Architektur und Programmierung von Grafik- und Koprozessoren

Rendering Algorithmen

Stefan Zellmann

Lehrstuhl für Informatik, Universität zu Köln

SS2019

Drei Rendering Algorithmen

Auswahlkriterien

Warum genau diese drei Algorithmen?

Es gibt eine Vielzahl von Rendering Algorithmen. Wir sind an denjenigen Algorithmen interessiert, die derzeit produktiv zum Einsatz kommen. Wir konzentrieren uns auf Algorithmen, die heute am populärsten z. B. in Film- oder Spieleindustrie sind, oder beim Echtzeit Rendering für Wissenschaftliche Visualisierung zum Einsatz kommen.

Wir behandeln drei Algorithmen, die entweder in Grafik Hardware fest implementiert sind, oder die sich einfach mit Hilfe von *programmierbarer* Grafikhardware implementieren lassen.

Auswahlkriterien

Warum genau diese drei Algorithmen?

Es gibt eine Vielzahl von Rendering Algorithmen. Wir sind an denjenigen Algorithmen interessiert, die derzeit produktiv zum Einsatz kommen. Wir konzentrieren uns auf Algorithmen, die heute am populärsten z. B. in Film- oder Spieleindustrie sind, oder beim Echtzeit Rendering für Wissenschaftliche Visualisierung zum Einsatz kommen.

Wir behandeln drei Algorithmen, die entweder in Grafik Hardware fest implementiert sind, oder die sich einfach mit Hilfe von *programmierbarer* Grafikhardware implementieren lassen.

Übersicht Rendering Algorithmen

Rasterisierung / z-Buffer Algorithmus

GPU Fixed-Function Pipeline, OpenGL und DirectX nutzen diesen Algorithmus.

g-Buffer Algorithmen ("Deferred Shading/Lighting")

Einfaches z-Buffering ist ineffizient, wenn viele Lichtquellen vorhanden. Erweiterung des z-Buffer Algorithmus, führe Beleuchtungsberechnung aus, *nachdem* Tiefentest entschieden ist ($\rightarrow$ viele Lichter).

Strahlverfolgung

Physikalisch plausibler als Rasterisierung - es wird ein Lichtpartikelmodell angenommen, bei dem sich Photonen entlang gerader Linien bewegen und dabei Phänomenen wie Absorption oder Streuung ausgesetzt sind.

Übersicht Rendering Algorithmen

Rasterisierung / z-Buffer Algorithmus

GPU Fixed-Function Pipeline, OpenGL und DirectX nutzen diesen Algorithmus.

g-Buffer Algorithmen ("Deferred Shading/Lighting")

Einfaches z-Buffering ist ineffizient, wenn viele Lichtquellen vorhanden. Erweiterung des z-Buffer Algorithmus, führe Beleuchtungsberechnung aus, *nachdem* Tiefentest entschieden ist ($\rightarrow$ viele Lichter).

Strahlverfolgung

Physikalisch plausibler als Rasterisierung - es wird ein Lichtpartikelmodell angenommen, bei dem sich Photonen entlang gerader Linien bewegen und dabei Phänomenen wie Absorption oder Streuung ausgesetzt sind.

Übersicht Rendering Algorithmen

Rasterisierung / z-Buffer Algorithmus

GPU Fixed-Function Pipeline, OpenGL und DirectX nutzen diesen Algorithmus.

g-Buffer Algorithmen ("Deferred Shading/Lighting")

Einfaches z-Buffering ist ineffizient, wenn viele Lichtquellen vorhanden. Erweiterung des z-Buffer Algorithmus, führe Beleuchtungsberechnung aus, *nachdem* Tiefentest entschieden ist ($\rightarrow$ viele Lichter).

Strahlverfolgung

Physikalisch plausibler als Rasterisierung - es wird ein Lichtpartikelmodell angenommen, bei dem sich Photonen entlang gerader Linien bewegen und dabei Phänomenen wie Absorption oder Streuung ausgesetzt sind.

Anmerkung zur Performanz von Rendering Algorithmen

Es gibt keine "per Konstruktion" langsamen Algorithmen, bestimmte Phänomene aber besser (oder schneller) mit bestimmten Algorithmen lösbar, z. B.:

- wenige Punktlichtquellen, lokale Beleuchtung: eher Rasterisierung.
- globale Beleuchtung, Scattering Phänomene, Flächenlichtquellen: eher Ray Tracing et al.
- viele Lichtquellen, Einsatz von Post Processing Verfahren (z. B. Bloom, Lens Flare, Screen Space Ambient Occlusion): g-Buffer.

Hardware Implementierung

Dedizierte Hardware Implementierung kann Algorithmen beschleunigen:

- Umgehung von General Purpose Befehlssatz.
- Speicherabstraktion ausgelegt auf Speicherzugriffsmuster, z. B. raumfüllende Kurven für 2D Texturen.
- Hardware Implementierung geht häufig mit dediziertem Befehlssatz für den Algorithmus einher (z. B. Register für 4-Komponenten Vektor Operationen) (denn nicht programmierbare Architekturen auf Dauer langweilig).

