Programación masivamente paralela en procesadores gráficos (GPUs)

E. Dufrechou , M. Freire, P. Ezzatti y M. Pedemonte

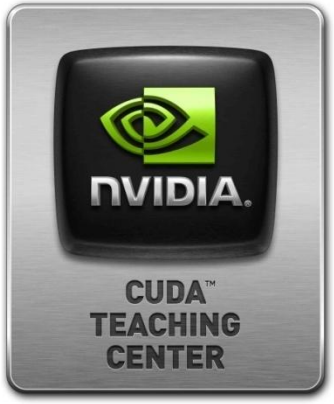

Clase 8
Patrones de cómputo 2

Contenido

- **Stencil**
  - **Tiling**
  - **Padding**
  - **Memoria constante y caché**
- **Scan**

Stencil

Stencil

- Se caracteriza por actualizar los elementos de una grilla de acuerdo a un patrón fijo conocido a priori (stencil - plantilla).
- Suelen usarse en métodos iterativos por lo que se realiza una secuencia de actualizaciones sobre la grilla.
- En general, la grilla suele ser de 2 o 3 dimensiones.
- En cada paso de tiempo, se actualizan todos los elementos de la grilla.
- Para calcular el nuevo valor de cada celda de la grilla, se utilizan los elementos adyacentes de la matriz usando un patrón regular de cómputo.

Stencil

- **Este tipo de patrón de cómputo es común en la resolución de ecuaciones diferenciales en derivadas parciales, autómatas celulares, el método Gauss-Seidel, procesamiento de imágenes.**

- **Un ejemplo conocido: El juego de la vida (Game of life)**

https://youtu.be/C2vgICfQawE

Stencil

- **Convolución:**
  - **Se usa ampliamente en el procesamiento de audio, imágenes y video.**
  - **En general se utilizan como un filtro que transforma los valores de los pixeles.**
  - **Se pueden definir como una operación matricial en la que cada elemento de la salida es una suma ponderada de un subconjunto de los elementos de entrada vecinos.**
  - **Los pesos usados en el cálculo de la suma ponderada se definen a través de máscaras.**

Stencil

- Ejemplo de convolución 1D
- Se suelen usar para procesamiento de audio.
- Las máscaras suelen tener largo impar por simetría.

