



*N*VIDIA®

パフォーマンス・ツール

パフォーマンス・ツール概要



- GPUアーキテクチャについて
- NVGLExpert: OpenGL APIの援助
- NVShaderPerf: シェーダのパフォーマンス
- NVPerfKit: ドライバとGPUのパフォーマンス
- NVPerfHUD: 対話式パフォーマンス解析

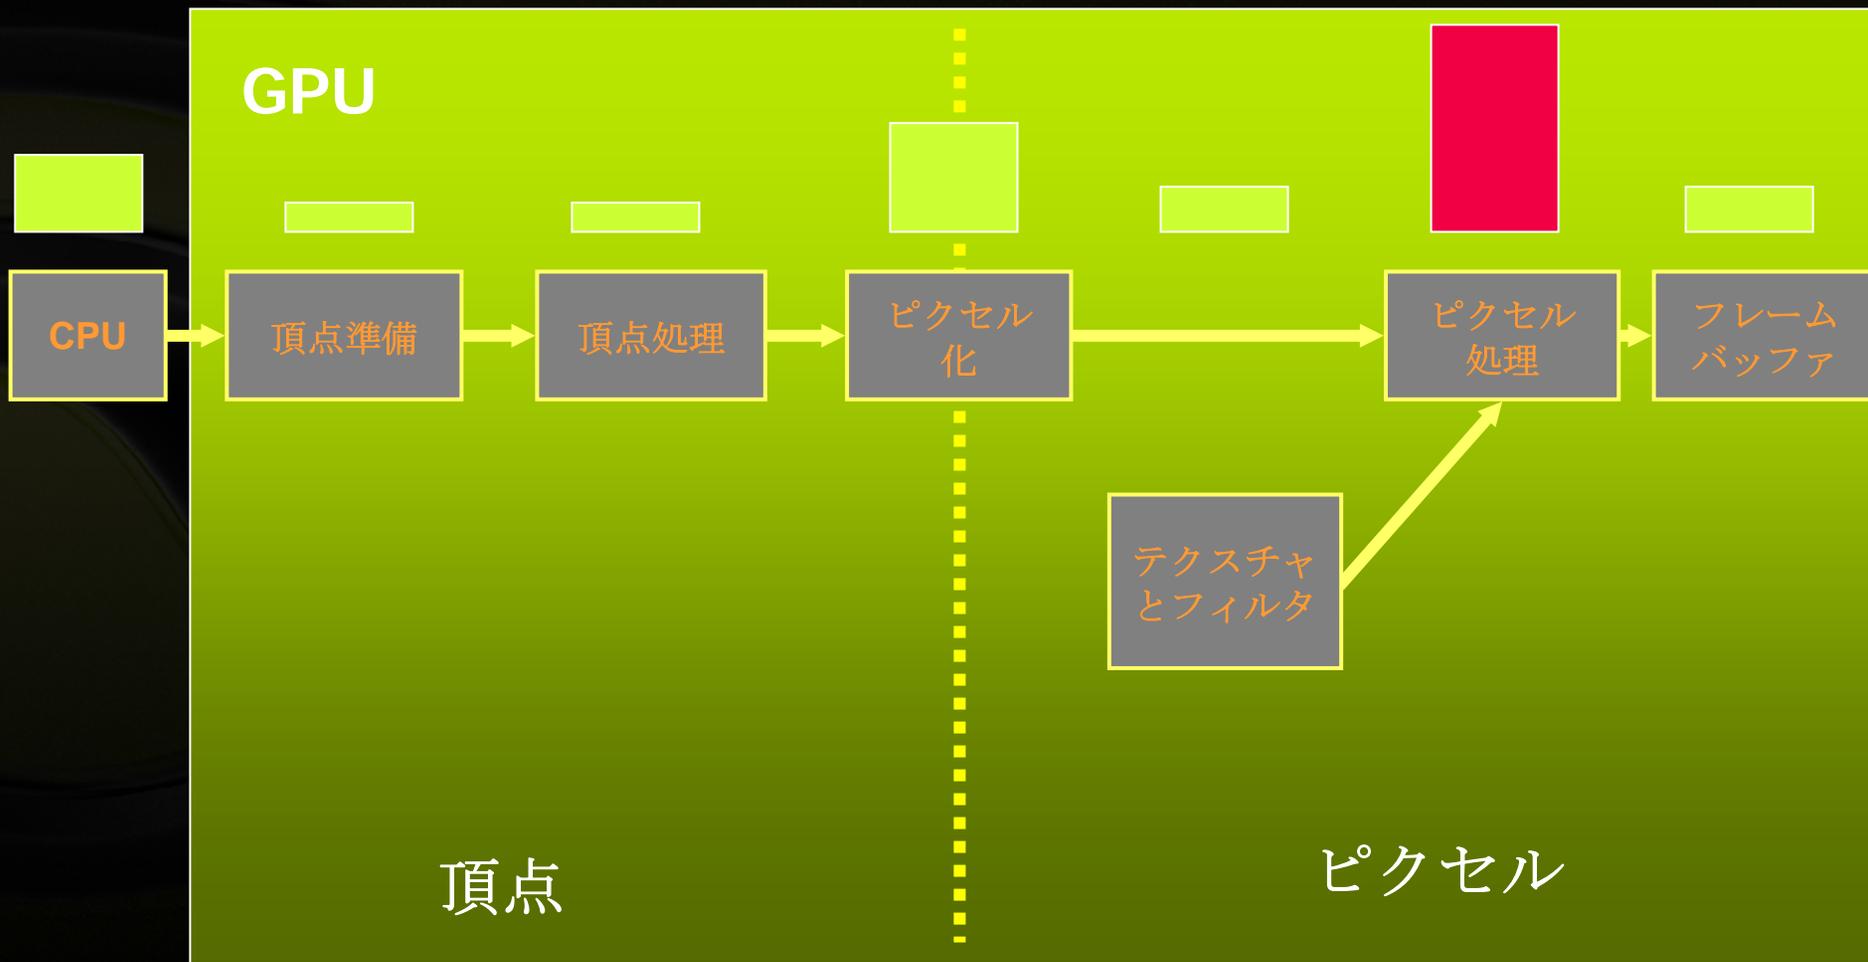
GPUアーキテクチャ



- パイプライン構成
 - 各ユニットは、仕事をするのに前のユニットからのデータが必要
- ボトルネックの発見と解消
- パイプラインを平均化

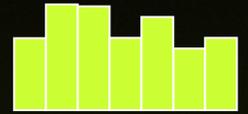


GPUパイプライン構成(簡略図)



単一ユニットによりパイプライン速度が制限

ボトルネックの発見

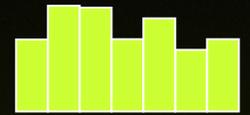


- ユニットの仕事を量を変化させる
 - 負荷を低減



- パフォーマンス (**FPS**) の改善があれば、このユニットがボトルネック
- 他ユニットの仕事量を変えないように注意

ボトルネックの発見

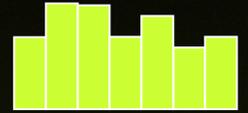


- 他ユニットの可能性を排除
 - 仕事量をほとんどなくす



- パフォーマンスに顕著な変化が見られなければ、このユニットがボトルネック
- 検証中ユニットの負荷を変えないように注意

ボトルネックの発見



- パイプライン中各点の計測
 - **NVPerfKit**と**NVPerfHUD**を使用
 - 最大処理速度と比較した実質処理量

NVGLExpert



- 概要
- プロジェクトの現状

概要



- CPU処理の問題を解消
- 計測用**OpenGL**ドライバ
 - ファイル、コンソール、またはデバッガへの情報出力
 - 各グループレベルでの情報詳細
- 簡単な**GUI**ツールで操作
 - **Windows**版ではレジストリを設定
 - **Linux**版では環境変数を設定
- 現時点での機能
 - **OpenGL**エラーの出力
 - ドライバがソフトウェア処理を使っているか
 - シェーダのコンパイルエラー
 - **VBO**の保存領域
 - **GL_FRAMEBUFFER_UNSUPPORTED_EXT**の理由
- 機能はこれからも拡張予定

プロジェクトの現状



- 次の大きなドライバ配布で公開
- **Windows**ならびに**Linux**
- 現在は**NV3x**と**NV4x**のみ
- 他に必要な情報は？

NVGLExpert@nvidia.com

NVShaderPerf



- 概要
- バージョン**1.8**での更新
- バージョン**2.0**で更新になる事項

```
2f BumpReflectVS(a2v IN,
uniform float4x4 WorldViewProj,
uniform float4x4 World,
uniform float4x4 ViewIT)
```



NVShaderPerf

```
// first rows are the tangent and binormal scaled by the bump scale
TangentToObjSpace[0] = float3(IN.Tangent.x, IN.Binormal.x, IN.Normal.x);
TangentToObjSpace[1] = float3(IN.Tangent.y, IN.Binormal.y, IN.Normal.y);
TangentToObjSpace[2] = float3(IN.Tangent.z, IN.Binormal.z, IN.Normal.z);
OUT.TexCoord1.xyz = dot(World[0].xyz, TangentToObjSpace[0]);
OUT.TexCoord2.xyz = dot(World[1].xyz, TangentToObjSpace[0]);
OUT.TexCoord3.xyz = dot(World[2].xyz, TangentToObjSpace[0]);
OUT.TexCoord1.x = dot(World[0].xyz, TangentToObjSpace[1]);
OUT.TexCoord2.y = dot(World[1].xyz, TangentToObjSpace[1]);
OUT.TexCoord3.z = dot(World[2].xyz, TangentToObjSpace[1]);
OUT.TexCoord1.y = dot(World[0].xyz, TangentToObjSpace[2]);
OUT.TexCoord2.x = dot(World[1].xyz, TangentToObjSpace[2]);
OUT.TexCoord3.y = dot(World[2].xyz, TangentToObjSpace[2]);
float4 worldPos = mul(IN.Position, World);
// compute the vector pointing from shaded point to eye in cube space
float3 eyeVec = WorldPos - ViewIT[3]; // view inv. transpose contains eye position in world space
OUT.TexCoord1.w = eyeVec.x;
OUT.TexCoord2.w = eyeVec.y;
OUT.TexCoord3.w = eyeVec.z;
return OUT;
}

float4 BumpReflectVS(a2v IN,
uniform float4x4 WorldViewProj,
uniform float4x4 World,
uniform samplerCUBE EnvironmentMap,
uniform float BumpScale) : COLOR
{
// fetch the bump normal from the normal map
float3 normal = tex2D(NormalMap, IN.TexCoord.xy).xyz * 2.0 - 1.0;
normal = normalize(float3(normal.x * BumpScale, normal.y * BumpScale, normal.z));
// transform the bump normal into cube space
// then use the transformed normal and eye vector to compute a reflection vector
// used to fetch the cube map
// (we multiply by 2 only to increase precision)
float3 eyeVec = float3(IN.TexCoord1.w, IN.TexCoord2.w, IN.TexCoord3.w);
float3 worldNorm;
worldNorm.x = dot(IN.TexCoord1.xyz, normal);
worldNorm.y = dot(IN.TexCoord2.xyz, normal);
worldNorm.z = dot(IN.TexCoord3.xyz, normal);
float3 lookup = reflect(eyeVec, worldNorm);
return texCUBE(EnvironmentMap, lookup);
}
```

- 入力:
- HLSL
- GLSL (フラグメント)
- FP1.0
- ARBfp1.0
- PS1.x, PS2.x, PS3.x
- VS1.x, VS2.x, VS3.x
- Cg

NVShaderPerf

GPUアーキテクチャ:

- GeForce 7800 GTX
- GeForce 6X00 FXシリーズ
- Quadro FXシリーズ

C:\WINDOWS\system32\cmd.exe

```

dp3 r0.x, r1, r1
rsq r0.w, r0.x
nrm r0.xyz, t1
mad r1.xyz, r1, r0.w, r0
nrm r2.xyz, r1
nrm r1.xyz, t2
dp3 r2.x, r2, r1
max r1.w, r2.x, c9.x
pow r0.w, r1.w, c5.x
add r1.w, r0.w, -c7.x
mov r2.w, c6.x
add r2.w, r2.w, -c7.x
rcp r2.w, r2.w
mul_sat r2.w, r1.w, r2.w
mad r1.w, r2.w, c9.y, c9.z
mul r2.w, r2.w, r2.w
mul r1.w, r1.w, r2.w
mov r2.x, c9.w
add r2.w, r2.x, -c8.x
mad r1.w, r1.w, r2.w, c8.x
dp3 r0.x, r0, r1
mul r0.w, r0.w, r1.w

mul r1.xyz, r0.w, c4
add r0.w, r0.x, c9.w
mul r0.w, r0.w, c10.x
mov r0.xyz, c0
add r0.xyz, r0, -c1
add r2.xyz, r0, -c2
add r2.xyz, r0, -c3
add r2.w, r0.w, c3
mov r1.w, c9.w
rcp r0.w, r0.w

// Shader performance using all FP32
Target: GeForce 6800 Ultra (NV40) :: Unified Compiler: v61.7
Cycles: 14.00 :: R Regs Used: 2 :: R Regs Max Index (0 based)
Pixel throughput (assuming 1 cycle texture lookup) 304.76 M
=====
Shader performance using all FP16
Target: GeForce 6800 Ultra (NV40) :: Unified Compiler: v61.7
Cycles: 21.00 :: R Regs Used: 3 :: R Regs Max Index (0 based)
Pixel throughput (assuming 1 cycle texture lookup) 457.14 M
=====
C:\Temp\NVShaderPerf_61_77>

```

出力:

- アセンブリ
- サイクル数
- 一時レジスタ数
- ピクセル処理量
- 全てfp16と全てfp32のケース

NVShaderPerf: 制作工程での使用



- 現在のパフォーマンス
 - 目標サイクル数に対して
 - 最適化の可能性を検証
- 自動的復帰試験
- **FX Composer 1.7への統合**

FX Composer 1.7 – Shader Perf



- アセンブリ
- 対象となる**GPU**
- ドライバのバージョンとの適合
- サイクル数
- レジスタ数
- ピクセル処理量
- 全てfp16と全てfp32のケース (パフォーマンス範囲の特定)

The screenshot displays two instances of the 'Shader Perf' window. The top window is for 'GeForceFX 5200' and the bottom window is for 'GeForce 6800 Ultra'. Both windows show performance metrics for a 'Pixel Shader' on 'p0'.

