Multiprocesorski sistemi

Paralelni algoritmi na CUDA

Marko Mišić

13S114MUPS, 13E114MUPS

2019/2020.

Paralelni algoritmi na grafičkom procesoru (1)

- Grafički procesor je *data-parallel* orijentisan
  - Vise hiljada niti se izvršava u paraleli
  - Vise hiljada elemenata se obrađuje
  - Sve podatke obrađuje isti program
    - SPMD model izvršavanja
  - Kontrast u odnosu na *task-parallel* model i paralelizam na nivou instrukcije (ILP)
- Način razmišljanja mora biti drugačiji i orijentisan ka podacima:
  - Algoritmi se moraju dizajnirati za paralelizam na nivou podataka
  - Potrebno je koristiti *data-parallel* primitive kao gradivne elemente za efikasno programiranje
  - Potrebno je razumeti složenost paralelnih algoritama

Paralelni algoritmi na grafičkom procesoru (2)

- Ključni koraci u paralelnom programiranju:
  - Pronaći konkurentnost u problemu
  - Strukturirati algoritam
    tako da se konkurentnost prevede u performanse
  - Implementirati algoritam u pogodonom programskom okruženju
  - Izvršiti program i podesiti performanse koda
    na stvarnom paralelnom sistemu
- Na žalost, ovi koraci nisu podeljeni u nivoe apstrakcije kojima bi mogli da se bavimo nezavisno jednim od drugih

Problemi paralelnih algoritama

- Performanse mogu biti drastično umanjeno zbog velikog broja faktora:
  - Režijskog vremena potrebnog za sprovođenje paralelnog procesiranja
  - Disbalansa u opterećenju među procesnim elementima
  - Neefikasnim obrascima deljenja podataka
  - Zasićenja kritičnih resursa
    - Kao što je memorijski propusni opseg
- Pronalaženje i iskorišćavanje paralelizma često zahteva razmatranje problema iz ugla koji nije očigledan na prvi pogled
  - *Computational thinking*

Podeli i sumiraj

- *Partition and Summarize*
  - Česta algoritamska strategija za procesiranje velikih skupova podataka na GPU
  - Nalikuje *MapReduce* radnom okviru za distribuiranu obradu
- Tehnika podrazumeva da:
  - Ne postoji neki zahtevani poredak obrade elemenata u skupu
    - Operacije koje se sprovode su asocijativne i komutativne
  - Skup podataka se deli na manje celine (*chunks*)
  - Jedna nit obrađuje jednu celinu
  - Redukciono stablo se koristi da se rezultati kombinuju u krajnji rezultat
- Poslednji korak je tipično najvažniji u efikasnoj implementaciji na GPU

Operacija redukcije (1)

- Tipična operacija koja se javlja u paralelnim algoritmima je operacija redukcije
  - Kao što su algoritmi sa logikom *Partition and Summarize*
- Redukcija prodrazumeva svođenje niza vrednosti na jednu skalarnu vrednost
  - Računanje zbira, proizvoda, makismuma, minimuma, logičko I/ILI nad svim elementima strukture i sl.
  - Upotreba dobro definisane jedinične vrednosti
- Podrazumeva se da je operator koji se upotrebljava u redukciji asocijativan
  - Tehnički, to ne mora biti tačno za aritmetiku u pokretnom zarezu
    - U ovom slučaju treba biti pažljiv

Operacija redukcije (2)

- Radukcije se koriste u velikom broju primena, mada ne obavezno u paralelnoj formi
  - Kod množenja matrice, pojedinačna nit je vršila redukciju prilikom računanja skalarnog proizvoda vrste i kolone matrice
- Redukcija je potrebna zbog određenih transformacija koje se obavljaju prilikom paralelizacije koda
  - Tipičan primer je privatizacija izlazne lokacije, kako bi se smanjila potreba za sinhronizacijom
  - Umesto da više niti dodaje svoj rezultat u istu lokaciju, svaka nit dobija svoju privatnu lokaciju
  - Konačan rezultat se dobija kombinovanjem vrednosti privatnih lokacija putem redukcije

Sekvencijalna redukcija

- Inicijalizuje se rezultat jediničnom vrednošću redukcione operacije
  - 0 za zbir
  - 1 za proizvod
  - Najmanja ili najveća vrednost za max i min
- Iterira se kroz ulazni niz i sprovodi se redukciona operacija nad rezultatom i trenutnom vrednošću elementa na ulazu
  - Sprovodi se N redukcionih operacija za N ulaznih vrednosti
  - Složenost O(n)
  - Računski efikasan algoritam

Paralelna redukcija (1)

- Neefikasan način da se ovo obavi na GPU predstavlja sledeći kod:
  - Nit 0 iz bloka sabira elemente sekvencijalno
  - Ostale niti ne rade ništa

```
if (threadID == 0) {
   float sum = 0;
   for (int t = 0; t < n; ++t)
         sum += array[t];
}
```

Paralelna redukcija (2)

- Da bismo izvršili redukciju N elemenata u paraleli, možemo koristiti princip stabla
  - Redukcija se vrši kroz N-1 operaciju u log(N) koraka

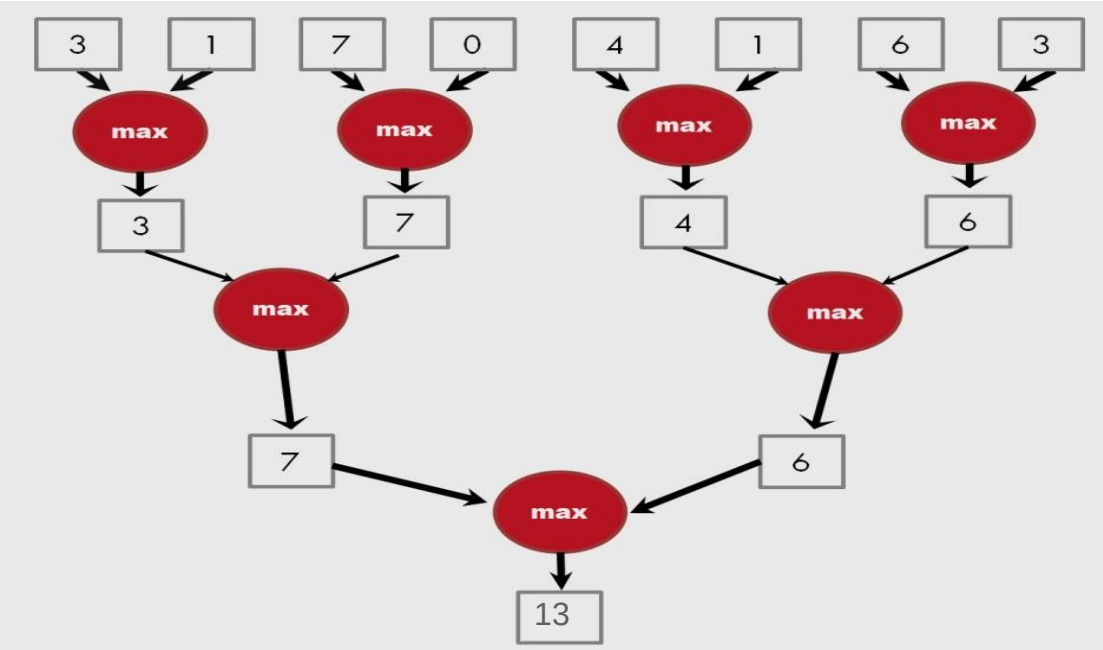

Složenost paralelne redukcije

- Redukcija se obavlja u *log(N)* paralelnih koraka
  - U svakom koraku *S*,
    izvršava se *N/2S* paralelnih operacija
- Za $N=2^D$, izvršava se $\sum_{S\in[1..D]}2^{D-S} = N-1$ operacija
  - Algoritam je računski efikasan, jer ne izvršava
    više operacija nego sekvencijalna redukcija
- Sa *P* niti fizički u paraleli,
  vremenska složenost je *O(N/P + log N)*
  - U poređenju sa *O(N)* za sekvencijalnu redukciju

Paralelna redukcija na GPU (1)

- Primer sumiranja elemenata vektora
  - Vektor se nalazi u globalnoj memoriji uređaja
  - Dužina je deljiva veličinom bloka niti
- Prikazujemo redukciju na nivou bloka niti
  - Rekurzivno se deli broj niti na pola u svakom koraku
  - Sumiraju se dve vrednosti na nivou niti u svakom koraku
- Finalna redukcija se može uraditi ponovnim pozivanjem jezgra ili na domaćinu

