Algorithmen im Chip-Entwurf 10

Verbesserungen

Andreas Koch
FG Eingebettete Systeme
und ihre Anwendungen
TU Darmstadt

Übersicht

- Verbesserung der Platzierung
- Vorschläge
  - Verdrahtungsorientierte Platzierung
  - Parallele Platzierung
- Brainstorming

Verbesserungen

- **Basisfunktionen**
  - Platzierung
  - Verdrahtung

- **Vorschläge zur Verbesserung**
  - Bessere Ergebnisse
    - Weniger Tracks
    - Weniger Verzögerung
  - Schnellere Laufzeiten
    - Um welchen Preis?

Verdrahtungsorientierung

- **Während der Platzierung**
- **Bisher nur sehr einfach**
  - **Gesamtverdrahtungslänge**
- **Nicht berücksichtigt**
  - **Örtliche Verdrahtungsdichte**
  - **Schnitt-basierte Verdrahtungsdichte**

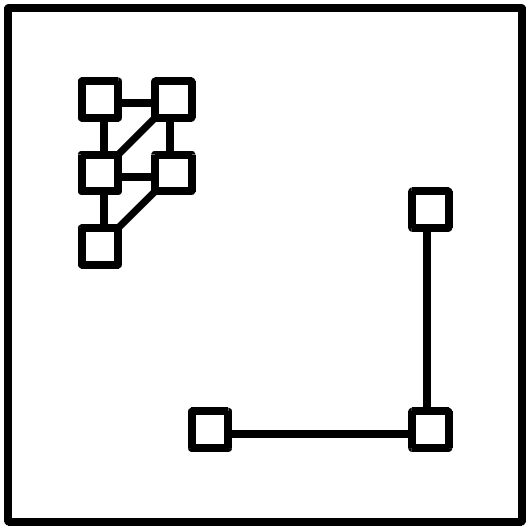

Örtlich

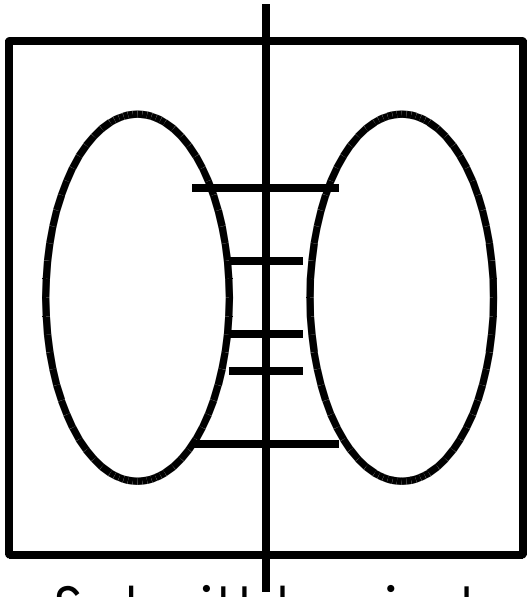

Schnitt-basiert

Örtliche Verdrahtungsdichte

- Abschätzungen
- Über Netzdichten
  - Flächenorientiert
  - Ansatz von RISA
    - Cheng: ICCAD 1994
- Statistische Modelle
  - Pfadorientiert
  - Ansatz von fGREP und fGREP2
    - Bhatia: FPL 2001, DAC 2002

Berechnung von Netzdichten

- **Idee: Netzlänge pro Ressource**
  - **Abschätzung Netzlänge L(n)**
    - **Anzahl Terminals**
    - **Korrekturfaktor *q***
  - **Fläche ist bekannt**
    - **Netzumspannendes Rechteck BB**
    - **Daraus Anzahl Verdrahtungsressourcen bestimmen**
      - **R(BB(n)) = Anzahl Metallsegmente in Fläche BB(n)**

