Computación de Propósito General en Unidades de Procesamiento Gráfico (GPGPU)

E. Dufrechou, P. Ezzatti y M. Pedemonte

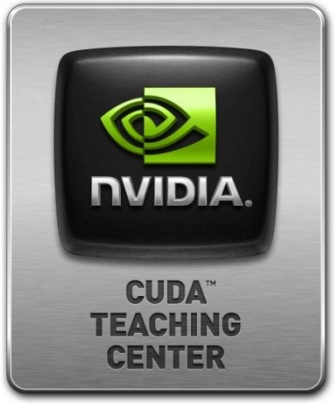

Clase 10
Ecosistema CUDA (extendido)

Contenido

- Ecosistema CUDA
- Thrust
- Nvidia Performance Primitives (NPP)
- OpenACC

Ecosistema CUDA

Ecosistema CUDA

- CUBLAS, NVBLAS
- Cusparse
- CuSolver
- CUDA Profiling Tools Interface (CUPTI)
- CURAND

Conceptos previos a CUBLAS

BLAS (Basic Linear Algebra Subprograms):

- **Es una especificación!**
- **Las operaciones se dividen en tres niveles:**
  - **BLAS-1, BLAS-2 y BLAS-3.**
- **Cuanto mayor sea el nivel de las operaciones, mejores resultados de optimización se obtienen.**
- **Matrices generales y estructuradas (triangulares, banda)**

BLAS

- **Mantiene una nomenclatura estándar.**
- **5 letras agrupadas en 3 bloques:**
  - **TMMOO: tipo de datos, tipo de matriz, código de operación**
- **Nomenclatura:**

	Real	Complejo
Simple Pre.	S	C
Doble Pre.	D	Z

	General	Simetrica/ Hermitiana	Triangular
Densa	GE	SY/HE	TR
Banda	GB	SB/HB	TB

BLAS

BLAS1

- Implementa operaciones tipo vector – vector y escalares.
- O(n) datos y O(n) operaciones.
- Movimiento de Datos:
  - Copia, intercambio.
- Operaciones vectoriales:
  - Escalado vectorial.
- Operaciones de reducción:
  - Producto escalar, norma vectorial, sumatoria, máximos.
- Nomenclatura operaciones:
  - xYYYY.
  - x {S,C,D,Z}, Y: operación.
  - Ej:xCOPY(……).

BLAS

BLAS2

- **Implementa operaciones tipo matriz – vector.**
- **$O(n^2)$ datos y $O(n^2)$ cálculos**
- **Ejemplos destacados:**
  - **Producto matriz – vector.**
  - **Actualizaciones de rango 1 y 2**

BLAS

BLAS3

- **Implementa operaciones tipo matriz – matriz.**
- **$O(n^2)$ datos y $O(n^3)$ cálculos**
- **Operaciones destacadas:**
  - **Producto matriz – matriz.**
  - **Actualizaciones de rango *k* y *2k*.**
  - **Resolución de sistemas triangulares.**

BLAS

Distintas versiones según plataformas:

- **ACML de AMD**
- **ESSL de IBM**
- **MKL de Intel**
- **Sun Performance Library de SUN**
- **GotoBLAS para Intel Pentium, SPARC, IBM PowerPC (discontinuada)**
- **OpenBLAS (basada en GotoBLAS2)**
- **ATLAS (implementación portable)**

BLAS

- MKL es la implementación de referencia en arquitecturas Intel.
- Es la biblioteca de álgebra lineal utilizada por MATLAB (en gral).
- Desempeño de OpenBLAS comparable con MKL para algunas arquitecturas
- Algunas versiones proporcionan paralelismo a nivel de hilos para arquitecturas con memoria compartida.
  - Intel MKL
  - OpenBLAS
  - ATLAS, etc.

CUBLAS

Bases para CUBLAS

- [2003, Kruger y Westermann] Primeras ideas tendientes sobre implementación de BLAS en GPU.

Con el surgimiento de CUDA

- Se incluye CUBLAS
  - Implementación en GPU de BLAS.
  - Comienza en simple precisión, luego evoluciona …

CUBLAS

Mejoras a CUBLAS

- [2008, Volkov y Demmel] Importantes mejoras en la operación gemm (multiplicación de matrices generales). Luego incorporado a CUBLAS.

- [2008, Barrachina y otros] Uso de padding y estrategias híbridas (CPU+GPU).

CUBLAS

CUBLAS v2

- La forma de acceder incluye un handler.
- Se puede acceder a los escalares por referencia tanto en GPU como en CPU.
- Se han agregado funciones multi-GPU.
- Se han agregado funciones batch.

NVBLAS

- Ejecución dinámica de operaciones BLAS-3 en más de una GPU (y CPU).

CuSparse

En las últimas versiones incluye funciones de alto nivel:

Ofrece spmv y sptrsv en distintos formatos de matriz dispersa, funciones de conversión.

