

Massively-Parallel Proximity Queries for Point Clouds

Max Kaluschke

October 6, 2014

Motivation

Neuer Datentyp

- ▶ Neuer Datentyp: Point Clouds
- ▶ traditionell Triangle-Mesh
 - ▶ viel-erforschter Bereich
 - ▶ Surface Reconstruction sehr aufwändig
- ▶ immer frische Daten
 - ▶ Kinect hat ca. 30 FPS
 - ▶ kein Preprocessing möglich
- ▶ Umfassen sehr viele Punkte
 - ▶ Auflösung einer einzelnen Kinect Aufnahme: ca. 300.000 Punkte

Motivation

Kollisionen vermeiden

- ▶ Möglichst schnelle Berechnung

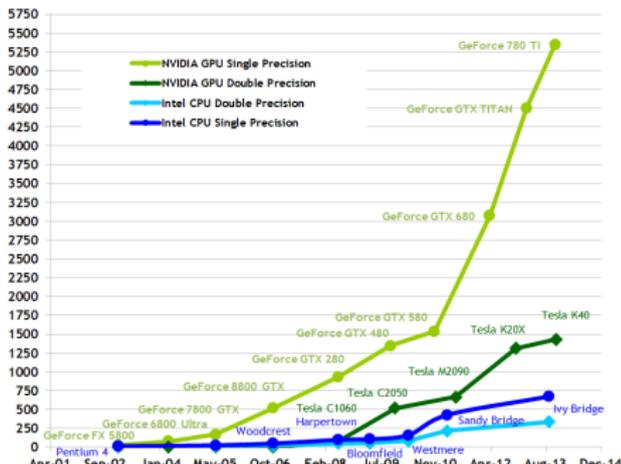


Motivation

Vorteile der GPU

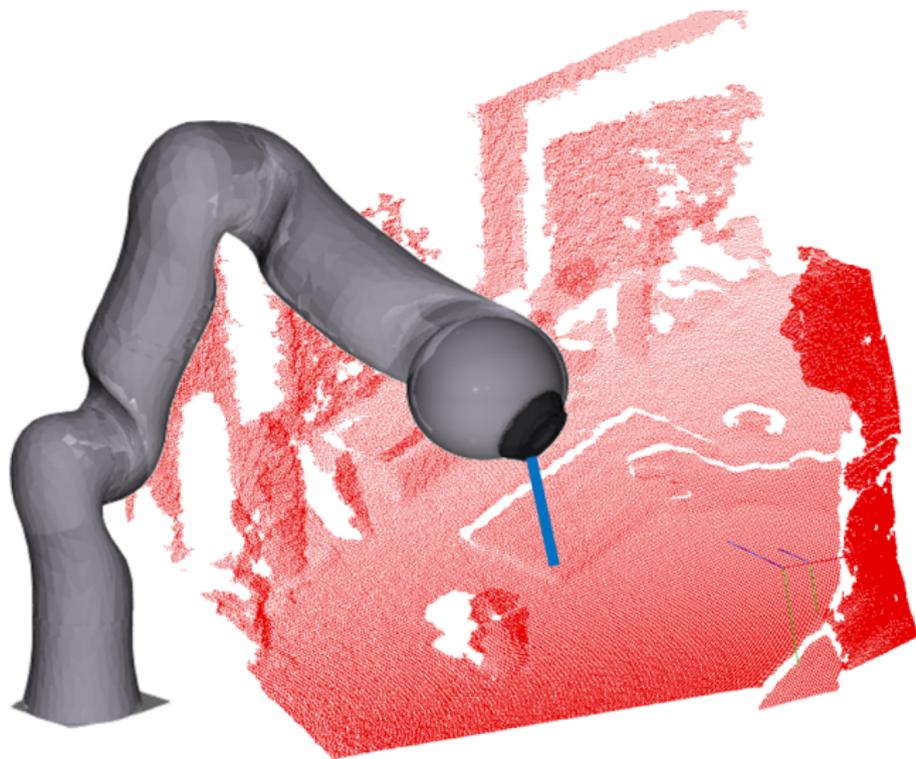
- ▶ CPU Fortschritt stagniert
 - ▶ früher: Transistoren werden immer kleiner → mehr Transistoren passen auf die selbe Fläche
 - ▶ in den letzten Jahren: mehr Cache, mehr Parallelisierung
- ▶ GPUs sind dagegen ausgelegt für parallele Arbeit
 - ▶ GPUs übertreffen CPUs in theoretischer Leistung:

Theoretical GFLOP/s



Das konkrete Setup

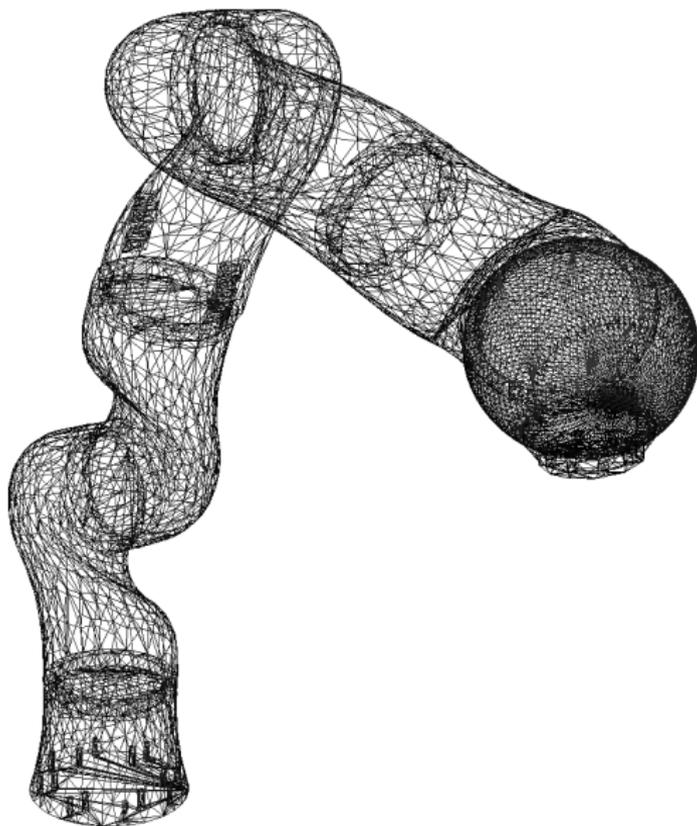
- ▶ Zusammenarbeit mit KUKA



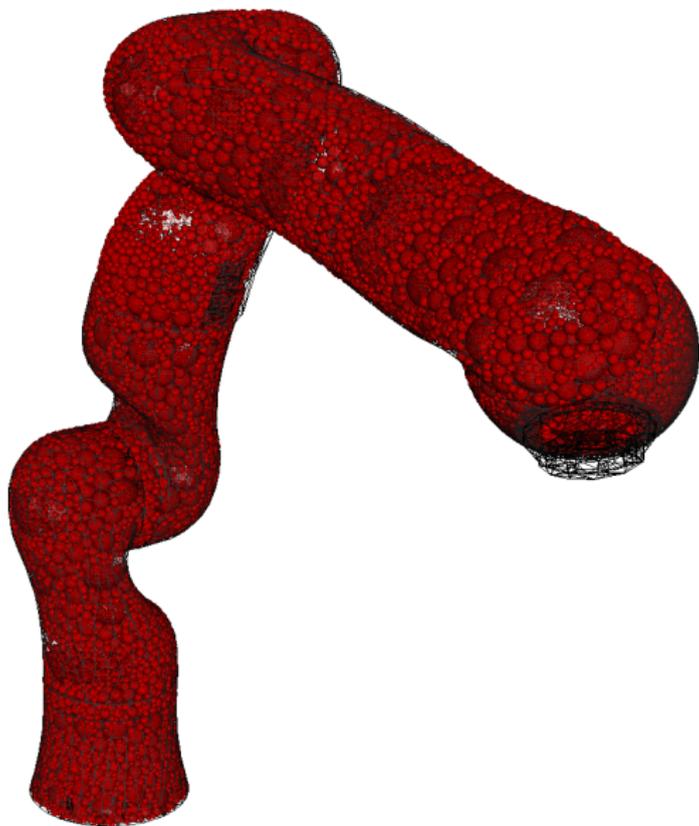
Der Roboter



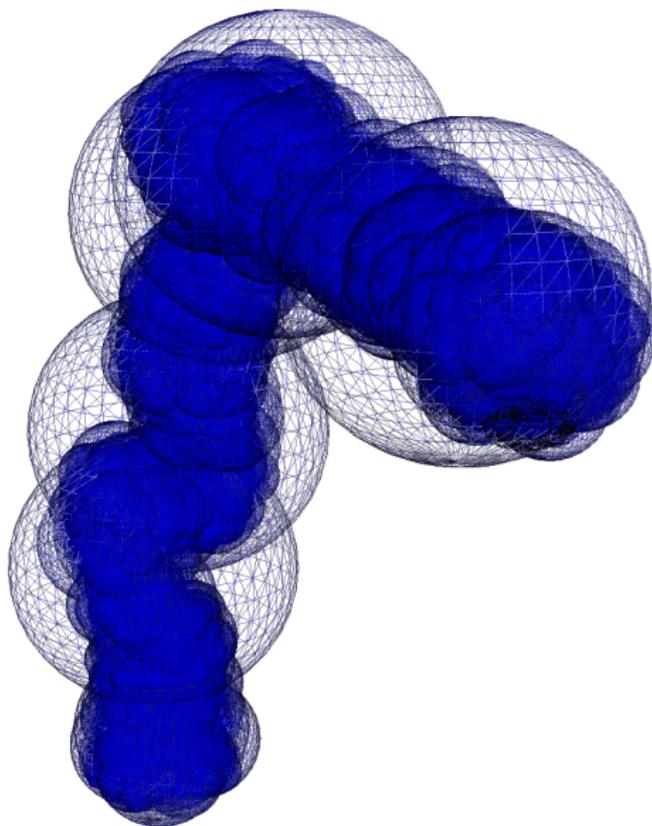
Der Roboter



Der Roboter



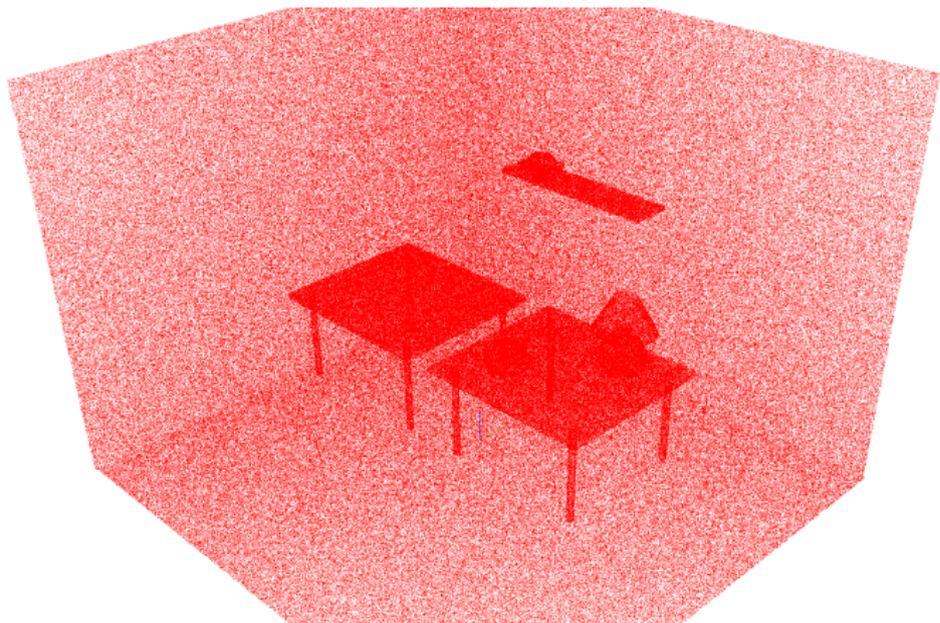
Der Roboter



Die Umgebung - Kinect Aufnahmen



Die Umgebung - von 3D-Mesh approximiert



Sequentieller Algorithmus

- ▶ Man iteriert über jeden Roboterteil und dann jeweils jeden Punkt aus der Punktwolke:
 - ▶ dabei macht man einen Abstandstest zwischen dem Punkt und dem Baum des Roboterteils
 - ▶ das Minimum aller Abstände ist unser kleinster Abstand

Algorithm 3.1: getMinDist(Set of ISTs R , point cloud P)

```
1: minDistance = maximum float
2: forall the ISTs  $r \in R$  do
3:   forall the Points  $p \in P$  do
4:     distance = traverseIST( Root sphere of  $r$ ,  $p$ , minDistance )