- **Annahme**
  - **Netzlänge verteilt sich homogen auf Verdrahtungsressourcen**

$$\mathrm{d}(n) = \frac{\mathrm{L}(n)}{\mathrm{R}(\mathrm{BB}(n))}$$

Berechnung von Netzdichten

- **Vorgehen**
  - Berechne d(*n*) für alle Netze *n*
    - Anhand aktueller Platzierung (z.B. je SA Schritt/e)
  - Berechne örtliche Dichte für CLB c_{ij}
    - Summiere d(*n*) für alle Netze *n* mit (*i*,*j*) in BB(*n*)

- **Optimierungsziel**
  - Zusätzlich zu Verzögerung und Gesamtlänge
  - Minimiere örtliche Dichte
    - Präziser: Überschreitung der vorhandenen Tracks
      - Theoretisch: d(*n*) > 1
    - Aber: Abschätzung sehr ungenau
    - Korrekturfaktor durch Analyse realer Verdrahtungen
      - Vergleich mit Abschätzungen
      - qi.txt

Beispiel

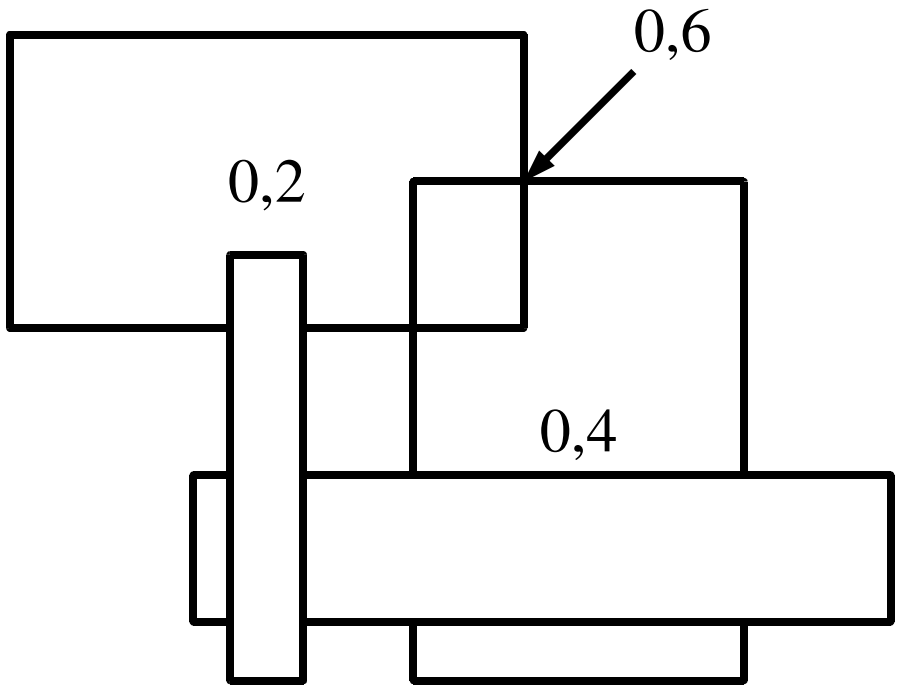

- **Aufsummieren der Netzdichten**
  - **Je Block**
  - **Verfeinerung**
    - **Getrennt nach H und V Segmenten**
      - **Vorzugsrichtung des Netzes**

Statistische Modellierung

- **Pfadwahrscheinlichkeiten**
  - Nicht mehr flächenorientiert
  - Berücksichtigen pro Netz *n*
    - Anzahl der Terminals
    - Lage der Terminals in BB(*n*)
- **Genauer als flächenorientierter Ansatz**
  - 3,8% Fehler statt 34% (RISA, ICCAD 1994)
- **Aber langsamer**
  - Praktisch ca. 660x
    - Bhatia, FPL 2001
  - Verbesserbar bis auf 37x langsamer
    - Bhatia, DAC 2002
- **Beide Papers auf Web-Site**

