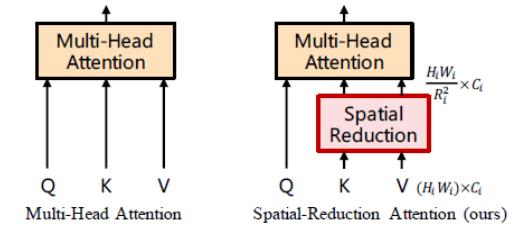
# Background

- Pyramid vision transformer(PVT)

- $\text{Query} \cdot \text{key.transpose} = A \rightarrow (hw \times C) \cdot (C \times \frac{hw}{R^2}) = (hw \times \frac{hw}{R^2})$

- $A \cdot \text{value} = \text{output} \rightarrow (hw \times \frac{hw}{R^2}) \cdot (\frac{hw}{R^2} \times C) = (hw \times C)$

- hw : patch 개수(L), C : hidden dimension



# Background

- Pyramid vision transformer(PVT)

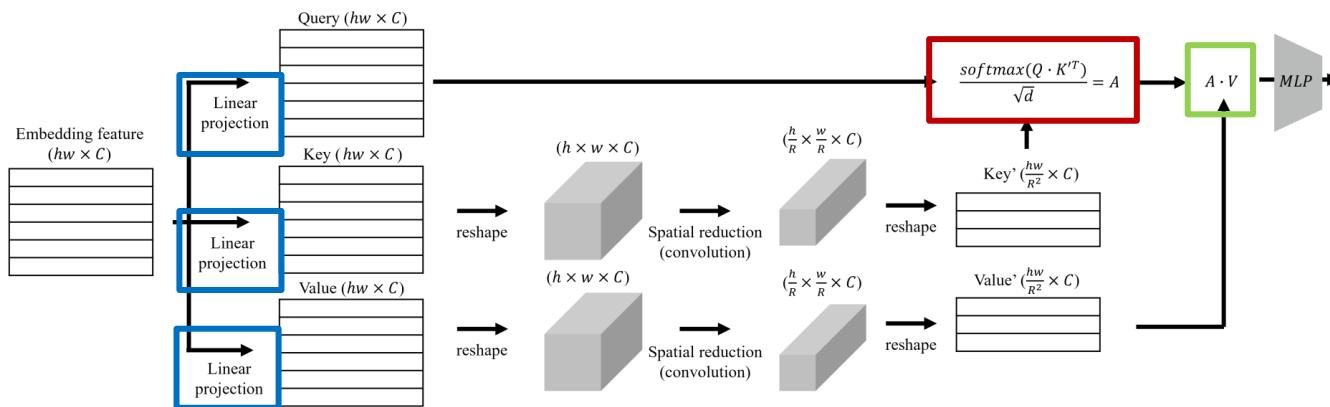
- Self attention computational complexity :  $2 \frac{(hw)^2}{R^2} C \rightarrow O(hw^2 C)$

- hw : patch 개수(L), C : hidden dimension

- Computational complexity 계산

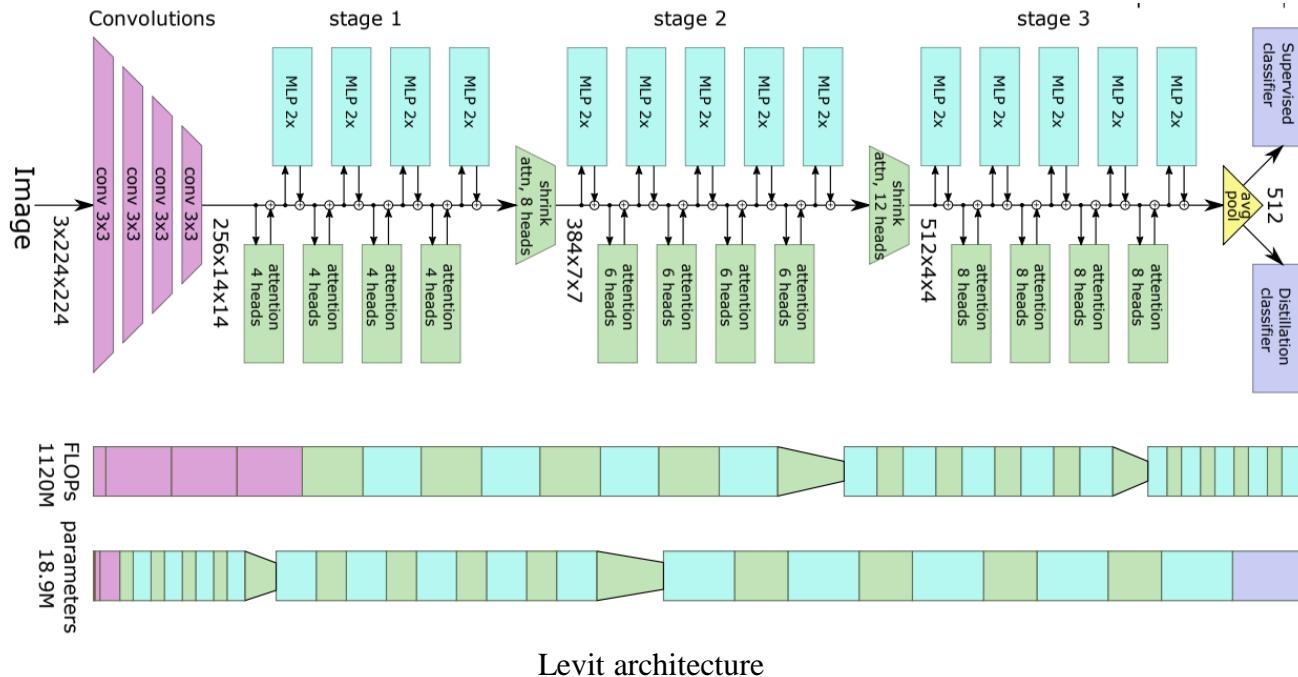
$$\text{연산 } 1\text{번} \rightarrow \frac{(hw)^2}{R^2} C$$