5:     if distance < minDistance then
6:       minDistance = distance
```

Sequentieller Algorithmus

Traversierung der ISTs

- ▶ Rekursive Definition
- ▶ normale BVH-Traversierung
 - ▶ Innere Knoten führen zu Rekursion wenn ein kleinerer Abstand möglich ist
 - ▶ bei Blättern wird der Abstand zurückgegeben

Algorithm 3.2: `traverseIST(Sphere s , point p , minDistance)`

```
1: if  $s$  is Leaf then  
2:   return  $d$   
3: forall the Children  $s_c$  of  $s$  do  
4:    $d = \text{distance}(s_c, p)$   
5:   if  $d < \text{minDistance}$  then  
6:     traverseIST(  $s_c, p, d$  )
```

Paralleler Algorithmus

- ▶ sehr ähnlich zum sequentiellen Algorithmus
- ▶ globale Variable für die untere Schranke
 - ▶ globale Variablen können von jedem Thread gelesen und beschrieben werden
 - ▶ wird idR vermieden, da der Zugriff extrem langsam ist

Algorithm 3.3: getMinDist(Set of ISTs R , point cloud P)

- 1: **global**MinDistance¹ = maximum float
 - 2: **In parallel forall the** *ISTs* $r \in R$ **do**
 - 3: **In parallel forall the** *Points* $p \in P$ **do**
 - 4: traverseIST(Root sphere of r , p)
-

Paralleler Algorithmus

Traversierung

- ▶ Race-Condition bei Blättern
 - ▶ gelöst durch atomic Integer Operator (float als int interpretieren)
 - ▶ Ordnung bleibt erhalten

Algorithm 3.4: `traverseIST(Sphere s , point p , distance d)`

```
1: if  $s$  is Leaf then  
2:   atomicMin(  $d$ , globalMinDistance )  
3: forall the Children  $s_c$  of  $s$  do  
4:    $d = \text{distance}( s_c, p )$   
5:   if  $d < \text{minGlobalDistance}$  then  
6:     traverseIST(  $s_c, p, d$  )
```

Implementierung

Rekursion

- ▶ Wird seit CUDA 3.1 unterstützt
- ▶ gilt im Allgemeinen als zu langsam, durch die zusätzliche Divergence
- ▶ Iterative Traversierung implementiert:

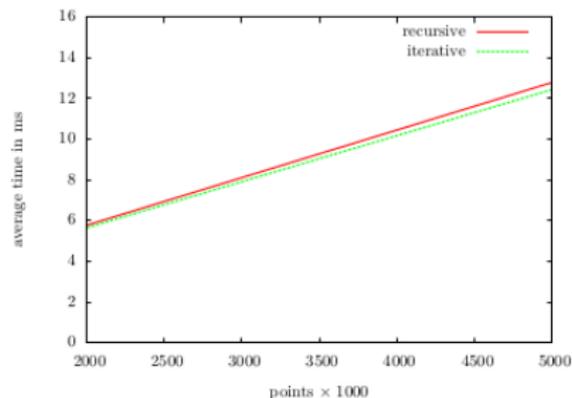
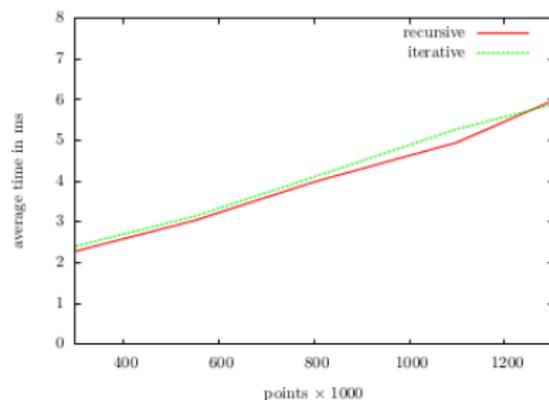
Algorithm 4.1: `traverseIST(Tree t, Point p)`

```
1: Stack stack
2: stack.push( root of t )
3: while stack not empty do
4:   Sphere s = stack.pop()
5:   forall the Children  $s_i$  of s do
6:     d = distance( s, p )
7:     if d < globalMinDistance then
8:       if si is leaf then
9:         atomicMin( d, globalMinDistance )
10:      else
11:        stack.push( si )
```

Implementierung - Rekursion

Ergenis

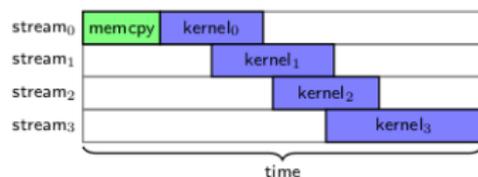
- ▶ keine Verbesserung!



Implementierung

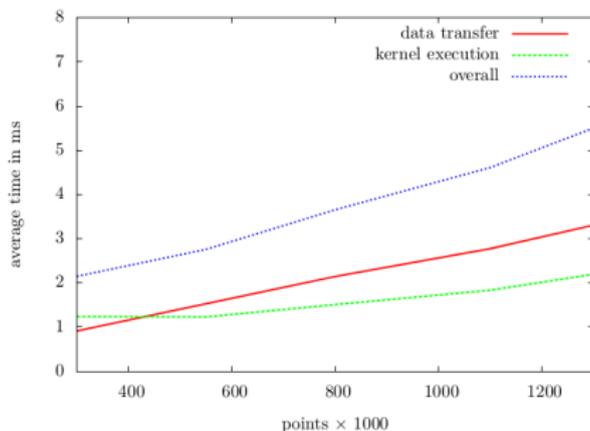
Streams

- ▶ Datenabhängigkeiten sind mit einem Stream nicht korrekt dargestellt
- ▶ jeder Kernel hängt nur von einem Datentransfer ab



