

Laboratorul 07 - Arhitecturi de tip GPGPU

Intro

Procesorul grafic (GPU - graphics processing unit) reprezinta un circuit electronic specializat in crearea si manipularea imaginilor trimise catre o unitate de display (e.g. monitor). Termenul GPGPU (general purpose graphics processing unit) denota un procesor grafic cu o flexibilitate ridicata de programare, capabil de a rezolva si probleme generale. In executie, o arhitectura de tip GPU foloseste paradigma SIMD (single instruction multiple data, taxonomia Flynn), ceea ce presupune, schimb rapid de context intre thread-uri, planificarea in grupuri de thread-uri si orientare catre prelucrari masive de date. Procesorul grafic dispune si de un spatiu propriu de memorie (GPU dedicat → VRAM, GPU integrat → RAM).

Unitatile tip GPU sunt potrivite pentru paralelismul de date, intensiv computationale. Datorita faptului ca aceleasi instructiuni sunt execute pentru fiecare element, nu sunt necesare mecanisme complexe pentru controlul fluxului. Ierarhia de memorie este simplificata comparativ cu cea a unui procesor x86/ARM. Deoarece calculele sunt intensive computationale, latenta accesului la memorie poate fi ascunsa prin paralelism (massive multithreading, SIMD sau Single Instruction Multiple Threads) in locul folosirii extensive a memoriei cache.

Nu orice algoritm paralel ruleaza optim pe o arhitectura GPGPU. De principiu probleme de tip SIMD sau MIMD se preteaza rularii pe GPU-uri.

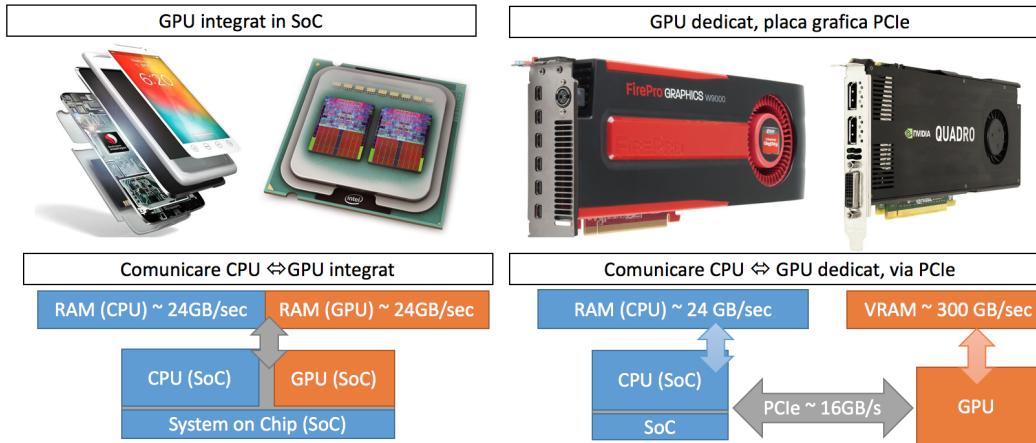
In multe cazuri, termenul de GPGPU apare atunci cand unitatea GPU este folosita ca si coprocesor matematic. In ziua de azi, majoritatea unitatilor de tip GPU sunt si GPGPU. In ultimii ani folosirea unitatilor GPGPU a luat amprenta. Acest lucru se datoreaza:

- diferentelor de putere de procesare bruta dintre CPU si GPU in favoarea acestora din urma
- standardizarea de API-uri care usureaza munca programatorilor pentru a folosi GPU-ul
- raspandirea aplicatiilor ce pot beneficia de pe urma paralelismului tip SIMD
- regasirea unitatilor GPU atat in unitatile computationale consumer (PC, Smartphone, TV etc) cat si cele industriale (Automotive, HPC etc).

Principalii producatori de core-uri IP (intellectual property) tip GPU sunt:

- Intel http://en.wikipedia.org/wiki/List_of_Intel_graphics_processing_units [http://en.wikipedia.org/wiki/List_of_Intel_graphics_processing_units]
- Nvidia http://en.wikipedia.org/wiki/List_of_Nvidia_graphics_processing_units [http://en.wikipedia.org/wiki/List_of_Nvidia_graphics_processing_units]
- Amd http://en.wikipedia.org/wiki/List_of_AMD_graphics_processing_units [http://en.wikipedia.org/wiki/List_of_AMD_graphics_processing_units]
- Apple https://en.wikipedia.org/wiki/Apple_silicon [https://en.wikipedia.org/wiki/Apple_silicon]
- Imagination http://en.wikipedia.org/wiki/List_of_PowerVR_products [http://en.wikipedia.org/wiki/List_of_PowerVR_products]
- Qualcomm <http://en.wikipedia.org/wiki/Adreno> [<http://en.wikipedia.org/wiki/Adreno>]
- Vivante http://en.wikipedia.org/wiki/Vivante_Corporation [http://en.wikipedia.org/wiki/Vivante_Corporation]

Daca un IP de GPU este integrat pe aceeasi pastila de siliciu a unui SoC (system on chip), acesta se numeste GPU integrat (integrated GPU). Exemple de SoC-uri cu IP de GPU integrat includ procesoarele x86 Intel si Amd cat si majoritatea SoC-urilor pentru dispozitive mobile bazate pe arhitectura ARM (ex. Qualcomm Snapdragon). Un GPU integrat imparte mare parte din ierarhia de memorie cu alte IP-uri (ex core-uri ARM/x86, controller PCIe/USB/SATA/ETH). Pe de alta parte un GPU dedicat (discrete GPU) presupunea integrarea IP-ului de GPU pe o placă cu memorie dedicata (VRAM) cat si o magistrala PCIe/AGP8x/USB pentru comunicare cu sistemul. Exemple de GPU-uri dedicate sunt seriile de placi grafice Geforce (Nvidia) si Radeon (Amd).