$$\text{연산 } 1\text{번} \rightarrow \frac{(hw)^2}{R^2} C$$



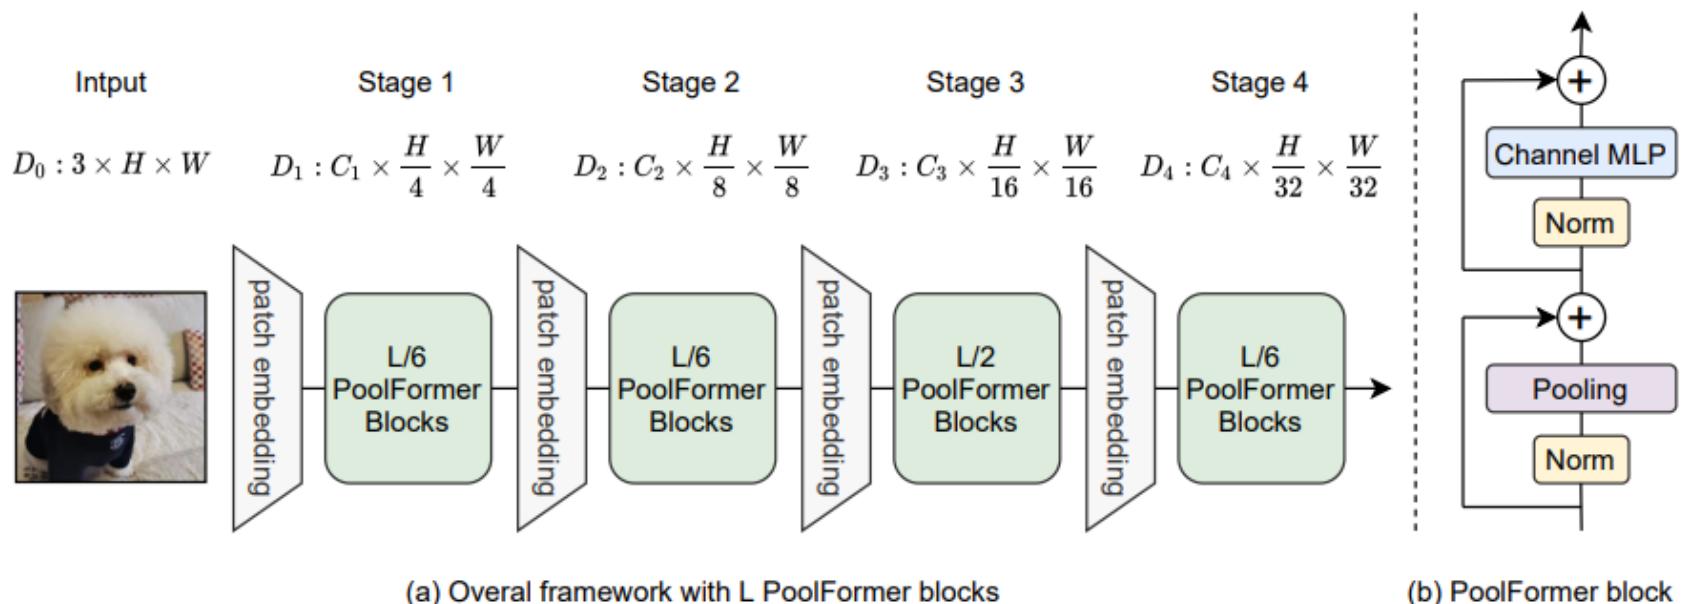
# Background

- 이 이후에도 transformer 기반의 다양한 경량화 모델이 등장
  - LeViT[1] : Convolution과 self attention을 적절히 섞어서 사용하는 모델