Popularität des Rasterisierungsalgorithmus rührt u. a. daher, dass GPUs speziell diesen Algorithmus in Hardware implementieren.

Weiteres Vorgehen

- Zunächst Erarbeiten einer formalen Beschreibung der drei Familien von Rendering Algorithmen.
- Darauf aufbauend Komplexitätsanalyse:
  - bzgl. #Polygone, #Pixel (Auflösung), sowie #Lichtquellen.
  - unter Annahme einer Turing Maschine (seriell, wahlfreier Zugriff auf Speicher).
  - später unter Annahme paralleler Architektur (PRAM).

Der Rasterisierungsalgorithmus

Rasterisierung

Im Abschnitt *Grundlegendes* dieses Vorlesungsteils haben wir die meisten Einzelkomponenten des Rasterisierungsalgorithmus schon kennengelernt. Wir wollen nun die Komponenten zusammenfügen und den Algorithmus formal analysieren.

Rasterisierung - Eingabedaten (1)

Liste von Vertices $V_i := \{\mathbf{p_i}, \vec{n}_i, TC_i, C_i, \cdots\}$

Position $\mathbf{p_i} \in \mathbb{R}^3$

Weitere (ggf. benutzerdefinierte) Vertex Attribute, z. B.:

Normalenvektor $\vec{n}_i \in \mathbb{R}^3$, wobei $\|\vec{n}_i\| = 1$

Texturkoordinate $TC_i \in \mathbb{R}^2$

Vertexfarben $\mathbf{C_i}$

Annahme:

Jeweils n aufeinanderfolgende Vertices $V_i, i \bmod n = [1, .., n-1, 0]$ sind koplanar bzgl. $\mathbf{p_i}$ (wir nehmen $n = 3$ an, also Dreiecke).

Bemerkung:

Da sich mehrere Dreiecke ein Vertex teilen können, hat man häufig einen Vertex Buffer und einen *Index Buffer*, aus dem die Dreiecke zusammengesetzt werden. Wird hier der Einfachheit halber ignoriert.

Rasterisierung - Eingabedaten (2)

Liste von Materialeigenschaften und Texturen

M_k

Liste von (Punkt-)Lichtquellen $L_j := \{P_j, I_j\}$

Position $P_j \in \mathbb{R}^3$
Lichtintensität $I_j(W/sr)$

Rasterisierung - Eingabedaten (3)

Beleuchtungsfunktion ("Shader")

$$\begin{aligned} f\colon \{\vec{\omega_i}, \vec{\omega_o}, M_k, L_j, ...\} &\to C, \\ C &\in \mathbb{R}^n_+, \\ \vec{\omega_i}, \vec{\omega_o} &\in \mathbb{R}^3 \end{aligned} \tag{19}$$

Bidirektionale Reflektionsverteilungsfunktionen in Abhängigkeit von Lichtrichtungsvektoren $\vec{\omega_i}$ und $\vec{\omega_o}$ (kompliziertere Modelle sind möglich).
C ist i. Allg. Farbe oder spektrale Energieverteilung.

Rasterisierung - Eingabedaten (4)

Kameraparameter

Matrix $MV \in \mathbb{R}^{4\times4}$ (*extrinsische* Kameraparameter).
Matrix $PR \in \mathbb{R}^{4\times4}$ (*intrinsische* Kameraparameter).
Bildebene definiert durch Rechteck $VP = (x, y, w, h)$
(Ursprung + Breite und Höhe).

Extrinsische Parameter $\rightarrow$ Positionierung und Orientierung der Kamera bzgl. der Geometrie (affine Transformationen).

Intrinsische Parameter transkodieren, wie die *perspektivische Verzerrung* (der Effekt, dass entfernte Objekte kleiner erscheinen) anzuwenden ist. Hängen von Kameraeigenschaften wie Blendenöffnungswinkel, fokale Länge etc. ab.

Rasterisierung - Ausgabe

Rasterbild $I(VP)$, Dimensionen gemäß VP aus den Eingabedaten.

Rasterisierung Algorithmus 1

```
function RASTERISIERUNG(V,M,L,f,MV,PR,VP)
    for all v1, v2, v3 ∈ V do
        TRANSFORMATIONEN(v1,v2,v3,MV,PR)
        CLIPPING(v1,v2,v3,PR)
        T ←ERZEUGEDREIECKE(v1,v2,v3)
        for all t ∈ T do
            Fragmente ←SCANKONVERTIERUNG(t,VP)
            for all F ∈ Fragmente do
                for all Lj ∈ Lichtquellen do
                    BELEUCHTE(F,M,Lj,f)
                end for
                TIEFENTEST(F, I)
                ALPHABLENDING(F, I)
            end for
        end for
    end for
end function
```

Rasterisierung - Vertex Phase

```
function RASTERISIERUNG(V,M,L,f,MV,PR,VP)
    for all v1, v2, v3 ∈ V do
        TRANSFORMATIONEN(v,MV,PR)
        CLIPPING(v,PR)
        ...
    end for
end function
```

1. Wende Viewing- und Perspektivische Transformation auf jedes Vertex an.
2. Clippe Vertices am Sichtbaren Frustum.

Rasterisierung - Primitive Assembly

function RASTERISIERUNG(V,M,L,f,MV,PR,VP)

...