GeForceFX 5200 Performance:

- Target: GeForceFX 5200 Ultra (NV34) :: Unified Compiler: v61.77
- Cycles: 51 :: # R Registers: 4
- Pixel throughput (assuming 1 cycle texture lookup) 15.69 MP/s
- Shader performance using all FP16: Cycles: 51 :: # R Registers: 2, Pixel throughput: 15.69 MP/s

GeForce 6800 Ultra Performance:

- Target: GeForce 6800 Ultra (NV40) :: Unified Compiler: v61.77
- Cycles: 21.00 :: R Regs Used: 3 :: R Regs Max Index (0 based): 2
- Pixel throughput (assuming 1 cycle texture lookup) 304.76 MP/s
- Shader performance using all FP16: Cycles: 14.00 :: R Regs Used: 2 :: R Regs Max Index (0 based): 1, Pixel throughput: 457.14 MP/s
- Shader performance using all FP32: Cycles: 21.00 :: R Regs Used: 3 :: R Regs Max Index (0 based): 2, Pixel throughput: 304.76 MP/s
- PS Instructions: 38
- ps_2_0: def c9, 0, -2, 3, 1; def c10, 0.5, 0, 0, 0

NVShaderPerf 1.8



- **GeForce 7800 GTXとQuadro FX 4500のサポート**
- **ForceWare 77.72から統合されたコンパイラ**
- **分岐パフォーマンスの向上**
 - デフォルトではシェーダ中最長のパスを計算
 - **-minbranch**を使用すれば最短パスを計算

NVShaderPerf 1.8



```
////////////////////////////////////  
// determine where the iris is and update normals, and lighting parameters to simulate iris geometry  
////////////////////////////////////
```

```
float3 objCoord = objFlatCoord;  
float3 objBumpNormal = normalize( f3tex2D( g_eyeNermel, v2f.UVtex0 ) * 2.0 - float3( 1, 1, 1 ) );  
objBumpNormal = 0.350000 * objBumpNormal + ( 1 - 0.350000 ) * objFlatNormal;  
half3 diffuseCol = h3tex2D( g_irisWhiteMap, v2f.UVtex0 );  
float specExp = 20.0;  
half3 specularCol = h3tex2D( g_eyeSpecMap, v2f.UVtex0 ) * g_specAmount;
```

```
float tea;
```

```
float3 centerToSurfaceVec = objFlatNormal; // = normalize( v2f.objCoord )  
float firstDot = centerToSurfaceVec.y; // = dot( ce  
if( firstDot > 0.805000 )
```

```
{  
    // We hit the iris. Do the math.
```

```
    // we start with a ray from the eye to the surface  
    float3 ray_dir = normalize( v2f.objCoord - objEye  
    float3 ray_origin = v2f.objCoord;
```

```
    // refract the ray before intersecting with the iris  
    ray_dir = refract( ray_dir, objFlatNormal, g_refra
```

```
    // first, see if the refracted ray would leave the e  
    float t_eyeballSurface = SphereIntersect( 16.0, r  
    float3 objPosOnEyeBall = ray_origin + t_eyeball  
    float3 centerToSurface2 = normalize( objPosOn
```

```
if( centerToSurface2.y > 0.805000 )
```

```
{  
    // Display a blue color  
    diffuseCol = float3( 0, 0, 0.7 );  
    objBumpNormal = objFlatNormal;  
    specularCol = float3( 0, 0, 0 );  
    specExp = 10.0;
```

```
}
```

```
else  
{  
    // transform into irisSphere space  
    ray_origin.y -= 5.109000;
```

```
    // intersect with the Iris sphere  
    float t = SphereIntersect( 9.650000, ray_origin, ray_dir );  
    float3 SphereSpaceIntersectCoord = ray_origin + t * ray_dir;  
    float3 irisNormal = normalize( -SphereSpaceIntersectCoord );
```

Lunaの目を描画するシェーダ
最長パスで674サイクル
最短パスで193サイクル

```
C:\WINDOWS\System32\cmd.exe  
T:\tmp>t:\sw\devrel\sdk\tools\bin\release_pdb\nvshperf\nvshaderperf -a NU40 cornea2.txt  
-----  
Running performance on file Cornea2.txt  
-----  
Target: GeForce 6800 Ultra <NU40> :: Unified Compiler: v77.72  
Cycles: 674.25 :: R Regs Used: 12 :: R Regs Max Index <0 based>: 11  
Pixel throughput <assuming 1 cycle texture lookup> 9.50 MP/s  
T:\tmp>t:\sw\devrel\sdk\tools\bin\release_pdb\nvshperf -minbranch -a NU40 cornea2.txt  
-----  
Running performance on file Cornea2.txt  
-----  
Target: GeForce 6800 Ultra <NU40> :: Unified Compiler: v77.72  
Cycles: 192.82 :: R Regs Used: 12 :: R Regs Max Index <0 based>: 11  
Pixel throughput <assuming 1 cycle texture lookup> 33.33 MP/s  
T:\tmp>_
```

NVShaderPerf – バージョン 2.0



- 頂点処理量
- **GLSL**頂点シェーダ
- ひとつの**NVShaderPerf**で複数バージョンのドライバに対応
- 他に必要な機能は？

NVShaderPerf@nvidia.com

NVPerfKit



- 概要
- 関連ツール
- **NVPerfKit 2.0**

NVPerfKit: 解答を提供



- CPU最適化をしても、**13FPS**で走るアプリ？
- GPU内で何が起きているのか？
- なぜIHVエンジニアにはそれが分かるのか？

概要



- ドライバと**GPU**のパフォーマンス測定カウンタ
 - Performance Data Helper (PDH)
 - Microsoft PIX for Windows
- アプリケーションで**NVPerfHUD**の機能を実現
- アプリケーションでサンプリングを起動
- **OpenGL**と**Direct3D**

NVPerfKitで提供されるもの



● 測定用ドライバ

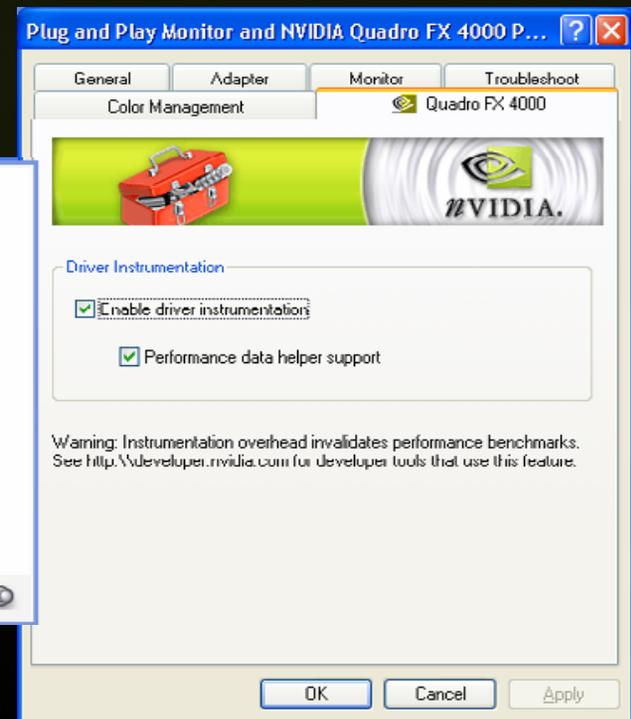
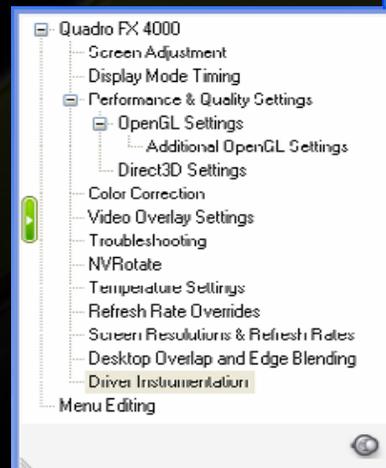
- ドライバと**GPU**のカウンタ
- **OpenGL**と**Direct3D**のサポート
- **SLI**サポート

● ツール

- **NVDevCPL**
- **PIX Plugin**
- **NVAppAuth**

● SDK

- サンプルコード
- ヘルパークラス
- ドキュメント



OpenGLカウンタ



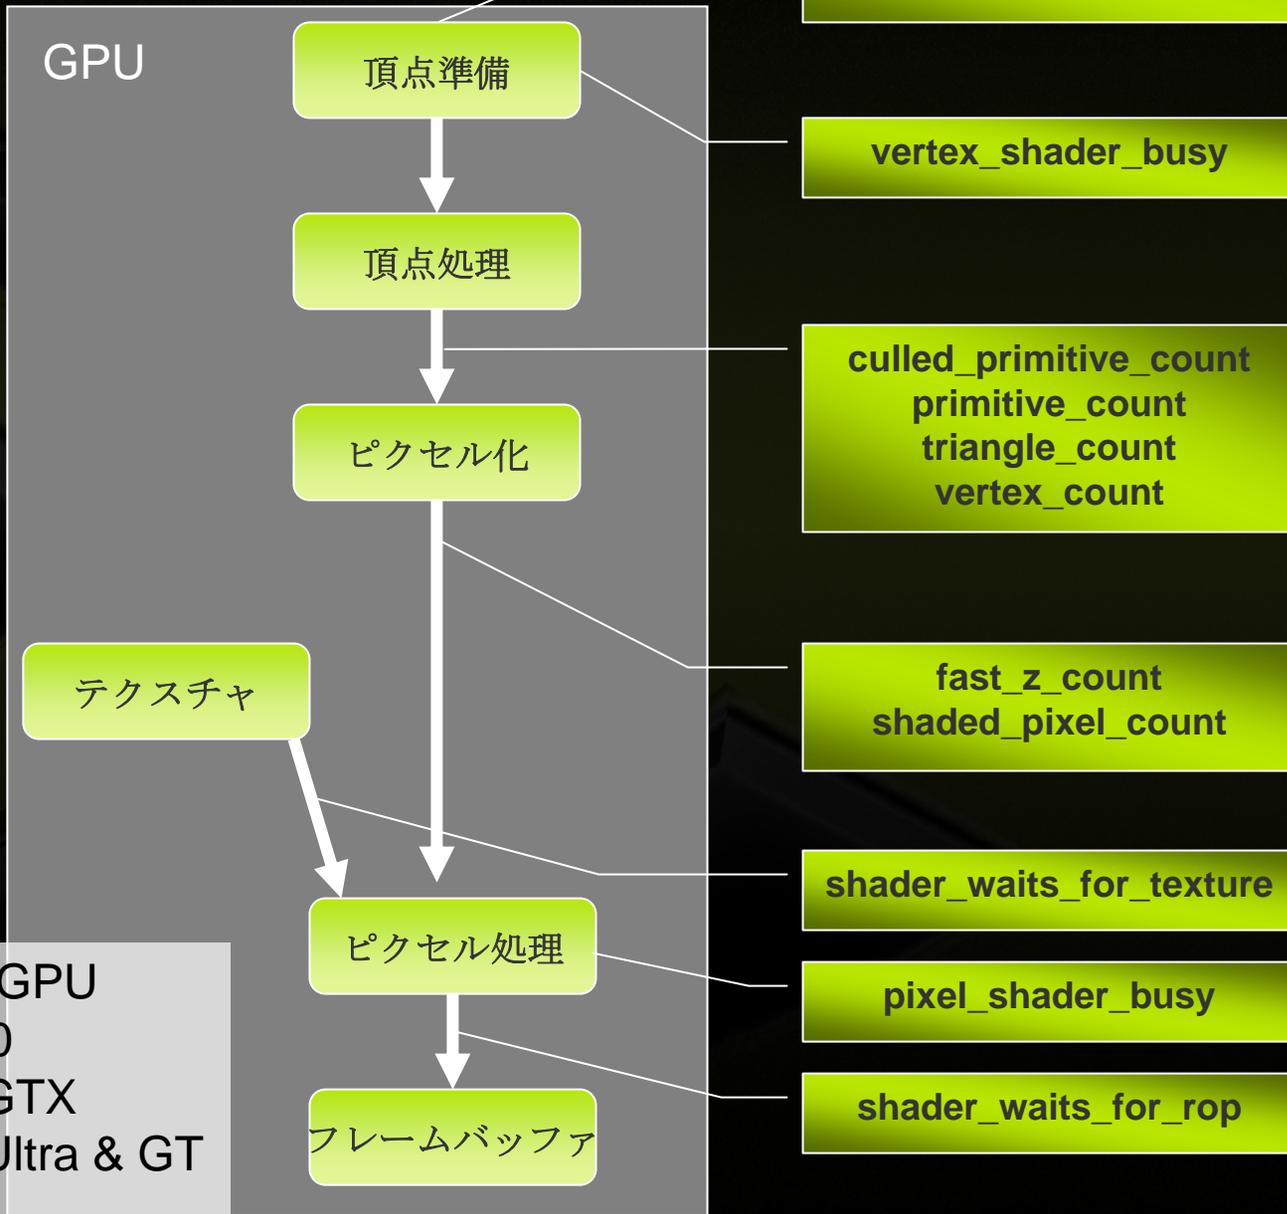
説明	名前
FPS	OGL FPS
フレーム時間 (1/FPS)	OGL frame time mSec
ドライバのGPU待ち時間	OGL frame mSec Sleeping

