Mamba

2024, 4, 10

Why not Transformer

- Attention是$O(n^2)$复杂度
- 无法见到窗口外的内容（拓展窗口会二次方扩大计算量）

- 传统RNN是O(n)且理论上可以见到前面所有内容（其实会遗忘）

Mamba结构

- 类似RNN结构，h(t)依赖于h(t-1)
- 利用selection实现过去的存储x(t)
- 单独的输出函数y(t)=Ch(t)

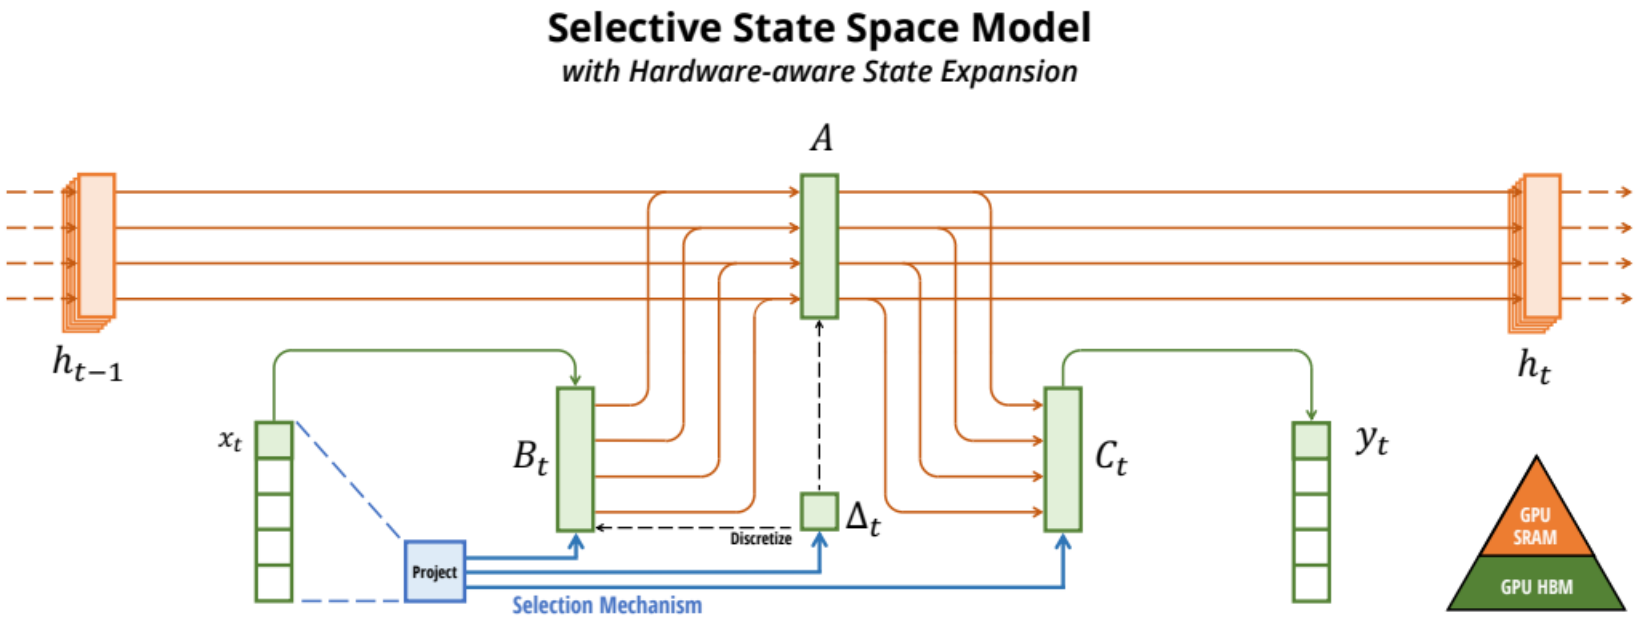

$$h'(t) = Ah(t) + Bx(t) \quad (1a)$$
$$y(t) = Ch(t) \quad (1b)$$

$$h_t = \overline{A}h_{t-1} + \overline{B}x_t \quad (2a)$$
$$y_t = Ch_t \quad (2b)$$

$$\overline{K} = (C\overline{B}, C\overline{AB}, \dots, C\overline{A}^k\overline{B}, \dots) \quad (3a)$$
$$y = x * \overline{K} \quad (3b)$$

