

Algorithmen im Chip-Entwurf 5

Reale Algorithmen zur Partitionierung, Timing-Analyse und Platzierung

Andreas Koch
FG Eingegebettete Systeme
und ihre Anwendungen
TU Darmstadt

Reale Algorithmen

Timing-Analyse

- **Kritischer Pfad**
 - Einfach (slack=0)
 - Nächstkritischerer Pfad?
- **Vorgehensweisen**
 - Alle Pfade berechnen
 - ◆ Rechenzeit- und Speicherbedarf
 - k längste Pfade en Block berechnen
 - ◆ Wenig flexibel: k bei Start der Berechnung fest
 - Pfade inkrementell berechnen
 - ◆ Flexibel: Rechen- und Speicheraufwand reduziert
- **Idee**
 - Timing-Graph annotieren
 - Pfade aufzählen (enumerate)

Reale Algorithmen

Übersicht

- **Timing-Analyse**
 - Mehrere kritische Pfade
- **Platzierung**
 - Annealing Mechanismus
 - Kostenfunktion
- **Optional: Kernighan-Lin**
 - Partitionierung via MinCut
- **Zusammenfassung**

Reale Algorithmen

Verfahren nach Ju und Saleh

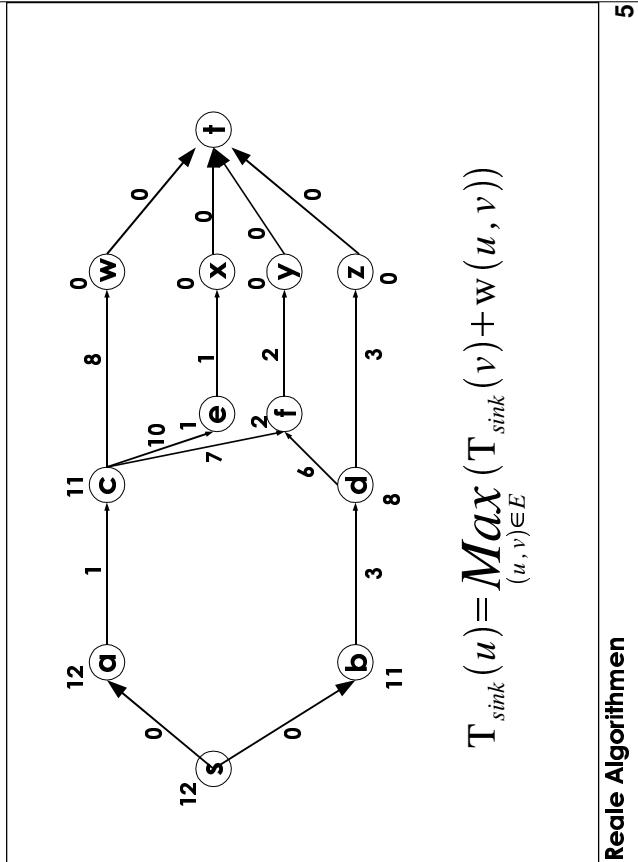
- **Design Automation Conference 1991**
 - Paper auf Web-Seite
 - Details in Abschnitt 3
- **Graphannotation**
 - Längste Verzögerung bestimmen
 - Aber auch an jeder Abzweigung merken
 - ◆ Wieviel schneller würde die Alternative sein?
- **Pfadaufzählung**
 - Beginne mit längstem Pfad
 - Wähle minimal schnellere Abzweigung
 - Erzeuge von dort ausgehend längsten Pfad
- **Vorteil**
 - Erzeugung beliebig vieler/weniger Pfade
 - ◆ Exakt an Anforderungen anpassbar