Para precondicionamiento

- **IC, ILU, etc.**

Para reordenamiento

- **Coloreado de grafos**

cuSolver

Se incluyen funciones para resolver operaciones de álgebra densa y dispersa:

- **LU, Cholesky**
- **SVD**
- **eig**
- **QR**

CUDA Profiling Tools Interface (CUPTI)

- Permite crear herramientas de profiling y tracing sobre CUDA.
- Provee 4 APIs:
  - Activity API
  - Callback API
  - Event API
  - Metric API

CUPTI

Activity API

Permite guardar en forma asincrónica la traza de una aplicación.

Elementos:

- **Activity record: estructuras de C donde se reportan las actividades.**
- **Activity Buffer: para almacenar los activity records.**
- **Activity Queue: cola con los activity buffers (global, context, stream).**

CUPTI

Callback API

Permite guardar un callback en el código.

El callback es invocado cuando una aplicación llama al CUDA runtime, a una función del driver o ciertos eventos del CUDA driver.

CUPTI

- **Event API**

Permite consultar, configurar, lanzar, parar y consultar el event counter de un device.

- **Metric API**

Permite consolidar métricas de aplicaciones calculadas por uno o varios valores de evento.

CURAND

Biblioteca para la generación de números pseudo-aleatorios y quasi-aleatorios.

- **Una secuencia pseudo-aleatoria satisface la mayoría de las propiedades estadísticas pero es generada por un algoritmo determinístico.**

- **Una secuencia quasi-aleatoria de puntos n-dimensional es generada por un algoritmo determinístico diseñado para completar un espacio posiblemente n-dimensional.**

CURAND

CURAND incluye dos componentes:

- **Una biblioteca en el host (CPU).**
- **Un archivo cabezal para el device (GPU).**

CURAND

Biblioteca

Los números aleatorios pueden ser generados en el device o en el host.

- Cuando se generan en el device: la llamada a la biblioteca se realiza en el host (pero se ejecuta en el device). Los números generados se guardan en memoria global del device.

- Cuando se genera en CPU: el trabajo se realiza en CPU y los números se almacenan en memoria del host.

CURAND

Archivo cabezal

- Define las funciones en el device para inicializar los estados del generador de números aleatorios y generar las secuencias de números aleatorios.

- Utilizando las funciones directamente, se puede evitar escribir en memoria (consumiendo al mismo tiempo que se van generando los números).

CURAND

Resumen del funcionamiento:

- Los números aleatorios son calculados por los generadores.
- Los generadores encapsulan el estado interno para seguir la secuencia.
- Se pueden crear varios generadores al mismo tiempo.
- La secuencia producida por cada generador es determinística. Dada los mismos parámetros iniciales se genera la misma secuencia !!

CURAND

Secuencia normal de uso:

1. Crear un nuevo generador con curandCreateGenerator().
2. Especificar las opciones del generador.
3. Allocar memoria en el device con cudaMalloc().
4. Generar números aleatorios con curandGenerate() (u otra función generadora).
5. Usar los números ...
6. Si es necesario, generar más números llamar nuevamente a curandGenerate().
7. Finalizar con curandDestroyGenerator().

CURAND

- Para generar números aleatorios en el host:
  - En el paso 1, llamar a curandCreateGeneratorHost(),
  - En el paso 3, alocar memoria en el host para recibir los números.
- Notar que curandGenerate() en el paso 4 , lanza el kernel y retorna en forma asincrónica.
  - Si se lanza otro kernel en otro stream, y se necesitan los resultados de curandGenerate(), se necesita llamar a cudaThreadSynchronize() o sincronizar los streams, para garantizar que el generador finalizó antes de que el kernel sea lanzado.
- Obviamente no es válido pasar un puntero a memoria del host cuando se trabaja en el device y viceversa.

Thrust

Thrust

Es una biblioteca orientada a la productividad para CUDA

- **Basada en C++ Standard Template Library (STL)**
- **Ofrece una interfaz de alto nivel al uso de GPUs**
- **Mantiene la interoperabilidad con el resto de las aplicaciones CUDA**

Thrust

Se desarrolla mediante el uso de algoritmos de alto nivel, delegando a la biblioteca como se implementa.

Los algoritmos básicos:

- **for_each,**
- **scan,**
- **sort,**
- **reduction.**

No se especifica configuración de ejecución !!!

Thrust

Múltiples opciones para el desarrollo:

- **Se puede desarrollar aplicaciones completas en Thrust.**
- **Se puede desarrollar aplicaciones mixtas (Thrust, CUDA).**

Thrust

Sort

Un ejemplo claro de la independencia del uso y la implementación.

Dependiendo del tipo de dato y de la cantidad de tamaños se utiliza:

- radix sort
- merge sort.

Thrust

Aspectos de eficiencia

- **Fusión: permite aumentar la cantidad de cálculos por acceso a memoria.**

- **Acceso coalesced: tener en cuenta los tipos de datos utilizados (struct de arrays, arrays de structs).**

NPP

NVIDIA Performance Primitives (NPP)

- **NPP es una biblioteca de funciones para acelerar en forma sencilla aplicaciones con GPUs.**

- **Las funciones incluidas se centran en procesamiento de imágenes y video.**

OpenACC

OpenACC

- Paralelismo sencillo.
- Paralelización mediante cláusulas.
- Extensión del estilo OpenMP.
- Incluye las transferencias