Paralelna redukcija na GPU (2)

- Redukcija se obavlja *in-place* korišćenjem deljene memorije
  - Pretpostavimo da se vektor nalazi u globalnoj memoriji uređaja
  - Koristi se deljena memorija za smeštanje međurezultata (vektora parcijalnih suma)
  - U svakoj iteraciji dobija se vektor parcijalnih suma
    - U svakom koraku smo bliži konačnom rezultatu
  - Finalni rezultat se smešta u element 0 u deljenoj memoriji

Paralelna redukcija na GPU (3)

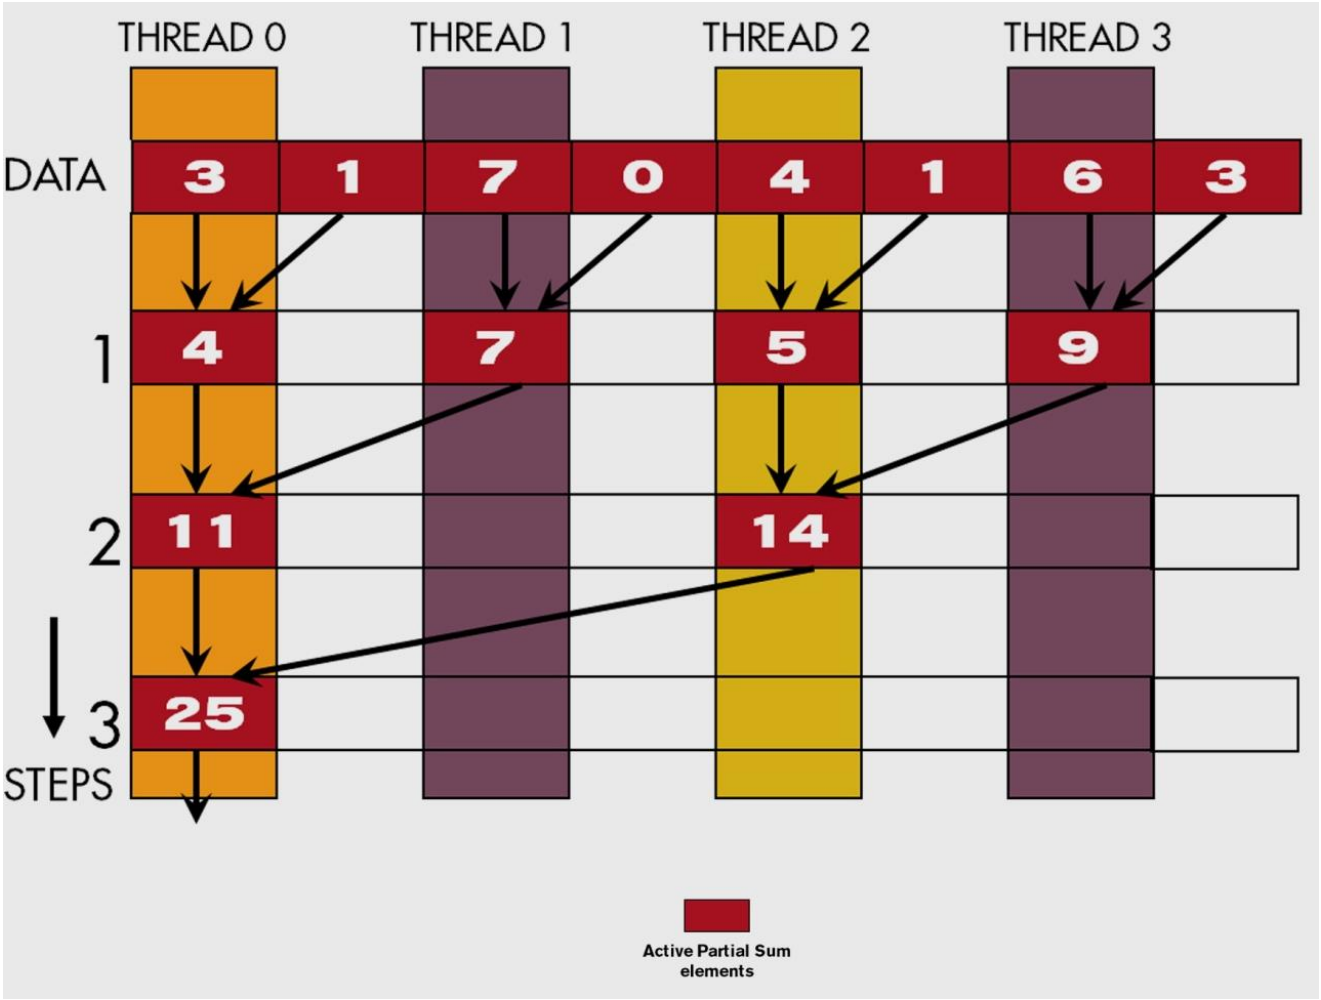

Paralelna redukcija na GPU (4)

- U primeru sa slike:
  - Svaka nit je odgovorna za jednu (izlaznu) lokaciju sa parnim indeksom u vektoru parcijalnih suma
  - Nakon svakog koraka redukcije, polovina niti više nije potrebna
  - Jedna od ulaznih lokacija za svaku aktivnu nit je uvek jedna od izlaznih lokacija iz prethodnog koraka
  - U svakom koraku se distanca između ulaznih elementa svake aktivne niti povećava
- Naivna implementacija redukcije

Naivna paralelna redukcija (1)

```
__global__ void reduce(int *g_idata, int *g_odata) {
  extern __shared__ int sdata[];

  // Load shared mem
  unsigned int tid = threadIdx.x;
  unsigned int i = blockIdx.x * blockDim.x + threadIdx.x;
  sdata[tid] = g_idata[i];

  // Do reduction in shared memory
  for (unsigned int stride = 1; s < blockDim.x; s *= 2) {
    __syncthreads();
    int index = 2 * stride * tid;
    if (index < blockDim.x) {
      sdata[index] += sdata[index + stride];
    }
  }

  // Thread 0 writes result for this block to global mem
  if (tid == 0) g_odata[blockIdx.x] = sdata[0];
}
```

Memorijski konflikt

Naivna paralelna redukcija (2)

- Dešavaju se konflikti u deljenoj memoriji
  - Dešava se simultani pristup kod indeksiranja niza i to dva puta
  - Prvi pristup (`sdata[index]`)

Naivna paralelna redukcija (3)

- Drugi simultani pristup (**`sdata[index + stride]`**)