Reale Algorithmen

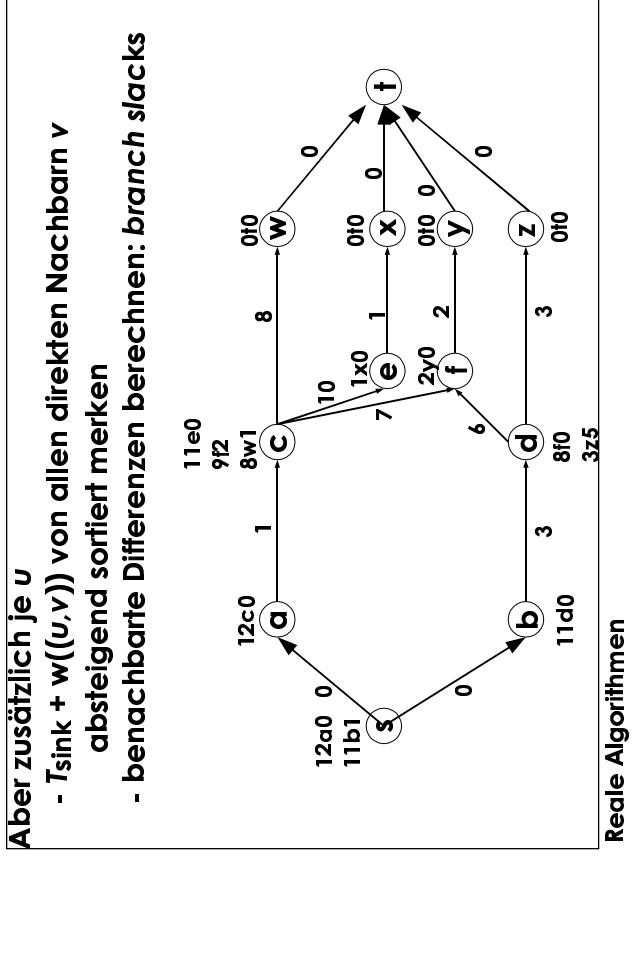
3

4

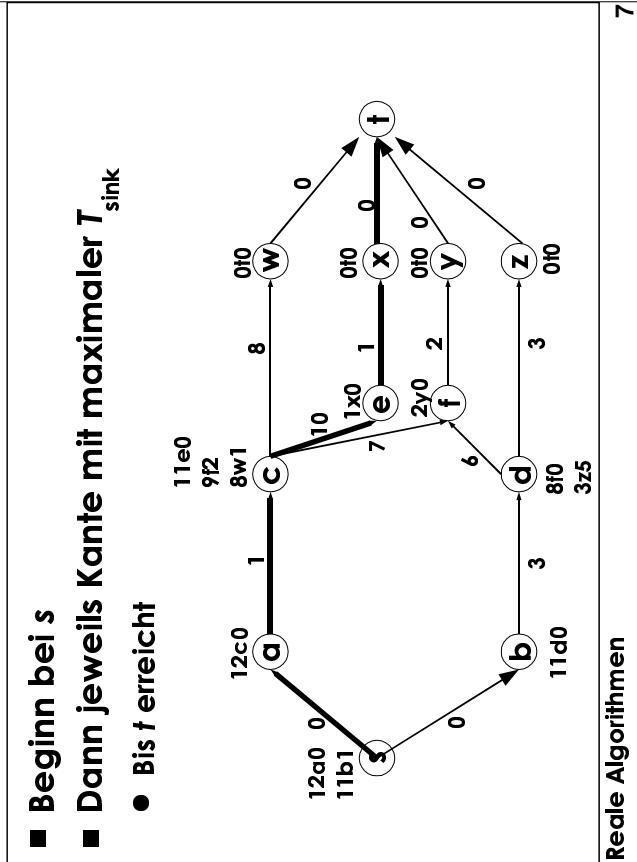
Annotation des Timing-Graphen



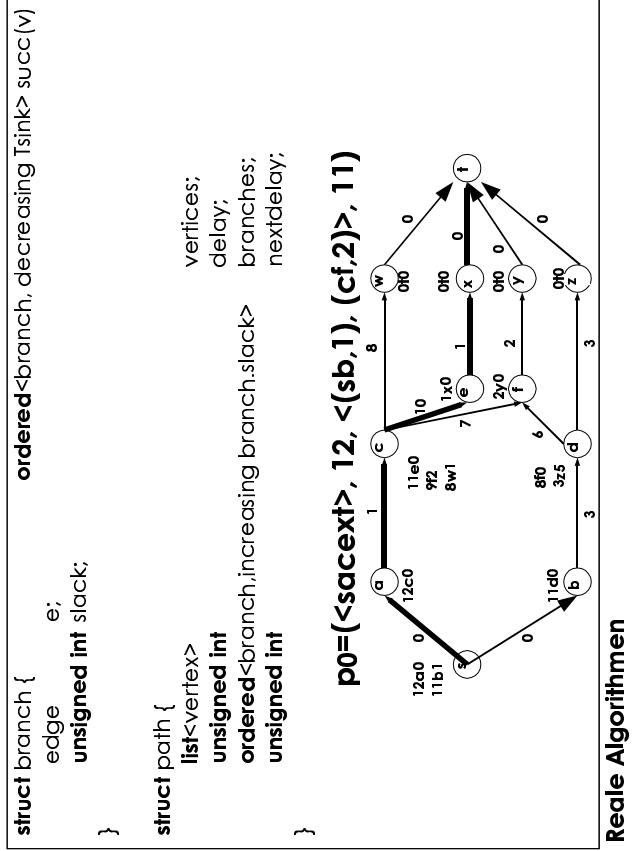
Erweiterung



Längster Pfad



Datenstruktur



Vorgehen 1

- **longest_path(list<vertex> head)**
 - Verlängert head zu längstmöglichem Pfad
 - ◆ Wählt dazu jeweils Nachbar mit max. Tsink
 - Merkt sich Nachbarn mit nächstkleinerer Tsink
 - ◆ Also: Den mit kleinstem branch slack
 - Berechnet aktuelles und nächstkleineres Delay
 - **branch_path(path p)**
 - Zweigt an Stelle v mit min. branch slack von p ab
 - Markiert Abzweigung in p als „genommen“
 - ◆ Berechne nächstkleineres Delay von p neu
 - Berechnet nun longest_path(p.vertices+<v>)

