4. Funkcionális primitívek GPUn

GPU API emlékeztető

Jelenleg a következő eszközök állnak rendelkezésre GPUs kódok futtatására:

- DirectX vagy OpenGL vagy Vulkan Compute Shader
  - Ez grafikai célokra van kitalálva, nem tudományos számításokra
  - Nincs teljes körű kontroll a memória elrendezés felett (nem lehet átcastolni memóriát), nincs garantálva a pontosság minden IEEE lebegőpontos műveletre
- Microsoft C++ AMP – leálltak a fejlesztéssel, csak egy demonstráció volt
- OpenMP, OpenACC és társai:
  - pragma alapú párhuzamosítás a forciklusok előtt, nem túl elegáns…
- OpenCL: A C kernelnyelv nem skálázik, összetett dolgokra és generikusságra nem alkalmas, a 2.1-be tervezett C++ kernelnyelv még sehol nincs implementálva…

GPU API emlékeztető

Jelenleg a következő eszközök állnak rendelkezésre GPUs kódok futtatására:

- Clang / GCC is tud C/C++ kódokat a megfelelő köztesekre átfordítani
- AMD HCC stack: csak AMD eszközökön működő, a C++ AMP szabvány továbbfejlesztésére épülő nyelvi kiterjesztés

Mi az alábbiakkal fogunk részletesebben foglalkozni:

- NVIDIA CUDA:
  - C++ nyelvi kiterjesztés, aktívan fejlesztik, azonban csak NVIDIA GPUkon fut (bár vannak kísérletek ennek független eszközökkel való átfordítására
- KHRONOS SYCL standard és annak a ComputeCpp implementációja
  - Még eléggé béta állapotú, de szintén aktívan fejlesztett könyvtár (NEM nyelvi kiterjesztés!!!)
  - Előnye, hogy elvileg minden OpenCL-t támogató szabványos implementáció fölött képes futni (a gyakorlatban ez jelenleg Intel és AMD eszközöket jelent)

CUDA vs SYCL

CUDA vs SYCL

Hasonlóságok:

- Mindkét rendszer lehetővé teszi a C++ nyelvi eszközök használatát a GPU-kon.
  - Nyilván azokat a részeket, amiket az eszköz nem támogat, nem lehet használni, ebben a közös probléma az exception handling, ezért lényegében a C++ STL-je nem használható GPUkon.
- Mindkét rendszer alól lehet a grafikai elemeket használni, így textúrákat, grafikus interopot, vektor regisztereket, stb.
- Mindkét rendszer single-source, azaz közös forrásfájlban található az eszköz és a gazda oldali kód (ellentétben pl. az OpenCL-el).

CUDA vs SYCL

Különbségek:

- A CUDA támogat dinamikus allokációt az eszközoldali kódban, a SYCL nem.
- A CUDA fordítója az nvcc, amely PTX köztest állít elő
- A SYCL forráskód először C++ kódra és SPIR / SPIRV köztesre fordul, majd a C++ kódot egy gazda oldali fordító fordítja binárissá, amely a megfelelő OpenCL hívásokkal betölti a köztest.

CUDA vs SYCL

Különbségek:

- A CUDA egy **nyelvi kiterjesztés**, a függvényeket annotálni kell, hogy az eszközön, a gazdaoldalon, vagy mindkettőn lesznek majd meghívva. SYCL-ben ilyen megkülönböztetés nincs.

```
//Ez csak host oldalon hívható:
__global__ int sq(int x){ return x*x; }
//Ez csak az eszközön:
__device__ int sq(int x){ return x*x; }
//Ez mindkettőn:
__global__ __device__ int sq(int x){ return x*x; }
```

CUDA vs SYCL

Különbségek:

- SYCL-ben nincs megkülönböztetve a kód, nem kell a függvényeket és lambdákat annotálni. A fordító ismeri fel, hogy melyik függvény az, ami majd az eszköz hívás belépési pontja lesz és az abban hivatkozott függvényeket megpróbálja az eszközre is lefordítani.

- Amíg nem használunk olyan funkcionalitást az eszközoldali kódon belül, amit nem lehet a GPUra lefordítani, addig a fordító szó nélkül feldolgozza a tetszőleges (akár nem is GPUra szánt) kódokat.

CUDA vs SYCL

Jelenlegi állapot:

- CUDA 9 (2017 május óta)
  - C++ 14 támogatás az eszközoldali kódban is, helyenként limitációkkal
- SYCL – ComputeCpp 0.3.3 béta (2017 október)
  - Clang 3.9 alapú, így elvileg ez is támogatja a c++14-et, bár vannak bugok a GPU kódgenerálásban

Funkcionális primitívek GPU-n

A három legfontosabb funkcionális primitív, a map, zip, reduce hatékonyan párhuzamosítható, így ezeket implementáljuk először a GPU-kra.

CUDA map

A teljes kód itt érhető el:

https://github.com/Wigner-GPU-Lab/Teaching/blob/master/GPGPU2/map.cu

CUDA map

Az eszközoldali kód törzse:

```
template<typename F, typename T>
__global__ void map(F f, T* src, T* dst)
{
    int id = blockIdx.x * blockDim.x + threadIdx.x;
    dst[id] = f(src[id]);
}
```

CUDA map

Az eszközoldali kód törzse:

Ez a belépési pont a gazdaoldalról lesz hívva.

```
template<typename F, typename T>
__global__ void map(F f, T* src, T* dst)
{
    int id = blockIdx.x * blockDim.x + threadIdx.x;
    dst[id] = f(src[id]);
}
```

CUDA map

Az eszközoldali kód törzse:

Az eszközoldalon beépített változók a számítási tartomány paraméterei (mint openCL-ben)

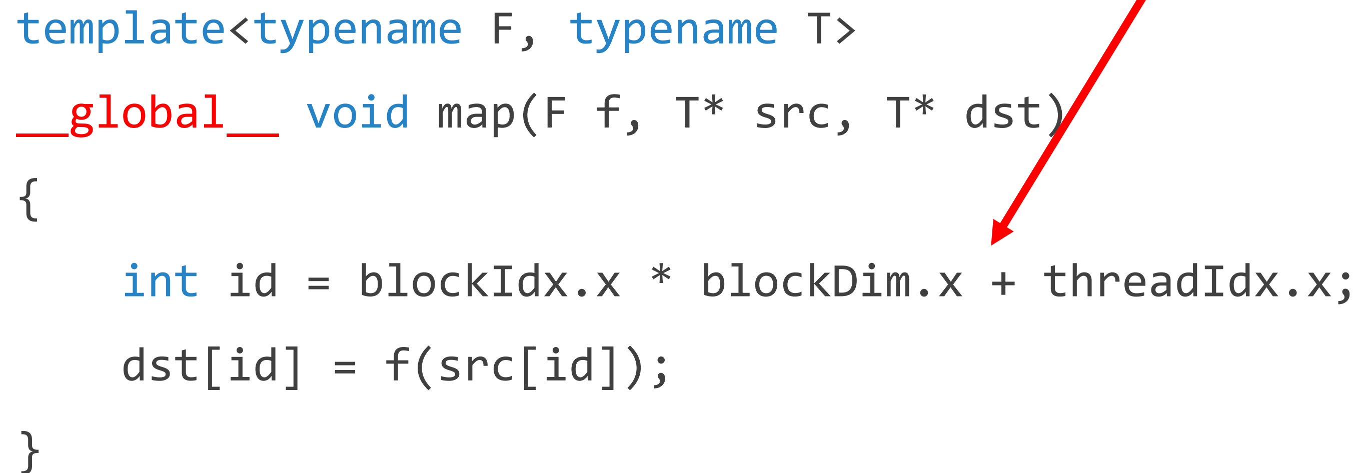

```
template<typename F, typename T>
__global__ void map(F f, T* src, T* dst)
{
    int id = blockIdx.x * blockDim.x + threadIdx.x;
    dst[id] = f(src[id]);
}
```

CUDA map

Az eszközoldali kód törzse:

```
template<typename F, typename T>
__global__ void map(F f, T* src, T* dst)
{
    int id = blockIdx.x * blockDim.x + threadIdx.x;
    dst[id] = f(src[id]);
}
```

A meghívott f függvénynek `__device__` annotáltnak kell lennie!