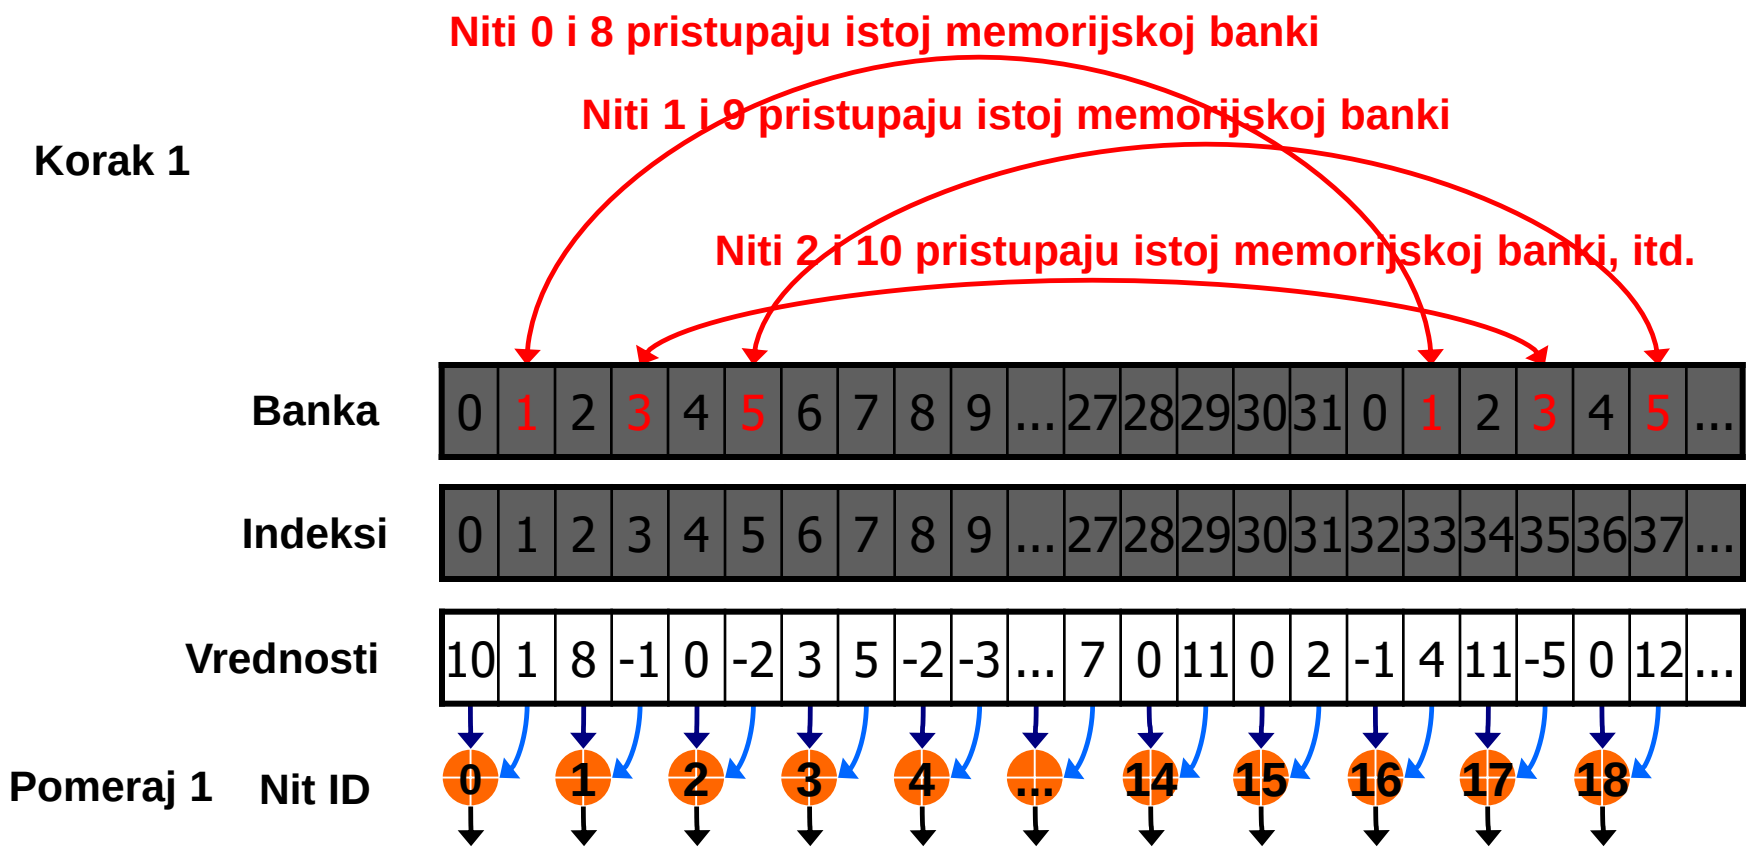

Naivna paralelna redukcija (4)

- Prvi simultani pristup (**`sdata[index]`**)
  - 4-ostruki konflikt

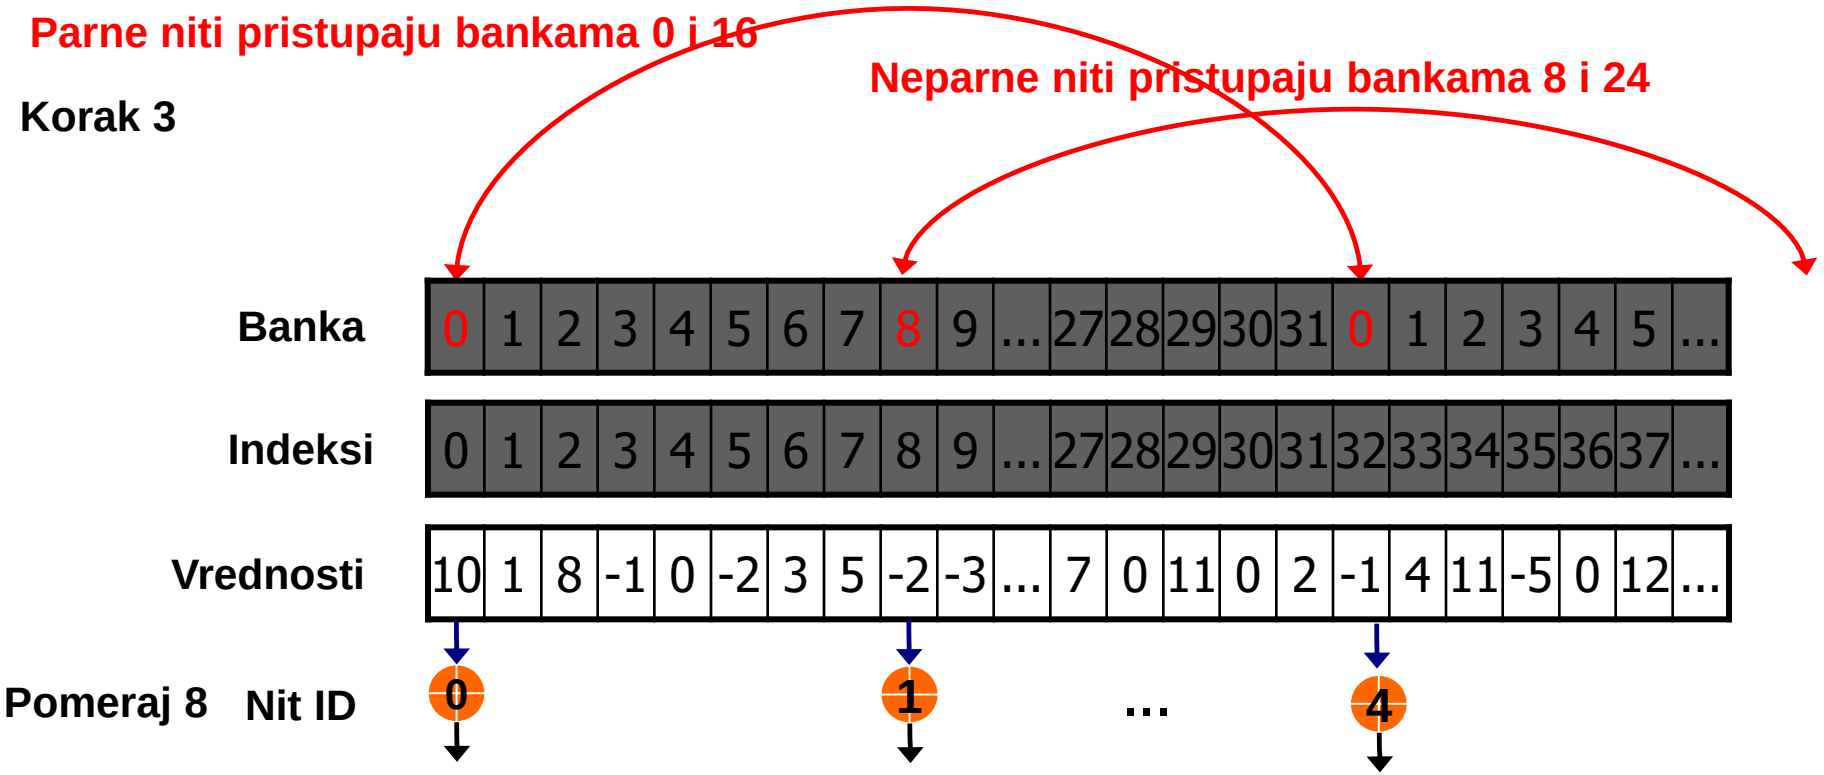

Redukcija bez konflikta (1)

- Korektna implementacija bez memorijskih konflikta:

```
for (int s = 1; s < blockDim.x; s *= 2) {
    __syncthreads();
    if (threadIdx.x % (2 * s) == 0)
        sdata[threadID] += sdata[threadIdx.x + s];
}
```

- Problem je veliki broj divergentnih *warp*-ova prilikom izvršavanja ovakvog koda
  - Polovina niti (parne niti) će biti aktivna, a polovina ne (neparne niti)
  - Ukoliko postoje grananja unutar *warp*-a, sve niti će izvršiti sve putanje, što dovodi do usporenja

Redukcija bez konflikta (2)

