

# Algorithmen für Chip-Entwurfswerkzeuge

## Mathematische Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

Vorlesung  
WS 2014/2015

Andreas Koch

Eingebette Systeme und Anwendungen  
Technische Universität Darmstadt



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig
  - ▶ NP-hart (mindestens so aufwendig wie NP-vollständig)



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig
  - ▶ NP-hart (mindestens so aufwendig wie NP-vollständig)
- ▶ Exakt lösbar nur für kleine Problemgrößen



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig
  - ▶ NP-hart (mindestens so aufwendig wie NP-vollständig)
- ▶ Exakt lösbar nur für kleine Problemgrößen
- ▶ Falls suboptimale Lösungen akzeptabel:



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig
  - ▶ NP-hart (mindestens so aufwendig wie NP-vollständig)
- ▶ Exakt lösbar nur für kleine Problemgrößen
- ▶ Falls suboptimale Lösungen akzeptabel:
  - ▶ Näherungsverfahren, Approximationen



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig
  - ▶ NP-hart (mindestens so aufwendig wie NP-vollständig)
- ▶ Exakt lösbar nur für kleine Problemgrößen
- ▶ Falls suboptimale Lösungen akzeptabel:
  - ▶ Näherungsverfahren, Approximationen
    - ▶ Garantieren eine bestimmte Lösungsqualität





- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig
  - ▶ NP-hart (mindestens so aufwendig wie NP-vollständig)
- ▶ Exakt lösbar nur für kleine Problemgrößen
- ▶ Falls suboptimale Lösungen akzeptabel:
  - ▶ Näherungsverfahren, Approximationen
    - ▶ Garantieren eine bestimmte Lösungsqualität
    - ▶ Nicht allgemein formulierbar



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig
  - ▶ NP-hart (mindestens so aufwendig wie NP-vollständig)
- ▶ Exakt lösbar nur für kleine Problemgrößen
- ▶ Falls suboptimale Lösungen akzeptabel:
  - ▶ Näherungsverfahren, Approximationen
    - ▶ Garantieren eine bestimmte Lösungsqualität
    - ▶ Nicht allgemein formulierbar
  - ▶ Heuristiken



- ▶ Alle Probleme im Bereich VLSI CAD sind Optimierungsprobleme, viele davon sind
  - ▶ NP-vollständig
  - ▶ NP-hart (mindestens so aufwendig wie NP-vollständig)
- ▶ Exakt lösbar nur für kleine Problemgrößen
- ▶ Falls suboptimale Lösungen akzeptabel:
  - ▶ Näherungsverfahren, Approximationen
    - ▶ Garantieren eine bestimmte Lösungsqualität
    - ▶ Nicht allgemein formulierbar
  - ▶ Heuristiken
    - ▶ Schwankende Lösungsqualität



- ▶ Gesamtverbindungslänge



- ▶ Gesamtverbindungslänge
  - ▶ Optimiert indirekt auch andere Ziele



- ▶ Gesamtverbindungslänge
  - ▶ Optimiert indirekt auch andere Ziele
- ▶ Verdrahtungsdichte / Verdrahtbarkeit



- ▶ Gesamtverbindungslänge
  - ▶ Optimiert indirekt auch andere Ziele
- ▶ Verdrahtungsdichte / Verdrahtbarkeit
- ▶ Signalverzögerung



- ▶ Gesamtverbindungslänge
  - ▶ Optimiert indirekt auch andere Ziele
- ▶ Verdrahtungsdichte / Verdrahtbarkeit
- ▶ Signalverzögerung
- ▶ Energieverbrauch





- ▶ Gesamtverbindungslänge
  - ▶ Optimiert indirekt auch andere Ziele
- ▶ Verdrahtungsdichte / Verdrahtbarkeit
- ▶ Signalverzögerung
- ▶ Energieverbrauch
- ▶ Thermisches Verhalten



- ▶ Gesamtverbindungslänge
  - ▶ Optimiert indirekt auch andere Ziele
- ▶ Verdrahtungsdichte / Verdrahtbarkeit
- ▶ Signalverzögerung
- ▶ Energieverbrauch
- ▶ Thermisches Verhalten



- ▶ Gesamtverbindungslänge
  - ▶ Optimiert indirekt auch andere Ziele
- ▶ Verdrahtungsdichte / Verdrahtbarkeit
- ▶ Signalverzögerung
- ▶ Energieverbrauch
- ▶ Thermisches Verhalten

⇒ Zielfunktion (objective function) (Funktion die max./min. werden soll)  
entsprechend wählen



- ▶ Gesamtverbindungslänge
  - ▶ Optimiert indirekt auch andere Ziele
- ▶ Verdrahtungsdichte / Verdrahtbarkeit
- ▶ Signalverzögerung
- ▶ Energieverbrauch
- ▶ Thermisches Verhalten

⇒ Zielfunktion (objective function) (Funktion die max./min. werden soll)  
entsprechend wählen

**Am gebräuchlichsten:**

(Gewichtete) Gesamtverbindungslänge



## ► Wozu?



- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer



- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts



## ▶ Wozu?

- ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
- ▶ Analysiere fertige Layouts
- ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung





- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts
  - ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
    - ▶ Erkenne kritische Verbindungen



### ▶ Wozu?

- ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
- ▶ Analysiere fertige Layouts
- ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
  - ▶ Erkenne kritische Verbindungen
  - ▶ Behandle diese mit Vorrang



- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts
  - ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
    - ▶ Erkenne kritische Verbindungen
    - ▶ Behandle diese mit Vorrang
- ▶ Worauf?



- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts
  - ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
    - ▶ Erkenne kritische Verbindungen
    - ▶ Behandle diese mit Vorrang
- ▶ Worauf?
  - ▶ Schaltungselement



- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts
  - ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
    - ▶ Erkenne kritische Verbindungen
    - ▶ Behandle diese mit Vorrang
- ▶ Worauf?
  - ▶ Schaltungselement
    - ▶ Gatter, Werttabellen (LUT), Register, I/O-Blöcke, ...



- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts
  - ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
    - ▶ Erkenne kritische Verbindungen
    - ▶ Behandle diese mit Vorrang
- ▶ Worauf?
  - ▶ Schaltungselement
    - ▶ Gatter, Werttabellen (LUT), Register, I/O-Blöcke, . . .
    - ▶ Bleiben konstant, exakte Verzögerungen bekannt



- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts
  - ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
    - ▶ Erkenne kritische Verbindungen
    - ▶ Behandle diese mit Vorrang
- ▶ Worauf?
  - ▶ Schaltungselement
    - ▶ Gatter, Werttabellen (LUT), Register, I/O-Blöcke, ...
    - ▶ Bleiben konstant, exakte Verzögerungen bekannt
  - ▶ Netze




- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts
  - ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
    - ▶ Erkenne kritische Verbindungen
    - ▶ Behandle diese mit Vorrang
- ▶ Worauf?
  - ▶ Schaltungselement
    - ▶ Gatter, Werttabellen (LUT), Register, I/O-Blöcke, ...
    - ▶ Bleiben konstant, exakte Verzögerungen bekannt
  - ▶ Netze
    - ▶ Nur nach Layouterzeugung bekannt





- ▶ Wozu?
  - ▶ Zielfunktion für Optimierung? **Nein!**  
Häufige Auswertung zu teuer
  - ▶ Analysiere fertige Layouts
  - ▶ Analysiere einzelne Verbindungen *während* Layouterzeugung
    - ▶ Erkenne kritische Verbindungen
    - ▶ Behandle diese mit Vorrang
- ▶ Worauf?
  - ▶ Schaltungselement
    - ▶ Gatter, Werttabellen (LUT), Register, I/O-Blöcke, ...
    - ▶ Bleiben konstant, exakte Verzögerungen bekannt
  - ▶ Netze
    - ▶ Nur nach Layouterzeugung bekannt
    - ▶ Vorher schätzen



- ▶ Auf 4-partitem Graph
  - ▶ Externe Eingänge
  - ▶ Externe Ausgänge
  - ▶ Eingangs-Ports
  - ▶ Ausgangs-Ports



- ▶ Ankunftszeit (arrival) an Knoten  $v$   
$$T_a(v) = \max_{(u,v) \in E} (T_a(u) + w(u, v))$$



- ▶ Ankunftszeit (arrival) an Knoten  $v$   
 $T_a(v) = \max_{(u,v) \in E} (T_a(u) + w(u, v))$
- ▶ Idee: BFS oder DAG LP



- ▶ Ankunftszeit (arrival) an Knoten  $v$   
$$T_a(v) = \max_{(u,v) \in E} (T_a(u) + w(u, v))$$
- ▶ Idee: BFS oder DAG LP
  - ▶ Beginne mit  $T_a(v) = 0$  bei folgenden Knoten:  
Externer Eingänge, Registerausgänge



- ▶ Ankunftszeit (arrival) an Knoten  $v$

$$T_a(v) = \max_{(u,v) \in E} (T_a(u) + w(u, v))$$

- ▶ Idee: BFS oder DAG LP

- ▶ Beginne mit  $T_a(v) = 0$  bei folgenden Knoten:  
Externer Eingänge, Registerausgänge
- ▶ Bearbeite Knoten bei denen alle Vorgänger bearbeitet sind



- ▶ Ankunftszeit (arrival) an Knoten  $v$

$$T_a(v) = \max_{(u,v) \in E} (T_a(u) + w(u, v))$$

- ▶ Idee: BFS oder DAG LP

- ▶ Beginne mit  $T_a(v) = 0$  bei folgenden Knoten:  
Externer Eingänge, Registerausgänge
- ▶ Bearbeite Knoten bei denen alle Vorgänger bearbeitet sind
- ▶ Späteste Gesamtankunftszeit  $D_{max} =$  Taktperiode  
(an Externen Ausgängen, Registereingängen)

- ▶ Ankunftszeit (arrival) an Knoten  $v$

$$T_a(v) = \max_{(u,v) \in E} (T_a(u) + w(u, v))$$

- ▶ Idee: BFS oder DAG LP

- ▶ Beginne mit  $T_a(v) = 0$  bei folgenden Knoten:  
Externer Eingänge, Registerausgänge
- ▶ Bearbeite Knoten bei denen alle Vorgänger bearbeitet sind
- ▶ Späteste Gesamtankunftszeit  $D_{max} =$  Taktperiode  
(an Externen Ausgängen, Registereingängen)

## In Beispielschaltung

$$D_{max} = 13.6 \text{ ns}$$





- ▶ Wie unwichtig sind unkritische Netze?



- ▶ Wie unwichtig sind unkritische Netze?
  - ▶ Hier auf Zeitintervalle anwenden



- ▶ Wie unwichtig sind unkritische Netze?
  - ▶ Hier auf Zeitintervalle anwenden

## Beantwortet die Frage

Wieviel langsamer kann ein Netz werden ohne das die gesamte Schaltung leidet?



- ▶ Wie unwichtig sind unkritische Netze?
  - ▶ Hier auf Zeitintervalle anwenden

## Beantwortet die Frage

Wieviel langsamer kann ein Netz werden ohne das die gesamte Schaltung leidet?

- ▶ Berechnung



- ▶ Wie unwichtig sind unkritische Netze?
  - ▶ Hier auf Zeitintervalle anwenden

## Beantwortet die Frage

Wieviel langsamer kann ein Netz werden ohne das die gesamte Schaltung leidet?

- ▶ Berechnung
  - ▶ Mittels spätestmöglicher Ankunftszeit



- ▶ Wie unwichtig sind unkritische Netze?
  - ▶ Hier auf Zeitintervalle anwenden

## Beantwortet die Frage

Wieviel langsamer kann ein Netz werden ohne das die gesamte Schaltung leidet?

- ▶ Berechnung
  - ▶ Mittels spätestmöglicher Ankunftszeit
  - ▶ Required Time  $T_r(v)$  an Knoten  $v$



- ▶ Wie unwichtig sind unkritische Netze?
  - ▶ Hier auf Zeitintervalle anwenden

## Beantwortet die Frage

Wieviel langsamer kann ein Netz werden ohne das die gesamte Schaltung leidet?

