Cours 3: Sous le capot

Xavier Décoret – INF 683 - École Polytechnique

Overview

- Carte graphique
  - Pipeline
  - Framebuffer et tests
  - Considérations techniques
    - Interpolation
    - Rendu offscreen
- Shaders
  - Histoire & motivations
  - Principes & mise en oeuvre

Pipeline

- Le GPU est un *stream processor*
  - Prend en entrée un flux de sommets et de faces
  - Produit en sortie un flux de fragments
  - Combine ces fragments en une image
- Les étapes sont
  - Transform & lighting
  - Assembly stage
  - Scan conversion
  - Blending & tests

Fait ça en parallèle

SIMD

Attention au problème de concurrence

Transform & lighting

- Les coordonnées homogènes du sommet sont multipliées par la *modelview matrix* puis la *projection matrix*
- Les normales sont transformées
  - Voir le transparent suivant…
- Pour chaque source (1 à 8)
  - Le vecteur sommet/source est calculé
  - On calcule une couleur avec le modèle de Phong

produit

- Normalized Device Coordinates
- Couleur
- Coordonnées textures

Transformation des normales

- Un plan est caractérisé par

$$\underbrace{[a \quad b \quad c \quad d]}_{n}.[x \quad y \quad z \quad w]^T = 0$$

- Quelle est la caractérisation de la transformée d'un plan par une transformation affine de matrice M?

On cherche n' tel que $n'.(M[x \quad y \quad z \quad w]^T) = 0 \Leftrightarrow n.[x \quad y \quad z \quad w]^T$

Une solution est $n' = (M^T)^{-1} n$

Les normales doivent être transformées par **la transposée inverse**!

Assembly stage (1/2)

- Clippe les primitives contre le *viewport*
  - Évite de produire des fragments en dehors de l'image
  - Décompose en un ou plusieurs triangles
- On peut spécifier des plans de *clipping* (`glClipPlane`)

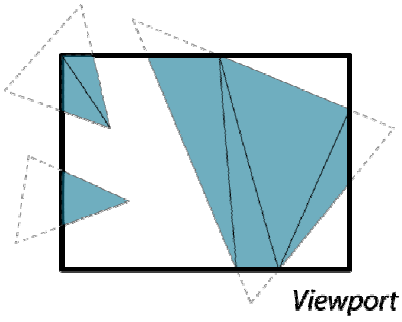

Assembly stage (2/2)

- Backface culling
  - Si un objet est "étanche", alors il n'y a pas besoin de dessiner les faces qui tournent le dos à l'observateur

On peut définir un intérieur et extérieur

Basé sur l'ordre des `glVertex`

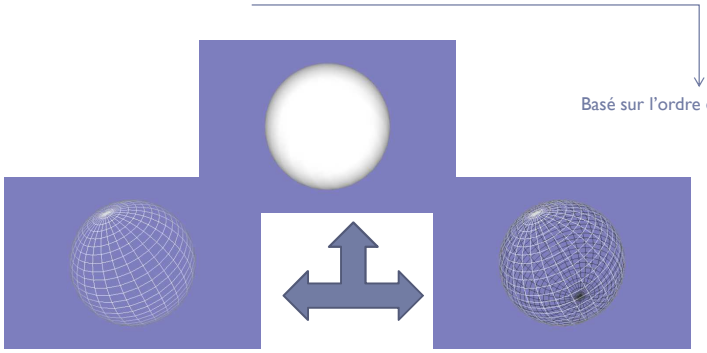

Avec culling

Sans culling

Scan conversion *aka* Raster (1/2)

- On considère les pixels dont *le centre* est dans le triangle
- Cela crée de l'aliasing
- Il faut filtrer
  - On peut filtrer soit-même
    - On double la résolution du viewport
    - On filtre l'image obtenue
  - Les cartes gèrent du *subsampling*

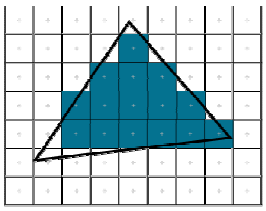

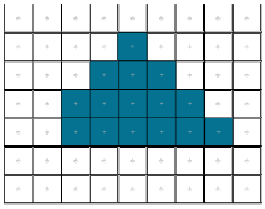

```
glSampleCoverage()
glHint()
```

Attention à l'activer sur la carte e.g.
- par le panneau de configuration
- par une variable d'environnement

Scan conversion *aka* Raster (2/2)

- On considère les pixels dont le centre est dans le triangle
- Cela crée de l'aliasing
- Il faut filtrer

Framebuffer (1/2)

- Au final on obtient une image couleur
- Mais en réalité, les pixels stockent plus d'information
  - Couleur RVB (chaque canal sur 8 bits)
  - Profondeur z (sur 24 bits)
  - Opacité A (sur 8 bits, packés avec RVB)
  - Valeur de *Stencil** (sur 8 bits, packés avec z)
- L'ensemble de ces pixels/valeurs forment le *framebuffer*

Comment les fragments produits par le *scan convert* sont-ils combinés avec les pixels correspondants du *framebuffer*?