CUDA map

A gazdaoldali kód törzse:

```
int main()
{
    using T = double;   using P = T*;

    int n = 16;  size_t sz = n*sizeof(T);
    std::vector<T> h_src(n), h_dst(n);
    P d_src, d_dst;

    cudaMalloc( &d_src, sz );
    cudaMalloc( &d_dst, sz );
    cudaMemcpy( d_src, h_src.data(), sz, cudaMemcpyHostToDevice);
    cudaMemcpy( d_dst, h_dst.data(), sz, cudaMemcpyHostToDevice);
```

CUDA map

A gazdaoldali kód törzse:

```
int main()
{
    using T = double;   using P = T*;

    int n = 16;  size_t sz = n*sizeof(T);

    std::vector<T> h_src(n), h_dst(n);

    P d_src, d_dst;

    cudaMalloc( &d_src, sz );
    cudaMalloc( &d_dst, sz );

    cudaMemcpy( d_src, h_src.data(), sz, cudaMemcpyHostToDevice);
    cudaMemcpy( d_dst, h_dst.data(), sz, cudaMemcpyHostToDevice);
```

CUDA map

A gazdaoldali kód törzse:

```
int main()
{
    using T = double;   using P = T*;

    int n = 16;  size_t sz = n*sizeof(T);

    std::vector<T> h_src(n), h_dst(n);

    P d_src, d_dst;

    cudaMalloc( &d_src, sz );
    cudaMalloc( &d_dst, sz );

    cudaMemcpy( d_src, h_src.data(), sz, cudaMemcpyHostToDevice);
    cudaMemcpy( d_dst, h_dst.data(), sz, cudaMemcpyHostToDevice);
```

CUDA map

A gazdaoldali kód törzse:

```
int blockSize = 4;
int gridSize = (int)ceil((float)n/blockSize);

auto sq = [] __device__ (auto const& x){ return x*x; };

map<<<gridSize, blockSize>>>(sq, d_src, d_dst);
```

CUDA map

A gazdaoldali kód törzse:

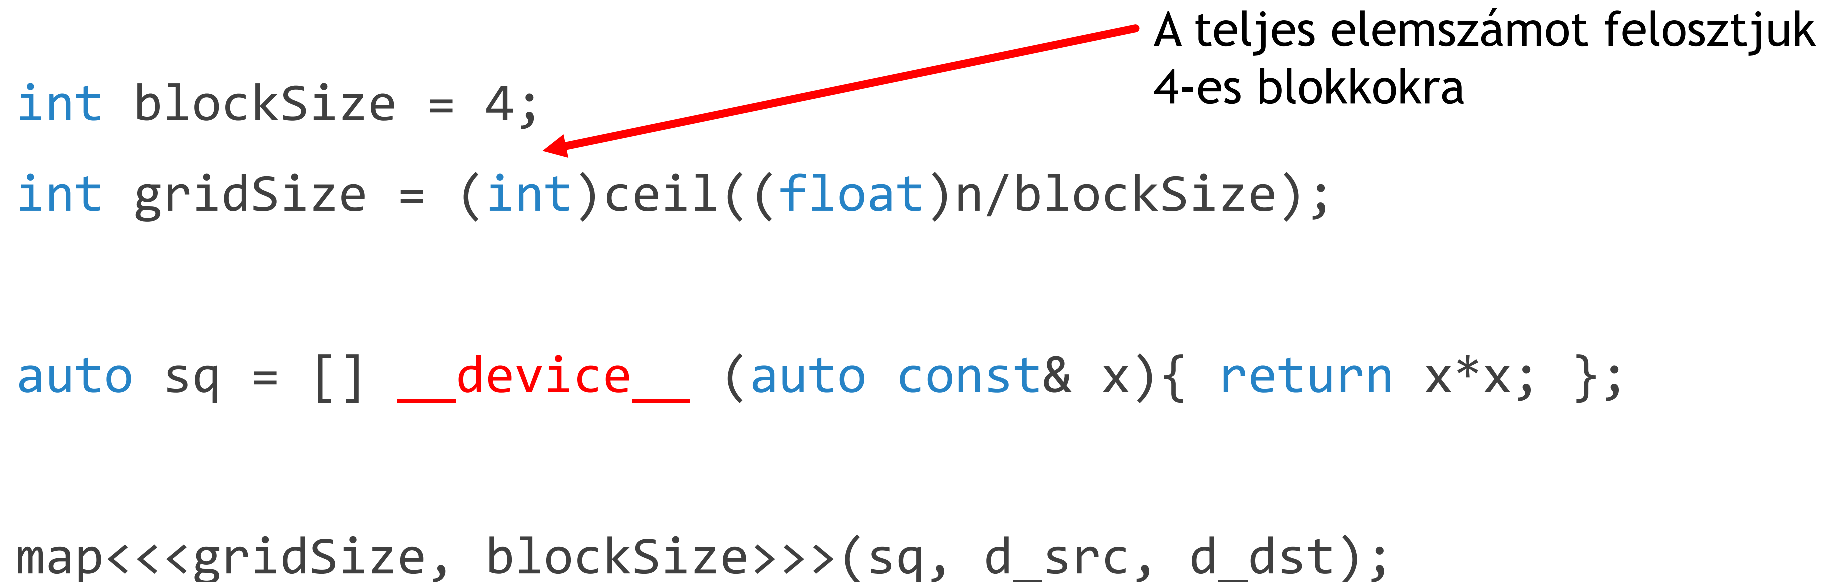

CUDA map

A gazdaoldali kód törzse:

Itt adjuk át a méreteket az eszköznek: a blokkok számát és az egy blokkon belüli szálak számát

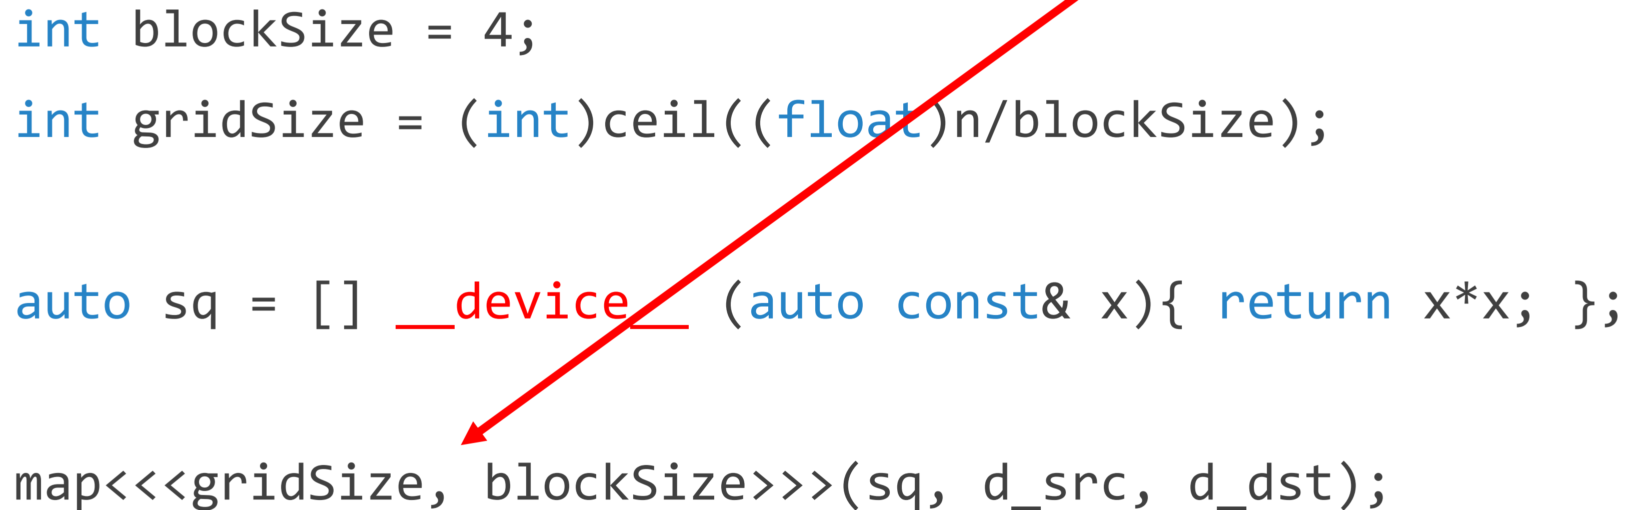

```
int blockSize = 4;
int gridSize = (int)ceil((float)n/blockSize);

auto sq = [] __device__ (auto const& x){ return x*x; };

map<<<gridSize, blockSize>>>(sq, d_src, d_dst);
```