Aplicatii arhitecturi GPGPU

Exemple de domenii ce folosesc procesare GPGPU: prelucrari video si de imagini, simulari de fizica, finante, dinamica fluidelor, criptografie, design electronic (VLSI). Exemple de aplicatii pentru GPGPU: Automotive - self driving cars (BMW, Continental etc)

- <https://www.nvidia.com/en-us/self-driving-cars/partners/bmw/> [<https://www.nvidia.com/en-us/self-driving-cars/partners/bmw/>]
- <https://blogs.nvidia.com/blog/2018/09/18/audi-unveils-e-tron-electric-suv/> [<https://blogs.nvidia.com/blog/2018/09/18/audi-unveils-e-tron-electric-suv/>]

Inteligenta artificiala - antrenare retele neurale, inferenta

- <https://www.forbes.com/sites/forbestechcouncil/2017/12/01/for-machine-learning-its-all-about-gpus/> [<https://www.forbes.com/sites/forbestechcouncil/2017/12/01/for-machine-learning-its-all-about-gpus/>]
- <https://www.quora.com/Why-are-GPUs-well-suited-to-deep-learning> [<https://www.quora.com/Why-are-GPUs-well-suited-to-deep-learning>]

Criptomonde - mining via hashing

- <https://coincentral.com/best-gpu-for-mining-2018-edition/> [<https://coincentral.com/best-gpu-for-mining-2018-edition/>]

SmartTV, Smartphone - accelerare video, recunoastere faciala/audio Simulari fizice - NVIDIA Physx, Folding@Home

- <https://blogs.nvidia.com/blog/2018/11/13/weather-predicted-sc18-gpu-hpc-jensen-huang/> [<https://blogs.nvidia.com/blog/2018/11/13/weather-predicted-sc18-gpu-hpc-jensen-huang/>]

Prelucrari multimedia - filtre imagini GIMP/Photoshop Alte domenii - arhivare (WinZip), encriptare



Programarea GPGPU

In cadrul unui sistem ce contine o unitate IP de tip GPU, procesorul general care coordoneaza executia este numit "HOST" (CPU) pe cand unitatea care efectueaza calculele este numita "DEVICE" (GPU). O unitate GPU contine un procesor de comanda ("command processor") care citeste comenzi scrise de catre HOST (CPU) in anumite zone din RAM mapate spre access atat catre unitatea GPU cat si catre unitatea CPU. Toate schimbarile de stare in cadrul unui GPU, alocarile/transferurile de memorie si evenimentele ce tin de sistemul de operare sunt controlate de catre CPU (HOST).

In general, o prelucrare de date folosind unitatea GPU, necesita in prealabil un transfer din spatiul de memorie de la CPU catre spatiul de memorie de la GPU. In cazul unui procesor grafic dedicat acest transfer se face printr-o magistrala (PCIe, AGP, USB...). Viteza de transfer RAM-VRAM via magistrala este inferioara vitezei RAM sau VRAM. O potientala optimizare in transferul RAM↔VRAM ar fi intercalarea cu procesarea. In cazul unui procesor integrate transferul RAM↔VRAM presupune o mapare de memorie, de multe ori translataata printr-o operatie de tip zero copy.

Programarea unui GPU se face printr-un API (Application Programming Interface). Cele mai cunoscute API-uri orientate catre folosirea unui GPU ca coprocesor matematic sunt: Cuda, OpenCL, DirectCompute, OpenACC, Vulkan. Dezvoltarea de cod pentru laboratoarele de GPU se va face folosind Cuda.

De ce CUDA ?

CUDA este un API introdus in 2006 de catre NVIDIA pentru GPU-urile sale. In prezent CUDA este standardul de facto pentru folosirea unitatilor GPU in industrie si cercetare. Aceasta se datoreaza faptului ca este o platforma stabila cu multe facilitati. O noua versiune de CUDA introduce noi functionalitati dar acestora uneori necesita versiuni recente ale arhitecturilor fiind dezactivate daca nu exista suport hardware. O versiune noua de CUDA extinde versiunea mai veche - de exemplu versiunea CUDA 9.0 reprezinta in mare o extensie/update asupra versiunii CUDA 8.0. In mare toate GPU-urile oferite de NVIDIA sunt suportate, diferenta fiind la facilitatile suportate. Singura limitare majora a platformei CUDA este ca suporta numai unitati de procesare de tip GPU de la NVIDIA.

Un standard alternativ la CUDA este OpenCL, suportata de Khronos ca standard si implementata de majoritatea producatorilor de GPU (inclusiv NVIDIA ca o extensie la CUDA). Problema majora la OpenCL este ca suportul este fragmentat si standardul este mult mai restrictiv decat CUDA si mai complicat de scris programe.

Arhitectura NVIDIA CUDA

Implementarea NVIDIA pentru GPGPU se numeste CUDA (Compute Unified Device Architecture) si permite utilizarea limbajului C pentru programarea pe GPU-urile proprii cat si extensii pentru alte limbiage (ex Python). Deoarece una din zonele tinta pentru CUDA este HPC (High Performance Computing), in care limbajul Fortran este foarte popular, PGI ofera un compilator de Fortran ce permite generarea de cod si pentru GPU-urile Nvidia. Există binding-uri pana si pentru Java (jCuda), Python (PyCUDA) sau .NET (CUDA.NET). Framework-ul/arhitectura CUDA expune si API-ul de OpenCL prin intermediuil caruia vom interactiona cu GPGPU-ul Nvidia Tesla disponibil pe dp.