# Background

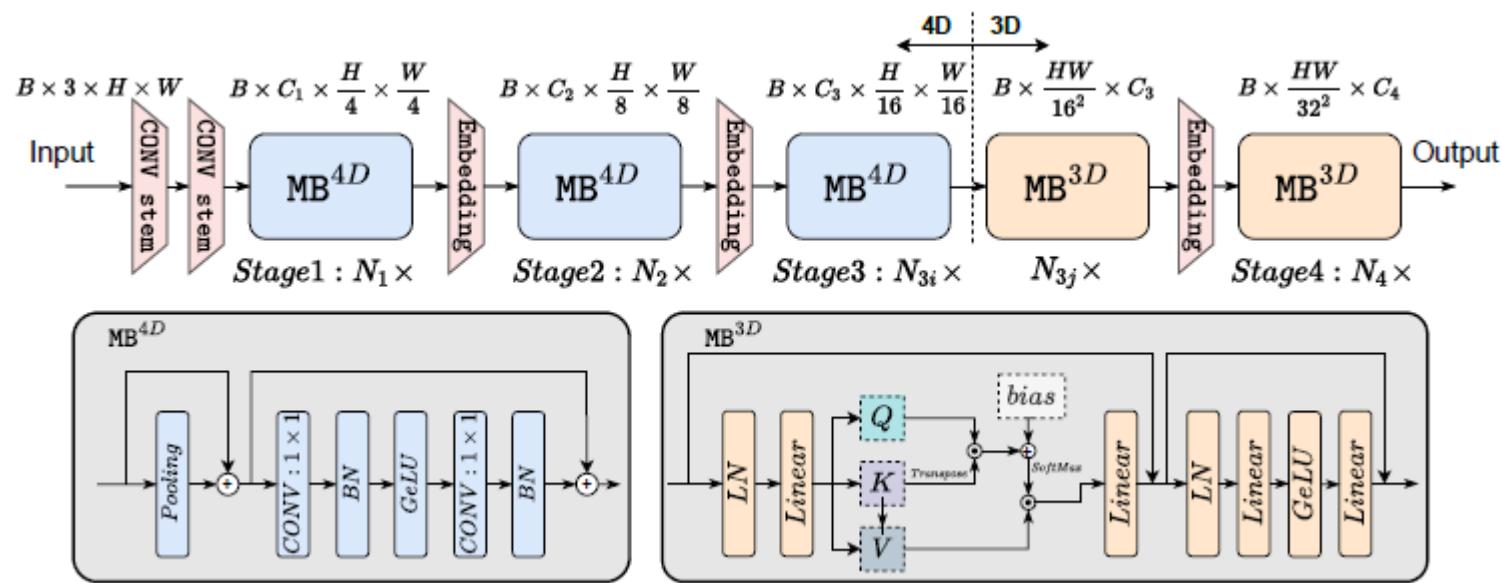
- 이 이후에도 transformer 기반의 다양한 경량화 모델이 등장
  - Poolformer[1] : self attention이 중요한 것이 아니라 transformer가 갖고 있는 기본적인 구조가 중요하다고 주장
    - Self attention의 자리에 가장 기본적인 연산 pooling을 넣어도 잘 된다는 것을 보여줌



Poolformer architecture

# Background

- 이 이후에도 transformer 기반의 다양한 경량화 모델이 등장
  - Efficientformer[1] : Poolformer를 기반으로 convolution과 self attention을 적절히 사용



