推理引擎-Kernel优化

汇编与循环优化

ZOMI

Talk Overview

1. **推理系统介绍**：推理系统架构 – 推理引擎架构
2. **模型小型化**：CNN小型化结构 – Transform小型化结构
3. **离线优化压缩**：低比特量化 – 模型剪枝 – 知识蒸馏
4. **模型转换与优化**：模型转换细节 - 计算图优化
5. **Kernel 优化**
   - 算法优化 (Winograd / Strassen)
   - 内存布局 (NC1HWC0 / NCHW4)
   - 汇编优化 (指令与汇编)
   - 调度优化
6. **Runtime 优化**

推理引擎架构

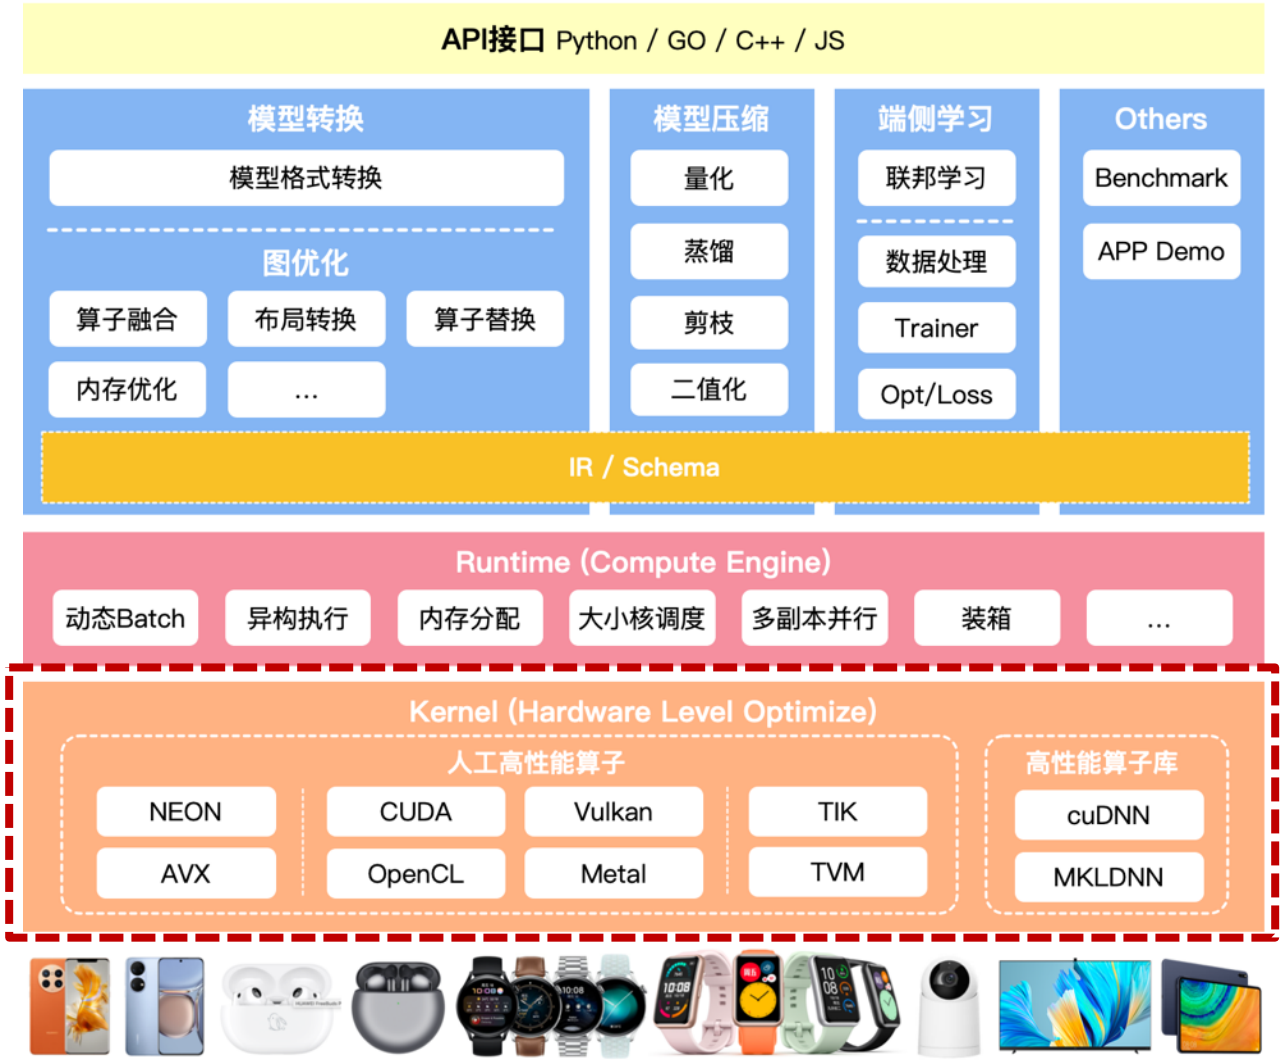

高性能算子层

- 算子优化
- 算子执行
- 算子调度

汇编优化

汇编优化

- 为了降低读写冗余，很多推理引擎在 CPU 中会利用汇编代码来实现算子对应的 Kernel。而汇编代码中最重要的是实现循环展开，并手排指令减少相依数据依赖，提升 Kernel 的执行性能。