GPU Computing Applications						
Libraries and Middleware						
cuDNN TensorRT	cuFFT, cuBLAS, cuRAND, cuSPARSE	CULA MAGMA	Thrust NPP	VSIPL, SVM, OpenCurrent	PhysX, OptiX, iRay	MATLAB Mathematica
Programming Languages						
C	C++	Fortran	Java, Python, Wrappers	DirectCompute	Directives (e.g., OpenACC)	
CUDA-enabled NVIDIA GPUs						
Turing Architecture (Compute capabilities 7.x)	DRIVE/JETSON AGX Xavier	GeForce 2000 Series	Quadro RTX Series	Tesla T Series		
Volta Architecture (Compute capabilities 7.x)	DRIVE/JETSON AGX Xavier			Tesla V Series		
Pascal Architecture (Compute capabilities 6.x)	Tegra X2	GeForce 1000 Series	Quadro P Series	Tesla P Series		
Maxwell Architecture (Compute capabilities 5.x)	Tegra X1	GeForce 900 Series	Quadro M Series	Tesla M Series		
Kepler Architecture (Compute capabilities 3.x)	Tegra K1	GeForce 700 Series GeForce 600 Series	Quadro K Series	Tesla K Series		
	EMBEDDED	CONSUMER DESKTOP, LAPTOP	PROFESSIONAL WORKSTATION	DATA CENTER		

Arhitectura CUDA (toate GPU-urile, serile Geforce (consumer), Tesla (HPC), Jetson (automotive)). Driver cu suport Windows, Linux, ce suporta atat CUDA API cat si OpenCL API. Framework/toolkit compilator cu suport CUDA/OpenCL API (nvcc), debugger/profiler (CUDA API only) Numeroase biblioteci si exemple CUDA/OpenCL API

Unitatea de baza in cadrul arhitecturii CUDA este numita SM (Streaming Multiprocessor). Ea contine in functie de generatie un numar variabil de Cuda Cores sau SP (Stream Processors) - de regula intre 8SP si 128SP. Unitatea de baza in scheduling este denumita "warp" si alcatuita din 32 de thread-uri. Vom aborda mai amanuntit arhitectura CUDA in laboratorul urmator. Ultima versiune de CUDA 8.0 suport OpenCL 1.2.

Compute capability

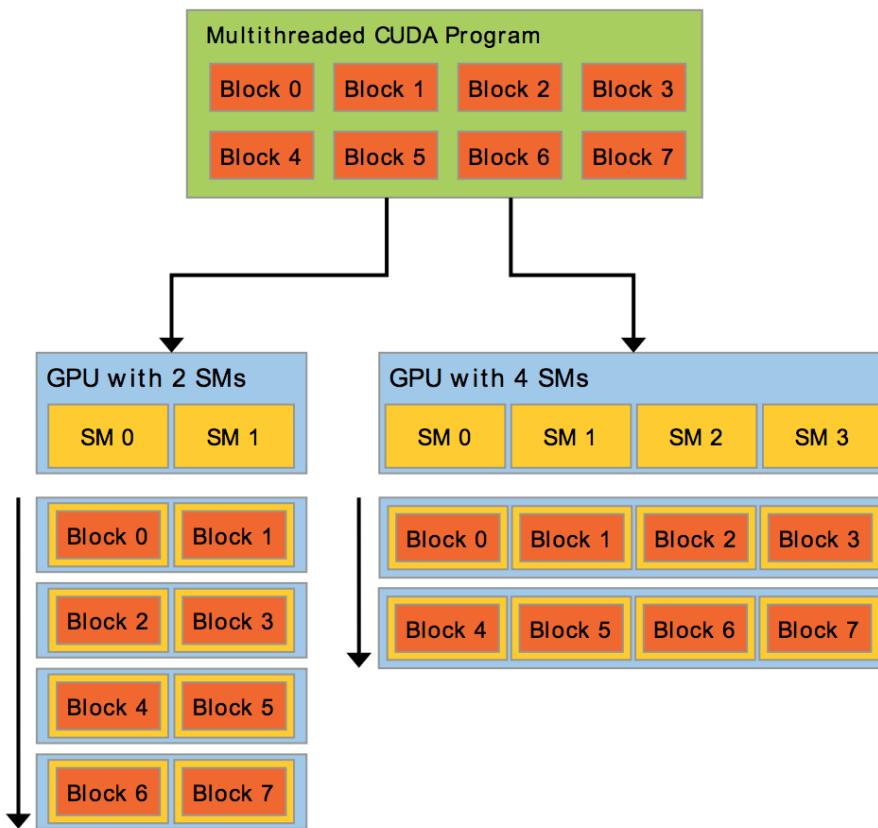
Versiunea de "compute capability" a unui SM (Streaming Multiprocessor), in cadrul arhitecturii CUDA, este reprezentat de un format X.Y, unde X este versiunea majora pe cand Y este versiunea minora. Partea majora identifica generatia din care face parte arhitectura. Astfel revizia 7 denota arhitectura Volta, 6 este pentru arhitectura Pascal, 5 pentru arhitectura Maxwell, 3 pentru arhitectura Kepler, 2 pentru Fermi iar 1 pentru Tesla. Partea minora identifica diferentele incrementale in arhitectura si posibilele noi functionalitati. Stiind versiunea majora si cea minora cunoastem facilitatile hardware oferite de catre arhitectura. GPU-urile care au aceasi versiune suporta aceleasi capabilitati.