Efficientformer architecture

# Efficient attention

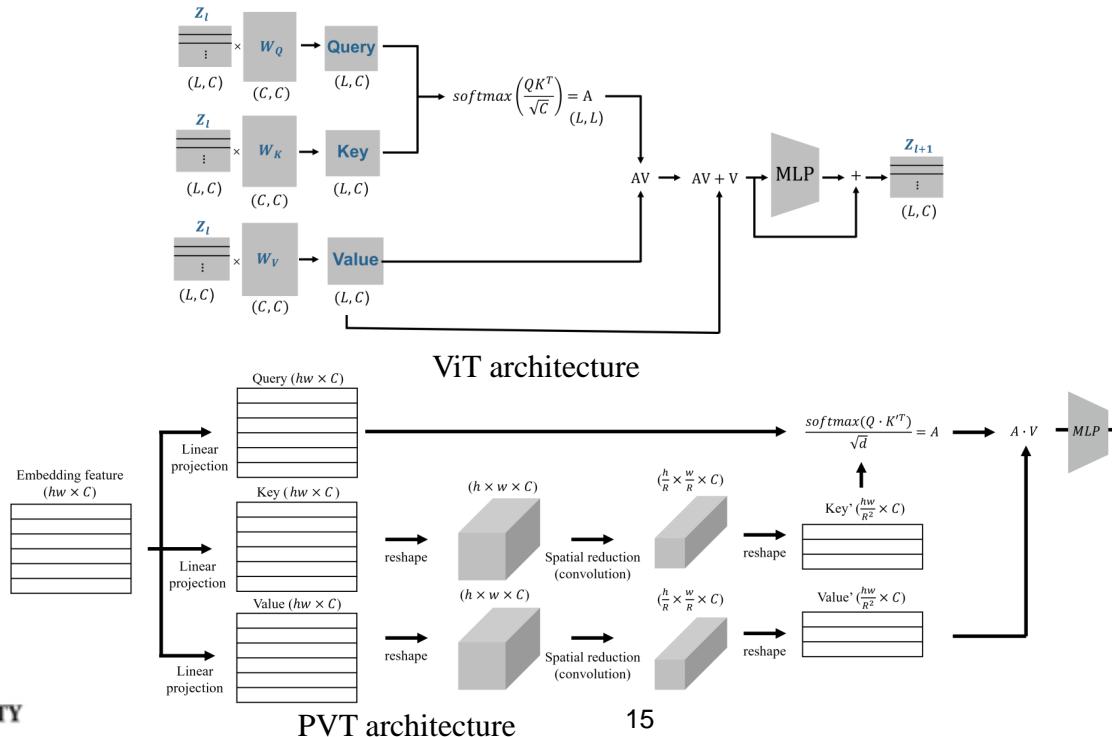
- 기존 문제

- Self attention을 수행할 때 quadratic한 computational cost가 발생

- Vision transformer(ViT) :  $2(hw)^2C \rightarrow O(hw^2C)$

- Pyramid vision transformer(PVT) :  $2 \frac{(hw)^2}{R^2} C \rightarrow O(hw^2C)$

- 즉, 해상도 (token의 개수)에 quadratic하게 computational cost가 발생



# Efficient attention

- Attention with linear complexity[1]

- self attention 연산

- $A(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{D}}\right)V$

- 행렬곱은 결합법칙 성립

- $\therefore (AB)C = A(BC)$

- 근데 이때  $\sqrt{D}$ 로 나눠주고 softmax를 취하는 과정이 없다고 가정하면

- $(Q_h K_h^T) V_h$  을  $Q_h(K_h^T V_h)$  으로 바꿔줬을 때 똑같은 연산인데 computational complexity가 바뀜

- $\therefore$  Query, key, value의 shape이 모두  $T \times D$  일 때

- $\therefore (Q_h K_h^T) V_h$  연산  $\rightarrow O(T^2 D)$

- $\checkmark (T \times D) \cdot (D \times T) \rightarrow (T \times T)$  연산량  $T^2 D$

- $\checkmark (T \times T) \cdot (T \times D) \rightarrow (T \times D)$  연산량  $T^2 D$

- $\therefore Q_h(K_h^T V_h)$  연산  $\rightarrow O(D^2 T)$

- $\checkmark (D \times T) \cdot (T \times D) \rightarrow (D \times D)$  연산량  $D^2 T$

- $\checkmark (T \times D) \cdot (D \times D) \rightarrow (T \times D)$  연산량  $D^2 T$

# Efficient attention

- Attention with linear complexity

- Multi head self attention 연산

- $A(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{D}}\right)V$

- $\therefore (Q_h K_h^T) V_h$  연산  $\rightarrow O(T^2 D)$

- $\therefore Q_h (K_h^T V_h)$  연산  $\rightarrow O(D^2 T)$

- 그럼 이제  $\sqrt{D}$ 로 나눠주기 및 softmax로 묶여있는 함수를 decompose 해야함

- 근데 위의 과정이 결국에 normalization을 수행하는 과정

- 그래서 이를  $A(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{D}}\right)V \approx \frac{QK^T}{T}V$ 로 근사

- 그런데  $\text{softmax}\left(\frac{QK^T}{\sqrt{D}}\right)V \approx (\phi(Q)\phi(K^T))V$ 로 근사시키는 방법[1]도 있음