Ideen

- **Bei wachsender Entfernung vom Ursprung**
  - **Mehr Möglichkeiten der Pfadführung**
- **Benutzungswahrscheinlichkeit für gegebene Verdrahtungsressource (VR)**
  - **Umgekehrt proportional zu Möglichkeiten**
- **Bei mehreren Ursprüngen**
  - **Nahegelegenster bestimmt die Nachfrage**

Modellierung

- **Von Terminal *t* equidistante VR *r* der Distanz *q***

$$\mathrm{LS}(t,q)=\{r\in R\,|\,dist(t,r)=q\}$$

- **Terminalnachfrage von *t* nach VR *r***

$$\mathrm{TD}(t,r)=\frac{1}{|LS(t,\mathrm{dist}(t,r))|}$$

- **Netznachfrage von *n* nach VR *r***

$$\mathrm{ND}(n,r)=max\ \mathrm{TD}(t,r),\ t\in\{u\in n\,|\,\mathrm{dist}(u,r)=\min_{v\in n}\mathrm{dist}(v,r)\}$$

- **Gesamtnachfrage nach VR *r***

$$\mathrm{D}(r)=\sum_{n\in N}\mathrm{ND}(n,r)$$

Beispiel 1

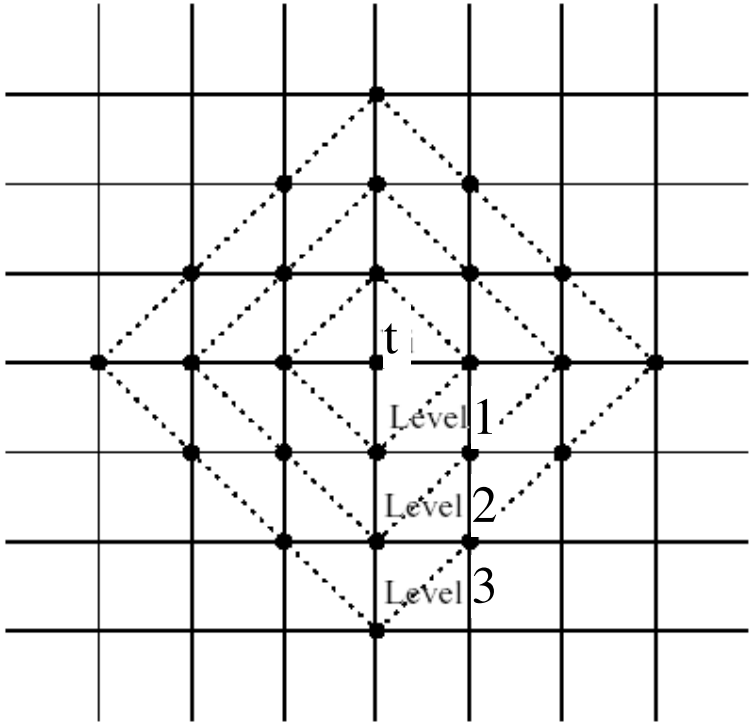

Level-Set LS(t,*q*) für
q=0,1,2,3

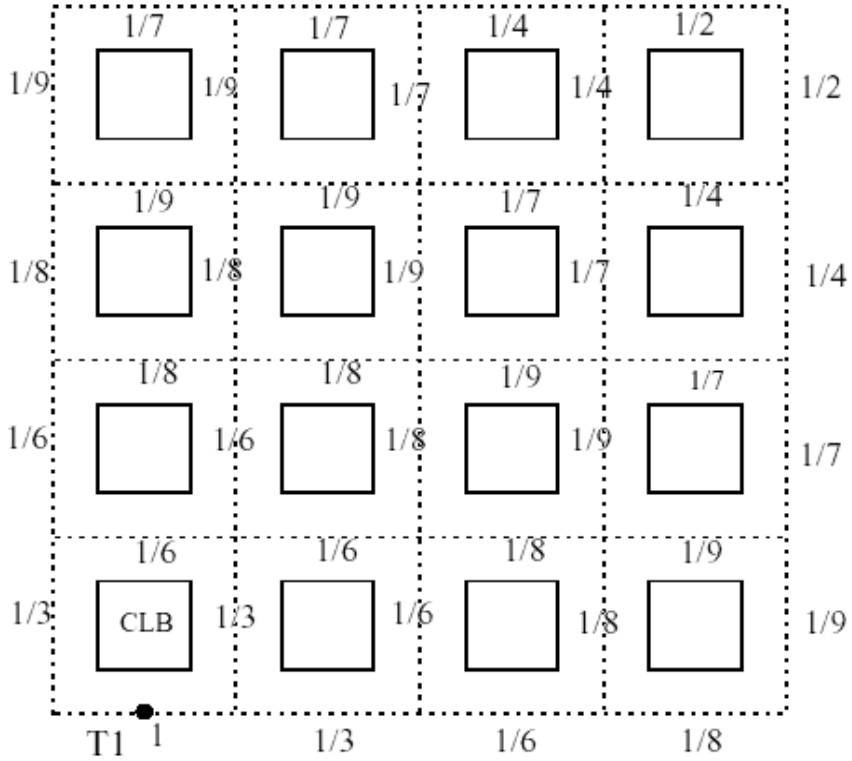

Terminalnachfrage TD(T1, *r*)
für alle *r* in BB(*n*)

Beispiel 2

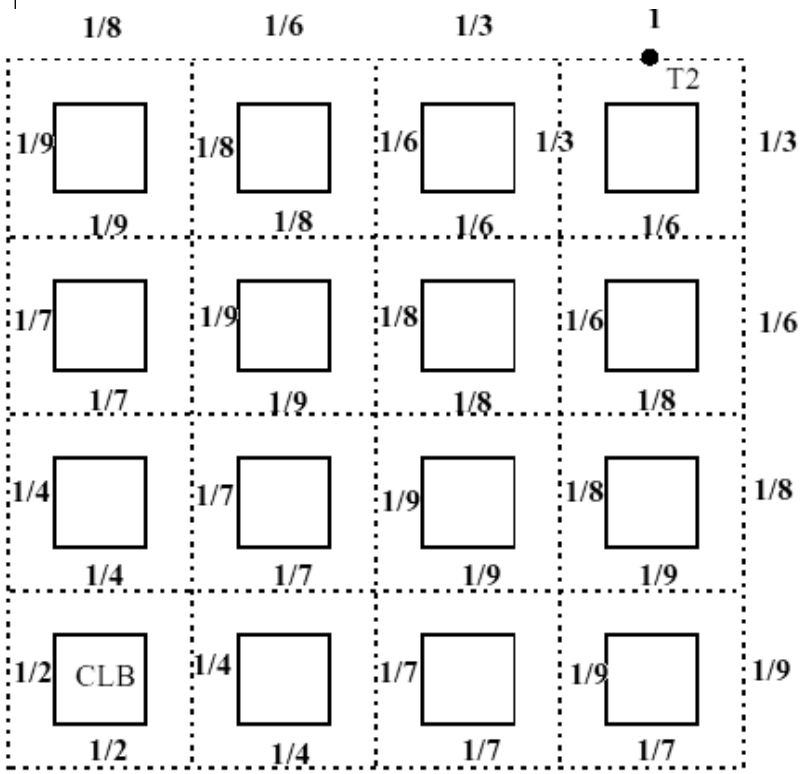

Terminalnachfrage TD(T2, *r*)
für alle *r* in BB(*n*)