O lista a GPU-urilor NVIDIA si versiunile lor majore/minore se regaseste aici [<https://developer.nvidia.com/cuda-gpus>]. In cadrul cozii hpsl se regasesc GPU-uri Tesla K40M [https://www.nvidia.com/content/pdf/kepler/tesla-k40-active-board-spec-bd-06949-001_v03.pdf], iar in cadrul cozii dp GPU-uri Tesla 2070 [https://www.nvidia.com/docs/IO/43395/NV_DS_Tesla_C2050_C2070_jul10_lores.pdf].

Programarea in CUDA

CUDA extinde limbajul C prin faptul ca permite unui programator sa defineasca functii C, denumite kernels, care urmeaza a fi execute de N ori in paralel de N thread-uri CUDA. Scopul este de a abstractiza arhitectura GPU astfel incat partea de scheduling cat si gestiunea resurselor se face de catre stack-ul software CUDA impreuna cu suportul hardware. Figura de mai jos denota distribuirea thread-urilor catre 2 arhitecturi partionate diferit.

Un kernel se defineste folosind specificatorul global iar executia sa se face printre-o configuratia de executie folosind <<<...>>. Configuratia de executie denota numarul de blocks si numarul de thread-uri dintr-un block. Fiecare thread astfel poate fi identificat unic prin blockIdx si threadIdx.



Mai jos avem definit un kernel, `vector_add`, care are ca argumente pointers de tip float respectiv `size_t`. Acesta calculeaza $f(x) = 2x + 1/(x + 1)$, pentru fiecare elemente din vector. Numarul total de thread-uri este dimensiunea vectorului.

```
__global__ void vector_add(const float *a, float *b, const size_t n) {
    // Compute the global element index this thread should process
    unsigned int i = threadIdx.x + blockDim.x * blockIdx.x;

    // Avoid accessing out of bounds elements
    if (i < n) {
        b[i] = 2.0 * a[i] + 1.0 / (a[i] + 1.0);
    }
}
```

Configuratia de executie denota maparea intre date si instructiuni. In functia de kernel, se defineste setul de instructiuni ce se va executa repeatat pe date. Mai jos `vector_add` este lansat in executie cu N thread-uri (blocks_no x block_size) organizate cate block_size thread-uri per block.

```
// Launch the kernel
vector_add<<<blocks_no, block_size>>>(device_array_a, device_array_b, num_elements);
```

Aplicatie HelloWorld CUDA

```
#include <stdio.h>

__global__ void kernel_example(int value) {
    /**
     * This is a kernel; a kernel is a piece of code that
     * will be executed by each thread from each block in
     * the GPU device.
     */
    printf("[GPU] Hello from the GPU!\n");
    printf("[GPU] The value is %d\n", value);
    printf("[GPU] blockDim=%d, blockIdx=%d, threadIdx=%d\n", blockDim.x, blockIdx.x, threadIdx.x);
}

int main(void) {
    /**
     * Here, we declare and/or initialize different values or we
     * can call different functions (as in every C/C++ program);
     * In our case, here we also initialize the buffers, copy
     * local data to the device buffers, etc (you'll see more about
     * this in the following exercises).
     */
    int nDevices;
    printf("[HOST] Hello from the host!\n");

    /**
     * Get the number of compute-capable devices. See more info
     * about this function in the Cuda Toolkit Documentation.
     */
    cudaGetDeviceCount(&nDevices);
    printf("[HOST] You have %d CUDA-capable GPU(s)\n", nDevices);

    /**
     * Launching the above kernel with a single block, each block
     */
}
```

```

 * with a single thread. The synchronize and the checking functions
 * assures that everything works as expected.
 */
kernel_example<<<1,1>>>(25);
cudaDeviceSynchronize();

/**
 * Here we can also deallocate the allocated memory for the device
 */
return 0;
}

```

Aplicatie compute CUDA

O aplicatie CUDA are ca scop executia de cod pe GPU-uri NVIDIA CUDA. In cadrul laboratoarelor partea de CPU (host) va fi folosita exclusiv pentru managementul executiei partii de GPU (device). Aplicatiilor vor viza executia folosind un singur GPU NVIDIA CUDA.

0. Definire functie kernel

In codul prezentat mai jos, functia vector_add este marcata cu **"global"** si va fi compilata de catre CUDA NVCC compiler [https://docs.nvidia.com/cuda/pdf/CUDA_Compiler_Driver_NVCC.pdf] pentru GPU-ul de pe sistem (in cazul cozii hpsl va fi NVIDIA Tesla K40M).

```

/**
 * This kernel computes the function f(x) = 2x + 1/(x + 1) for each
 * element in the given array.
 */
__global__ void vector_add(const float *a, float *b, const size_t n) {
    // Compute the global element index this thread should process
    unsigned int i = threadIdx.x + blockDim.x * blockIdx.x;

    // Avoid accessing out of bounds elements
    if (i < n) {
        b[i] = 2.0 * a[i] + 1.0 / (a[i] + 1.0);
    }
}

```

1. Definire zone de memorie host si device

Din punct de vedere hardware, partea de host (CPU) are ca memorie principala RAM (chip-uri memorie instalate pe placă de bază via slot-urile memorie) iar partea de device (GPU) are VRAM (chip-uri de memorie prezente pe placă video). Cand vorbim de memoria host (CPU) ne referim la RAM, iar în cazul memoriei device (GPU) la VRAM.

