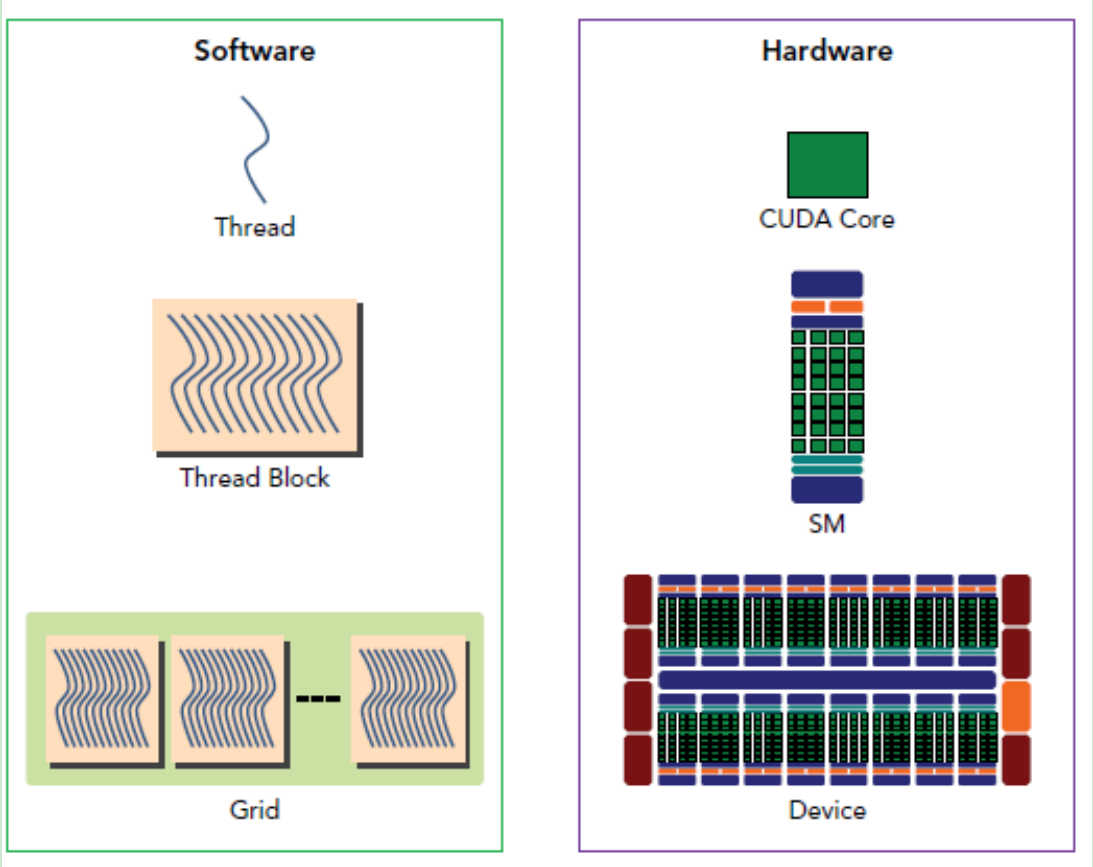

GPU并行计算与CUDA编程

资料整理
火龙果软件
荐

本周介绍内容

- 1. 并行编程的通讯模式
  - 1.1 什么是通讯模式
  - 1.2 常见通讯模式的类型和原来
- 2. GPU硬件模式
  - 2.1 GPU，SM(流处理器)，Kernel(核)，thread block(线程块)，线程
- 3. CUDA编程模型
  - 3.1 CUDA编程模型的优点和缺点
  - 3.2 CUDA编程编程模型的一些原则
  - 3.3 CUDA内存模型
  - 3.4 同步性synchronisation和屏障barrier
  - 3.5 编程模型
- 4. 开始编写CUDA程序
  - 4.1 GPU程序的一般步骤
  - 4.2 第一个GPU程序讲解——并行求平方

资料整理
火龙果软件
荐

1. 并行编程的通讯模式（Communication Patterns）

1.1 什么是通讯模式

1.2 通讯模式的类型和原理

资料整理
火龙果软件
荐

1.1 通讯模式(Communication Patterns)

- 并行计算：非常多的线程在**合作**解决一个问题

Communication

- 内存：

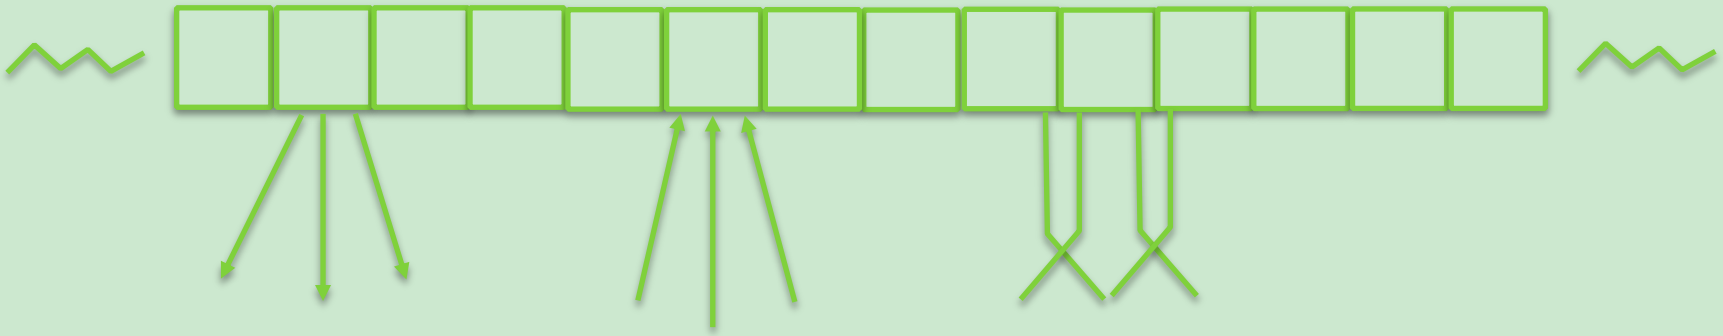

资料整理
火龙果软件
荐

1.2 常见通信模式

- 1. 映射Map
- 2. 聚合gather
- 3. 分散scatter
- 4. 模板stencil
- 5. 转换transpose
- 6. 压缩reduce
- 7. 重排scan/sort