Implementierung - Streams

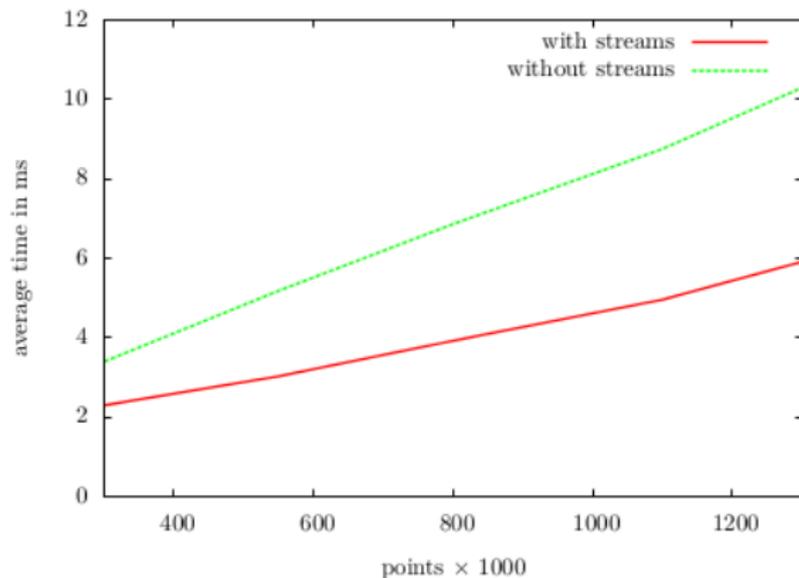
- ▶ Auch nützlich wenn Punktwolken für bestimmte Robotoerteile vorgefiltert wurden
 - ▶ zB durch einen Octree
- ▶ Grafikkarten können gleichzeitig Daten transferrieren und Instruktionen ausführen
 - ▶ gleichzeitig zu jedem Kernel wird der Transfer für den nächsten Kernel durchgeführt
- ▶ Bottleneck: Datentransfer



Implementierung - Streams

Ergebnis

- ▶ Speedup von fast 2



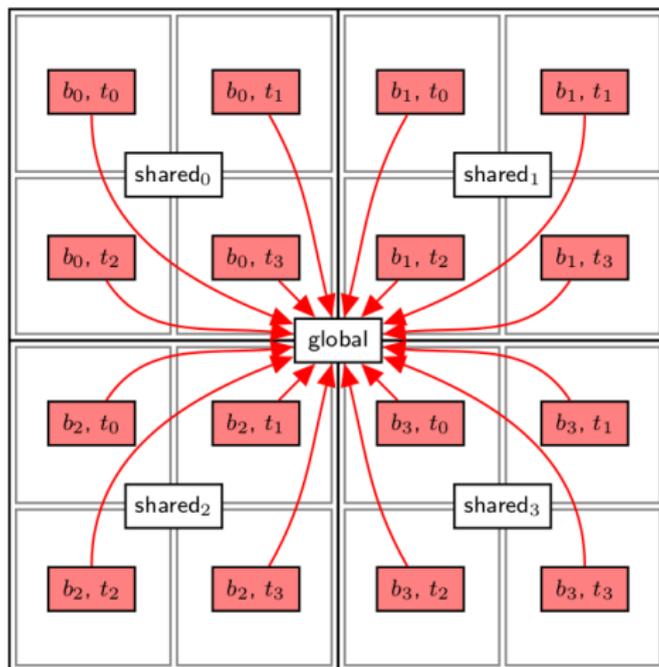
Implementierung

Shared Memory

- ▶ Idee: Keine globale Variable benutzen für die untere Schranke
 - ▶ Lesen und Schreiben extrem langsam bei globalem Speicher
- ▶ Shared Memory: Speicher den sich sog. Blöcke teilen
 - ▶ extrem schnell, praktisch kostenlos
 - ▶ ca. 100 mal schneller als globaler Speicher