- ▶ Berechnung
  - ▶ Mittels spätestmöglicher Ankunftszeit
  - ▶ Required Time  $T_r(v)$  an Knoten  $v$
  - ▶ Spätestmöglicher Ankunftszeitpunkt von Signalen
    - ⇒ **Sonst Verlangsamung der gesamten Schaltung**

# Berechnung Spätestmögl. Ankunftszeit und Slack

- ▶ Beginne mit  $T_r(u) = D_{max}$  bei folgenden Knoten:  
Externen Ausgänge, Registereingänge



# Berechnung Spätestmögl. Ankunftszeit und Slack



- ▶ Beginne mit  $T_r(u) = D_{max}$  bei folgenden Knoten:  
Externen Ausgänge, Registereingänge
- ▶ Nun BFS/LP Rückwärts

# Berechnung Spätestmögl. Ankunftszeit und Slack

- ▶ Beginne mit  $T_r(u) = D_{max}$  bei folgenden Knoten:  
Externen Ausgänge, Registereingänge
- ▶ Nun BFS/LP Rückwärts
- ▶ Rückwärts  $\Rightarrow$  Graph mit umgedrehten Kanten

# Berechnung Spätestmögl. Ankunftszeit und Slack

- ▶ Beginne mit  $T_r(u) = D_{max}$  bei folgenden Knoten:  
Externen Ausgänge, Registereingänge
- ▶ Nun BFS/LP Rückwärts
- ▶ Rückwärts  $\Rightarrow$  Graph mit umgedrehten Kanten
- ▶ Bearbeite Knoten

# Berechnung Spätestmögl. Ankunftszeit und Slack

- ▶ Beginne mit  $T_r(u) = D_{max}$  bei folgenden Knoten:  
Externen Ausgänge, Registereingänge
- ▶ Nun BFS/LP Rückwärts
- ▶ Rückwärts  $\Rightarrow$  Graph mit umgedrehten Kanten
- ▶ Bearbeite Knoten
  - ▶ Nur mit komplett bearbeiteten Vorgängern

# Berechnung Spätestmögl. Ankunftszeit und Slack

- ▶ Beginne mit  $T_r(u) = D_{max}$  bei folgenden Knoten:  
Externen Ausgänge, Registereingänge
- ▶ Nun BFS/LP Rückwärts
- ▶ Rückwärts  $\Rightarrow$  Graph mit umgedrehten Kanten
- ▶ Bearbeite Knoten
  - ▶ Nur mit komplett bearbeiteten Vorgängern
  - ▶  $T_r(u) = \min_{(u,v) \in E} (T_r(v) - w(u, v))$

# Berechnung Spätestmögl. Ankunftszeit und Slack

- ▶ Beginne mit  $T_r(u) = D_{max}$  bei folgenden Knoten:  
Externen Ausgänge, Registereingänge
- ▶ Nun BFS/LP Rückwärts
- ▶ Rückwärts  $\Rightarrow$  Graph mit umgedrehten Kanten
- ▶ Bearbeite Knoten
  - ▶ Nur mit komplett bearbeiteten Vorgängern
  - ▶  $T_r(u) = \min_{(u,v) \in E} (T_r(v) - w(u, v))$
- ▶ *Slack (Schlupf)* einer Verbindung von  $u$  nach  $v$   
 $slack(u, v) = T_r(v) - T_a(u) - w(u, v)$

# Berechnung Spätestmögl. Ankunftszeit und Slack

- ▶ Beginne mit  $T_r(u) = D_{max}$  bei folgenden Knoten:  
Externen Ausgänge, Registereingänge
- ▶ Nun BFS/LP Rückwärts
- ▶ Rückwärts  $\Rightarrow$  Graph mit umgedrehten Kanten
- ▶ Bearbeite Knoten
  - ▶ Nur mit komplett bearbeiteten Vorgängern
  - ▶  $T_r(u) = \min_{(u,v) \in E} (T_r(v) - w(u, v))$
- ▶ *Slack (Schlupf)* einer Verbindung von  $u$  nach  $v$   
 $slack(u, v) = T_r(v) - T_a(u) - w(u, v)$
- ▶ Auf kritischem Pfad:  $slack = 0$

# Beispiel



Node: 4 INPAD\_SOURCE Block #2 (s27\_in\_3\_)  
T\_arr: 0 T\_req: -3.88578e-16 Tdel: 5e-10

Node: 5 INPAD\_OPIN Block #2 (s27\_in\_3\_)  
Pin: 0  
T\_arr: 5e-10 T\_req: 5e-10 Tdel: 5e-09  
Net to next node: #2 (s27\_in\_3\_). Pins on net: 5.

Node: 12 CLB\_IPIN Block #6 (s27\_out)  
Pin: 0  
T\_arr: 5.5e-09 T\_req: 5.5e-09 Tdel: 0

Node: 17 SUBBLK\_IPIN Block #6 (s27\_out)  
Pin: 0 Subblock #0  
T\_arr: 5.5e-09 T\_req: 5.5e-09 Tdel: 9e-10

Node: 21 SUBBLK\_OPIN Block #6 (s27\_out)  
Pin: 4 Subblock #0  
T\_arr: 6.4e-09 T\_req: 6.4e-09 Tdel: 0

Node: 16 CLB\_OPIN Block #6 (s27\_out)  
Pin: 4  
T\_arr: 6.4e-09 T\_req: 6.4e-09 Tdel: 1e-09  
Net to next node: #5 (s27\_out). Pins on net: 2.