**Stencil* = pochoir

Framebuffer (2/2)

- Les valeurs RVBA et z d'un fragment sont obtenues par interpolation linéaire des valeurs calculées aux sommets
- On effectue un certains nombres de tests
  - Depth test
  - Alpha test
  - Stencil test
- Selon le résultats de ces tests:
  - La couleur du fragment est combinée avec celle du pixel
  - Le z de ce pixel est remplacé par celui du fragment
  - La valeur de stencil est mise à jour

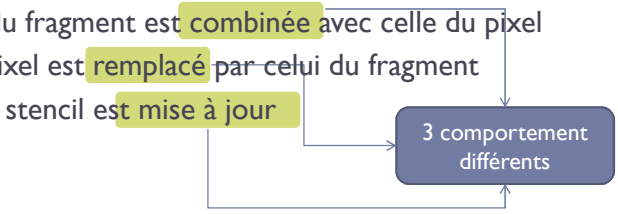

Interpolation et perspective (1/4)

- Il faut faire attention en interpolant en espace image

Le milieu des projections des extremités d'un segment
ne coïncide pas avec la projection du milieu du segment

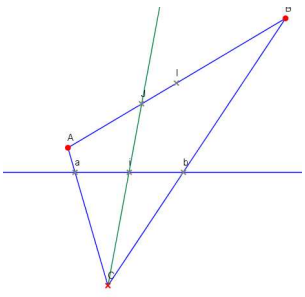

Interpolation et perspective (2/4)

Projeter le point c'est trouver l…

Par Thales, on obtient $l = \frac{y}{w} \times \frac{-d}{-d + \frac{z}{w}}$

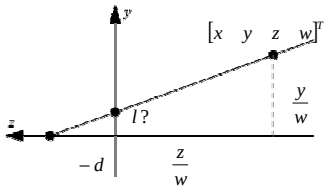

On vérifie que si on pose

$$\begin{pmatrix} X \\ Y \\ Z \\ W \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{-d} & 1 \end{pmatrix} \begin{pmatrix} x \\ y \\ z \\ w \end{pmatrix}$$

On a

$$\frac{Y}{W} = \frac{y}{\frac{z}{-d} + w} = \frac{y}{w} \times \frac{d}{d - \frac{z}{w}} = l$$

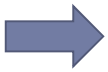

La matrice 4x4 représente la projection en coordonnées homogènes

Interpolation perspective (3/4)

Si $a = [x \quad y \quad z \quad w]$
$a' = [x' \quad y' \quad z' \quad w']$ sont des coordonnées homogènes de A et A'

alors le projeté du barycentre de (α,A),(α',A') admet pour coordonnées homogènes

$$b = \alpha Ma + \alpha' Ma' \quad \text{avec} \quad M = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{-d} & 1 \end{pmatrix}$$

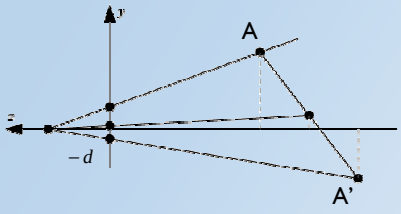

On peut interpoler linéairement les coordonnées homogènes!

Interpolation perspective (4/4)

- Exemple du *Projective Texture Mapping*

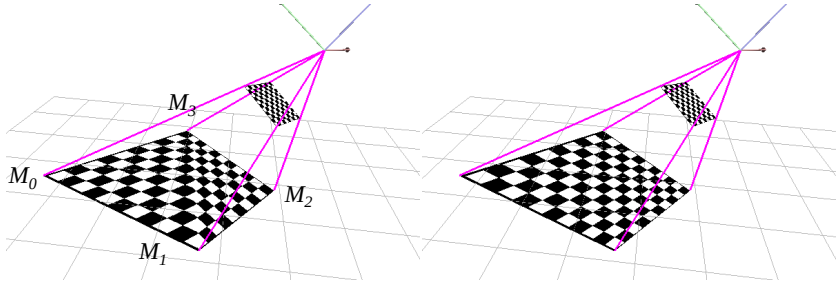

On prend des coord. textures "unitaires"
M_0 : (0,0) M_2:(1,1)
M_1 :(1,0) M_3:(0,1)

On calcule les coord. textures en utilisant une transformation 4x4 qui projete les M_i dans l'espace texture et peut être interpolé correctement.