SSM是什么

- State Space Models（状态机）
- 依赖输入序列x(t)
- 状态函数：h(t)=Ah(t)+Bx(t)
- 输出函数：y(t)=Ch(t) [加上可能的short connection]

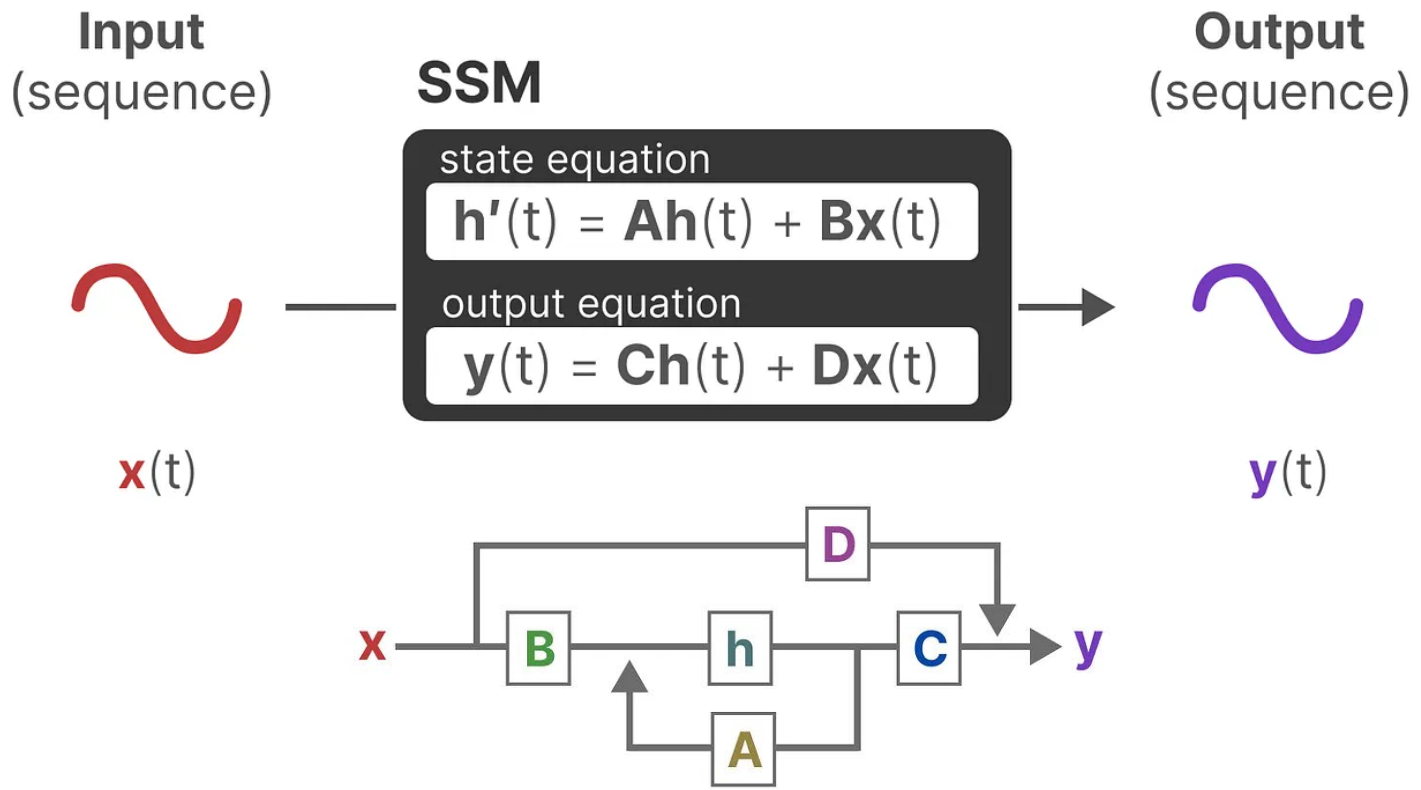

第二个要点：selection

- RNN结构是滑动窗口，没有attention作用（平均权重）
- 使用selection方法，挑选“有价值”历史输入作为x(t)