Node: 10 OUTPAD\_IPIN Block #5 (out:s27\_out)  
Pin: 0  
T\_arr: 7.4e-09 T\_req: 7.4e-09 Tdel: 3e-10

Node: 11 OUTPAD\_SINK Block #5 (out:s27\_out)  
T\_arr: 7.7e-09 T\_req: 7.7e-09

Tnodes on crit. path: 8 Non-global nets on crit. path: 2.  
Global nets on crit. path: 0.  
Total logic delay: 1.7e-09 (s) Total net delay: 6e-09 (s)



# Gesamtverbindungslänge

## Exakte Kosten



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Häufigstes Optimierungsziel in der Praxis

# Gesamtverbindungslänge

## Exakte Kosten



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Häufigstes Optimierungsziel in der Praxis
- ▶ Optimal: Exaktes (und perfektes) Routing während der Platzierung

# Gesamtverbindungslänge

## Exakte Kosten



- ▶ Häufigstes Optimierungsziel in der Praxis
- ▶ Optimal: Exaktes (und perfektes) Routing während der Platzierung
- ▶ Exaktes Routing zu aufwendig

# Gesamtverbindungslänge

## Exakte Kosten



- ▶ Häufigstes Optimierungsziel in der Praxis
  - ▶ Optimal: Exaktes (und perfektes) Routing während der Platzierung
  - ▶ Exaktes Routing zu aufwendig
- ⇒ Verbindungslänge für jedes Netz schätzen und aufsummieren

# Gesamtverbindungslänge

## Exakte Kosten



- ▶ Häufigstes Optimierungsziel in der Praxis
  - ▶ Optimal: Exaktes (und perfektes) Routing während der Platzierung
  - ▶ Exaktes Routing zu aufwendig
- ⇒ Verbindungslänge für jedes Netz schätzen und aufsummieren
- ▶ Annahme optimales Routing möglich (d.h. keine Umwege wegen Hindernissen)

# Gesamtverbindungslänge

## Exakte Kosten



- ▶ Häufigstes Optimierungsziel in der Praxis
  - ▶ Optimal: Exaktes (und perfektes) Routing während der Platzierung
  - ▶ Exaktes Routing zu aufwendig
- ⇒ Verbindungslänge für jedes Netz schätzen und aufsummieren
- ▶ Annahme optimales Routing möglich (d.h. keine Umwege wegen Hindernissen)
  - ▶ Für bis 3 Pins trivial: HPWL Abschätzung exakt

# Gesamtverbindungslänge

## Exakte Kosten

- ▶ Häufigstes Optimierungsziel in der Praxis
  - ▶ Optimal: Exaktes (und perfektes) Routing während der Platzierung
  - ▶ Exaktes Routing zu aufwendig
- ⇒ Verbindungslänge für jedes Netz schätzen und aufsummieren
- ▶ Annahme optimales Routing möglich (d.h. keine Umwege wegen Hindernissen)
  - ▶ Für bis 3 Pins trivial: HPWL Abschätzung exakt
  - ▶ Für (viel) mehr: HPWL Abschätzung zunehmend ungenau

# Gesamtverbindungslänge

## Exakte Kosten



- ▶ Häufigstes Optimierungsziel in der Praxis
  - ▶ Optimal: Exaktes (und perfektes) Routing während der Platzierung
  - ▶ Exaktes Routing zu aufwendig
- ⇒ Verbindungslänge für jedes Netz schätzen und aufsummieren
- ▶ Annahme optimales Routing möglich (d.h. keine Umwege wegen Hindernissen)
  - ▶ Für bis 3 Pins trivial: HPWL Abschätzung exakt
  - ▶ Für (viel) mehr: HPWL Abschätzung zunehmend ungenau
  - ▶ Andere Möglichkeiten RSMT, RMST, korrigierte HPWL, FLUTE, quadratische Verbindungslänge, LSE, WA, Star+, ...





- ▶ Abstand  $d(x, y)$  zweier Punkte (Pins) im Raum (in der Ebene)



- ▶ Abstand  $d(x, y)$  zweier Punkte (Pins) im Raum (in der Ebene)
- ▶ Definit:  $x = y \Leftrightarrow d(x, y) = 0$



- ▶ Abstand  $d(x, y)$  zweier Punkte (Pins) im Raum (in der Ebene)
- ▶ Definit:  $x = y \Leftrightarrow d(x, y) = 0$
- ▶ Symmetrisch:  $d(x, y) = d(y, x)$



- ▶ Abstand  $d(x, y)$  zweier Punkte (Pins) im Raum (in der Ebene)
- ▶ Definit:  $x = y \Leftrightarrow d(x, y) = 0$
- ▶ Symmetrisch:  $d(x, y) = d(y, x)$
- ▶ Erfüllt Dreiecksungleichung:  $d(x, y) \leq d(x, z) + d(z, y)$



- ▶ Abstand  $d(x, y)$  zweier Punkte (Pins) im Raum (in der Ebene)
- ▶ Definit:  $x = y \Leftrightarrow d(x, y) = 0$
- ▶ Symmetrisch:  $d(x, y) = d(y, x)$
- ▶ Erfüllt Dreiecksungleichung:  $d(x, y) \leq d(x, z) + d(z, y)$
- ▶ Üblicherweise benutzt man von Norm induzierte Metrik

$$d(x, y) := ||x - y||$$

- ▶ Abstand  $d(x, y)$  zweier Punkte (Pins) im Raum (in der Ebene)
- ▶ Definit:  $x = y \Leftrightarrow d(x, y) = 0$
- ▶ Symmetrisch:  $d(x, y) = d(y, x)$
- ▶ Erfüllt Dreiecksungleichung:  $d(x, y) \leq d(x, z) + d(z, y)$
- ▶ Üblicherweise benutzt man von Norm induzierte Metrik

$$d(x, y) := ||x - y||$$

- ▶ **Wichtige Frage:** Wie handhabt man Netze mit mehr als 2 Pins?