CUDA map

A gazdaoldali kód törzse:

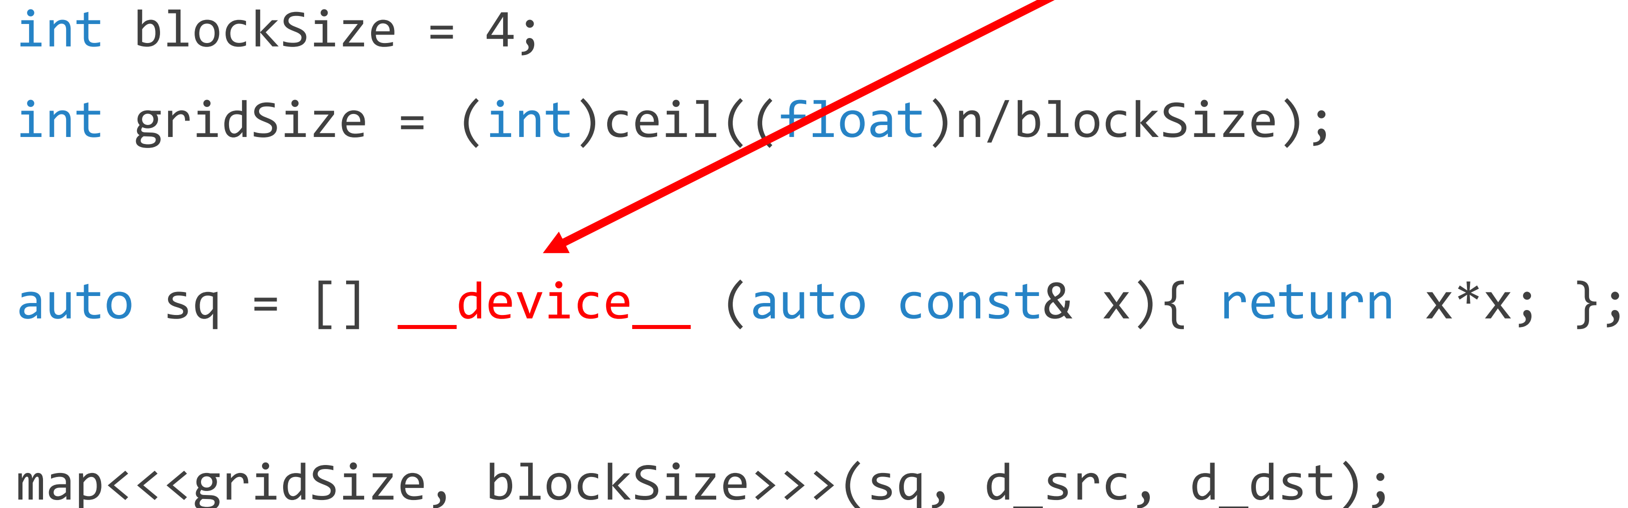

CUDA map

A gazdaoldali kód törzse:

```
cudaMemcpy( h_dst.data(), d_dst, sz, cudaMemcpyDeviceToHost );

cudaFree(d_src);
cudaFree(d_dst);
```

CUDA map

A gazdaoldali kód törzse:

```
cudaMemcpy( h_dst.data(), d_dst, sz, cudaMemcpyDeviceToHost );

cudaFree(d_src);
cudaFree(d_dst);
```

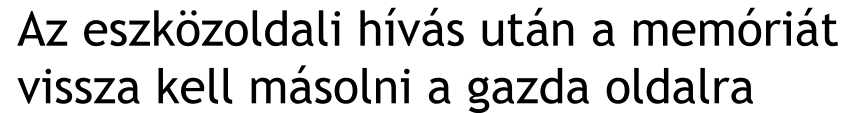

CUDA map

A gazdaoldali kód törzse:

```
cudaMemcpy( h_dst.data(), d_dst, sz, cudaMemcpyDeviceToHost );

cudaFree(d_src);
cudaFree(d_dst);
```

CUDA map

Fordítás:

- Ha CMAKE-el szeretnénk fordítani, nézzük meg az itteni példát.
- Paranssorból kézzel:
  - nvcc -std=c++14 --expt-extended-lambda map.cu

CUDA map

Fordítás:

- Ha CMAKE-el szeretnénk fordítani, nézzük meg az itteni példát.
- Paranssorból kézzel:
  - nvcc -std=c++14 --expt-extended-lambda map.cu

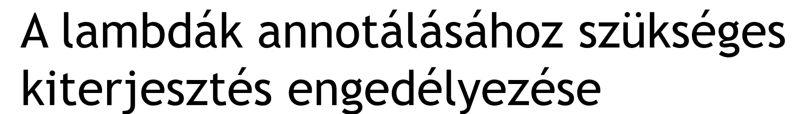

A lambdák annotálásához szükséges kiterjesztés engedélyezése

CUDA zip

A teljes kód itt érhető el:

https://github.com/Wigner-GPU-Lab/Teaching/blob/master/GPGPU2/zip.cu

CUDA zip

A zip teljesen hasonló a map-hoz:

```
template<typename F, typename T>
__global__ void zip(F f, T* src1, T* src2, T* dst)
{
    int id = blockIdx.x * blockDim.x + threadIdx.x;
    dst[id] = f(src1[id], src2[id]);
}
```

És most ugyan ez SYCL-ben!

SYCL map

A teljes kód itt érhető el:

https://github.com/Wigner-GPU-Lab/Teaching/blob/master/GPGPU2/map_sycl.cpp

SYCL map

A sycl használatához be kell includolni a sycl.hpp-t:

```
// SYCL include
#include <CL/sycl.hpp>
```

SYCL map

A map függvény belsejét külön függvényben írtuk meg:

```
template<typename F, typename RA, typename WA>
void map(F f, RA src, WA dst, cl::sycl::id<1> id)
{
   dst[id] = f(src[id]);
}
```

SYCL map

A map függvény belsejét külön függvényben írtuk meg:

```
template<typename F, typename RA, typename WA>
void map(F f, RA src, WA dst, cl::sycl::id<1> id)
{
    dst[id] = f(src[id]);
}
```

SYCL map

A map függvény belsejét külön függvényben írtuk meg:

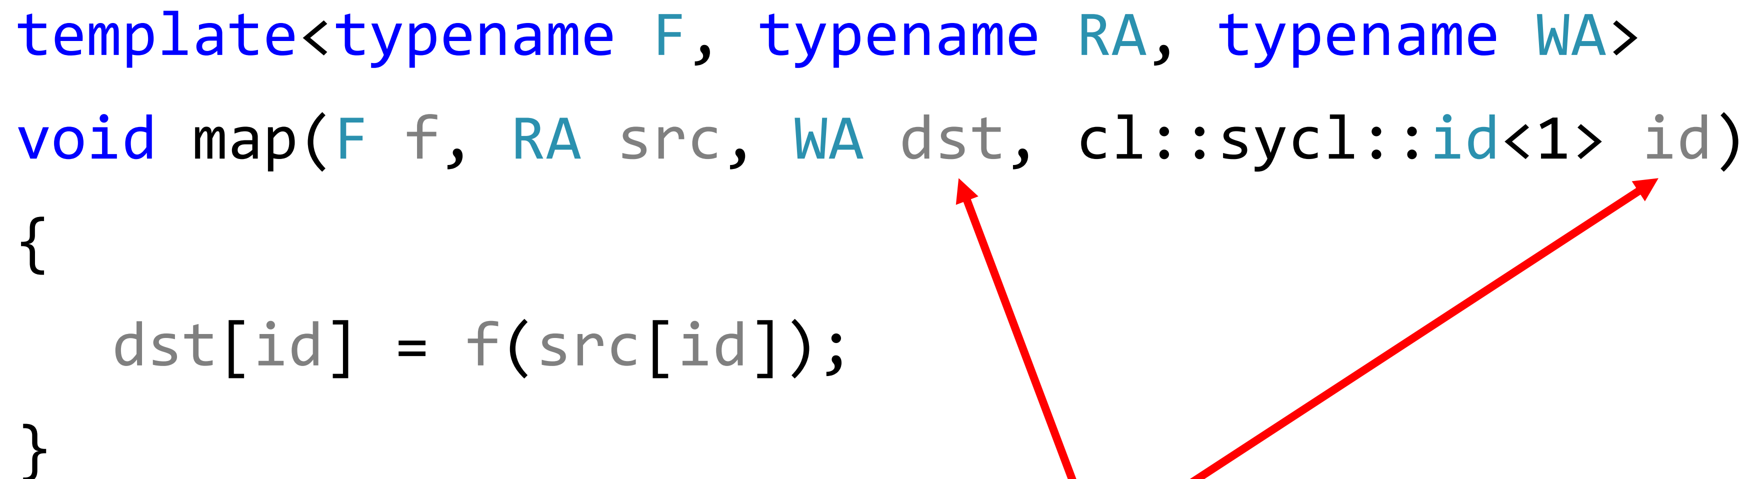

```
template<typename F, typename RA, typename WA>
void map(F f, RA src, WA dst, cl::sycl::id<1> id)
{
   dst[id] = f(src[id]);
}
```