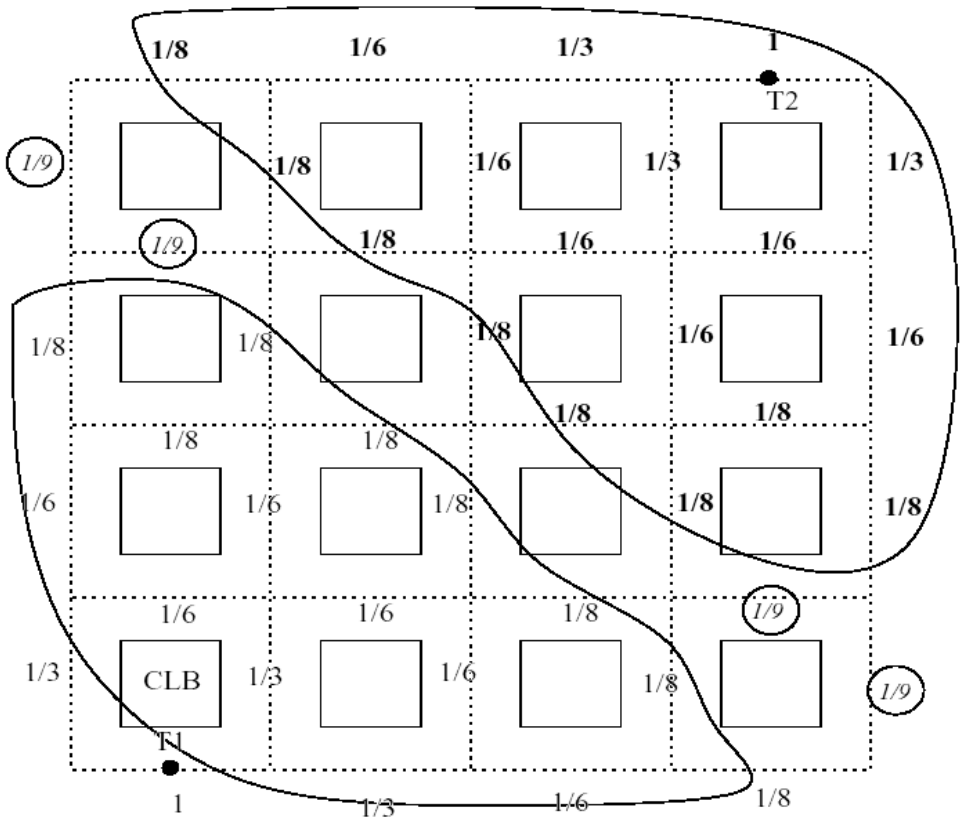

Netznachfrage ND(n, r)
für alle *r* in BB(*n*)
mit *n* = {T1, T2}

Vorgehen

- **Gesamtnachfrage berechnen**
  - Aufsummieren über alle Netze
- **Algorithmus**
  - Breitensuche ausgehend von Terminal
    - Bis alle *r* in BB(*n*) besucht
  - Komplexität O(|n| |R|)
- **Laufzeit**
  - 5-20x schneller als VPR Router (für geg. W_h, W_v)
- **Verbesserung** (DAC 2002)
  - Einflusszonen um Terminal herum
    - Nachfrage wird nur durch ein Terminal bestimmt
    - Ausnutzen: Nachfrage nach jedem *r* nur 1x berechnen
      - Nicht mehr 1x pro Netz
    - Komplexität dann nur noch O(|R|)