# 1-Norm

## Manhattan-/Taxi-Metrik



- ▶  $p$ -Norm induzierte Metrik

$$d(x, y) = \sqrt[p]{\sum_i |x_i - y_i|^p}$$

# 1-Norm

## Manhattan-/Taxi-Metrik



- ▶  $p$ -Norm induzierte Metrik

$$d(x, y) = \sqrt[p]{\sum_i |x_i - y_i|^p}$$

- ▶ 1-Norm gibt Abstand wenn man sich rechtwinklig bewegt



# 1-Norm

## Manhattan-/Taxi-Metrik



- ▶  $p$ -Norm induzierte Metrik

$$d(x, y) = \sqrt[p]{\sum_i |x_i - y_i|^p}$$

- ▶ 1-Norm gibt Abstand wenn man sich rechtwinklig bewegt
- ▶ Gibt exakte Länge in einem Raster

# 1-Norm

## Manhattan-/Taxi-Metrik



- ▶  $p$ -Norm induzierte Metrik

$$d(x, y) = \sqrt[p]{\sum_i |x_i - y_i|^p}$$

- ▶ 1-Norm gibt Abstand wenn man sich rechtwinklig bewegt
- ▶ Gibt exakte Länge in einem Raster
- ▶ Sehr schnell zu berechnen

# 1-Norm

## Manhattan-/Taxi-Metrik



- ▶  $p$ -Norm induzierte Metrik

$$d(x, y) = \sqrt[p]{\sum_i |x_i - y_i|^p}$$

- ▶ 1-Norm gibt Abstand wenn man sich rechtwinklig bewegt
  - ▶ Gibt exakte Länge in einem Raster
  - ▶ Sehr schnell zu berechnen
- ⇒ Sehr weit verbreitet

# HPWL

## Half-Perimeter-Wirelength



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Verallgemeinerung der 1-Norm für mehr als 2 Pins

# HPWL

## Half-Perimeter-Wirelength



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Verallgemeinerung der 1-Norm für mehr als 2 Pins
- ▶ Halber Umfang des umschliessenden Rechtecks aller Pins

# HPWL

## Half-Perimeter-Wirelength



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Verallgemeinerung der 1-Norm für mehr als 2 Pins
- ▶ Halber Umfang des umschliessenden Rechtecks aller Pins
- ▶ Exakt für bis zu 3 Pins

# HPWL

## Half-Perimeter-Wirelength



- ▶ Verallgemeinerung der 1-Norm für mehr als 2 Pins
- ▶ Halber Umfang des umschliessenden Rechtecks aller Pins
- ▶ Exakt für bis zu 3 Pins
- ▶ Untere Grenze für  $> 3$  Pins

# HPWL

## Half-Perimeter-Wirelength



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Verallgemeinerung der 1-Norm für mehr als 2 Pins
- ▶ Halber Umfang des umschliessenden Rechtecks aller Pins
- ▶ Exakt für bis zu 3 Pins
- ▶ Untere Grenze für  $> 3$  Pins



# HPWL

## Half-Perimeter-Wirelength



- ▶ Verallgemeinerung der 1-Norm für mehr als 2 Pins
- ▶ Halber Umfang des umschliessenden Rechtecks aller Pins
- ▶ Exakt für bis zu 3 Pins
- ▶ Untere Grenze für  $> 3$  Pins

### Vorteile

- ▶ Sehr schnell zu berechnen:

$$HPWL = (\max x_i - \min x_i) + (\max y_i - \min y_i)$$

# HPWL

## Half-Perimeter-Wirelength

- ▶ Verallgemeinerung der 1-Norm für mehr als 2 Pins
- ▶ Halber Umfang des umschließenden Rechtecks aller Pins
- ▶ Exakt für bis zu 3 Pins
- ▶ Untere Grenze für  $> 3$  Pins

### Vorteile

- ▶ Sehr schnell zu berechnen:

$$HPWL = (\max x_i - \min x_i) + (\max y_i - \min y_i)$$

### Nachteile

- ▶ Für große Anzahl Pins wird der schnell Fehler groß  
⇒ Korrekturfaktoren für große Netze (Abhängig von # Pins)
- ▶ Nicht differenzierbar

# HPWL

## Beispiele



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT



# HPWL

## Beispiele



# HPWL

## Beispiele



Exakt



# HPWL

## Beispiele



Exakt




# HPWL

## Beispiele



Exakt



# HPWL


## Beispiele



Exakt



Exakt





# HPWL



## Beispiele



Exakt



Exakt



# HPWL




## Beispiele



Exakt



Exakt



# HPWL



## Beispiele




Exakt



Exakt



Untere Grenze



# RSMT

## Rectilinear Steiner Minimal Tree



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Rechtwinkliger Minimaler Steiner Baum, d.h. Steinerbaum mit rechtwinkliger Metrik

# RSMT

## Rectilinear Steiner Minimal Tree



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Rechtwinkliger Minimaler Steiner Baum, d.h. Steinerbaum mit rechtwinkliger Metrik
- ▶ Steinerbaumproblem: Finde kleinsten geometrisch aufspannenden Baum eines Graph (Verzweigungen nicht zwangsweise an Knoten)

# RSMT

## Rectilinear Steiner Minimal Tree



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Rechtwinkliger Minimaler Steiner Baum, d.h. Steinerbaum mit rechtwinkliger Metrik
- ▶ Steinerbaumproblem: Finde kleinsten geometrisch aufspannenden Baum eines Graph (Verzweigungen nicht zwangsweise an Knoten)

# RSMT

## Rectilinear Steiner Minimal Tree



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Rechtwinkliger Minimaler Steiner Baum, d.h. Steinerbaum mit rechtwinkliger Metrik
- ▶ Steinerbaumproblem: Finde kleinsten geometrisch aufspannenden Baum eines Graph (Verzweigungen nicht zwangsweise an Knoten)

### Vorteile

- ▶ Exakt

# RSMT

## Rectilinear Steiner Minimal Tree

- ▶ Rechtwinkliger Minimaler Steiner Baum, d.h. Steinerbaum mit rechtwinkliger Metrik
- ▶ Steinerbaumproblem: Finde kleinsten geometrisch aufspannenden Baum eines Graph (Verzweigungen nicht zwangsweise an Knoten)

### Vorteile

- ▶ Exakt

### Nachteile

- ▶ NP-Vollständig  $\Rightarrow$  Impraktikabel
- ▶ Normalerweise sogar Heuristiken lange Laufzeit
- ▶ **NEU:** FLUTE  
Tabellenbasierte RSMT-Heuristik
- ▶ Nicht differenzierbar



# RMST

## Rectilinear Minimum Spanning Tree



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Rechtwinkliger minimal aufspannender Baum

# RMST

## Rectilinear Minimum Spanning Tree



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Rechtwinkliger minimal aufspannender Baum

# RMST

## Rectilinear Minimum Spanning Tree



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Rechtwinkliger minimal aufspannender Baum