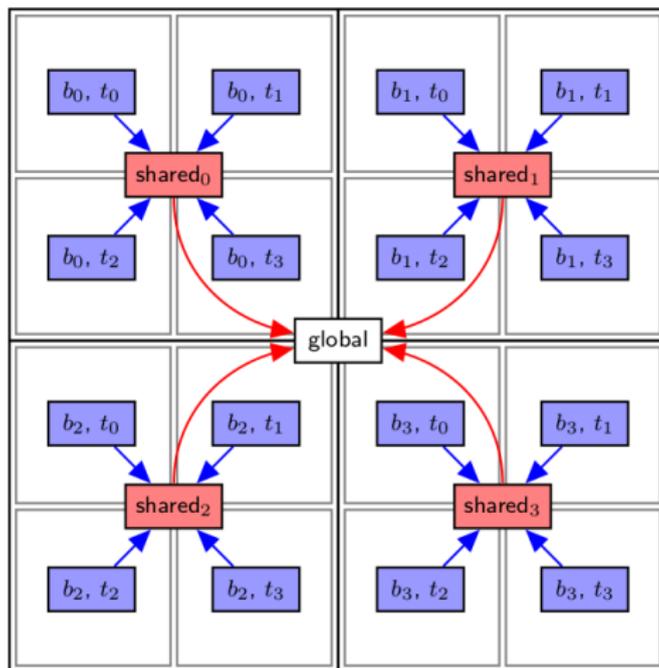
Implementierung - Shared Memory

Speicherzugriffe mit globalem Speicher



Implementierung - Shared Memory

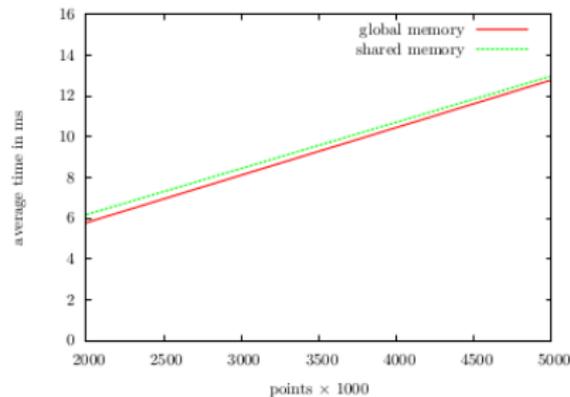
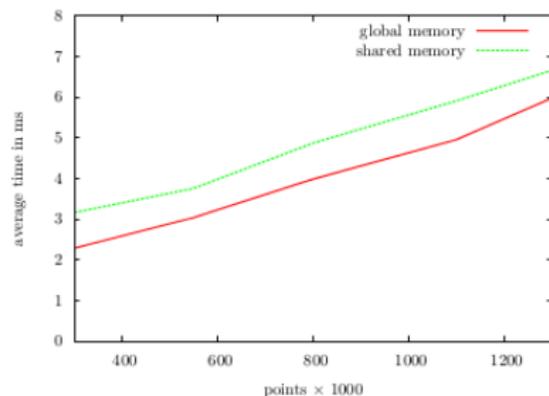
Speicherzugriffe mit Shared Memory



Implementierung - Shared Memory

Ergebnis

► Langsamer!