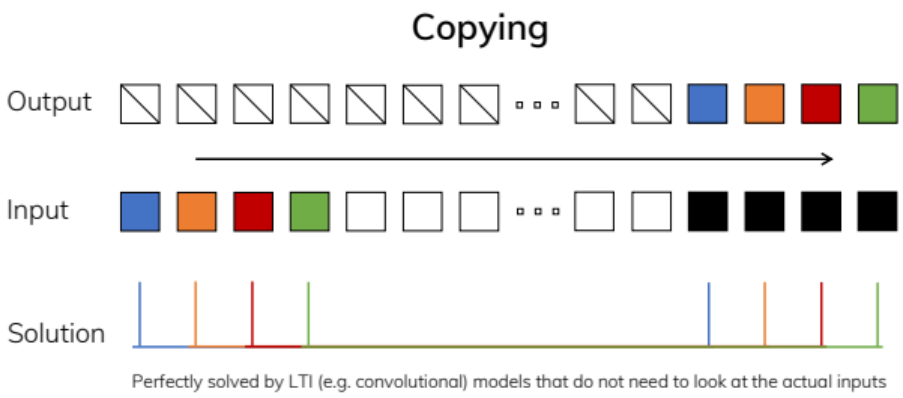

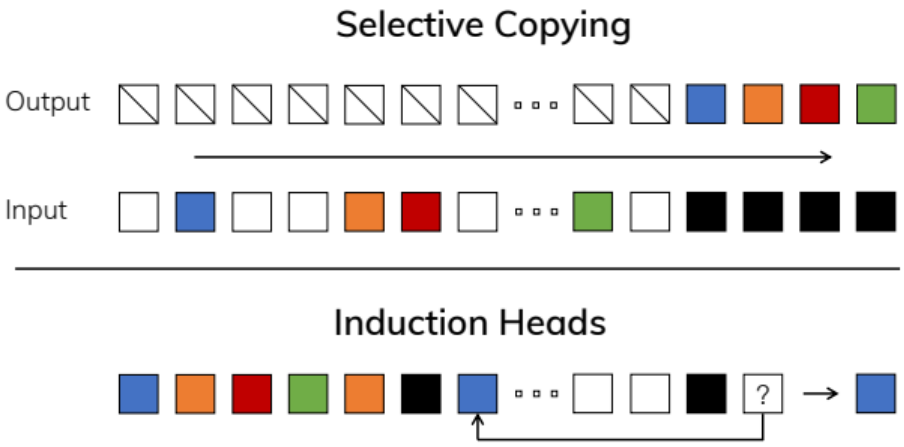

第三个要点：硬件友好并行

- 类似RNN结构（依赖t-1）不能直接并行
- 并行扫描技术（某种cache和广播操作）

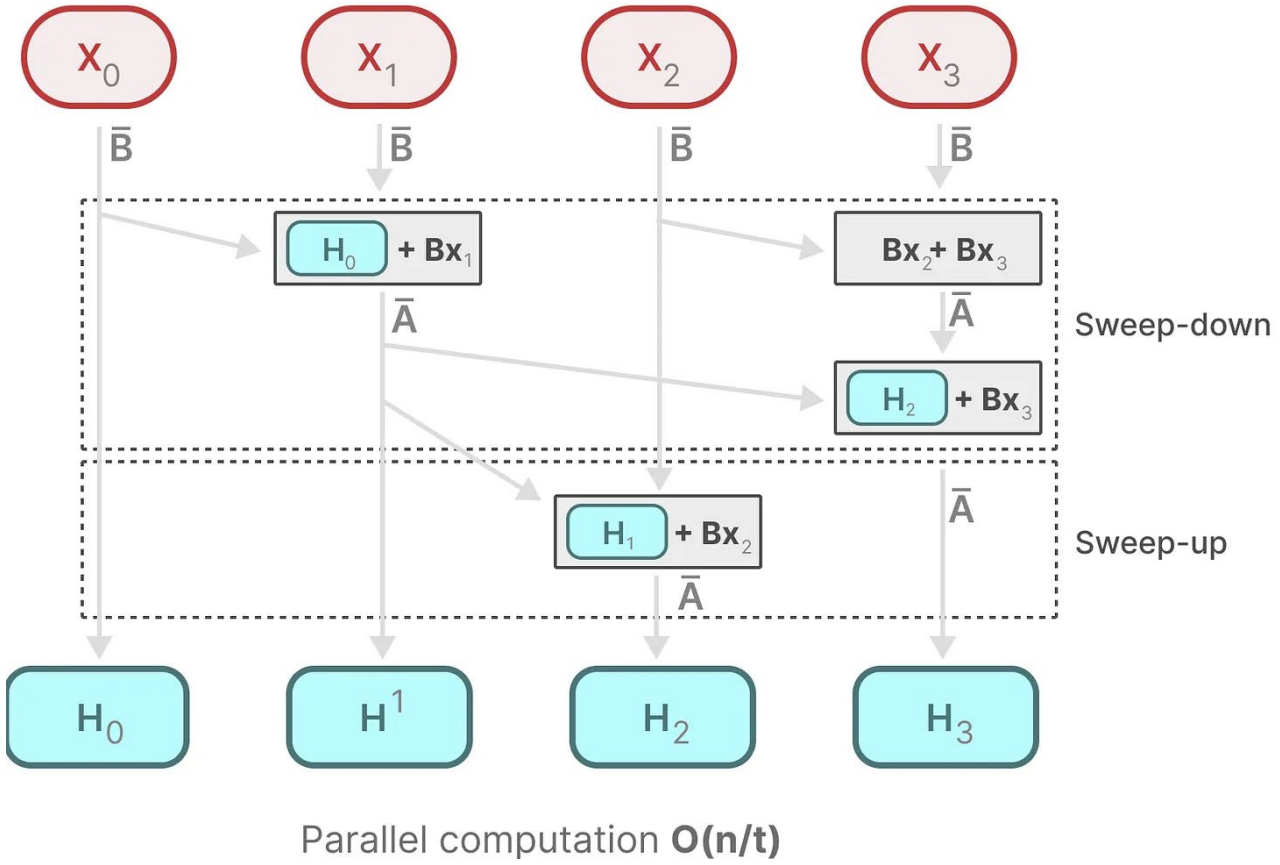