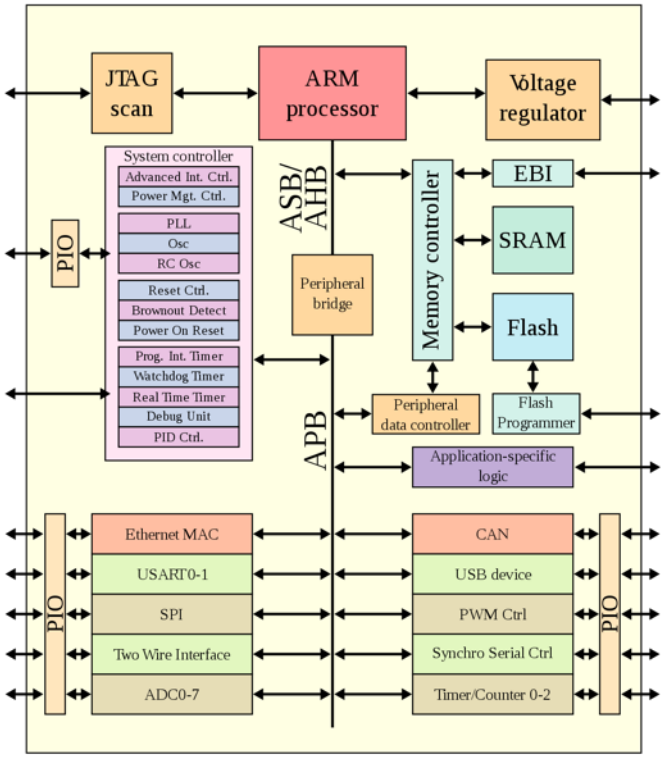

人工手排指令，减少相邻数据依赖，减少总延迟

```
        MAIN_TRANSPOSE_E12
        st1 {v20.8h, v21.8h, v22.8h, v23.8h}, [x0], #64
        st1 {v24.8h, v25.8h, v26.8h, v27.8h}, [x0], #64
        st1 {v28.8h, v29.8h, v30.8h, v31.8h}, [x0], #64

        add x1, x2, x4
        sub x5, x5, #8
        cmp x5, #8
        bge Body_LoopL8

    cbz x5, Body_LoopLEnd
    Body_LoopLExtra:
        MAIN_TRANSPOSE_E12
        cmp x5, #7 // if x5 < 7
        blt Body_LoopLEx6 // jump to Body_LoopLEx6
```