$T \leftarrow$ ERZEUGEDREIECKE(v_1,v_2,v_3)

...

end function

3. Für jedes Eingabedreieck $\{v_1, v_2, v_3\}$, erzeuge Dreiecke, die sich *nach Clipping* ergeben.

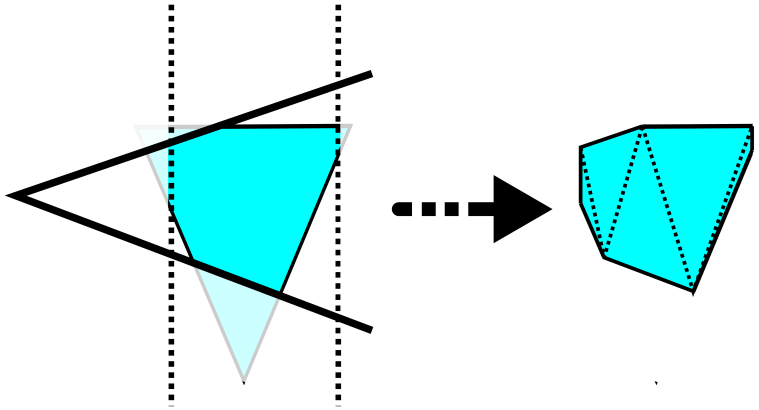

Rasterisierung - Fragment Phase

```
function RASTERISIERUNG(V,M,L,f,MV,PR,VP)
    ...
    for all t ∈ T do
        Fragmente ←SCANKONVERTIERUNG(t,VP)
        for all f ∈ Fragmente do
            for all L_j ∈ Lichtquellen do
                BELEUCHTE(F,M,L_j,f)
            end for
            TIEFENTEST(F, I)
            ALPHABLENDING(F, I)
        end for
    end for
    ...
end function
```

4. Fragmente ergeben sich nach Scan Konvertierung.
5. Jedes Fragment wird beleuchtet, erst dann Tiefentest!

Rasterisierung Algorithmus 1 - Bemerkungen

- Manche Implementierungen führen Beleuchtungsberechnungen auf den Vertices durch und interpolieren später die resultierenden Farben.
- Der Algorithmus unterstützt sowohl opake als auch teiltransparente Geometrie. I. d. R. wird man den Tiefentest nur für opake, und Alpha-Blending nur für teiltransparente Fragmente ausführen.
- APIs (Direct3D, OpenGL, Vulkan) garantieren, dass Reihenfolge während Fragment Phase Eingabereihenfolge entspricht.

Rasterisierung Algorithmus 1 - Worst-Case Komplexität

Vorabüberlegungen

- Aus der *Primitive Assembly Phase* ergeben sich durch Clipping bis zu vier Dreiecke. Die Schleife über alle Dreiecke T lässt sich also durch $O(4)$ abschätzen.
- Die Anzahl an Fragmenten, die nach Scan Konvertierung *eines* Dreiecks entstehen, ist durch $O(VP)$ beschränkt, wobei VP die Bildschirmauflösung bezeichnet.
- Wir nehmen an, dass es für die Subroutinen TRANSFORMATIONEN und CLIPPING, BELEUCHTE, TIEFENTEST, ALPHABLENDING und ERZEUGEDREIECKE jeweils $O(1)$ Algorithmen gibt. SCANKONVERTIERUNG ist durch $O(VP)$ beschränkt.

Rasterisierung - Worst-Case Komplexität

Es ergibt sich also im schlechtesten Fall für den Algorithmus Rasterisierung (1) die Komplexität:

$$O(V) \times O(4) \times (O(VP) \times O(L) + O(VP)) = O(V \times VP \times L) \quad (20)$$

Wir wollen im folgenden vereinfachend annehmen, dass die Anzahl Lichtquellen L konstant ist. Damit ergibt sich die Laufzeitkomplexität

$$O(V \times VP). \quad (21)$$

Wenn wir uns mit "Deferred Shading" beschäftigen, werden wir wieder von variabel vielen Lichtquellen ausgehen.

Rasterisierung - Algorithmus 2

Bemerkung

Unter praktischen Gesichtspunkten ist die Laufzeitkomplexität dieses Algorithmus sehr hoch. Praktische Arbeitslasten verarbeiten Millionen von Dreiecken und erzeugen Bilder mit Millionen von Pixeln.