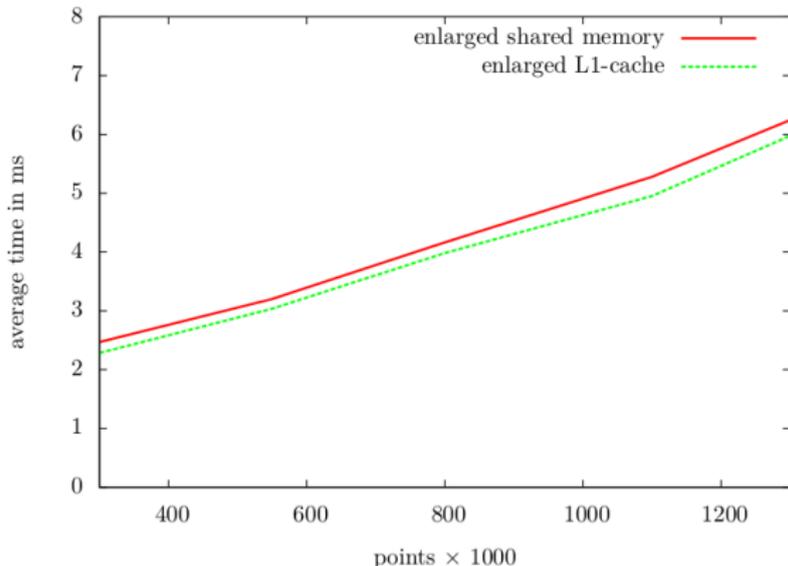


- Erklärung: Wahrscheinlich gibt es zu wenig Schreibzugriffe auf den untere Schranke, es lohnt sich mehr effektiver zu cullen
- möglicherweise Vorteilhaft wenn man die ISTs anders aufbaut
 - weniger inner Knoten, größerer Verzweigungsgrad

Implementierung

Cache

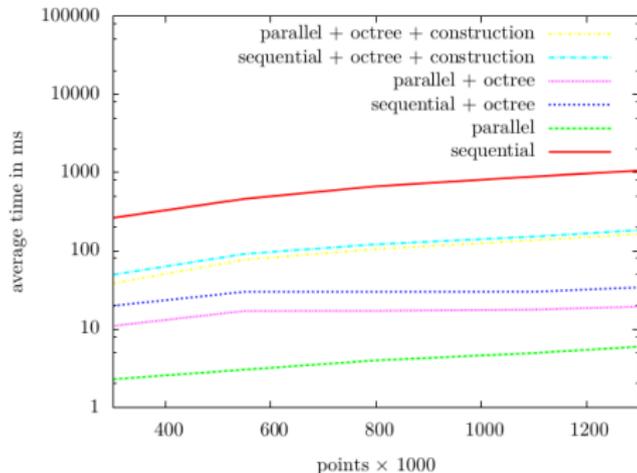
- ▶ Shared Memory wird für allgemeinen Cache verwendet
 - ▶ verschnellert manche Lesezugriffe auf globale untere Schranke



Results

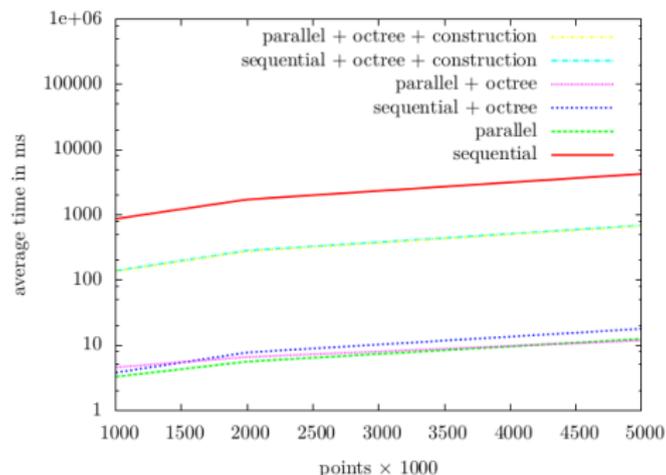
Allgemeine Messungen

- ▶ Bei Punktwolken die durch Kinect aufgenommen wurden:



Results - Allgemeine Messungen

- ▶ Bei künstlichen Punktwolken die an ein 3D-Mesh angenähert wurden:



Conclusion

- ▶ Paralleler Algorithmus ist in günstigen Fällen um eine Größenordnung schneller
 - ▶ noch mehr wenn man den Aufbau von BVHs einberechnet
- ▶ Zeiten sind Realtime fähig
- ▶ benutzt keine Preprocessing
 - ▶ wie zB den Aufbau eines Octrees
- ▶ einfach zu implementieren

Future Work

- ▶ für Haptisches Feedback müssen Anfragen in 1ms bearbeitet werden
- ▶ Mögliche Verbesserung: angepasste BVH für Punktwolken
 - ▶ BVH kann grob filtern, da viele Punkte verzeihbar sind
 - ▶ dafür müssten Anfragen und Aufbau extrem schnell sein
 - ▶ Auf der GPU, damit der Bottleneck Datentransfer nur einmal auftritt