Reale Algorithmen

9

Vorgehen 2

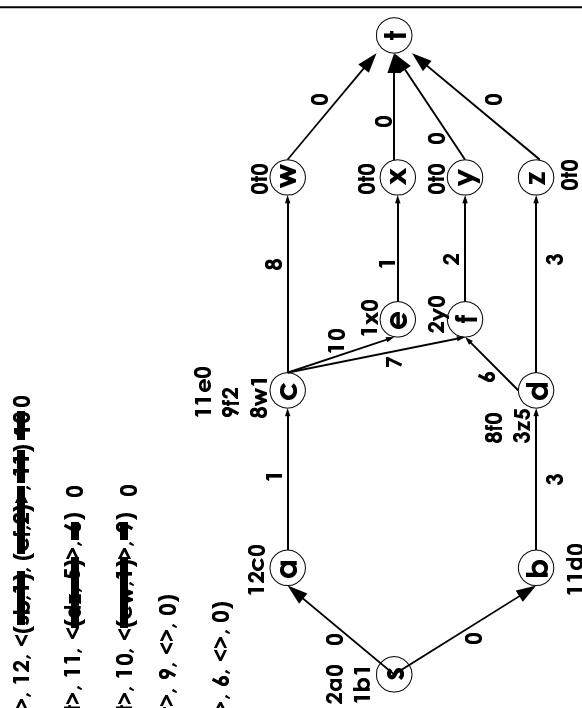
- **Kernalgorithmus**
 - Annotiere Graph mit Tsink und branch stacks
 - Berechne längsten Pfad $p_0 = \text{longest_path}(<s>)$
 - Merkt sich p_0 in P
 - Wiederholt, bis genug Pfade oder Delay=0:
 - ◆ Finde p' aus P mit nächstkleinerem Delay = Max > 0
 - ◆ Generiere neuen Pfad $p' = \text{branch_path}(p)$
 - Verwende langsamste Abzweigung (min. branch slack)
 - Nimm p' in P auf
 - **P enthält danach die gesuchten Pfade**

Reale Algorithmen

10

Beispiel

```
p0 = (<scext>, 12, <sbdfyt>, 11, <scdfyt>, 10, <scdfyt>, 9, <scdfyt>, 8, <scdfyt>, 7, <scdfyt>, 6, <scdfyt>, 5, <scdfyt>, 4, <scdfyt>, 3, <scdfyt>, 2, <scdfyt>, 1, <scdfyt>, 0)
p1 = (<|sbdft>, 11, <|scdfyt>, 10, <|scdfyt>, 9, <|scdfyt>, 8, <|scdfyt>, 7, <|scdfyt>, 6, <|scdfyt>, 5, <|scdfyt>, 4, <|scdfyt>, 3, <|scdfyt>, 2, <|scdfyt>, 1, <|scdfyt>, 0)
p2 = (<sa|cfty>, 10, <sa|cfty>, 9, <sa|cfty>, 8, <sa|cfty>, 7, <sa|cfty>, 6, <sa|cfty>, 5, <sa|cfty>, 4, <sa|cfty>, 3, <sa|cfty>, 2, <sa|cfty>, 1, <sa|cfty>, 0)
p3 = (<sa|cwt>, 9, <>, 0)
p4 = (<sb|dzt>, 6, <>, 0)
p5 = (<sa|cwt>, 8, <>, 0)
p6 = (<sa|cwt>, 7, <>, 0)
p7 = (<sa|cwt>, 6, <>, 0)
p8 = (<sa|cwt>, 5, <>, 0)
p9 = (<sa|cwt>, 4, <>, 0)
p10 = (<sa|cwt>, 3, <>, 0)
p11 = (<sa|cwt>, 2, <>, 0)
p12 = (<sa|cwt>, 1, <>, 0)
p13 = (<sa|cwt>, 0, <>, 0)
```



Reale Algorithmen

11

VPR

- **Versatile Place and Route**
 - Betz und Marquardt, U Toronto
- **Platzierer**
 - Simulated Annealing-basiert
 - ◆ Adaptive Annealing Schedule
 - Optimiert gleichzeitig
 - ◆ Leitungslänge
 - ◆ Verzögerung

Reale Algorithmen

12

Züge

- **Paarweises Austauschen von Blöcken**
 - N_{blocks} = Größe der Schaltung
 - **Aber nicht ganz wahllos**
 - Beschränkung der Entfernung

Reale Algorithmen 13

Starttemperatur

- **Wird automatisch bestimmt**
 - Für aktuelle Schaltung passend
 - **Idee:**
 - Anfangs fast alle Züge akzeptieren
 - Wie hoch muss die Starttemperatur sein?
- **Vorgehen**
 - N_{blocks} paarweise Austausche
 - Beobachte Änderung der Kostenfunktion x
 - ◆ Standardabweichung
- Starttemperatur = $20 \times s_x$

Reale Algorithmen 14

Thermal Equilibrium

- **Anzahl von Schritten pro Temperaturstufe:**

$$10 N_{blocks}^{4/3}$$

- **10x schneller, aber ca. 10% schlechter:**

$$N_{blocks}^{4/3}$$

Reale Algorithmen 15

Abkühlen 1

- **Beobachtung**
 - Anfangs: T hoch, fast alle Züge akzeptiert
 - ◆ Im wesentlichen zufälliges Bewegen
 - ◆ Keine echte Verbesserung der Kostenfunktion
 - Ende: T niedrig, kaum Züge akzeptiert
 - ◆ Fast keine Bewegung mehr
 - ◆ Wenig Veränderung in Kostenfunktion
- **Idee**
 - Meiste Optimierung passiert dazwischen
 - Bringe T schnell in den produktiven Bereich
 - Halte T lange im produktiven Bereich
- **Vorgehen**
 - Steuere T anhand der Akzeptanzrate

Reale Algorithmen 16

Abkühlen 2

α	Acceptance Rate R_a
0.50	$R_a > 0.96$
0.90	$0.80 < R_a \leq 0.96$
0.95	$0.15 < R_a \leq 0.80$
0.80	$R_a \leq 0.15$