实验结果

- 同FLOPS性能最优
- 参考： https://blog.csdn.net/v_JULY_v/article/details/134923301

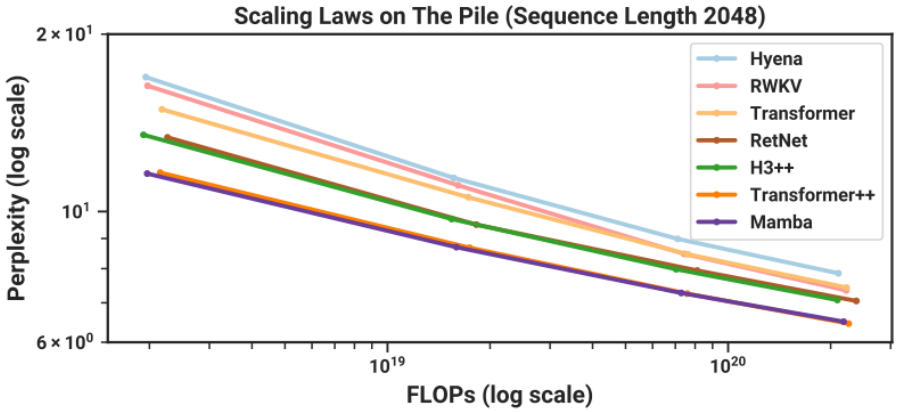

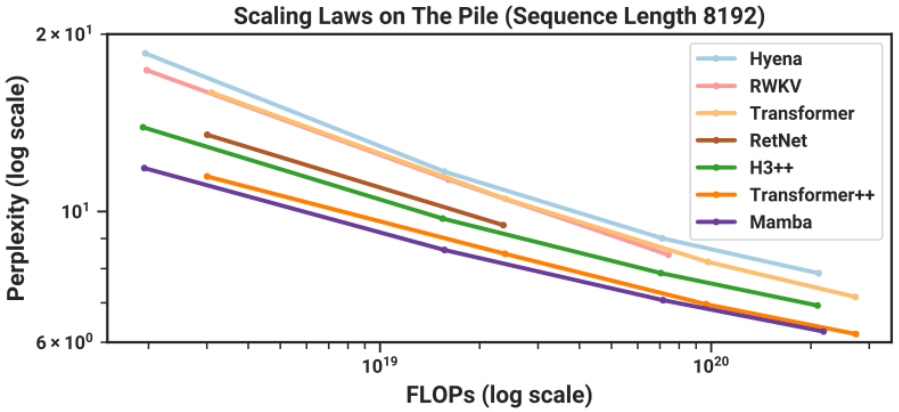

Vision Mamba (ViM)

