

高速な Swin Transformer についての考察

加古 遼太郎 松井 勇佑

東京大学

1 序論

Transformer モデル [1] は、自然言語処理、画像処理などの分野でその有効性を認められ、注目を集めている。Transformer モデルは Self-attention (図 1) をネットワーク内に組み込むことで、様々なタスクの精度向上を可能とした。しかし、Self-attention の計算量は、入力系列長 n に対し空間計算量と時間計算量ともに $O(n^2)$ であることが知られている [2]。この計算の効率化および高速化が求められており、そのために様々な手法が提案されている。

Swin Transformer [3] は、画像を対称とした Transformer の 1 つである。Swin-Transformer は、画像を分割してそれぞれで Self-attention を計算することにより、計算の高速化を図っている。一方で、画像の分割の方法を固定せず可変にすることにより、画像分類などのタスクの精度も高く維持している。しかし、画像の解像度を大きくする場合は、分割する回数も大きくしないと時間計算量は結局 n の二乗に比例して増加する。さらに、分割を増加させたことによる精度への影響は明らかでない。

そこで本論文では、Swin Transformer の利点を活かしつつさらに高速化する手法について議論、提案する。

2 関連研究

2.1 Self-attention

Self-attention は、Transformer を特徴づける重要な要素技術である [1]。Self-attention $\mathbf{A} \in \mathbb{R}^{n \times c}$

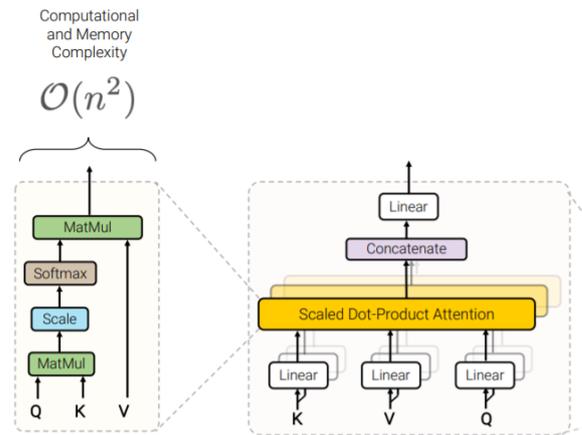


図 1: Self-attention のブロック図 [2]

は、以下のように定義される。

$$\mathbf{A} = \mathbf{softmax}(\mathbf{QK}^T)\mathbf{V} \quad (1)$$

ここで、 $\mathbf{Q}, \mathbf{K}, \mathbf{V} \in \mathbb{R}^{n \times c}$ は、学習される行列、 $n \in \mathbb{N}$ は入力系列長、 $c \in \mathbb{N}$ は一つの入力系列の特徴量の次元数である。また、 $\mathbf{softmax}$ 関数は、ベクトルに対する $\mathbf{softmax}$ 関数を行列のそれぞれの行に適用する関数である。入力系列は、ここでは画像を正方形のグリッドに分割したものである。この式に加え、正規化項などを導入することもある。この定義式より、式 (1) の時間計算量は $O(n^2c)$ であることがわかる。

2.2 Swin Transformer

Swin Transformer [3] は、Transformer の計算量を改善したネットワークである。図 2 に示すように、画像をいくつかの単位 (Window) に分割し、それぞれに対して Self-attention を計算する。Window の数を w とすると、1 つの Window に含

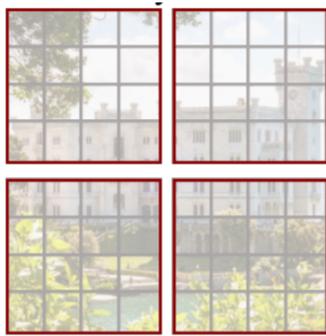


図 2: Swin Transformer は画像をいくつかの単位(Window)に分割する [3]

まれる系列の数を s とし

$$n = ws \tag{2}$$

が成立する. またこのときの Self-attention の計算の時間計算量は $\mathcal{O}(s^2c)$ であり, これを w 個の Window に対して計算するので合計で $\mathcal{O}(w(s^2c))$ となる. $w \gg s$ のとき, 時間計算量は w について一次間数的に増加すると近似することができる.

3 提案手法

提案手法では, \mathbf{Q}, \mathbf{K} の次元を圧縮し, 精度を保ちつつ計算量を下げる. つまり, Self-attention を次のように定義し直す.

$$\hat{\mathbf{A}} = \text{softmax}((\mathbf{QR})(\mathbf{KS})^\top)\mathbf{V} \tag{3}$$

ここで, $\mathbf{Q}, \mathbf{K}, \mathbf{V} \in \mathbb{R}^{n \times c}$ および $\mathbf{R}, \mathbf{S} \in \mathbb{R}^{c \times d}$ は, 学習される行列, $n \in \mathbb{N}$ は入力系列長, $c \in \mathbb{N}$ は一つの入力系列の特徴量の次元数, d はハイパーパラメータで $d < c$ である. このとき, \mathbf{QR} および \mathbf{KS} の計算量は $\mathcal{O}(scd)$, $((\mathbf{QR})(\mathbf{KS})^\top)$ の計算量は $\mathcal{O}(s^2d)$ である. したがって, softmax 関数の引数の部分に着目すると, Swin Transformer の計算量は $\mathcal{O}(w(s^2c))$, 提案手法の計算量は $\mathcal{O}(w(scd + s^2d))$ である. 提案手法では, 計算の一部について s について線形時間となる.

4 今後の課題

オリジナルの Swin Transformer モデルと提案手法のモデルで Self-attention の計算時間を計測した

ものを表 1 に示す. この表に示すとおり, 時間計算量の議論上では高速化するが, 実際には高速になっていないことがわかる. 今後の課題として, この点を考察する必要がある.

表 1: それぞれのネットワークにおける Self-attention を 1 回計算するのにかかる時間. いずれのネットワークも $c = 32, s = 49$

ネットワーク	時間
オリジナル [1]	50.541ms
提案手法 ($d = 32$)	70.194ms
提案手法 ($d = 16$)	66.304ms
提案手法 ($d = 8$)	60.311ms

原因としては, s が小さいことが考えられる. 今回の実験では $s = 49$ であったため, 計算量における定数倍が無視できず, このような結果になったと考えられる. 今後, s を増加させた場合についても検証が必要である. 対称とする画像の解像度を高くする場合, 一定の精度を得るには s を増加させる必要があるため, s を増加させた場合について考察することは非常に重要である.

参考文献

[1] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Łukasz Kaiser, and Illia Polosukhin. Attention is all you need. In *Advances in neural information processing systems*, pp. 5998–6008, 2017.

[2] Yi Tay, Mostafa Dehghani, Dara Bahri, and Donald Metzler. Efficient transformers: A survey. September 2020.

[3] Ze Liu, Yutong Lin, Yue Cao, Han Hu, Yixuan Wei, Zheng Zhang, Stephen Lin, and Baining Guo. Swin transformer: Hierarchical vision transformer using shifted windows. March 2021.