Voir le code source de l'exemple sur le site du cours

Interpolation & shading

- Il faut renormaliser les normales
  - Une combinaison linéaire de vecteur unitaires n'est pas unitaire
  - On peut utiliser `glEnable(GL_NORMALIZE)`
- L'interpolation du *light vector* est incorrecte
  - Mais c'est bon si la lampe est "loin"

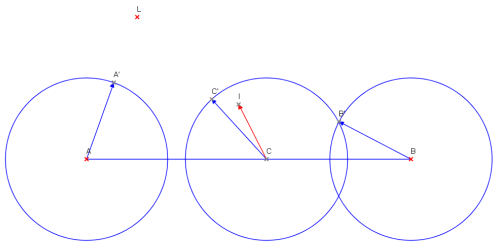

Framebuffer

- Les valeurs RVBA et z d'un fragment sont obtenues par interpolation linéaire des valeurs calculées aux sommets
- On effectue un certains nombres de tests
  - Depth test
  - Alpha test
  - Stencil test
- Selon le résultats de ces tests:
  - La couleur du fragment est combinée avec celle du pixel
  - Le z de ce pixel est remplacé par celui du fragment
  - La valeur de stencil est mise à jour

Depth-test (1/4)

Sortie du scan convert Stocké dans le z-buffer

- Le z du fragment est comparé avec le z du pixel

```
glDepthFunc(GL_LEQUAL)
// ou GL_GREATER, GL_LESS, GL_ALWAYS, GL_NONE, GL_EQUAL
```

- En cas d'échec, le frament est discardé
  - Autres tests pas effectués
  - Mais mise à jour possible du framebuffer (cf. stencil test)
- C'est inventé pour l'élimination des faces cachées
- Mais il y a pleins d'usages détournés…

T. Theoharis, The Magic of the Z-Buffer: A Survey, 2001

Depth-test (2/4)

- Cubist images

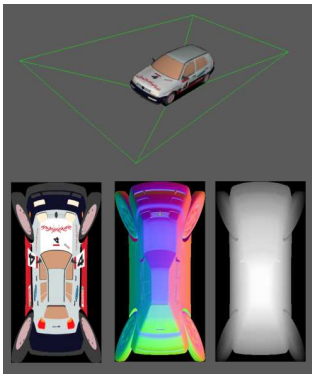

Hanson A. et al., Image-Based Rendering with Occlusions via Cubist Images, 1998

Baboud L. and Décoret X., Rendering Geometry with Relief Textures, 2006

Depth-test (2/4)

- Diagramme de Voronoï

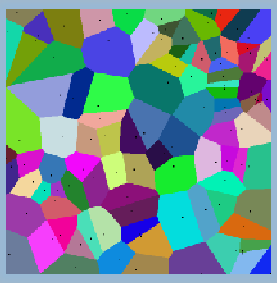

Le diagramme de Voronoi associe à des points p_i des régions $V(p_i)$ telles que tous les points de V(p) sont plus proches de p_i que de n'importe quel p_j

2D site	Shape of Distance Function	Figure
Point	Right circular cone	3a
Line segment	"Tent"	3b
Polygon	Cones and tents	5

Table 1: Shape of Distance Functions for 2D Sites

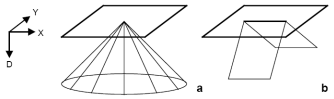

Figure 3: The distance meshes used for a point (left) and a line segment (right). The XY-plane containing the site is shown above each mesh.