La versiunile mai recente de CUDA, folosind limbajul C/C++, un pointer face referire la spațiul virtual care este unificat pentru host (CPU) și device (GPU). Adresele virtuale însă sunt transluate către adrese fizice ce rezidă ori în memoria RAM (CPU) ori în memoria VRAM (GPU). Astfel este important cum alocăm memorie (fie cu malloc pentru CPU sau cudaMalloc pentru GPU) și respectiv să facem cu atenție transferurile de memorie între zonele virtuale definite (de la CPU la GPU și respectiv de la GPU la CPU).

```

// Declare variable to represent ~1M float values and
// computes the amount of bytes necessary to store them
const int num_elements = 1 << 16;
const int num_bytes = num_elements * sizeof(float);

// Declaring the 'host arrays': a host array is the classical
// array (static or dynamically allocated) we worked before.
float *host_array_a = 0;
float *host_array_b = 0;

// Declaring the 'device array': this array is the equivalent
// of classical array from C, but specially designed for the GPU
// devices; we declare it in the same manner, but the allocation
// process is going to be different
float *device_array_a = 0;
float *device_array_b = 0;

```

2. Alocare memorie host (CPU)

Functia malloc va întoarce o adresă virtuală ce va avea corespondent o adresă fizică din RAM.

```

// Allocating the host array
host_array_a = (float *) malloc(num_bytes);
host_array_b = (float *) malloc(num_bytes);

```

3. Alocare memorie device (GPU)

Functia cudaMalloc va întoarce o adresă virtuală ce va avea corespondent o adresă fizică din VRAM.

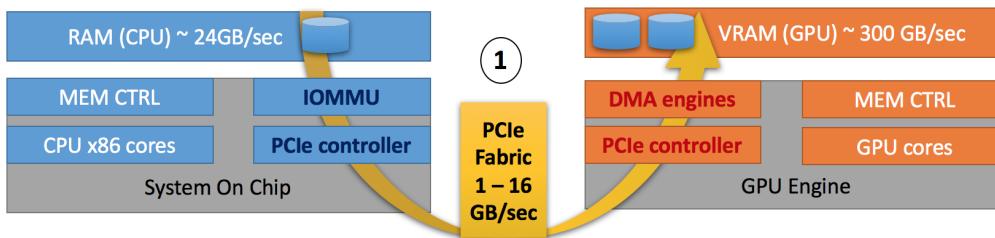
```

// Allocating the device's array; notice that we use a special
// function named cudaMalloc that takes the reference of the
// pointer declared above and the number of bytes.
cudaMalloc((void **) &device_array_a, num_bytes);
cudaMalloc((void **) &device_array_b, num_bytes);

// If any memory allocation failed, report an error message
if (host_array_a == 0 || host_array_b == 0 || device_array_a == 0 || device_array_b == 0) {
    printf("[HOST] Couldn't allocate memory\n");
    return 1;
}

```

4. Initializare memorie host (CPU) și copiere pe device (GPU)

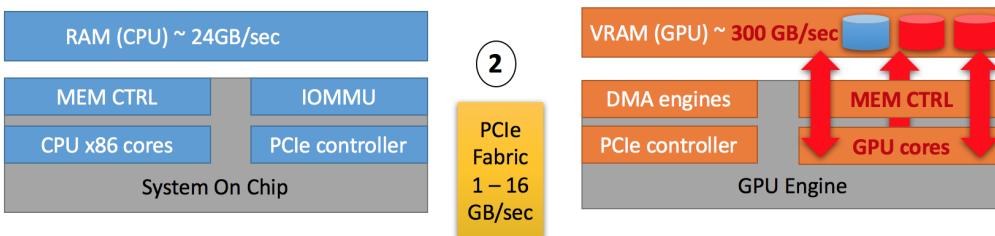


```
// Initialize the host array by populating it with float values
for (int i = 0; i < num_elements; ++i) {
    host_array_a[i] = (float) i;
}

// Copying the host array to the device memory space; notice the
// parameters of the cudaMemcpy function; the function default
// signature is cudaMemcpy(dest, src, bytes, flag) where
// the flag specifies the transfer type.

// host -> device: cudaMemcpyHostToDevice
// device -> host: cudaMemcpyDeviceToHost
// device -> device: cudaMemcpyDeviceToDevice
cudaMemcpy(device_array_a, host_array_a, num_bytes, cudaMemcpyHostToDevice);
```

5. Executie kernel



```
// Compute the parameters necessary to run the kernel: the number
// of blocks and the number of threads per block; also, deal with
// a possible partial final block
const size_t block_size = 256;
size_t blocks_no = num_elements / block_size;

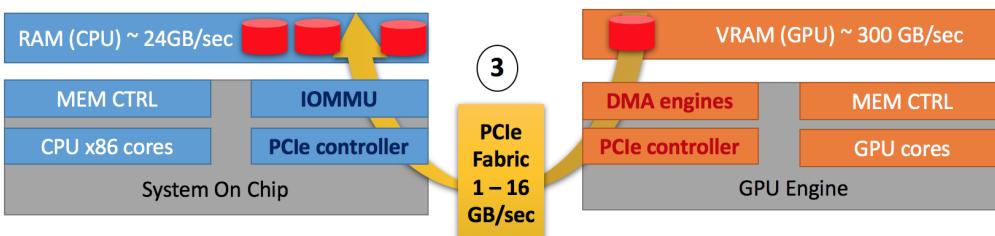
if (num_elements % block_size)
    ++blocks_no;

// Launch the kernel
vector<double><<<blocks_no, block_size>>>(device_array_a, device_array_b, num_elements);
cudaDeviceSynchronize();
```

6. Copiere date inapoi de la device (GPU) catre host (CPU)

```
// Copy the result back to the host memory space
cudaMemcpy(host_array_b, device_array_b, num_bytes, cudaMemcpyDeviceToHost);

// Print out the first 10 results
for (int i = 0; i < 10; ++i) {
    printf("Result %d: 2 * %1.1f + 1.0/(%1.1f + 1.0)= %1.3f\n",
        i, host_array_a[i], host_array_b[i], host_array_b[i]);
}
```