### Vorteile

- ▶ Viel schneller als RSMT:  
 $\mathcal{O}(n \log n)$
- ▶ Gütegarantie: Ergebnis  
max. 50% schlechter

# RMST

## Rectilinear Minimum Spanning Tree

- ▶ Rechtwinkliger minimal aufspannender Baum

### Vorteile

- ▶ Viel schneller als RSMT:  
 $\mathcal{O}(n \log n)$
- ▶ Gütegarantie: Ergebnis  
max. 50% schlechter

### Nachteile

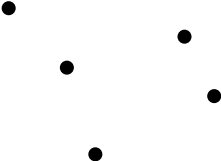
- ▶ Schlechter als RMST
- ▶ Vielfaches langsamer als HPWL
- ▶ Nicht differenzierbar

# Vergleich HPWL – RMST – RSMT




TECHNISCHE  
UNIVERSITÄT  
DARMSTADT


Unverbundenes  
Netz




# Vergleich HPWL – RMST – RSMT



# Vergleich HPWL – RMST – RSMT



# Vergleich HPWL – RMST – RSMT





# Nichtlineare Metriken

## Quadratische Verdrahtungslänge



- ▶ 2-Norm basiert, allerdings ohne Wurzel und mit Faktor

$$QWL = \frac{1}{2}((x_i - x_j)^2 + (y_i - y_j)^2)$$

# Nichtlineare Metriken

## Quadratische Verdrahtungslänge



- ▶ 2-Norm basiert, allerdings ohne Wurzel und mit Faktor

$$QWL = \frac{1}{2}((x_i - x_j)^2 + (y_i - y_j)^2)$$

- ▶ Da oft mit Ableitung gearbeitet wird: Faktor von  $\frac{1}{2}$

# Nichtlineare Metriken

## Quadratische Verdrahtungslänge

- ▶ 2-Norm basiert, allerdings ohne Wurzel und mit Faktor

$$QWL = \frac{1}{2}((x_i - x_j)^2 + (y_i - y_j)^2)$$

- ▶ Da oft mit Ableitung gearbeitet wird: Faktor von  $\frac{1}{2}$

# Nichtlineare Metriken

## Quadratische Verdrahtungslänge

- ▶ 2-Norm basiert, allerdings ohne Wurzel und mit Faktor

$$QWL = \frac{1}{2}((x_i - x_j)^2 + (y_i - y_j)^2)$$

- ▶ Da oft mit Ableitung gearbeitet wird: Faktor von  $\frac{1}{2}$

## Vorteile

- ▶ Differenzierbar
- ▶ Konvex

# Nichtlineare Metriken

## Quadratische Verdrahtungslänge

- ▶ 2-Norm basiert, allerdings ohne Wurzel und mit Faktor

$$QWL = \frac{1}{2}((x_i - x_j)^2 + (y_i - y_j)^2)$$

- ▶ Da oft mit Ableitung gearbeitet wird: Faktor von  $\frac{1}{2}$

### Vorteile

- ▶ Differenzierbar
- ▶ Konvex

### Nachteile

- ▶ Weicht von linearer ( $p = 1$ ) Norm ab  $\Rightarrow$  Funktion linearisieren (z.B. Star+)

# Nichtlineare Metriken

## Log-Summe-Exp-Verdrahtungslänge (LSE)



- ▶ Logarithmus-Summe-Exponentialfunktion:

$$LSE(z_i) = \alpha \left( \log \left( \sum_i e^{\frac{z_i}{\alpha}} \right) \right)$$

# Nichtlineare Metriken

## Log-Summe-Exp-Verdrahtungslänge (LSE)



- ▶ Logarithmus-Summe-Exponentialfunktion:

$$LSE(z_i) = \alpha(\log(\sum_i e^{\frac{z_i}{\alpha}}))$$

- ▶ Approximation der max-Funktion

# Nichtlineare Metriken

## Log-Summe-Exp-Verdrahtungslänge (LSE)



- ▶ Logarithmus-Summe-Exponentialfunktion:

$$LSE(z_i) = \alpha(\log(\sum_i e^{\frac{z_i}{\alpha}}))$$

- ▶ Approximation der max-Funktion
- ▶  $\alpha$  Genauigkeit der Approximation



# Nichtlineare Metriken

## Log-Summe-Exp-Verdrahtungslänge (LSE)



- ▶ Logarithmus-Summe-Exponentialfunktion:

$$LSE(z_i) = \alpha(\log(\sum_i e^{\frac{z_i}{\alpha}}))$$

- ▶ Approximation der max-Funktion
- ▶  $\alpha$  Genauigkeit der Approximation
- ▶ Für  $\alpha \rightarrow 0$ : LSE konvergiert gegen max

# Nichtlineare Metriken

## Log-Summe-Exp-Verdrahtungslänge (LSE)

- ▶ Logarithmus-Summe-Exponentialfunktion:

$$LSE(z_i) = \alpha \left( \log \left( \sum_i e^{\frac{z_i}{\alpha}} \right) \right)$$

- ▶ Approximation der max-Funktion
- ▶  $\alpha$  Genauigkeit der Approximation
- ▶ Für  $\alpha \rightarrow 0$ : LSE konvergiert gegen max
- ▶ Approximiert somit HPWL

$$\alpha \times \left( \left( \log \left( \sum_i e^{\frac{x_i}{\alpha}} \right) \right) + \left( \log \left( \sum_i e^{\frac{-x_i}{\alpha}} \right) \right) + \left( \log \left( \sum_i e^{\frac{y_i}{\alpha}} \right) \right) + \left( \log \left( \sum_i e^{\frac{-y_i}{\alpha}} \right) \right) \right)$$

# Nichtlineare Metriken

## Log-Summe-Exp-Verdrahtungslänge (LSE)

- ▶ Logarithmus-Summe-Exponentialfunktion:

$$LSE(z_i) = \alpha \left( \log \left( \sum_i e^{\frac{z_i}{\alpha}} \right) \right)$$