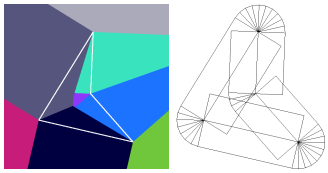

Hoff et al., Fast Computation of Generalised Voronoi Diagrams Using Graphics Hardware, 1999

Depth-test (3/4)

- Le z-buffer a une précision limité (24 bits)
- On ne peut pas représenter tous les z
  - Il faut limiter l'intervalle de profondeur!
  - C'est pour cela que la caméra *pinhole* a des *near/far planes*!
  - Les points en deçà/au delà sont clippés

$$\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & \frac{1}{-near} & 1 \end{bmatrix}$$

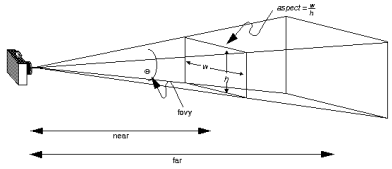

$$\begin{bmatrix} \frac{f}{aspect} & 0 & 0 & 0 \\ 0 & f & 0 & 0 \\ 0 & 0 & \frac{near+far}{near-far} & \frac{2near\,far}{near-far} \\ 0 & 0 & -1 & 0 \end{bmatrix}$$

avec $f = \text{cotan}(\frac{\theta}{2})$

Matrice que l'on a trouvé tout à l'heure pour effectuer la division par z (perspective)

Matrice corrigé pour mapper le view frustum sur le cube unité (NDC)

Depth-test (4/4)

- Le z-buffer n'a pas une dynamique linéaire!
  - À cause de l'interpolation en coordonnées homogènes
  - À cause du *near* et *far plane* http://www.sjbaker.org/steve/omniv/love_your_z_buffer.html
- On a des problèmes de *z-fighting*
  - *Ça vient aussi du fait que la rasterisation n'est pas "constante"*
  - *C'est accentué par la non-linéarité du z*

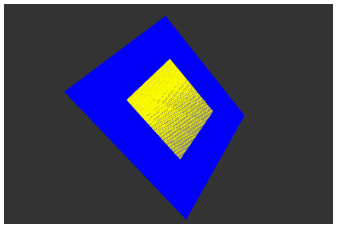

Bien optimiser ses near/far!

On reparlera de ce problème dans le cours sur les ombres

Stencil Test (1/2)

Attention, pas du fragment!

- Compare le stencil du pixel avec une constante
  `glStencilFunc(GL_EQUAL,1,~0)`
- Met à jour par incrément/décrément ou constante
  `glStencilOp(GL_INCR,GL_KEEP,GL_REPLACE)`
  `fail zfail zpass`

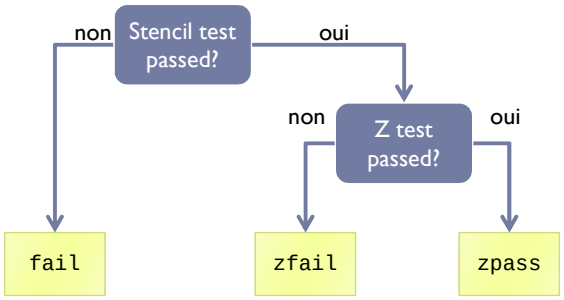

Stencil Test (2/2)

- Applications nombreuses
  - Effectuer un traitement spécial dans une zone du *viewport*
  - Mesurer l'*overdraw*
  - Calculer des ombres (cf. cours sur les ombres)
  - …

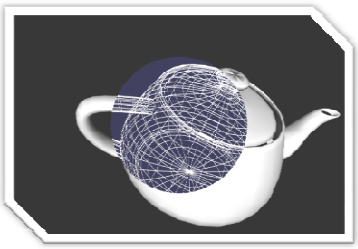

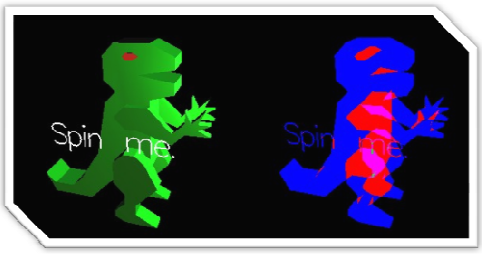

http://excamera.com/articles/2/index.html

Alpha test

- Compare le A à une constante
  `glAlphaFunc(GL_GREATER,0.0f)`
- Discarde le fragment en cas d'échec
  - Notamment, n'écrit rien dans le z-buffer
  - On va voir dans un instant à quoi ça sert…

Alpha blending

- Combine le RVBA du fragment (source) avec celui du pixel (destination)
  - `glBlendFunc(GL_SRC_ALPHA,GL_ONE_MINUS_SRC_ALPHA);`
- Permet des effets de transparence
- Nécessite de trier
  - Pas possible par primitives, doit être par pixel
  - C'est problème sans solution simple aujourd'hui