Wir wollen eine alternative Formulierung des Algorithmus RASTERISIERUNG betrachten. Ziel: besser verstehen, welche *Umstrukturierungsmaßnahmen* auf GPUs vorgenommen werden, um den *Durchsatz* zu erhöhen.

Rasterisierung - Algorithmus 2

```
function RASTERISIERUNG(V,M,L,f,MV,PR,VP)
    for all v ∈ V do
        TRANSFORMATIONEN(v,MV,PR)
        CLIPPING(v,PR)
    end for
    T ←ERZEUGEDREIECKE(V)
    for all t ∈ T do
        Fragmente ←SCANKONVERTIERUNG(t, VP)
    end for
    for all F ∈ Fragmente do
        for all L_j ∈ Lichtquellen do
            BELEUCHTE(F,M,L_j,f)
        end for
        TIEFENTEST(F, I)
        ALPHABLENDING(F, I)
    end for
end function
```

Rasterisierung - Algorithmus 2

Struktur von Algorithmus 2:

```
function RASTERISIERUNG(V,M,L,f,MV,PR,VP)
    for all v ∈ V do                                  ▷ Vertex Phase
        ...
    end for
    ...                                               ▷ Pufferung von Dreiecken
    for all t ∈ T do                                  ▷ Scan Konvertierung
        ...                                           ▷ Pufferung aller Fragmente
    end for
    for all F ∈ Fragmente do                          ▷ Fragment Phase
        ...
    end for
end function
```

Rasterisierung - Algorithmus 2

Algorithmus Rasterisierung 2 hat offensichtlich die gleiche obere **Laufzeitschranke** wie Algorithmus 1

$$O(V) \times O(VP) \times O(L). \tag{22}$$

Allerdings: Dreiecke und Fragmente werden gepuffert $\Rightarrow$ **Speicherbedarf**:

$$O(V) \times O(VP) \tag{23}$$

Bemerkung: nach der Vertex Phase müssen auch Dreiecke gepuffert werden. Asymptotisch hängt dies von V ab. Da es aber konstant mal so viele Ausgabe- wie Eingabe Vertices gibt, vernachlässigen wir dies und nehmen einfach an, dass die neuen Vertices "in der Nähe" der Eingabe Vertices gepuffert werden können.

Rasterisierung - Algorithmus 2

Bemerkungen

- Wir haben jetzt also zwei alternative Formulierungen des Rasterisierungsalgorithmus. Die zweite Formulierung hat augenscheinlich den Nachteil sehr hohen Speicherbedarfs.
- Den Ansatz, erst Vertices und dann Fragmente zu verarbeiten, nennt man in der Computergrafik “deferred”: die Verarbeitung der Fragmente wird hinausgezögert, bis (genügend) Vertices verarbeitet wurden.

Rasterisierung - PRAM Formulierung

Wir betrachten im folgenden PRAM Formulierungen des Rasterisierungsalgorithmus.

Wir wollen verstehen, an welchen Stellen die beiden Formulierungen Parallelismus exponieren und welche Auswirkungen das auf den *Durchsatz* hat.

Rasterisierung Paralleler Algorithmus 1

```
function RASTERISIERUNG(V,M,L,f,MV,PR,VP)
    for all v1, v2, v3 ∈ V do in parallel                    ▷
        TRANSFORMATIONEN(v1,v2,v3,MV,PR)
        CLIPPING(v1,v2,v3,PR)
        T ←ERZEUGEDREIECKE(v1,v2,v3)
        for all t ∈ T do
            Fragmente ←SCANKONVERTIERUNG(t,VP)
            for all F ∈ Fragmente do
                for all Lj ∈ Lichtquellen do
                    BELEUCHTE(F,M,Lj,f)
                end for
                TIEFENTEST(F, I)
                ALPHABLENDING(F, I)
            end for
        end for
    end for
end function
```

Rasterisierung Paralleler Algorithmus 1

Komplexität

- Der Parallele Algorithmus 1 ist auf der CRCW PRAM lauffähig (synchronisierte Zugriffe für TiefenTest und AlphaBlending).
- Arbeitskomplexität: $W(n) = O(V \times VP)$.
- Zeitkomplexität: $S(n) = O(1) \times O(4) \times O(VP)$.
  - $\Rightarrow$ die Zeitkomplexität beträgt $O(VP)$.

