Programação Paralela em Ambientes Computacionais Heterogêneos com OpenCL

César L. B. Silveira
Prof. Dr. Luiz G. da Silveira Jr.
Prof. Dr. Gerson Geraldo H. Cavalheiro

08 de novembro de 2010

cesar@v3d.com.br

Introdução

- Ambientes computacionais atuais: CPUs *multicore* e GPUs *many-core*
  - Ambientes **heterogêneos**
  - Processamento paralelo
  - Alto desempenho
- Como utilizar todo este poder computacional?

Introdução

- Programação paralela
  - CPUs
    - *Multithreading*
      - POSIX Threads, Windows Threads, OpenMP, etc.
  - GPUs
    - APIs gráficas (OpenGL, DirectX)
    - *Shaders*
    - Tecnologias proprietárias
      - NVIDIA CUDA, AMD Streaming SDK

Introdução

- Problema: múltiplas ferramentas e paradigmas
  - Alto custo de implementação
  - Aplicações dependentes de plataforma
- Necessidade de um padrão para programação paralela

Introdução

- Open Computing Language (OpenCL)
  - Padrão aberto, livre de *royalties*, para programação paralela em ambientes heterogêneos
  - Criado pela Apple
  - Mantido pelo Khronos Group desde 2008
  - Define *framework*
    - Arquitetura
    - Linguagem
    - API

Introdução

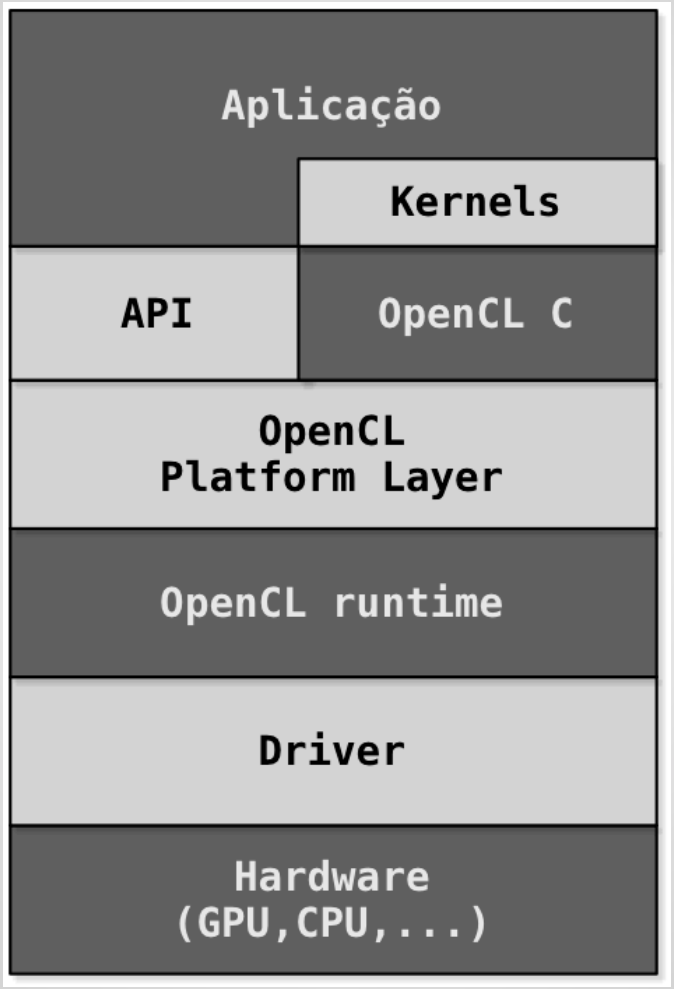

Camadas de uma aplicação OpenCL

Hello World

- Código sequencial

```
void ArrayDiff(const int* a,
               const int* b,
               int* c,
               int n)
{
    for (int i = 0; i < n; ++i)
    {
        c[i] = a[i] - b[i];
    }
}
```

Hello World

- Código OpenCL (*kernel*)

```
__kernel void ArrayDiff(__global const int* a,
                        __global const int* b,
                        __global int* c)
{
    int id = get_global_id(0);
    c[id] = a[id] - b[id];
}
```

Arquitetura OpenCL

- Arquitetura abstrata de baixo nível
- Implementações mapeiam para entidades físicas
- Quatro modelos
  - Plataforma
  - Execução
  - Programação
  - Memória

