Compute shaders

Framtiden för GPU computing eller sen efterapning av Direct Compute?

Tidigare rent Microsoft-koncept, Direct Compute

Senare även i OpenGL, ny shadertyp från OpenGL 4.3

Starkt alternativ

Varför använda det i stället för CUDA eller OpenCL?

+ Bättre integration med OpenGL

+ Ingen extra installation behövs!

+ Enklare att konfigurera än OpenCL

+ Inte NVidia-specifikt som CUDA

+ Om du kan GLSL så är Compute Shaders (ganska) lätt!

Men det är ju inte bara plus...

- En del nya koncept

- Inte del av grafikpipelinen som fragment shaders

- Apple har egen lösning

Compute shaders är ensamma, kompileras inte med några andra.

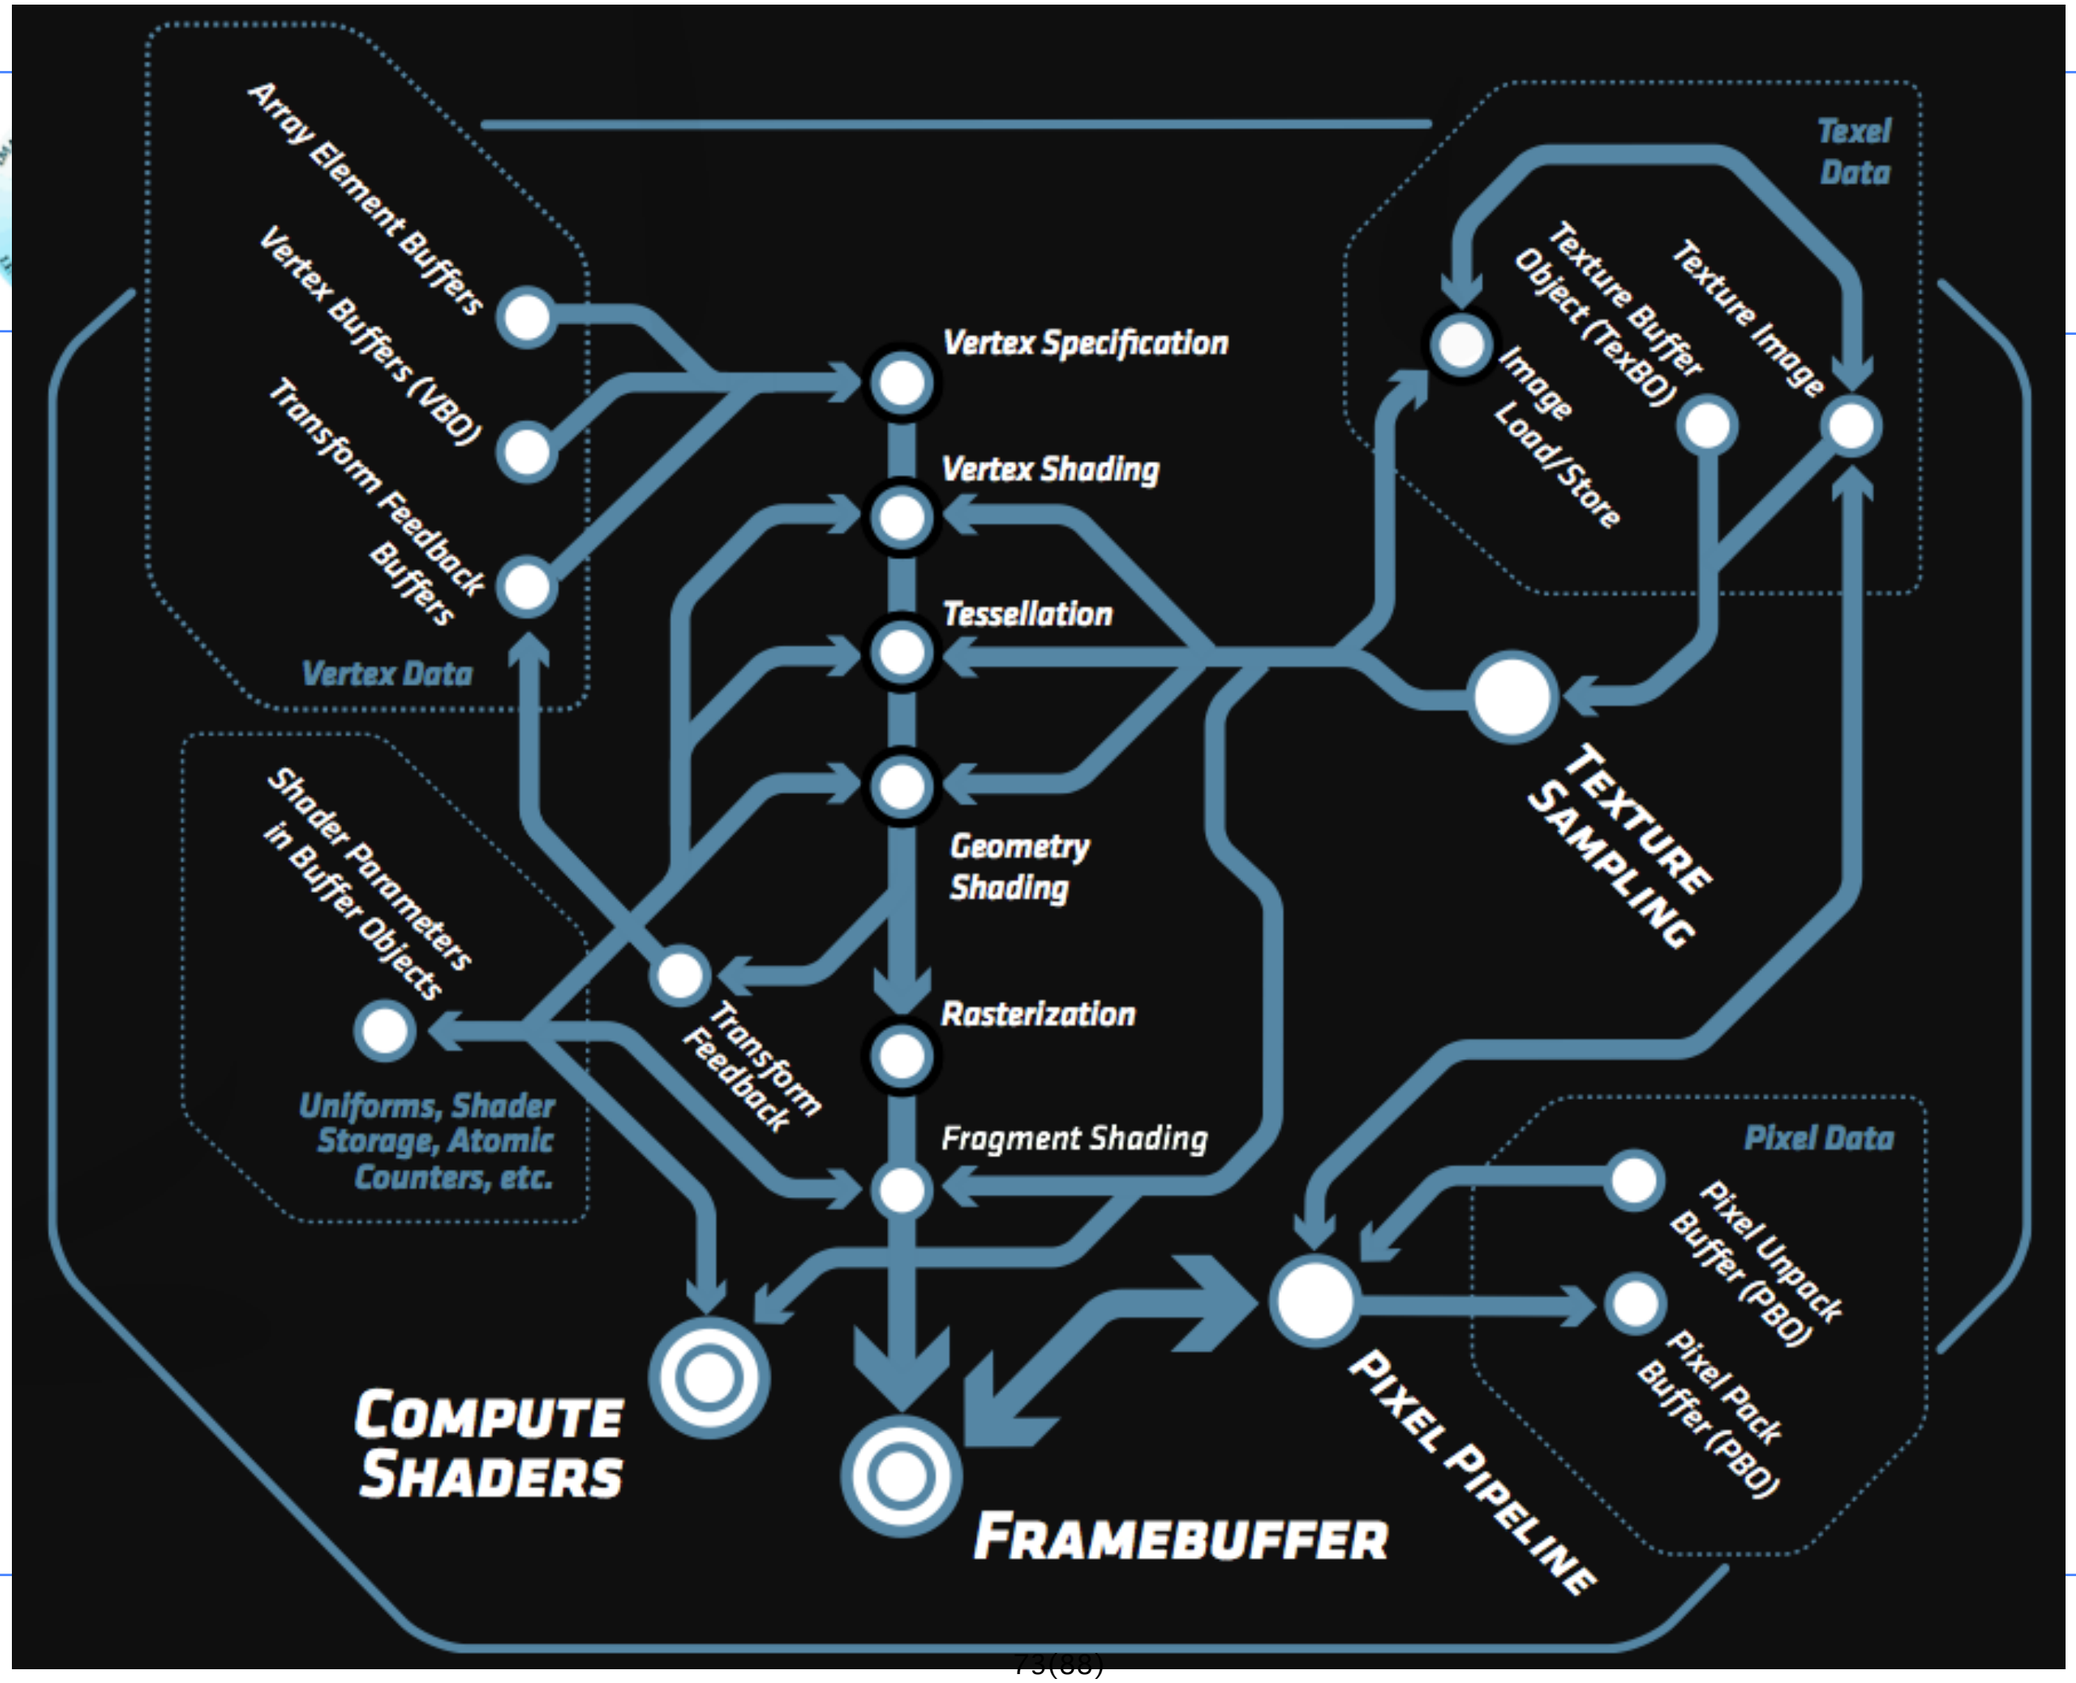
Array Element Buffers
Vertex Buffers (VBO)
Transform Feedback Buffers
Vertex Data
Vertex Specification
Vertex Shading
Tessellation
Geometry Shading
Rasterization
Fragment Shading
Texel Data
Texture Buffer Object (TexBO)
Texture Image
Image Load/Store
Texture Sampling
Shader Parameters in Buffer Objects
Uniforms, Shader Storage, Atomic Counters, etc.
Transform Feedback
Pixel Data
Pixel Unpack Buffer (PBO)
Pixel Pack Buffer (PBO)
Pixel Pipeline
Compute Shaders
Framebuffer