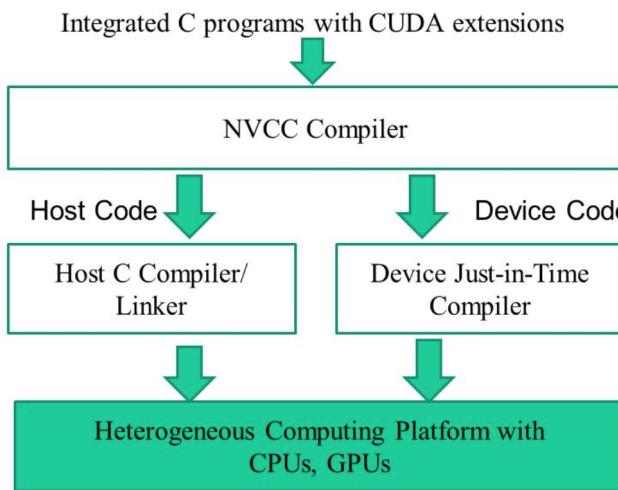


7. Cleanup

```
// Deallocate memory
free(host_array_a);
free(host_array_b);
cudaFree(device_array_a);
cudaFree(device_array_b);
```

Compilare si executie

Desi pentru un programator partile de host/CPU respectiv device/GPU pot fi in acelasi fisier *.cu, compilatorul CUDA (nvcc) le separa facand o compilare diferita pentru partea de host/CPU respectiv device/GPU. Figura de mai jos denota acest aspect.



© David Kirk/NVIDIA and Wen-mei W. Hwu, 2007-2011
ECE408/CS483, University of Illinois, Urbana-Champaign

Intrati pe frontend-ul fep8.grid.pub.ro folosind contul de pe curs.upb.ro. Executati comanda

```
srun --pty -p hpsl /bin/bash
```

pentru a accesa una din statiile cu GPU-uri. Cozile ce au unitati GPU NVIDIA Tesla sunt hpsl si dp.

```
[@fep8 ~]$ srun --pty -p hpsl /bin/bash
[@hpsl-wn01 ~]$ nvidia-smi      # NVIDIA System Management Interface program
+-----+
| NVIDIA-SMI 470.82.01    Driver Version: 470.82.01    CUDA Version: 11.4 |
+-----+
| GPU  Name Persistence-M  Bus-Id Disp.A  Volatile Uncorr. ECC |
| Fan  Temp  Perf  Pwr/Usage/Cap | Memory-Usage | GPU-Util  Compute M. |
| |          |          |          |          |          |          | MIG M. |
+-----+
|  0  Tesla K40m        Off  | 00000000:08:00.0 Off   |       0 | | | | |
| N/A  40C   P0  63W / 235W |     0MiB / 11441MiB |      0%  Default |
|          |          |          |          |          |          | N/A |
+-----+
|  1  Tesla K40m        Off  | 00000000:24:00.0 Off   |       0 | | | | |
| N/A  44C   P0  64W / 235W |     0MiB / 11441MiB |      0%  Default |
|          |          |          |          |          |          | N/A |
+-----+
|  2  Tesla K40m        Off  | 00000000:27:00.0 Off   |       0 | | | | |
| N/A  40C   P0  62W / 235W |     0MiB / 11441MiB |      52%  Default |
|          |          |          |          |          |          | N/A |
+-----+
```

Pentru laboratoare si teme vom folosi CUDA 9.1 aici

[https://developer.download.nvidia.com/compute/cuda/9.1/Prod/docs/sidebar/CUDA_Toolkit_Release_Notes.pdf].

```
[@hpsl-wn01 ~]$ apptainer run --nv docker://gitlab.cs.pub.ro:5050/asc/asc-public/cuda-labs:1.9.1
INFO: Using cached SIF image
Apptainer>
```

SDK-ul CUDA de la NVidia include atat implementarea de CUDA API cat si cea de OpenCL API. In cadrul laboratoarelor vom programa numai folosind CUDA. Verificam mai jos ca scheletul laboratorului compileaza.

```
Apptainer> wget -O lab7_skl.tar.gz https://ocw.cs.pub.ro/courses/_media/asc/lab7/lab7_skl.tar.gz
--2020-03-22 18:52:14- http://ocw.cs.pub.ro/courses/_media/asc/lab7/lab7_skl.tar.gz
Resolving ocw.cs.pub.ro (ocw.cs.pub.ro)... 141.85.227.65
Connecting to ocw.cs.pub.ro (ocw.cs.pub.ro)|141.85.227.65|:80... connected.
HTTP request sent, awaiting response... 302 Found
Location: https://ocw.cs.pub.ro/courses/_media/asc/lab7/lab7_skl.tar.gz [following]
--2020-03-22 18:52:14- https://ocw.cs.pub.ro/courses/_media/asc/lab7/lab7_skl.tar.gz
Connecting to ocw.cs.pub.ro (ocw.cs.pub.ro)|141.85.227.65|:443... connected.
HTTP request sent, awaiting response... 200 OK
Length: 4884 (4.8K) [application/octet-stream]
Saving to: 'lab7_skl.tar.gz'

100%[=====] 4,884      ---K/s  in 0s

2020-03-22 18:52:14 (11.1 MB/s) - 'lab7_skl.tar.gz' saved [4884/4884]

Apptainer> tar -xvf lab7_skl.tar.gz
task1/
task1/task1.cu
task1/Makefile
task1/Makefile_Cluster
task2/
task2/task2.cu
task2/Makefile
task2/Makefile_Cluster
...
Apptainer> cd task1/
```