Arquitetura OpenCL

- Modelo de plataforma
  - Descreve entidades do ambiente OpenCL

Arquitetura OpenCL

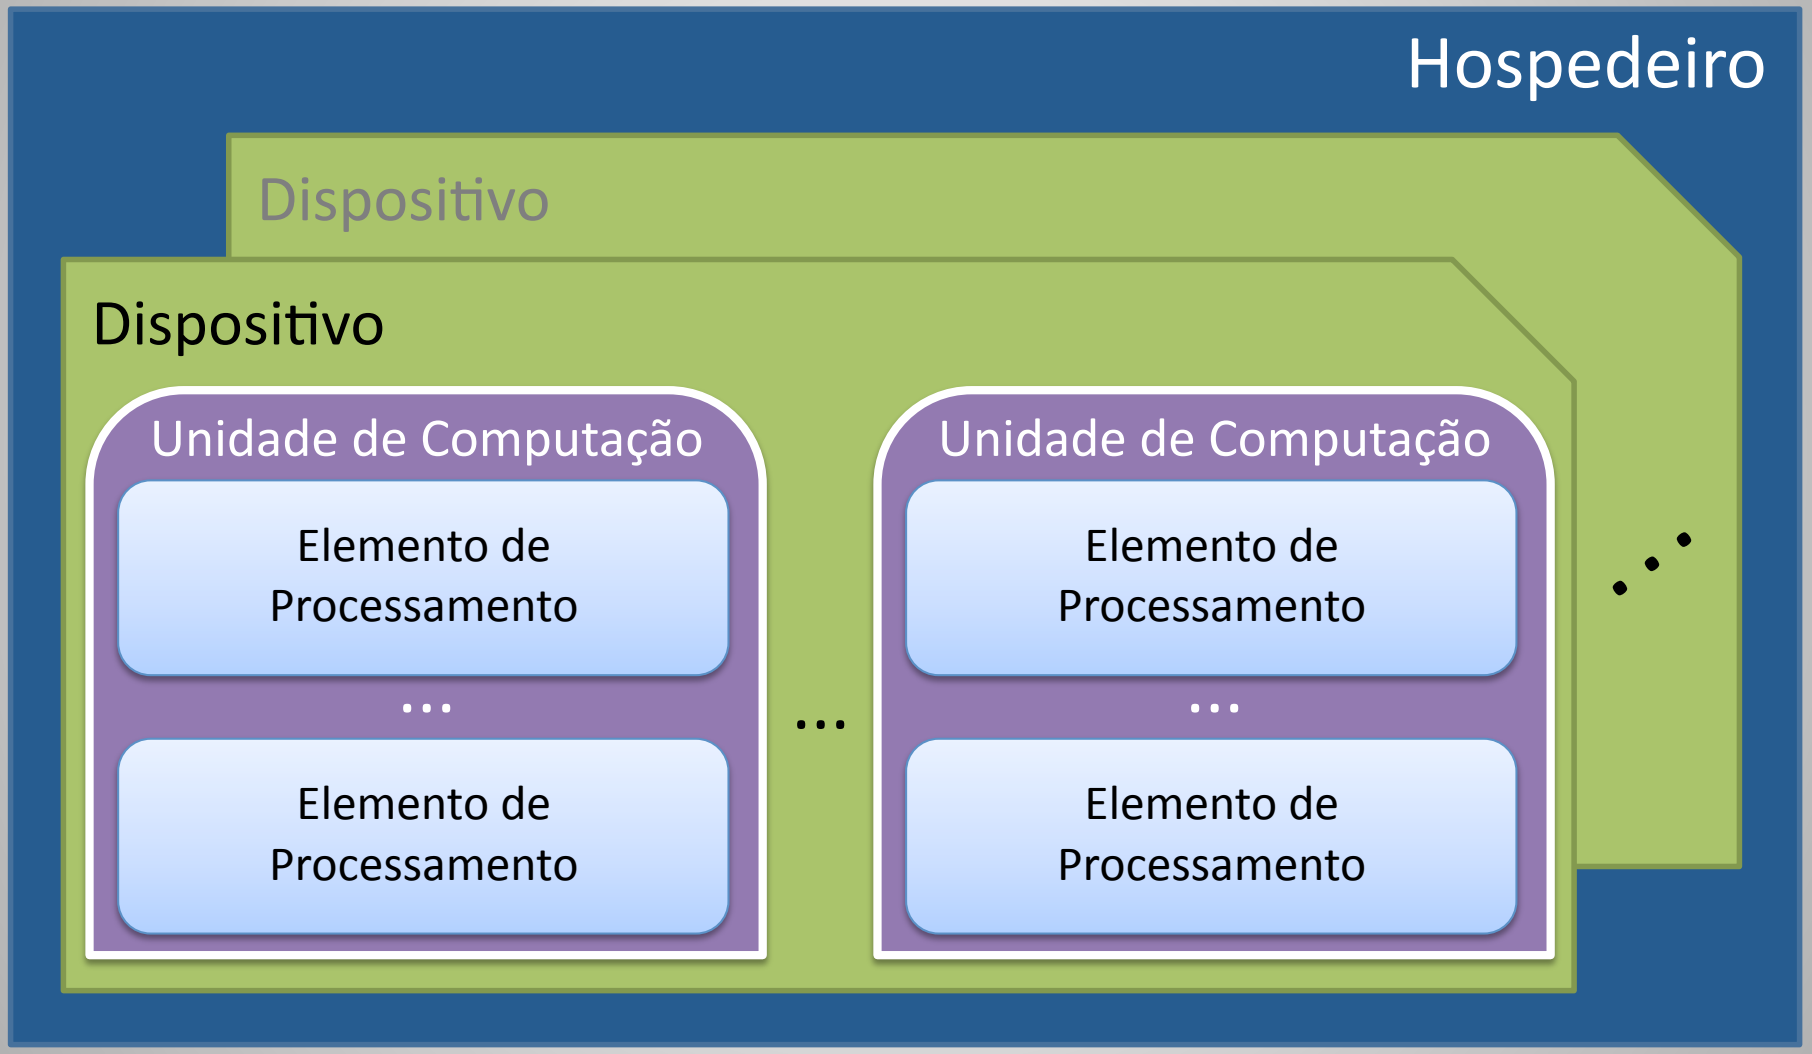

Modelo de Plataforma

Arquitetura OpenCL

- Modelo de execução
  - Descreve instanciação e identificação de *kernels*

Arquitetura OpenCL

- Modelo de execução
  - Espaços de índices

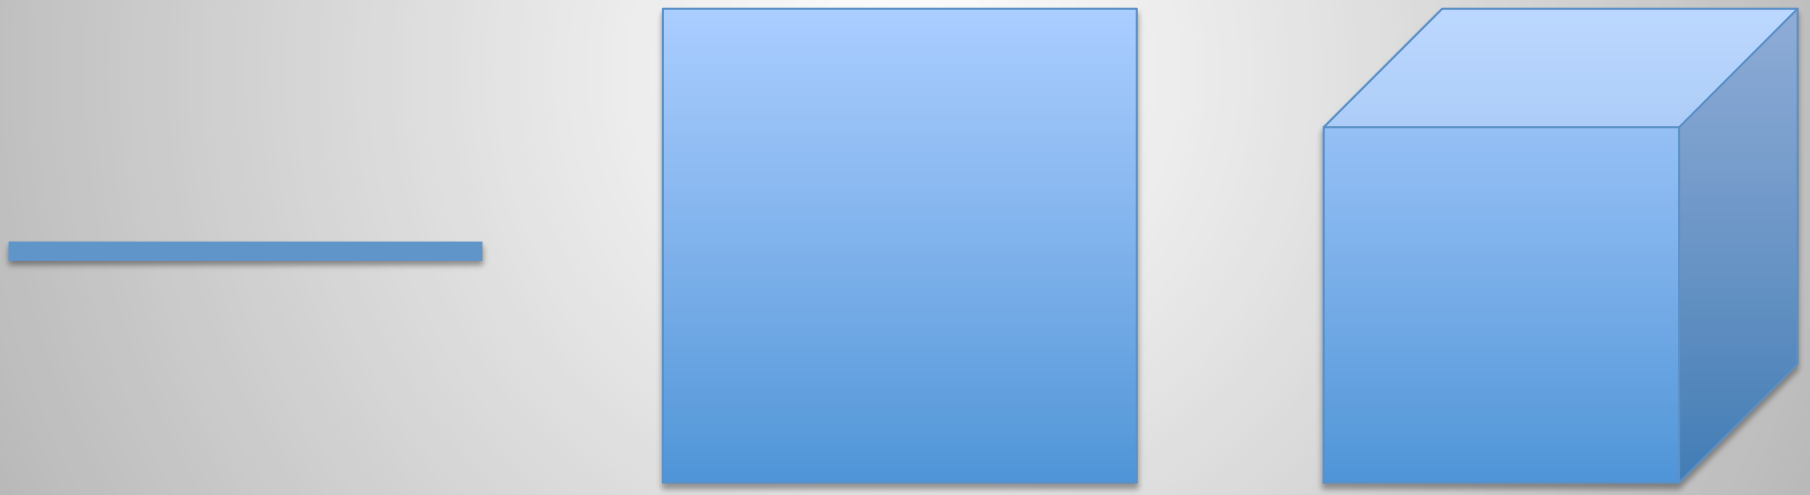

1D 2D 3D

