

# Transformer

- 1. 数据并行
- 2. 模型并行
- 3. scaling
- 4. “数据并行”和“模型并行” GPU 利用率 GPU 数量
- 5. nlp token 并行
- 6. token 并行
  - 1. kq token v
  - 2. kqv sequence
  - 3. 并行
  - 4. weight



- 1. 数据并行
- 2. 模型并行 AGI AGI
- 3. Transformer

# Attention

- 1. token key value
  - 1. 并行
  - 1. 并行
  - 2. KV cache
- 2. 并行
- 3. 并行
- 4. attention
  - 1. Transformer  $O(T^2)$   $O(T)$   $O(1)$
  - 2. RWKV status,  $O(T)$   $O(1)$
  - 2. token
  - 3. MOE CoT

6.

2.

2. 