Az itteni megvalósításban a bemenő argumentumok accessorok, és a szálazonosító is argumentumként jön a függvénybe (nincsenek beépített változók, mint CUDA-ban)

SYCL map

A SYCL kód gazda oldali része:

```
{
   cl::sycl::queue queue{ cl::sycl::gpu_selector() };
   cl::sycl::buffer<T, 1> b_src(h_src.data(), n);
   cl::sycl::buffer<T, 1> b_dst(h_dst.data(), n);
   cl::sycl::range<1> r(n);





}
```

SYCL map

A SYCL kód gazda oldali része:

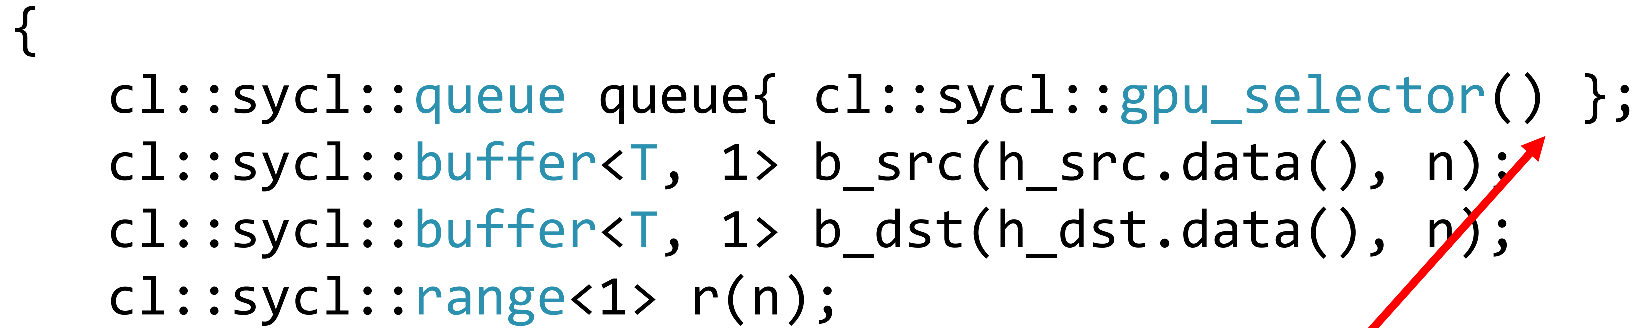

```
{
    cl::sycl::queue queue{ cl::sycl::gpu_selector() };
    cl::sycl::buffer<T, 1> b_src(h_src.data(), n);
    cl::sycl::buffer<T, 1> b_dst(h_dst.data(), n);
    cl::sycl::range<1> r(n);



}
```

Parancslista létrehozása, ami most az első GPU eszközt próbálja meg kiválasztani

SYCL map

A SYCL kód gazda oldali része:

```
{
    cl::sycl::queue queue{ cl::sycl::gpu_selector() };
    cl::sycl::buffer<T, 1> b_src(h_src.data(), n);
    cl::sycl::buffer<T, 1> b_dst(h_dst.data(), n);
    cl::sycl::range<1> r(n);




}
```

Bufferek létrehozása az adatokhoz

SYCL map

A SYCL kód gazda oldali része:

```
{
   auto sq = [](auto const& x){ return x*x; };
   queue.submit([&](cl::sycl::handler& cgh)
   {
     auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
     auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);
     cgh.parallel_for<class Map>(r, [=](cl::sycl::id<1> i)
     {
       map(sq, a_src, a_dst, i); });
     });
}
```

SYCL map

A SYCL kód gazda oldali része:

Semmilyen annotáció nem kell a lambdához sem

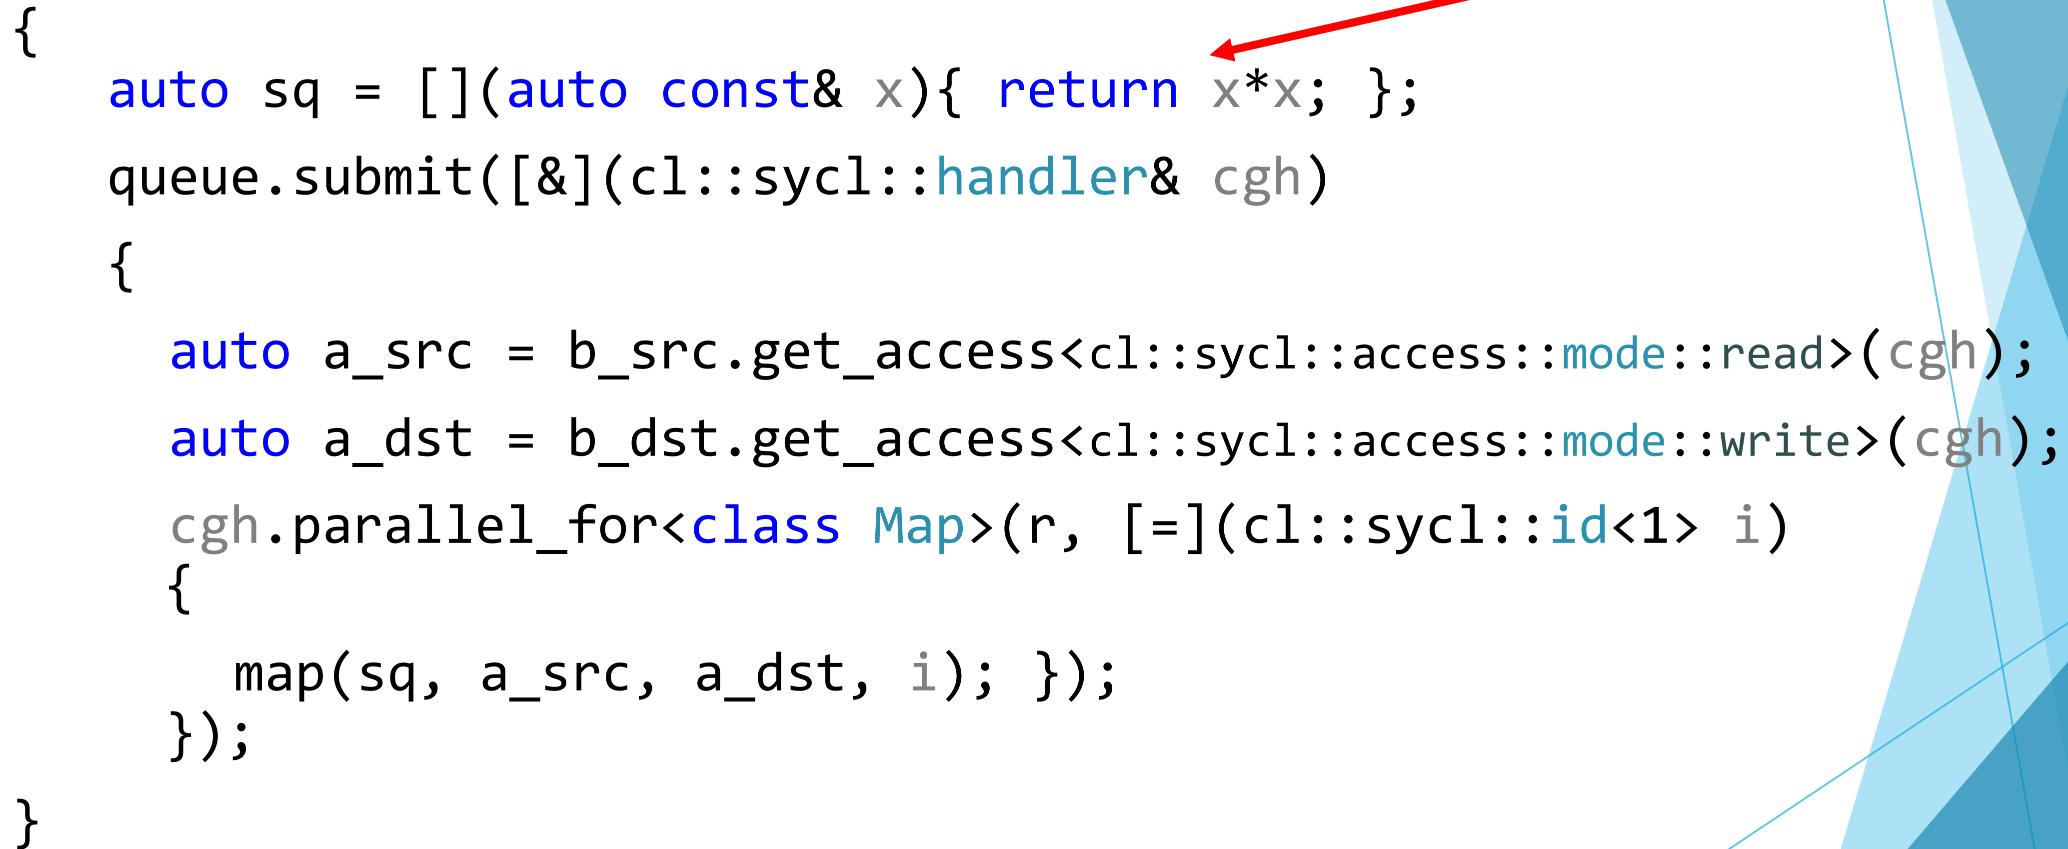

SYCL map

A SYCL kód gazda oldali része:

```
{
   auto sq = [](auto const& x){ return x*x; };
   queue.submit([&](cl::sycl::handler& cgh)
   {
     auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
     auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);
     cgh.parallel_for<class Map>(r, [=](cl::sycl::id<1> i)
     {
       map(sq, a_src, a_dst, i); });
     });
}
```

SYCL map

A SYCL kód gazda oldali része:

```
{
   auto sq = [](auto const& x){ return x*x; };
   queue.submit([&](cl::sycl::handler& cgh)
   {
     auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
     auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);
     cgh.parallel_for<class Map>(r, [=](cl::sycl::id<1> i)
     {
       map(sq, a_src, a_dst, i); });
     });
}
```

Egy parallel_for hívást hajtunk végre a megadott kernel névvel...

SYCL map

A SYCL kód gazda oldali része:

```
{
    auto sq = [](auto const& x){ return x*x; };
    queue.submit([&](cl::sycl::handler& cgh)
    {
      auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
      auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);
      cgh.parallel_for<class Map>(r, [=](cl::sycl::id<1> i)
      {
        map(sq, a_src, a_dst, i); });
      });
}
```

Átveszünk mindent érték szerint, ideértve az accessorokat is

SYCL map

A SYCL kód gazda oldali része:

```
{
   auto sq = [](auto const& x){ return x*x; };
   queue.submit([&](cl::sycl::handler& cgh)
   {
     auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
     auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);
     cgh.parallel_for<class Map>(r, [=](cl::sycl::id<1> i)
     {
       map(sq, a_src, a_dst, i); });
     });
}
```

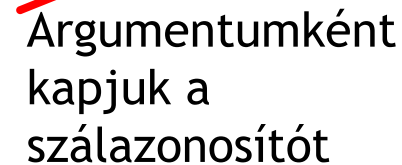

SYCL map

A SYCL kód gazda oldali része:

```
{
    auto sq = [](auto const& x){ return x*x; };
    queue.submit([&](cl::sycl::handler& cgh)
    {
      auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
      auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);
      cgh.parallel_for<class Map>(r, [=](cl::sycl::id<1> i)
      {
        map(sq, a_src, a_dst, i); });
      });
}
```

Meghívjuk a korábban megírt függvényünket.

SYCL fordítás

A ComputeCpp-vel, CMAKE-el történő fordításhoz, nézzük meg ezt a példakódot:

https://github.com/Wigner-GPU-Lab/Teaching/tree/master/GPGPU1/SYCL

Amihez szükség van a FindComputeCpp CMAKE modulra, aminek a legfrissebb verziója innen tölthető le:

https://github.com/codeplaysoftware/computecpp-sdk/tree/master/cmake/Modules

SYCL fordítás

Ha nem akarunk CMAKE-el fordítani, akkor parancssorból kb. így fest a dolog:

Először a compute++ fordító kiszedi a cpp fáljból a SYCL specifikus részeket és legenerál egy úgynevezett „integration headert” (esetünkben main.cpp.sycl):

```
/opt/Codeplay/ComputeCpp/latest/bin/compute++ -std=c++14 -O2 -mllvm -inline-threshold=1000
-sycl -emit-llvm -intelspirmetadata -isystem /opt/Codeplay/ComputeCpp/latest/include/
-I/opt/Codeplay/ComputeCpp/latest/include/ -I/usr/include -o main.cpp.sycl -c main.cpp
```

Ezután a szokásos módon lefordítjuk a forrásfáljt, CSAK hozzá kell adni a generált headert includeként expliciten!:

```
g++ -isystem /opt/Codeplay/ComputeCpp/latest/include -O3 -DNDEBUG -include main.cpp.sycl
-std=gnu++14 -o main.o -c main.cpp
```

Végül linkelünk (a –Wl, -rpath varázslásról bővebben itt):

```
g++ -O3 -DNDEBUG main.o -o SYCL_app –rdynamic /opt/Codeplay/ComputeCpp/latest/lib/libComputeCpp.so
-lOpenCL -Wl,-rpath,/opt/Codeplay/ComputeCpp/latest/lib
```

SYCL zip

A teljes kód itt:

https://github.com/Wigner-GPU-Lab/Teaching/blob/master/GPGPU2/zip_sycl.cpp

Redukciók GPU-n

Redukciók GPU-n

A korábban bevezetett primitívek között a foldl/r szerepelt mint redukciós primitív:

```
foldl :: (a -> b -> a) -> a -> f b -> a
```

Ezzel az a probléma, hogy nem párhuzamosítható, mert explicit végrehajtási sorrendet ír elő.

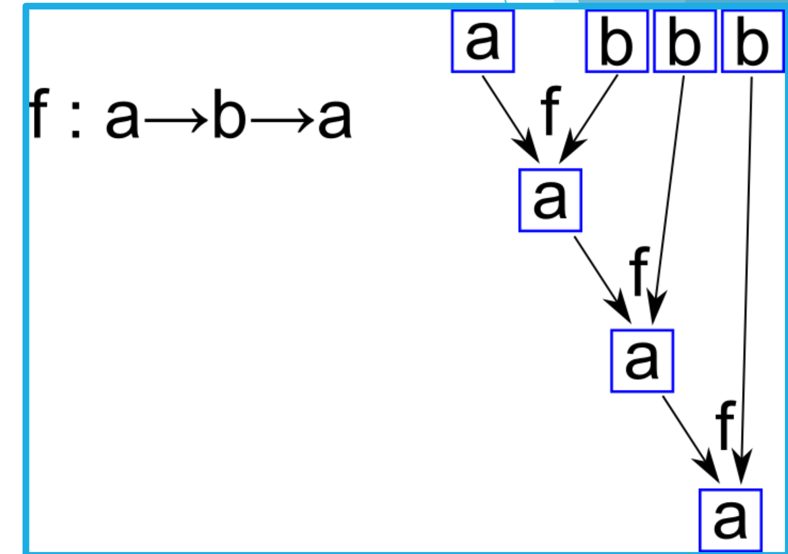

Redukciók GPU-n

A korábban bevezetett primitívek között a foldl/r szerepelt mint redukciós primitív:

```
foldl :: (a -> b -> a) -> a -> f b -> a
```