OK, hur gör jag?

Kompileras som alla andra shaders!

Modifiera labbkoden från GL_utilities, kompilera (ensam) som GL_COMPUTE_SHADER.

Lätta saker:

• Uniforms fungerar som vanligt

• Texturer fungerar som vanligt

(OBS att man kan skriva till texturer på Fermi och upp!)

Vadå skriva till texturer?

Japp. (Enbart nyaste GPUerna.)

Anrop i shader: imageStore()

imageStore(texUnit, texCoord, color);

Farligt! Risk för racing! Därför finns nytt anrop för synkronisering:

glMemoryBarrier() samt memoryBarrier() i shaders.

GLSL går mot allt generellare arkitektur - men frihet gör det inte lättare.

Tillbaka till Compute Shaders...

Lite annorlunda än vanliga shaders

Attribut finns inte

Inte en tråd per fragment

Shader Storage Buffer Objects:

Generell buffertyp för godtyckliga data

Kan deklareras så shadern ser det som en array av strukturer

Kan läsas och skrivas fritt av Compute Shaders!

Hur får jag in indata?

Ladda upp till SSBO:

```
glGenBuffers(1, &ssbo);
glBindBuffer(GL_SHADER_STORAGE_BUFFER, ssbo);
glBufferData(GL_SHADER_STORAGE_BUFFER, size, ptr,
GL_STATIC_DRAW);
```

Hur får shadern veta om den?

```
glBindBufferBase(GL_SHADER_STORAGE_BUFFER, id,
ssbo);
```

```
layout(std430, binding = id, buffer x {type y[];};
```

Hur accessar jag data i shadern?

