

Multiprocesorski sistemi

Domaći zadatak 4

CUDA – osnove

(10 poena)

Uvod

Cilj zadatka je da studente obuči da samostalno razvijaju osnovne CUDA programe za izvršavanje na grafičkom procesoru.

Podešavanje okruženja

Detaljna uputstva za instaliranje, podešavanje i prvo izvršavanje CUDA programa se mogu naći na adresi <http://developer.nvidia.com/nvidia-gpu-computing-documentation> ili na sajtu predmeta pod nazivom CUDA Getting Started Guide (Windows) ili CUDA Getting Started Guide (Linux) u zavisnosti koji operativni sistem se koristi. Po tom uputstvu podesiti okruženje za razvoj i kontrolisano izvršavanje (engl. debugging) CUDA programa na lokalnom računaru. Alternativno, koristiti CUDA (**nvcc**) na računaru **rtidev5.etf.rs**. Prevodilac se nalazi u direktorijumu: **/usr/local/cuda/bin/**.

Izveštaj

Uz predati domaći zadatak (izvorne kodove) treba napisati i priložiti kratak izveštaj o izvršenoj paralelizaciji i dobijenim ubrzanjima u odnosu na sekvencijalnu verziju koda. Za svaki rešeni zadatak treba kratko opisati uočena mesta koja je moguće paralelizovati i način paralelizacije. Takođe, potrebno je dati logove izvršenog koda za sve test primere koji se izvršavaju i nalaze se u **run** datoteci i nacrtati grafike ubrzanja u odnosu na sekvencijalnu verziju. Na graficima je potrebno dati i rezultate poređenja različitih načina paralelizacije za isti broj niti, ukoliko postoje takvi zahtevi u okviru teksta zadatka. Šablon za pisanje izveštaja se nalazi u okviru sekcije za domaće zadatke predmetnog sajta.

Zadaci

Svi programi treba da koriste GPU za bilo koju obradu. Smatrati da je broj GPU niti na nivou jednog bloka niti određen konstantom **NUM_OF_GPU_THREADS**, čija je vrednost za sve zadatke 1024. Obezbediti da niti koje u nekom koraku nemaju posla na korektan način stignu do kraja tela CUDA jezgra.

Kod zadatka gde je to zahtevano, korisnik zadaje samo dimenzije nizova/matrica, a sve potrebne ulazne podatke generisati u operativnoj memoriji uz pomoć generatora slučajnih brojeva iz biblioteke jezika C, a zatim prebaciti u GPU memoriju. Generisani brojevi treba da budu odgovarajućeg tipa u opsegu od **-MAX** do **+MAX**, gde **MAX** ima vrednost 1024. Za sve zadatke je potrebno napisati ili iskoristiti zadatu sekvencijalnu (CPU) implementaciju odgovarajućeg problema koja će biti korišćena kao referentna (*gold*) implementacija prilikom testiranja programa.

Svaki program treba da:

- Generiše ili koristi već obezbeđene ulazne test primere.
- Kopira test primere u GPU memoriju i rezultat iz GPU memorije.
- Izvrši CUDA jezgro nad zadatim test primerom.
- Izvrši sekvencijalnu implementaciju nad zadatim test primerom.
- Ispiše vreme izvršavanja CUDA i sekvencijalne implementacije problema.
- Uporedi rezultat CUDA i sekvencijalne implementacije problema.
- Ispiše "**Test PASSED**" ili "**Test FAILED**" u zavisnosti da li se rezultat izvršavanja CUDA implementacije podudara sa rezultatom izvršavanja sekvencijalne implementacije.

Kod zadataka koji koriste realne tipove (**float**, **double**) tolerisati maksimalno odsupanje od $\pm \text{ACCURACY}$ prilikom poređenja rezultata CPU i GPU implementacije. Smatrati da konstanta **ACCURACY** ima vrednost 0.01. **Prilikom rešavanja zadataka voditi računa da se postigne maksimalni mogući paralelizam.** Dozvoljeno je ograničeno preuređivanje dostupnih sekvencijalnih implementacija prilikom paralelizacije. **Ukoliko u nekom zadatku nešto nije dovoljno precizno definisano, student treba da uvede razumnu pretpostavku i da nastavi da izgrađuje svoje rešenje na temeljima uvedene pretpostavke.**

Dostupne sekvencijalne implementacije se nalaze u arhivi **MPS_DZ4_CUDA.zip** ili **MPS_DZ4_CUDA.tar.bz2** koje se mogu preuzeti na adresi <http://mups.etf.rs/dz/2019-2020/>. Na **rtidev5.etf.rs** računaru arhiva se može dohvatiti i raspakovati sledećim komandama:

Dohvatanje: `wget http://mups.etf.rs/dz/2019-2020/MPS_DZ4_CUDA.tar.bz2`

Raspakivanje: `tar xjvf MPS_DZ4_CUDA.tar.bz2`

1. Paralelizovati program koji formira sliku tačaka koje pripadaju Julia skupu tačaka (https://en.wikipedia.org/wiki/Julia_set). Neka se posmatra skup tačaka (x, y) u na pravougaonom domenu $x, y \in [-1,5, 1.5]$ i neka važi $z = x+yi$. Julia skup je skup tačaka za koji iteracija $z = z^2 + c$ ne divergira za određene zadate početne uslove. U zadanom programu početni uslov odgovara $c = -0.8 + 0.156i$. Ukoliko u bilo kom trenutku važi $1000 < |z|$, smatra se da tačka z ne pripada Julia skupu. Program formira sliku u *Targa* (.tga) formatu koja se može otvoriti u nekom od namenskih pregledača slika. Program se nalazi u datoteci **julia.c** u arhivi koja je priložena uz ovaj dokument, dok se primeri izlaznih datoteka nalaze u direktorijumu **output**. Program testirati sa parametrima koji su dati u datoteci **run**.
2. Paralelizovati program koji izoštrava zadanu sliku u *Portable Graymap Format* (PGM) formatu. PGM format se može otvoriti u nekom od namenskih pregledača slika ili *online* na adresi <http://paulcuth.me.uk/netpbm-viewer/>. Program se nalazi u direktorijumu **sharpen** u arhivi koja je priložena uz ovaj dokument. Program se sastoji od više datoteka, od kojih su od interesa datoteke **sharpen.c**, **dosharpen.c** i **filter.c**. Obratiti pažnju na mogućnost korišćenja deljene memorije radi ubrzavanja pristupa podacima. Koristiti 2D organizaciju jezgra. Program testirati sa parametrima koji su dati u datoteci **run**.
3. Paralelizovati program koji vrši mapiranje neuniformnih podataka u 3D prostoru na regularnu mrežu u 3D prostoru. Svaka tačka iz neuniformnog 3D prostora doprinosi susednim tačkama u regularnoj mreži u skladu sa *Kaiser-Bessel* funkcijom za određivanje rastojanja. Program se nalazi u direktorijumu **mri-gridding** u arhivi koja je priložena uz ovaj dokument. Program se sastoji od više datoteka, od kojih su od interesa datoteke **main.c** i **CPU_kernels.c**. Analizirati dati kod i obratiti pažnju na način generisanja vrednosti tačaka u regularnoj mreži. Obratiti pažnju na efikasnost paralelizacije, mogućnost upotrebe deljene memorije i potrebu za redukcijom. Ulazni test primeri se nalaze u direktorijumu **data**. Verifikaciju paralelizovanog rešenja vršiti nad nizovima **gridData** i **sampleDensity** iz glavnog programa. Način pokretanja programa se nalazi u datoteci **run**.