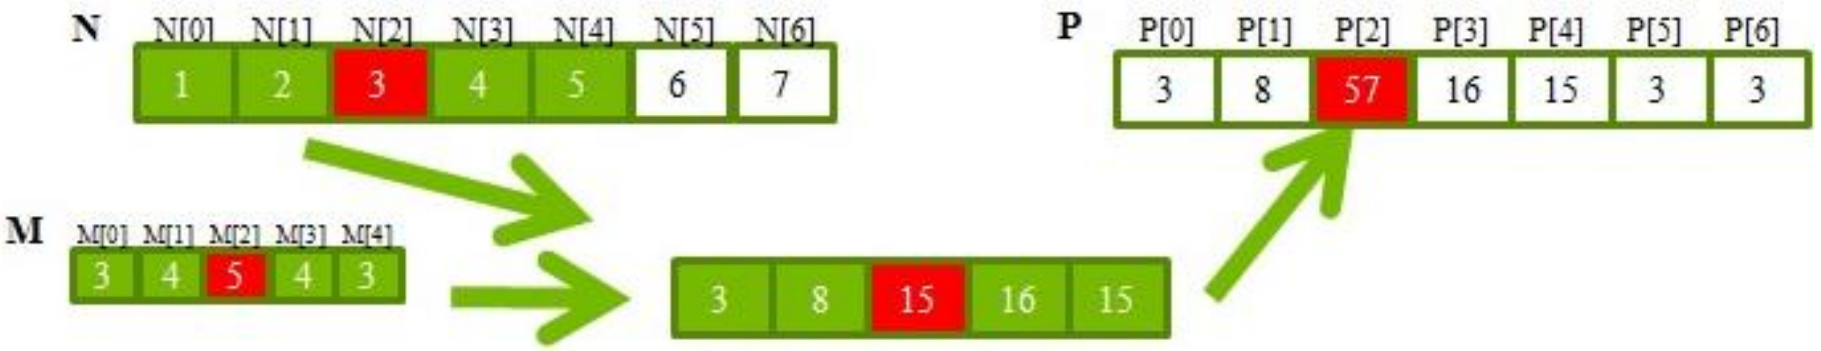

$$P[2] = N[0]*M[0] + N[1]*M[1] + N[2]*M[2] + N[3]*M[3] + N[4]*M[4]$$

Stencil

- **Ejemplo de convolución 1D**

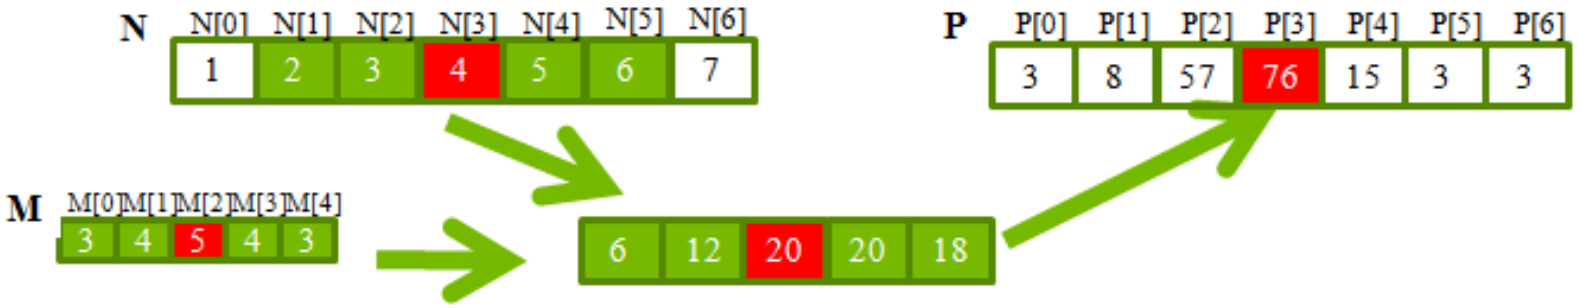

Stencil

- **Ejemplo de convolución 1D**

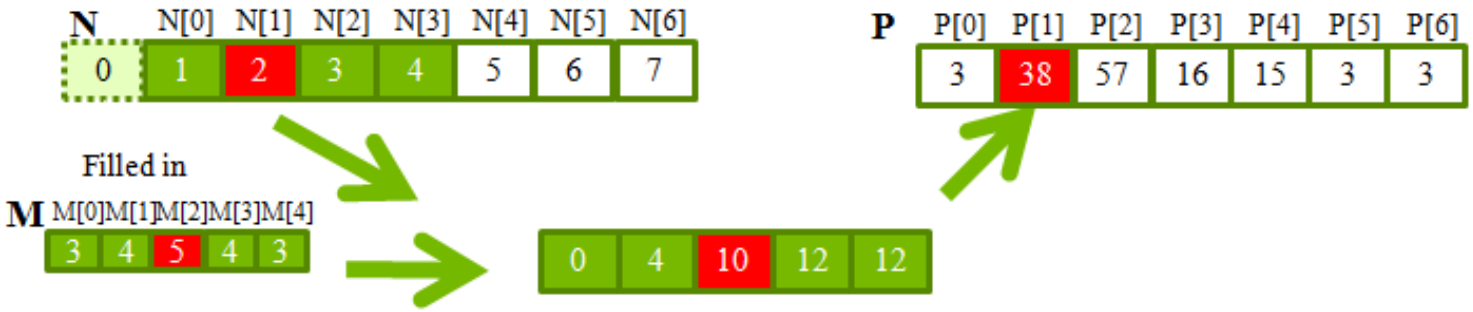

- **En los bordes hay que hacer correcciones: agregar 0s, repetir los valores del borde, etc.**
- **Para "agregar 0s" basta con poner un if dentro del loop que calcula el nuevo valor.**

Stencil

- **Ejemplo de convolución 1D**

```
 __global__ void convolution_1D_basic_kernel(float *N, float *M,
        float *P, int Mask_Width, int Width)
{
    int i = blockIdx.x*blockDim.x + threadIdx.x;

    float Pvalue = 0;
    int N_start_point = i - (Mask_Width/2);

    for (int j = 0; j < Mask_Width; j++) {
        if (N_start_point + j >= 0 && N_start_point + j < Width) {
            Pvalue += N[N_start_point + j]*M[j];
        }
    }

    P[i] = Pvalue;
}
```