Direct3Dカウンタ



説明	名前
FPS	D3D frame FPS
フレーム時間 (1/FPS)	D3D frame time mSec
AGPメモリ使用量	D3D frame agpmem MB
ビデオ・メモリ使用量	D3D frame vidmem MB
ドライバ時間	D3D frame mSec in driver
ドライバのGPU待ち時間	D3D frame mSec Sleeping
三角形数	D3D frame tris
バッチ数	D3D frame num batches
ロックされた描画ターゲット数	D3D Locked Render Targets

GPUカウンタ



サポートされるGPU
Quadro FX 4500
GeForce 7800 GTX
GeForce 6800 Ultra & GT
GeForce 6600

PDHとPerfmon



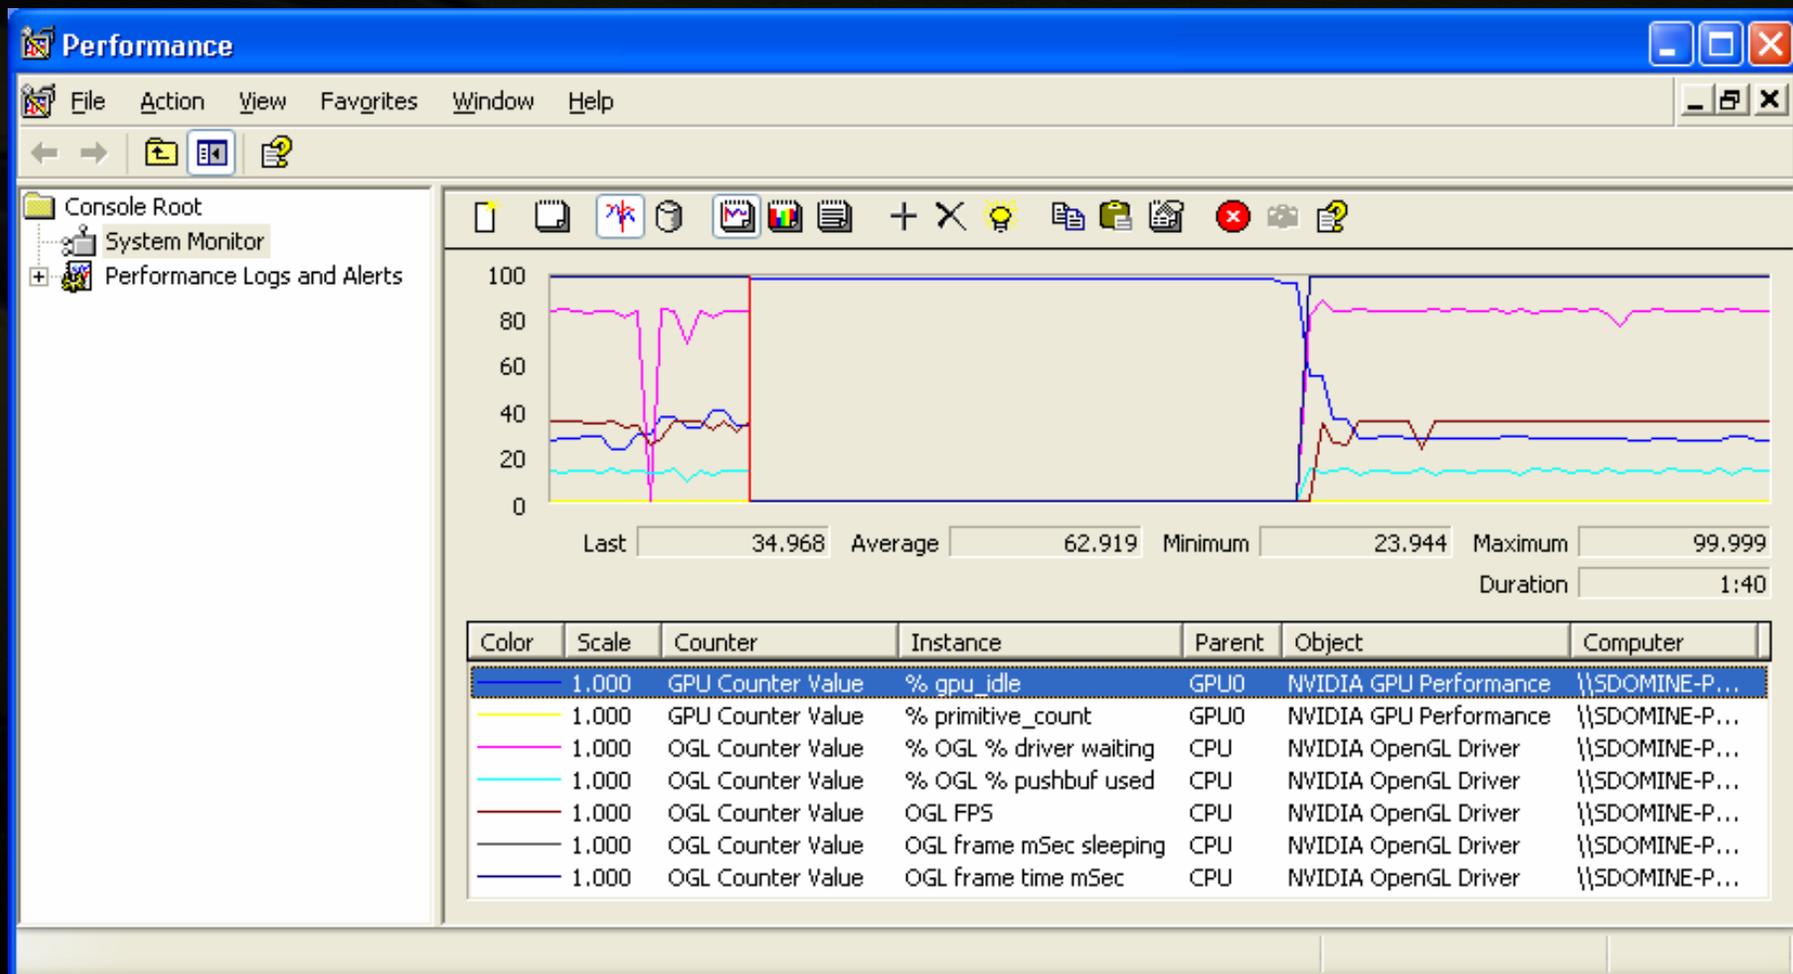
● PDH: Performance Data Helper for Windows

- アプリケーションにパフォーマンス関連のデータを提供するための**Win32 API**
- 多くのアプリケーションで使用されている

● Perfmon: (またはMicrosoft Management Console)

- PHDを使った**Win32**アプリケーション
- 低周波数のサンプリング (**1X/s**)
- PDHのカウンタを表示:
 - **OS: CPU**使用量, **memory**使用量, **スワップファイル**使用量, **ネットワーク**情報など
 - **NVIDIA: NVPerfKit**の全てのカウンタ

関連ツール: Perfmon



関連ツール: NVDevCPL



NVIDIA Developer Control Panel

Available Counters

- D3D frame mSec sleeping
- D3D frame num batches
- D3D frame time mSec
- D3D frame tris
- D3D frame vidmem MB
- D3D Locked Render Targets
- D3D SLI Linear Buffer Sync Bytes
- D3D SLI Linear Buffer Syncs
- D3D SLI P2P Bytes
- D3D SLI P2P transfers
- D3D SLI Render Target Sync Bytes
- D3D SLI Render Target Syncs
- D3D SLI Texture Sync Bytes
- D3D SLI Texture Syncs
- GPU
 - GPU_Graphics
 - gpu_idle
 - shaded pixel count

Active Counters

- All
 - D3D
 - CPU
 - D3D frame FPS
 - D3D frame mSec in driver
 - GPU
 - GPU_Graphics
 - gpu_idle
 - shaded_pixel_count
 - OpenGL (OGL)
 - CPU
 - OGL FPS

Counter Description

gpu_idle : Time the graphics portion of the chip is idle.

Settings

Default location for counter configuration files (*.ctr)

関連ツール: NVIDIA Plug-In for Microsoft PIX for Windows



The screenshot displays the PIX for Windows interface. The main window is titled "PIX for Windows - Experiment1" and shows an "Advanced View" of an experiment. A "PIX Counters" dialog box is open, showing a tree view of available counters. The "NVIDIA Performance Counters" folder is expanded, and "D3D frame mSec in driver" is selected. The "Chosen counters" list contains "% gpu_idle". The "Description of selected counter" field shows "D3D Last frame mSec spent in D3D driver".

PIX Counters

All available counters

- My Countersets
- Direct3D Counters
- Performance Counters
- Plugin Counters
 - NVIDIA Performance Counters
 - D3D frame FPS
 - D3D frame mSec in driver**
 - % gpu_idle