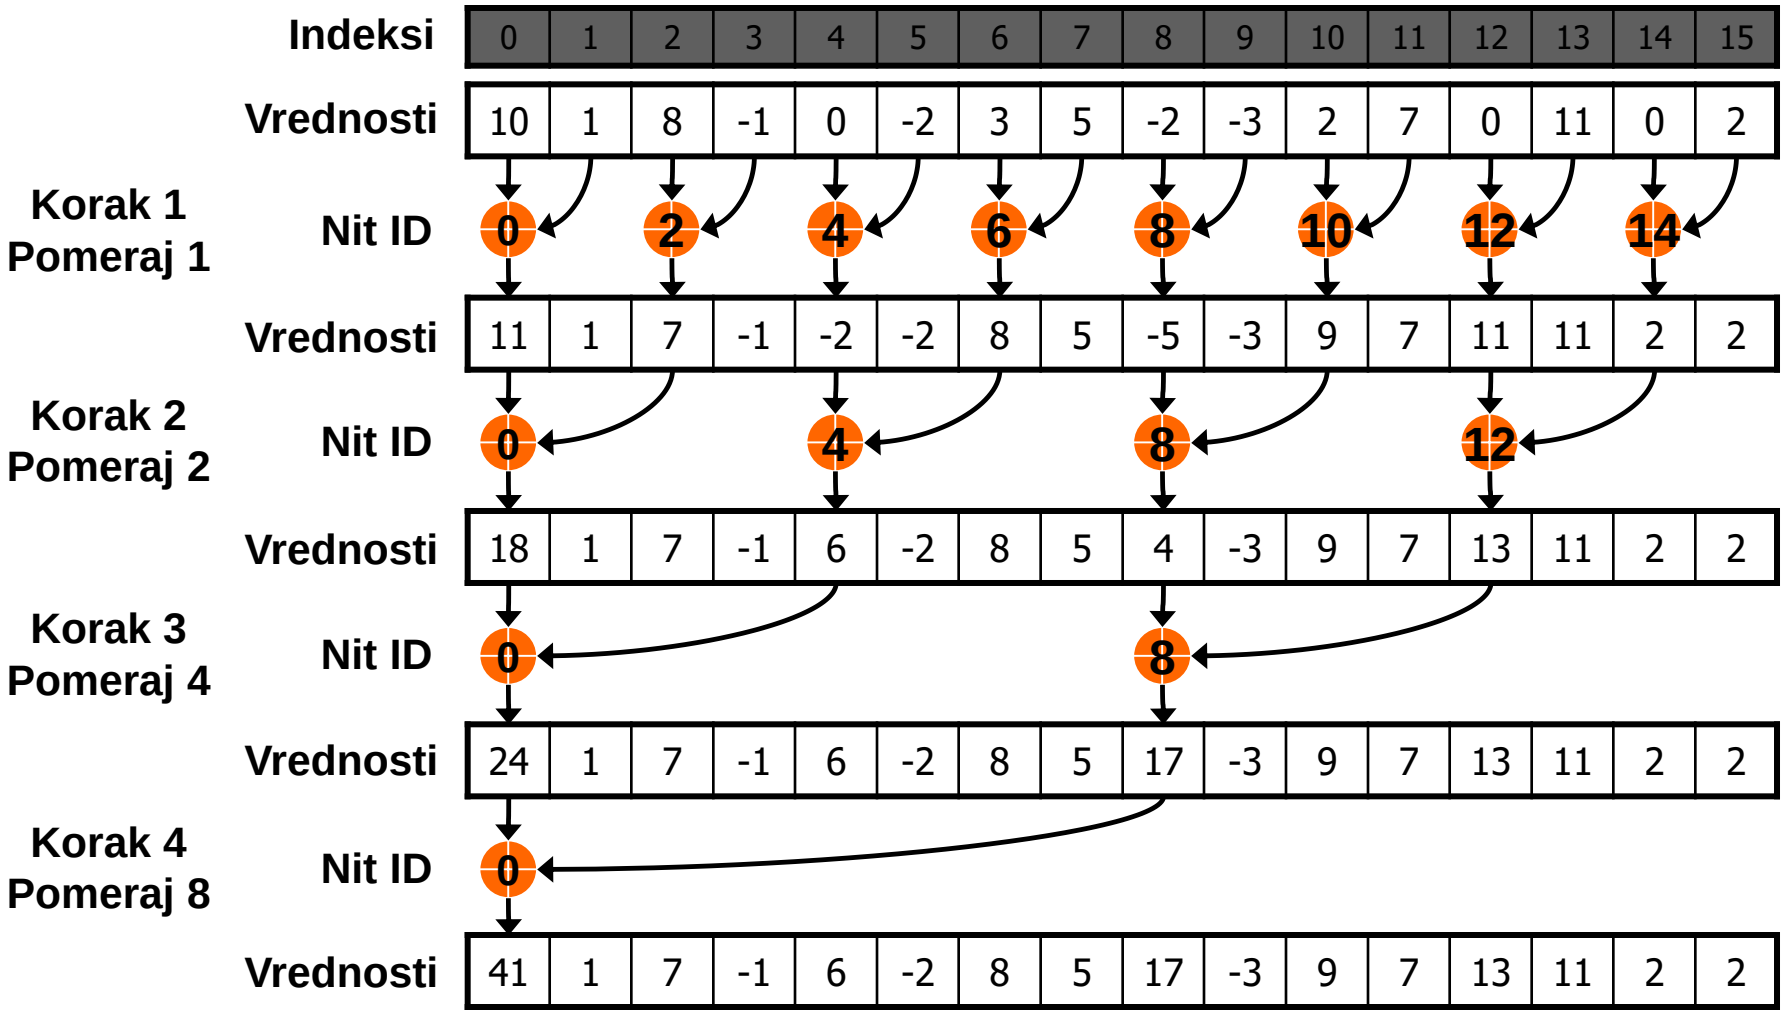

Bolje rešenje redukcije (1)

- Prethodna rešenja iskazuju sledeće probleme:
  - Memorijske konflikte (prvo rešenje)
  - Divergenciju u kontroli toka
  - Slabo iskorišćenje resursa
    - Većina niti u *warp*-u prestaje da bude aktivna posle nekoliko koraka
  - Polovina niti učestvuje samo u učitavanju podataka
    - Blok podataka redukuje efektivno N/2 niti

Bolje rešenje redukcije (2)

- Bolje rešenje redukcije se dobija primenom sledećih saveta:
  - Parcijalne sume treba održavati u početnim lokacijama niza
  - Aktivne niti treba da budu konsekutivne u bloku
- Ideja je da niti pristupaju nesusednim elementima u bloku koji redukuju
  - Moguće s obzirom da su redukcioni operatori komutativni i asocijativni

Bolje rešenje redukcije (3)

