

UF I5AISE51

Dimensionnement et évaluation des architectures
Introduction à la programmation massivement parallèle

Partie 3
Kernel à plusieurs dimensions

P.-E. Hladik

INSA Toulouse

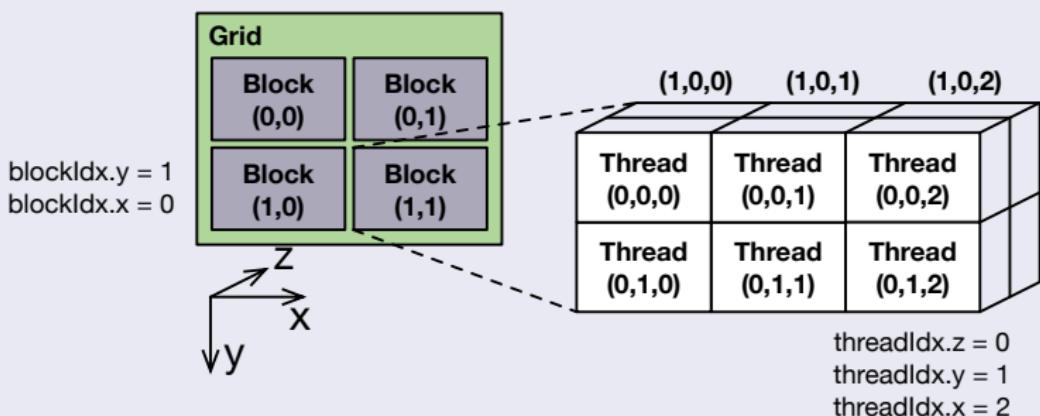
4 janvier 2021

Plan

- 1 Introduction à la programmation parallèle
- 2 Allocation des données et exécution d'un kernel
- 3 Kernel à plusieurs dimensions

blockIdx et threadIdx

- les index de block et de thread sont des variables à trois dimensions
- cela simplifie les adresses mémoires quand on travaille avec des données multidimensionnelles (image, volumes, etc.)



Exemple : niveau de gris pour une image en 2D



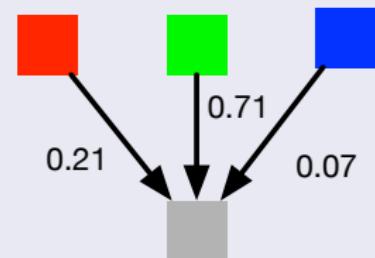
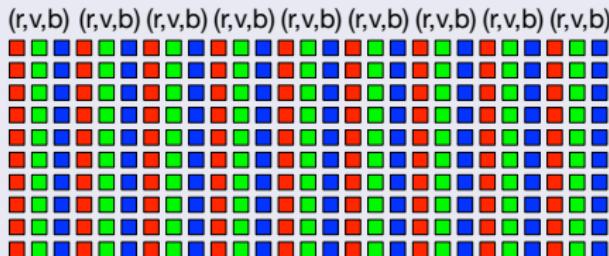
pictures : 39x26 pixels

Représentation RVB d'une image et niveau de gris

- Pour chaque pixel (r, v, b) en position (i, j) :

$$\text{grayPixel}[i, j] = 0.21 \times r + 0.71 \times v + 0.07 \times b$$

- C'est l'équivalent du produit scalaire $(r, v, b) \cdot (0.21, 0.71, 0.07)$ avec des constantes spécifiques à l'espace RVB



Row-Major Order en C/C++

Row-major order

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

[0,0]	[0,1]	[0,2]	[0,3]
[1,0]	[1,1]	[1,2]	[1,3]
[2,0]	[2,1]	[2,2]	[2,3]

Column-major order

$$\begin{bmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{bmatrix}$$

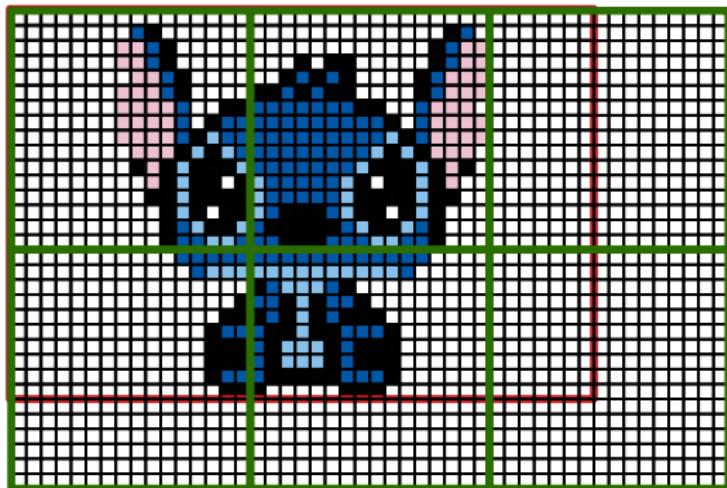
[0,0]	[0,1]	[0,2]	[0,3]	[1,0]	[1,1]	[1,2]	[1,3]	[2,0]	[2,1]	[2,2]	[2,3]
[0]	[1]	[2]	[3]	[4]	[5]	[6]	[7]	[8]	[9]	[10]	[11]