Chosen counters

- % gpu_idle

Add >>

<< Remove

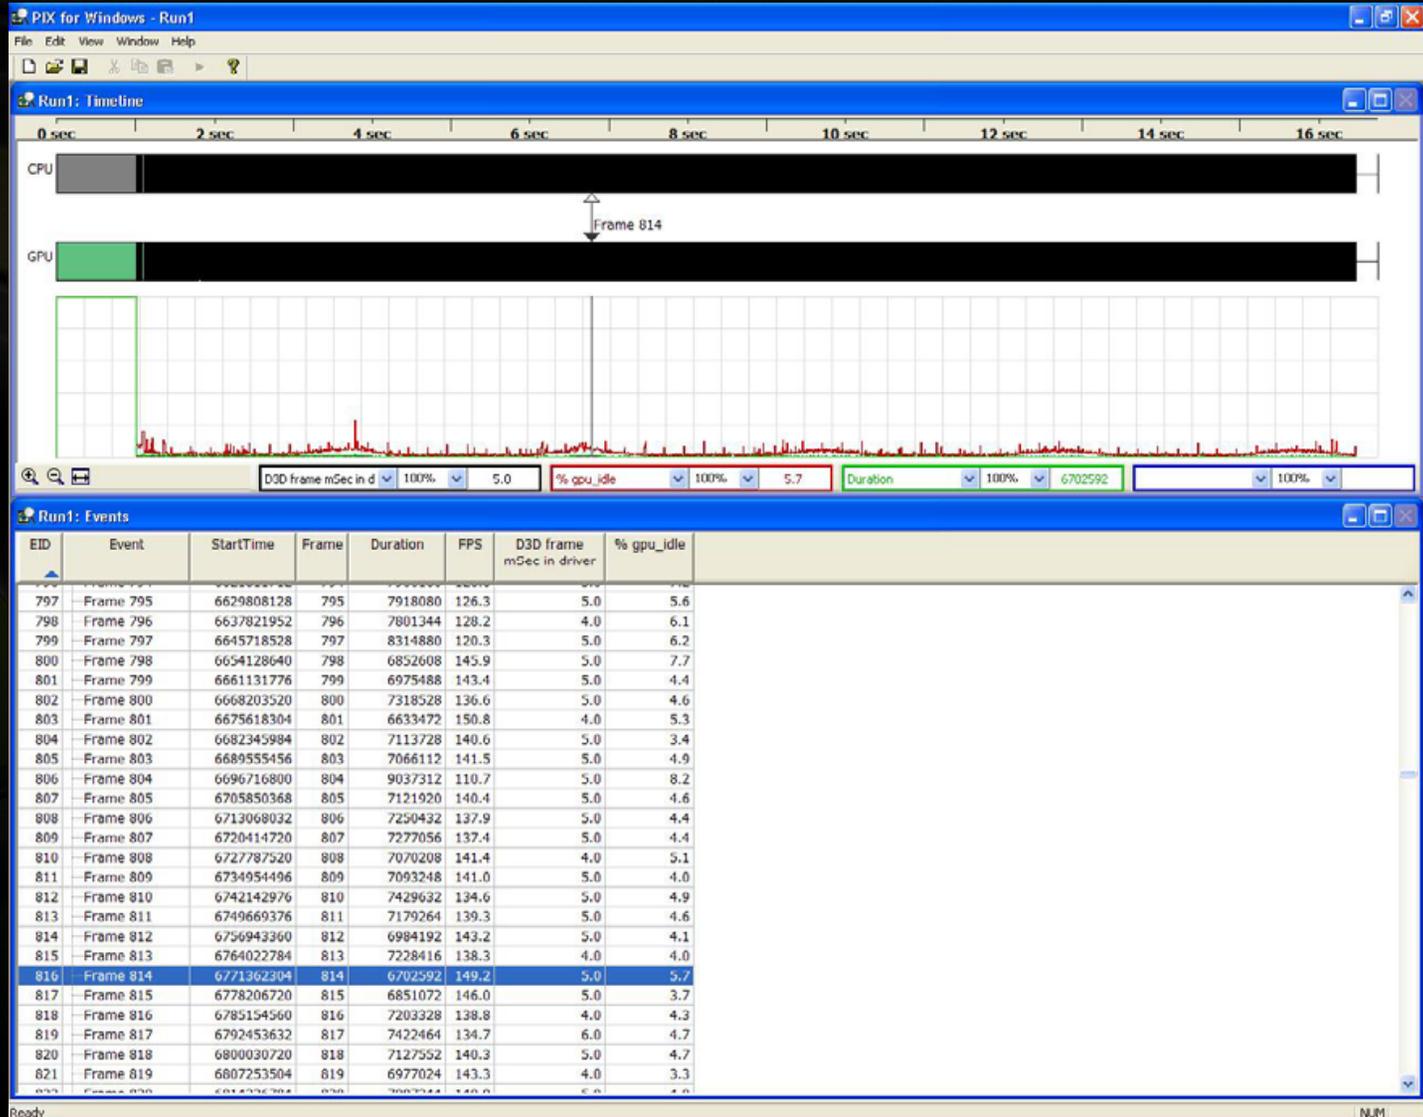
Save As Counterset...

Description of selected counter

D3D Last frame mSec spent in D3D driver

OK Cancel

関連ツール: NVIDIA Plug-In for Microsoft PIX for Windows



ヘルパークラスとコードサンプル



● CPDHelper: PDHの使用を簡略化

```
int nIndex = pdh.add("countername");  
pdh.sample();  
float fValue = pdh.value(nIndex);
```

- CTrace: パフォーマンス情報を保持するためのバッファ
- CTraceDisplay: 簡単なAPI非依存の描画ライブラリ
- OpenGLとDirect3Dでのサンプル
 - ヘルパークラスの使用方法
 - セキュリティ機構の使用方法

Graphic RemedyのgDEDebugger 2.0



gDEDebugger - SceneGraph - Trial Version, 30 Days Left

File Edit View Debug Breakpoints Tools Help

Normal mode 50 Fs

Performance Graph

Counter Name	Real Value	Scaled Value	Width
GPU0: % shader_waits_for_texture	29	29 [1]	1px
GPU0: % vertex_shader_busy	11	11 [1]	1px
GPU0: % gpu_idle	0	0 [1]	1px
GPU0: % pixel_shader_busy	30	30 [1]	1px
GPU0: % texture_waits_for_shader	14	14 [1]	1px
CPU: OGL FPS	35	35 [1]	1px
CPU: % OGL % driver waiting	88	88 [1]	1px
CPU: OGL AGP/PCE-E usage (MB)	2	2 [1]	1px
CPU: OGL vidmem usage (MB)	52	52 [1]	1px

Add counter...

DT dll loaded: c:\windows\system32\msvcr71.dll
DT dll loaded: c:\windows\system32\rsaenh.dll
DT dll loaded: c:\windows\system32\crypt32.dll
DT dll loaded: c:\windows\system32\msasn1.dll
DT dll loaded: c:\windows\system32\uxtheme.dll
DT dll loaded: c:\windows\system32\msctf.dll
DT dll loaded: c:\windows\system32\nvogln.dll
DT dll loaded: c:\windows\system32\mcd32.dll
DLL unloaded: C:\WINDOWS\system32\MCD32.DLL
DT dll loaded: c:\windows\system32\msibui.dll
DT dll loaded: c:\windows\system32\oleaut32.dll
DT dll loaded: c:\windows\system32\ole32.dll

Welcome to gDEDebugger!

NVPerfKit 2.0



- 実験の簡略化
- ボトルネック発見のための解析
 - PDHによる単一カウンタの補助
 - 複数のGPUカウンタが必要なマルチパスの実験
 - NVPerfHUD 4.0の全ての機能を提供
- より多くのOpenGLとDirect3Dカウンタ
- NVPerfHUD 4.0
- Linuxサポート



NVIDIA®

NVPerfHUD 4.0

Raul Aguaviva

NVPerfHUD



- 概要
- 仕組み
- デモ
- スケジュール



- **PERFormance Heads Up Display**の略
 - グラフやダイアログをアプリケーションの上に表示
 - 対話式**HUD**



● 4種類のHUD

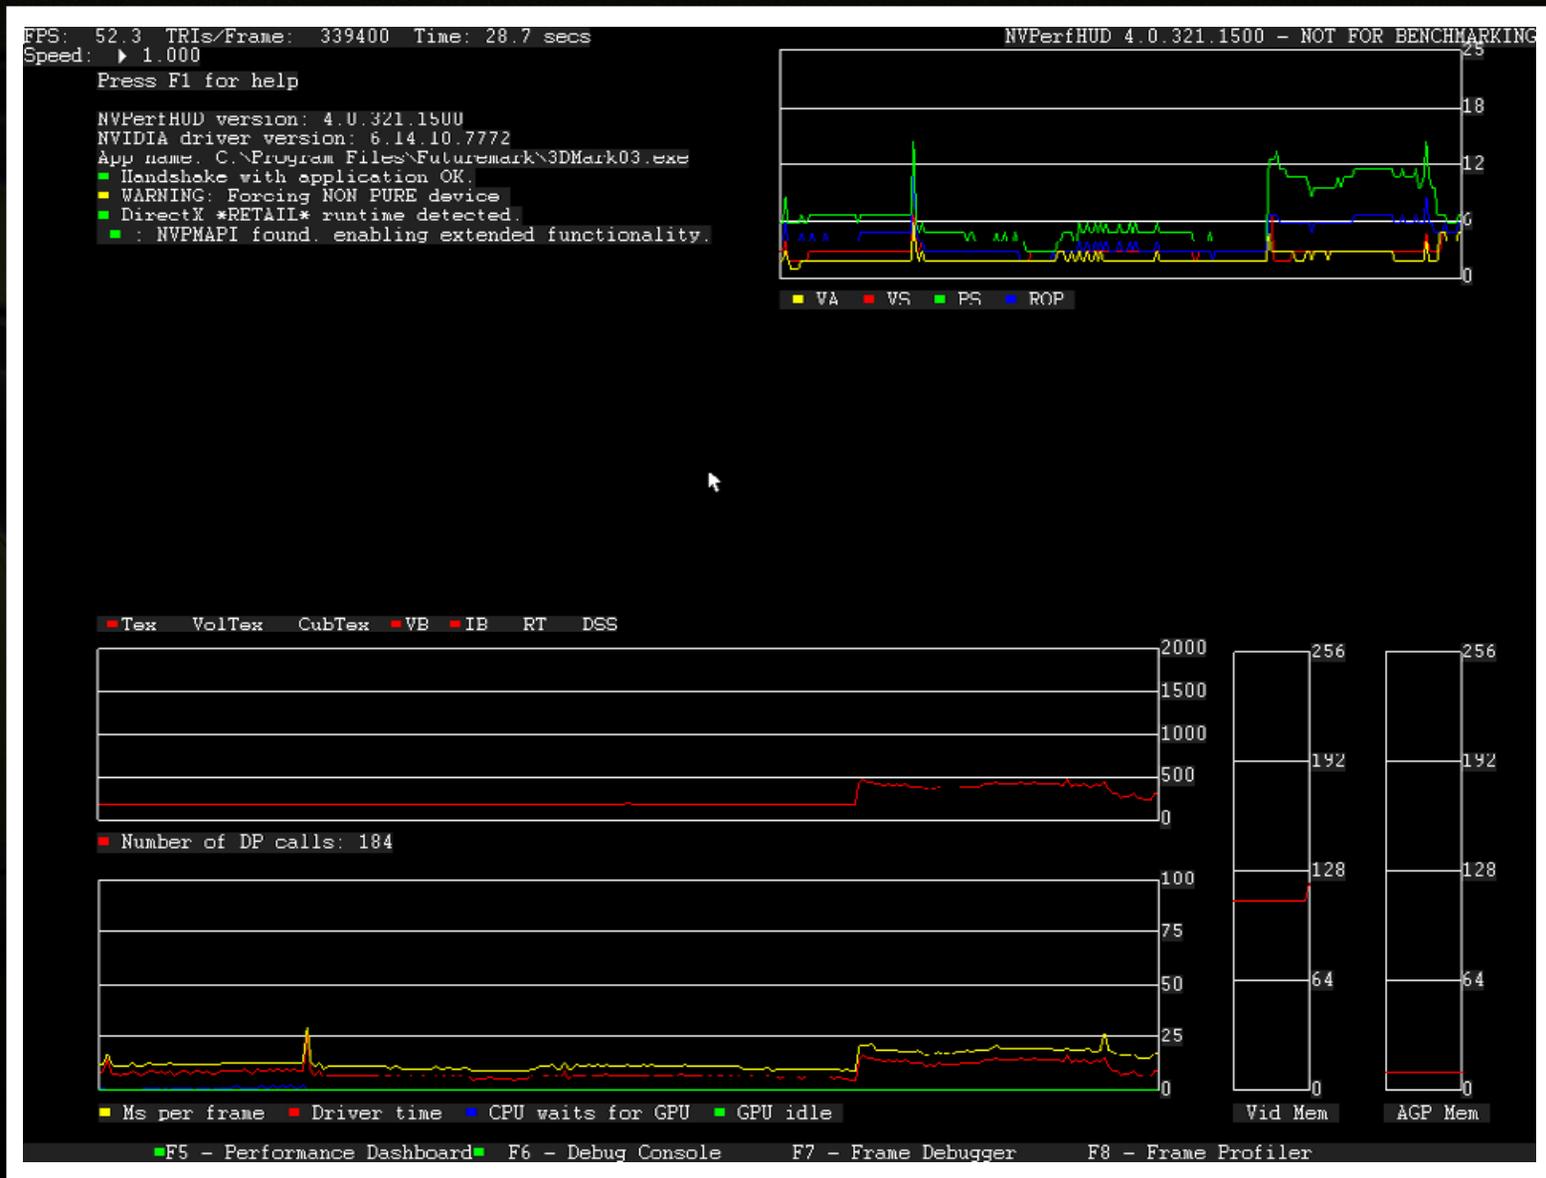
- パフォーマンス・ダッシュボード
- デバッグ・コンソール
- フレーム・デバッガ
- フレーム・プロファイラ (4.0での新機能)

使い方



- **NVPerfHUD**と一緒にアプリケーションを起動
- 通常通り使用:
 - 機能の問題 - デバッガを使用
 - パフォーマンス問題 - プロファイラを使用