- $\phi$ 는 learnable parameter로 구성된 linear projection 수행하는 함수

# Efficient attention

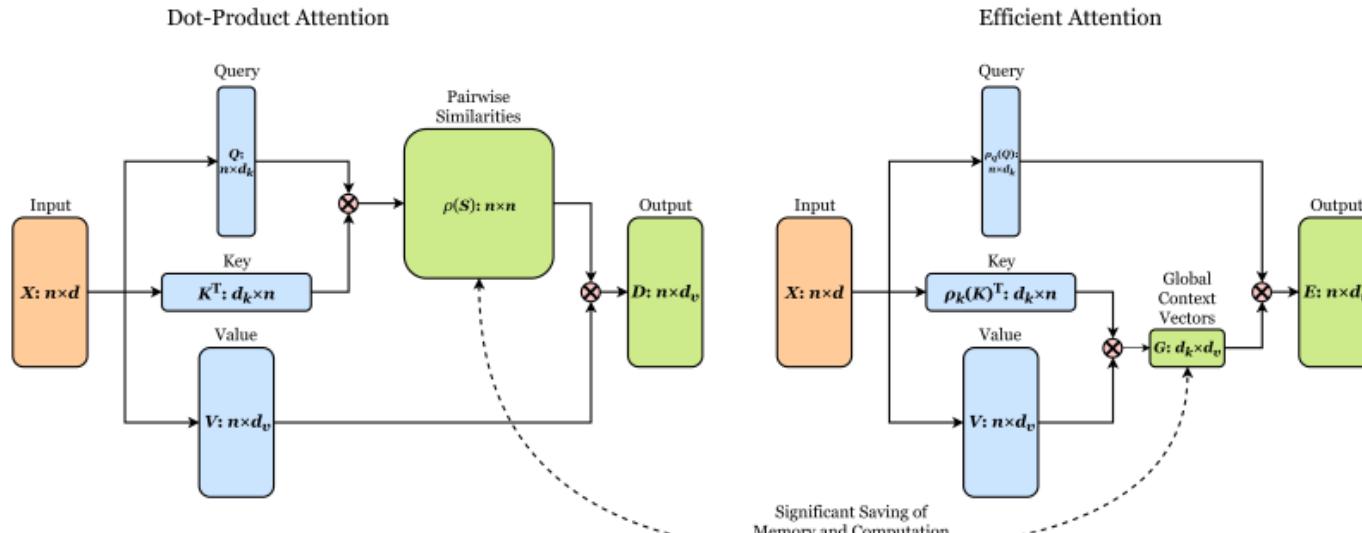
- Attention with linear complexity

- Multi head self attention 연산

$$- A(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{D}}\right)V$$

∴  $\frac{Q}{\sqrt{T}}$ ,  $\frac{K^T}{\sqrt{T}}$ ,  $V$ 로 decompose할 수 있고  $\frac{Q}{\sqrt{T}}\left(\frac{K^T}{\sqrt{T}}V\right)$ 의 연산을 수행  $\rightarrow O(D^2T)$