Rasterisierung Paralleler Algorithmus 2

(1/2)

```
function RASTERISIERUNG(V,M,L,f,MV,PR,VP)
    for all v ∈ V do in parallel                                  ▷
        TRANSFORMATIONEN(v,MV,PR)
        CLIPPING(v,PR)
    end for
    for all v1, v2, v3 ∈ V do in parallel                         ▷
        T ←ERZEUGEDREIECKE(v1,v2,v3)
    end for
    for all t ∈ T do in parallel                                  ▷
        Fragmente ←SCANKONVERTIERUNG(t,VP)
    end for
    ...
end function
```

Rasterisierung Paralleler Algorithmus 2

(2/2)

```
function RASTERISIERUNG(V,M,L,f,MV,PR,VP)
    ...
    for all F ∈ Fragmente do in parallel                    ▷
        for all L_j ∈ Lichtquellen do
            BELEUCHTE(F,M,L_j,f)
        end for
        TIEFENTEST(F, I)
        ALPHABLENDING(F, I)
    end for
end function
```

Rasterisierung Paralleler Algorithmus 2

Komplexität

- Arbeitskomplexität: $W(n) = O(V \times VP)$.
- Zeitkomplexität: $S(n) = O(1) + O(4)O(VP) + O(1) = O(VP)$.
- Die Speicherkomplexität bleibt ggü. dem seriellen Algorithmus unverändert.
- Wir können die einzelnen Phasen des Algorithmus *separat* parallelisieren.

Rasterisierung Paralleler Algorithmus 2

Bemerkungen

- Die Umformulierung führt asymptotisch nicht zu einer Veränderung von Zeit- und Arbeitskomplexität. Der Algorithmus teilt sich nun jedoch in mehrere parallele Arbeitsphasen auf.
- Durch die Operation TiefenTest ergeben sich Speicherzugriffe, die synchronisiert werden müssen ($\Rightarrow$ CRCW), dies ist jedoch bei beiden Algorithmen der Fall.
- Es bleibt der hohe Speicherbedarf ($O(V \times VP)$), der sich mit Hilfe des PRAM Modells nicht auflösen lässt.

Rasterisierung Paralleler Algorithmus 2

Überlegungen

Überlappe die $O(V)$ und $O(V \times VP)$ Arbeitsphasen zeitlich. PRAM für jede Arbeitsphase. Schlange für Dreiecke und Fragmente.

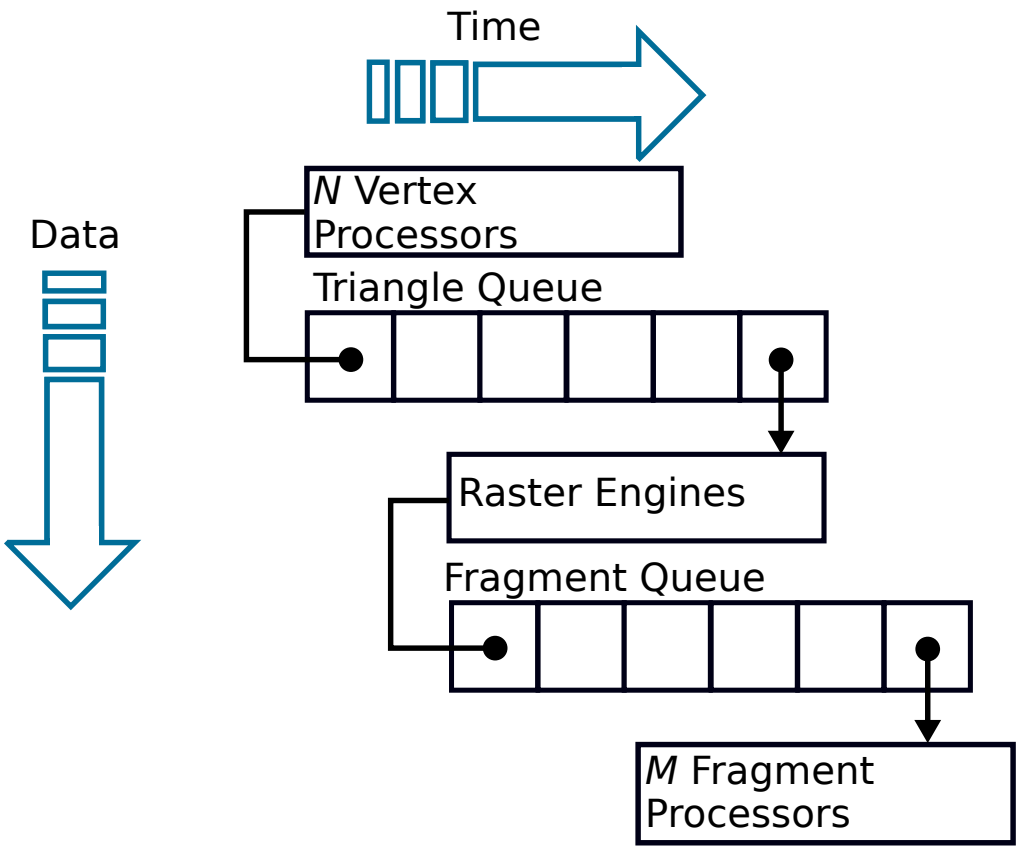

Deferred Shading

Deferred Shading

Vorabüberlegungen

- Der zweite parallele Rasterisierungsalgorithmus kommt dem tatsächlich in Hardware implementierten Algorithmus auf GPUs sehr nahe. Wir gehen im folgenden davon aus, dass das Speicherbedarfsproblem durch Methoden wie Pipelining und Queueing gelöst ist.
- Bei unseren Überlegungen gingen wir von einer konstanten, geringen Anzahl an Lichtquellen aus. Für bestimmte 3D Beleuchtungsszenarien ist dies jedoch nicht adäquat. Wir betrachten daher im folgenden den Fall, dass wir viele Lichtquellen haben, und dass die Anzahl an Lichtquellen asymptotischen Einfluss hat.