Arquitetura OpenCL

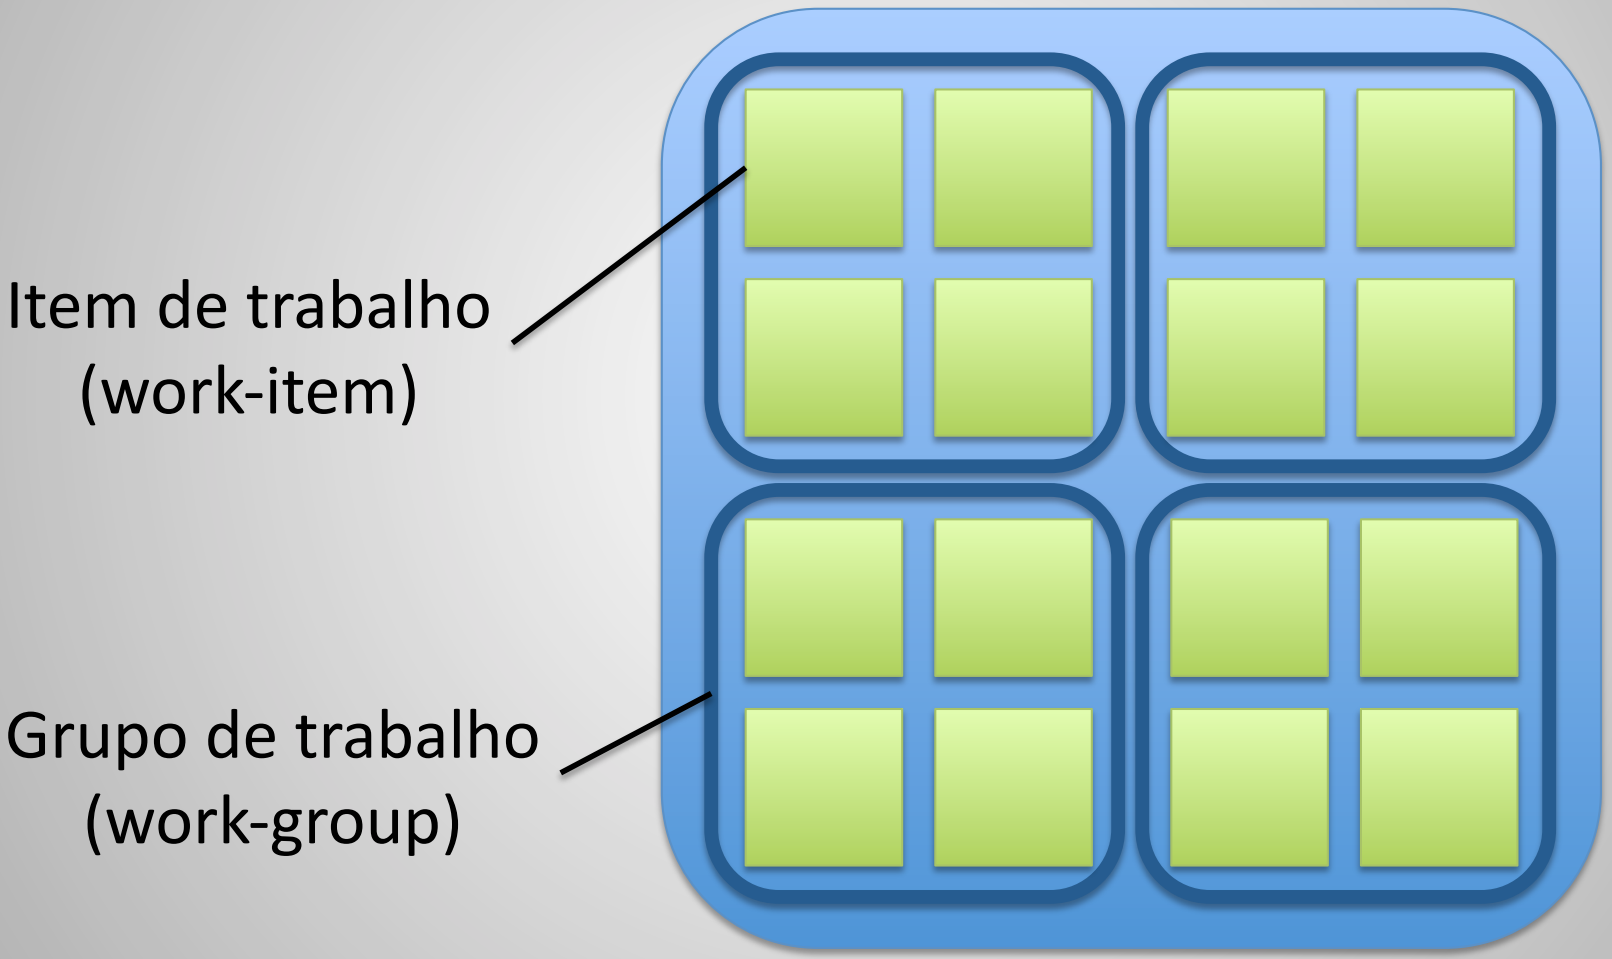

Modelo de execução: itens e grupos de trabalho

Arquitetura OpenCL

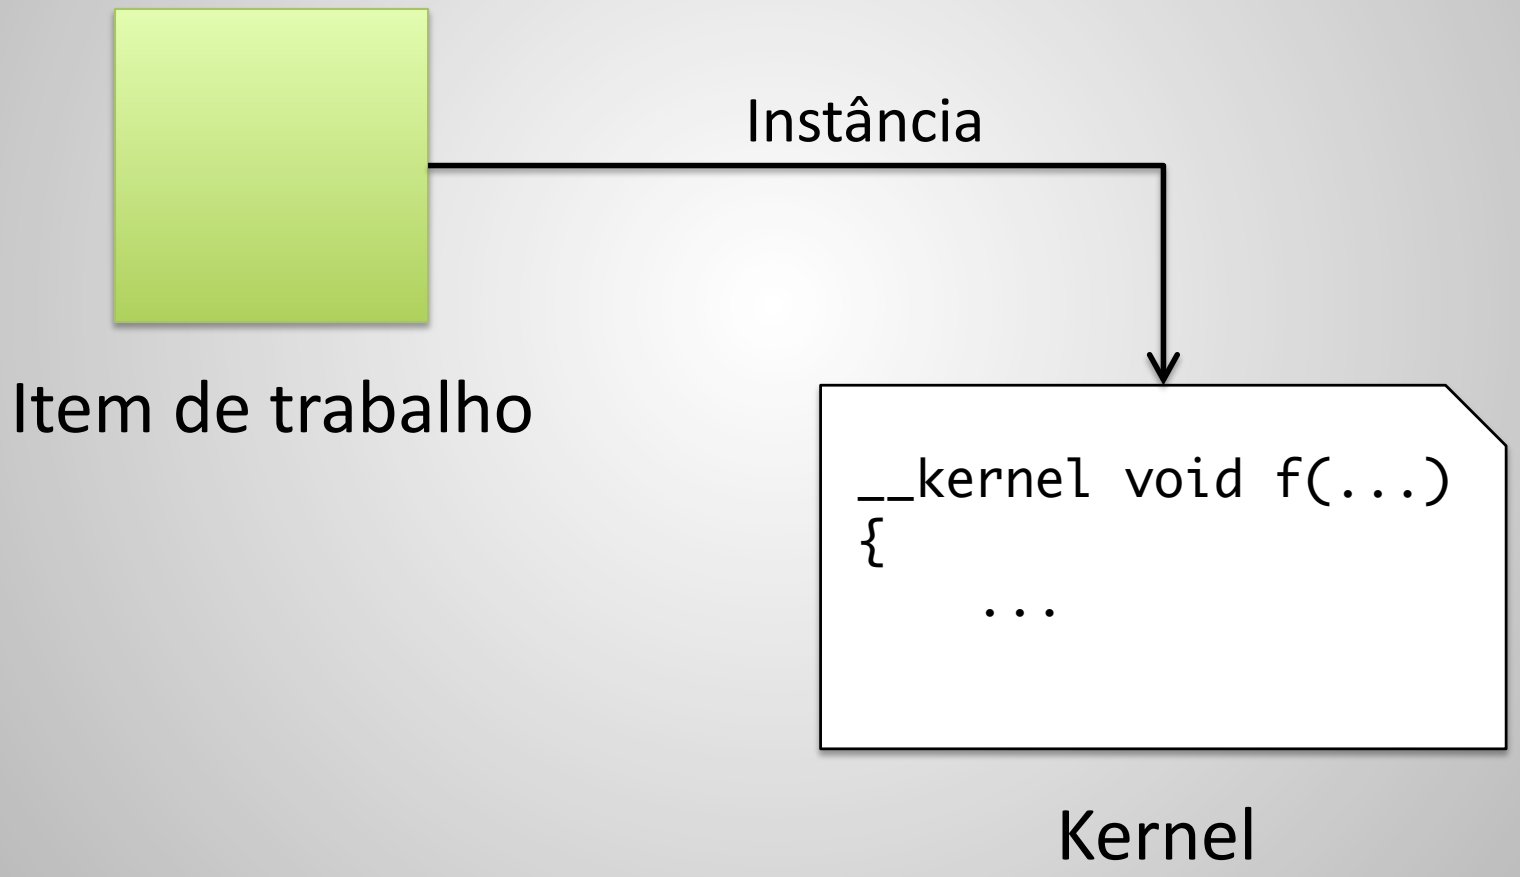

Arquitetura OpenCL

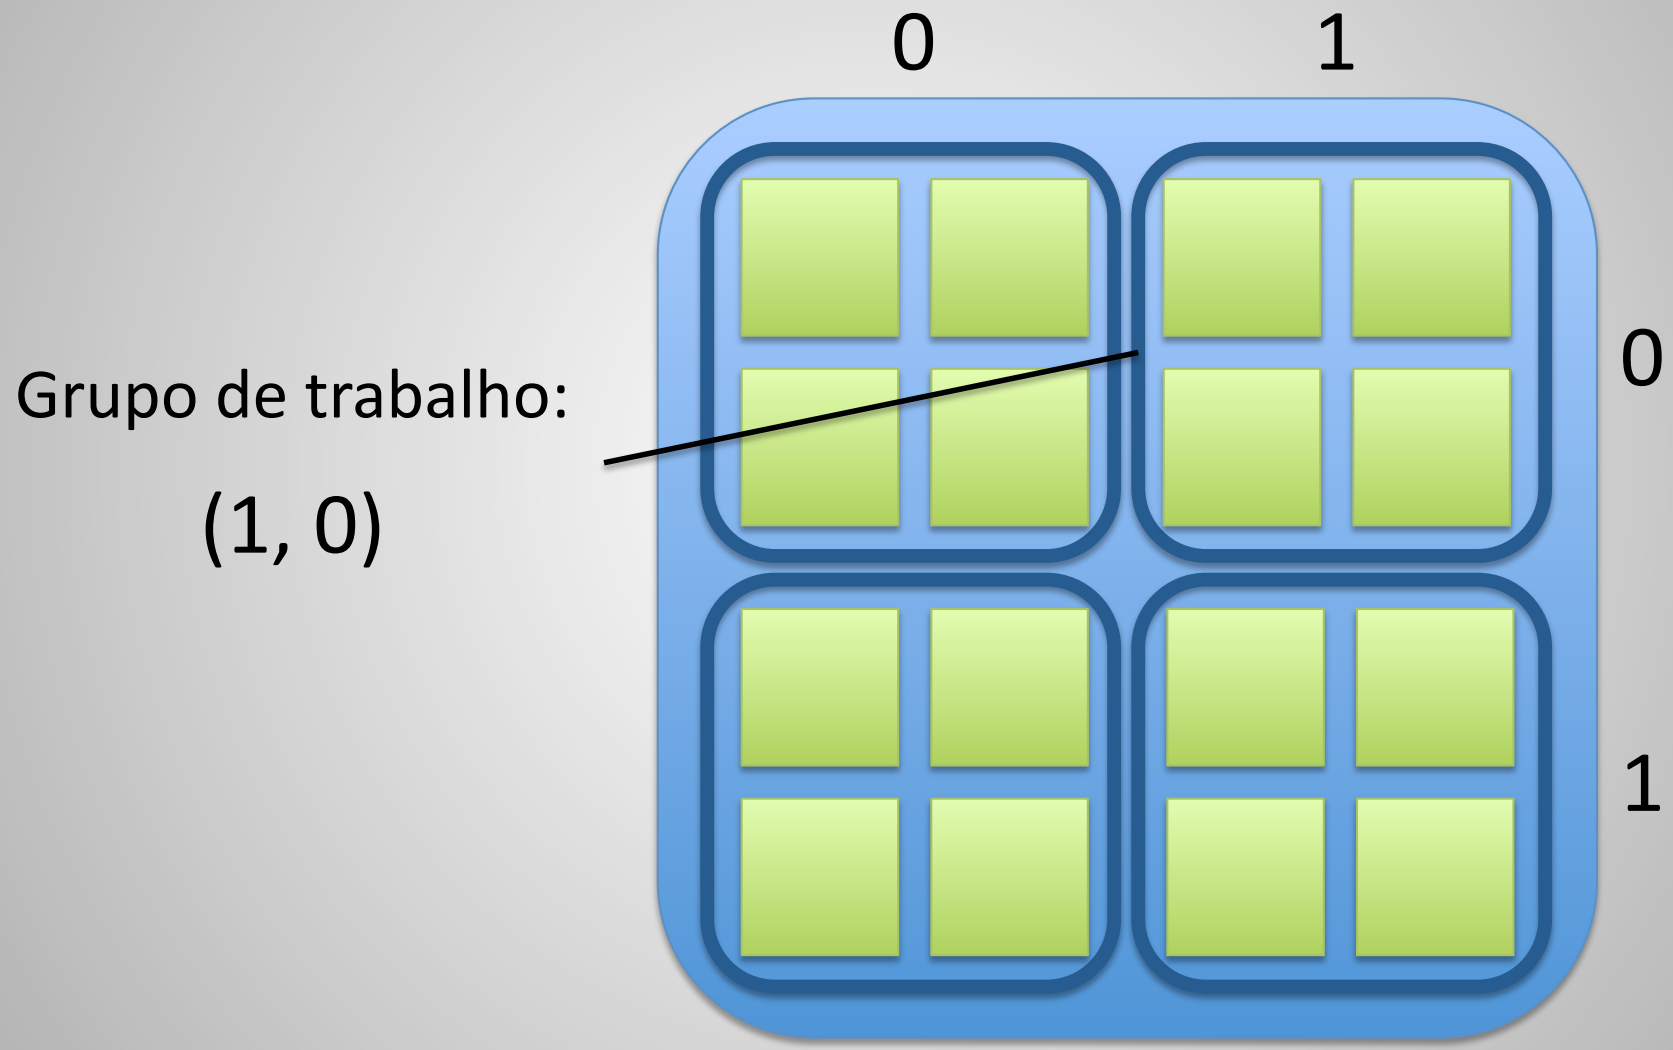

Modelo de execução: identificadores

Arquitetura OpenCL

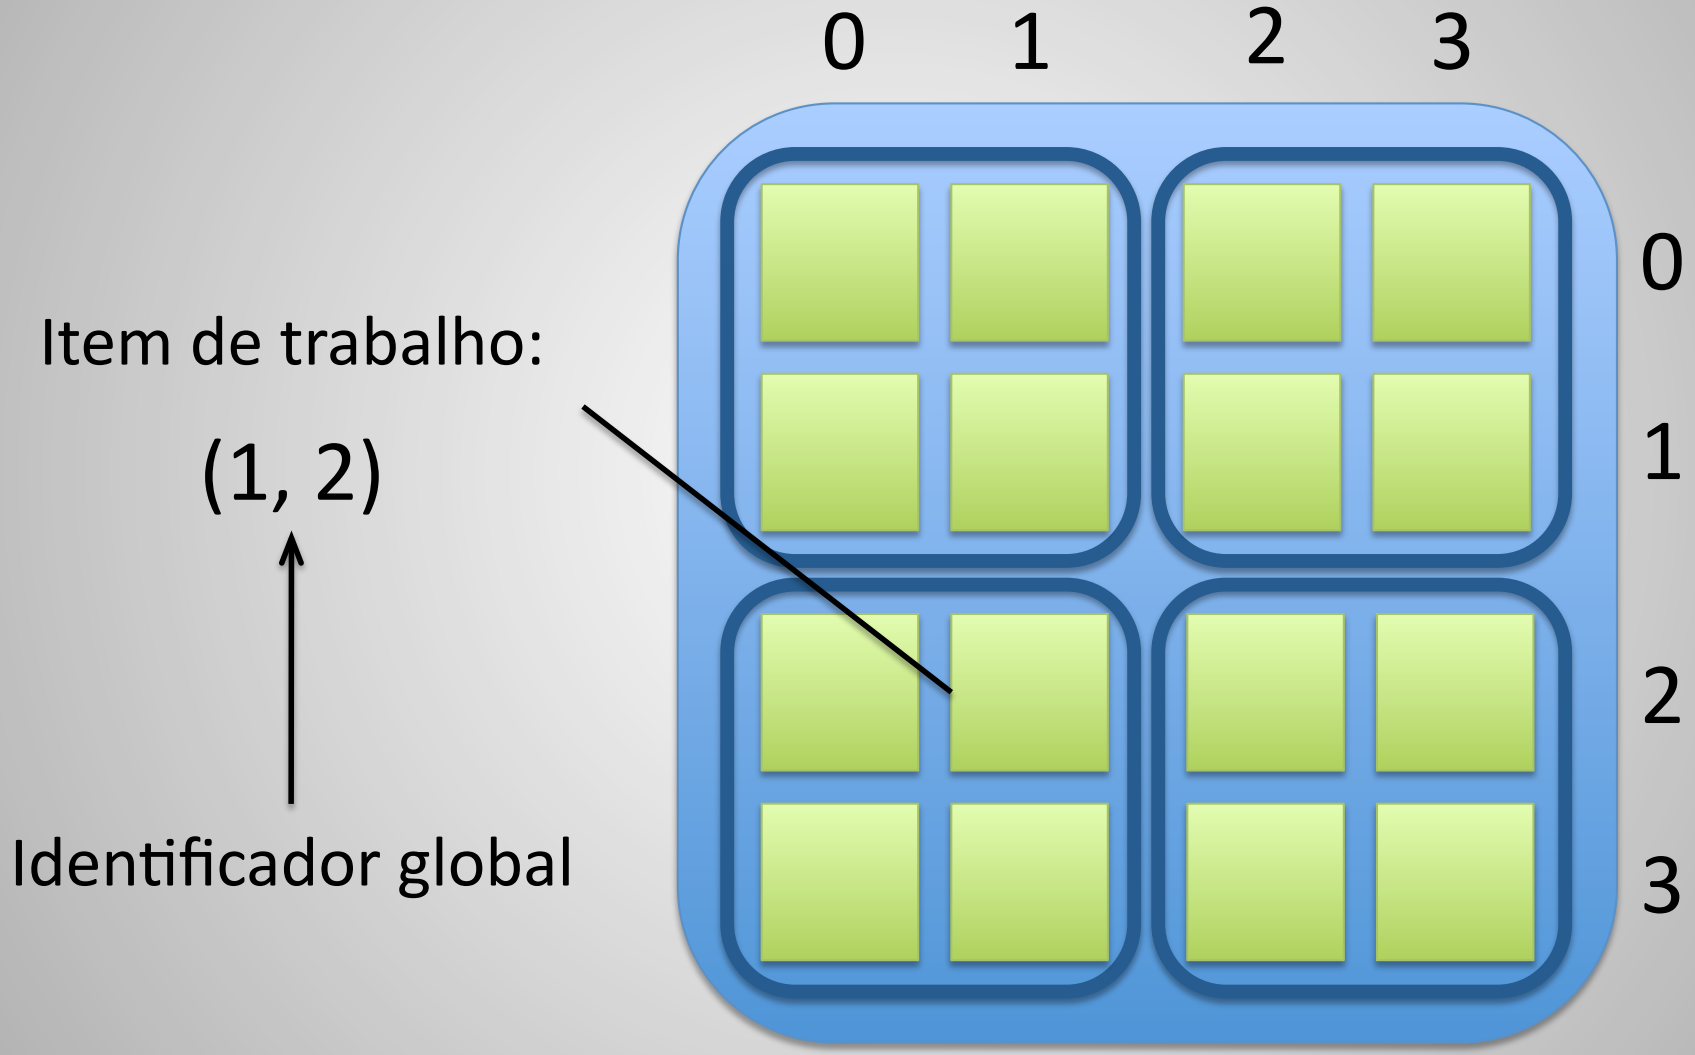

Modelo de execução: identificadores

Arquitetura OpenCL