Ha megváltoztatjuk a szignatúrát, és feltételezzük, hogy a bináris művelet asszociatív és kommutatív, akkor lehetőségünk nyílik átrendezni és párhuzamosítani a műveletet:

```
reduce :: (a -> a -> a) -> f a -> a
```

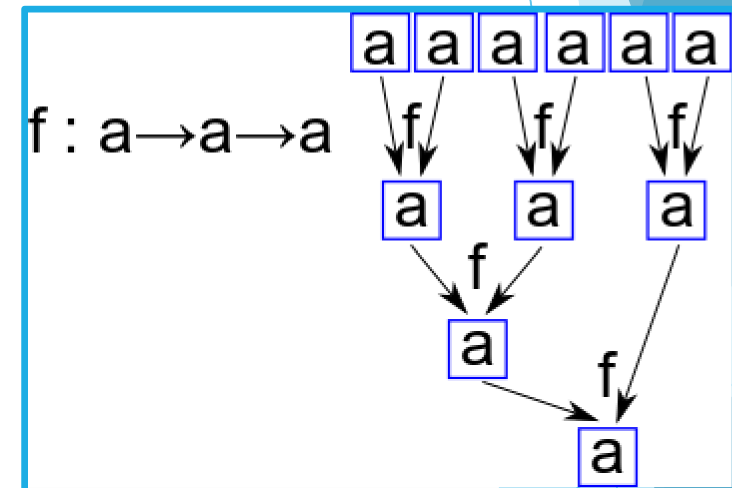

Redukciók GPU-n

A redukciót a következő logikával végezzük el:

- Az első globális memóriából történő olvasásnál két elemet olvasunk be, eltolva a blokk mérettel (koaleszkált memória hozzáférés)

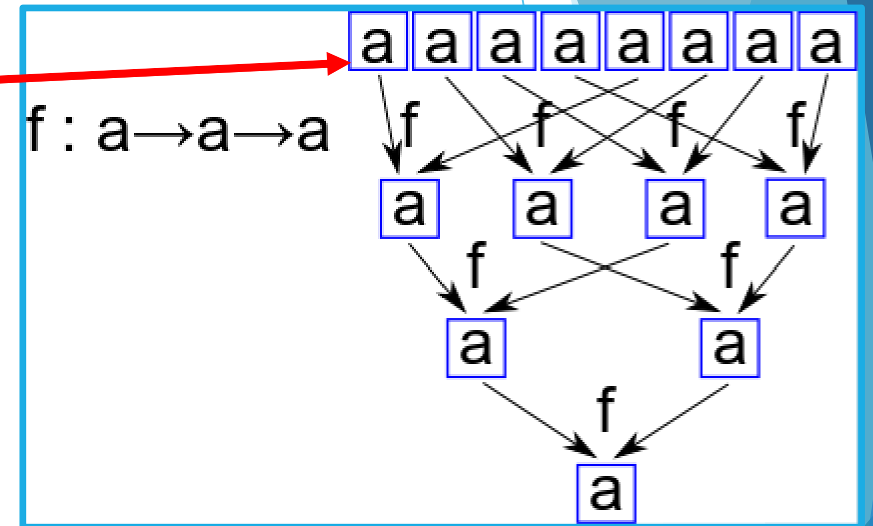

Redukciók GPU-n

A redukciót a következő logikával végezzük el:

- Az első globális memóriából történő olvasásnál két elemet olvasunk be, eltolva a blokk mérettel (koaleszkált memória hozzáférés)
- ezeket azonnal redukáljuk és letároljuk a lokális (shared) memóriában.

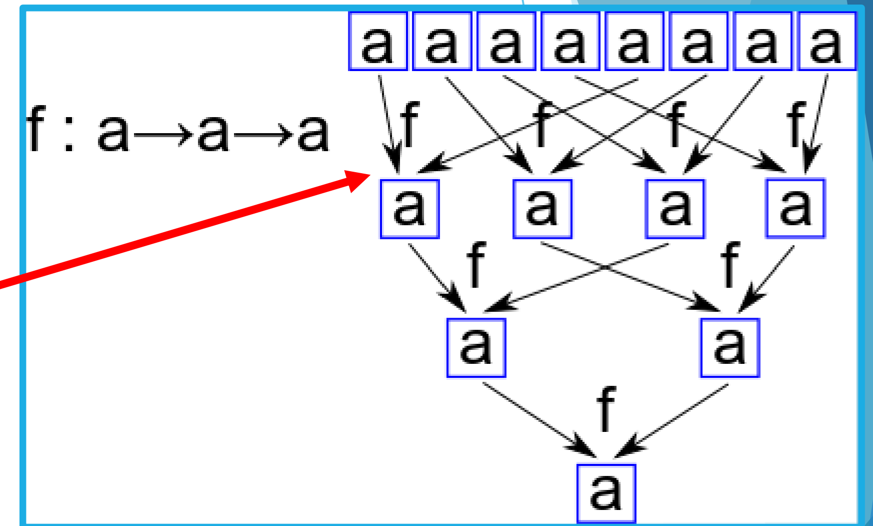

Redukciók GPU-n

A redukciót a következő logikával végezzük el:

- Az első globális memóriából történő olvasásnál két elemet olvasunk be, eltolva a blokk mérettel (koaleszkált memória hozzáférés)
- ezeket azonnal redukáljuk és letároljuk a lokális (shared) memóriában.
- A további redukciót is ugyan itt végezzük, minden lépésben felezve az eltolást (a megosztott memória bank-conflictjainak elkerülésére)

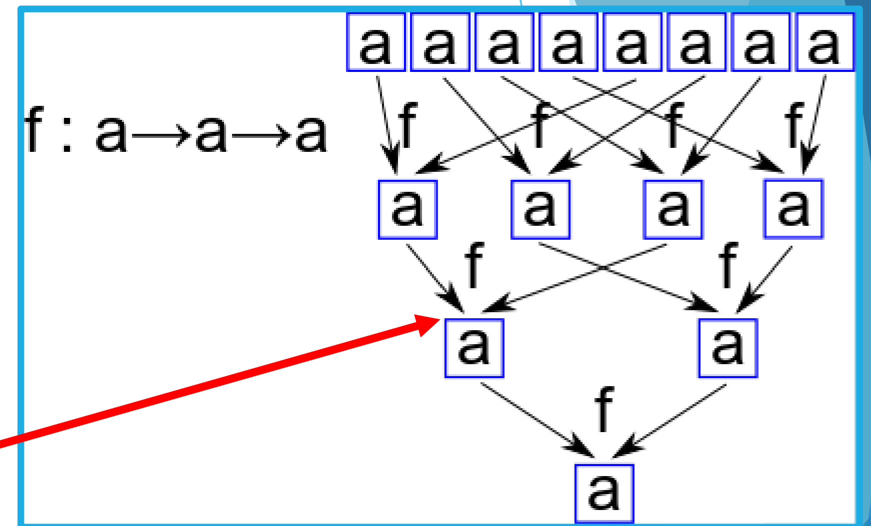

Redukciók GPU-n

A redukciót a következő logikával végezzük el:

- Az első globális memóriából történő olvasásnál két elemet olvasunk be, eltolva a blokk mérettel (koaleszkált memória hozzáférés)
- ezeket azonnal redukáljuk és letároljuk a lokális (shared) memóriában.
- A további redukciót is ugyan itt végezzük, minden lépésben felezve az eltolást (a megosztott memória bank-conflictjainak elkerülésére)
- Végeredményben minden munkacsoport (blokk) egyetlen értéket fog előállítani. Ennek a redukálását vagy gazda oldalon végezzük, vagy egy külön kernel indításban.