- 一比一复刻ViT
- 乏善可陈

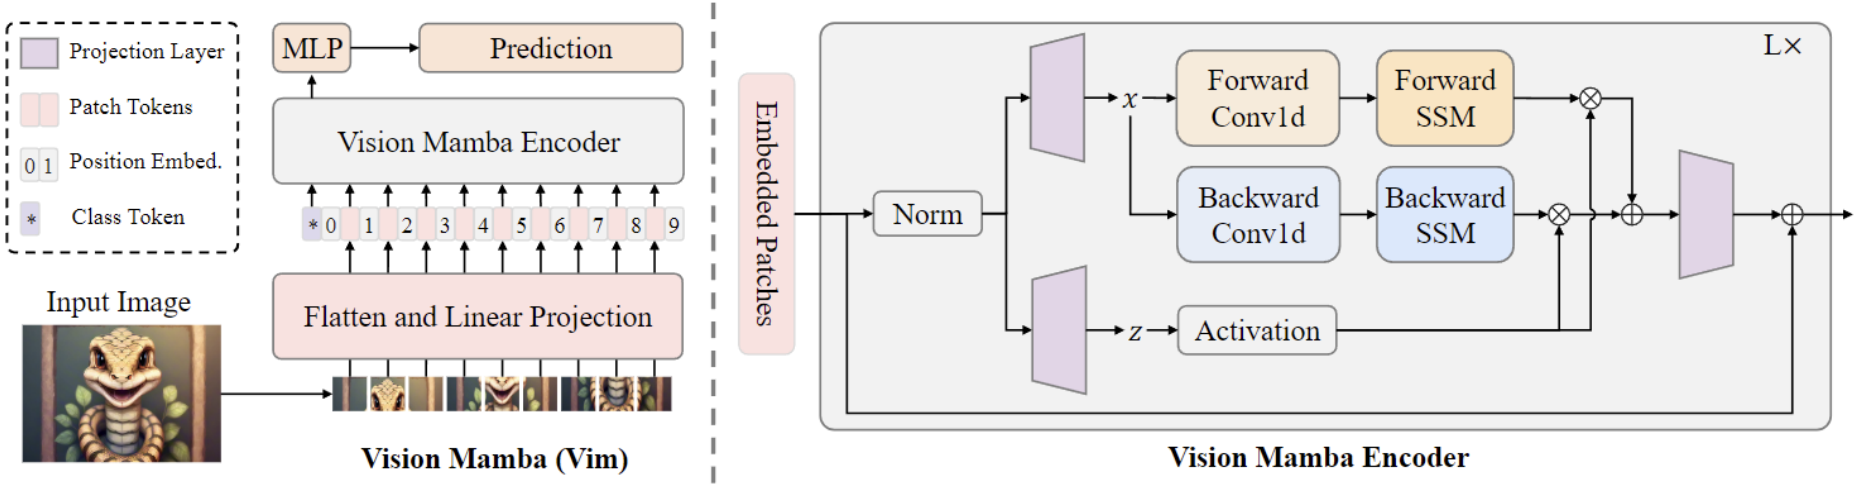

VMamba

- 类似于swin思路
