

Multiprocesorski sistemi

Domaći zadatak 4
Školska godina 2024/2025
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>. Po tom uputstvu podešiti 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 direktoriju: `/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 sekvensijalnu 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 sekvensijalnu 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 zadataka gde je to zahtevano, korisnik zadaje samo dimenzije nizova/matrice, 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 sekvensijalnu (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 sekvensijalnu implementaciju nad zadatim test primerom.
- Ispiše vreme izvršavanja CUDA i sekvensijalne implementacije problema.
- Uporedi rezultat CUDA i sekvensijalne implementacije problema.
- Ispiše "`Test PASSED`" ili "`Test FAILED`" u zavisnosti da li se rezultat izvršavanja MPI implementacije podudara sa rezultatom izvršavanja sekvensijalne implementacije.

Kod zadataka koji koriste realne tipove (**float**, **double**) tolerisati maksimalno odsupanje od **±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 sekvensijalnih 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 sekvensijalne implementacije se nalaze u arhivi **MPS_DZ.tar.gz** koje se mogu preuzeti na adresi <http://mups.etf.rs/dz/2024-2025/>. Na **rtidev5.etf.rs** računaru arhiva se može dohvatiti i raspakovati sledećim komandama:

Dohvatanje: `wget http://mups.etf.rs/dz/2024-2025/MPS_DZ.tar.gz`

Raspakivanje: `tar xjvf MPS_DZ.tar.gz`

- Paralelizovati program koji vrši jednostavno generalizovano množenje matrica u jednostrukoj preciznosti *Single precision floating General Matrix Multiply* (SGEMM). SGEMM operacija je definisana sledećom formom:

$$C \leftarrow \alpha \cdot A \cdot B + \beta \cdot C$$

Program se nalazi u datoteci **sgemm.cc** u arhivi koja je priložena uz ovaj dokument. Program testirati sa parametrima koji su dati u **run** skripti.

Prilikom zadavanja izvršne konfiguracije jezgra, koristiti 1D rešetku (grid).

- Paralelizovati program koji izračunava aproksimaciju integrala koristeći [Gauss-Laguerre kvadraturno pravilo](#). Po ovom pravilu, integral oblika:

$$\int_a^{\infty} e^{-b(x-a)} f(x) dx$$

se aproksimira sumom:

$$\sum_{i=1}^{order} \omega(i) \cdot f(x(i))$$

gde su $\omega(i)$ težinski koeficijenti, a $x(i)$ odgovarajuće čvorne tačke.

Program se nalazi u direktorijumu **gauss_laguerre** u arhivi koja je priložena uz ovaj dokument. Program testirati sa parametrima koji su dati u **run** skripti.

- Paralelizovati program koji vrši statističku analizu prostorne distribucije posmatranih astronomskih tela korišćenjem tzv. *two point angular correlation function* ([TPACE](#)). Algoritam proračunava uglovne distance između svih parova tačaka (tela) sa ulaza i generiše histogram posmatranih distanci.

Program se nalazi u direktorijumu **tpacf** u arhivi koja je priložena uz ovaj dokument. Program se sastoji od više datoteka, od kojih su od interesa datoteke **main.c** i **model_compute_cpu.c**. Analizirati dati kod i obratiti pažnju na algoritam za izračunavanje distanci unutar datoteke **model_compute_cpu.c**. Program testirati sa parametrima koji su dati u **run** skripti.