Reale Algorithmen 17

Abkühlen 3

Vorahnung
• Gute Fortschritte bei $R_a \approx 0.5$
Am effizientesten $R_a = 0.44$
• Beste Fortschritte
Idee
• R_a möglichst auf diesem Wert halten
• Nicht temperaturbasiert (kühl nur ab!)
• Sondern: Auswirkungen der Züge beeinflussen
• Beobachtung
◆ Weite Züge: Große Änderung der Kostenfunktion
◆ Kurze Züge: Kleine Änderung der Kostenfunktion
Vorgehen
• Variiere Zugweite D_{limit} , um $R_a \approx 0.44$ zu halten

Reale Algorithmen 18

Abkühlen 4

D_{limit} klein
• Kleine Zugreichweite
• Kleine Änderungen der Kostenfunktion
• Kleine Verschlechterungen
◆ Werden eher angenommen
• R_a steigt
D_{limit} gross
• Grosse Zugreichweite
• Grosse Änderungen der Kostenfunktion
• Große Verschlechterungen
◆ Werden eher abgelehnt
• R_a sinkt

Reale Algorithmen 19

Abkühlen 5

Anfangs: $D_{\text{limit}} = ganzer Chip L_{\text{Chip}}$
Bei jedem Abkühlsschritt:
$D_{\text{limit}}^{new} = D_{\text{limit}}^{old} (1 + R_a^{old} - 0.44)$, $1 \leq D_{\text{limit}}^{new} \leq L_{\text{Chip}}$
Zuviel akzeptiert: D_{limit} grösser machen
• Zuwenig akzeptiert: D_{limit} kleiner machen

Reale Algorithmen 20

Abbruchbedingung

- Wann Abkühlung beenden?
- Idee
 - Erkennung von Stillstand
- Vorgehen
 - Jeder Zug beeinflusst mindestens ein Netz
 - Bestimme die durchschnittlichen Kosten pro Netz
 - Wenn T kleiner als Bruchteil davon ...
 - ◆ Nur noch kleine Chance, dass Zug akzeptiert wird
 - ◆ $T < 0.005 \text{ Cost}/\#\text{Nets}$

Reale Algorithmen 21

Kostenfunktion

- Gleichzeitig optimieren
 - Zeitverhalten
 - Verdrahtungslänge
- Verdrahtungslänge
 - Bestimmt als korrigierter halber Netzumfang

$$C_w = \sum_{n \in N} q(n_{pincount}) [bb_x(n) + bb_y(n)]$$

- $q(i) = 1$ für $i=1..3$, $=2.79$ für $i=50$ (Cheng 1994)
- Web-Seite: Paper, Datei mit Korrektur faktoren $q(i)$

Reale Algorithmen 22

Inkrementelle Berechnung 1

- Berechnung des Netzumfangs
 - Simpel: $O(k)$, K Anzahl der Pins
 - Problem: $k = 100 \dots 1000$ realistisch
 - Nach jedem Zug neu berechnen
- Besser:
 - Nach Möglichkeit nur bewegte Pins neu berechnen
 - ◆ Ein Pin ist nur in einem Netz
 - ◆ Ein Block hat aber mehrere Pins
 - Vorgehen
 - Je Netz umspannendes Rechteck speichern
 - ◆ $(x_{min}, x_{max}, y_{min}, y_{max})$
 - Position der Seiten
 - ◆ $(N_{x_{min}}, N_{x_{max}}, N_{y_{min}}, N_{y_{max}})$
 - Anzahl Pins direkt auf den Seiten

Reale Algorithmen 23

Inkrementelle Berechnung 2

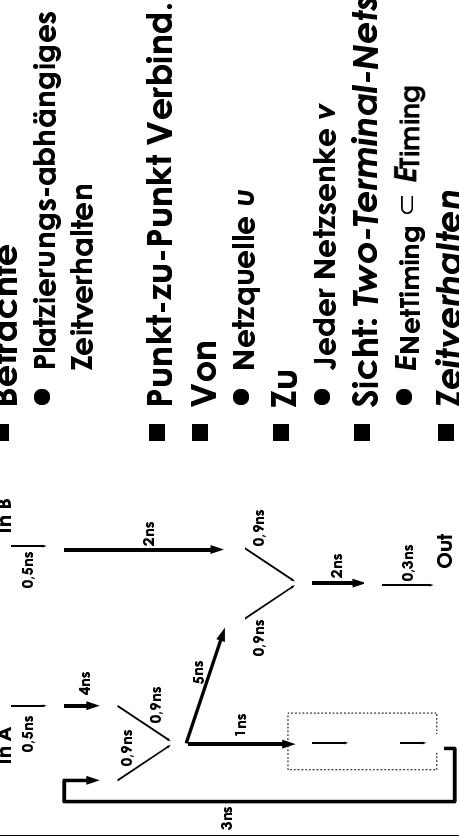
```
Betrachtet nur linke Seite (xmin)
- Bewege Terminal von xold nach xnew
- Netz an Terminal: n

if (xnew != xold) { // horiz. bewegt
    if (xnew < n.xmin) {
        n.xmin = xnew;
        n.Nxmin = 1;
    } else if (xnew == n.xmin) {
        n.Nxmin++;
    } else if (xold == n.xmin) {
        if (n.Nxmin > 1) {
            n.Nxmin--;
        } else {
            n.Nxmin++;
        }
    }
}
(1,1)

xmin=2
xmax=7
ymin=3
ymax=7
BruteForce(n);
}
```