Rasterisierung

Wir betrachten wieder den Algorithmus RASTERISIERUNG, diesmal in vereinfachter Form:

```
function RASTERISIERUNG(M,L,f)
    Fragmente ← VERTEXPHASE
    for all F ∈ Fragmente do in parallel
        for all L_j ∈ Lichtquellen do
            BELEUCHTE(F,M,L_j,f)
        end for
        TIEFENTEST(F, I)
        ALPHABLENDING(F, I)
    end for
end function
```

Vertex Transformation und Scan Konvertierung analog zu "Parallele Rasterisierung 2" - wir interessieren uns für Fragment Phase, die asymptotisch von der Anzahl Lichtquellen abhängt.

Beleuchtung von Fragmenten

Problem: Beleuchtung muss für alle Fragmente durchgeführt werden, da Geometrie evtl. teiltransparent. Weitere Vereinfachung daher: nur opake Geometrie.

```
function RASTERISIERUNG(M,L,f)
    Fragmente ← VERTEXPHASE
    for all F ∈ Fragmente do in parallel
        for all L_j ∈ Lichtquellen do
            BELEUCHTE(F,M,L_j,f)
        end for
        TIEFENTEST(F, I)
    end for
end function
```

In der Praxis: separate *Render Passes* für opake und für *tiefensortierte*, transparente Geometrie. 2. Pass: berücksichtige Tiefenpuffer aus erstem Pass.

Beleuchtung von Fragmenten

Unter diesen Annahmen kann man auch die Fragment Phase "deferred" formulieren.

```
function RasterisierungDeferred(M,L,f)
    Fragmente ← VertexPhase
    for all F ∈ Fragmente do in parallel
        Pixel(F) ← TiefenTest(F, I)
    end for
    for all L_j ∈ Lichtquellen do
        for all p ∈ Pixel do in parallel
            Beleuchte(p,M,L_j,f)
        end for
    end for
end function
```

Deferred Shading Komplexität

Durch die Umformulierung verringert sich die Arbeitskomplexität des Algorithmus.
Ursprünglich:

$$W(n) = O(V) \times O(VP) \times O(L) \tag{24}$$

Deferred:

$$W(n) = O(V) \times O(VP) + O(L) \times O(VP) \tag{25}$$

Wie auch schon bei der Umformulierung von Rasterisierung ergibt sich weiterer Speicherbedarf, nämlich dadurch, dass VP "Pixel" gespeichert werden müssen.

Deferred Shading Komplexität

Der erhöhte Speicherbedarf wird asymptotisch ammortisiert, wenn man davon ausgeht, dass wir Deferred Shading auf Basis von Parallele Rasterisierung 2 implementieren:

$$O(V \times VP) + O(VP) = O(V \times VP) \tag{26}$$

Deferred Shading in der Praxis

Wir wollen betrachten, wie man Deferred Shading in der Praxis auf GPUs implementiert. Wir verwenden vier 2D Texturen, die die gleiche Auflösung wie das zu rendernde Bild haben:

1. Tiefentextur (DB): Tiefeninformation für jedes Pixel aus Tiefentest (i. Allg. kann man auf den Tiefenpuffer von GPUs nicht direkt zugreifen, sondern muss diesen kopieren).
2. Normalentextur (NB): Shading Normale für jedes Pixel bzgl. der Geometrie, die den Tiefentest bestanden hat.
3. Diffuse Textur (TB): Diffuse Texturinformation für jedes Pixel.
4. Materialindextextur (MB): Materialindex für jedes Pixel.

Die sich ergebende Datenstruktur nennt man *Geometry Buffer* (g-Buffer).