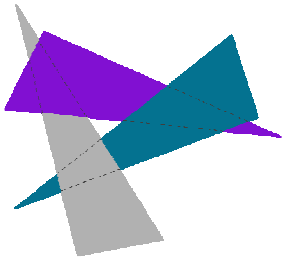

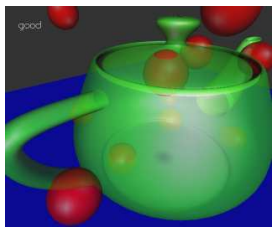

http://developer.nvidia.com/object/Interactive_Order_Transparency.html

Alpha test & alpha blending (1/2)

- L'alpha test permet de régler le problème du tri pour du blending "binaire" (A=0 ou 1)

Ordre de rendu 

Sans alpha test Avec alpha test

Alpha test & alpha blending (2/2)

- Mais ça crée des problèmes avec la magnification linéaire

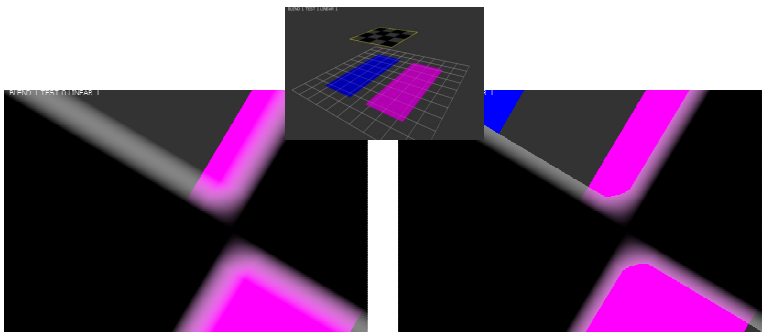

Accéder au framebuffer

- On "voit" la couleur dans la fenêtre associée au contexte OpenGL, mais quid des autres composantes?
- On peut les récupérer avec un `glReadPixels()`
  - Transfert CPU/GPU potentiellement coûteux
  - Visualisation à définir (e.g. code couleur pour stencil)
- On peut utiliser un framebuffer temporaire
  - On voit ça tout de suite avec le rendu *offscreen*…
- On peut reprogrammer la couleur des fragments
  - On voit ça juste après le rendu *offscreen*!

Rendu *offscreen* (1/2)

- Rendu dans un framebuffer qui n'est pas associé à une fenêtre à l'écran (utilise sa propre zone mémoire)
  - Utilise son propre contexte OpenGL: *P-buffer*
  - Partage le contexte avec celui de la fenêtre: *framebuffer*
  - Fait la même chose qu'un `glReadPixels+glTexImage` mais sans transferts CPU/GPU
- Un peu technique à mettre en oeuvre
  - Et encore, aujourd'hui c'est standardisé!
  - Partir d'un exemple qui marche (cf. site web du cours)
- Quelques limitations
  - Le multisampling ne marche pas sur les *framebuffer*
  - Le z-buffer nécessite une recopie manuelle

Rendu *offscreen* (2/2)

- Permet de faire des calculs temporaires
- Pleins d'applications en graphisme
  - Exemple du miroir
  - *Shadow map* (cf. le cours sur les ombres)
- Pleins d'applications aux calculs génériques

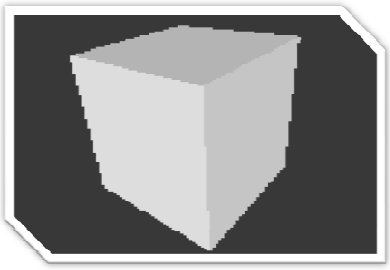
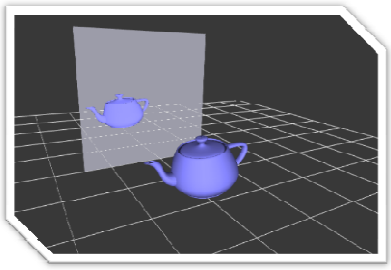

Bilan (soufflons un peu)

- On a vu beaucoup de choses
  - Mais ce n'est qu'un petit bout!