汇编优化

- 为了降低读写冗余，很多推理引擎在 CPU 中会利用汇编代码来实现算子对应的 Kernel。而汇编代码中最重要的是实现循环展开，并手排指令减少相依数据依赖，提升 Kernel 的执行性能。

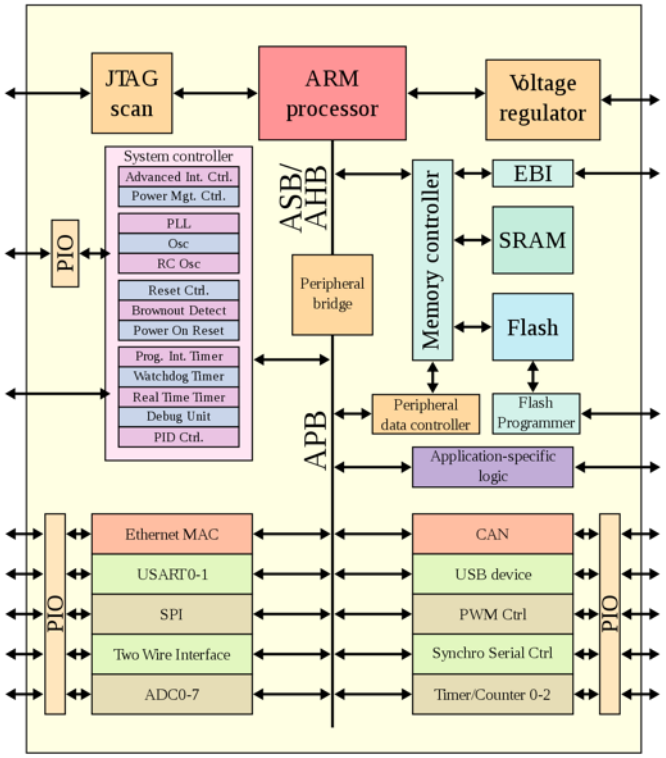

循环优化，按寄存器数量，尽可能一次时钟周期内计算更多的数据

```
.macro MAIN_TRANSPOSE_E12
// src:[v0-v11]
    ld1 {v0.8h}, [x1], x6
    ld1 {v1.8h}, [x1], x6
    ld1 {v2.8h}, [x1], x6
    ld1 {v3.8h}, [x1], x6
    ld1 {v4.8h}, [x1], x6
    ld1 {v5.8h}, [x1], x6
    ld1 {v6.8h}, [x1], x6
    ld1 {v7.8h}, [x1], x6
    ld1 {v8.8h}, [x1], x6
    ld1 {v9.8h}, [x1], x6
    ld1 {v10.8h}, [x1], x6
    ld1 {v11.8h}, [x1], x6

    TRANSPOSE_8x8 v20, v12, v23, v13
```

```
mov x9, #2   // sizeof(FLOAT16)
mul x7, x11, x7
mul x8, x9, x8
add x0, x0, x7
add x0, x0, x8
mov x2, #0
ldr w2, [x3, #0] // e

Body:
    cmp w2, #12 // eP
    blt E8
    cmp x5, #8
    blt Body_LoopLExtra
    Body_LoopL8:
        mov x2, x1
```

算子调度优化方法

- 循环展开（Loop Unrolling）
- 循环分块（loop tiling）
- 循环重排（loop Reorder）
- 循环融合（loop Fusion）
- 循环拆分（loop Split）
- 向量化（Vector）
- 张量化（Tensor）
- 访存延迟（ Latency Hiding ）
- 存储分配（Memory Allocation）

循环优化（Loop Optimization）

指令优化（Instructions Optimization）

存储优化（Memory Optimization）

循环优化
Loop Optimization

循环展开 Loop Unrolling

- 对循环进行展开，以便每次迭代多次使用加载的值，使得一个时钟周期的流水线上尽可能满负荷计算。在流水线中，会因为指令顺序安排不合理而导致NPU等待空转，影响流水线效率。循环展开为编译器进行指令调度带来了更大的空间。