Reale Algorithmen 24

Zeitverhalten 1



Reale Algorithmen 25

Zeitverhalten 2

- „Wichtigkeit“ einer Verbindung
 - Punkt-zu-Punkt zwischen Terminals u und v
- $$\text{Criticality}(u, v) = 1 - \frac{\text{slack}(u, v)}{D_{\max}}$$
- (u,v) auf kritischem Pfad
 - ◆ slack(u,v) = 0 \Leftrightarrow Criticality(u,v) = 1
 - (u,v) absolut unkritisch
 - ◆ slack(u,v) = D_{\max} \Leftrightarrow Criticality(u,v) = 0

- Timing Cost: Delay(u,v) ist Schätzung!
 - Noch kein „echtes“ Routing

$$c_i = \sum_{(u, v) \in E_{NetTiming}} \text{Delay}(u, v) \text{Criticality}(u, v)^{\text{CriticalityExponent}}$$

Reale Algorithmen 26

Zeitverhalten 3

- Criticality Exponent
 - Gewichtet kritischere Verbindungen höher
 - ◆ Wenige kritische Verbindungen dominieren c_i
 - Untergewichtet unkritischere Verbindungen
 - ◆ Fallen fast ganz aus c_i Berechnung heraus
- Idee
 - Gegen Ende auf kritische Netze konzentrieren
- Vorgehen:
 - Steigern von $ce_{start} = 1$ auf $ce_{final} = 8$ (experimentell)

$$\text{CritExp} = \left| 1 - \frac{R_{limit}^{now} - 1}{R_{limit}^{start} - 1} \right| \cdot (ce_{final} - ce_{start}) + ce_{start}$$

Reale Algorithmen

27

Zeitverhalten 4

- slack() ist platzierungsabhängig
 - Unkritische Netze können kritisch werden
 - ◆ Zu lange Leitungslängen
 - Kritische Netze können unkritisch werden
 - ◆ Sehr kurze Leitungslängen
- Slack-Werte müssen aktualisiert werden
 - Timing-Analyse: T_a, T_r
- Wie oft?
 - Nach jedem Zug? Nach N Zügen?
 - N-mal pro Temperaturstufe?
 - Alle N Temperaturstufen?
 - Bewährt:
 - 1x pro Temperaturstufe

Reale Algorithmen

28

Gesamtkostenfunktion

■ Selbstnormalisierend

$$\Delta c = \lambda \frac{\Delta c_i}{c_i^{old}} + (1 - \lambda) \frac{\Delta c_w}{c_w^{old}}$$

■ **λ** gewichtet Zeit ./. Längenoptimierung

- Aber $\lambda=1$ erzeugt nicht die schnellste Lösung
- Netze wechselnd kritisch/unkritisch
 - ◆ Nicht erkannt, da Timing-Analyse nur 1x pro Temp.
- Besser $\lambda=0.5$
 - ◆ Längenmaß wirkt als Dämpfer für Oszillation

Reale Algorithmen

29

Gesamtalgorithmus

```

S = RandomPlacement();
T = InitialTemperature();
Rlimit = InitialRlimit();
CritExp = ComputeNewExponent(Rlimit);

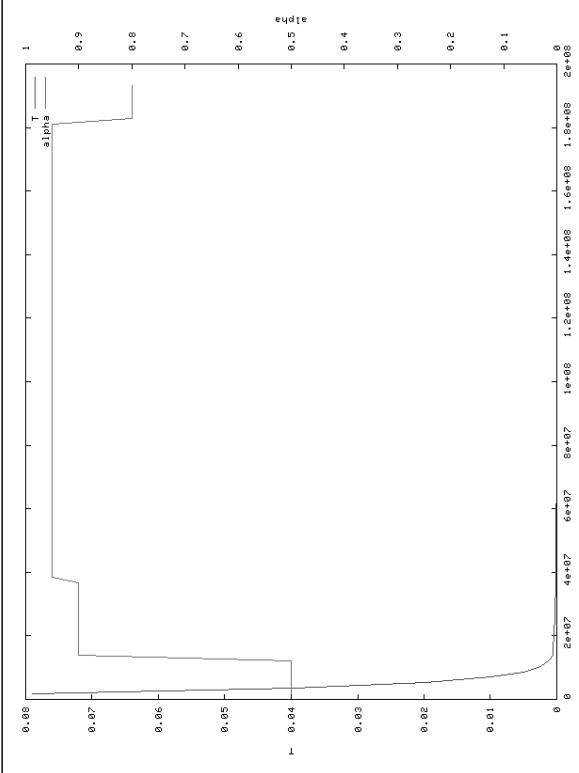
while (!ExitCriterion()) {
    TimingAnalyzer();
    OldWiringCost = WiringCost(S);
    OldTimingCost = TimingCost(S);
    while (InnerLoopCriterion()) {
        Snew = GenerateSwap(S, Rlimit);
        WiringCost = WiringCost(Snew) - WiringCost(S);
        TimingCost = TimingCost(Snew) - TimingCost(S);
        ΔC = λ * (TimingCost/OldTimingCost) + (1-λ) * (WiringCost/OldWiringCost);
        if (ΔC < 0)
            S = Snew;
        else
            if (random(0,1) < exp(-ΔC/T))
                S = Snew
    }
    T = UpdateTemp();
    Rlimit = UpdateRlimit();
    CritExp = ComputeNewExponent(Rlimit);
}