Stencil

- **Ejemplo de convolución 2D**

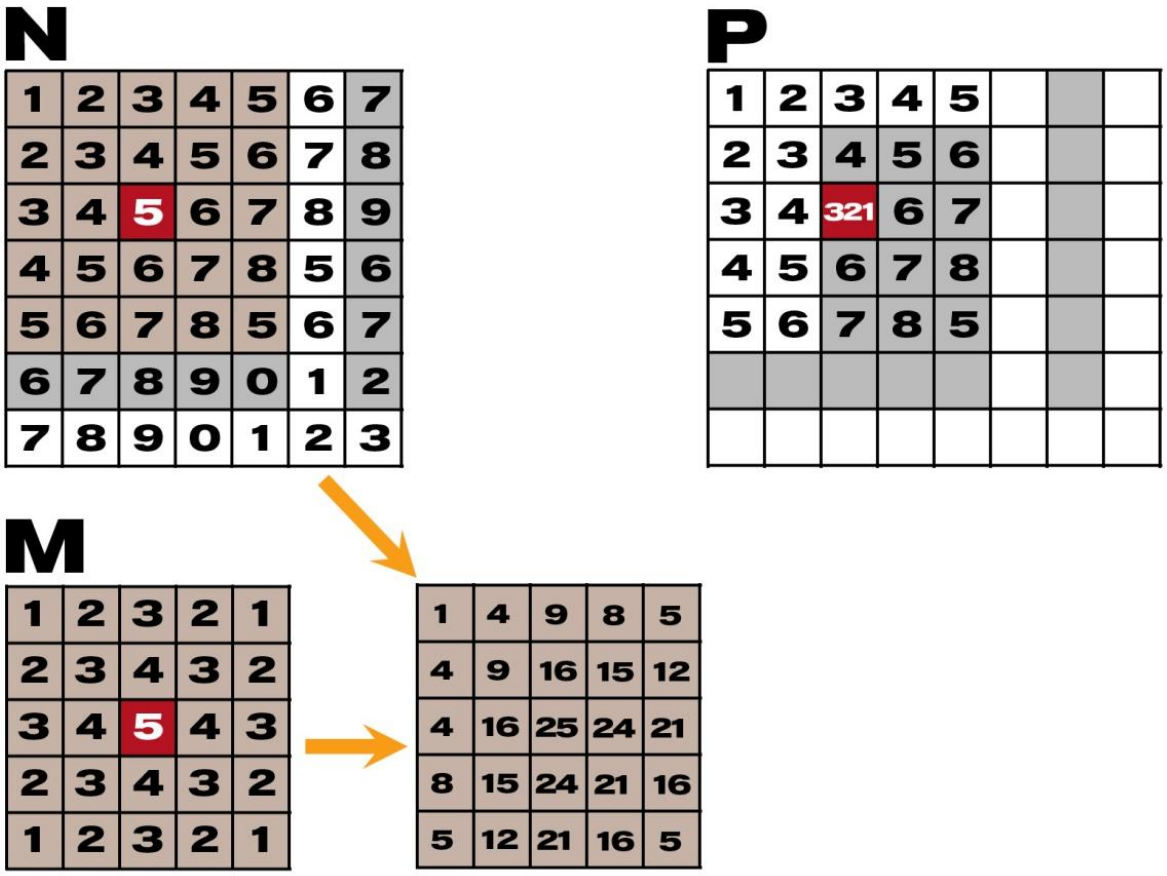

Stencil

- **Ejemplo de convolución 2D**

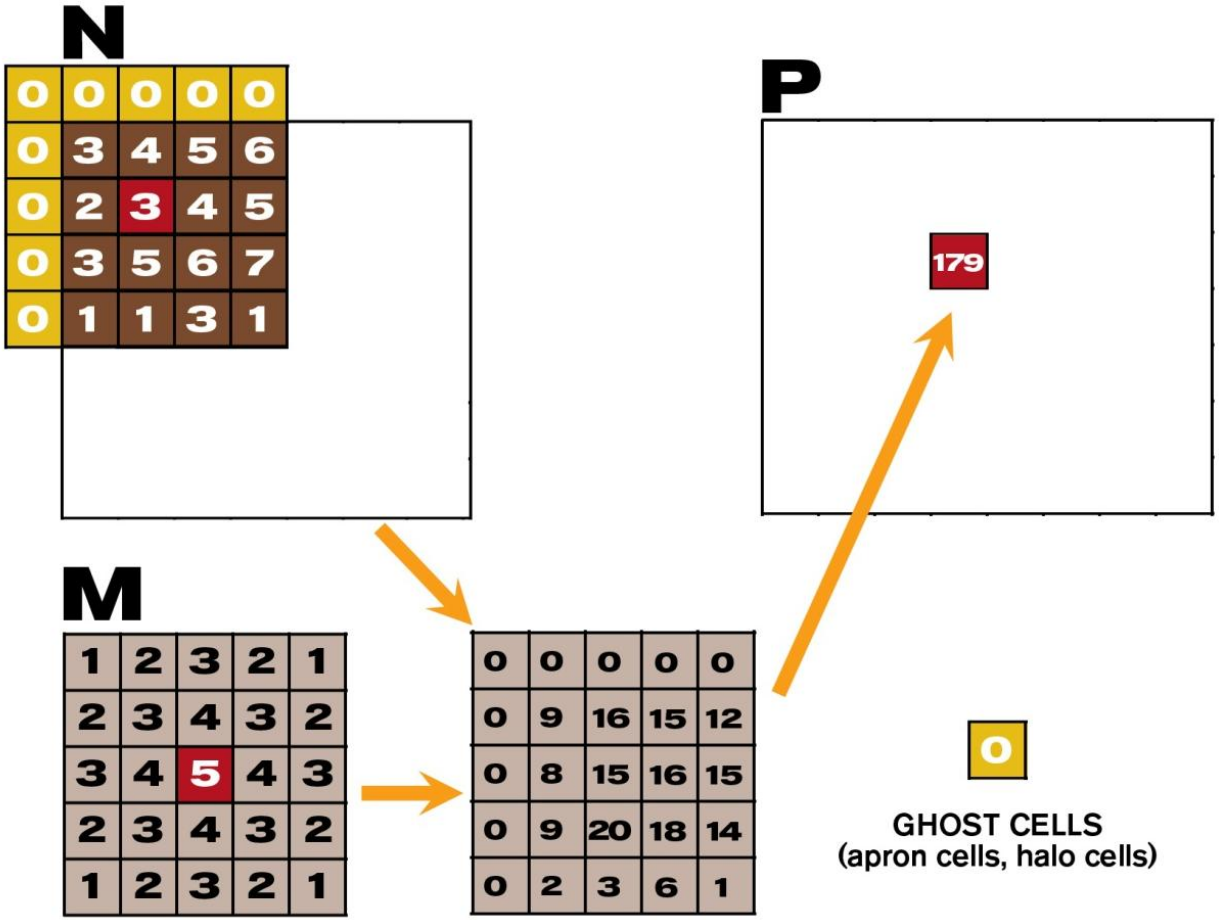

Stencil

- El cálculo de elementos de salida adyacente involucra el uso de elementos de entrada comunes.
- N[2] se usa en el cálculo de P[0], P[1], P[2], P[3] y P[4].
- Se pueden cargar los elementos necesarios para la ejecución de todos los hilos del bloque en memoria compartida para reducir el acceso a memoria global.