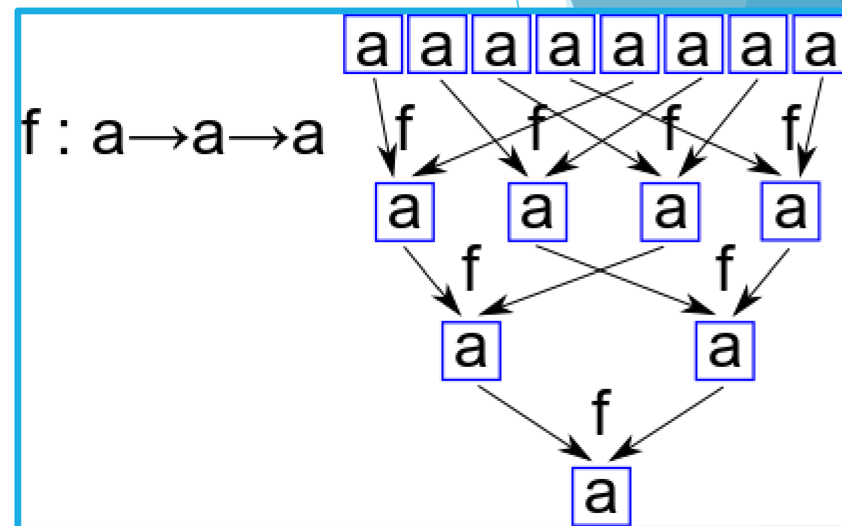

CUDA reduce

A teljes kód itt:

https://github.com/Wigner-GPU-Lab/Teaching/blob/master/GPGPU2/reduce.cu

CUDA reduce

```
template<typename F, typename T>
__global__ void reduce(F f, T* src, T* dst)
{
    extern __shared__ T tmp[];
    auto t = threadIdx.x;
    auto i = blockIdx.x * (2*blockDim.x) + threadIdx.x;
    tmp[t] = f( src[i], src[i+blockDim.x] );
    __syncthreads();

    for(auto s=blockDim.x/2; s > 0; s >>= 1)
    {
       if(t < s){ tmp[t] = f(tmp[t], tmp[t + s]); }
       __syncthreads();
    }
    if(t == 0){ dst[blockIdx.x] = tmp[0]; }
}
```

CUDA reduce

```
template<typename F, typename T>
__global__ void reduce(F f, T* src, T* dst)
{
    extern __shared__ T tmp[];
    auto t = threadIdx.x;
    auto i = blockIdx.x * (2*blockDim.x) + threadIdx.x;
    tmp[t] = f( src[i], src[i+blockDim.x] );
    __syncthreads();

    for(auto s=blockDim.x/2; s > 0; s >>= 1)
    {
       if(t < s){ tmp[t] = f(tmp[t], tmp[t + s]); }
       __syncthreads();
    }
    if(t == 0){ dst[blockIdx.x] = tmp[0]; }
}
```

Lokális memória bevezetése,
a mérete a hívó oldalról jön.

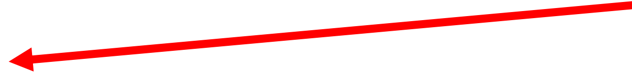

CUDA reduce

```
template<typename F, typename T>
__global__ void reduce(F f, T* src, T* dst)
{
    extern __shared__ T tmp[];
    auto l = threadIdx.x;
    auto i = blockIdx.x * (2*blockDim.x) + threadIdx.x;
    tmp[l] = f( src[i], src[i+blockDim.x] );
    __syncthreads();

    for(auto s=blockDim.x/2; s > 0; s >>= 1)
    {
       if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
       __syncthreads();
    }
    if(l == 0){ dst[blockIdx.x] = tmp[0]; }
}
```

Lokális (blokkon belüli) szálindex

CUDA reduce

```
template<typename F, typename T>
__global__ void reduce(F f, T* src, T* dst)
{
    extern __shared__ T tmp[];
    auto l = threadIdx.x;
    auto i = blockIdx.x * (2*blockDim.x) + threadIdx.x;
    tmp[l] = f( src[i], src[i+blockDim.x] );
    __syncthreads();

    for(auto s=blockDim.x/2; s > 0; s >>= 1)
    {
       if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
       __syncthreads();
    }
    if(l == 0){ dst[blockIdx.x] = tmp[0]; }
}
```

Globális szálazonosító, de kétszeresére felhízlalt blokkmérettel az eltolás miatt

CUDA reduce

```
template<typename F, typename T>
__global__ void reduce(F f, T* src, T* dst)
{
    extern __shared__ T tmp[];
    auto l = threadIdx.x;
    auto i = blockIdx.x * (2*blockDim.x) + threadIdx.x;
    tmp[l] = f( src[i], src[i+blockDim.x] );
    __syncthreads();

    for(auto s=blockDim.x/2; s > 0; s >>= 1)
    {
       if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
       __syncthreads();
    }
    if(l == 0){ dst[blockIdx.x] = tmp[0]; }
}
```

Első redukció a globális olvasáskor, a két elem között egy blokkméret eltolás van

CUDA reduce

```
template<typename F, typename T>
__global__ void reduce(F f, T* src, T* dst)
{
    extern __shared__ T tmp[];
    auto l = threadIdx.x;
    auto i = blockIdx.x * (2*blockDim.x) + threadIdx.x;
    tmp[l] = f( src[i], src[i+blockDim.x] );
    __syncthreads();

    for(auto s=blockDim.x/2; s > 0; s >>= 1)
    {
      if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
      __syncthreads();
    }
    if(l == 0){ dst[blockIdx.x] = tmp[0]; }
}
```

Lokális memóriát írtunk, és most olvasni fogjuk, ezért szinkronizálni kell a szálakat!

CUDA reduce

```
template<typename F, typename T>
__global__ void reduce(F f, T* src, T* dst)
{
    extern __shared__ T tmp[];
    auto l = threadIdx.x;
    auto i = blockIdx.x * (2*blockDim.x) + threadIdx.x;
    tmp[l] = f( src[i], src[i+blockDim.x] );
    __syncthreads();

    for(auto s=blockDim.x/2; s > 0; s >>= 1)
    {
       if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
       __syncthreads();
    }
    if(l == 0){ dst[blockIdx.x] = tmp[0]; }
}
```

Egyre csökkenő eltolással további redukció a lokális memóriában

Minden lépés végén szinkronizáció!

CUDA reduce

```
template<typename F, typename T>
__global__ void reduce(F f, T* src, T* dst)
{
    extern __shared__ T tmp[];
    auto l = threadIdx.x;
    auto i = blockIdx.x * (2*blockDim.x) + threadIdx.x;
    tmp[l] = f( src[i], src[i+blockDim.x] );
    __syncthreads();

    for(auto s=blockDim.x/2; s > 0; s >>= 1)
    {
       if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
       __syncthreads();
    }
    if(l == 0){ dst[blockIdx.x] = tmp[0]; }
}
```

Végül egyetlen szál visszaírja a lokális memória elejéről a kimenő tömbbe a blokk eredményét

CUDA reduce

Gazdaoldali felparaméterezés:

```
int n = 256;
int blockSize = 16;
size_t gridSize = (size_t)ceil((float)n/2/blockSize);
reduce<<<gridSize, blockSize, blockSize*sizeof(T)>>>(sum, d_src, d_dst);
```

CUDA reduce

Gazdaoldali felparaméterezés:

Minden szál 2 értéket olvas a globális memóriából, ezért a teljes méretet itt felezni kell!

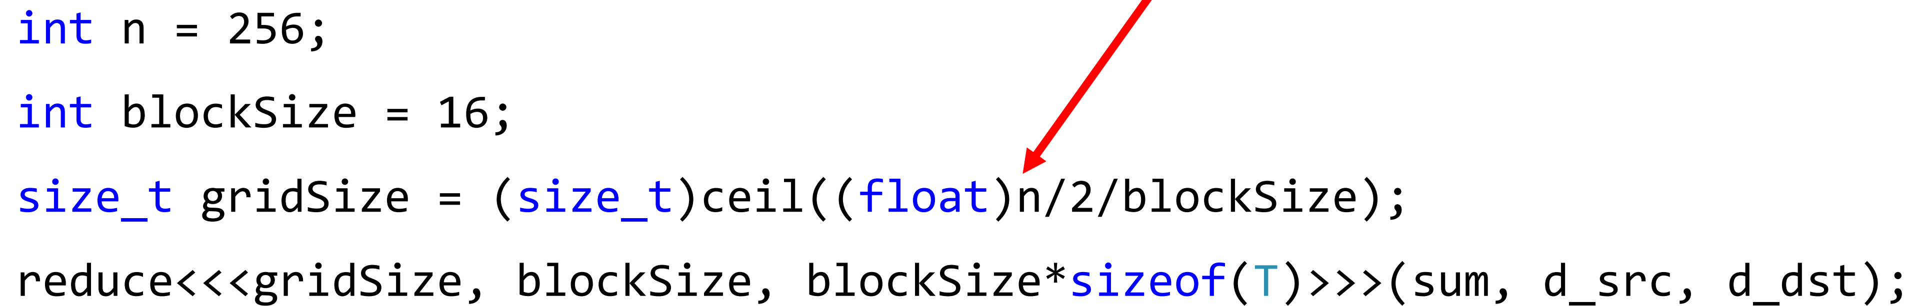

```
int n = 256;
int blockSize = 16;
size_t gridSize = (size_t)ceil((float)n/2/blockSize);
reduce<<<gridSize, blockSize, blockSize*sizeof(T)>>>(sum, d_src, d_dst);
```

CUDA reduce

Gazdaoldali felparaméterezés:

```
int n = 256;
int blockSize = 16;
size_t gridSize = (size_t)ceil((float)n/2/blockSize);
reduce<<<gridSize, blockSize, blockSize*sizeof(T)>>>(sum, d_src, d_dst);
```

Itt kell megadni a lokális memória méretét byte-okban

SYCL reduce

Hogy fest ugyanez SYCL-ben?