- 从两边到中间，扫四次，降低运算量

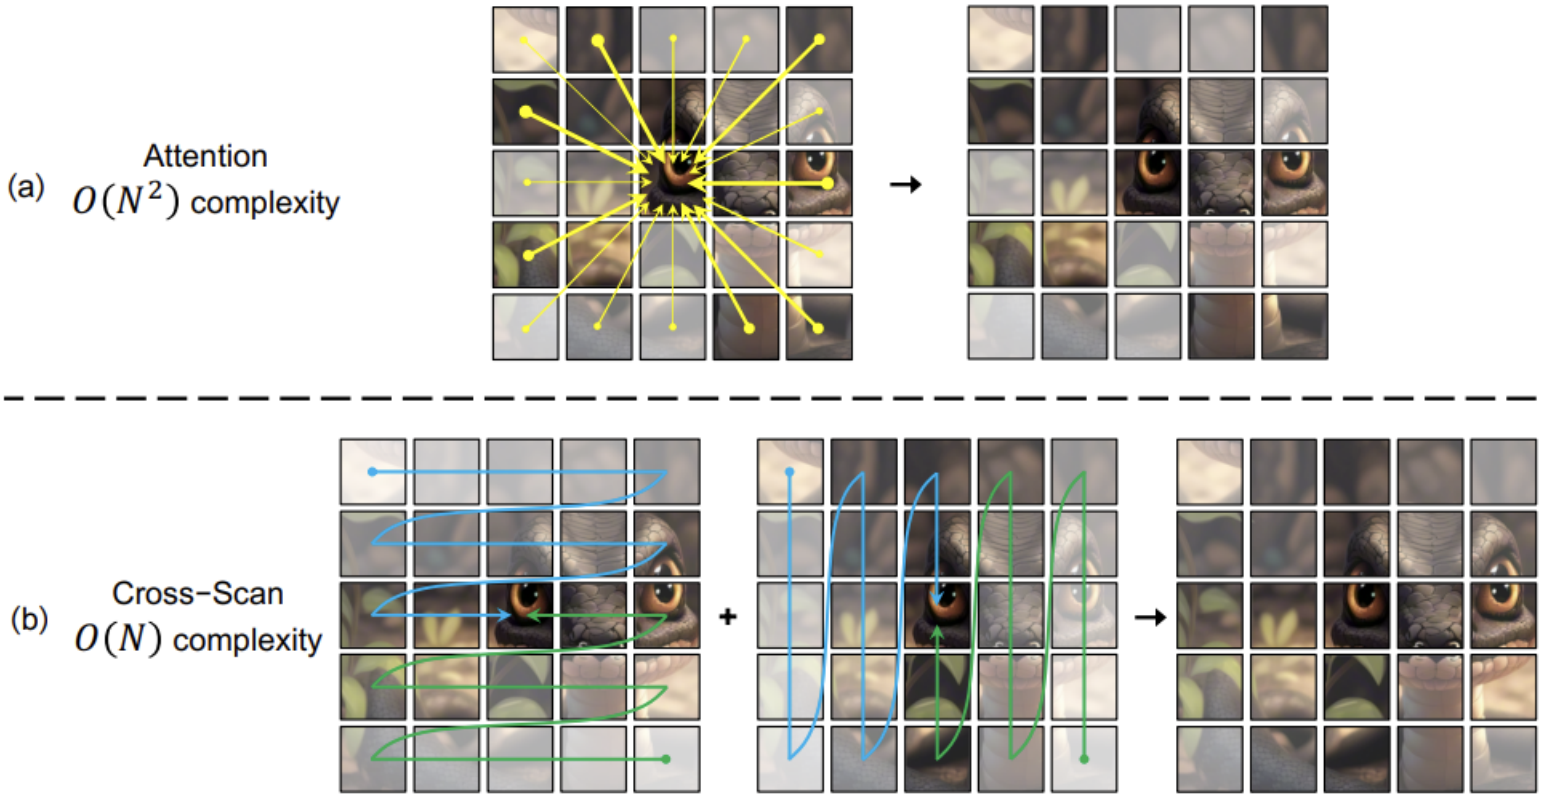

VMamba

- 有CNN的localization性
- 又带一点全局性