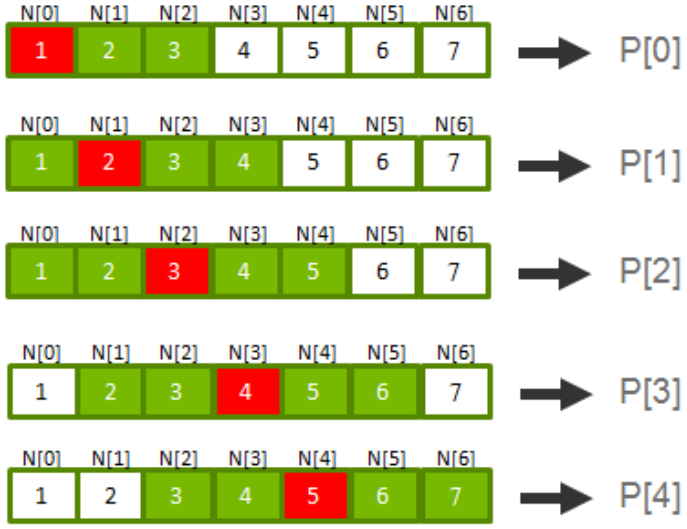

Stencil

- ¿Cuántos elementos se precisan?
- Si queremos que cada bloque calcule T elementos de salida:
  - T + Mask_Width -1 elementos se necesitan para T salidas.
  - T + Mask_Width -1 no es múltiplo de T (en general).
  - T suele ser mucho más grande que Mask_Width

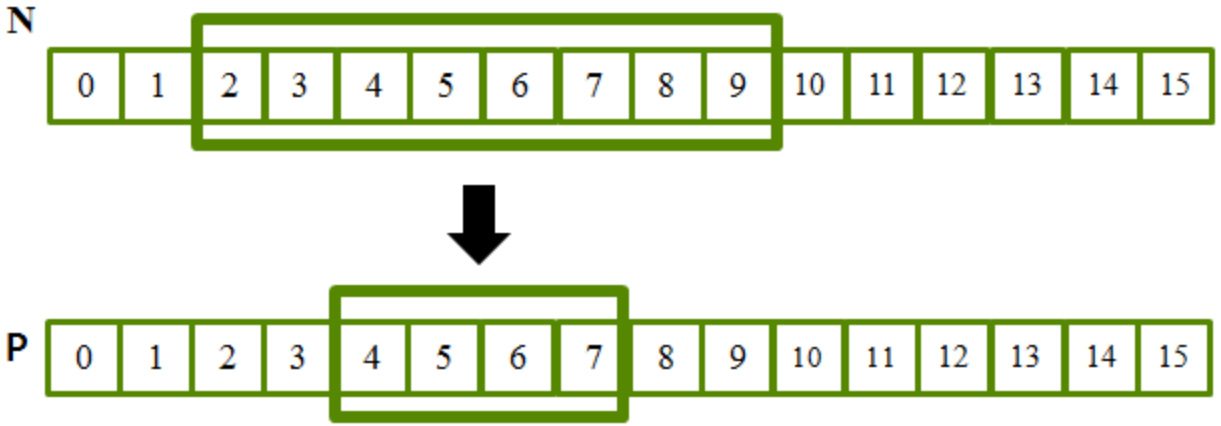

Stencil

- Cada bloque de hilos calcula un tile de salida
- Cada tile de salida tiene como ancho O_TILE_WIDTH

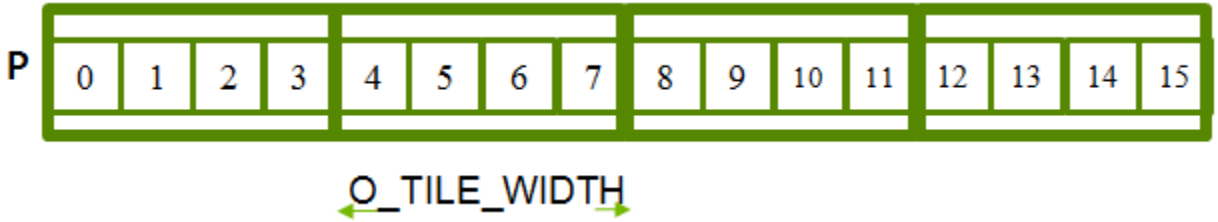

Stencil

- **Alternativas de diseño 1:**
  - **El tamaño de cada bloque de hilos coincide con el tamaño del tile de salida.**
  - **Todos los hilos participan en calcular elementos de la salida.**
  - **Algunos hilos tienen que cargar más de un elemento en memoria compartida.**
- **Alternativas de diseño 2:**
  - **El tamaño de cada bloque de hilos coincide con el tamaño del tile de entrada.**
  - **Algunos hilos no participan en calcular elementos de la salida.**
  - **Todos los hilos tienen que cargar un elemento en memoria compartida.**