∴ 이를 통해 input image resolution T에 대해서 linear complexity를 가질 수 있음



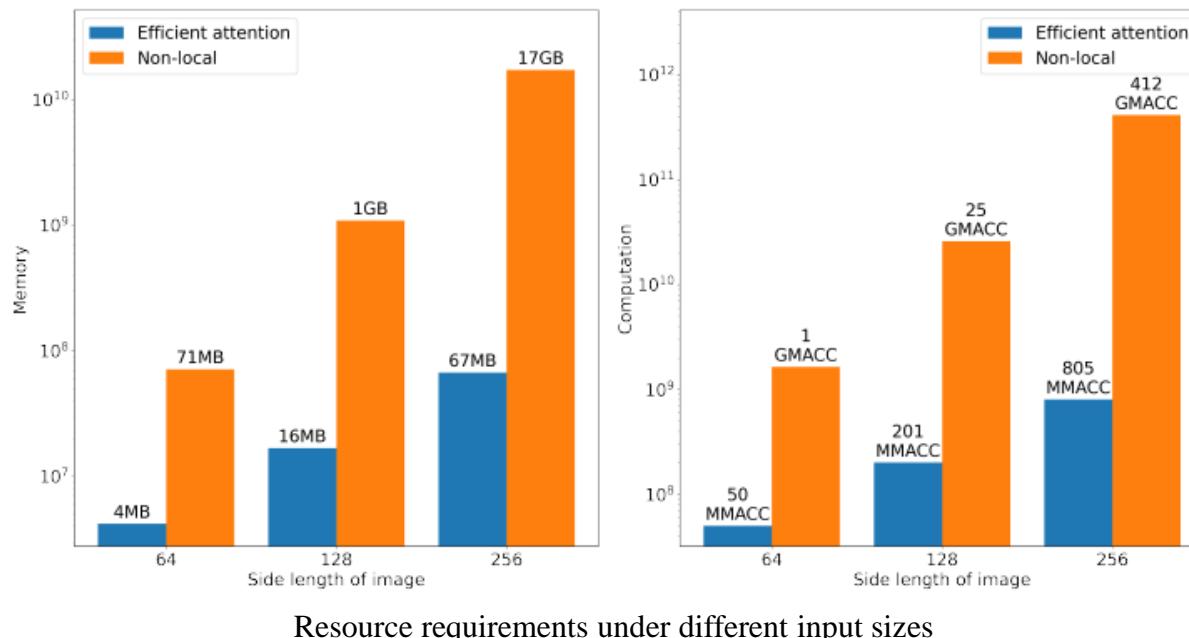
# Efficient attention

- Attention with linear complexity

- Multi head self attention 연산

- $(Q_h K_h^T) V_h$  연산  $\rightarrow O(T^2 D)$

- $Q_h (K_h^T V_h)$  연산  $\rightarrow O(D^2 T)$



# Results

Layer(s)	EA module				Non-local module				
	Box	Mask	Mem.	Comp.	Box	Mask	Mem.	Comp.	Input size
None	39.4	35.1	0	0	39.4	35.1	0	0	N/A
res3	40.2	36.0	41.3 M	1.21 G	40.3	35.9	122 M	3.74 G	56 × 80
res4	40.2	35.9	19.5 M	596 M	40.1	36.0	24.5 M	748 M	28 × 40
fpn1	39.9	35.8	220 M	5.28 G	OOM	OOM	20.8 G	662 G	224 × 320
fpn2	39.7	35.7	55.1 M	1.32 G	OOM	OOM	1.34 G	42.3 G	112 × 160
fpn3	39.7	35.5	13.8 M	330 M	39.8	35.5	94.0 M	2.86 G	56 × 80
fpn4	39.7	35.4	3.46 M	82.6 M	39.5	35.3	8.46 M	234 M	28 × 40
fpn5	39.6	35.3	877 K	20.6 M	39.4	35.2	1.17 M	28.4 M	14 × 20
res3-4+fpn3-5	40.6	36.2	78.9 M	2.24 G	<b>40.7</b>	<b>36.3</b>	250 M	7.62 G	N/A
res3-4+fpn1-5	<b>41.2</b>	<b>36.7</b>	354 M	8.85 G	OOM	OOM	22.4 G	712 G	N/A

Comparison between the efficient attention and non-local modules on MS-COCO  
2017 object detection and instance segmentation.

# Hydra Attention[1]

- Multi-head attention

$$\cdot A(Q_h, K_h, V_h) = \text{softmax}\left(\frac{Q_h K_h^T}{\sqrt{D}}\right) V_h \quad \forall h \in \{1, \dots, H\}$$

-  $Q_h, K_h, V_h \in \mathbb{R}^{T \times \frac{D}{H}}$  일 때

-  $Q_h K_h^T$  연산 시  $(T \times \frac{D}{H}) \cdot (\frac{D}{H} \times T)$  연산 H번  $\rightarrow HT^2 \frac{D}{H} \rightarrow T^2 D$

- 즉, multi head를 적용하기 전과 후가 똑같음

- 하지만 linear attention을 사용한다면 상황이 달라짐

$$\cdot A(Q_h, K_h, V_h) = \left( \phi(Q_h) \phi(K_h^T) \right) V_h = \phi(Q_h) (\phi(K_h^T) V_h) \quad \forall h \in \{1, \dots, H\}$$

-  $\phi(K_h^T) V_h$  연산 시  $(\frac{D}{H} \times T) \cdot (T \times \frac{D}{H})$  연산 H번  $\rightarrow HT(\frac{D}{H})^2 = TD^2/H$

- Head 개수가 연산량에 영향을 미침

∴ Head 개수가 증가할수록 complexity가 감소하는 형태

# Hydra Attention

- Multi-head linear attention

$$\cdot A(Q_h, K_h, V_h) = \left( \phi(Q_h) \phi(K_h^T) \right) V_h = \phi(Q_h) (\phi(K_h^T) V_h) \quad \forall h \in \{1, \dots, H\}$$

-  $\phi(K_h^T) V_h$  연산 시  $(\frac{D}{H} \times T) \cdot (T \times \frac{D}{H})$  연산 H번  $\rightarrow HT(\frac{D}{H})^2 = TD^2/H$

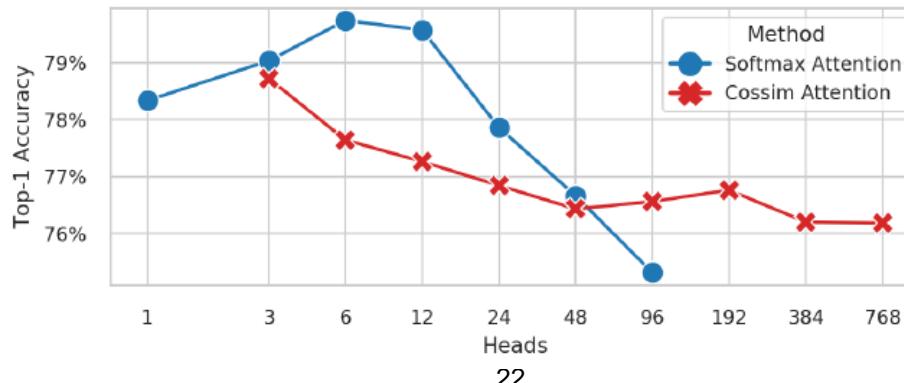
- Head 개수가 증가할수록 complexity가 감소하는 형태

- 그럼 head를 얼마나 증가시킬 수 있을지 최적의 값을 찾아봄

∴ 원래 기존 transformer에서 사용되는 head 개수는 보통 6개~16개 정도 가량임

∴ 기존 multi head attention (Softmax attention)과 multi head linear attention (Cossim attention)을 head 개수에 따라 분석

✓기존 self attention 은 head 개수가 12개 이상부터 성능이 급격히 감소하는 것에 반면 Linear attention의 경우 H=768까지 상당히 일관되게 유지되는 것을 실험적으로 분석