资料整理
火龙果软件
荐

- 1. 映射Map

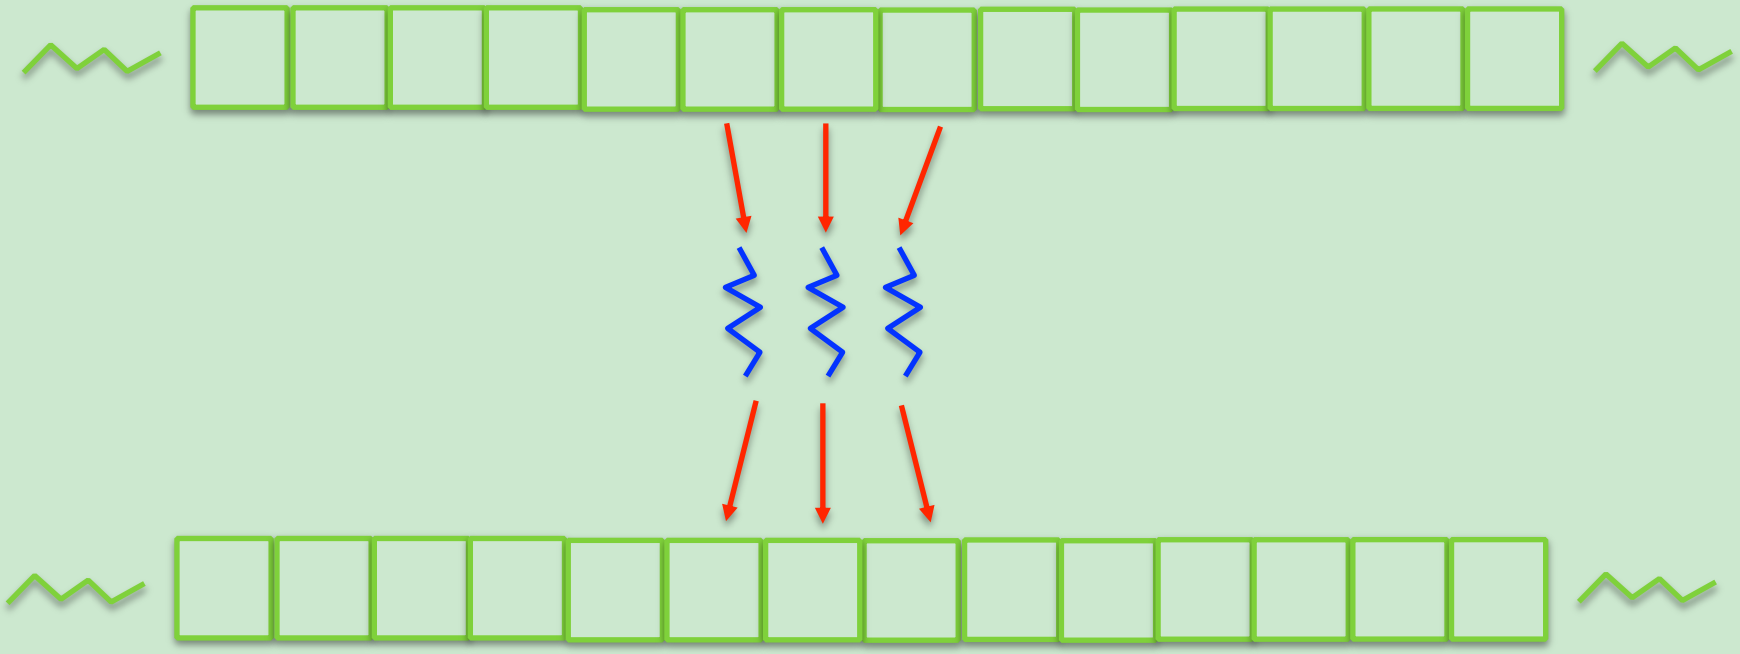

- 输入输入关系：——对应(one-to-one)
- 例子：每个元素倍数扩大，y[i]=3*x[i]