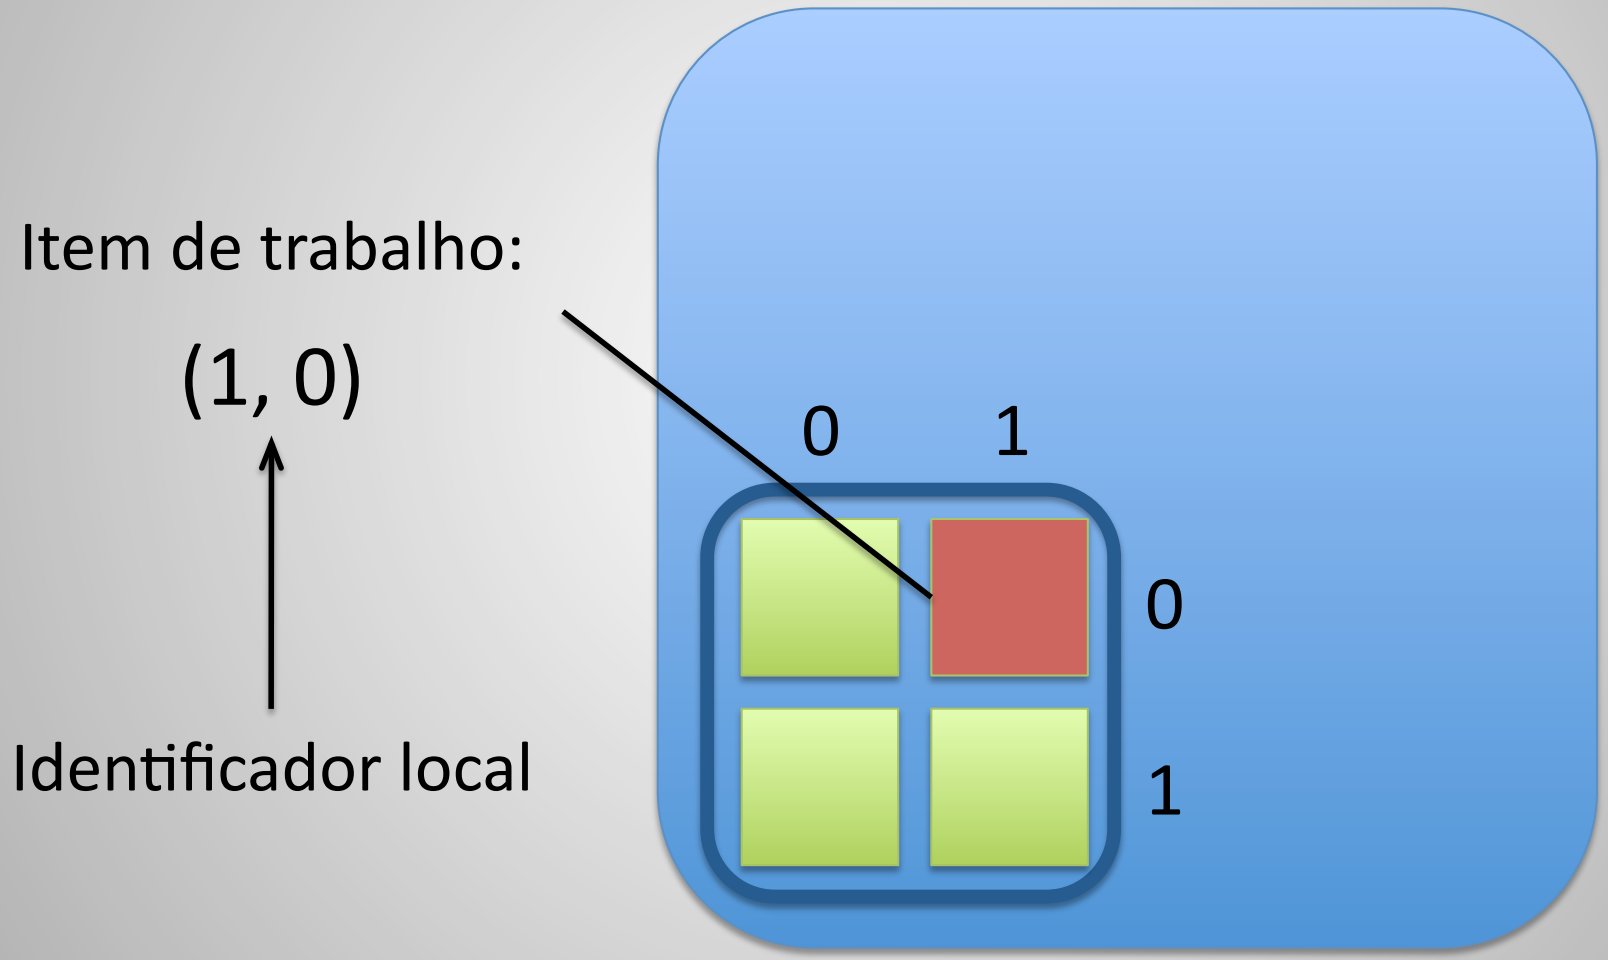

Modelo de execução: identificadores

Arquitetura OpenCL

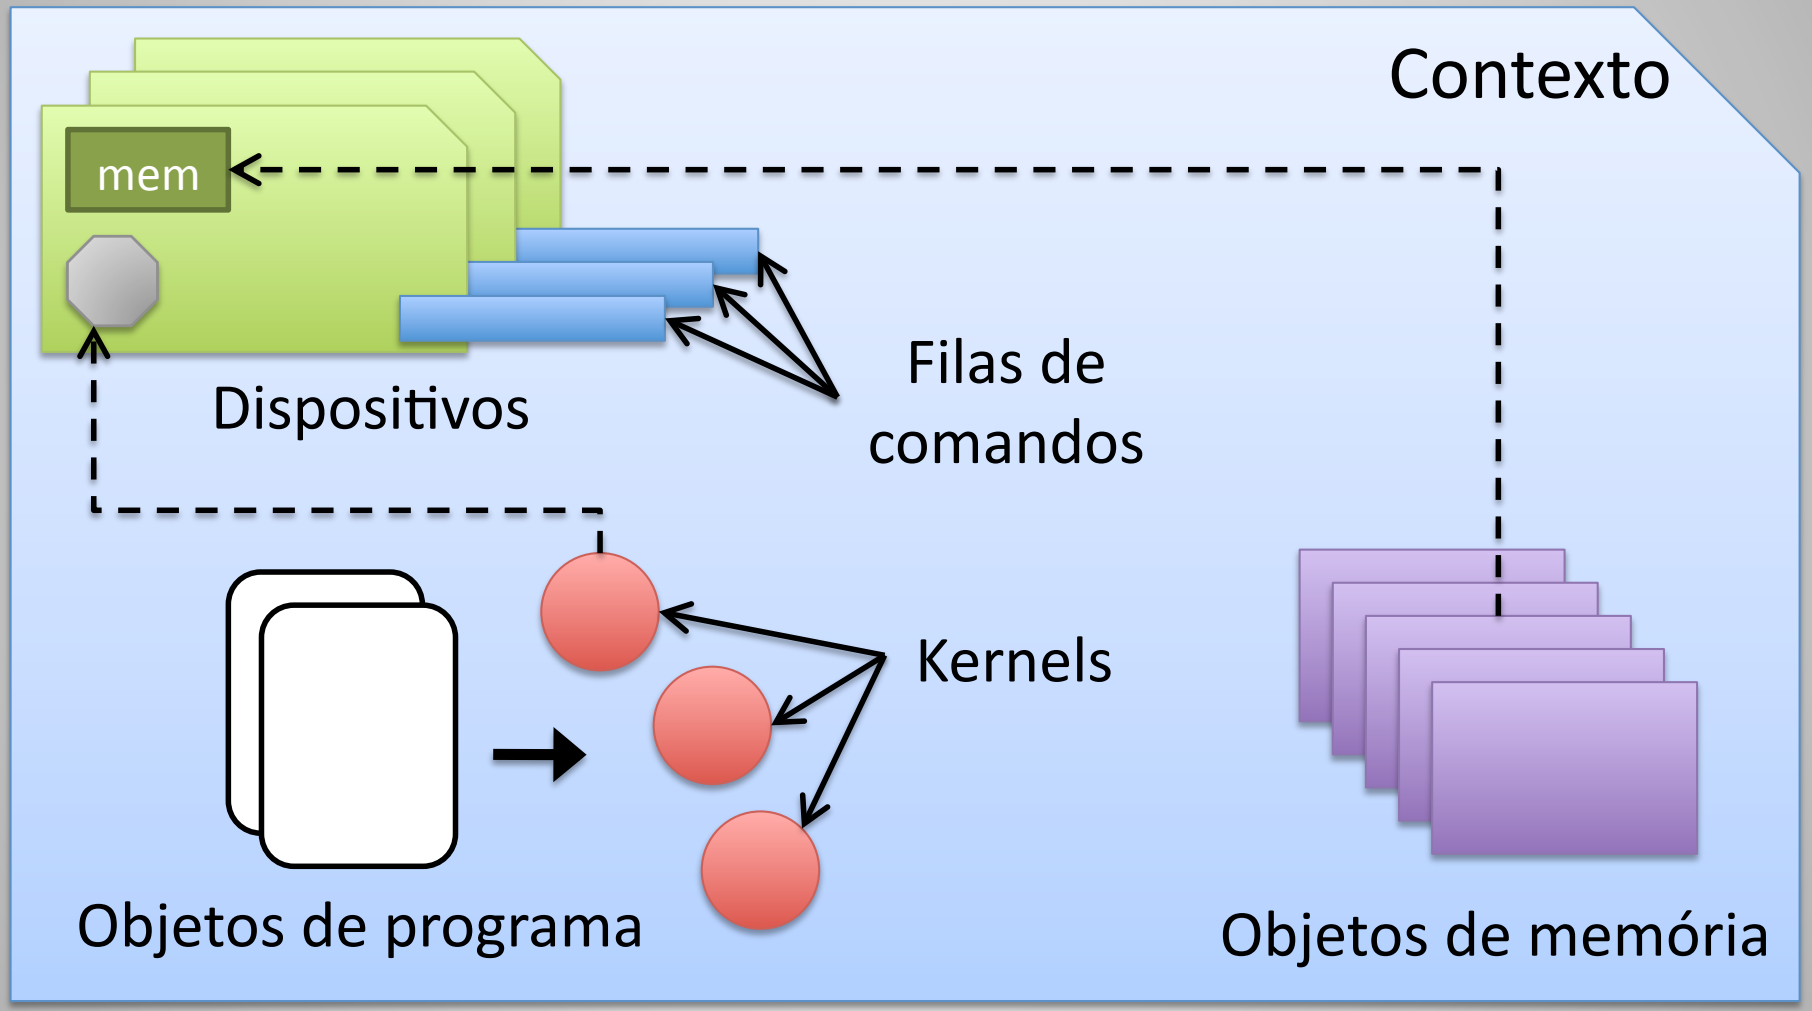

Modelo de execução: objetos

Arquitetura OpenCL

- Modelo de execução: objetos
  - Toda comunicação com um dispositivo é feita através da sua fila de comandos
  - Objetos de memória
    - *Buffers*: acesso direto via ponteiros
    - *Images*: acesso especial via samplers

Arquitetura OpenCL

- Modelo de programação
  - **Paralelismo de dados** (*data parallel*): múltiplos itens de trabalho para um *kernel*
  - **Paralelismo de tarefas** (*task parallel*): um item de trabalho para um *kernel*

Arquitetura OpenCL

- Modelo de memória
  - Descreve uma hierarquia de memória e o compartilhamento de cada nível entre itens e grupos de trabalho