Stencil

- **Padding en stencils 2D:**
  - **Es deseable en algunas oportunidades completar cada fila de la matriz 2D para que coincida con los segmentos de la memoria global.**
  - **Corresponde a agregar columnas.**

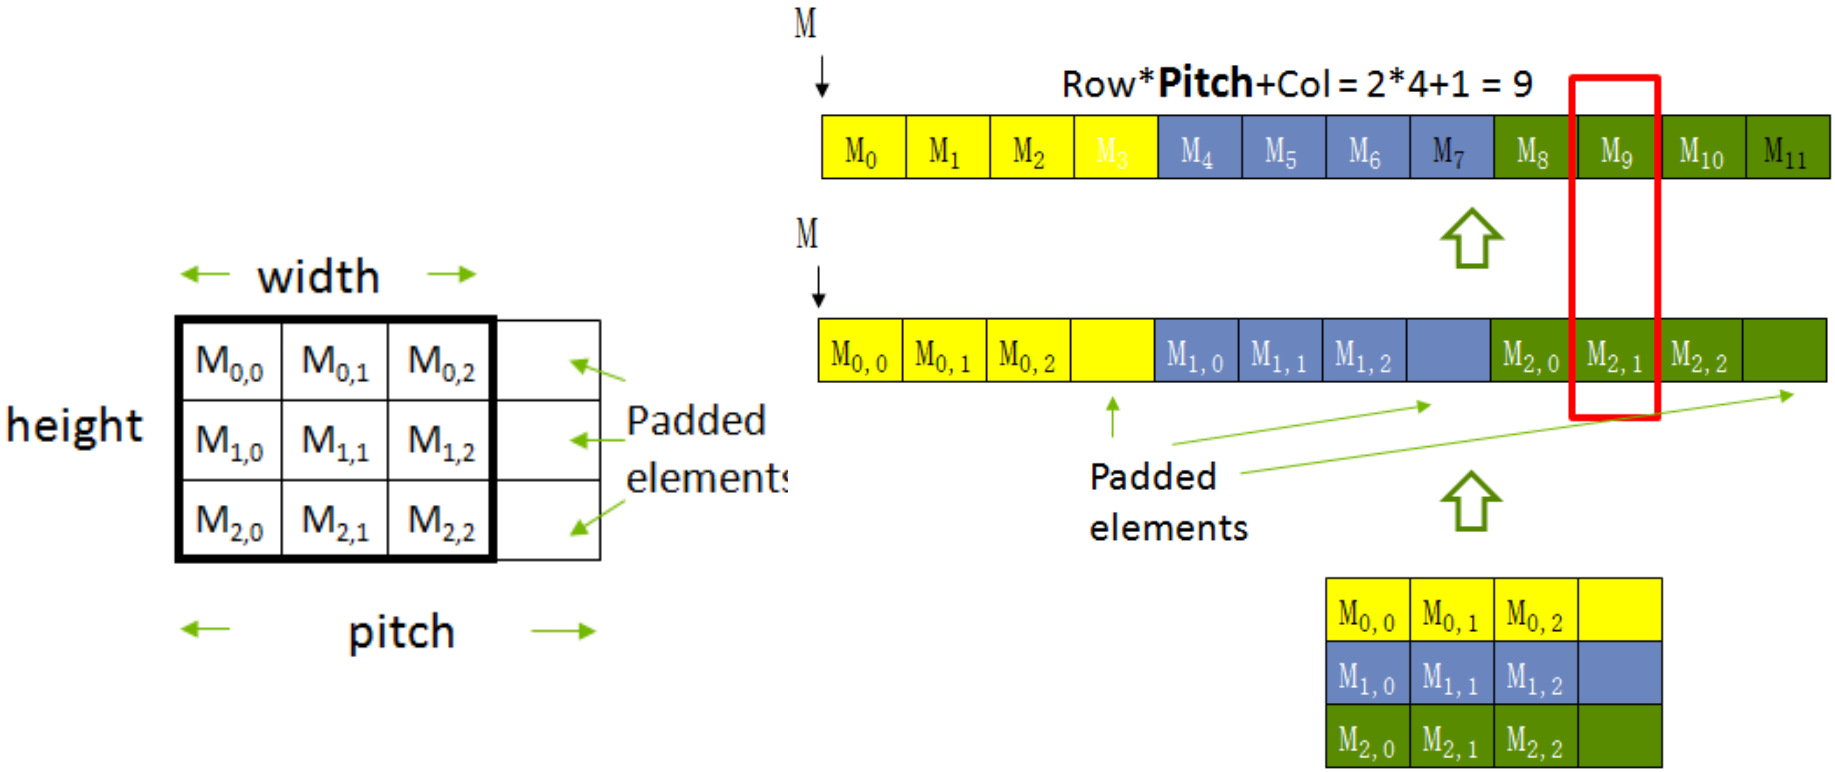

Stencil

- **Memoria constante y caché para la máscara:**
  - **La máscara es usada por todos los hilos pero no es modificada por la convolución.**
  - **Todos los hilos de un warp acceden a las mismas posiciones de la máscara en el mismo paso de tiempo.**
  - **La memoria constante utiliza fuertemente el caché de la GPU.**
  - **Es una forma efectiva de aumentar el ancho de banda real sin consumir shared memory.**
  - **Se puede indicar al compilador con `const __restrict__` que el parámetro que se usa para la máscara es elegible para ser cacheado en memoria constante.**

```
__global__ void convolution_2D_kernel(float *P,
      float *N, height, width, channels,
        const float __restrict__ *M) {
```