资料整理
火龙果软件
荐

- 2.聚合gatter

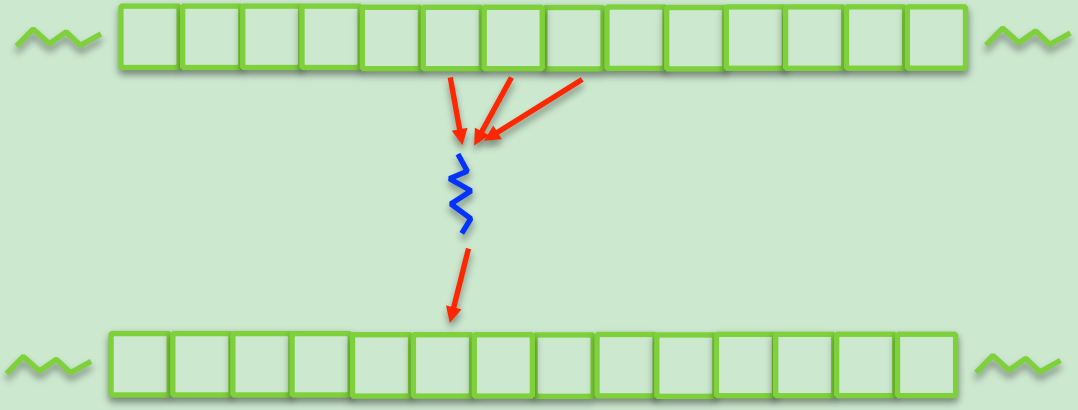

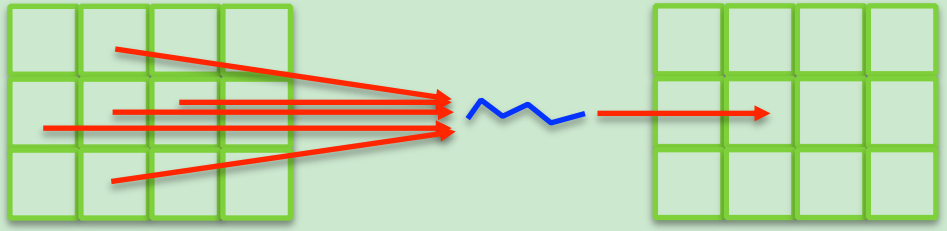

- 输入输出关系：多对一(many-to-one)
- 例子：每相邻3个元素求平均，y[i]=(x[i-1]+x[i]+x[i+1])/3

资料整理
火龙果软件
荐

- 3.分散scatter

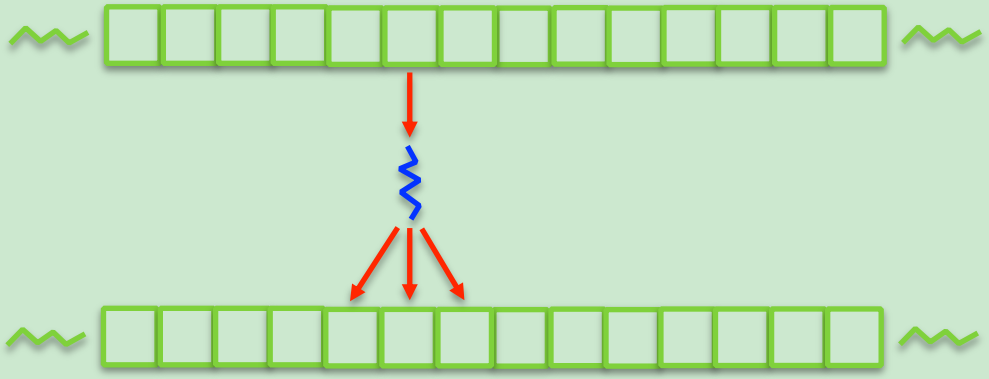

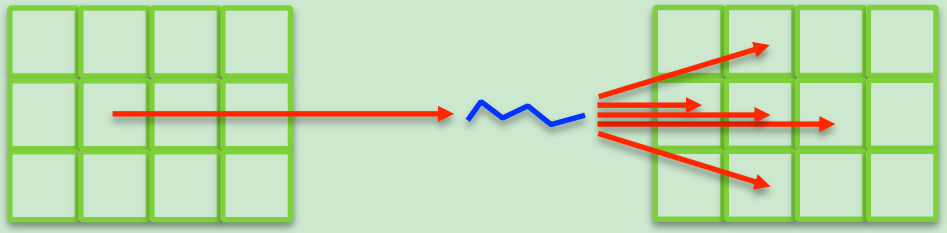

- 输入输出关系：一对多(one-to-many)