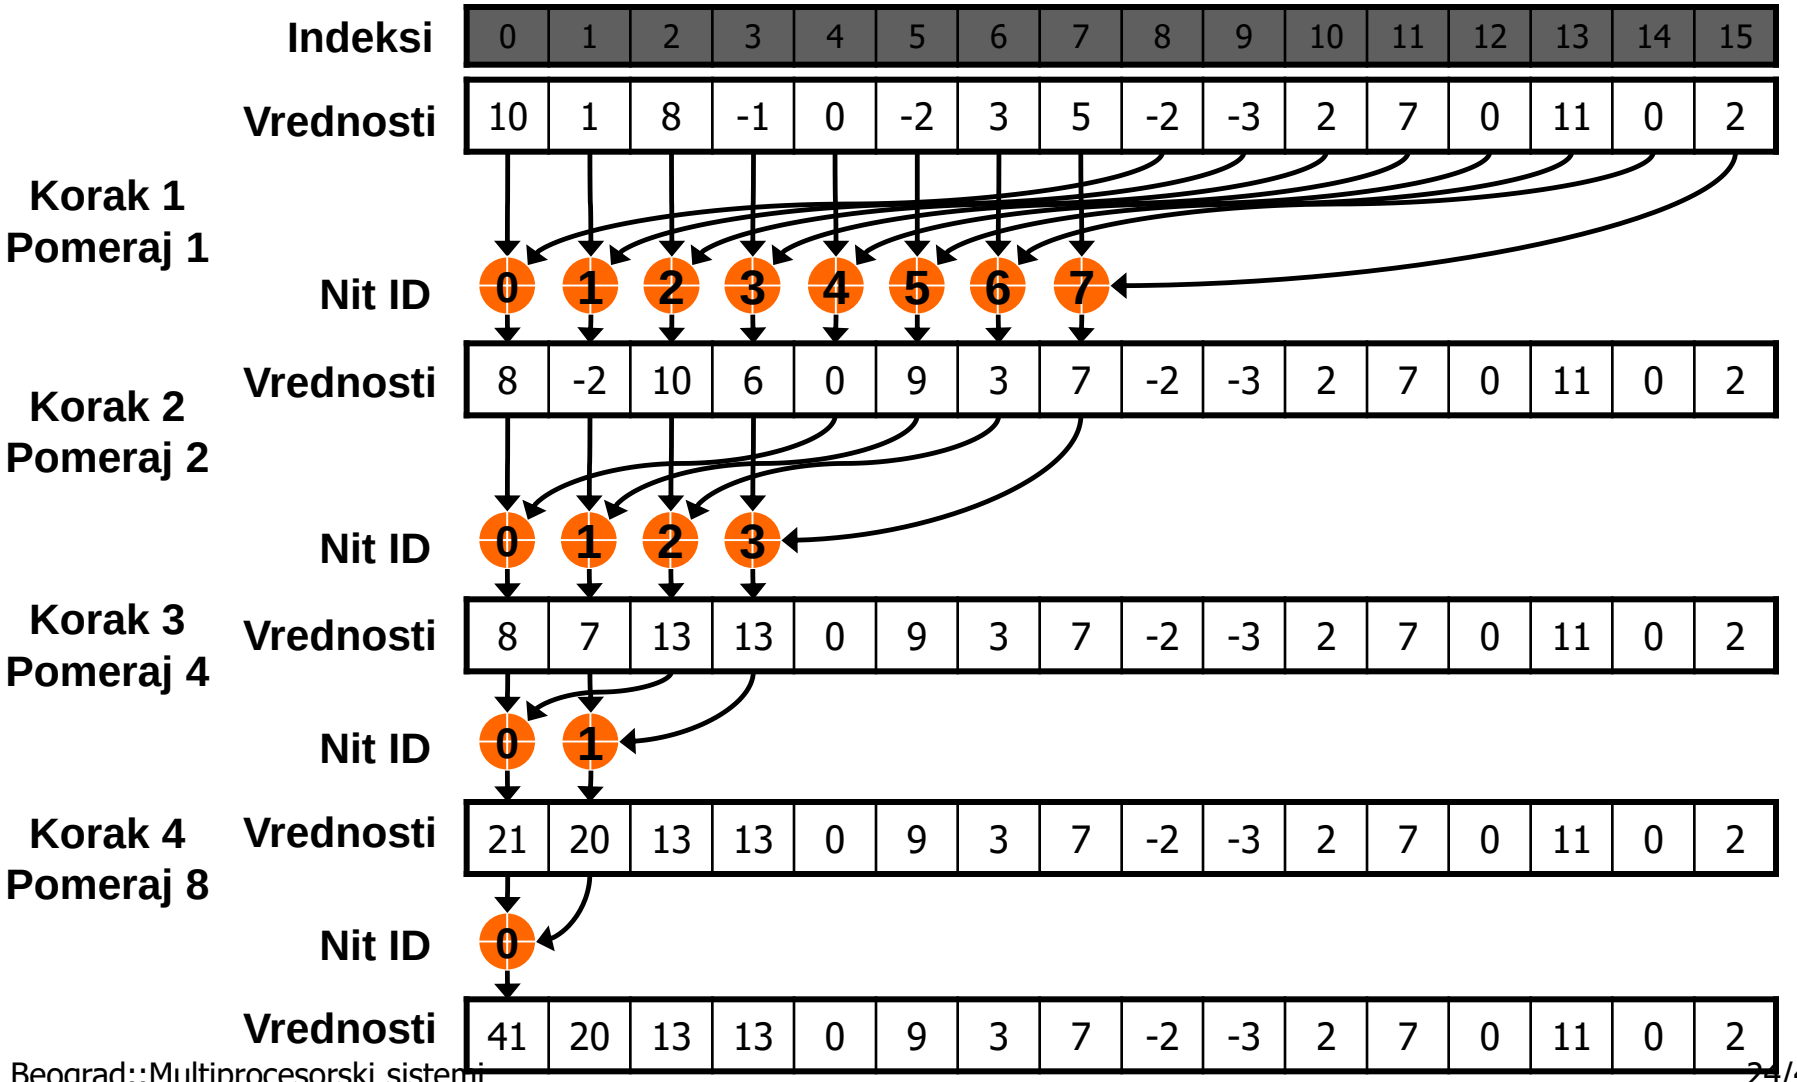

Bolje rešenje redukcije (4)

```
__global__ void reduce(int *g_idata, int *g_odata) {
    extern __shared__ int sdata[];
    // load shared mem
    unsigned int tid = threadIdx.x;
    unsigned int i = blockIdx.x * blockDim.x + threadIdx.x;
    sdata[tid] = g_idata[i];
    __syncthreads();
    // do reduction in shared mem
    for (unsigned int s = blockDim.x/2; s > 0; s >>= 1) {
        if (tid < s) {
            sdata[tid] = sdata[tid] + sdata[tid + s];
        }
        __syncthreads();
    }
    // write result for this block to global mem
    if (tid == 0) g_odata[blockIdx.x] = sdata[0];
}
```

Bolje rešenje redukcije (5)

- Treba primetiti da nakon učitavanja elementa u deljenu memoriju samo polovina niti radi redukciju:

```
for (unsigned int s = blockDim.x/2; s > 0; s >>= 1) {
  if (tid < s)
      sdata[tid] = sdata[tid] + sdata[tid + s];
  __syncthreads();
}
```

- To se može promeniti tako što će svaka nit raditi dva čitanja i prvo sumiranje u redukciji:
  - Broj blokova se tako smanjuje za pola

```
unsigned int tid = threadIdx.x;
unsigned int i = blockIdx.x*(blockDim.x*2) + threadIdx.x;
sdata[tid] = g_idata[i] + g_idata[i+blockDim.x];
__syncthreads();
```

Bolje rešenje redukcije (6)

```
__global__ void reduce(int *g_idata, int *g_odata) {
    extern __shared__ int sdata[];
    // load shared mem
    unsigned int tid = threadIdx.x;
    unsigned int i = blockIdx.x*(blockDim.x*2) + threadIdx.x;
    sdata[tid] = g_idata[i] + g_idata[i+blockDim.x];
    __syncthreads();
    // do reduction in shared mem
    for (unsigned int s = blockDim.x/2; s > 0; s >>= 1) {
        if (tid < s) {
            sdata[tid] = sdata[tid] + sdata[tid + s];
        }
        __syncthreads();
    }
    // write result for this block to global mem
    if (tid == 0) g_odata[blockIdx.x] = sdata[0];
}
```

Uklanjanje petlji (1)

- Samo jedan *warp* unutar bloka je aktivan u poslednjih nekoliko koraka redukcije
  - Broj iteracija petlje se može smanjiti i time ukloniti suvišni pozivi **`__syncthreads()`**
- Može da se uradi razmotavanje petlje
  - Poznata *loop unrolling* tehnika koju sprovode prevodioci ili programer
  - Eliminišu se skokovi u petlji ponavljanjem naredbi iz tela petlje
    - Optimizacija vreme/prostor
    - Povećava dužinu binarnog koda

Uklanjanje petlji (2)

- Razmotavaju se sve iteracije petlje u kojima učestvuje samo jedan *warp* od 32 niti

```
for (unsigned int s = blockDim.x/2; s > 32; s >>= 1) {
  if (tid < s) {
     sdata[tid] += sdata[tid + s];
  }
  __syncthreads();
}
if (tid < 32) sdata[tid] += sdata[tid + 32];
if (tid < 16) sdata[tid] += sdata[tid + 16];
if (tid <  8) sdata[tid] += sdata[tid +  8];
if (tid <  4) sdata[tid] += sdata[tid +  4];
if (tid <  2) sdata[tid] += sdata[tid +  2];
if (tid <  1) sdata[tid] += sdata[tid +  1];
```

Redukcija nad velikim nizovima (1)

- Do sada je razmatrana redukcija na nivou bloka podataka
  - Nezavisni blokovi niti redukuju jedan blok podataka iz globalne memorije
  - CUDA ne dozvoljava globalnu sinhronizaciju među blokovima
- Potreban način da niti iz različitih blokova međusobno sarađuju
  - Rešenje je iskoristiti višestruke pozive istog jezgra
  - Poziv jezgru se može posmatrati kao globalna sinhorizaciona tačka
    - Poziv jezgru troši zanemarljivo režijsko vreme
  - Nakon završetka redukcije na nivou pojedinačnih blokova, treba pozvati jezgro ponovo, sada samo sa jednim blokom
  - Alternativno, poslednji korak se može izvršiti na CPU