În cadrul imaginii CUDA avem compilatorul nvcc.

```
COMPILER=nvcc
LIBS=-lm

%: %.cu
$(COMPILER) $^ -o $@ $(LIBS)

clean:
    rm -rf task0
```

Exemplu de compilare si rulare interactiva pe coada hpsl

```
Apptainer> make task1
nvcc task1.cu -o task1 -lm
Apptainer> ./task1
[HOST] Hello from the host!
[HOST] You have 3 CUDA-capable GPU(s)
Apptainer> make clean
rm -rf task1
Apptainer> cd ../task2
Apptainer> make task2
nvcc task2.cu -o task2 -lm
Apptainer> ./task2
Result 0: 2 * 0.0 + 1.0/(0.0 + 1.0)= 0.000
Result 1: 2 * 1.0 + 1.0/(1.0 + 1.0)= 0.000
Result 2: 2 * 2.0 + 1.0/(2.0 + 1.0)= 0.000
Result 3: 2 * 3.0 + 1.0/(3.0 + 1.0)= 0.000
Result 4: 2 * 4.0 + 1.0/(4.0 + 1.0)= 0.000
Result 5: 2 * 5.0 + 1.0/(5.0 + 1.0)= 0.000
Result 6: 2 * 6.0 + 1.0/(6.0 + 1.0)= 0.000
Result 7: 2 * 7.0 + 1.0/(7.0 + 1.0)= 0.000
Result 8: 2 * 8.0 + 1.0/(8.0 + 1.0)= 0.000
Result 9: 2 * 9.0 + 1.0/(9.0 + 1.0)= 0.000
Apptainer>
```

Exemplu executie program CUDA folosind rularea ne-interactiva pe coada de executia hpsl (apelul trebuie facut de pe fep8.grid.pub.ro):

```
[fep8 ~]$ cd task2/
[fep8 task2]$ cat ..../utils/batch_run.sh
#!/bin/bash
aptainer exec --nv $CONTAINER_IMAGE \
./$TASK
[fep8 task2]$ sbatch --time 01:00:00 -p hpsl --export=TASK=task2,CONTAINER_IMAGE=docker://gitlab.cs.pub.ro:5050/asc/asc-public/cuda-labs:1.9.1 ..../utils/batch_run.sh
Submitted batch job 1816
[fep8 task2]$ squeue | grep 1816
     1816      hpsl batch_ru stefan_d   R      0:07      1 hpsl-wn01
[fep8 task2]$ cat slurm-1816.out
INFO: Using cached SIF image
Result 0: 2 * 0.0 + 1.0/(0.0 + 1.0)= 1.000
Result 1: 2 * 1.0 + 1.0/(1.0 + 1.0)= 2.500
Result 2: 2 * 2.0 + 1.0/(2.0 + 1.0)= 4.333
Result 3: 2 * 3.0 + 1.0/(3.0 + 1.0)= 6.250
Result 4: 2 * 4.0 + 1.0/(4.0 + 1.0)= 8.200
Result 5: 2 * 5.0 + 1.0/(5.0 + 1.0)= 10.167
Result 6: 2 * 6.0 + 1.0/(6.0 + 1.0)= 12.143
Result 7: 2 * 7.0 + 1.0/(7.0 + 1.0)= 14.125
Result 8: 2 * 8.0 + 1.0/(8.0 + 1.0)= 16.111
Result 9: 2 * 9.0 + 1.0/(9.0 + 1.0)= 18.100
```

Puteți folosi Makefile_Cluster:

```
[fep8 ~]$ cd task2/
[fep8 task2]$ make -f Makefile_Cluster clean
rm -rf task2
rm -rf slurm-*
[fep8 task2]$ make -f Makefile_Cluster task2
sbatch --time 01:00:00 -p hpsl --export=TASK=task2,CONTAINER_IMAGE=docker://gitlab.cs.pub.ro:5050/asc/asc-public/cuda-labs:1.9.1 ..../utils/batch_build.sh | ..../utils/batch_wait.sh
INFO: Using cached SIF image
nvcc task2.cu -o task2 -lm
[fep8 task2]$ make -f Makefile_Cluster run_task1
sbatch --time 01:00:00 -p hpsl --export=TASK=task2,CONTAINER_IMAGE=docker://gitlab.cs.pub.ro:5050/asc/asc-public/cuda-labs:1.9.1 ..../utils/batch_run.sh | ..../utils/batch_wait.sh
INFO: Using cached SIF image
Result 0: 2 * 0.0 + 1.0/(0.0 + 1.0)= 1.000
Result 1: 2 * 1.0 + 1.0/(1.0 + 1.0)= 2.500
Result 2: 2 * 2.0 + 1.0/(2.0 + 1.0)= 4.333
Result 3: 2 * 3.0 + 1.0/(3.0 + 1.0)= 6.250
Result 4: 2 * 4.0 + 1.0/(4.0 + 1.0)= 8.200
Result 5: 2 * 5.0 + 1.0/(5.0 + 1.0)= 10.167
Result 6: 2 * 6.0 + 1.0/(6.0 + 1.0)= 12.143
Result 7: 2 * 7.0 + 1.0/(7.0 + 1.0)= 14.125
Result 8: 2 * 8.0 + 1.0/(8.0 + 1.0)= 16.111
Result 9: 2 * 9.0 + 1.0/(9.0 + 1.0)= 18.100
```

Recomandăm sa va delegati mereu de pe serverele din cluster dupa terminarea sesiunii, utilizand comanda exit

Alternativ, daca ati uitat sesiuni deschise, puteti verifica acest lucru de pe fep8.grid.pub.ro, utilizand comanda squeue. In cazul in care identificati astfel de sesiuni "agatațe", le puteti sterge (si va rugam sa faceti asta), utilizand comanda scancel ID unde ID-ul il identificati din comanda anterioara squeue. Puteți folosi mai precis squeue -u username (username de pe fep8.grid.pub.ro) pentru a vedea doar sesiunile care vă interesează.