$$\text{Row} * \text{Width} + \text{Col} = 1 * 4 + 3$$

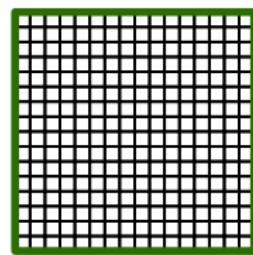
Pseudo-algo CPU

```
for ii from 0 to height do
    for jj from 0 to width do
        idx = ii * width + jj
        r = input[3*idx]
        g = input[3*idx + 1]
        b = input[3*idx + 2]
        grayImage[idx] = (0.21*r + 0.71*g + 0.07*b)
    end
end
```

Création de la *grid*



grid : 3x2 blocks



block : 16x16 threads

Kernel

```
#define CHANNELS 3 // we have 3 channels corresponding to RGB
// The input image is encoded as unsigned characters [0, 255]
__global__
void colorConvert(unsigned char * grayImage,
                  unsigned char * rgbImage,
                  int width, int height) {
    int x = threadIdx.x + blockIdx.x * blockDim.x; // Col
    int y = threadIdx.y + blockIdx.y * blockDim.y; // Row

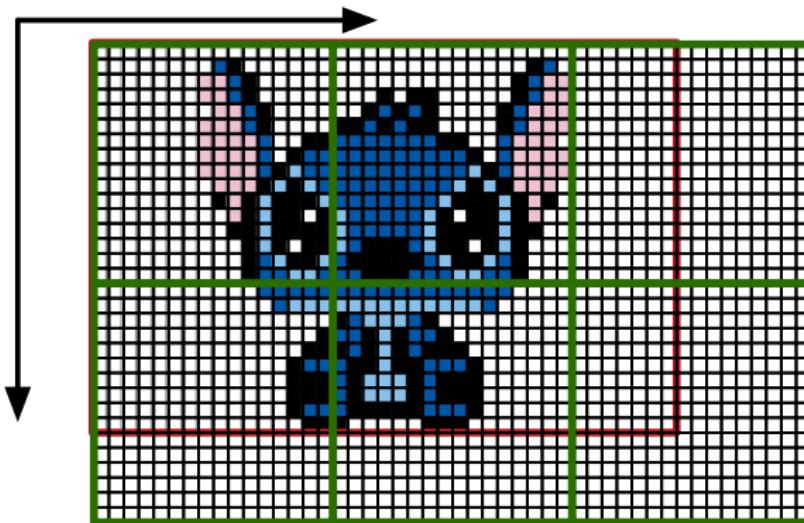
    if (x < width && y < height) {
        // get 1D coordinate for the grayscale image
        int grayOffset = y*width + x;

        // one can think of the RGB image having
        // CHANNEL times columns than the gray scale image
        int rgbOffset = grayOffset*CHANNELS;
        unsigned char r = rgbImage[rgbOffset]; // red value for pixel
        unsigned char g = rgbImage[rgbOffset + 2]; // green value for pixel
        unsigned char b = rgbImage[rgbOffset + 3]; // blue value for pixel

        // perform the rescaling and store it
        // We multiply by floating point constants
        grayImage[grayOffset] = 0.21f*r + 0.71f*g + 0.07f*b;
    }
}
```

Création de la *grid*

```
int y = threadIdx.y + blockIdx.y * blockDim.y;
```



```
int x = threadIdx.x + blockIdx.x * blockDim.x;
```

Code de l'*host* pour lancer l'exécution

```
// assume that the picture is m X n,
// m pixels in y dimension and n pixels in x dimension
// input d_Pin has been allocated on and copied to device
// output d_Pout has been allocated on device
...
dim3 DimGrid((n-1)/16 + 1, (m-1)/16+1, 1);
dim3 DimBlock(16, 16, 1);
colorConvert<<<DimGrid,DimBlock>>>(grayImage, rgbImage, width, height);
...
```

Couverture de l'image par les blocs

Tous les threads dans un bloc n'ont pas le même chemin dans leur flot de contrôle.