Scan

Scan

- **Es un algoritmo clave ya que permite convertir una estrategia cómputo secuencial en una paralela.**
- **Es un patrón de computación paralela de los más estudiados.**
- **Se puede implementar de forma eficiente en paralelo.**

Definición: La operación *scan* toma un operador binario (que tiene que ser asociativo) y un arreglo de *n* elementos $[x_0, x_1, \ldots, x_{n-1}]$ y devuelve el arreglo $[x_0, (x_0 \oplus x_1), \ldots, (x_0 \oplus x_1 \oplus \ldots \oplus x_{n-1})]$.

Ejemplo: Si $\oplus$ es la suma, aplicar la operación scan al arreglo [3 1 7 0 4 1 6 3] da como resultado [3 4 11 11 15 16 22 25].

Scan

- **Se busca convertir recurrencias secuenciales como:**

```
out[0] = in[0];

for(j=1;j<n;j++)
   out[j] = out[j-1] + f(in[j]);
```

- **En un cómputo paralelo como:**

```
forall(j) {
  temp[j] = f(in[j]);
}
scan(out, temp);
```

Scan

- Dada la secuencia [x0, x1, x2, ...] calcular [y0, y1, y2, ...] tal que:

  y0 = x0

  y1 = x0 + x1

  y2 = x0 + x1+ x2

- De forma secuencial se utiliza la definición recursiva $y_i = y_{i-1} + x_i$
- De forma paralela naïve se asigna un hilo a calcular cada elemento de y:
  - Cada hilo suma todos los elementos de x que se necesitan para el elemento y

    $y_0 = x_0$

    $y_1 = x_0 + x_1$

    $y_2 = x_0 + x_1 + x_2$
  - Obviamente que este enfoque es muy ineficiente.

Scan

- **Algoritmo paralelo:**
  - **Se leen los valores a memoria shared.**
  - **Se itera log(n) veces**
  - **El stride varía entre 1 y n-1, en cada iteración se dobla el stride.**

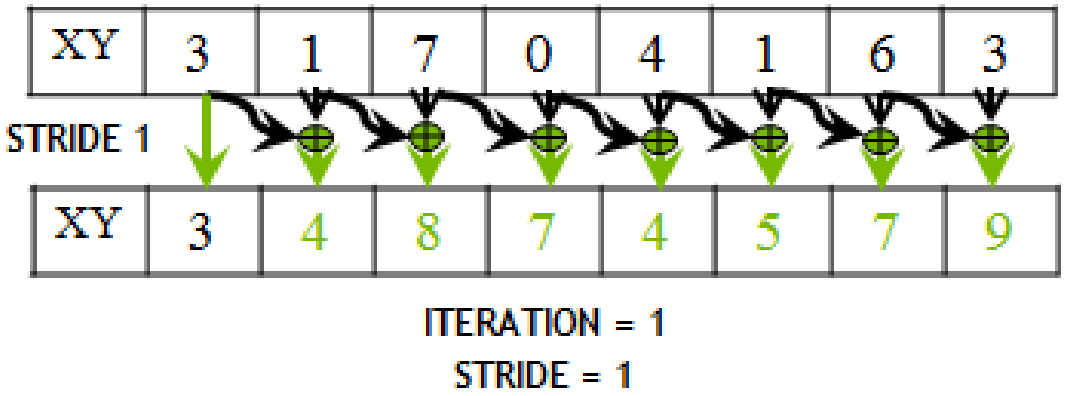

  - **Requiere usar barreras de sincronización antes de leer y antes de escribir.**