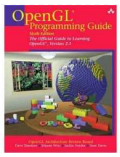

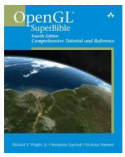

- Beaucoup de ces choses sont comme elles sont pour des raisons historiques
  - Les cartes cablaient "en dur" certaines fonctionnalités 3D
  - C'est ce qu'on appelle le *fixed pipeline*
- En 2003, il y a eu un gros bouleversement…

Besoins en programmabilité…

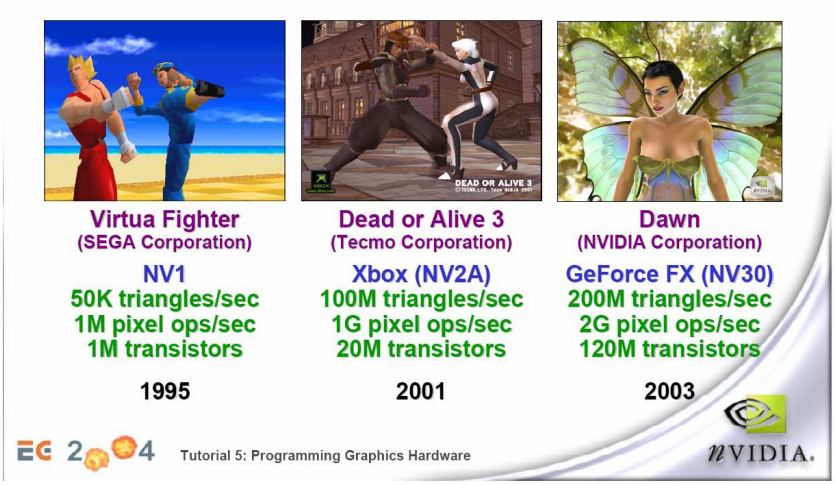

Besoins en programmabilité…

GeForce 7800 GTX	
Graphics Bus Technology	PCI Express
Memory	512MB
Memory Interface	256-bit
Memory Bandwidth (GB/sec.)	54.4
Fill Rate (billion pixels/sec.)	13.2
Vertices/sec. (million)	1100
Pixels per clock (peak)	24
RAMDACs (MHz)	400

Photo courtesy of id Software, © 2004.

Besoins en programmabilité…

- La puissance disponible augmente les attentes
  - Plus de complexité/détails dans la forme et le *shading*
  - Un rendu temps-réel avec une qualité type cinéFX
- Le hard est devenu programmable
  - Dans une certaine mesure
  - Mais pas exposé par les drivers
- Le *shading* réaliste est complexe
  - Son design doit être *artist-friendly*
  - Son design doit être modulaire = réutilisable

Qu'est ce qui est programmable?

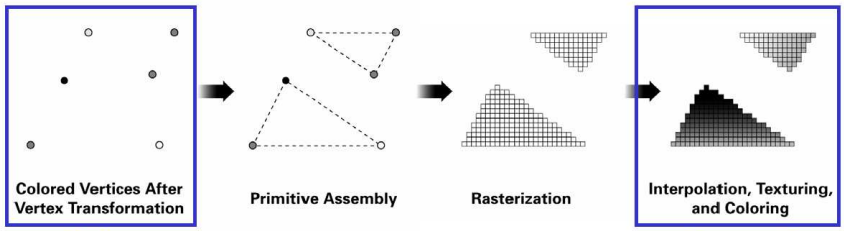

Vertex Program

Executed Once Per Vertex

On dit aussi vertex/fragment ***shader*** pour des raisons historiques.
Le terme "***program***" est bien mieux adapté au concept

Fragment Program

Executed Once Per Fragment

Avec quel langage?

- Bas niveau
  - Comme l'assembleur mais un peu plus simple
  - C'est l'approche historique
  - Formalisée sous forme d'extension OpenGL
- Haut niveau
  - Syntaxe proche du C/C++
  - Déjà existant pour le cinéFX
  - Plusieurs concurrents

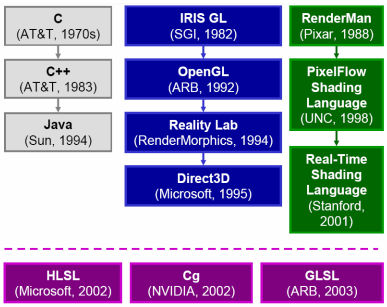

Haut *vs.* bas niveau (1/2)

- Bas niveau
  - Très proche du métal
    - Plus facile de comprendre les performances
    - Permet des optimisations sioux
  - Dur à programmer
  - Dépendent du hardware
    - Doit être ré-écrit/optimisé pour chaque plateforme
    - N'anticipe pas les évolutions du hard