# Hydra Attention

- Multi-head linear attention

- 분석 실험에 의거해 head개수를 channel(token dimension)과 동일하게 만드는 방법 제안

- $$- A(Q_h, K_h, V_h) = (\phi(Q_h)\phi(K_h^T))V_h = \phi(Q_h)(\phi(K_h^T)V_h) \quad \forall h \in \{1, \dots, H\}$$

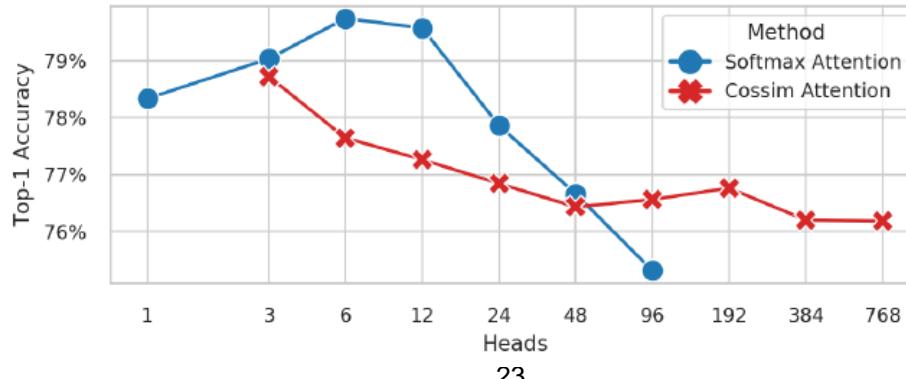
- $\cdot$  위의 수식을 바탕으로 head개수를 token dimension과 동일하게 하면 각 head에 할당된 dimension이 1이 됨

- $\therefore Q_h, K_h, V_h \in \mathbb{R}^{T \times 1}$  즉, vector가 됨

- $$- Hydra(Q_h, K_h, V_h) = \phi(Q_h) \odot \sum_{t=1}^T \phi(K_h^t) \odot V_h^t$$

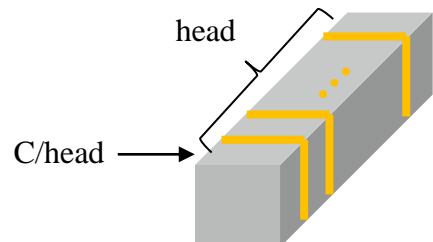
- $\odot$  : element wise multiplication

- $\therefore$  Key 및 value vector에 대한 내적을 수행한 scalar값이 query에 곱해지는 형태



# Hydra Attention

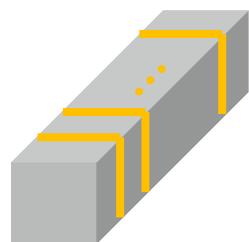
- Multi-head linear attention



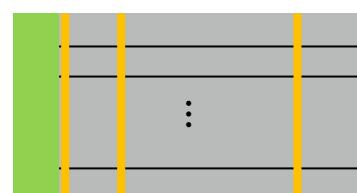
Key( $H \times W \times C$ )



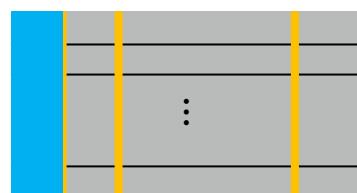
Key ( $HW \times C$ )



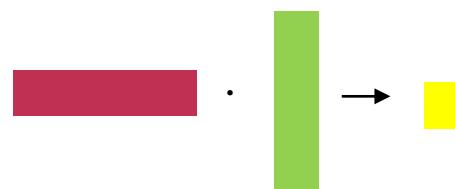
Value ( $H \times W \times C$ )



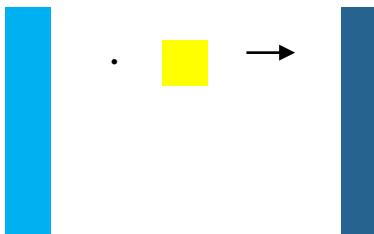
Value ( $HW \times C$ )



Query ( $HW \times C$ )



24



# Hydra Attention

- Multi-head linear attention

• 분석 실험에 의거해 head개수를 channel(token dimension)과 동일하게 만드는 방법 제안

$$- A(Q_h, K_h, V_h) = (\phi(Q_h)\phi(K_h^T))V_h = \phi(Q_h)(\phi(K_h^T)V_h) \quad \forall h \in \{1, \dots, H\}$$