资料整理
火龙果软件
荐

- 4.模板stencil：以固定的模式读取相邻的内存数值

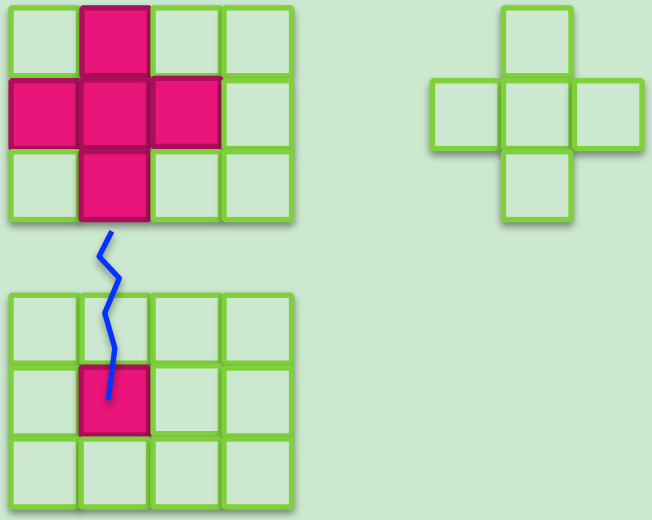

- 输入输出关系：serveral-to-one

资料整理
火龙果软件
荐

- 5.转置transpose

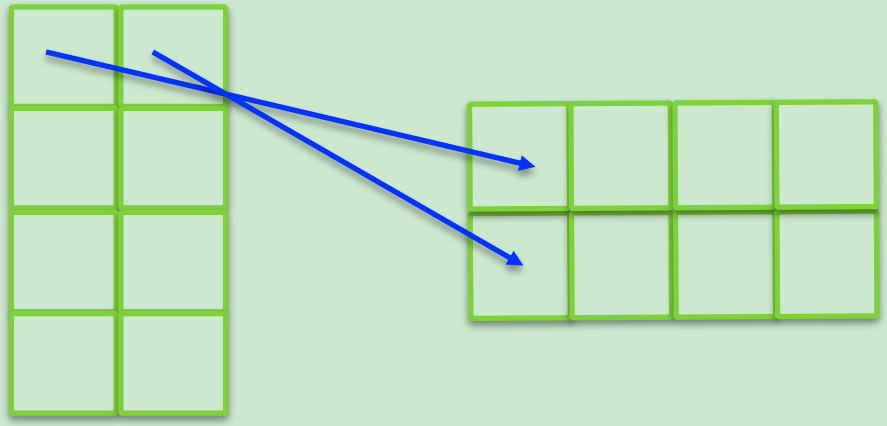

- 输入输出关系：一对一（one-to-one）

资料整理
火龙果软件
荐

- 6.压缩reduce

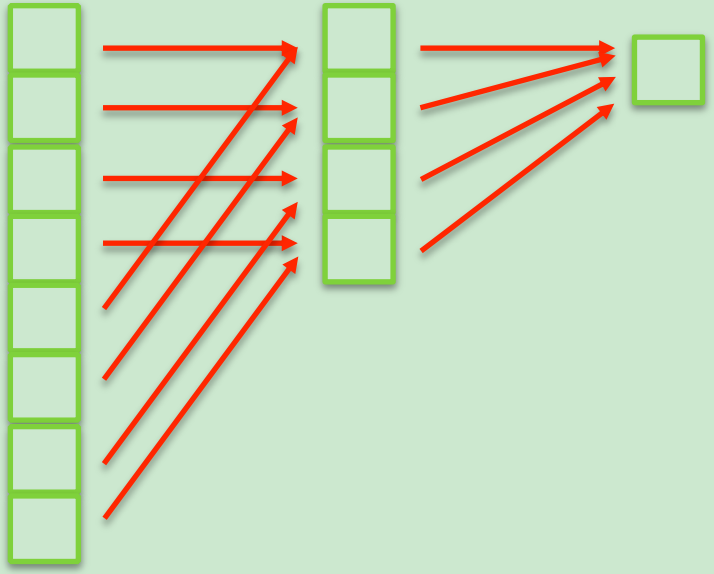

- 输入输出关系：多对一(all-to-one)

资料整理
火龙果软件
荐

- 7.重排scan/sort

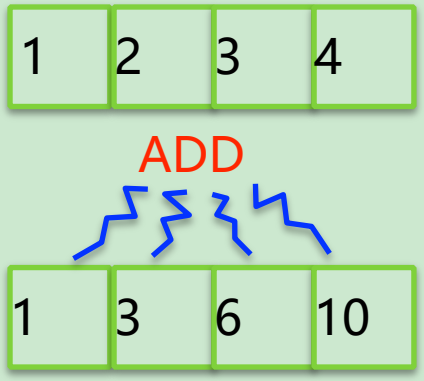

- 输入输出关系：多对多(all-to-all)