Scan

- **Algoritmo paralelo:**

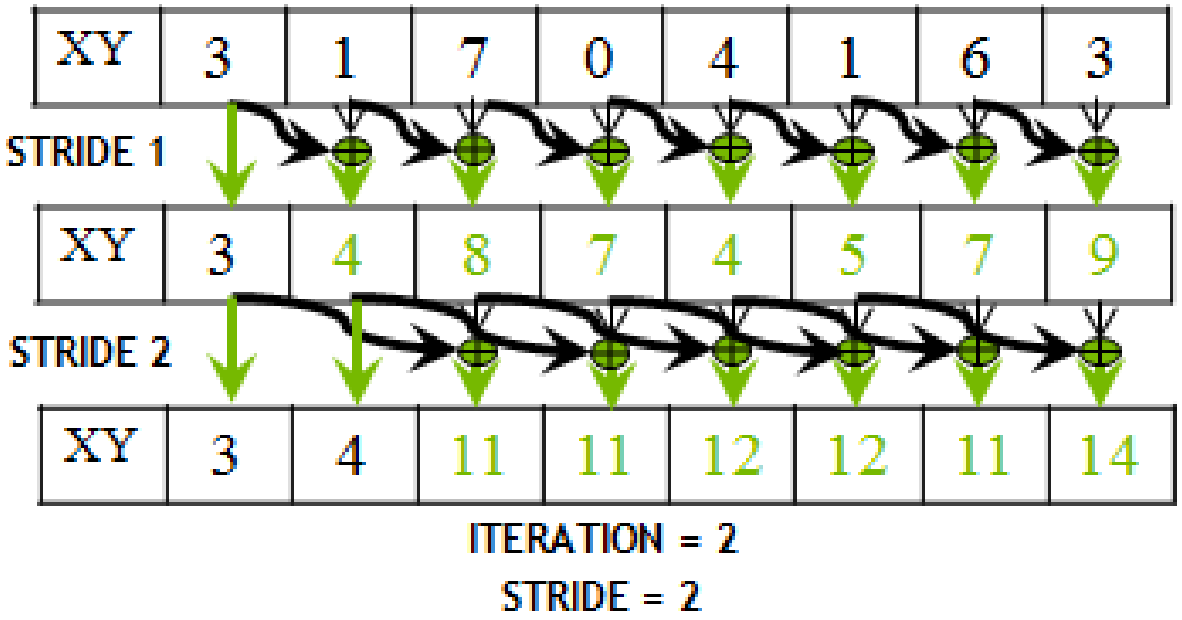

Scan

- **Algoritmo paralelo:**

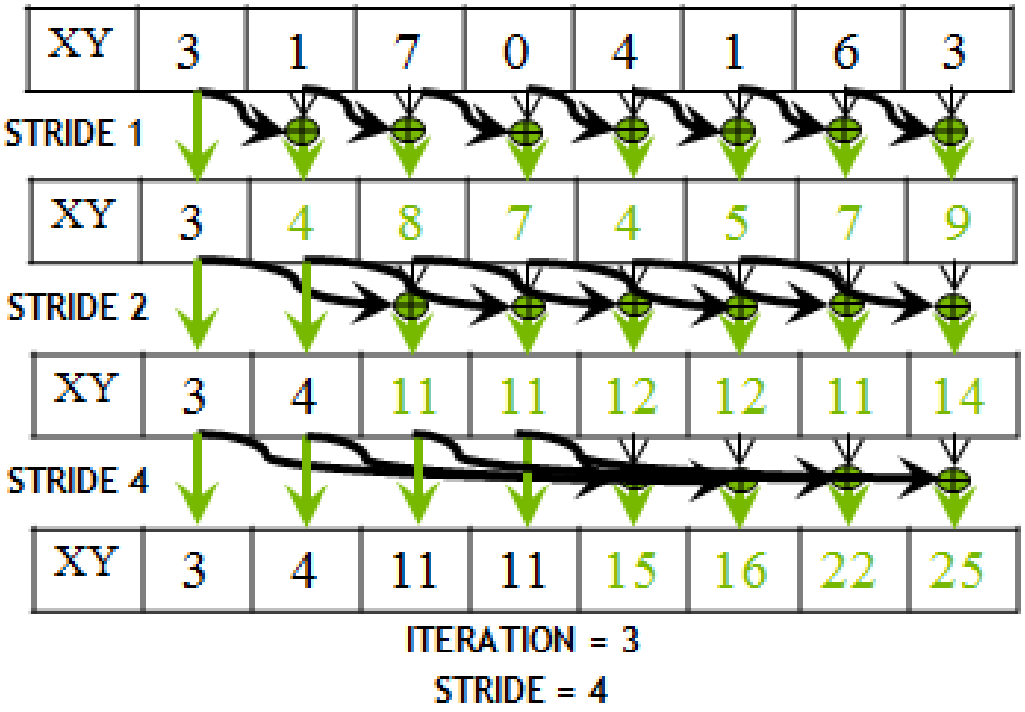

Scan

- Para mejorar la eficiencia se construye conceptualmente un árbol binario balanceado con los datos de entrada.
- Hay una primera etapa en la que se navega de las hojas a la raíz construyendo sumas parciales en los nodos internos del árbol.
- La raíz tiene como resultado la suma de todas las hojas.
- En una segunda etapa se navega en reversa para construir las salidas a partir de las sumas parciales.