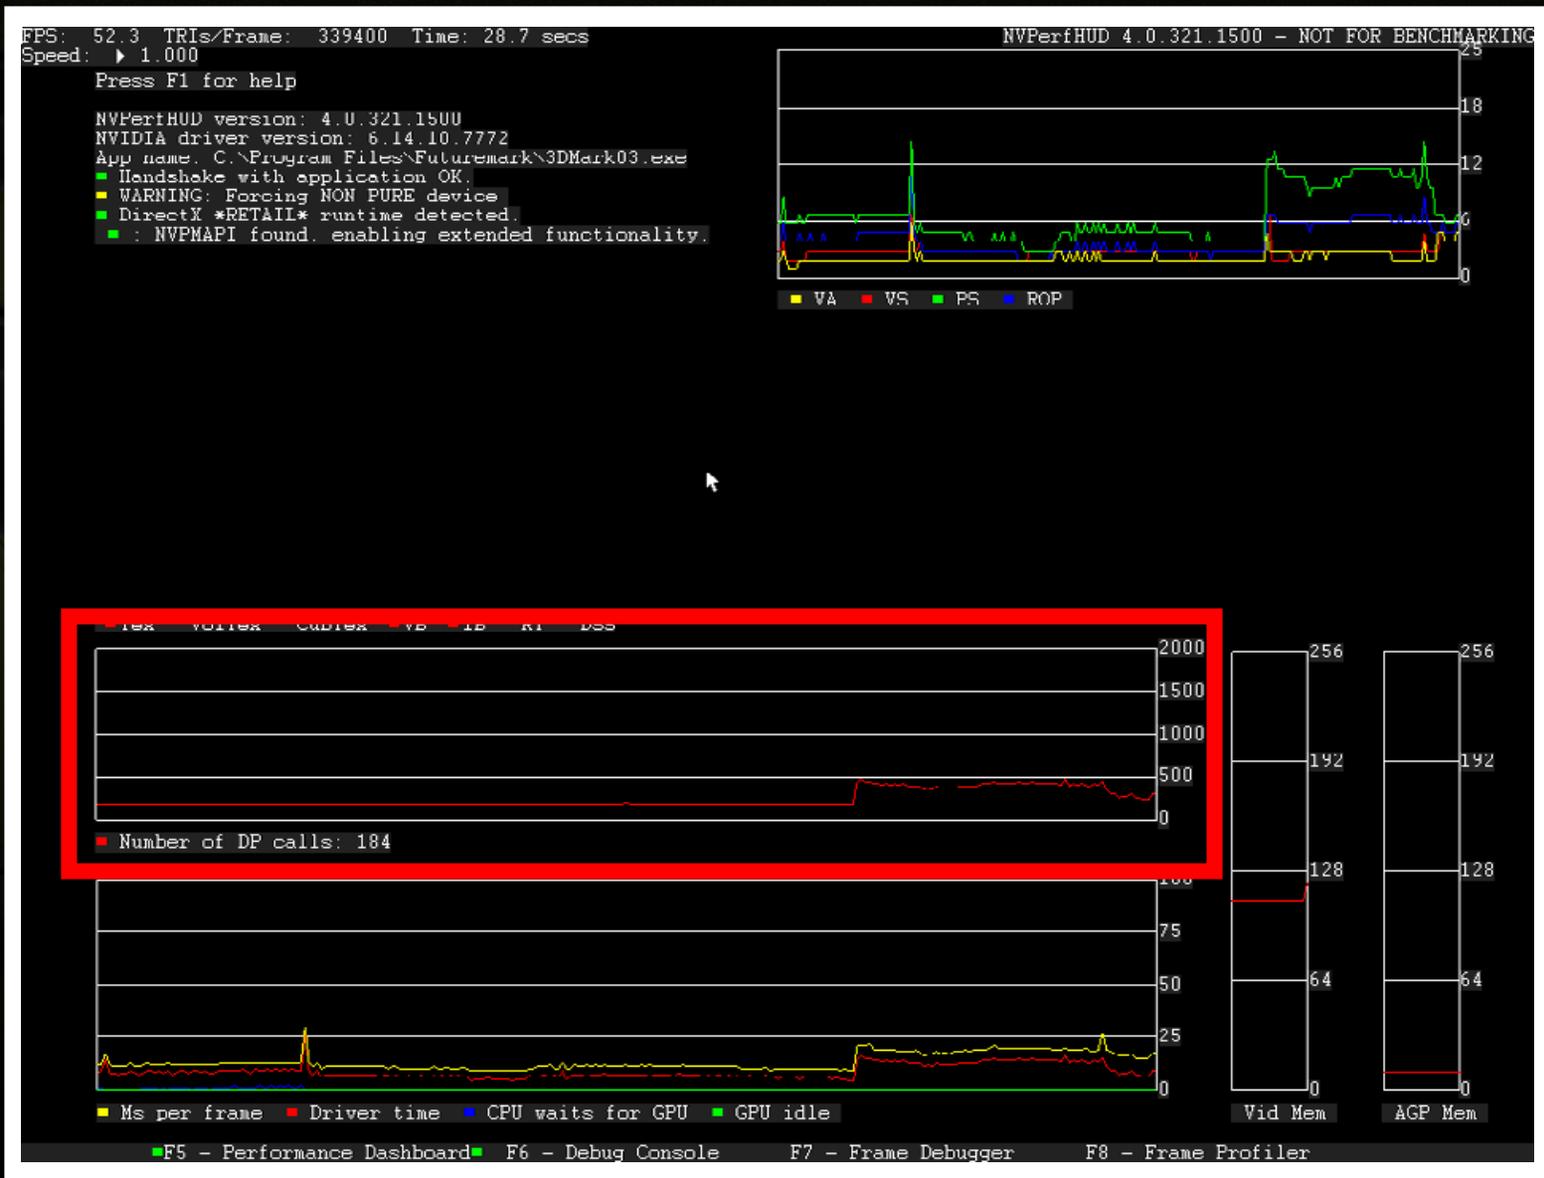
パフォーマンス・ダッシュボード



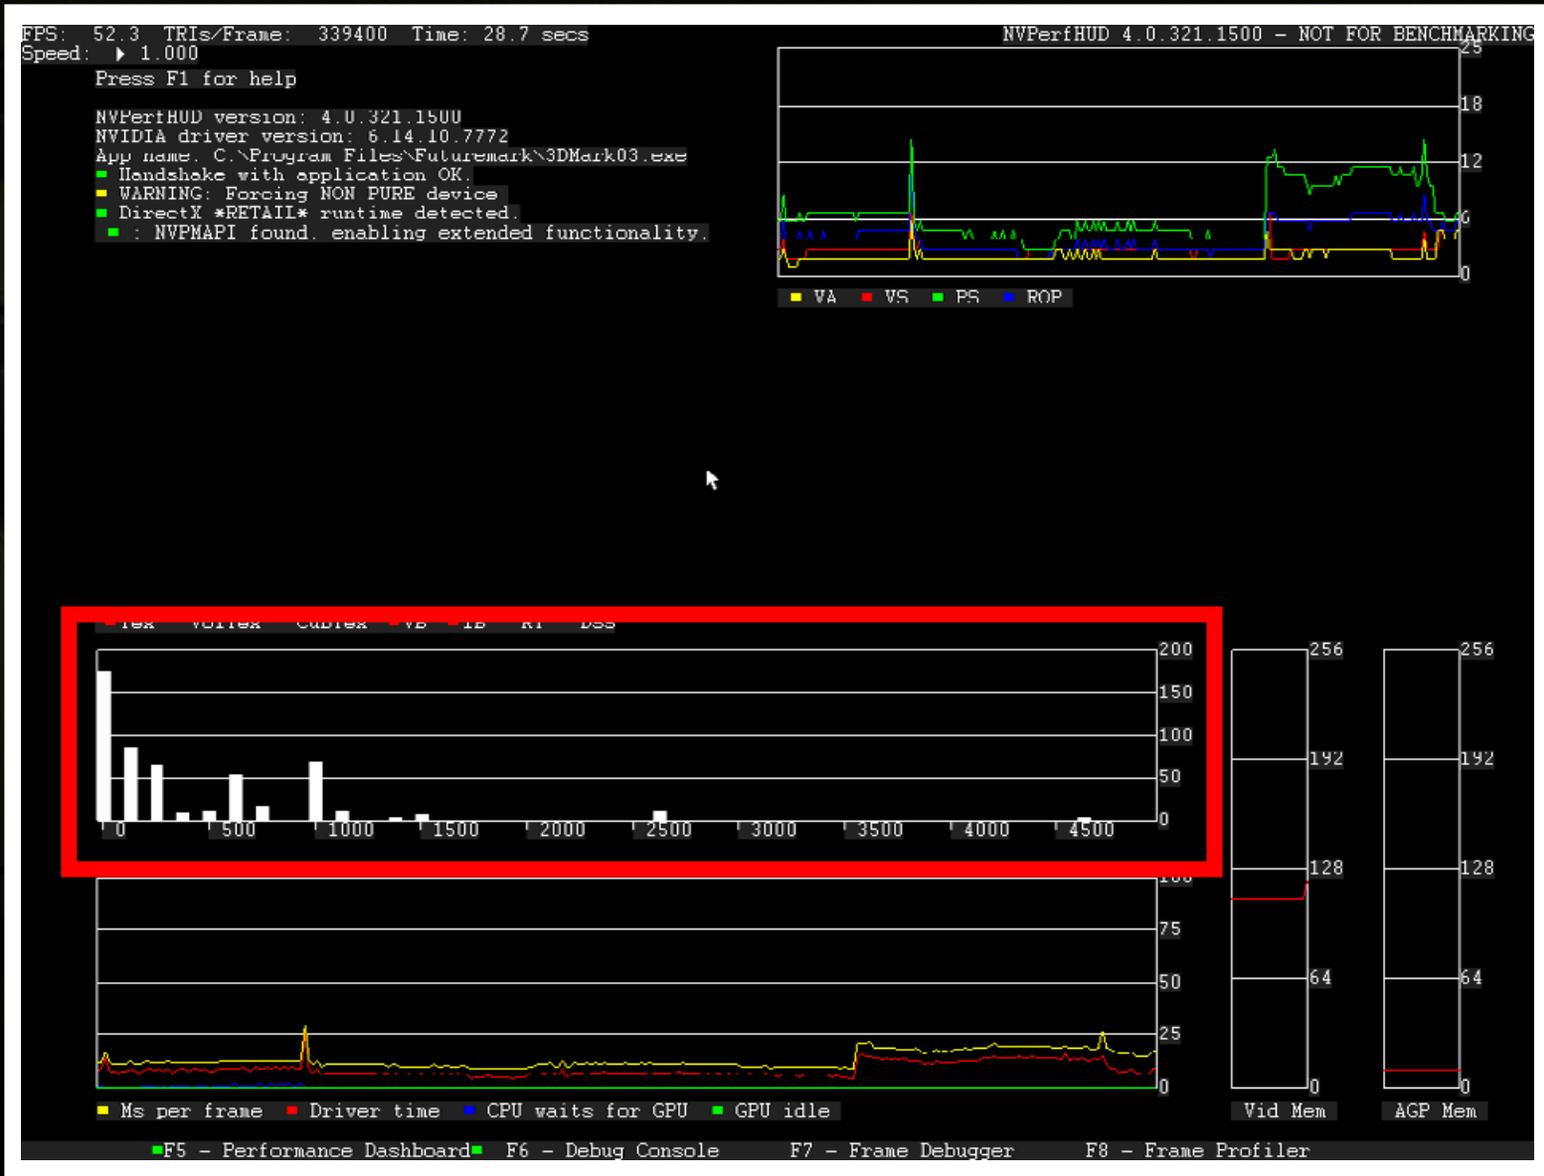
パフォーマンス・ダッシュボード



パフォーマンス・ダッシュボード



パフォーマンス・ダッシュボード



パフォーマンス・ダッシュボード



パフォーマンス・ダッシュボード



パフォーマンス・ダッシュボード



● リソース監視



● 監視されるリソース

- テクスチャ
- ボリューム・テクスチャ
- キューブ・テクスチャ
- 頂点バッファ
- インデックス・バッファ
- ステンシルと深度バッファ

パフォーマンス・ダッシュボード



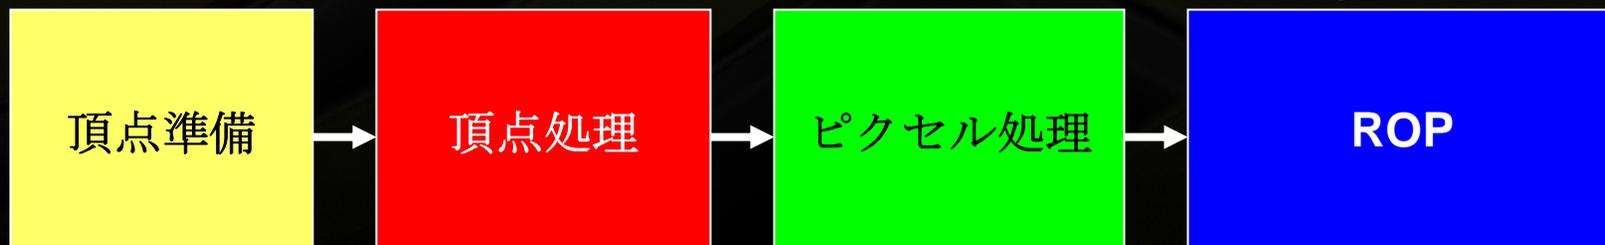
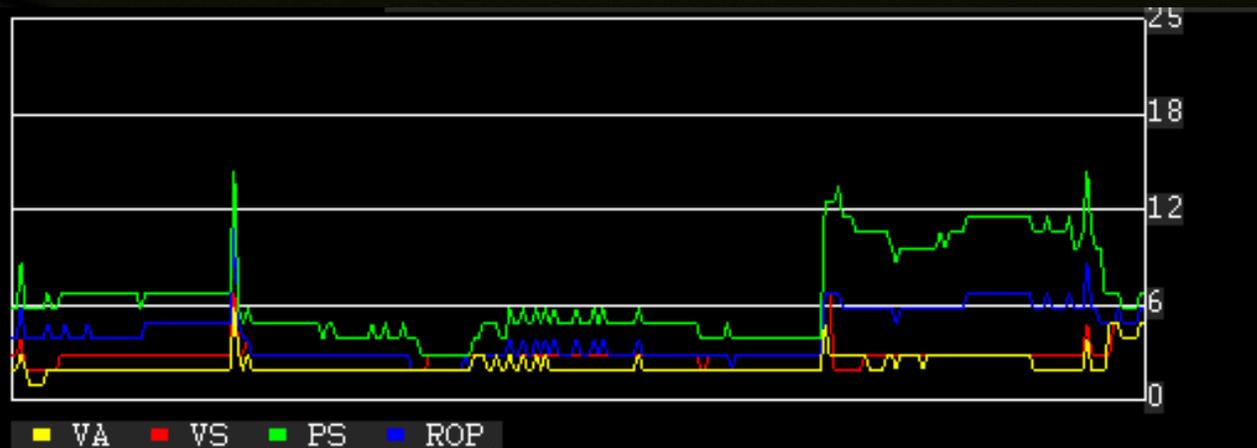
パフォーマンス・ダッシュボード