- ▶ Approximation der max-Funktion
- ▶  $\alpha$  Genauigkeit der Approximation
- ▶ Für  $\alpha \rightarrow 0$ : LSE konvergiert gegen max
- ▶ Approximiert somit HPWL

$$\alpha \times \left( \left( \log \left( \sum_i e^{\frac{x_i}{\alpha}} \right) \right) + \left( \log \left( \sum_i e^{\frac{-x_i}{\alpha}} \right) \right) + \left( \log \left( \sum_i e^{\frac{y_i}{\alpha}} \right) \right) + \left( \log \left( \sum_i e^{\frac{-y_i}{\alpha}} \right) \right) \right)$$

- ▶ Differenzierbar und konvex

# (Nicht)lineare Metriken

## Netze mit mehr als 2 Pins



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ *Auflösen* des Multi-Pin-Netzes in mehrere 2-Pin-Netze

# (Nicht)lineare Metriken

## Netze mit mehr als 2 Pins



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ *Auflösen* des Multi-Pin-Netzes in mehrere 2-Pin-Netze  
**Cliquen Modell** Netz wird durch vollständigen Teilgraphen (Clique) ersetzt

# (Nicht)lineare Metriken

## Netze mit mehr als 2 Pins

- ▶ *Auflösen* des Multi-Pin-Netzes in mehrere 2-Pin-Netze
  - Cliquen Modell** Netz wird durch vollständigen Teilgraphen (Clique) ersetzt
  - Stern Modell** Netz wird durch zusätzlichen Knoten und 2-Pin-Netze zu diesen Stern-Knoten ersetzt

# (Nicht)lineare Metriken

## Netze mit mehr als 2 Pins

- ▶ *Auflösen* des Multi-Pin-Netzes in mehrere 2-Pin-Netze
  - Cliquen Modell** Netz wird durch vollständigen Teilgraphen (Clique) ersetzt
  - Stern Modell** Netz wird durch zusätzlichen Knoten und 2-Pin-Netze zu diesen Stern-Knoten ersetzt
  - Hybrid Modell** Bis 4 Pins Clique Modell,  $> 4$  Stern Modell



- ▶ Basierend auf Stern-Netzmodell:  
Multipin-Netz wird ersetzt durch fiktiven Knoten und alle Pins verbinden zu diesem





- ▶ Basierend auf Stern-Netzmodell:  
Multipin-Netz wird ersetzt durch fiktiven Knoten und alle Pins verbinden zu diesem
- ▶ Fast lineare Funktion

- ▶ Basierend auf Stern-Netzmodell:  
Multipin-Netz wird ersetzt durch fiktiven Knoten und alle Pins verbinden zu diesem
- ▶ Fast lineare Funktion
- ▶ **Schnell**: Nach Zügen ein Update in  $\mathcal{O}(1)$  möglich

- ▶ Basierend auf Stern-Netzmodell:  
Multipin-Netz wird ersetzt durch fiktiven Knoten und alle Pins verbinden zu diesem

- ▶ Fast lineare Funktion

- ▶ **Schnell:** Nach Zügen ein Update in  $\mathcal{O}(1)$  möglich

- ▶ Schwerpunkt  $x_g$  für Netz  $l$  mit  $k_l$  Blocks

$$x_g := \frac{1}{k_l} \sum_{i \in \text{Netz}_l} x_i$$

$$\|\text{Netz}_l\|_x := \gamma \sqrt{\sum_{i \in \text{Netz}_l} (x_i - x_g)^2} + \phi$$

$\phi$  Konstante  $> 0$ , so dass es immer diff'bar

$\gamma$  Faktor zur Kompensation von Unterschätzung

- ▶ Basierend auf Stern-Netzmodell:  
Multipin-Netz wird ersetzt durch fiktiven Knoten und alle Pins verbinden zu diesem

- ▶ Fast lineare Funktion
- ▶ **Schnell:** Nach Zügen ein Update in  $\mathcal{O}(1)$  möglich
- ▶ Schwerpunkt  $x_g$  für Netz  $l$  mit  $k_l$  Blocks

$$x_g := \frac{1}{k_l} \sum_{i \in \text{Netz}_l} x_i$$

$$\|\text{Netz}_l\|_x := \gamma \sqrt{\sum_{i \in \text{Netz}_l} (x_i - x_g)^2 + \phi}$$

$\phi$  Konstante  $> 0$ , so dass es immer diff'bar

$\gamma$  Faktor zur Kompensation von Unterschätzung

- ▶  $y$ -Koordinate analog

- ▶ Basierend auf Stern-Netzmodell:  
Multipin-Netz wird ersetzt durch fiktiven Knoten und alle Pins verbinden zu diesem
- ▶ Fast lineare Funktion
- ▶ **Schnell**: Nach Zügen ein Update in  $\mathcal{O}(1)$  möglich
- ▶ Schwerpunkt  $x_g$  für Netz  $l$  mit  $k_l$  Blocks
$$x_g := \frac{1}{k_l} \sum_{i \in \text{Netz}_l} x_i$$
$$\|\text{Netz}_l\|_x := \gamma \sqrt{\sum_{i \in \text{Netz}_l} (x_i - x_g)^2 + \phi}$$
 $\phi$  Konstante  $> 0$ , so dass es immer diff'bar  
 $\gamma$  Faktor zur Kompensation von Unterschätzung
- ▶  $y$ -Koordinate analog
- ▶ Unterschied zu normalem Stern-Modell:  $\sqrt{\dots + \phi}$

- **Schnell:** Nach Veränderung von einzelnen Positionen ist ein Update in  $\mathcal{O}(1)$  möglich

$$\|\text{Netz}_l\|_x = \gamma \sqrt{\sum_{i \in \text{Netz}_l} (x_i - x_g)^2 + \phi} = \gamma \sqrt{\sum_{i \in \text{Netz}_l} x_i^2 - k_l x_g^2 + \phi}$$

- **Schnell:** Nach Veränderung von einzelnen Positionen ist ein Update in  $\mathcal{O}(1)$  möglich

$$\|\text{Netz}_l\|_x = \gamma \sqrt{\sum_{i \in \text{Netz}_l} (x_i - x_g)^2 + \phi} = \gamma \sqrt{\sum_{i \in \text{Netz}_l} x_i^2 - k_l x_g^2 + \phi}$$