Redukcija nad velikim nizovima (2)

- Primer redukcije u više nivoa
  - *Tiled* algoritam
  - Svaki blok niti redukuje jedan podblok podataka iz ulaznog niza
  - Međurezultati se smeštaju u globalnu memoriju i koriste kao ulazni podaci za sledeći poziv jezgru
  - Postupak se ponavlja onoliko puta koliko je potrebno

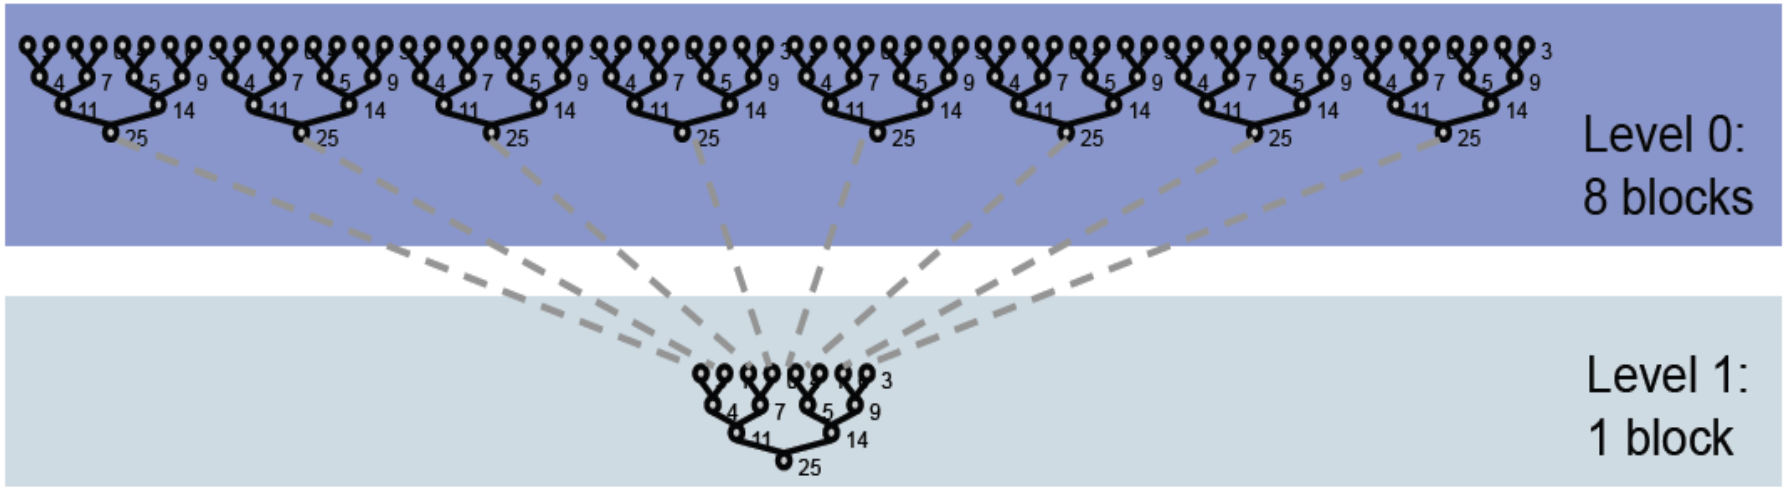

Određivanje histograma (1)

- Veoma često je potrebno odrediti statistiku pojavljivanja elemenata na skupu elemenata
  - Statistiku pojavljivanja pojedinačnih elemenata
  - Statistiku pojavljivanja elemenata klasifikovanih u određene podskupove ili opsege (*bins*)
- Bazično rešenje:
  - Koristiti niz brojača inicijalizovanih na 0
  - Za svaki element u skupu, iskoristiti vrednost da se identifikuje odgovarajući brojač koji treba inkrementirati
- Efikasno rešenje na grafičkom procesoru zahteva dosta drugačiji pristup od dosadašnjih
  - Zbog postojanja interferencije niti na izlazu

Određivanje histograma (2)

- Primer određivanja histograma stringa Programming Massively Parallel Processors
  - Pretpostaviti da svaki brojač predstavlja četiri uzastopna slova engleskog alfabeta
    - *a-d, e-h, i-l, m-p, q-t, u-x, y-z*
  - Za svaki karakter ulaznog stringa treba inkrementirati odgovarajući brojač

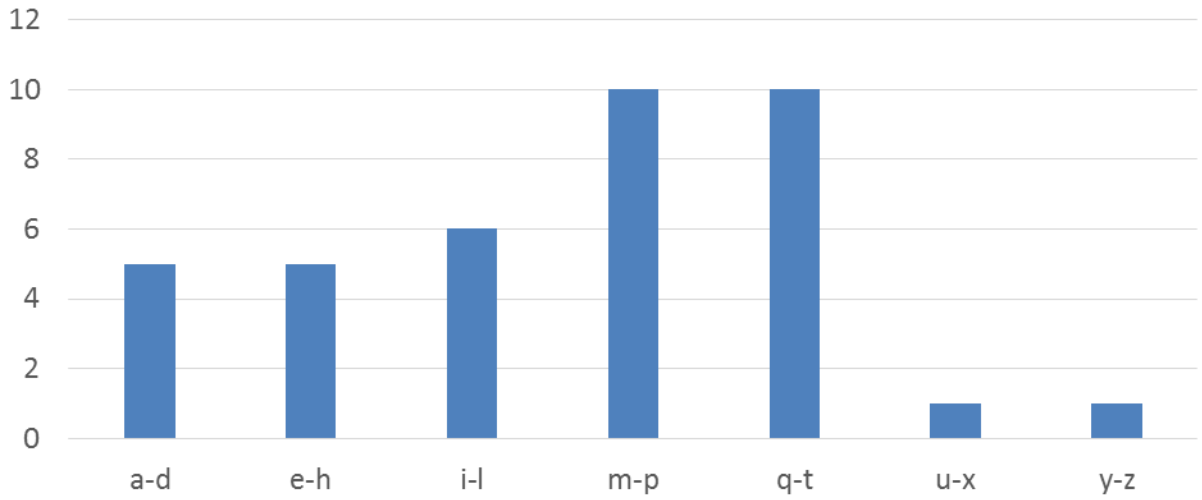

Određivanje histograma (3)

- Bazično rešenje na grafičkom procesoru
  - Podeliti ulazni niz na blokove (*tile*)
  - Jedna nit će biti zadužena za jedan element bloka
  - Nit će inkrementirati odgovarajući brojač
  - Uzastopne niti pristupaju uzastopnim elementima kako bi se obezbedio sjedinjeni pristup
  - Po potrebi, niti ponavljaju postupak

Interleaved partitioning

Određivanje histograma (4)