```

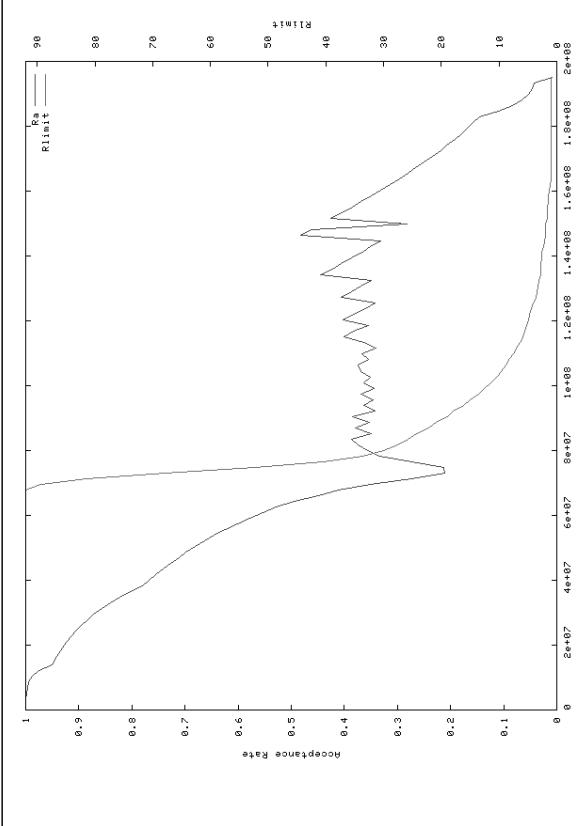
Reale Algorithmen

30

VPR Simulated Annealing 1



VPR Simulated Annealing 2

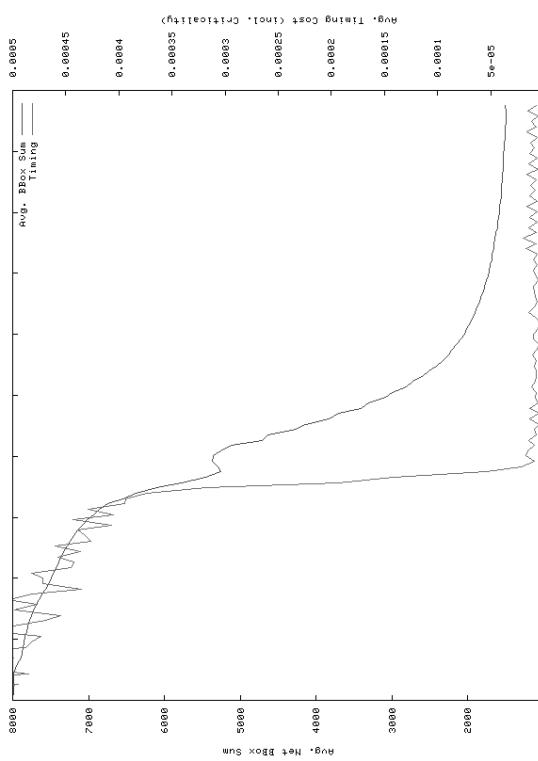


31

Reale Algorithmen

32

VPR Simulated Annealing 3



Reale Algorithmen

33

Partitionierung

- Aufteilen eines Graphen
- Hier motiviert durch Plazierung
- Min-Cut
- Andere Anwendungen
 - Aufteilen einer Schaltung auf mehrere Chips
 - Verkleinern der Problemgröße
 - ◆ Vorbearbeitung vor anderem Algorithmus
- Viele Verfahren
 - Beispiel: Kernighan-Lin

Reale Algorithmen

34

Kernighan-Lin Partitionierung 1

- Problem
 - Gewichteter, ungerichteter Graph $G(V,E)$
 - $|V| = 2n$
- γ_{ab} : Gewicht von $(a,b) \in E$, $\gamma_{ab}=0$ bei $(a,b) \notin E$
- Finde Mengen A und B mit
 - ◆ $A \cup B = V, A \cap B = \emptyset, |A| = |B| = n$
- Minimiere $\sum_{(a,b) \in A \times B} \gamma_{ab}$
- Arbeitet auf Cliquen-Modell

Kernighan-Lin Partitionierung 2

- Partitionierungsproblem ist NP-vollständig
- KL ist eine Heuristik
 - Im praktischen Einsatz bewährt
- Vorgehensweise
 - Anfangslösung bestehend aus A^0 und B^0
 - ◆ I.d.R. nicht optimal
 - Isoliere Unter Mengen von A^{m-1} und B^{m-1}
 - Tausche diese aus um A^m und B^m zu bestimmen
 - Wiederhole, solange Verbesserung erreichbar