Bestäm antal trådar per block:

layout(local_size_x = width, local_size_y = height)

Trådnummer:

gl_GlobalInvocation
gl_localInvocation

```
void main()
{
        buffer[gl_GlobalInvocation.x] =
                - buffer[gl_GlobalInvocation.x];
}
```

Hur kör jag kärnan?

glUseProgram(program);

glDispatchCompute(sizex, sizey, sizez);

Argumenten till glDispatchProgram anger antalet block / workgroups. Antal trådar (work items) per block anges av shadern.

Hur får jag ut utdata?

```
glBindBuffer(GL_SHADER_STORAGE, ssbo);
ptr = (int *) glMapBuffer(GL_SHADER_STORAGE,
GL_READ_ONLY);
```

Läs sedan från ptr[i]

```
glUnmapBuffer(GL_SHADER_STORAGE);
```

Komplett huvudprogram:

```
int main(int argc, char **argv)
{
  glutInit (&argc, argv);
  glutCreateWindow("TEST1");

// Load and compile the compute shader
  GLuint p =loadShader("cs.csh");

  GLuint ssbo; //Shader Storage Buffer Object

  // Some data
  int buf[16] = {1, 2, -3, 4, 5, -6, 7, 8, 9,
                 10, 11, 12, 13, 14, 15, 16};
  int *ptr;

// Create buffer, upload data
  glGenBuffers(1, &ssbo);
  glBindBuffer(GL_SHADER_STORAGE_BUFFER, ssbo);
  glBufferData(GL_SHADER_STORAGE_BUFFER,
      16 * sizeof(int), &buf, GL_STATIC_DRAW);

// Tell it where the input goes!
// "5" matches "layout" in the shader.

  glBindBufferBase(GL_SHADER_STORAGE_BUFFER,
         5, ssbo);

// Get rolling!
    glDispatchCompute(16, 1, 1);

// Get data back!
  glBindBuffer(GL_SHADER_STORAGE_BUFFER, ssbo);
  ptr = (int *)glMapBuffer(
         GL_SHADER_STORAGE_BUFFER,
         GL_READ_ONLY);
  for (int i=0; i < 16; i++)
  {
    printf("%d\n", ptr[i]);
  }
}
```

Enkel Compute Shader:

OBS: Egentligen alldeles för mycket trådar för data (16*16*16)

```
#version 430
#define width 16
#define height 16

// Compute shader invocations in each work group

layout(std430, binding = 5) buffer bbs {int bs[];};

layout(local_size_x=width, local_size_y=height) in;

//Kernel Program
void main()
{
  int i = int(gl_LocalInvocationID.x * 2);
  bs[gl_LocalInvocationID.x] = -bs[gl_LocalInvocationID.x];
}
```

Shared memory och synkronisering

Shared memory deklareras *shared*.

shared float myShared[SIZE];

Synkronisering finns i flera former, kallas barriers.

barrier()
memoryBarrier()
memoryBarrierShared()
groupMemoryBarrier()

Exempel: Transponering med shared memory

```
#version 450
#extension GL_ARB_compute_shader : enable
#define width 16
#define height 16

layout(std430, binding = 7) buffer bufc {float c[];};
layout(std430, binding = 5) buffer bufa {float a[];};
layout(local_size_x=width, local_size_y=height) in;

shared float s[width*height];

//Kernel Program
void main()
{
   uint theSizeX = gl_NumWorkGroups.x * gl_WorkGroupSize.x;
   uint theSizeY = gl_NumWorkGroups.y * gl_WorkGroupSize.y;

   int i = int(gl_GlobalInvocationID.y*theSizeX + gl_GlobalInvocationID.x);
   int j = int(gl_GlobalInvocationID.x*theSizeY + gl_GlobalInvocationID.y);
   int li = int(gl_LocalInvocationID.y*width + gl_LocalInvocationID.x);
   int lj = int(gl_LocalInvocationID.x*height + gl_LocalInvocationID.y);
   s[li] = a[i];

   barrier();

   c[i] = s[lj];
}
```

Kan du köra Compute Shaders?

Krav: OpenGL 4.3 + Kepler!

Inget svårt problem. 600-serien och uppåt.

Compute Shaders, ofta förbisett starkt alternativ

- Portabelt mellan olika grafikkort och OS
- I princip samma funktionalitet som CUDA och OpenCL
- Ingen separat installation

Projekt med Compute Shaders?

Varför inte - om du har ett problem stort nog.

Parallellprogrammering är framtiden!

All shaderprogrammering är parallellprogrammering.

Så gott som all prestandaökning i framtiden kommer från parallelism.

Vi fortsätter i TDDD56.

...och kanske i era projekt i denna kurs?