● 速度制御

```
FPS: 52.5 Iris/Frame: 339400 Time: 28.7  
Speed: ▶ 1.000  
Press F1 for help  
  
NVPerfHUD version: 4.0.321.1500  
NVIDIA driver version: 6.14.10.7772  
App name: C:\Program Files\Futuremark\
```

簡略化されたパイプライン



デバッグ・コンソール



FPS: 93.1 TRIs/Frame: 131910 Time: 15.9 secs NVPerfHUD 4.0.321.1500 - NOT FOR BENCHMARKING

Time: 7.03 secs, IDirect3DDevice9::CreateVertexBuffer(1600,8,0,1)
Time: 7.03 secs, IDirect3DDevice9::CreateIndexBuffer(348,8,101,1)
Time: 7.03 secs, IDirect3DDevice9::CreateVertexBuffer(128,8,0,1)
Time: 7.03 secs, IDirect3DDevice9::CreateIndexBuffer(12,8,101,1)
Time: 7.53 secs, IDirect3DDevice9::CreateVertexBuffer(5952,8,0,1)
Time: 7.53 secs, IDirect3DDevice9::CreateIndexBuffer(1236,8,101,1)
Time: 44.66 secs, IDirect3DDevice9::CreateOffscreenPlainSurface()
Time: 70.00 secs, IDirect3DDevice9::CreateVertexBuffer(65536,520,0,0)
Time: 70.00 secs, IDirect3DDevice9::CreateVertexBuffer(393216,520,0,0)
Time: 70.01 secs, IDirect3DDevice9::CreateIndexBuffer(49152,8,101,1)
Time: 70.01 secs, IDirect3DDevice9::CreateVertexDuffer(90304,520,0,0)
Time: 70.01 secs, IDirect3DDevice9::CreateIndexDuffer(24570,0,101,1)
Time: 70.01 secs, IDirect3DDevice9::CreateVertexBuffer(80,8,0,1)
Time: 70.17 secs, IDirect3DDevice9::CreateTexture(1024x1024,1,0,22,1)
Time: 70.18 secs, IDirect3DDevice9::CreateTexture(512x64,1,0,22,1)
Time: 70.18 secs, IDirect3DDevice9::CreateVertexBuffer(1280,520,0,0)

- Clear Log Each Frame
- Stop Logging
- Fade Console

F5 - Performance Dashboard F6 - Debug Console F7 - Frame Debugger F8 - Frame Profiler

フレーム・プロファイラ



- パフォーマンスのカウンタを測定
- 解析

フレーム・プロファイラでの測定



- **NVPerfHUDはNVPerfKitを使用する**
 - 約**40**のカウンタを使用
- 同時に全てを読むことはできない
- 全てのカウンタを読むために、同じフレームを何回も描画しなければならない



フレーム・プロファイラでの解析

● 最適化のための解析:

- ステートごとにまとめる – ボトルネックごとのグループ
- これらのグループは『**state buckets**』と呼ばれる

● 手順

- ステートにより、描画コールを分類
- 最も時間のかかっているグループのボトルネックを見つける
 - **NVPerfHUD**による解析
- ボトルネックを解消

アプリケーションの一時停止



- アプリケーションが実時間ベースのアニメーションをしている場合のみに可能
- タイマーを停止
 - `QueryPerformanceCounter()`、`timeGetTime()`を使用
 - RDTSCは使用しない
- **`Pos += V * DeltaTime`**

予定



● ベータ: 8月

● リリース: 9月



REGISTERED DEVELOPERS
JOIN

HOME
NEWS
DOCUMENTATION
TOOLS & SDKs
PARTNERS

NEWSLETTER SIGN-UP
EVENTS CALENDAR
DRIVERS
CONTACT



Legal Info

NVPerfHUD 3

Quick Links

- ◆ [Introductory Video](#)
- ◆ [Downloads](#)
- ◆ [GameDev.net Review](#)

Overview

Modern GPUs generate images through a pipelined sequence of operations. A pipeline runs only as fast as its slowest stage, so tuning graphical applications for optimal performance requires a pipeline-based approach to performance analysis. NVPerfHUD analyzes your graphics pipeline performance and provides real-time statistics you can use to diagnose performance bottlenecks in your 3D application.

The latest release includes several new features and update modes:

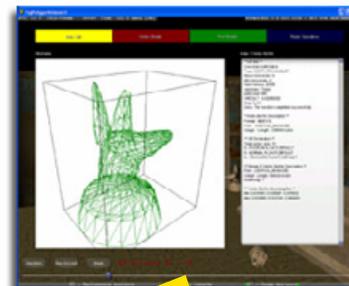
- ◆ **Frame Analysis Mode**
Freeze your application and single-step through the current frame to see what is happening inside the GPU at each stage of your graphics pipeline to find the Index Unit, Vertex Shader, Pixel Shader & Raster Operations Unit.
- ◆ **Debug Console Mode**
This mode shows you DirectX Debug Runtime messages, Direct3D events, and custom messages from your application.
- ◆ **Performance Mode**
The powerful performance analysis experiments from the previous release are still available in Performance Mode.

The opt-in mechanism for code alterations are necessary if you have already enabled NVPerfHUD 2.0 in your application.

Be sure to check out the Getting Started instructions in the [NVPerfHUD User Guide](#), and read through the methodology for effectively identifying and crushing performance bottlenecks in your application. We've also created a [Quick Reference Card](#) with tips and shortcuts that you can keep at your fingertips. Both these documents are available in English, Japanese, Chinese, and Korean.

See our "NVIDIA Performance Analysis Tools" talk from [GDC 2005](#) for more information on how to analyze your applications using NVPerfHUD. In addition, our "Practical Performance Analysis and Tuning" talk from [GDC 2004](#) explains the theory of pipeline analysis and bottleneck removal.

Downloads



NOW AVAILABLE!



Developer Reviews

NVPerfHUD has way more features than I expected! Blew me away!!
- *Romy Saville*
Graphics Programmer
Relic Entertainment, Inc.

[Frame Analysis Mode] is by far the most impressive mode of NVPerfHUD. ... A few moments in this mode does more to show how advanced graphic pipelines work than anything else I have seen. ... NVPerfHUD should be of interest to anybody who develops software that employs DirectX graphics. Even if you don't have an NVIDIA card it's worth the price of a GeForce 6600 or 6000 to get this tool.

- *Bryan Mau*
[GameDev.net Review](#)

NVPerfHUD 3 - it's simply amazing. I use it virtually every day.
- *Chris King, President*
IDV, Inc.

NVPerfHUD is a great tool for debugging and performance analysis.
- *Richard Schubert*
Graphics/Effects Programmer
Yager Development GmbH

I just wanted to drop a note to thank you for the hard work on the NVPerfHUD. This new version is incredibly useful. Not a day goes by that I don't appreciate the support NVIDIA gives developers with tools such as this.
- *Matt Shaw*
Director of Technology
Mythic Entertainment

質問



● サイト: <http://developer.nvidia.com>

NVGLExpert@nvidia.com

NVShaderPerf@nvidia.com

NVPerfKIT@nvidia.com

NVPerfHUD@nvidia.com

FXComposer@nvidia.com



NVIDIA®

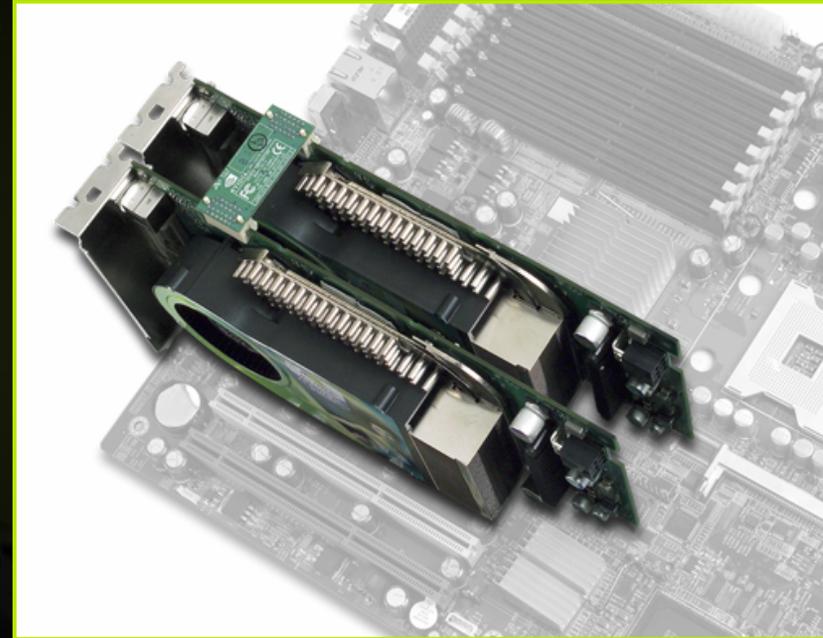
SLI

**Matthias M Wloka
NVIDIA Corporation**

SLI: Scalable Link Interface



- 同型のふたつの**GPU**を**PCI-E**マザーに挿して使用
- ドライバーはひとつの**GPU**として認識
 - **1.9x**程度までのスピードアップ
- ビデオメモリは倍にはならない



最上級のニッチ市場だけではない



- 主流製品でのSLI:

- GeForce 6600 GT SLI

- もちろん6800 GTと6800 Ultra

- デュアル・コアのボード

- Gigabyte 3D1:

- Dual 6600 GT

- SLIマザー

現在(2005年3月)までの販売数: **350,000**以上

- これはnForce4販売数の**25%**以上

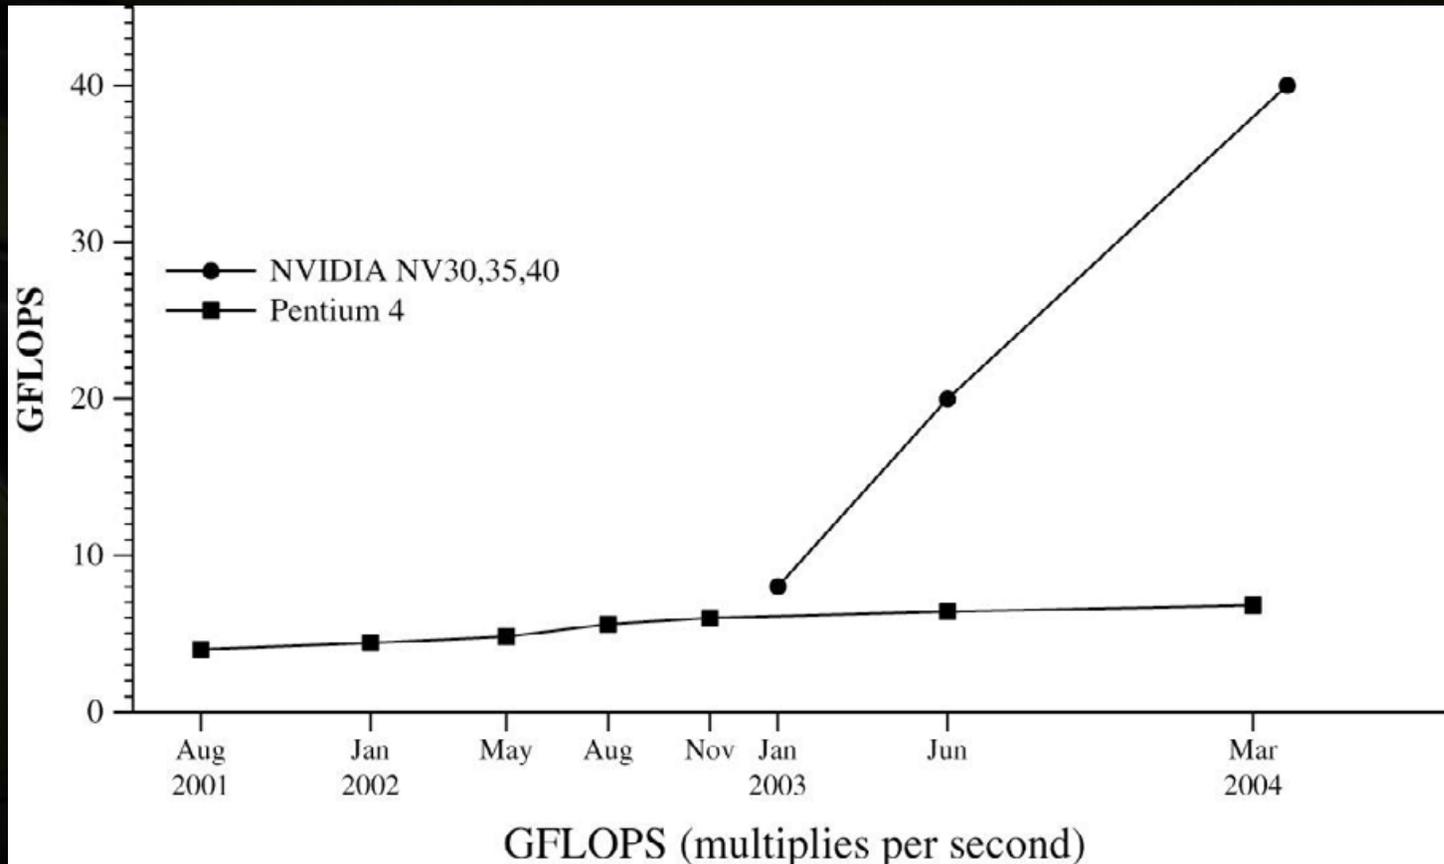


ゲーム開発サイクル



- 2年(かそれ以上)で
 - CPUパフォーマンスが倍(もしくはそれ以下)
 - GPUパフォーマンスが4倍
- CPU/GPUのバランスが変わる!
 - さらに悪化: CPUが必要なモジュールが後で足される:
AI、物理演算、ゲームプレイ
- SLIで将来のGPU対CPUバランスがうかがえる
 - 目標とする『主流』性能に対して

過去数年



Courtesy Ian Buck, Stanford University

SLIの仕組み



- 互換モード:
 - ひとつの**GPU**のみ使用
 - **SLI**の効果なし
- 交互フレーム描画 - **Alternate frame rendering (AFR)**
- 分割フレーム描画 - **Split frame rendering (SFR)**

AFR



- 各**GPU**はそれぞれのフレームを描画

GPU 0:

1

3

...

GPU 1:

2

4

...

- スキャン・アウトは読み出すフレームバッファを交互する

AFRでの一般的な描画



- フレームが独立していない:
 - 必要なデータをもうひとつの**GPU**へ送る
 - 例: テクスチャへの描画をフレームひとつおきに行う
- データの**GPU**同士の移動は余分な負荷
 - そのため**2倍**のスピードは出ない

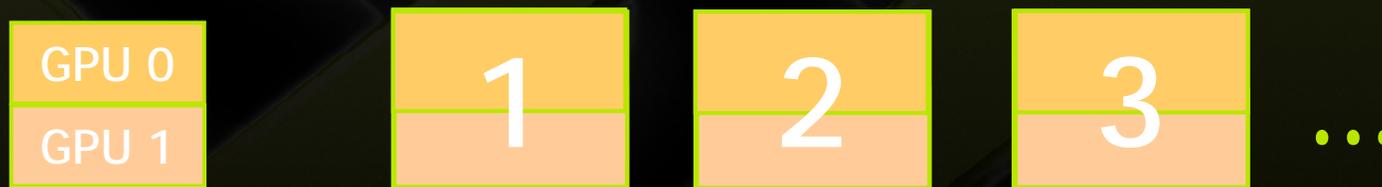
AFRの利点



- すべて並列処理
 - ピクセルのフィル、ピクセル化、頂点変形
- できればこちらを使用したい
- フレームが独立していると良い
 - 前のフレームのデータを使用しない
 - **GPU**間の通信による負荷を低減



- 両方の**GPU**が同一のフレームを処理
 - **GPU 0**が画面上
 - **GPU 1**が画面下



- スキャン・アウトはフレームバッファを合成

SFRでの一般的な描画



- 『上』と『下』での負荷調整
 - ひとつの**GPU**が時間をかけ過ぎた場合
 - 負荷を調整
- 頂点も上下にクリップ
 - 両方の**GPU**で全ての頂点进行处理することを防ぐ
 - 必ずうまくいくとは限らない
- これでもいくらかのデータ共有は必要:
 - 例: テクスチャ描画

AFRと比較したSFR



- **SFR**はためておくフレーム数を制限しても有効
 - 言い換えれば、**AFR**ではうまくいかないこともある
- 一般的に**SFR**の方が通信負荷が大きい
- 頂点処理が多い場合、**SFR**の価値は少ない

SLIシステムを検出する



- **NVCpl API:**

- 全ての**NVIDIA**ドライバをサポートする**NVIDIA**特有API

- **機能:**

- **NVCpl API**が使用可能かの検出
- バスのモード(**PCI/AGP/PCI-E**)と速度(**1x-8x**)
- ビデオ**RAM**の大きさ
- **SLI**

NVCpl APIのSLI検出



● SDKサンプルとドキュメント

```
HINSTANCE hLib = ::LoadLibrary("NVCPL.dll");

NvCplGetDataIntType NvCplGetDataInt;
NvCplGetDataInt =
    (NvCplGetDataIntType)::GetProcAddress(hLib,
        "NvCplGetDataInt");

long    numSLIGPUs = 0L;
NvCplGetDataInt(NVCPL_API_NUMBER_OF_SLI_GPUS,
                &numSLIGPUs);
```

ゲームからSLIを強制的に有効にする



- **NVCpl**を使用
 - **NvCplSetDataInt()**で
AFR、SFR、互換モードに設定
 - SDKサンプル参照
- プロファイルを変更、もしくは新しく作成:
 - http://nzone.com/object/nzone_sli_appprofile.html
 - ユーザがプロファイルを作成することもできる

概要: SLIが有効ではないケース



- CPU制限
 - またはvsyncが有効になっている
- バッファするフレーム数
- 通信負荷

CPU制限



- SLIではどうしようもない
- CPU負荷を削減するか、もしくは:
- CPU負荷をGPUへ移す
 - <http://GPGPU.org>参照
- フレーム・レートを制御しない

VSync有効



- モニタのリフレッシュにフレーム・レートを固定
- トリプル・バッファでは**vsync**の解決にはならない:
 - 描画速度がモニターのリフレッシュより速い場合、
 - **vsync**はやはり**GPU**を制限する
- さらに問題な、トリプル・バッファ
 - 時間差を広げる
 - 非常に多くのビデオ・メモリを使用

バッファされるフレームを制限

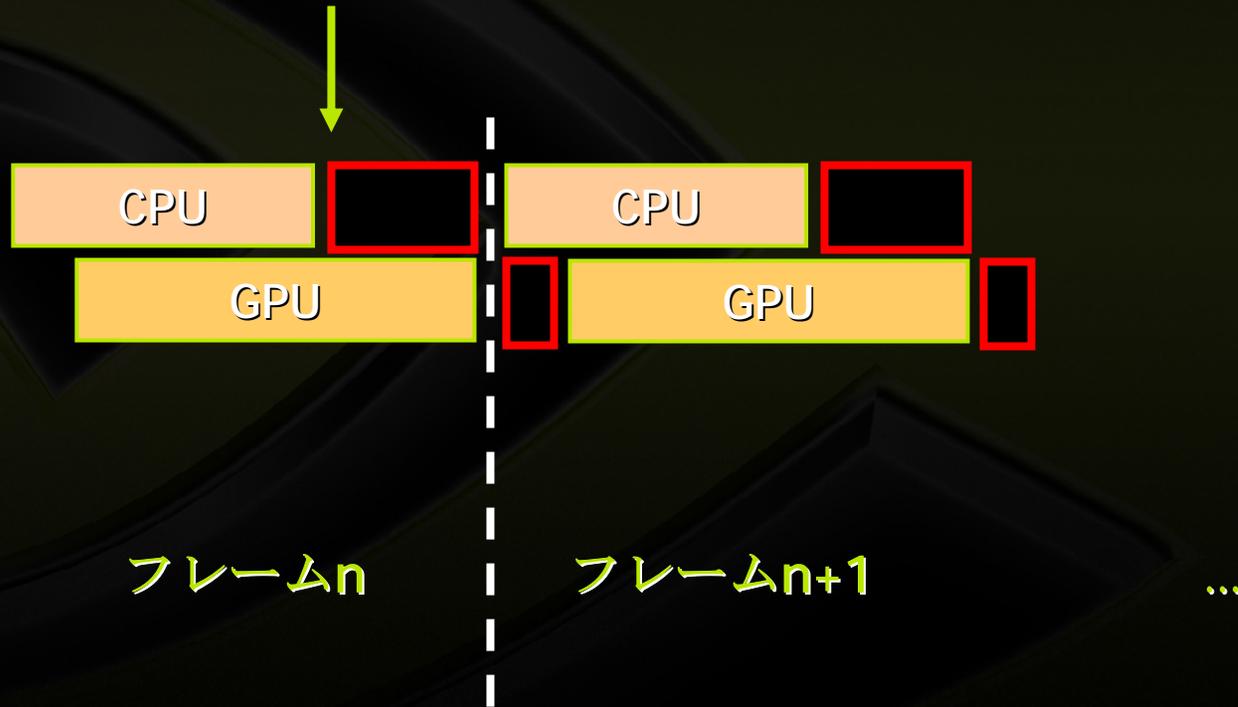


- 最大ひとつのフレームしかバッファしないゲームもある
 - 時間差を制限するため
 - イベント・クエリを使用
 - バック・バッファのロック/読み出しは**CPU**を制限する!
- **AFR SLI**の高速化を制限
- しかし**SLI**は最大約**1.9**倍の速度
 - 例: **SLI**システムが約**1.9**倍時間差が少ない場合

バック・バッファのロックが問題な理由



バック・バッファのロック：
GPUが描画終了するまで待つ



バッファするフレーム数を、GPU数に制限

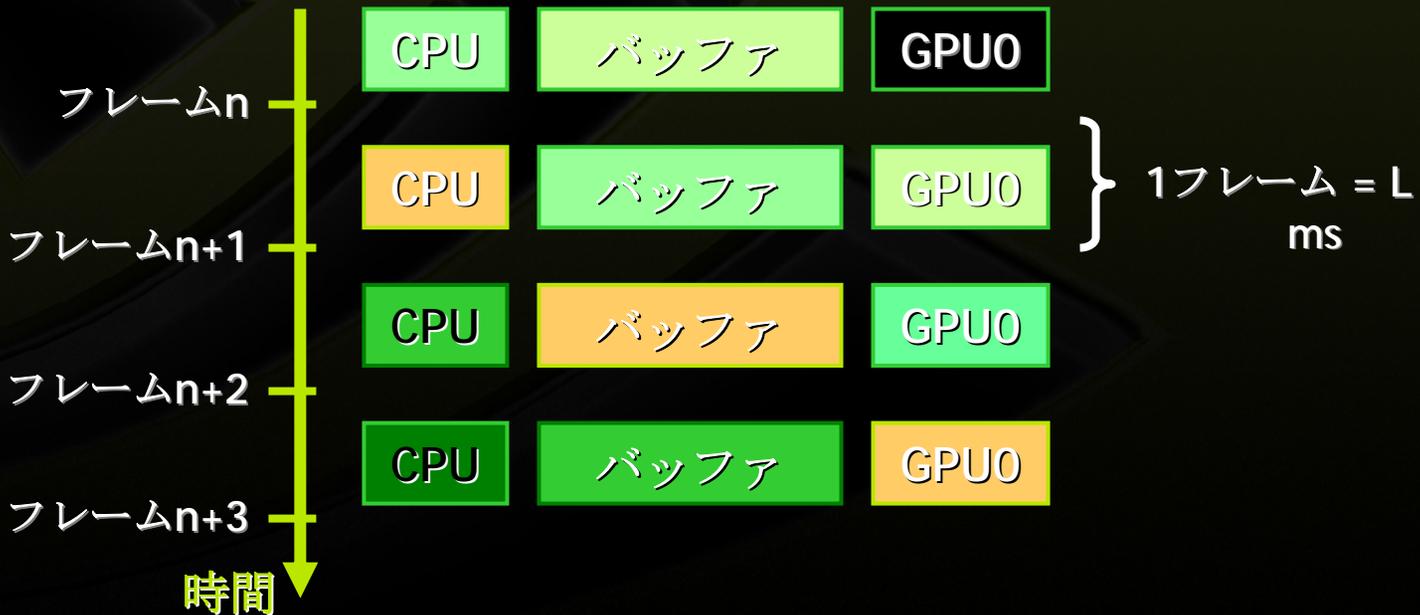


- 単一**GPU**のシステム:
最大1フレームのみバッファ
- **SLI**システムの場合:
最大2フレームのバッファ

パイプライン



フレームは時間に沿ってパイプラインを流れる:



単一GPUでの待ち時間



合計待ち時間: 3L ms

待ち時間の仮定



● GPU制限

- そうでなければ、バッファには1フレーム以下たまっている
- バッファを制限する意味はない

● SLIで2倍速

- あとでこれをゆるめる!