循环展开 Loop Unrolling

```
1
2   for j = 1,2 * n
3       for i = 1,m
4           A(j) = A(j) + B(i)
5       endfor
6   endfor
7
8   # After Unrolling
9
10  for j = 1,2 * n by 2
11      for i = 1,m
12          A(j) = A(j) + B(i)
13          A(j+1) = A(j+1) + B(i)
14      endfor
15  endfor
16
```

循环分块 Loop tiling

- 由于内存空间有限，代码访问的数据量过大时，无法一次性将所需要的数据加载到设备内存，循环分块能有效提高NPU cache 上的访存效率，改善数据局部性。
- 如果分块应用于外部循环，会增加计算的空间和时间局部性；分块应与缓存块一起作用，可以提高流水线的效率。

循环分块 Loop tiling

- Loop Tiling 的目的是确保一个 Cache 在被用过以后，后面再用的时候其仍然在 cache 中。

- **实现思路**：当一个数组总的数据量无法放在 cache 时，把总数据分成一个个 tile 去访问，令每个 tile 都可以满足 Cache
- **具体做法**：把一层内层循环分成 outer loop * inner loop。然后把 outer loop 移到更外层去，从而确保 inner loop 一定能满足 Cache

循环分块 Loop tiling

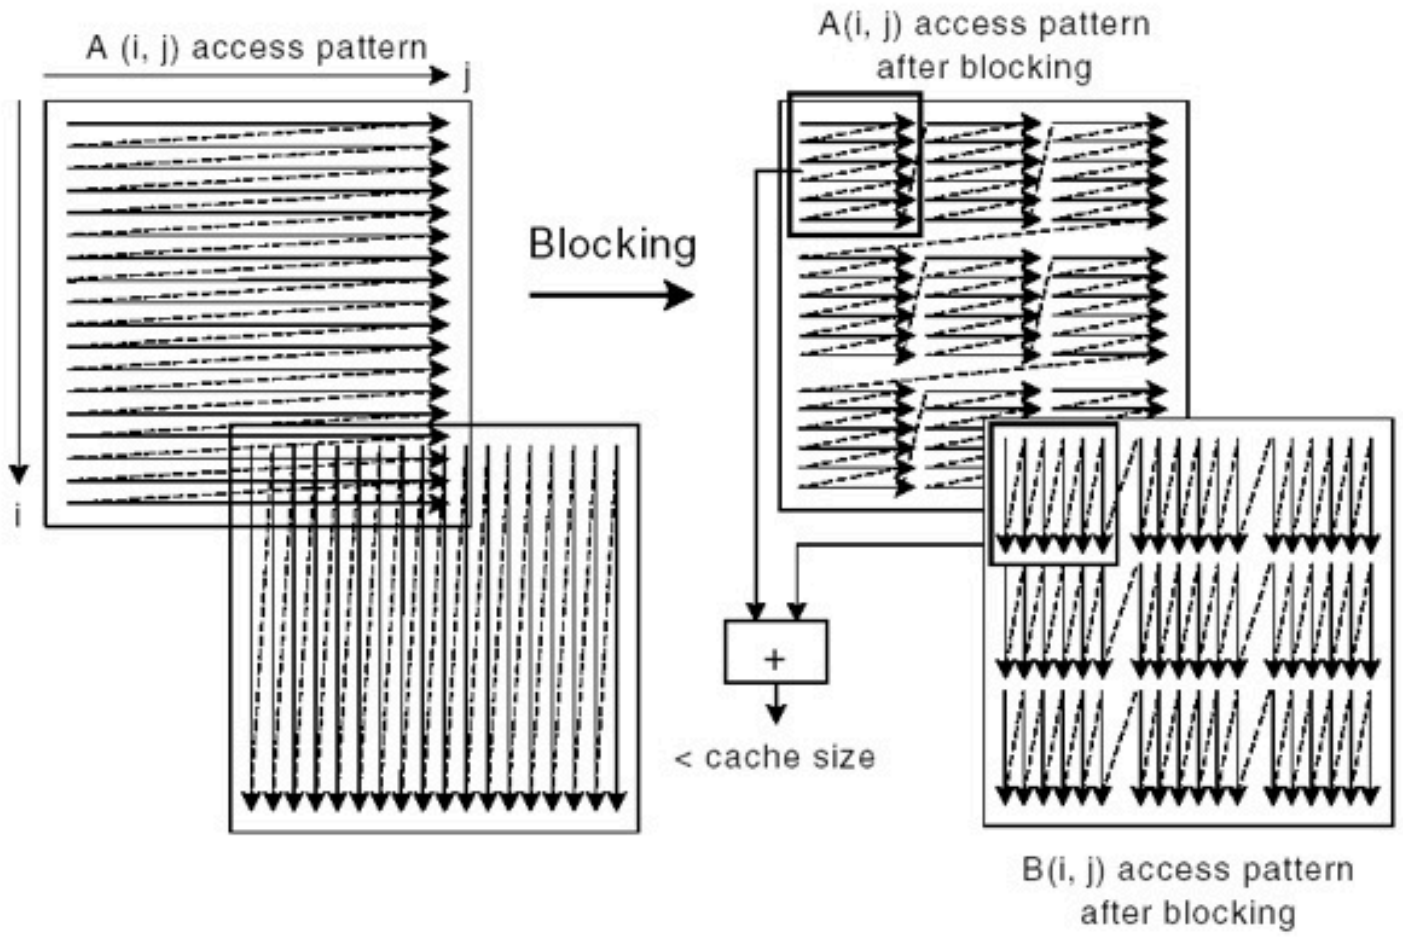

循环分块 Loop tiling

```
1
2  for j = 0, n
3      for i = 1, m
4          A(i) += B(j)
5      endfor
6  endfor
7
8  # After Tiling
9
10 for j_o = 0, m, T:
11     for i = 0, n:
12         for j_i = j_o, j_o + T:
13             A[i] += B[j_i]
14         endfor
15     endfor
16 endfor
17
```

循环重排 Loop Reorder

- 内外层循环重排，改善空间局部性，并最大限度地利用引入缓存的数据。对循环进行重新排序，以最大程度地减少跨步并将访问模式与内存中的数据存储模式对齐。

循环重排 Loop Reorder

```
1
2   for i = 1, n
3       for j = 1, m
4           A(i,j) = B(i, j) * C(i, j)
5       endfor
6   endfor
7
8   # After Reorder
9
10  for j= 1, m
11      for i = 1, n
12          A(i, j) = B(i, j) * C(i, j)
13      endfor
14  endfor
15
```

循环融合 Loop Fusion

- 循环融合将相邻或紧密间隔的循环融合在一起，减少的循环开销和增加的计算密度可改善软件流水线，数据结构的缓存局部性增加。

循环融合 Loop Fusion

```
2   for i = 0, n
3       A(i) = a(i) + b(i);
4       c(i) = 2 * a(i);
5   endfor
6   for i = 1, n - 1
7       D(i) = c(i) + a(i);
8   endfor
9
10  # After fusion
11
12  A(0) = a(0) + b(0);
13  c(0) = 2 * a(0);
14  A(n - 1) = a(n - 1) + b(n - 1);
15  c(n - 1) = 2 * a(n - 1);
16  for i = 1, n - 1
17      A(i) = a(i) + b(i)
18      c(i) = 2 * a(i)
19      D(i) = c(i) + a(i)
20  endfor
```