Scan

- **Etapa de reducción:**

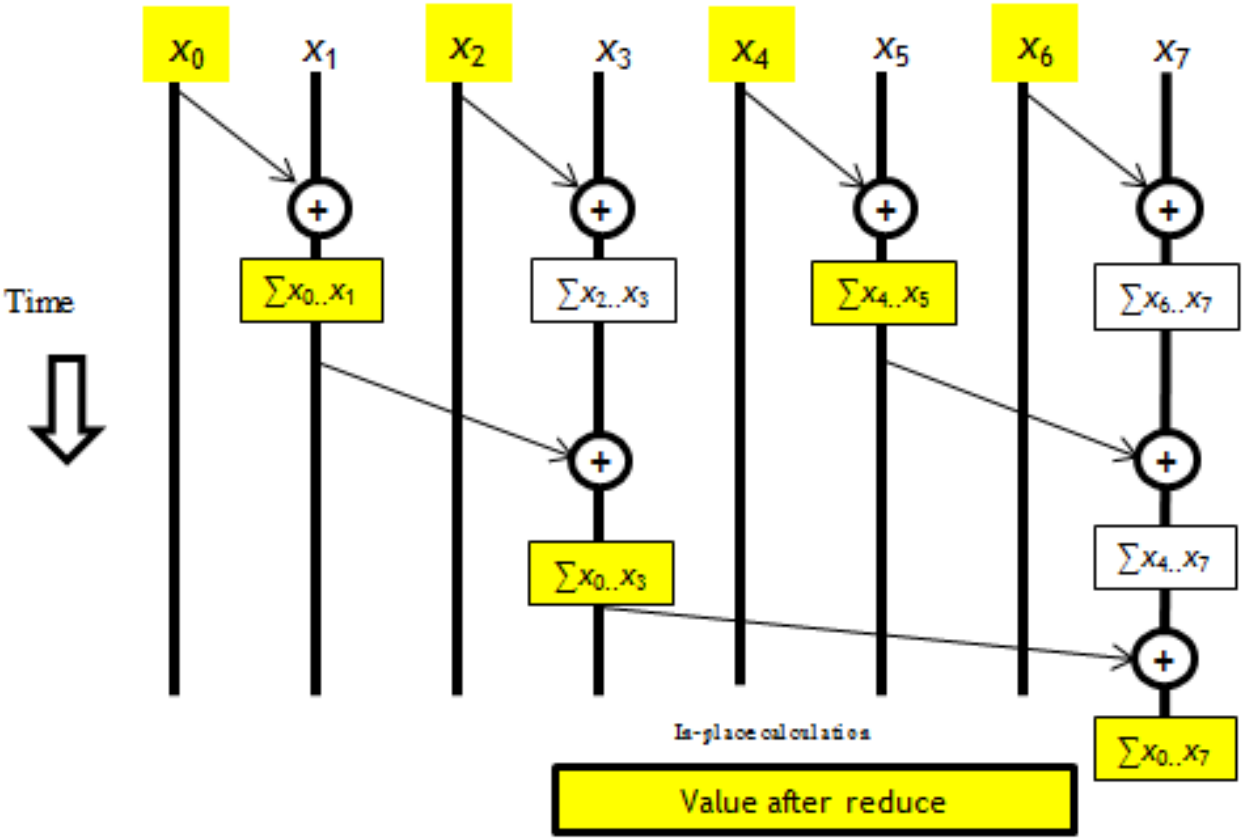

Scan

- **Fase reversa – post-reducción:**

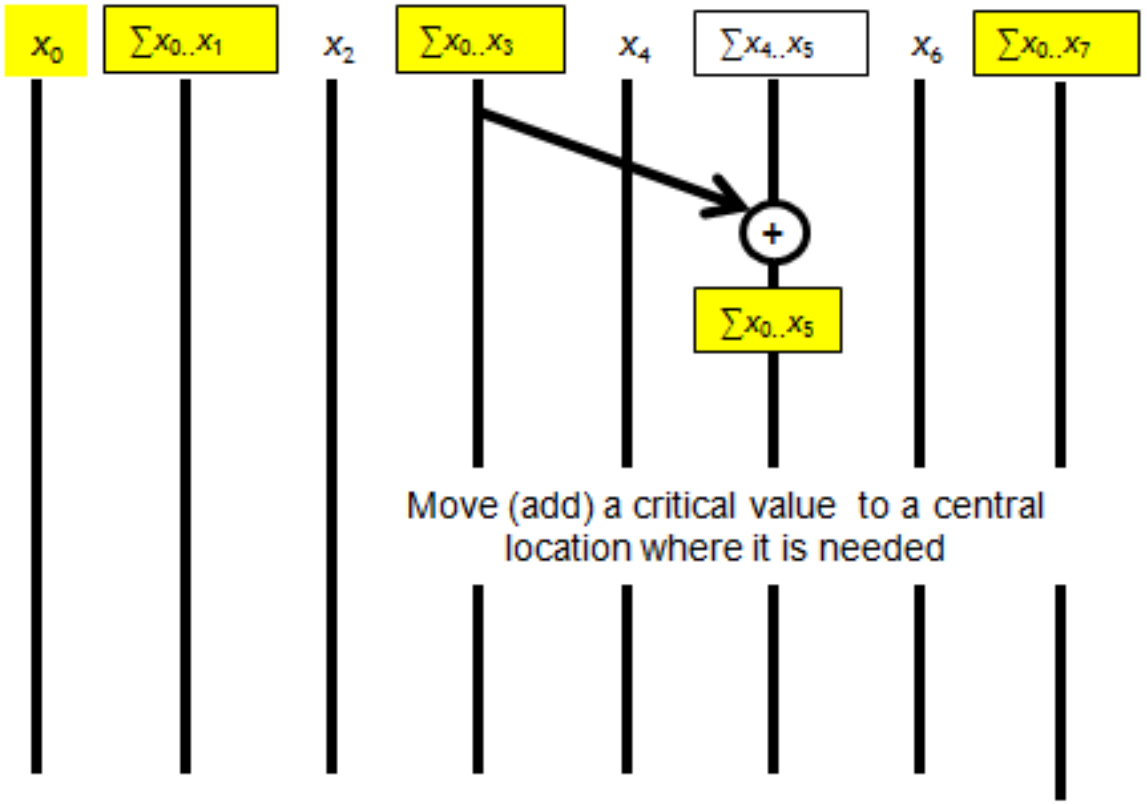

Scan

- **Fase reversa – post-reducción:**