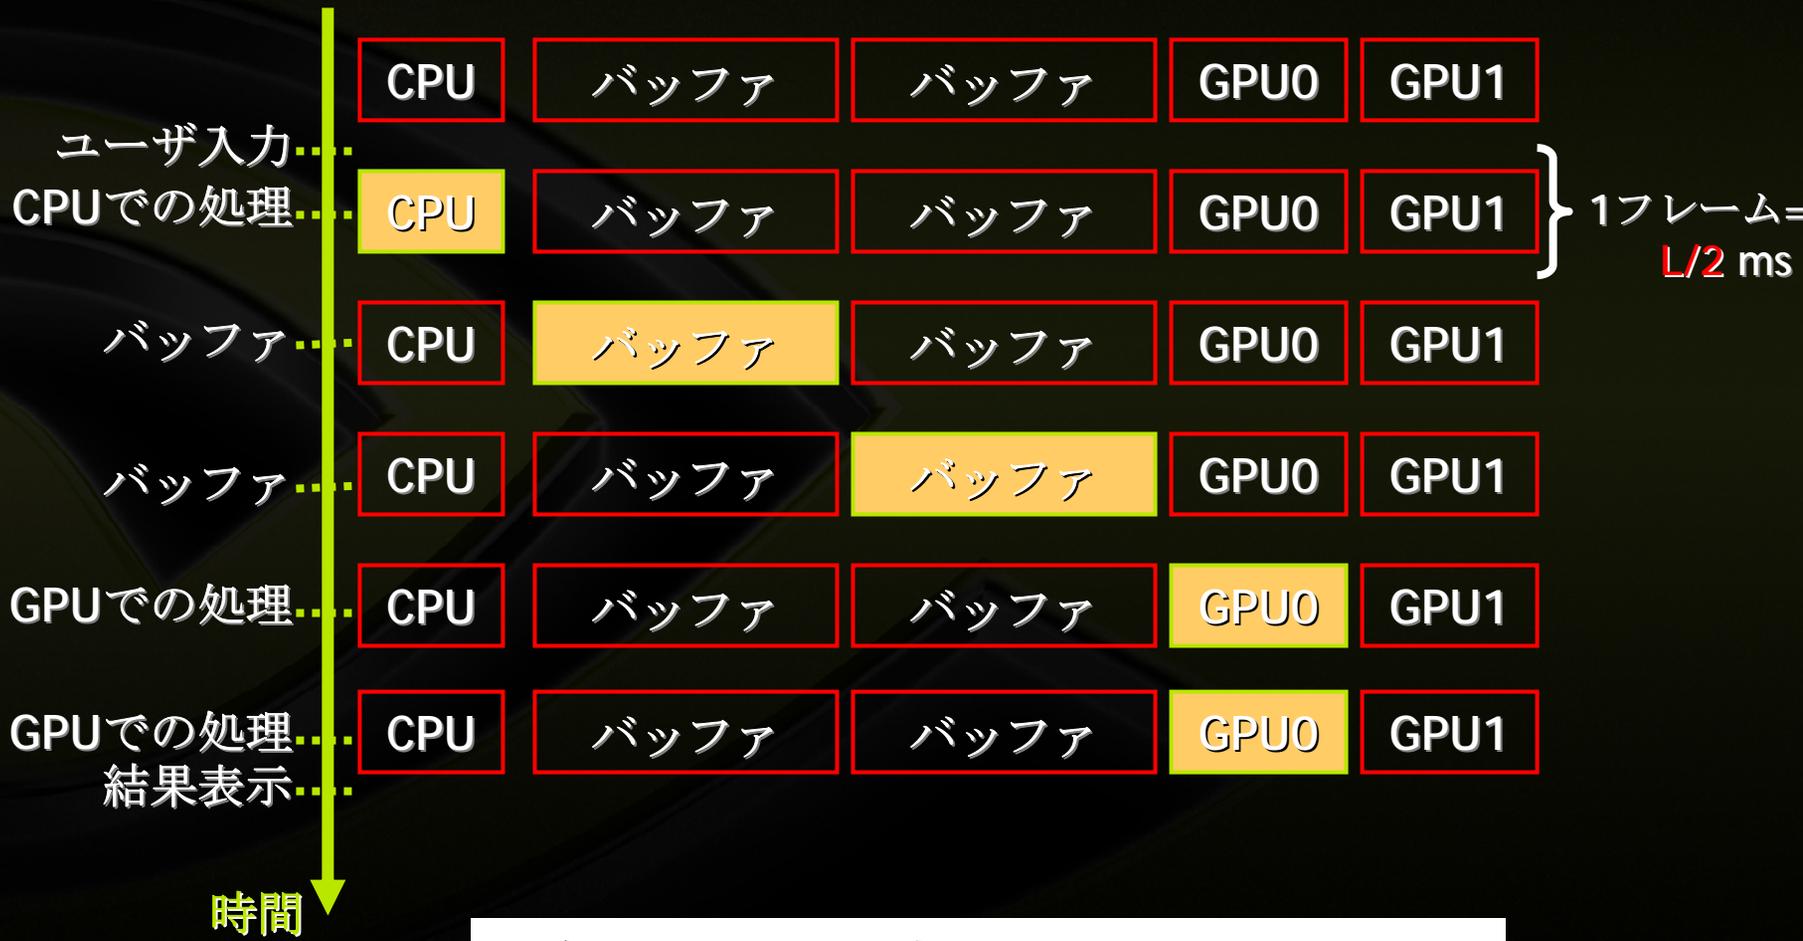
● バッファするフレームをふたつに:



AFR SLIを流れるフレーム



AFR SLI待ち時間



合計待ち時間: $5 \cdot L/2$ ms

待ち時間比較: 単一对AFR



- 単一GPU待ち時間: $3L$ ms
 - L 時間が3フレーム分
- AFR SLI GPU待ち時間: $5 L/2 = 2.5L$ ms!
 - $L/2$ 時間が5フレーム分
(フレーム・レートが倍)
 - 倍のフレームをバッファしているにもかかわらず
- SLIの高速化が1.66で良い!
 - $3L = 5L/x \rightarrow x = 5L/3L = 1.66$
 - ほとんどのゲームでは約1.8倍の高速化

SFRの待ち時間?



- **SFR**は1フレームのバッファでも問題ない
- **SFR**での高速化はそのまま待ち時間も減らす
 - もし**SFR**で2倍速なら
 - 待ち時間は半分に

さらに: **FPS**依存で時間差を制御



- ゲームが**100fps**超える場合、
 - 3フレームのバッファは問題ないだろう
- ゲームが**15**以下の場合
 - 1フレームだけバッファする
- 高速な**SLI**システムでは自動的に効果が上がる
- ドライバーはすでにこれを実装
 - **15fps**以上で3フレームをバッファ
 - **15fps**未満でバッファするフレーム数を減らす

概要: SLIが有効ではないケース



- CPU制限
 - またはvsyncが有効になっている
- バッファするフレーム数
- 通信負荷

通信負荷



● SLIメモリ転送

- 転送そのものに帯域幅と時間がかかる
- 転送を待つために**GPU**が制限

● 作業を両方の**GPU**で行う

- テクスチャ描画など

● 関連リソース:

- 頂点/インデックス・バッファ
- テクスチャ
- 描画領域

実行時にリソースをアップロード



- ビデオRAMは複製されている
- 両方のビデオRAMへの転送が必要
- 開発者にできることはほぼない

描画領域



- Zクリア
 - 常にZはクリア!
- SLI検出の際には色もクリア
 - ドライバーに前フレームのデータは必要ないと明示
 - 古いデータを**GPU**間で転送する必要がなくなる
- フレーム間でデータの再利用をしない
 - フレームを独立させる

更新省略『最適化』



● 余分なSLI負荷:



- GPU 1は GPU 0のRTT終了と転送を待つ
- もしくはGPU 1はRTT作業をする
- いっそSLI上では正しい動作をさせたほうが良いだろう

速めに描画、遅めに使用!



- 同期待ちを回避
 - AFR SLIで上のように
 - 単一GPUモードでも
 - 更新負荷は存在

非常に問題: 速めに使用、遅めに描画



もしくは: **SLI**の時はテクスチャをリング・バッファに!



SLIパフォーマンスのデバッグ



- **NVPerfKitのSLIサポート:**
 - ハードウェアとドライバのシグナル
 - **PIX**
 - **perfmon.exe**
 - **pdh (ゲーム、VTune、その他...)**

SLIパフォーマンスのシグナル



- 合計**SLI**転送量
- 合計**SLI**転送回数
- これは
 - 頂点/インデックス・バッファ
 - テクスチャ
 - 描画対象

質問?



- **GPU Programming Guide、第8章**
http://developer.nvidia.com/object/gpu_programming_guide.html
- <http://developer.nvidia.com>
The Source for GPU Programming
- mwloka@nvidia.com

The Source for GPU Programming

developer.nvidia.com

- Latest News
- Developer Events Calendar
- Technical Documentation
- Conference Presentations
- GPU Programming Guide
- Powerful Tools, SDKs and more ...



Join our FREE registered developer program for early access to NVIDIA drivers, cutting edge tools, online support forums, and more.

NVIDIA

developer.nvidia.com

©2004 NVIDIA Corporation. NVIDIA, and the NVIDIA logo are trademarks and/or registered trademarks of NVIDIA Corporation. Nalu is ©2004 NVIDIA Corporation. All rights reserved.

NVIDIA SDK

The Source for GPU Programming



Hundreds of code samples and effects that help you take advantage of the latest in graphics technology.

- Tons of updated and all-new DirectX and OpenGL code samples with full source code and helpful whitepapers:

Transparency AA, GPU Cloth, Geometry Instancing, Rainbow Fogbow, 2xFP16 HRD, Perspective Shadow Maps, Texture Atlas Utility, ...

- Hundreds of effects, complete with custom geometry, animation and more:

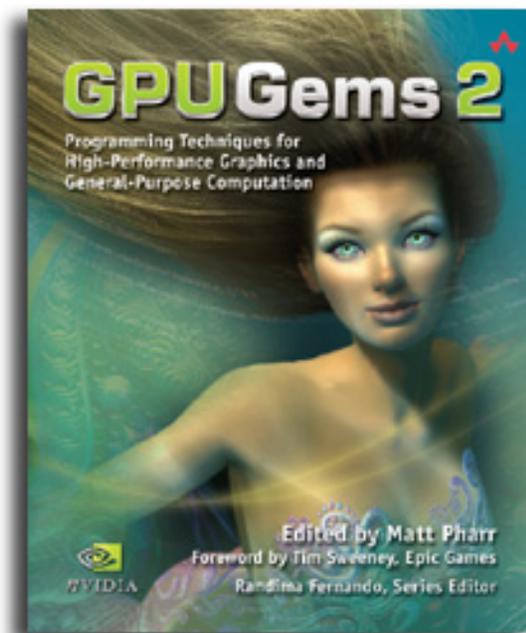
Shadows, PCSS, Skin, Plastics, Flame/Fire, Glow, Image Filters, HLSL Debugging Techniques, Texture BRDFs, Texture Displacements, HDR Tonemapping, and even a simple Ray Tracer!



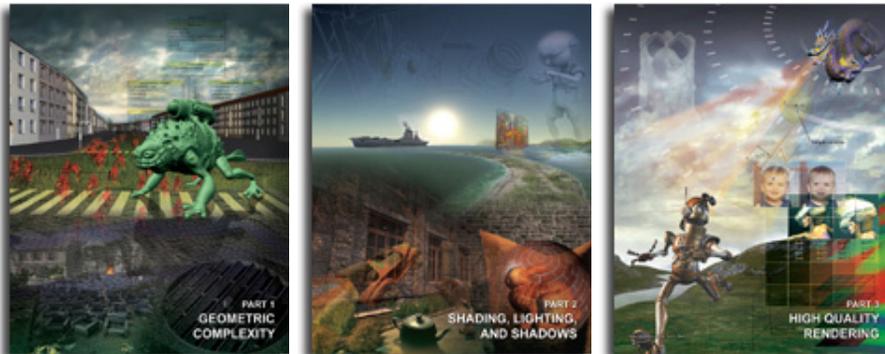
GPU Gems 2

Programming Techniques for High-Performance Graphics and General-Purpose Computation

- 880 full-color pages
- 330 figures
- Hard cover
- \$59.99
- Experts from universities and industry



Graphics Programming



- Geometric Complexity
- Shading, Lighting, and Shadows
- High-Quality Rendering

GPGPU Programming



- General Purpose Computation on GPUs: A Primer
- Image-Oriented Computing
- Simulation and Numerical Algorithms