Arquitetura OpenCL

Memória privada

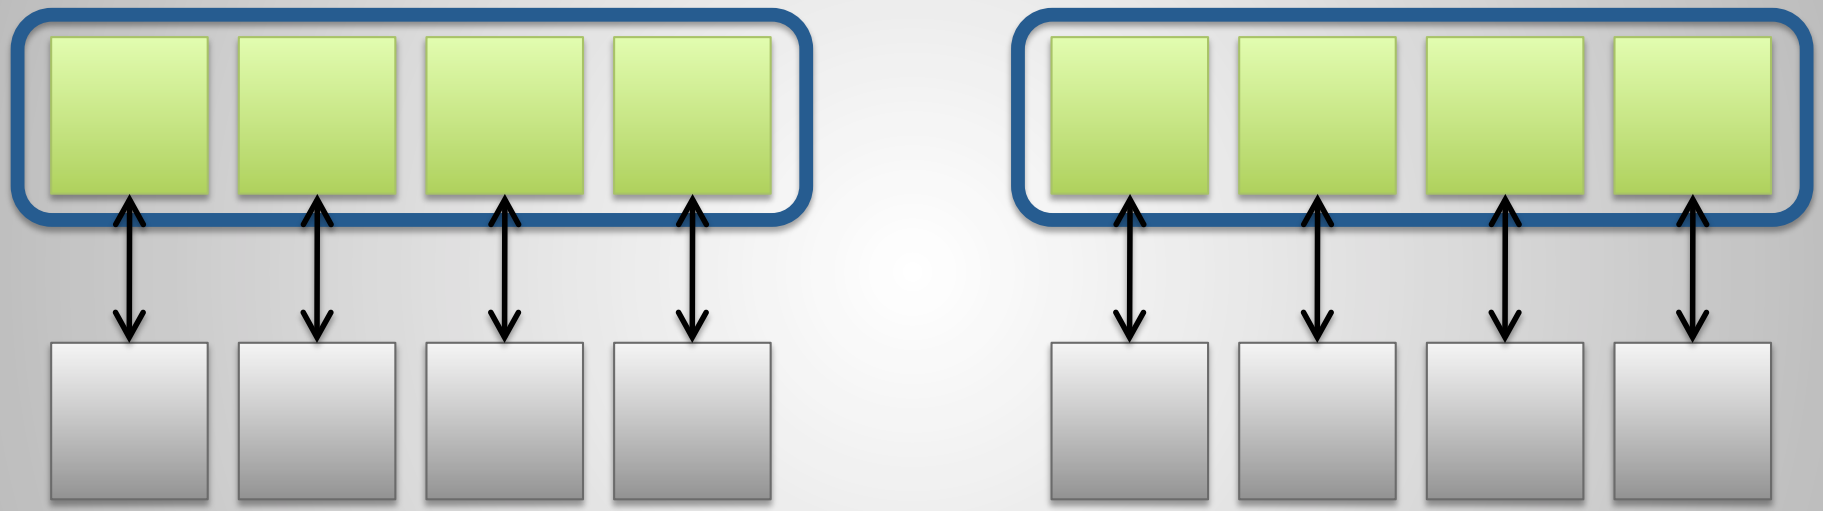

- Exclusiva de cada item de trabalho
- Leitura e Escrita

Modelo de memória

Arquitetura OpenCL

Memória local

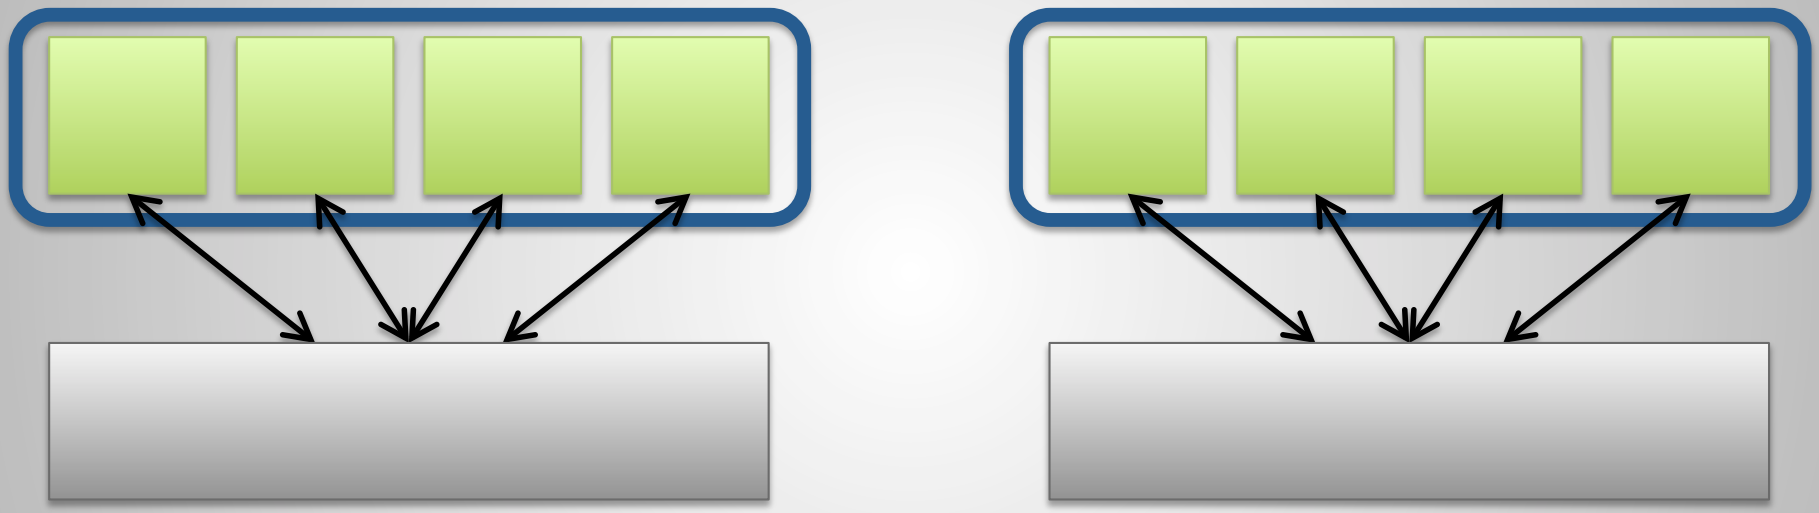

- Compartilhada pelo grupo de trabalho
- Leitura e Escrita

Modelo de memória

Arquitetura OpenCL

Memória global

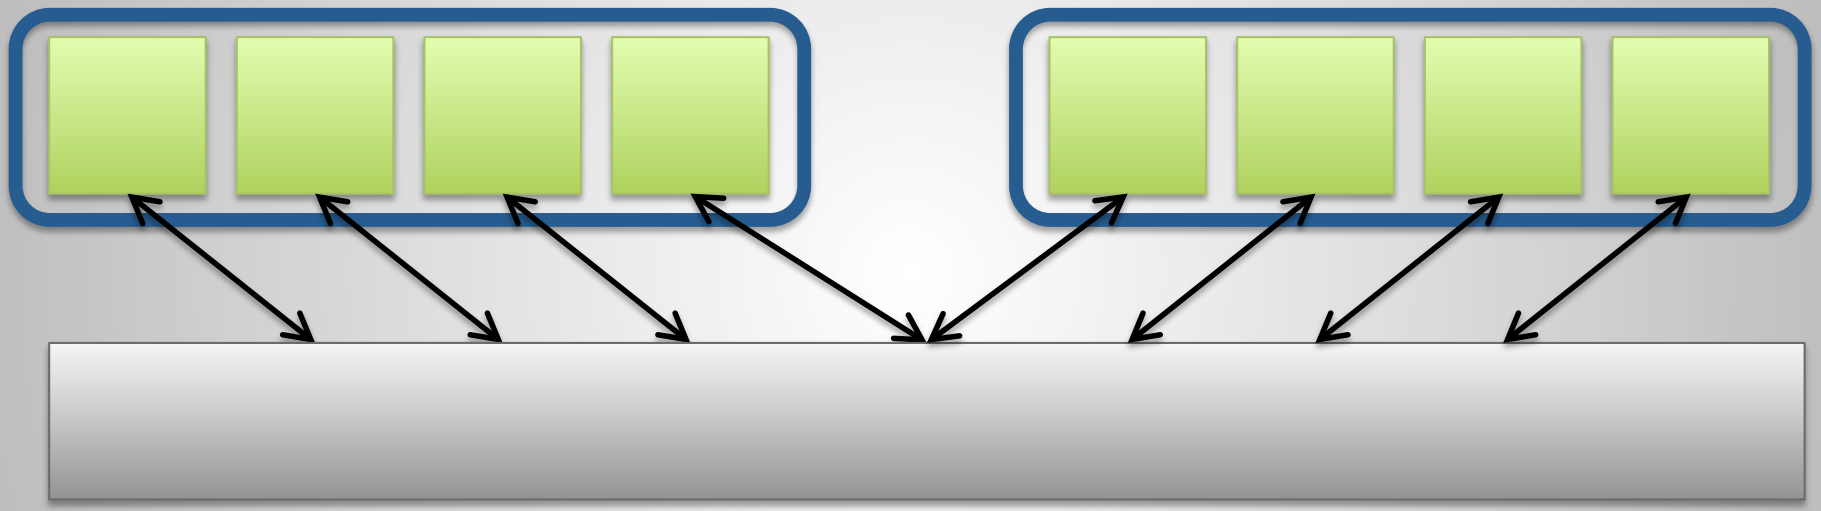

- Compartilhada por todos os itens de trabalho
- Leitura e Escrita

Modelo de memória

Arquitetura OpenCL

Memória constante

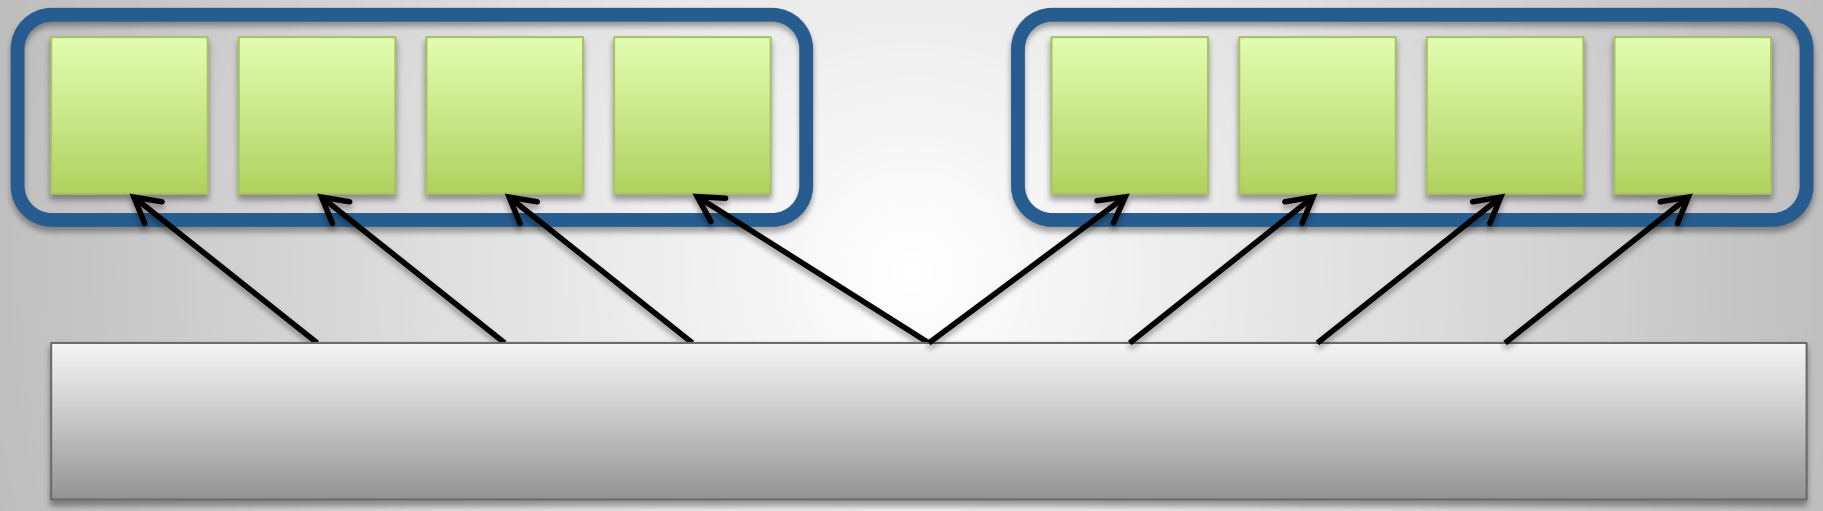

- Compartilhada por todos os itens de trabalho
- Somente leitura

Modelo de memória

Arquitetura OpenCL

- Modelo de memória: consistência
  - Um item de trabalho lê corretamente o que outros escrevem?