资料整理
火龙果软件
荐

2.GPU硬件模式

2.1 GPU，SM(流处理器)，Kernel(核)，thread block(线程块)，线程

资料整理
火龙果软件
荐

线程块

- Kernel核: 可以理解为C/C++中的一个函数function

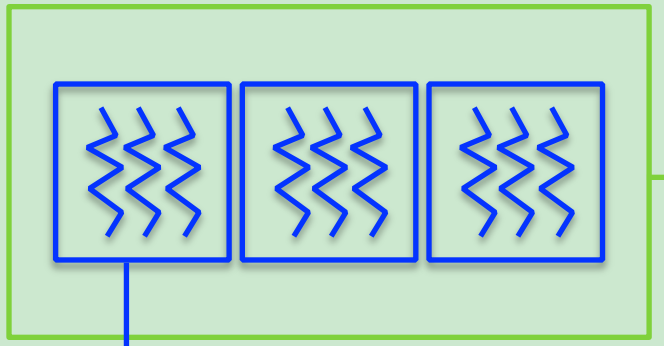

Thread Blocks: group of thread blocks to solve a function

Thread Block: a group of threads that cooperate to solve a (sub)problem
线程块

资料整理
火龙果软件
荐

GPU

- SM（stream multiprocessor）：流处理器

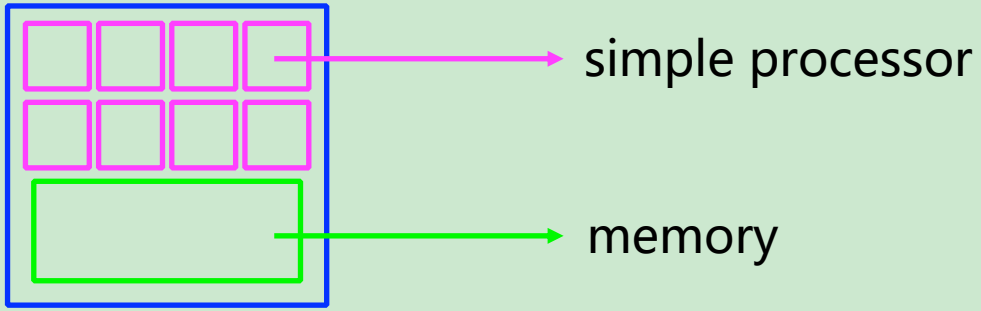

- GPU:每个GPU有若干个SM，最少有1个，目前16个算大的，每个SM并行而独立运行

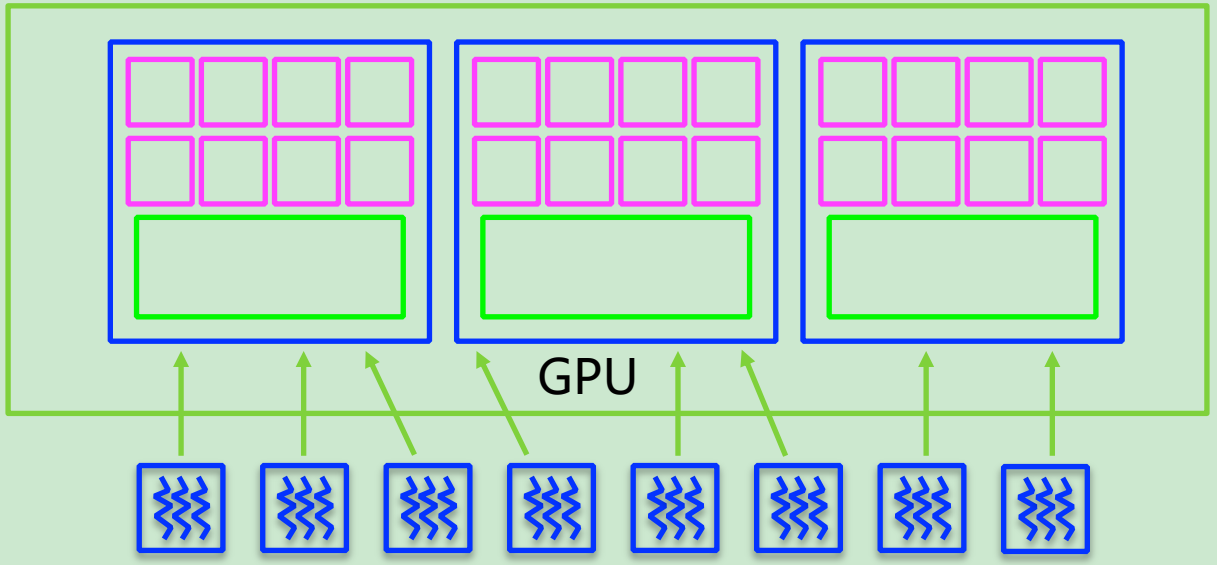

资料整理
火龙果软件
荐

3.CUDA编程模型

3.1 CUDA编程模型的优点和缺点

3.2 CUDA编程编程模型的一些原则

3.3 CUDA内存模型

3.4 同步性synchronisation和屏障barrier

3.5 编程模型

资料整理
火龙果软件
荐

3.1CUDA编程的优点和后果

- CUDA最大的特点：对线程块将在何处、何时运行不作保证。
- 优点：
- 1. 硬件真正有效的运行，灵活
- 2. 无需要线程间互相等待
- 3. 可扩展性强
- 后果：
- 1. 对于那个块在那个SM上运行无法进行任何假设
- 2. 无法获取块之间的明确通讯（hard to get communications between blocks）
  - dead lock（并行死锁）
  - 线程退出