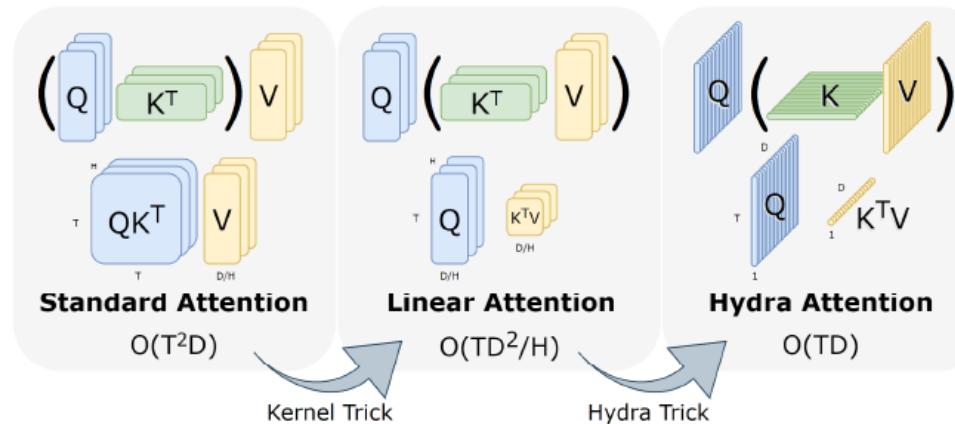
- 위의 수식을 바탕으로 head개수를 token dimension과 동일하게 하면 각 head에 할당된 dimension이 1이 됨

∴  $Q_h, K_h, V_h \in \mathbb{R}^{T \times 1}$  즉, vector가 됨

$$- Hydra(Q_h, K_h, V_h) = \phi(Q_h) \odot \sum_{t=1}^T \phi(K_h^t) \odot V_h^t$$

∴  $\odot$  : element wise multiplication

∴ Key 및 value vector에 대한 내적을 수행한 scalar값이 query에 곱해지는 형태



# Hydra Attention

- Multi-head linear attention

- 분석 실험에 의거해 head개수를 channel(token dimension)과 동일하게 만드는 방법 제안

- $\text{Hydra}(Q_h, K_h, V_h) = \phi(Q_h) \odot \sum_{t=1}^T \phi(K_h^t) \odot V_h^t$

- ;;  $Q_h, K_h, V_h \in \mathbb{R}^{T \times 1}$

- ;;  $\odot$  : element wise multiplication

- ;; Key 및 value vector에 대한 내적을 수행한 scalar값이 query에 곱해지는 형태

- Hydra attention의 연산량

- ;;  $\sum_{t=1}^T \phi(K_h^t) \odot V_h^t$  연산시  $(1 \times T) \cdot (T \times 1)$  연산이 H번  $\rightarrow TH$

- ;;  $\phi(Q_h) \odot A$  연산시  $(T \times 1) \cdot (1 \times 1)$  연산이 H번  $\rightarrow TH$

- $\sqrt{\sum_{t=1}^T \phi(K_h^t) \odot V_h^t} = A$

- ;; 따라서 총 연산량  $2TH$

- ;; 그런데  $H = D$ 이므로  $2TD \rightarrow O(TD)$

# Hydra Attention

- Complexity 비교

- 기존 self attention complexity  $O(T^2D)$

$$A(Q, K, V) = \text{softmax} \left( \frac{QK^T}{\sqrt{D}} \right) V$$

- Linear attention complexity  $O(TD^2)$

$$A(Q, K, V; \phi) = \phi(Q) (\phi(K)^T V)$$

- 제안하는 Hydra attention complexity  $O(TD)$

$$\text{Hydra}(Q, K, V; \phi) = \phi(Q) \odot \sum_{t=1}^T \phi(K)^t \odot V^t$$

# Hydra Attention

- Results

Method	Accuracy (%)	FLOPs (G)	Speed (im/s)
Standard Attention [32]	79.57	17.58	314.8
AFT-Simple [37]	74.02 (-5.55)	16.87 (-4.0%)	346.1 (+9.9%)
PolyNL [2]	73.96 (-5.61)	16.87 (-4.0%)	353.8 (+12.4%)
Hydra (2 layers)	80.64 (+1.1)	17.46 (-0.7%)	321.9 (+2.3%)
Hydra (8 layers)	79.45 (-0.12)	17.11 (-2.7%)	334.8 (+6.3%)
Hydra (12 layers)	76.40 (-3.17)	16.87 (-4.0%)	346.8 (+10.2%)

Results for different attention methods in a DeiT-B

Method	Accuracy (%)	FLOPs (G)	Speed (im/s)
Standard Attention [32]	81.33	55.54	92.5
Hydra (2 layers)	81.92 (+0.59)	54.52 (-1.8%)	96.3 (+4.1%)
Hydra (7 layers)	81.26 (-0.07)	51.96 (-6.4%)	106.8 (+15.4%)
Hydra (12 layers)	77.85 (-3.48)	49.40 (-11.0%)	117.6 (+27.1%)

384px Fine-Tuning

# Conclusion

- Self attention의 complexity 관점의 경량화 기법 조사
- 현재 self attention 및 cross attention이 다양한 task에 적용되어 연구되고 있으므로 경량화 관점을 도입한다면 응용할 수 있음