Assembly

```
DP3 R0, c[11].xyzx, c[11].xyzx;
RSQ R0, R0.x;
MUL R0, R0.x, c[11].xyzx;
MOV R1, c[3];
MUL R1, R1.x, c[0].xyzx;
DP3 R2, R1.xyzx, R1.xyzx;
RSQ R2, R2.x;
MUL R1, R2.x, R1.xyzx;
ADD R2, R0.xyzx, R1.xyzx;
DP3 R3, R2.xyzx, R2.xyzx;
RSQ R3, R3.x;
MUL R2, R3.x, R2.xyzx;
DP3 R2, R1.xyzx, R2.xyzx;
MAX R2, c[3].z, R2.x;
MOV R2.z, c[3].y;
MOV R2.w, c[3].y;
LIT R2, R2;
...
```

Haut *vs.* bas niveau (1/2)

- Haut niveau
  - Facile à programmer
  - Facile à réutiliser
  - Facile à réutiliser (vraiment!)
  - Compilé
    - Indépendent du hardware
    - Difficile d'identifier les goulots

High-Level Language

```
…
float3 cSpecular = pow(max(0, dot(Nf, H)),
                       phongExp).xxx;
float3 cPlastic = Cd * (cAmbient + cDiffuse) +
                  Cs * cSpecular;
…
```


Les langages existants

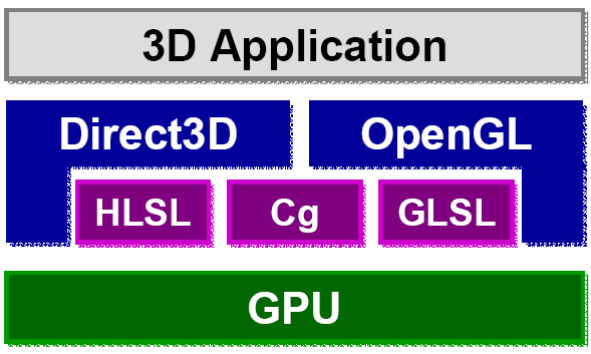

Language features (1/3)

- Control flow statements
  - if, for, while,break, continue
  - pas de goto
- Fonctions et struct définies par l'utilisateur
  - bien pour la modularité et la réusabilité
- Fonctions *builtins*
  - math :abs, pow, sqrt, step, smoothstep...
  - geometrie :dot, cross, normalize, reflect, refract...
  - texture lookups
  - accès à la machine à état OpenGL

Language features (2/3)

- Support pour les vecteurs et matrices

  - Component-wise + - * / for vectors
  - Dot product
    - `dot(v1,v2); // returns a scalar`
  - Matrix multiplications:
    - assuming a `float4x4 M` and a `float4 v`
    - matrix-vector: `mul(M, v); // returns a vector`
    - vector-matrix: `mul(v, M); // returns a vector`
    - matrix-matrix: `mul(M, N); // returns a matrix`

Language features (3/3)

- Nouveaux opérateurs
  - Swizzle operator extracts elements from vector or matrix

```
a = b.xxyy;
```

  - Examples:

```
float4 vec1 = float4(4.0, -2.0, 5.0, 3.0);
float2 vec2 = vec1.yx;      // vec2 = (-2.0,4.0)
float scalar = vec1.w;      // scalar = 3.0
float3 vec3 = scalar.xxx;   // vec3 = (3.0, 3.0, 3.0)
float4x4 myMatrix;

// Set myFloatScalar to myMatrix[3][2]
float myFloatScalar = myMatrix._m32;
```

  - Vector constructor builds vector

```
a = float4(1.0, 0.0, 0.0, 1.0);
```


Qu'est ce qui n'est pas programmable?

- L'assembly est en partie programmable
  - Ce sont les geometry *shaders/programs*
  - Seules les cartes très récentes le supportent (DX10)
  - Affecte fortement les perfs si mal utilisés
- Ne sont pas modifiables/programmables
  - Les tests (z,alpha,stencil)
  - L'interpolation pendant le scan convert
- On ne peut pas accéder au framebuffer dans un *program*
  - Poserait des problèmes de concurrence (SIMD)
  - Peut parfois être contourné par du multipass+render2texture

Résumé (retour au cours 1)