Beispiel Verbesserung

Voronoi-
Regionen

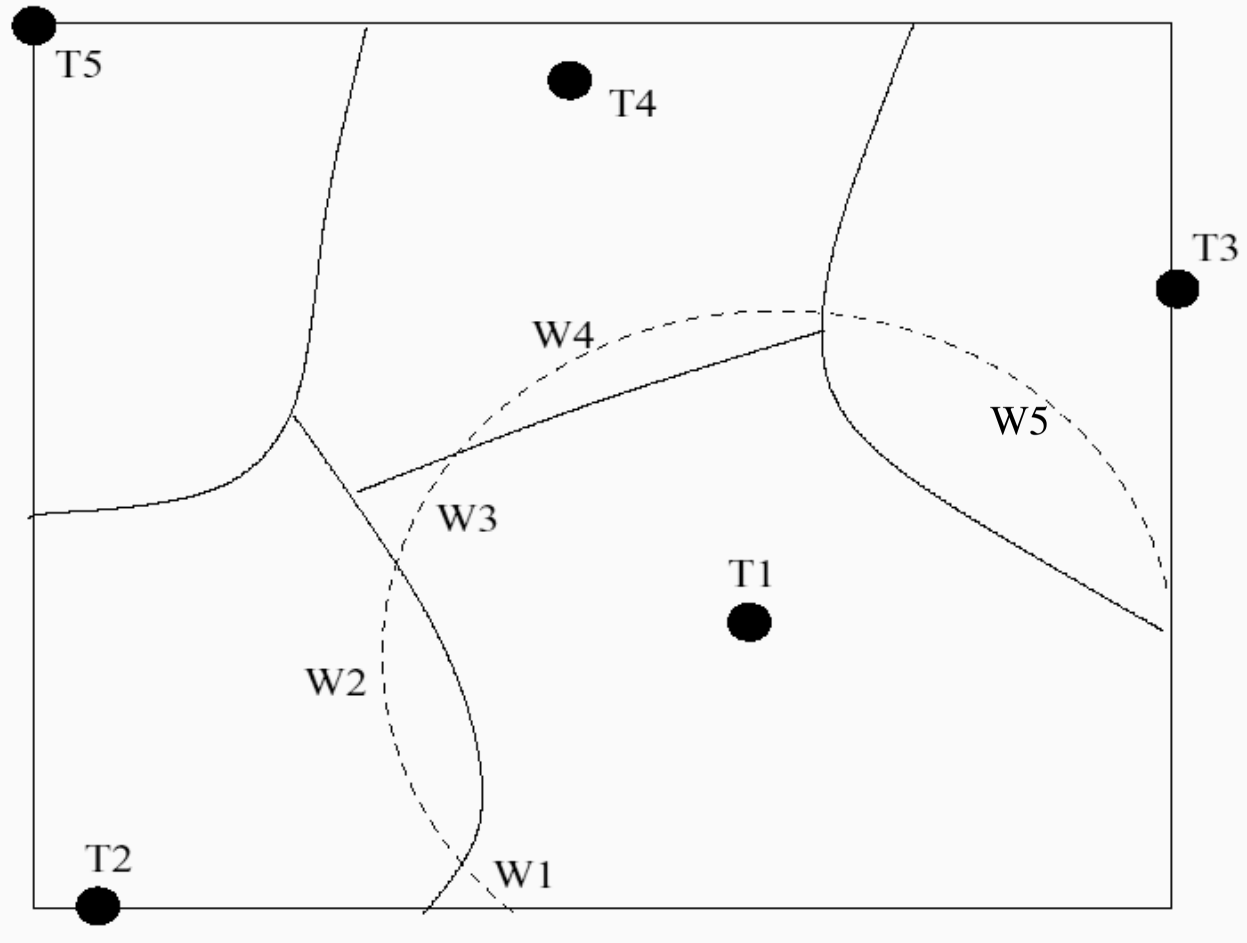

Einflusszonen um Terminals T_1 ... T_5

Fragmentierung der Wellenfront in W_1 ... W_4

Vorgehen

- **Parallele BFS von allen Terminals *t* in *n***
  - **Erreichen einer Zonengrenze**
    - **Zwei Wellenfronten treffen aufeinander**
- **Problem**
  - **Andere Teile der Wellenfront sind noch in Zone**
  - **Nicht einfach aufhören**
    - **LS(*t*, *q*) wäre falsch (zu klein!)**
      - $|W_1|+|W_3|$ **statt** $|W_1|+|W_2|+|W_3|+|W_4|+|W_5|$
- **Lösung**
  - **Wellenfront W von *t* aus weiter ausbreiten**
    - **Solange auch nur ein *r* aus *W* in der Zone von *t* liegt**
    - **Aber keine Dichten eintragen, nur LS(t,q) korrekt aufbauen**
- **Resultat**
  - **Gleiche Ergebnisse, 17x schneller**