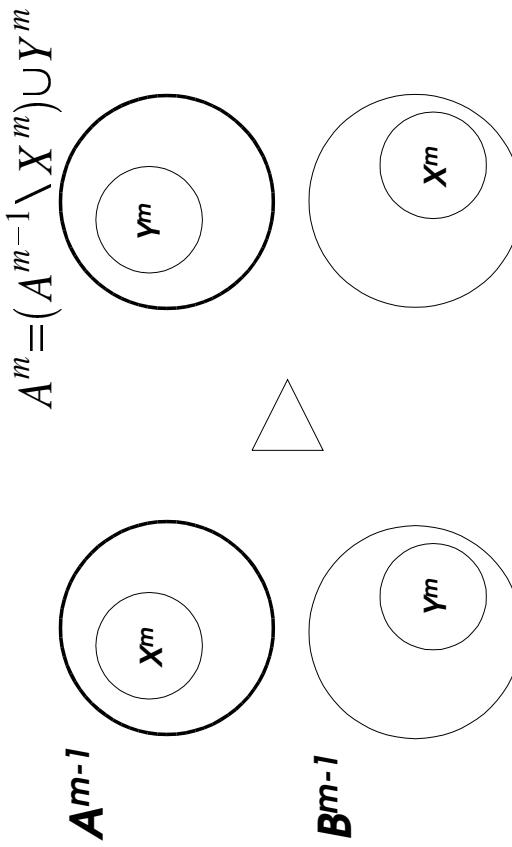
Reale Algorithmen

35

Reale Algorithmen

36

Kernighan-Lin Partitionierung 3



Reale Algorithmen 37

Kernighan-Lin Partitionierung 4

- Optimum immer in einem Schritt erzielbar
 - Bei geeignetem X^m und Y^m
 - Problem: Wie X^m und Y^m bestimmen?
 - Schwer zu finden
- Suche Lösung in mehreren Schritten
 - Wiederhole, bis keine Verbesserung mehr
 - Anzahl Schritte unabhängig von n
 - In der Praxis <= 4.

Reale Algorithmen 38

Kernighan-Lin Partitionierung 5

- Konstruktion von X^m und Y^m
- Externe Kosten

$$E_a = \sum_{y \in B^{m-1}} \gamma_{ay}, \quad a \in A^{m-1}$$

- Interne Kosten

$$I_a = \sum_{x \in A^{m-1}} \gamma_{ax}, \quad a \in A^{m-1}$$

- Analog für B

Kernighan-Lin Partitionierung 6

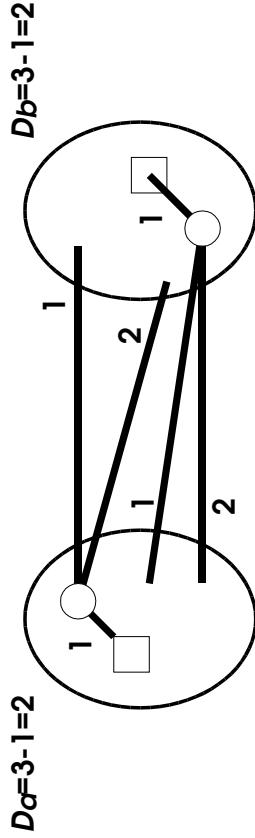
- $D\alpha = E\alpha - I\alpha$ für $\alpha \in A^{m-1}$ (desirability)
 - >0: Knoten sollte nach B getauscht werden
 - <0: Knoten sollte in A bleiben
- Verbesserung Δ der Schnittkosten
 - Bei Austausch von $a \in A^{m-1}$ und $b \in B^{m-1}$
 - Δ kann negativ sein!

$$\Delta = D_a + D_b - 2\gamma_{ab}$$

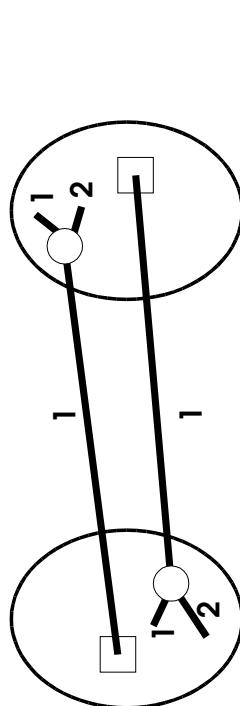
Reale Algorithmen 39

Reale Algorithmen 40

Kernighan-Lin Partitionierung 7

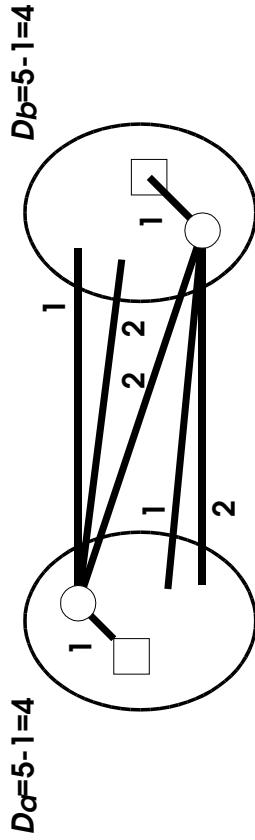


$$\Delta = Da + Db - 2 \gamma ab = 2 + 2 - 0 = 4$$

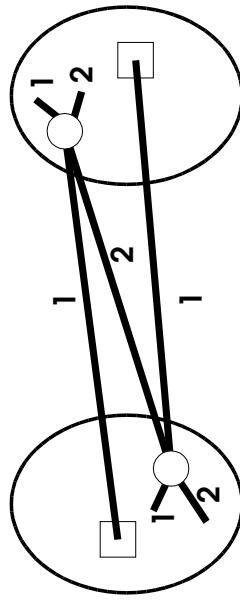


Reale Algorithmen 41

Kernighan-Lin Partitionierung 8



$$\Delta = Da + Db - 2 \gamma ab = 4 + 4 - 2 \cdot 2 = 4$$



Reale Algorithmen 42

Kernighan-Lin Partitionierung 9

```

initialize(A0, B0);
do {
    foreach  $a \in A^{m-1}$  "berechne Da";
    foreach  $b \in B^{m-1}$  "berechne Db";
    for (i := 1; i <= n; ++i) {
        "finde freie  $ai \in A^{m-1}, bi \in B^{m-1}$  mit
        " $\Delta_i := Da + Db - 2 \gamma abi$  maximal"
        "sperrre  $ai$  und  $bi$ "}
    foreach "freies"  $x \in A^{m-1}$   $Dx := Dx + 2 \gamma xai - 2 \gamma xbi$ ;
    foreach "freies"  $y \in B^{m-1}$   $Dy := Dy - 2 \gamma yai + 2 \gamma ybi$ ;
    } "finde ein  $k$  mit  $\sum_{i=1}^k \Delta_i$  ist max."
     $G := \sum_{i=1}^k \Delta_i$ 
    m := m + 1;
} while ( $G > 0$ );
    
```

if ($G > 0$) {
 $X^m := \{a_1, \dots, a_k\};$
 $Y^m := \{b_1, \dots, b_k\};$
 $A^m := (A^{m-1} \setminus X^m) \cup Y^m;$
 $B^m := (B^{m-1} \setminus Y^m) \cup X^m;$
"entsperre alle Knoten in A^m and $B^m"$
 } }