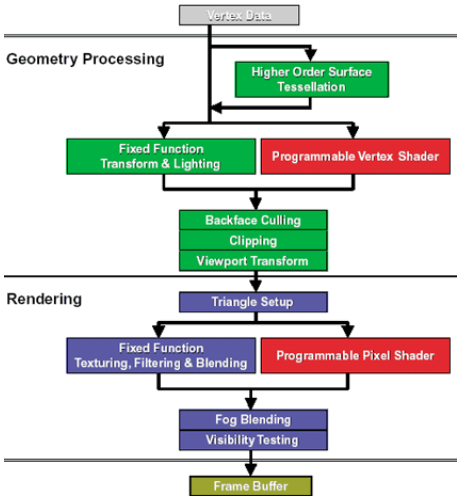

En pratique

- Appels à l'API pour
  - Spécifier les vertex & fragment programs
  - Activer les vertex & fragment programs
  - Passer les paramètres "globaux" aux programs
- Géometrie rendue comme précédemment
  - Le *vertex program* sera exécuté pour chaque *vertex*
  - Le *fragment program* sera exécuté pour chaque *fragment*
    - Sauf en cas d'échec du z-test si le shader ne modifie pas le z
    - C'est ce qu'on appelle *early z rejection*

Exemple: *toon shading* (1/3)

Fichier `toon.vert`

```
varying vec3 normal;

void main() {
    normal = gl_NormalMatrix * gl_Normal;
    gl_Position = ftransform();
}
```

Fichier `toon.frag`

```
varying vec3 normal;
uniform vec3 t;

void main()  {
    vec4 color;
    vec3 n = normalize(normal);
    float i = dot(vec3(gl_LightSource[0].position),n);
    if (i>treshold[0]) color = vec4(1.0,0.5,0.5,1.0);
    else if (i>threshold[1]) color = vec4(0.6,0.3,0.3,1.0);
    else if (i>threshold[2]) color = vec4(0.4,0.2,0.2,1.0);
    else color = vec4(0.2,0.1,0.1,1.0);

    gl_FragColor = color;
}
```


Exemple: *toon shading* (2/3)

```
GLhandleARB v = glCreateShaderObjectARB(GL_VERTEX_SHADER_ARB);
GLhandleARB f = glCreateShaderObjectARB(GL_FRAGMENT_SHADER_ARB);
char* vs = vs = textFileRead("toon.vert");
char* fs = textFileRead("toon.frag");
const char* vv = vs;
const char* ff = fs;
glShaderSourceARB(v, 1, &vv,NULL);
glShaderSourceARB(f, 1, &ff,NULL);
free(vs);
free(fs);
glCompileShaderARB(v);
glCompileShaderARB(f);

GLhandleARB p = glCreateProgramObjectARB();
glAttachObjectARB(p,v);
glAttachObjectARB(p,f);
glLinkProgramARB(p);

glUseProgramObjectARB(p);
```

Exemple: *toon shading* (3/3)

```
// once for all (in QGLViewer::init())
GLint thresholdParam = glGetUniformLocationARB(p,"threshold");

// at every frame (in QGLViewer::draw())
glUseProgramObjectARB(p);
glUniform3fARB(thresholdParam,0.95f,0.5f,0.25f);
glPolygonMode(GL_FRONT_AND_BACK,GL_LINE);
glBegin(GL_TRIANGLES);
// draw teapot
glNormal3fv(...);glVertex3v(...);
...
glEnd();
glUseProgramObjectARB(0);
```


Applications des shaders/programs

- Computer graphics
  - Pleins de beaux effets

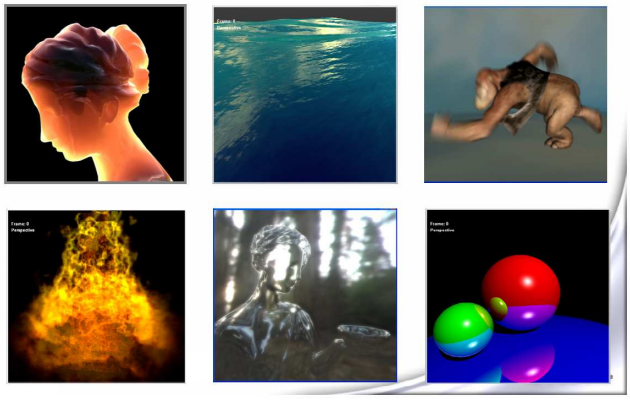

Applications des shaders/programs

- Computer graphics
  - Pleins de beaux effets
  - Des structures d'accélération
  - Voir *GPU Gems I & II*

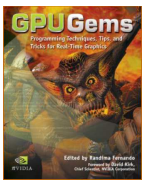

`http://developer.nvidia.com/object/gpu_gems_2_home.html`

- General Purpose GPU (GPGPU)
  - Algèbre linéaire
  - Simulation
  - …

C'est fini pour aujourd'hui

C'est l'heure de la pause

(can you find the hidden tiger?)