Schnittdichten

- Einfachere Idee, aber ungenauer
- Chip in mehrere Regionen aufteilen
  - 4x4, 16x16
- Je Schnittsegment
  - Horizontal und vertikal
  - Anzahl der kreuzenden Leitungen berechnen
  - Falls grösser als Anzahl Tracks
    - In Kostenfunktion bestrafen

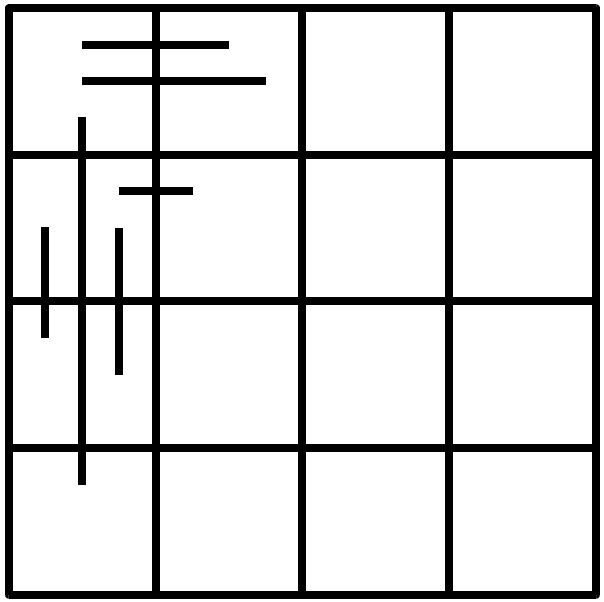

Parallele Platzierung

- Ziel ist kürzere Programmlaufzeit
- Vorgehen
  - Aufteilung des Platzierungsproblems
  - Verteilen auf N CPUs/Rechner
  - Lösen der Teilprobleme
  - Zusammenfügen zur Gesamtlösung
- Im Idealfall
  - Beschleunigung um Faktor N
  - Praktisch aber nicht:
    - Aufteilen: auf einer CPU
    - Kommunikation: Zusätzlicher Overhead
    - Zusammenfügen: I.d.R. auf einer CPU
      - Auch hierarchisches Vorgehen möglich

Aufteilung

- **Einfache Lösung**
  - Partitionierung mittels Min-Cut
  - Problem aufteilen
    - In möglichst unabhängige Unterprobleme
- **In heterogenen Systemumgebungen**
  - Partitionsgrösse an Rechenleistung anpassen
- **Selbst bei Aufteilung**
  - Kontextinformationen bestimmen
    - Relativ einfach: Topologie
    - Komplizierter: Delay
      - Verteilte Abschätzung oder zentrale Criticality-Berechnung
    - Über Partitionsgrenzen verteilen
- **Aber: Aufteilung vermindert Qualität**
  - Prinzip der Optimalität gilt nicht!

Implementierung

- **Einlesen der Eingabedaten**
  - Aufteilen
  - Bestimmen von Kontextdaten
- **Verteilen auf Rechenknoten**
  - Dort ständig laufende Server-Prozesse
  - Nehmen Anfragen via Java RMI entgegen
    - Teilproblem und Kontextdaten
  - Berechnung mit üblichem Algorithmus
  - Ggf.: Zentrale Berechnung der Criticality
    - Kommunikation mit Master-Knoten
- **Zusammenfügen der Teilergebnisse**
  - Übertragen auf Master-Knoten
- **Schreiben der Ausgabedaten**

Zusammenfassung

- Verbesserungen des P&R-Flusses
- Qualität
  - Verdrahtungsorientierte Platzierung
- Rechenzeit
  - Parallele Platzierung