Deferred Shading in der Praxis

g-Buffer

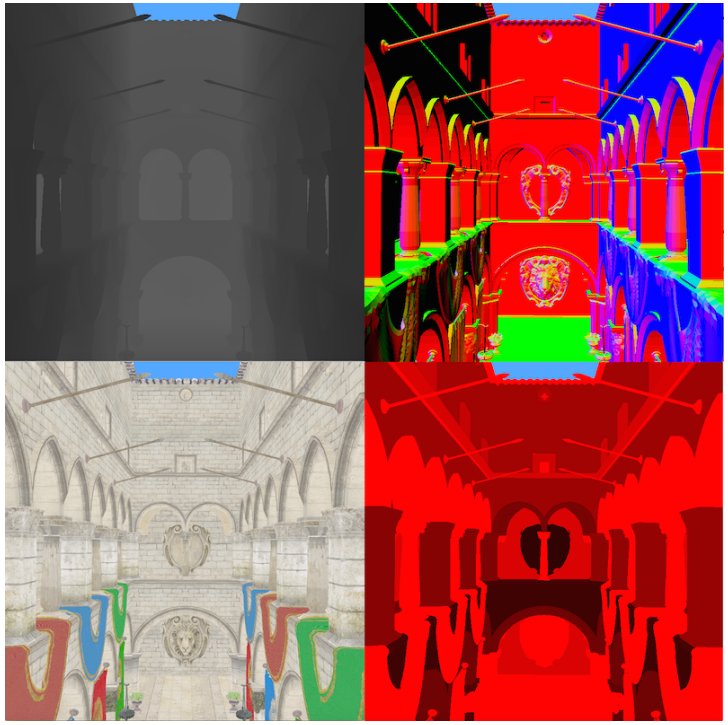

Ergebnis

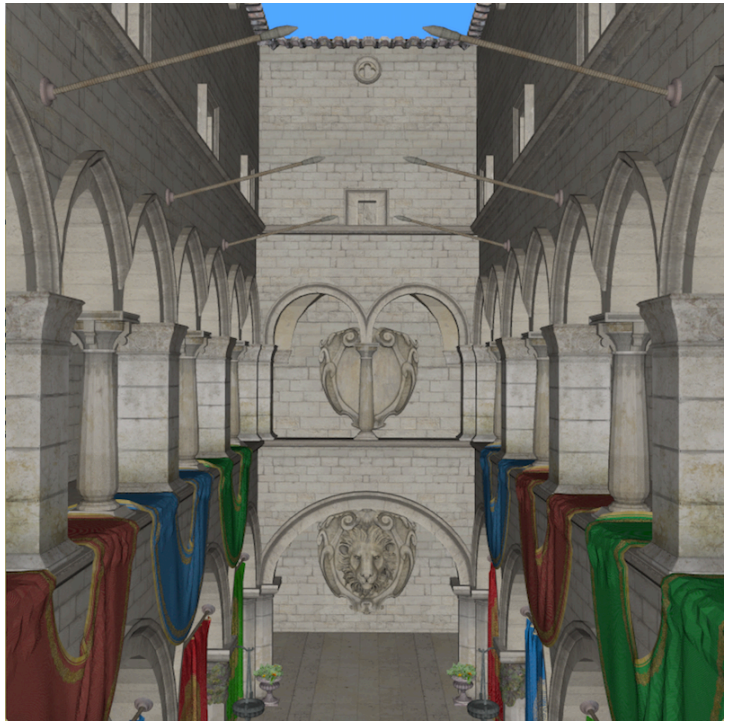

Crytek Sponza 3D Modell: Frank Meinl, (CC-BY 3.0), Rendering: Stefan Zellmann

Deferred Shading in der Praxis

Beim Deferred Shading auf der GPU wird die Fragment Phase von weiter oben leicht angepasst. Eine Implementierung sieht strukturell etwa so aus:

```
parallel_for_each(f in fragmente) {
    tiefen_test(f);
    gbuffer[f.x][f.y] = { f.tiefe, f.normale,
                          f.diffus, f.material_index };
}

for_each(l in lichter) {
    parallel_for_each(p in pixel) {
        beleuchte_pixel(l, p, gbuffer[p.x][p.y]);
    }
}
```

Deferred Shading in der Praxis

Implementiert als "Multi Render Pass" Verfahren. Erster Render Pass baut g-Buffer auf.

```
parallel_for_each(f in fragmente) {
    tiefen_test(f);
    gbuffer[f.x][f.y] = { f.tiefe, f.normale,
                          f.diffus, f.material_index };
}
```

Dann folgen #*Lichtquellen* viele Render Passes, die die *Pixel* (nicht mehr Fragmente!) beleuchten.

```
parallel_for_each(p in pixel) {
    beleuchte_pixel(l, p, gbuffer[p.x][p.y]);
}
```

Auf GPUs ist die Fragment Phase frei programmierbar. Die Render Passes (auch die über Pixel) erfolgen in einem *Fragment Programm* (werden im Vorlesungsteil zu GPU Architekturen besprochen).

Deferred Shading in der Praxis

Wir wollen einschätzen, wie hoch der Speicherbedarf für den g-Buffer beim Deferred Shading, etwa in MB, ist. Nehmen wir an, dass wir die g-Buffer Einträge wie folgt speichern:

DB	24-bit
NB	$2 \times$ 32-bit (Polarkoordinaten)
TB	$3 \times$ 32-bit (RGB)
MB	16-bit

Für eine Bildschirmauflösung von 1024×1024 Pixel ergibt sich dann etwa ein Speicherverbrauch von 25 MB.