资料整理
火龙果软件
荐

3.2 CUDA编程模型的原则

- 1. 所有在同一个线程块上的线程必然会在同一时间运行在同一个SM上
- 2. 同一个内核的所有线程块必然会全部完成了后，才会运行下一个内核

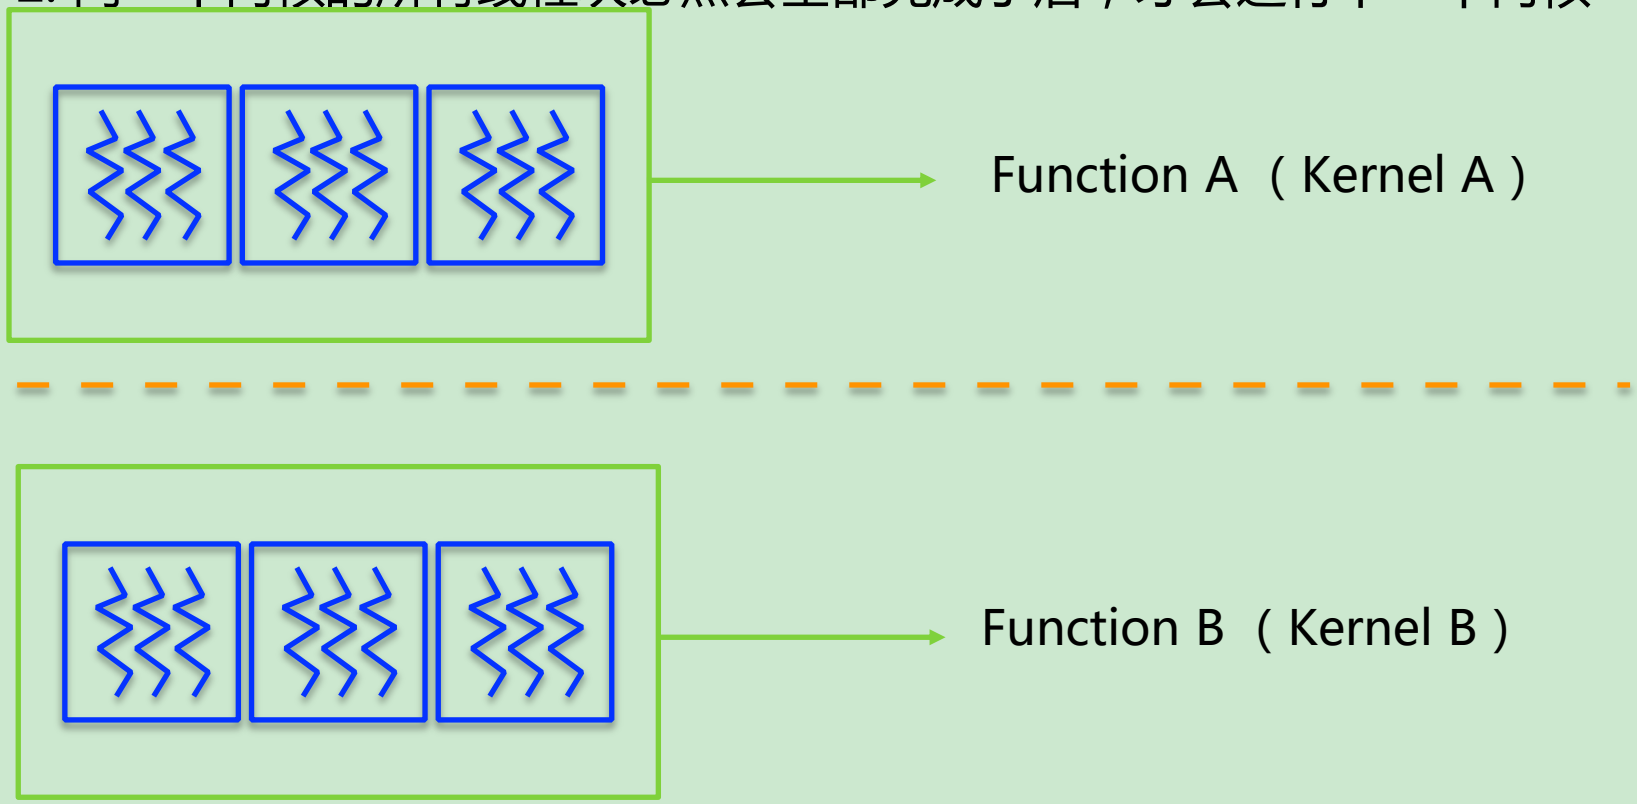

资料整理
火龙果软件
荐

3.3 内存模型

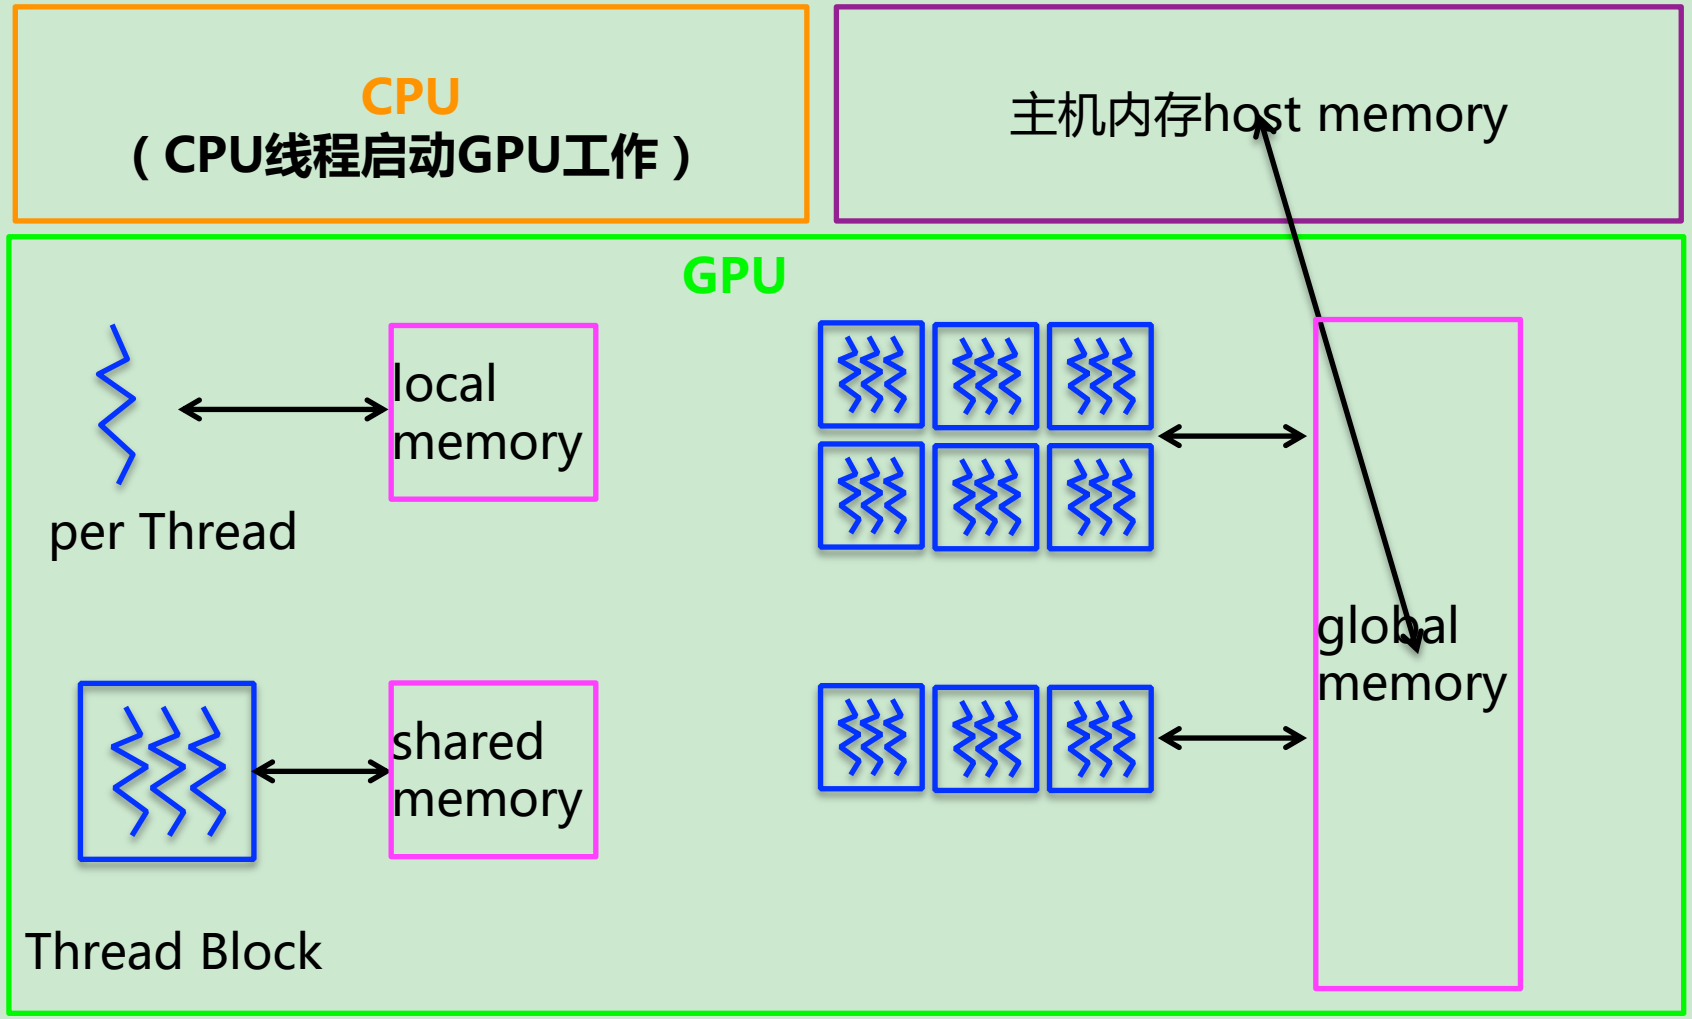

资料整理 火龙果软件 荐

内存速度比较

local memory > shared memory >> global memory > 主机内存host memory

资料整理
火龙果软件
荐

3.4 同步性synchronisation和屏障barrier

- 不同的线程在共享和全局内存中读写数据需要有先后的控制，所以引入了同步性的概念。
- 屏障的作用：用来控制多个线程的停止与等待，当所有线程都到达了屏障点，程序才继续进行。