Arquitetura OpenCL

- Memória é consistente para um item de trabalho

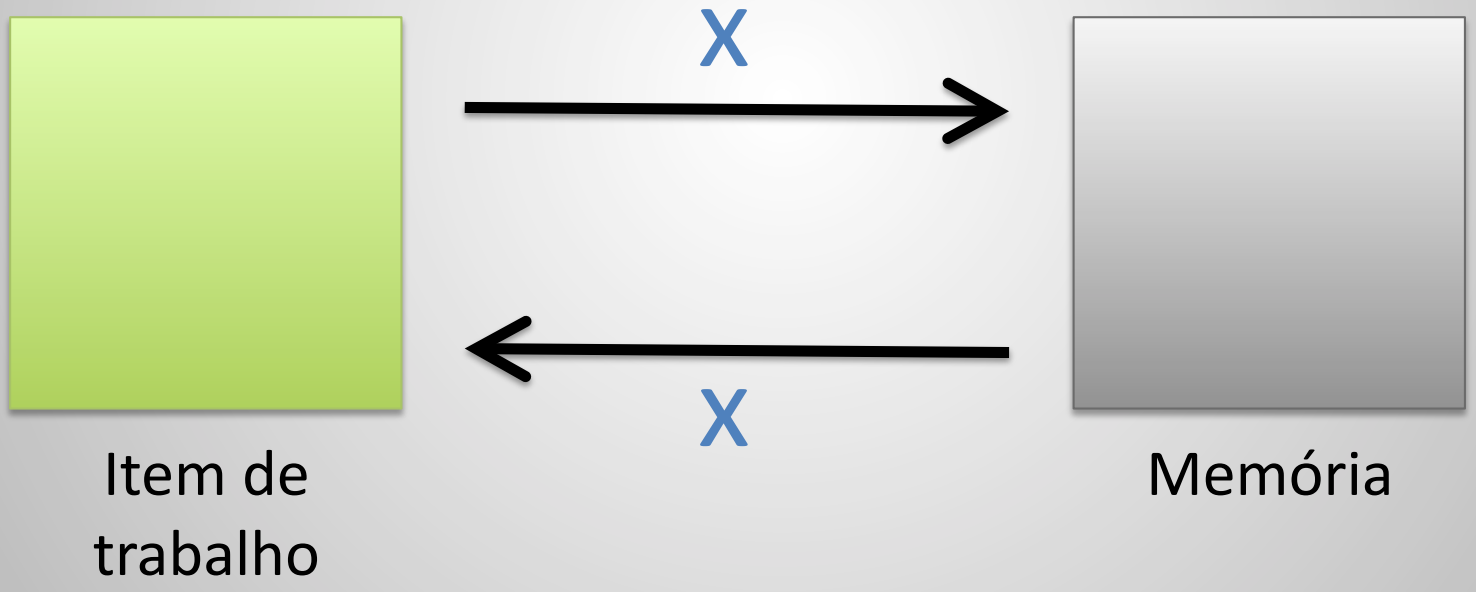

Modelo de memória: consistência

Arquitetura OpenCL

- Memória é consistente para um grupo de trabalho **após uma barreira (*barrier*)**

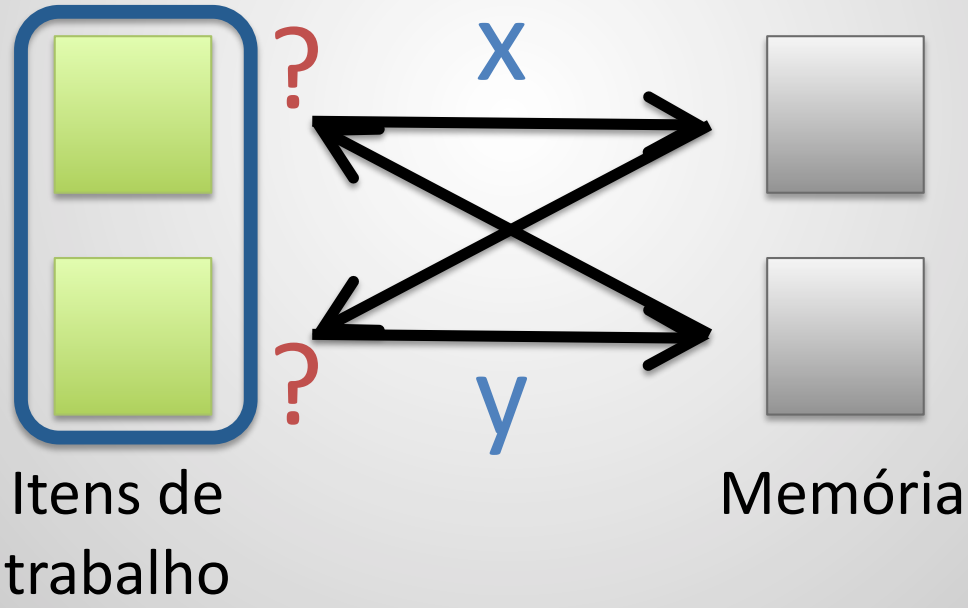

Modelo de memória: consistência

Arquitetura OpenCL

- Memória é consistente para um grupo de trabalho **após uma barreira (*barrier*)**

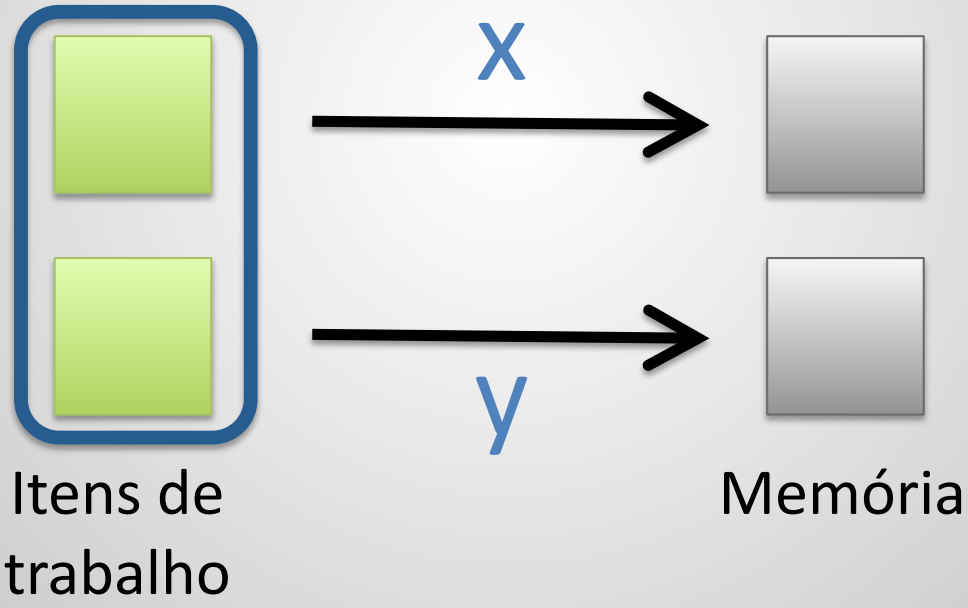

Modelo de memória: consistência

Arquitetura OpenCL

- Memória é consistente para um grupo de trabalho **após uma barreira (*barrier*)**

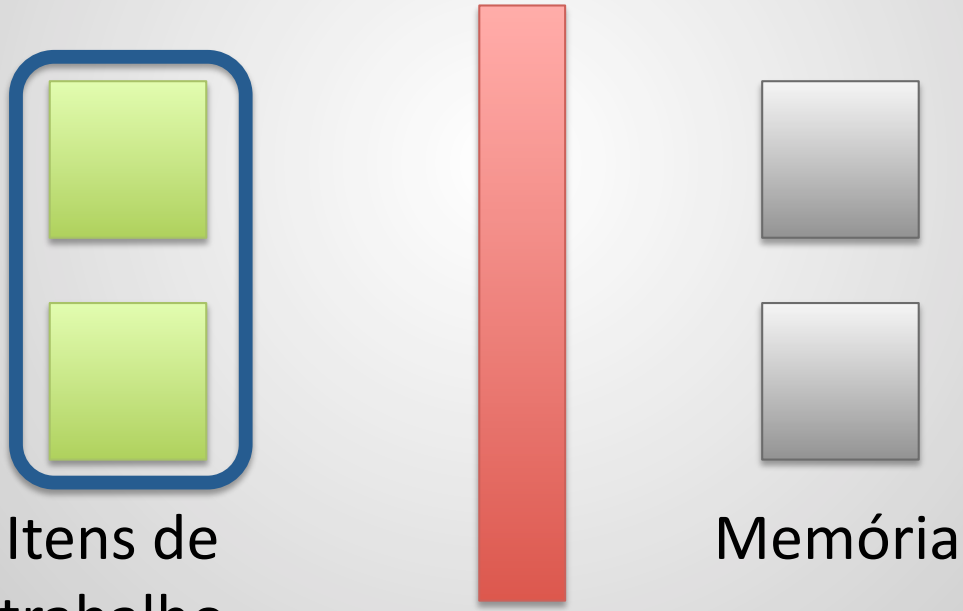

Modelo de memória: consistência

Arquitetura OpenCL

- Memória é consistente para um grupo de trabalho **após uma barreira (*barrier*)**

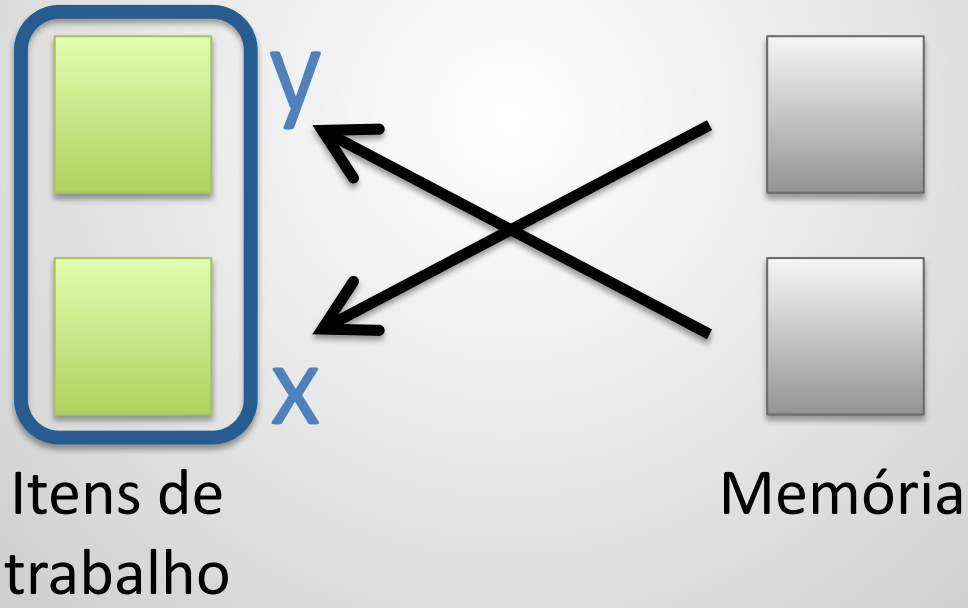

Modelo de memória: consistência

Arquitetura OpenCL

- Sincronização
  - Barreira: execução só prossegue após todos os itens de trabalho de um mesmo grupo de trabalho a terem atingido
  - **Não há sincronização entre grupos de trabalho**