- Prvi blok niti

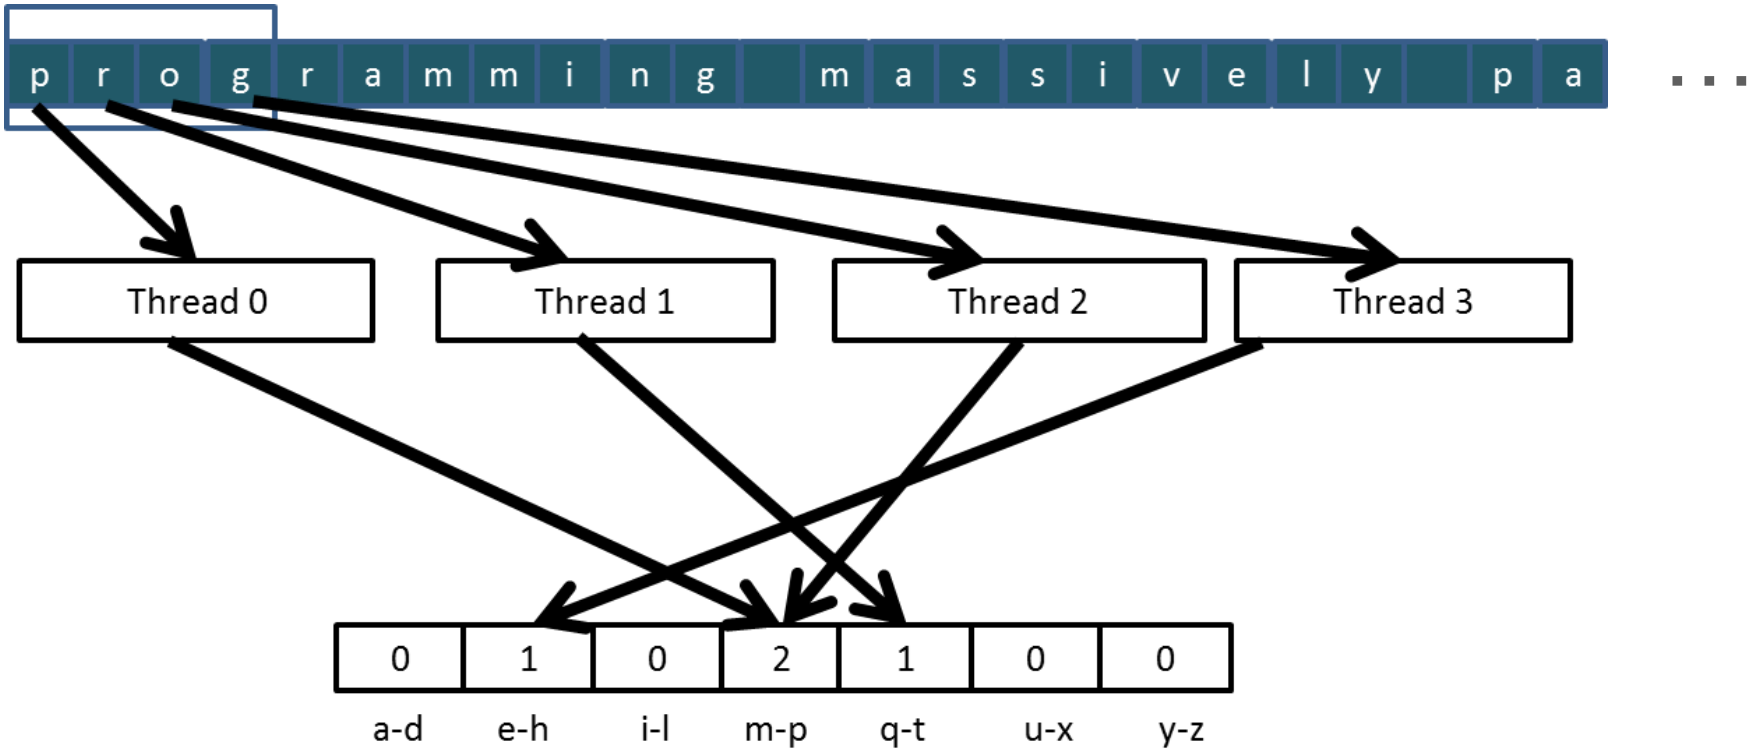

Određivanje histograma (5)

- Drugi blok niti
  - Primećuje se *race condition* problem kod pristupa brojačima!

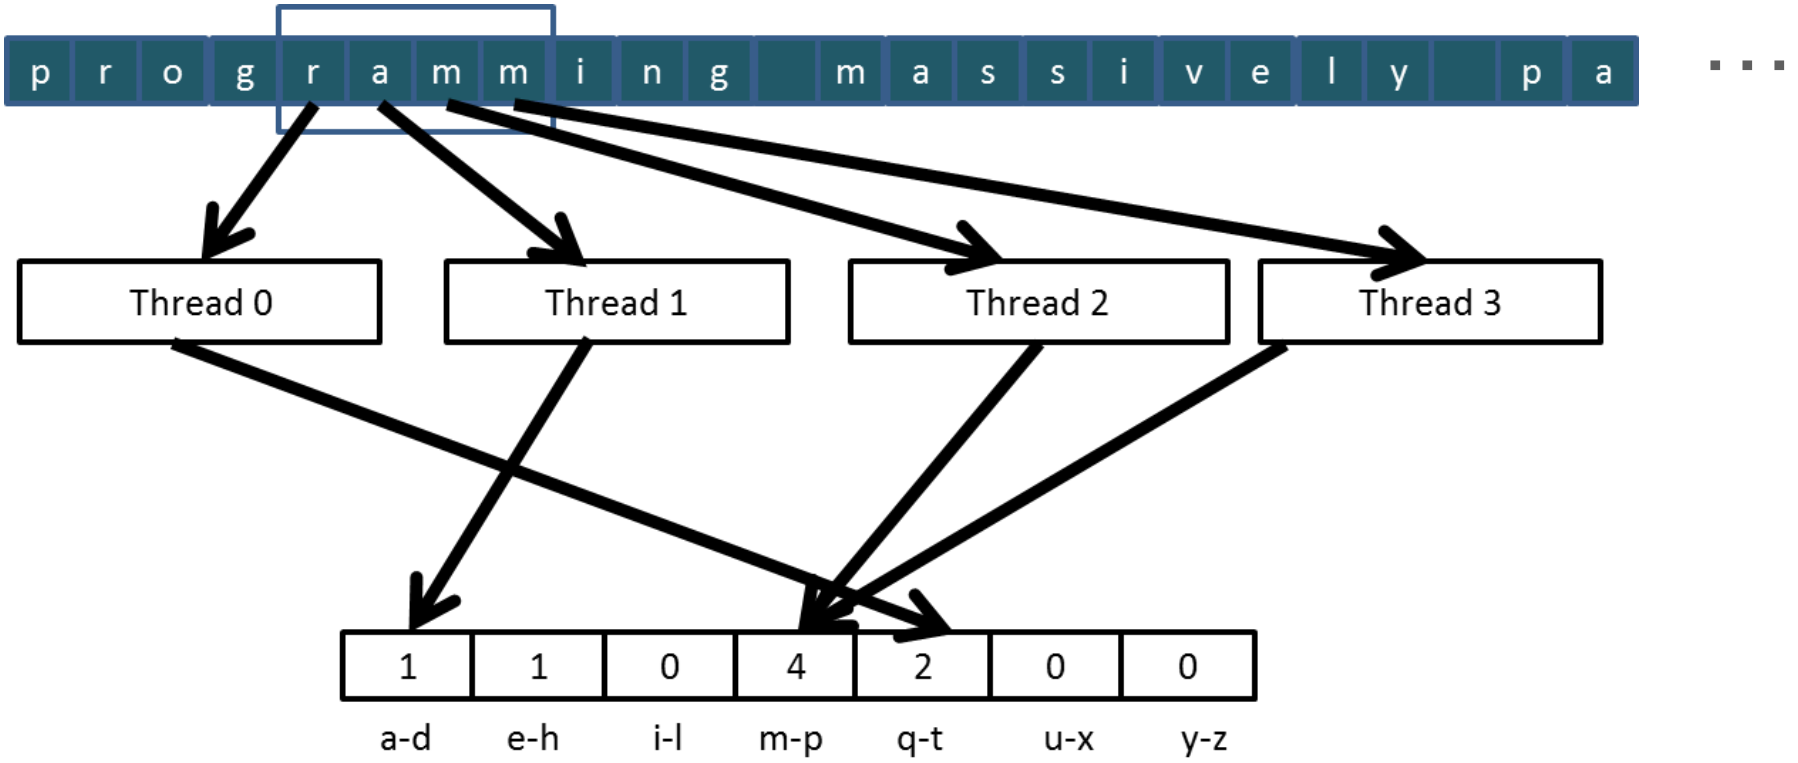

Određivanje histograma (6)

- Način podele podataka po nitima je dobar
  - Dobro se koristi propusni opseg
- Međutim, postoji utrkivanje (hazard) prilikom pristupa brojačima
  - Dešava se *Read-Modify-Write* sekvenca operacija
  - Mora se sprovesti atomično
- Rešenje je u korišćenju atomičnih operacija dostupnih u okviru CUDA jezgra
  - Na hardveru koji ih podržava

Bazično histogram jezgro (1)

```
__global__ void histo_kernel(unsigned char *buffer,
                long size, unsigned int *histo)
{
    int i = threadIdx.x + blockIdx.x * blockDim.x;

 // stride is total number of threads
    int stride = blockDim.x * gridDim.x;

 // All threads handle blockDim.x * gridDim.x
 // consecutive elements
   while (i < size) {
      int alphabet_position = buffer[i] – “a”;
      if (alphabet_position >= 0 && alpha_position < 26)
               atomicAdd(&(histo[alphabet_position/4]), 1);
       i += stride;
   }
}
```