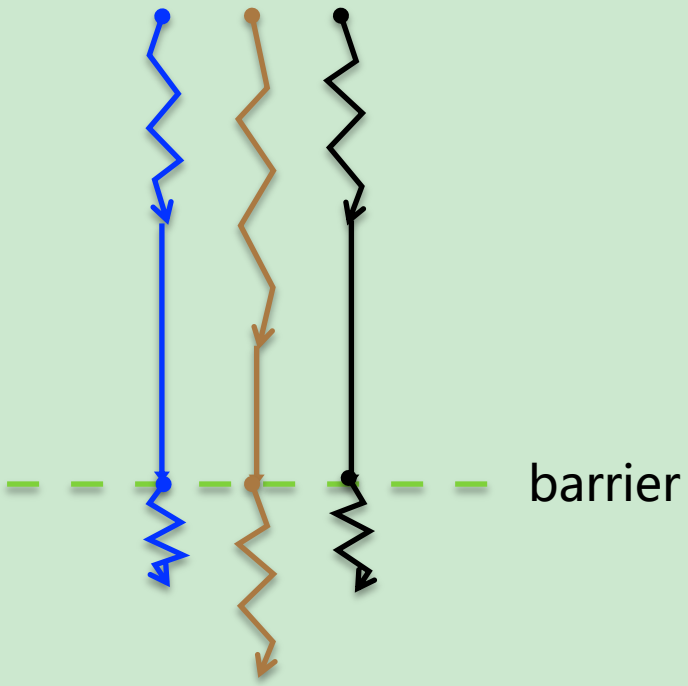

资料整理
火龙果软件
荐

3.5 CUDA编程模型

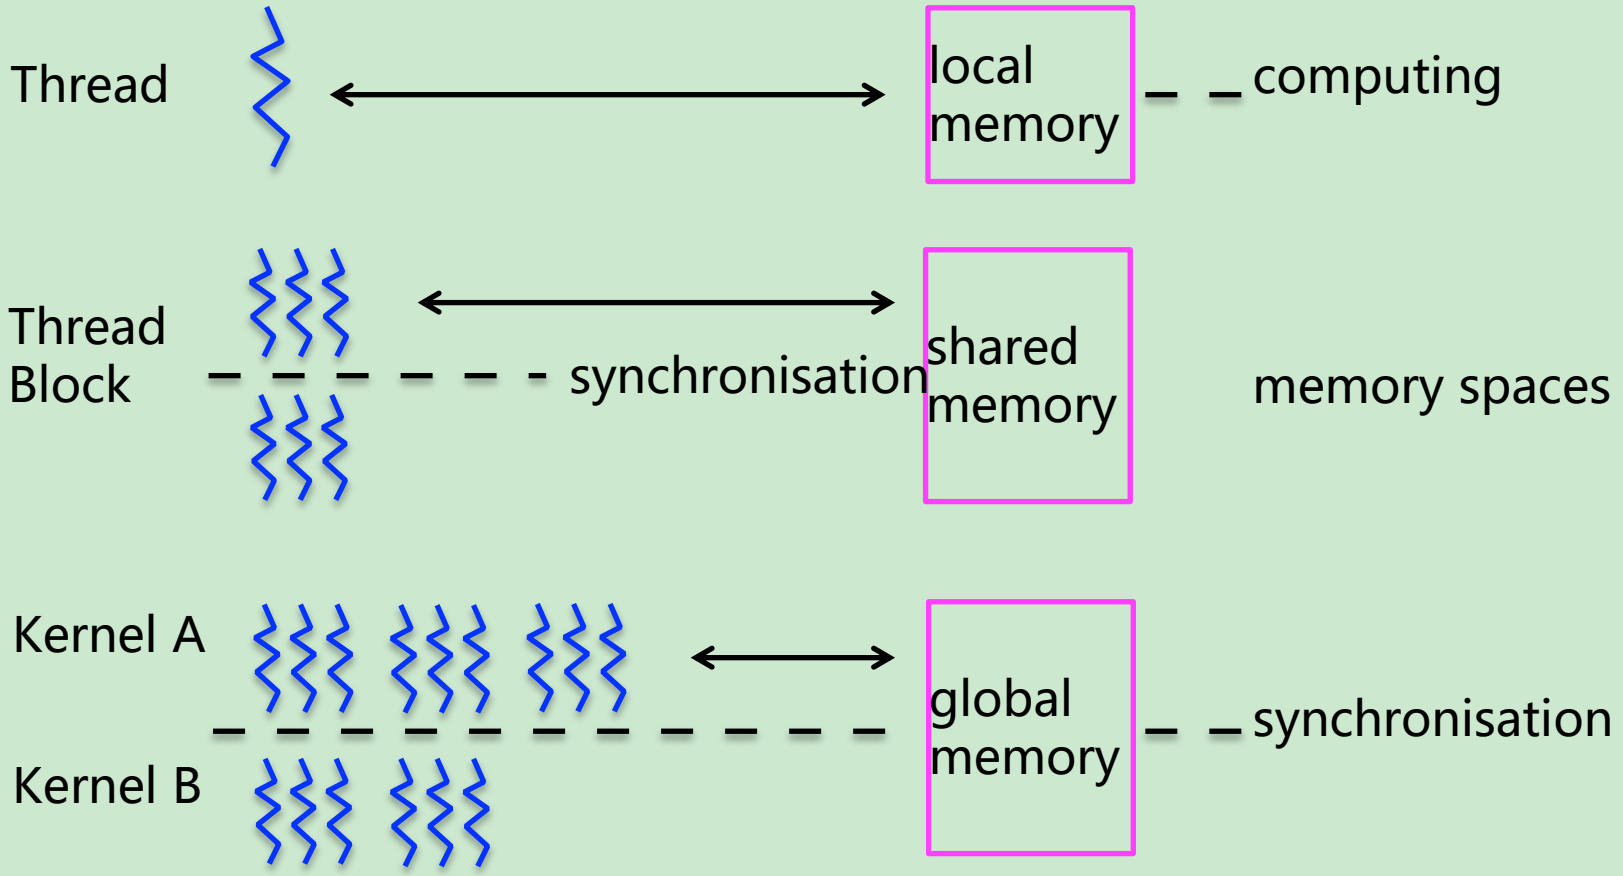

资料整理
火龙果软件
荐

CUDA编程模型—示意图

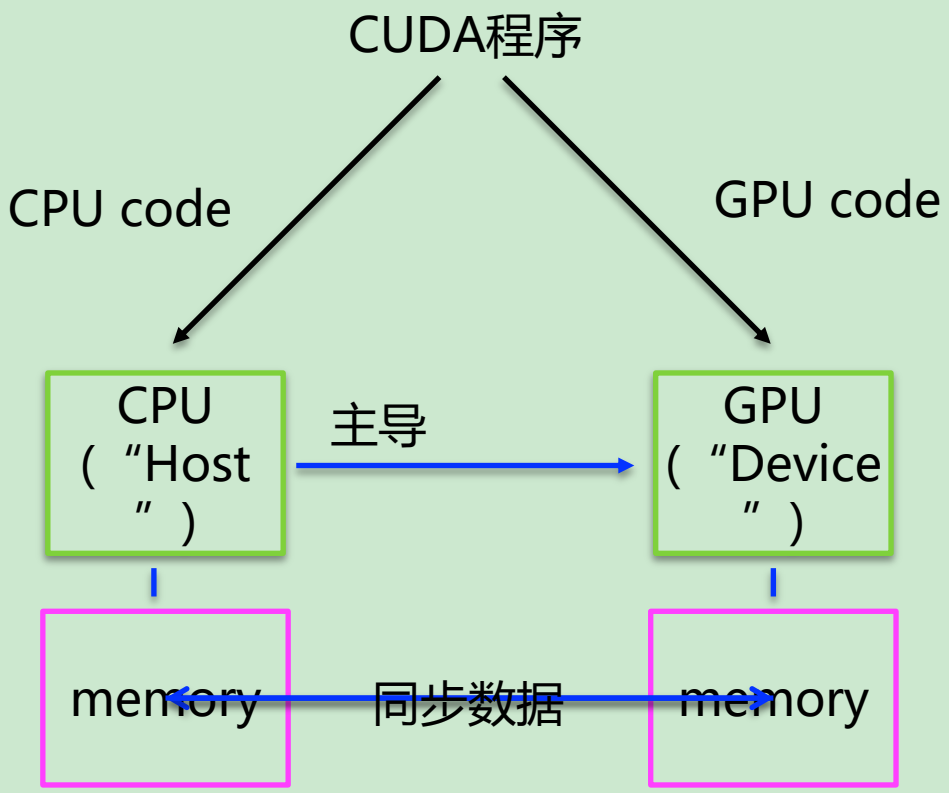

- CUDA程序中CPU是主导地位，负责完成以下的事情：
- 1. 从CPU同步数据到GPU
- 2. 从GPU同步数据到CPU
- （1、2使用cudaMemcpy）
- 3. 给GPU分配内存（cudaMalloc）
- 4. 加载Kernel到GPU上，launch kernel on GPU

资料整理
火龙果软件
荐

4.开始编写CUDA程序

4.1 GPU程序的一般步骤

4.2 第一个GPU程序讲解——并行求平方

资料整理
火龙果软件
荐

4.1 GPU程序一般步骤

- 1. CPU分配空间给GPU（cudaMalloc）
- 2. CPU复制数据给GPU（cudaMemcpy）
- 3. CPU加载kernels给GPU做计算
- 4. CPU把GPU计算结果复制回来

- 过程中，一般要尽量降低数据通讯的消耗，所以如果程序需要复制大量的数据到GPU，显然不是很合适使用GPU运算，最理想的情况是，每次复制的数据很小，然后运算量很大，输出的结果还是很小，复制回CPU。

资料整理
火龙果软件
荐

4.2 第一个GPU程序

- 程序讲解

```
#include <stdio.h>

__global__ void square(float* d_out,float* d_in){
  int idx = threadIdx.x;
  float f = d_in[idx];
  d_out[idx] = f * f;
}
```


资料整理
火龙果软件
荐

```
int main(int argc,char** argv){
  const int ARRAY_SIZE = 64;
  const int ARRAY_BYTES = ARRAY_SIZE * sizeof(float);