Deferred Shading in der Praxis

Überlegt man sich, dass um 2005 herum Videospeicher häufig bei etwa 100 MB bemessen war, versteht man, dass g-Buffer Datenstrukturen bzgl. des Speicherbedarfs optimiert werden mussten. Dies rückt angesichts mehrerer GB Speicher heutiger GPUs in den Hintergrund.

Unsere Überlegungen zum Speicherverbrauch in der Praxis über die Jahre bestätigen also, dass der zusätzliche Speicherbedarf durch eine verzögerte Beleuchtungsphase asymptotisch ammortisiert wird ($O(V \times VP) + O(VP) = O(V \times VP)$).

Deferred Shading in der Praxis

g-Buffer Latenz

- Problem allerdings: g-Buffer liegt in GDDR3 Speicher $\Rightarrow$ hohe Zugriffslatenz.
- Großes Problem auf alten GPUs.
- Moderne GPUs sind darauf optimiert, während Speicherzugriffen unabhängige Berechnungen durchzuführen. Positiv beim Deferred Shading.
- Mehr dazu im Vorlesungsteil zu GPU Architekturen.

Deferred Shading in der Praxis

Beleuchtungsphase

Wenn g-Buffer aufgebaut, L Passes über Pixel (Tiefentest ist also bereits entschieden, i. Allg. gilt: #Pixel << #Fragmente.

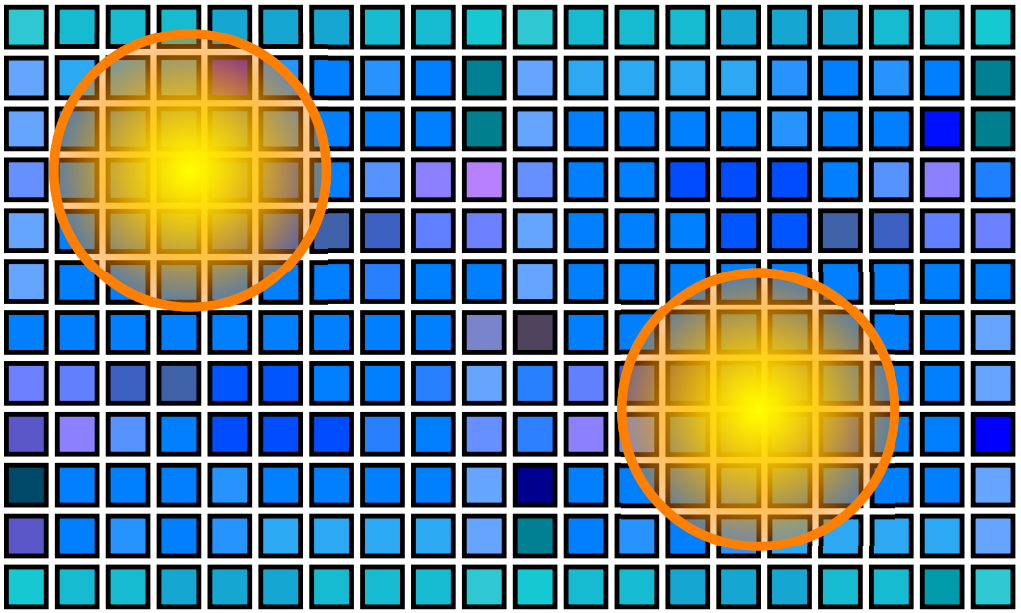

Punktlichtquellen: radialer Fall-Off ("inverse square"), man kann Umkugel für Lichtquellen berechnen $\Rightarrow$ Passes gehen i. d. R. nicht über alle Pixel.

Deferred Shading in der Praxis

- Deferred Shading wurde als Erweiterung der Rasterisierungs Pipeline älterer GPUs implementiert - maßgeblich in den Software-Industriezweigen, die sich mit realistisch anmutender Echtzeitgrafik beschäftigen (Spiele).
- Game Engines wie Unreal oder Unity verfügen über Rendering Pfade, die auf g-Buffer Algorithmen aufsetzen.
- Es wurden über die Jahre Erweiterungen oder alternative Verfahren entwickelt, die auf g-Buffer aufsetzen, u. a. *Deferred Lighting*, *Screen Space Ambient Occlusion*, aber auch Image-Filter Verfahren, die die Tiefeninformation ausnutzen.

Deferred Shading in der Praxis

"Pitfalls"

- Keine teiltransparente Geometrie (es gibt Verfahren wie etwa "Depth Peeling", die verwendet werden können, üblich ist aber ein separater "forward pass" ohne g-Buffer).
- Anti-aliasing nicht ganz einfach.
  - Man kann *nicht* einfach "supersamplen", also das Bild mit höherer Auflösung rendern und dann kleiner skalieren. Normalen aus der Normalentextur können beim Skalieren nicht einfach linear interpoliert werden.
- Anzahl an *Materialtypen* nicht variabel, g-Buffer kodiert Attribute.
- Es ist ungünstig, dass Tiefenwerte umkopiert werden müssen, obwohl die Hardware sie bereits speichert.