循环拆分 Loop Split

- 拆分主要是将循环分成多个循环，可以在有条件的循环中使用，分为无条件循环和含条件循环。

循环拆分 Loop Split

```
2    for i = 0, n
3        A(i) = a(i) + b(i)
4        c(i) = 2 * a(i)
5        if(temp[i] > data)
6            d(i) = a(i)
7    endfor
8
9    # After Split
10
11   for i = 0, n
12       A(i) = a(i) + b(i)
13       c(i) = 2 * a(i)
14   endfor
15   for i = 0, n
16       if(temp[i] > data)
17           d(i) = a(i)
18   endfor
```

调度优化

调度优化

- MNN 的预推理模块可以较好地降低调度冗余，我们把算子的执行拆分为 onResize 和 onExecute 两个部分，在预推理过程中执行 onResize ，在推理过程中执行 onExecute ，视各类 GPU 的 API 设计不同，可以不同程度地降低调度冗余。

调度优化

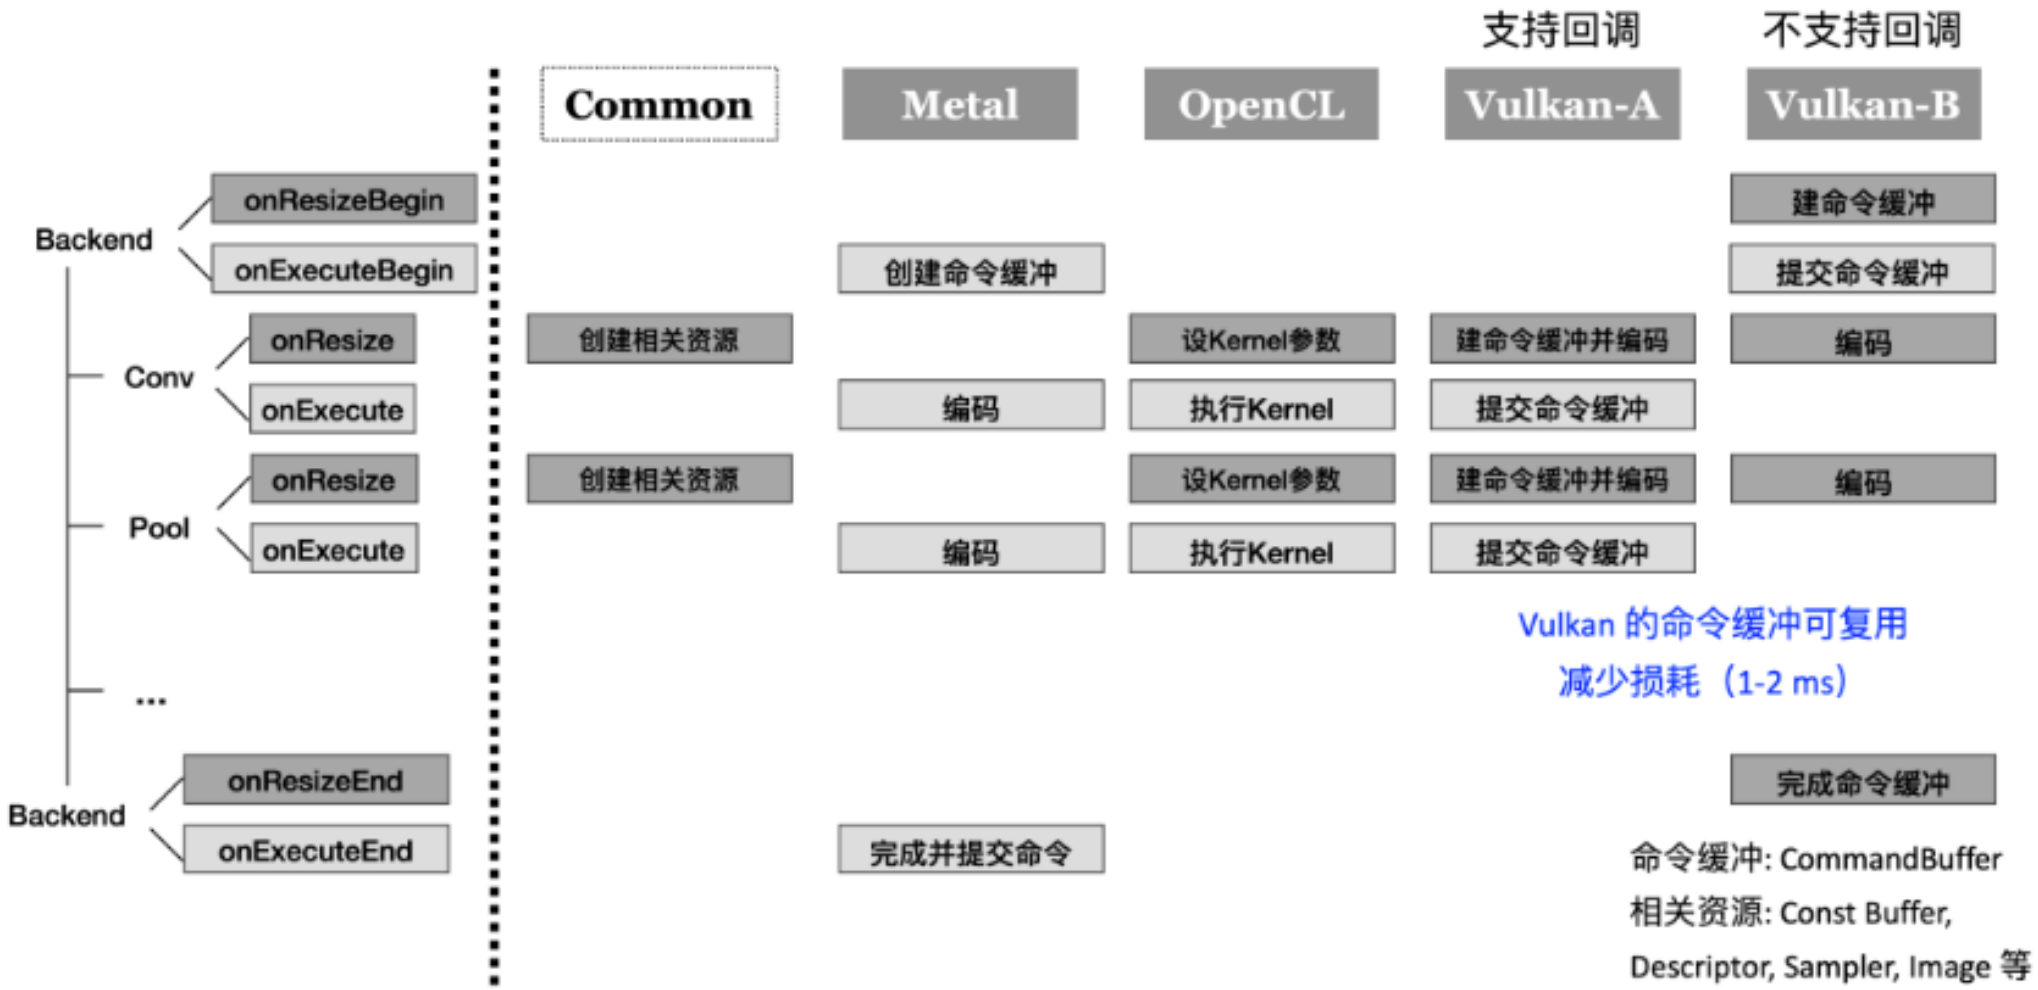

调度优化总结

1. 对于 OpenCL，可以减少 Kernel 参数设定，将计算资源的申请转移到预推理过程中；
2. 对于 Vulkan，可进一步把命令缓冲的创建全部转移到预推理中，最小化调度冗余；
3. 对于 Metal，可进一步降低命令提交频率；