Bazično histogram jezgro (2)

- Predstavljeno rešenje je korektno
  - Međutim, postoji nekoliko važnih nedostataka
- Atomične operacije konzumiraju značajan propusni opseg
  - Atomična operacija nad DRAM lokaciom počenje sa čitanjem koje ima kašnjenju od nekoliko stotina ciklusa
  - Atomična operacija nad DRAM lokaciom završava se pisanjem koje ima kašnjenju od nekoliko stotina ciklusa
  - U međuvremenu, nijedna nit ne može da pristupi lokaciji
- Svaka *Read-Modify-Write* sekvenca operacija prouzrokuje dvostruko kašnjenje u pristupu memoriji
  - Više pristupa istoj lokaciji prouzrokuje serijalizaciju

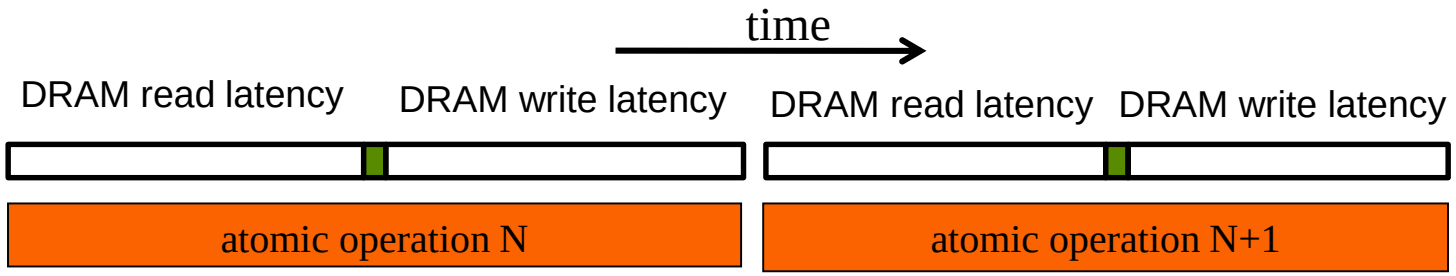

Propusni opseg atomičnih operacija

- Propusni opseg atomičnih operacija je limitiran
  - Zavisi od brzine kojom atomična operacija može da se sprovede
- Brzina sprovođenja atomične operacije je ograničena ukupnim kašnjenjem *Read-Modify-Write* sekvence operacija
  - Tipično oko 1000 ciklusa za DRAM lokaciju globalne memorije
- Hardverska poboljšanja utiču na ovu brzinu
  - Atomične operacije se značajno brže (~10 puta) nad lokacijama u L2 kešu
    - L2 keš je deljen od strane svih blokova niti na SM-u
  - Još brže se sprovode nad deljenom memorijom, što uobičajeno zahteva algoritamske promene u kodu

Bolje histogram jezgro (1)

- Rešenje za poboljšanje performansi jezgra u slučaju određivanja histograma je privatizacija izlaza
  - Tehnika privatizacije omogućava smanjivanje kašnjenja, povećanje propusnog opsega i smanjivanje serijalizacije

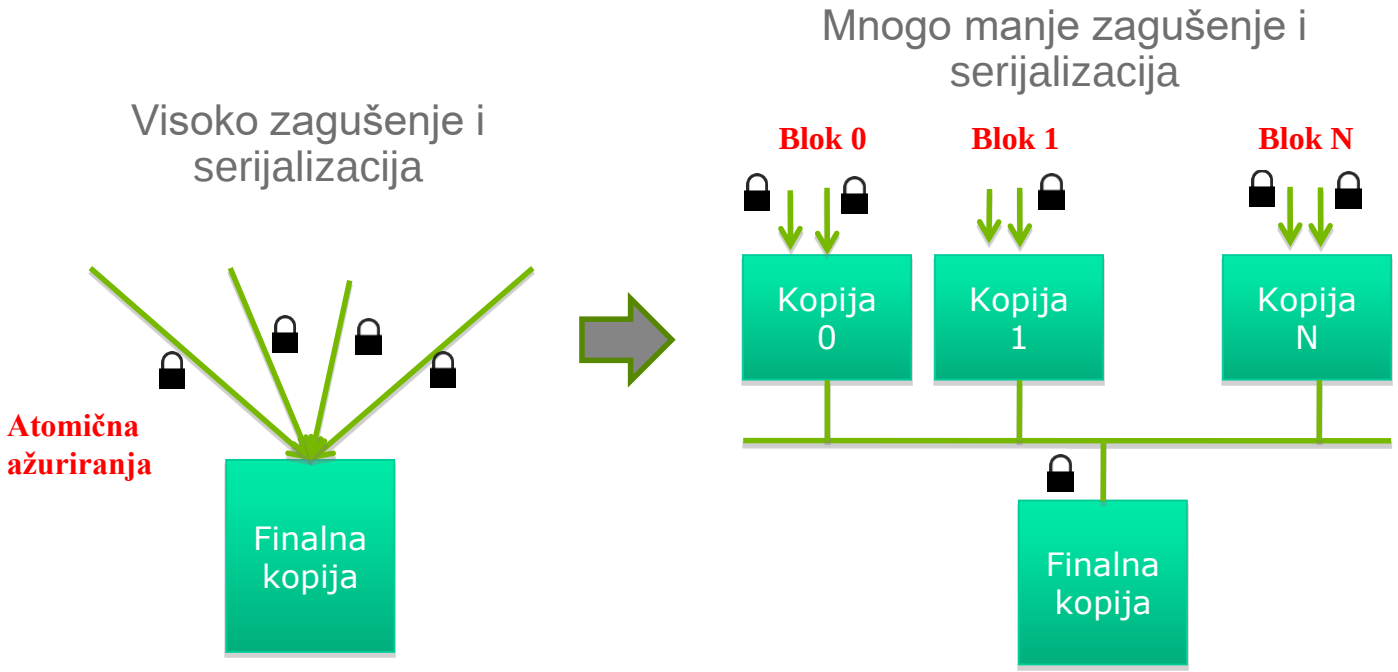

Bolje histogram jezgro (2)

- Privatizacija podataka donosi prednosti, ali i režijske troškove
  - Na GPU se privatizacija radi korišćenjem deljene memorije
- Prednosti privatizacije
  - Mnogo manje zagušenje i serijalizacija kod pristupa privatnim kopijama i finalnoj kopiji rezultata
    - Samo niti iz istog bloka pristupaju privatnim brojačima
  - Performanse mogu da se poboljšaju i do 10x
- Režijski troškovi privatizacije
  - Trošak kreiranja i inicijalizacije privatnih kopija
  - Trošak akumuliranja sadržaja privatnih kopija na globalnu kopiju sa finalnim rezultatom

Bolje histogram jezgro (3)

```
__global__ void histo_kernel(unsigned char *buffer,
                 long size, unsigned int *histo) {
   __shared__ unsigned int histo_private[7];

   if (threadIdx.x < 7) histo_private[threadidx.x] = 0;
   __syncthreads();

   int i = threadIdx.x + blockIdx.x * blockDim.x;
   // stride is total number of threads
   int stride = blockDim.x * gridDim.x;
   while (i < size) {
        atomicAdd( &(private_histo[buffer[i]/4), 1);
        i += stride;
   }
   // wait for all other threads in the block to finish
   __syncthreads();
   if (threadIdx.x < 7)
          atomicAdd(&(histo[threadIdx.x]), private_histo[threadIdx.x] );
}
```

Bolje histogram jezgro (4)

- Privatizacija je moćna i često korišćena tehnika za paralelizaciju
  - Operacija koja se sprovodi mora da bude asocijativna i komutativna
  - Računanje histograma jeste takva operacija
- Ograničenja jezgra za računanje histograma postoje
  - Privatni histogrami moraju da budu dovoljno mali da bi stali u deljenu memoriju
  - Kod velikih histograma se može primeniti delimična privatizacija histograma u deljenoj memoriji
    - Ostatak se onda nalazi u globalnoj memoriji

Literatura

- David Kirk, Wen-mei Hwu, Programming Massively Parallel Processors: A Hands on Approach, Morgan Kaufmann
- NVIDIA CUDA C Programming Guide 10.2, 2020.
- NVIDIA GPU Teaching Kit 2017
- Razni materijali i dokumentacija sa NVIDIA sajta
- http://en.wikipedia.org/wiki/GPGPU
- http://en.wikipedia.org/wiki/CUDA