  // generate the input array on the host
  float h_in[ARRAY_SIZE];
  for(int i=0;i<ARRAY_SIZE;i++){
    h_in[i] = float(i);
  }
  float h_out[ARRAY_SIZE];

  // declare GPU memory pointers
  float* d_in;
  float* d_out;

  // allocate GPU memory
  cudaMalloc((void**) &d_in,ARRAY_BYTES);
  cudaMalloc((void**) &d_out,ARRAY_BYTES);

  // transfer the array to GPU
  cudaMemcpy(d_in,h_in,ARRAY_BYTES,cudaMemcpyHostToDevice);
```

```
  // launch the kernel
  square<<<1,ARRAY_SIZE>>>(d_out,d_in);

  // copy back the result array to the GPU
  cudaMemcpy(h_out,d_out,ARRAY_BYTES,cudaMemcpyDeviceToHost);

  // print out the resulting array
  for(int i=0;i<ARRAY_SIZE;i++){
    printf("%f",h_out[i]);
    printf(((i%4) != 3) ? "\t" : "\n");
  }

  // free GPU memory allocation
  cudaFree(d_in);
  cudaFree(d_out);

  return 0;


}
```


资料整理
火龙果软件
荐

- 根据课程的讲解程序square.cu改写其中kernel部分，可以改成做cube或者其他的自定义运算，然后使用nvcc编译，把成功编译并运行的截图提交即可。

资料整理
火龙果软件
荐

Thanks

FAQ时间

资料整理
火龙果软件
荐