Linguagem OpenCL C

- Utilizada para a escrita de *kernels*
- Baseada no padrão C99
- Acrescenta extensões e restrições

Linguagem OpenCL C

- Extensão: tipos vetoriais
  - Notação: `tipo[# de componentes]`
  - 1, 2, 4, 8 ou 16 componentes
  - Exemplos:

```
float4
int8
short2
uchar16
```

Linguagem OpenCL C

- Operações com tipos vetoriais
  - Entre vetores de mesmo número de componentes
  - Entre vetores e escalares

```
float4 v = (float4)(1.0, 2.0, 3.0, 4.0);
float4 u = (float4)(1.0, 1.0, 1.0, 1.0);
float4 v2 = v * 2;
float4 t = v + u;
```

Linguagem OpenCL C

- Definição de *kernels*
  - Qualificador `__kernel`
  - Todo *kernel* deve ser `void`

```
__kernel void f(…)
{
    ...
}
```

Linguagem OpenCL C

- Qualificadores de espaço de endereçamento
  - Definem nível da memória apontada por um ponteiro
  - `__global`, `__local`, `__private` e `__const`
  - *Default*: `__private`

Linguagem OpenCL C

- Restrições
  - Ponteiros para função não são suportados
  - Funções e macros com número variável de argumentos não são suportados
  - Qualificadores `extern`, `static` e `auto` não são suportados
  - Não há suporte a recursão

API de suporte: *kernels*

- Funções de identificação
  - Informações sobre espaço de índices, item e grupo de trabalho

```
get_global_id(uint dimindx)
get_local_id(uint dimindx)
get_group_id(uint dimindx)
get_global_size(uint dimindx)
get_local_size(uint dimindx)
get_num_groups()
get_work_dim()
```

API de suporte: *kernels*

- Funções de sincronização

  ```
  barrier(cl_mem_fence_flags flags)
  ```

  Flags:

  ```
  CLK_LOCAL_MEM_FENCE
  CLK_GLOBAL_MEM_FENCE
  ```

API de suporte: hospedeiro

- Ilustração através de um exemplo prático
- Aplicação completa
  - *Kernel* para subtração dos elementos de dois *arrays*

Exemplo prático

- Exemplo de código executado no hospedeiro
  - Ilustra as principais etapas para o desenvolvimento de soluções OpenCL
  - Multi-plataforma

Exemplo prático

```
#ifdef __APPLE__
#include <OpenCL/opencl.h>
#else
#include <CL/opencl.h>
#endif
```

Exemplo prático

```
cl_platform_id platformId;
cl_device_id deviceId;

clGetPlatformIDs(1, &platformId, NULL);

clGetDeviceIDs(
    platformId,
    CL_DEVICE_TYPE_GPU, 1, &deviceId,
    NULL);
```

Exemplo prático

```
cl_context context =
  clCreateContext(
     NULL, 1, &deviceId,
     NULL, NULL, NULL);

cl_command_queue queue =
     clCreateCommandQueue(
          context, deviceId,
          NULL, NULL);
```

Exemplo prático

```
const char* source =
    "__kernel void ArrayDiff( \
        __global const int* a, \
        __global const int* b, \
        __global int* c) \
    { \
        int id = get_global_id(0);\
        c[id] = a[id] - b[id]; \
    }";
```

Exemplo prático

```
cl_program program =
    clCreateProgramWithSource(
        context,
        1, &source,
        NULL, NULL);
```

Exemplo prático

```
clBuildProgram(
    program,
    0, NULL, NULL, NULL, NULL);

cl_kernel kernel =
    clCreateKernel(
        program,"ArrayDiff",
        NULL);
```

Exemplo prático

```
#define N ...

cl_mem bufA = clCreateBuffer(
    context,
    CL_MEM_READ_ONLY,
    N * sizeof(int),
    NULL, NULL);

cl_mem bufB = ...;
cl_mem bufC = ...;
```

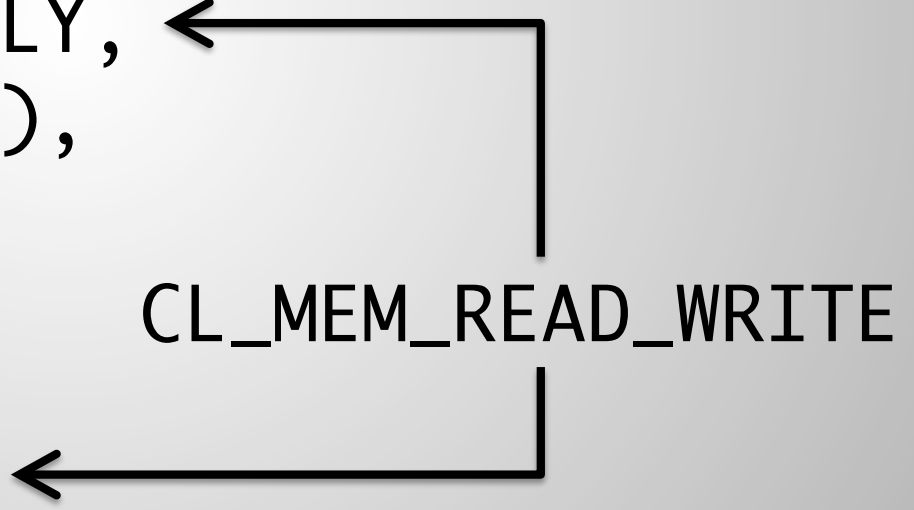

Exemplo prático

```
int* hostA;

clEnqueueWriteBuffer(
    queue,
    bufA,
    CL_TRUE,
    0,
    N * sizeof(int),
    hostA,
    0, NULL, NULL);
```

Exemplo prático

```
int* hostB;

clEnqueueWriteBuffer(
    queue,
    bufB,
    CL_TRUE,
    0,
    N * sizeof(int),
    hostB,
    0, NULL, NULL);
```

Exemplo prático

```
clSetKernelArg(
    kernel, 0,
    sizeof(cl_mem), &bufA);
clSetKernelArg(
    kernel, 1,
    sizeof(cl_mem), &bufB);
clSetKernelArg(
    kernel, 2,
    sizeof(cl_mem), &bufC);
```

Exemplo prático

```
const size_t globalSize[] =
    { N };

clEnqueueNDRangeKernel(
    queue, kernel,
    1, NULL, globalSize, NULL,
    0, NULL, NULL);

clFinish(queue);
```

Exemplo prático

```
int* hostC;

clEnqueueReadBuffer(
    queue,
    bufC,
    CL_TRUE,
    0,
    N * sizeof(int),
    hostC,
    0, NULL, NULL);
```

Exemplo prático

```
clReleaseMemObject(bufC);
clReleaseMemObject(bufB);
clReleaseMemObject(bufA);
clReleaseKernel(kernel);
clReleaseProgram(program);
clReleaseCommandQueue(queue);
clReleaseContext(context);
```

Interoperação com OpenGL

- Em GPUs, é possível compartilhar estruturas entre OpenCL e OpenGL
- Exemplo prático: malha tridimensional
  - Vértices posicionados via OpenCL
  - Exibição via OpenGL
  - Compartilhamento de Vertex Buffer Object (VBO)
    - OpenCL: *array* de float4

Interoperação com OpenGL

- Demonstração

Interoperação com OpenGL

```
__kernel void sine_wave(
    __global float4* pos,
    unsigned int width,
     unsigned int height,
    float time)
{
    unsigned int x = get_global_id(0);
    unsigned int y = get_global_id(1);
```

Kernel

Interoperação com OpenGL

```
    float u = x / (float) width;
    float v = y / (float) height;
    u = u*2.0f - 1.0f;
    v = v*2.0f - 1.0f;

    float freq = 4.0f;
    float w = sin(u * freq + time) *
              cos(v * freq + time) * 0.5f;

    pos[y * width + x] =
        (float4)(u, w, v, 1.0f);
}
```

```
cl_context_properties props[] = {
  CL_GL_CONTEXT_KHR,
  (cl_context_properties) wglGetCurrentContext(),
  CL_WGL_HDC_KHR,
  (cl_context_properties) wglGetCurrentDC(),
  CL_CONTEXT_PLATFORM,
  (cl_context_properties) platformId,
  0
};

context = clCreateContext(
      props, 1, &deviceId, NULL, NULL, NULL);
```

Criação do contexto

Interoperação com OpenGL

```
#define BUFFER_SIZE ...

GLuint vbo;

glGenBuffers(1, &vbo);
glBindBuffer(GL_ARRAY_BUFFER, vbo);
glBufferData(
    GL_ARRAY_BUFFER, BUFFER_SIZE, 0,
    GL_DYNAMIC_DRAW);
```

Criação do VBO

Interoperação com OpenGL

```
cl_mem vbo_cl;

vbo_cl = clCreateFromGLBuffer(
    context,
    CL_MEM_WRITE_ONLY,
    vbo,
    NULL);
```

Criação do objeto de memória a partir do VBO

Interoperação com OpenGL

```
clEnqueueAcquireGLObjects(
      queue,
      1,
      &vbo_cl,
      NULL,
      NULL,
      NULL);
```

Aquisição do VBO

Interoperação com OpenGL

```
size_t globalSize[] =
    { MESH_WIDTH, MESH_HEIGHT };

clEnqueueNDRangeKernel(
    queue, kernel, 2,
    NULL, globalSize, NULL,
    0, 0, 0);

clFinish(queue);
```

Execução do *kernel*

Interoperação com OpenGL

```
clEnqueueReleaseGLObjects(
    queue,
    1,
    &vbo_cl,
    NULL,
    NULL,
    NULL);
```

Liberação do VBO

Considerações finais

- NVIDIA e ATI suportam
- ATI adotou OpenCL como linguagem oficial do Streaming SDK
- Rumores de suporte a OpenCL em chips gráficos para dispositivos móveis
- Aplicações em jogos: IA, física

Considerações finais

- Material disponível em

http://labs.v3d.com.br/

Obrigado pela atenção!

Dúvidas?