Daca nu veti face aceasta delegare, veti putea ajunge in situatia in care sa nu va mai puteti loga pe nodurile din cluster.

Pentru editarea fișierelor pe cluster, recomandam sa va montați sistemul de pe fep8 pe mașină locală. Pași sunt detaliați mai jos - multumiri lui Radu Millo pentru redactare.

Tutorial chei ssh: <https://www.ssh.com/academy/ssh/keygen> [<https://www.ssh.com/academy/ssh/keygen>]

Tutorial montare filesystem din fep pe local - comenzi date pe local:

```
mkdir /mnt/asc
sudo chown -R <user> /mnt/asc
decomentam linia 'user_allow_other' din /etc/fuse.conf
sshfs -o allow_other <user.moodle>@fep8.grid.pub.ro:/ /mnt/asc
```

Exercitii

Pentru inceput:

1. Logati-vla pe fep8.grid.pub.ro folosind contul de pe curs.upb.ro
2. Executați comanda:

```
wget -O lab7_sk1.tar.gz http://ocw.cs.pub.ro/courses/_media/asc/lab7/lab7_sk1.tar.gz
```

1. Dezarhivati folosind comanda tar -xzvf lab7_sk1.tar.gz

Debug aplicatii CUDA aici [<https://docs.nvidia.com/cuda/cuda-gdb/index.html#introduction>]

Modificările se vor face acolo unde este necesar in task_<i>.cu unde <i> este numarul taskului. Urmăriți indicațiile TODO din cod. De asemenea, va recomandam să folosiți documentația oficială CUDA Toolkit Documentation de la adresa: <https://docs.nvidia.com/cuda/> [<https://docs.nvidia.com/cuda/>]. Aici veți găsi informații despre majoritatea funcțiilor de care aveți nevoie (folosiți funcția search).

Task 1 - Rulați task1 ca exemplu pentru a verifica funcționalitatea CUDA pe GPU

Task 2 - Rulați task2 ca exemplu pentru efectuarea unor operații pe GPU

Task 3 - Urmăriți TODO-uri din taks3.cu

- Listați informații despre device-urile existente și selectați primul device
- Completați și rulați kernelul kernel_parity_id
- Completați și rulați kernelul kernel_block_id; explicați rezultatul
- Completați și rulați kernelul kernel_thread_id; explicați rezultatul

Task 4 - Efectuați adunarea a doi vectori folosind CUDA în task4.cu

Task 5 - Urmăriți instrucțiunile din task5.cu pentru a realiza interschimbarea a doi vectori

Recomandăm să folosiți pentru compilarea și rularea task-urilor sbatch sau Makefile_Cluster

Resurse

Schelet Laborator 7

Indicații pentru asistenți
Soluție Laborator 7

Enunt Laborator 7

- Responsabili laborator: Grigore Lupescu, Stefan-Dan Ciocîrlan, Costin Carabaș

Referinte

- Documentatie CUDA:
 - CUDA C Programming [https://docs.nvidia.com/pdf/CUDA_C_Programming_Guide.pdf]
 - CUDA NVCC compiler [https://docs.nvidia.com/cuda/pdf/CUDA_Compiler_Driver_NVCC.pdf]
 - CUDA Visual Profiler [<https://docs.nvidia.com/cuda/profiler-users-guide/index.html>]
 - CUDA 9.1 Toolkit [https://developer.download.nvidia.com/compute/cuda/9.1/Prod/docs/sidebar/CUDA_Toolkit_Release_Notes.pdf]
 - CUDA GPUs [<https://developer.nvidia.com/cuda-gpus>]
- Acceleratoare hpsl (hpsl-wn01, hpsl-wn02, hpsl-wn03)
 - NVIDIA Tesla K40M [<http://international.download.nvidia.com/tesla/pdf/tesla-k40-passive-board-spec.pdf>]
 - NVIDIA Tesla [https://en.wikipedia.org/wiki/Nvidia_Tesla]
- Acceleratoare dp (dp-wn01, dp-wn02, dp-wn03, dp-wn04)
 - NVIDIA Tesla C2070 [https://www.nvidia.com/docs/IO/43395/NV_DS_Tesla_C2050_C2070_jul10_lores.pdf]
 - NVIDIA Tesla 2050/2070 [https://www.nvidia.com/docs/IO/43395/nv_ds_tesla_c2050_c2070_apr10_final_lores.pdf]
 - NVIDIA CUDA Fermi/Tesla [https://cseweb.ucsd.edu/classes/fa12/cse141/pdf/09/GPU_Gahagan_FA12.pdf]
- Advanced CUDA
 - CUDA Streams [<https://devblogs.nvidia.com/gpu-pro-tip-cuda-7-streams-simplify-concurrency/>]
 - CUDA Dynamic Parallelism [<https://devblogs.nvidia.com/introduction-cuda-dynamic-parallelism/>]
- Extra
 - CUDA Thread Basics [<http://www-personal.umich.edu/~smeyer/cuda/grid.pdf>]
 - An Even Easier Introduction to CUDA [<https://devblogs.nvidia.com/even-easier-introduction-cuda/>]
 - Supercomputing 2011 Tutorial [<https://www.nvidia.com/docs/IO/116711/sc11-cuda-c-basics.pdf>]