Reale Algorithmen 43

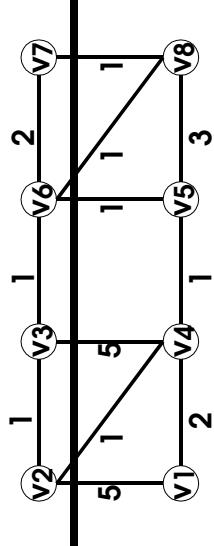
Reale Algorithmen 44

Kernighan-Lin Partitionierung 10

- Δ_i kann negativ werden
- $\sum \Delta_i$ kann zeitweise auch negativ sein
 - Dicht verbundene Teilmengen
 - ◆ Keine Verbesserung bei Austausch von Einzelknoten
 - ◆ Erst bei Austausch der gesamten Teilmenge

44

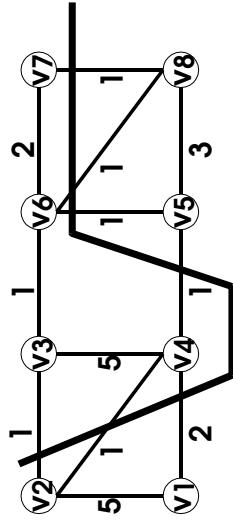
Kernighan-Lin Partitionierung 11



i	v_2	v_3	v_6	v_7	v_1	v_4	v_5	v_8	Δ_i
1	5	3	-1	-1	3	3	-3	-1	6
2	-5	-5	-1	1	-3	-1	-1	-2	-2
3	-5	1	1	1	-3	3	2	3	2
4	-3	-3	-3	-3	-3	-3	-3	-3	-6

Reale Algorithmen 45

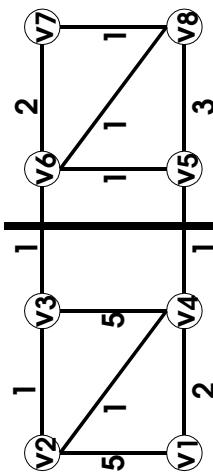
Kernighan-Lin Partitionierung 12



i	v_3	v_4	v_6	v_7	v_1	v_2	v_5	v_8	Δ_i
1	-5	-1	-1	-1	-3	-3	-1	-1	-2
2	5	5	5	5	-3	-3	-7	-5	8
3	3	3	3	3	-7	-7	-7	-7	-10
4	1	1	1	1	3	3	3	3	4

Reale Algorithmen 46

Kernighan-Lin Partitionierung 13



Kernighan-Lin Partitionierung 14

$\sum \Delta_i$									
i	v_3	v_4	v_6	v_7	v_1	v_2	v_5	v_8	Δ_i
1	-5	-1	-1	-1	-3	-3	-1	-1	-2
2	5	5	5	5	-3	-3	-7	-5	8
3	3	3	3	3	-7	-7	-7	-7	-10
4	1	1	1	1	3	3	3	3	4

- Danach keine Verbesserung mehr in G
- Innere Schleife: n Iterationen
 - Finden des Paars mit bestem Δ : $O(n^2)$
 - Nach Δ sortiert: $O(n \log n)$
 - $\rightarrow O(n^3)$ oder $O(n^2 \log n)$

Reale Algorithmen 47

Reale Algorithmen 48

Weiteres Vorgehen

- **Bewertung der Abgaben**
 - Bescheid über Platzzuweisung via E-Mail
 - Bis Mittwoch 18:00 Uhr
 - Zuweisung von Kolloquiums-Slot
- **Donnerstag**
 - Gruppenweise 30-minütige Kolloquien
 - Anwesenheitspflicht!
- **Freitag**
 - Gruppenweise 10-minütige Vorträge
 - Nicht überziehen!
 - Ausgabe der nächsten Aufgabe
- **VL Dienstag: 5.2-5.4 Exakte Optim.verfahren**

Reale Algorithmen

49

Zusammenfassung

- **Schnelle pfadorientierte Timing-Analyse**
 - VPR
 - Adaptives Simulated Annealing
 - Selbstnormalisierende Kostenfunktion
 - Schnelle Netzumfangsberechnung
 - Gesamtalgorithmus
 - Kernighan-Lin MinCut-Partitionierung
- **Papers auf Web-Seite**
 - Ju & Saleh 1991: Kritische Pfadaufzählung
 - ◆ Nur Abschnitt 3 relevant
 - Cheng 1994: q(i) Korrekturfaktoren
 - ◆ ... sonst eher schlecht zu lesen
 - Marquardt & Betz: VPR
 - ◆ 1997 Grundlagen
 - ◆ 2000 Timing-gesteuerte Betriebsart (Criticality, etc.)
- **Reale Algorithmen**

50