A teljes kód itt:

https://github.com/Wigner-GPU-Lab/Teaching/blob/master/GPGPU2/reduce_sycl.cpp

SYCL reduce

```
template<typename F, typename RA, typename RWA, typename WA>
void reduce(F f, RA src, RWA tmp, WA dst, cl::sycl::nd_item<1> id)
{
    auto g = id.get_group().get(0);
    auto bs = id.get_local_range().get(0);
    auto l = id.get_local().get(0);
    auto i = g * bs * 2 + l;
    tmp[l] = f( src[i], src[i+bs] );

    id.barrier(cl::sycl::access::fence_space::local_space);

    for(auto s=bs/2; s > 0; s >>= 1)
    {
        if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
        id.barrier(cl::sycl::access::fence_space::local_space);
    }
    if(l == 0){ dst[g] = tmp[0]; }
}
```

SYCL reduce

```
template<typename F, typename RA, typename RWA, typename WA>
void reduce(F f, RA src, RWA tmp, WA dst, cl::sycl::nd_item<1> id)
{
    auto g = id.get_group().get(0);
    auto bs = id.get_local_range().get(0);
    auto l = id.get_local().get(0);
    auto i = g * bs * 2 + l;
    tmp[l] = f( src[i], src[i+bs] );

    id.barrier(cl::sycl::access::fence_space::local_space);

    for(auto s=bs/2; s > 0; s >>= 1)
    {
        if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
        id.barrier(cl::sycl::access::fence_space::local_space);
    }
    if(l == 0){ dst[g] = tmp[0]; }
}
```

A lokális memóriát is accessorral érjük el, mint a buffereket!

SYCL reduce

```
template<typename F, typename RA, typename RWA, typename WA>
void reduce(F f, RA src, RWA tmp, WA dst, cl::sycl::nd_item<1> id)
{
    auto g = id.get_group().get(0);
    auto bs = id.get_local_range().get(0);
    auto l = id.get_local().get(0);
    auto i = g * bs * 2 + l;
    tmp[l] = f( src[i], src[i+bs] );

    id.barrier(cl::sycl::access::fence_space::local_space);

    for(auto s=bs/2; s > 0; s >>= 1)
    {
        if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
        id.barrier(cl::sycl::access::fence_space::local_space);
    }
    if(l == 0){ dst[g] = tmp[0]; }
}
```

SYCL reduce

```
template<typename F, typename RA, typename RWA, typename WA>
void reduce(F f, RA src, RWA tmp, WA dst, cl::sycl::nd_item<1> id)
{
    auto g = id.get_group().get(0);
    auto bs = id.get_local_range().get(0);
    auto l = id.get_local().get(0);
    auto i = g * bs * 2 + l;
    tmp[l] = f( src[i], src[i+bs] );

    id.barrier(cl::sycl::access::fence_space::local_space);

    for(auto s=bs/2; s > 0; s >>= 1)
    {
        if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
        id.barrier(cl::sycl::access::fence_space::local_space);
    }
    if(l == 0){ dst[g] = tmp[0]; }
}
```

Ez az indexelés pontosan a CUDA-s megvalósítást másolja

minden méretet és indexet az nd_item-ből tudunk lekérni

SYCL reduce

```
template<typename F, typename RA, typename RWA, typename WA>
void reduce(F f, RA src, RWA tmp, WA dst, cl::sycl::nd_item<1> id)
{
    auto g = id.get_group().get(0);
    auto bs = id.get_local_range().get(0);
    auto l = id.get_local().get(0);
    auto i = g * bs * 2 + l;
    tmp[l] = f( src[i], src[i+bs] );

    id.barrier(cl::sycl::access::fence_space::local_space);

    for(auto s=bs/2; s > 0; s >>= 1)
    {
        if(l < s){ tmp[l] = f(tmp[l], tmp[l + s]); }
        id.barrier(cl::sycl::access::fence_space::local_space);
    }
    if(l == 0){ dst[g] = tmp[0]; }
}
```

Szintén az nd_item-en keresztül történik a szinkronizáció is.

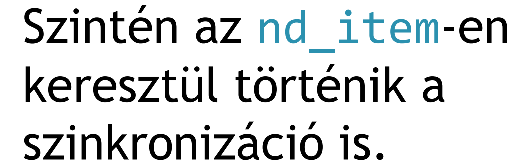

SYCL reduce

Gazdaoldali kód:

```
size_t n = 256, local_count = 16;

cl::sycl::nd_range<1> r(n/2, local_count);

queue.submit([&](cl::sycl::handler& cgh)
{
    auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
    auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);

    cl::sycl::accessor<T, 1, cl::sycl::access::mode::read_write,
                             cl::sycl::access::target::local>

    a_tmp(cl::sycl::range<1>(local_count), cgh);


    cgh.parallel_for<class Reduce>(r, [=](cl::sycl::nd_item<1> i)

    { reduce(sum, a_src, a_tmp, a_dst, i); });

});
```

SYCL reduce

Itt hozzuk létre az nd_range-t, ami a globális méretet és a blokkméretet írja le.

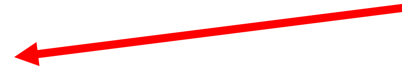

Gazdaoldali kód:

```
size_t n = 256, local_count = 16;
cl::sycl::nd_range<1> r(n/2, local_count);
queue.submit([&](cl::sycl::handler& cgh)
{
    auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
    auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);
    cl::sycl::accessor<T, 1, cl::sycl::access::mode::read_write,
                             cl::sycl::access::target::local>
    a_tmp(cl::sycl::range<1>(local_count), cgh);

    cgh.parallel_for<class Reduce>(r, [=](cl::sycl::nd_item<1> i)
    { reduce(sum, a_src, a_tmp, a_dst, i); });
});
```

SYCL reduce

Ez az accessor a lokális memóriához ad hozzáférést.

A típusa a használatát, a konstruktora a méretet adja meg.

Gazdaoldali kód:

```
size_t n = 256, local_count = 16;
cl::sycl::nd_range<1> r(n/2, local_count);
queue.submit([&](cl::sycl::handler& cgh)
{
    auto a_src = b_src.get_access<cl::sycl::access::mode::read>(cgh);
    auto a_dst = b_dst.get_access<cl::sycl::access::mode::write>(cgh);
    cl::sycl::accessor<T, 1, cl::sycl::access::mode::read_write,
                             cl::sycl::access::target::local>
    a_tmp(cl::sycl::range<1>(local_count), cgh);

    cgh.parallel_for<class Reduce>(r, [=](cl::sycl::nd_item<1> i)
    { reduce(sum, a_src, a_tmp, a_dst, i); });
});
```

GPU Reduce

A redukció még sokkal tovább optimalizálható a belső for ciklus kifejtésével.

Érdemes elolvasni ezt a redukció optimalizálásának gondolatmenetéről.

GPU Reduce

A most ismertetett konstrukcióban kihasználtuk, hogy a bináris művelet kommutatív és asszociatív!

- Ha nem asszociatív, akkor csak foldolni tudunk.
- Ha asszociatív, de nem kommutatív, akkor párhuzamosíthatunk, de a memóriahozzáférés nem lesz ideális