- **Schnell:** Nach Veränderung von einzelnen Positionen ist ein Update in  $\mathcal{O}(1)$  möglich

$$\|\text{Netz}_l\|_x = \gamma \sqrt{\sum_{i \in \text{Netz}_l} (x_i - x_g)^2 + \phi} = \gamma \sqrt{\sum_{i \in \text{Netz}_l} x_i^2 - k_l x_g^2 + \phi}$$

$$U_l := \sum_{i \in \text{Netz}_l} x_i^2, V_l := \sum_{i \in \text{Netz}_l} x_i = k_l x_g$$



- **Schnell:** Nach Veränderung von einzelnen Positionen ist ein Update in  $\mathcal{O}(1)$  möglich

$$\|\text{Netz}_l\|_x = \gamma \sqrt{\sum_{i \in \text{Netz}_l} (x_i - x_g)^2 + \phi} = \gamma \sqrt{\sum_{i \in \text{Netz}_l} x_i^2 - k_l x_g^2 + \phi}$$

$$U_l := \sum_{i \in \text{Netz}_l} x_i^2, V_l := \sum_{i \in \text{Netz}_l} x_i = k_l x_g$$

$$\|\text{Netz}_l\|_x = \gamma \sqrt{U_l - \frac{V_l^2}{k_l} + \phi}$$

- ▶ **Schnell:** Nach Veränderung von einzelnen Positionen ist ein Update in  $\mathcal{O}(1)$  möglich

$$\| \text{Netz}_l \|_x = \gamma \sqrt{\sum_{i \in \text{Netz}_l} (x_i - x_g)^2 + \phi} = \gamma \sqrt{\sum_{i \in \text{Netz}_l} x_i^2 - k_l x_g^2 + \phi}$$

$$U_l := \sum_{i \in \text{Netz}_l} x_i^2, V_l := \sum_{i \in \text{Netz}_l} x_i = k_l x_g$$

$$\| \text{Netz}_l \|_x = \gamma \sqrt{U_l - \frac{V_l^2}{k_l} + \phi}$$

Block  $b \in \text{Netz}_l$  wird bewegt, dann Update in  $\mathcal{O}(1)$

$$U_l^{\text{new}} = U_l - x_b^2 + (x_b^{\text{new}})^2$$

$$V_l^{\text{new}} = V_l - x_b + x_b^{\text{new}}$$

# Verbesserung der Kostenfunktion

## Gewichtete Netzkosten



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Bisher: Jedes Netz gleich behandelt

# Verbesserung der Kostenfunktion

## Gewichtete Netzkosten



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Bisher: Jedes Netz gleich behandelt
- ▶ Gesamtkosten =  $\sum$  Netzkosten

# Verbesserung der Kostenfunktion

## Gewichtete Netzkosten

- ▶ Bisher: Jedes Netz gleich behandelt
- ▶ Gesamtkosten =  $\sum$  Netzkosten
- ▶ Verbesserung: Gewichtung einzelner Teilnetze bzgl. bestimmter (anderer) Optimierungsziele

# Verbesserung der Kostenfunktion

## Gewichtete Netzkosten

- ▶ Bisher: Jedes Netz gleich behandelt
- ▶ Gesamtkosten =  $\sum$  Netzkosten
- ▶ Verbesserung: Gewichtung einzelner Teilnetze bzgl. bestimmter (anderer) Optimierungsziele
- ▶ Nun: Gesamtkosten =  $\sum c_i(\dots) \cdot$  Netzkosten

# Verbesserung der Kostenfunktion

## Gewichtete Netzkosten

- ▶ Bisher: Jedes Netz gleich behandelt
- ▶ Gesamtkosten =  $\sum$  Netzkosten
- ▶ Verbesserung: Gewichtung einzelner Teilnetze bzgl. bestimmter (anderer) Optimierungsziele
- ▶ Nun: Gesamtkosten =  $\sum c_i(\dots) \cdot$  Netzkosten
- ▶ Gewicht für jedes Netz muß separat bestimmt/berechnet werden



- ▶ Im folgenden





- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)



- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:



- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:
    - ▶ Zur Lösung der NP-Vollständigen Probleme



- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:
    - ▶ Zur Lösung der NP-Vollständigen Probleme
    - ▶ Bestimmung einer nicht optimalen (aber hoffentlich guten) Lösung



- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:
    - ▶ Zur Lösung der NP-Vollständigen Probleme
    - ▶ Bestimmung einer nicht optimalen (aber hoffentlich guten) Lösung
    - ▶ Bei nicht exponentieller Laufzeit

- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:
    - ▶ Zur Lösung der NP-Vollständigen Probleme
    - ▶ Bestimmung einer nicht optimalen (aber hoffentlich guten) Lösung
    - ▶ Bei nicht exponentieller Laufzeit
  - ▶ Einige **exakte** mathematische Optimierungsalgorithmen:

- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:
    - ▶ Zur Lösung der NP-Vollständigen Probleme
    - ▶ Bestimmung einer nicht optimalen (aber hoffentlich guten) Lösung
    - ▶ Bei nicht exponentieller Laufzeit
  - ▶ Einige **exakte** mathematische Optimierungsalgorithmen:
    - ▶ Oft vereinfachtes Modell  $\Rightarrow$  Nicht exponentielle Laufzeit

- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:
    - ▶ Zur Lösung der NP-Vollständigen Probleme
    - ▶ Bestimmung einer nicht optimalen (aber hoffentlich guten) Lösung
    - ▶ Bei nicht exponentieller Laufzeit
  - ▶ Einige **exakte** mathematische Optimierungsalgorithmen:
    - ▶ Oft vereinfachtes Modell  $\Rightarrow$  Nicht exponentielle Laufzeit
    - ▶ Nur für sehr kleine Problemgrößen (bei NP-Vollständigen Algorithmen)



- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:
    - ▶ Zur Lösung der NP-Vollständigen Probleme
    - ▶ Bestimmung einer nicht optimalen (aber hoffentlich guten) Lösung
    - ▶ Bei nicht exponentieller Laufzeit
  - ▶ Einige **exakte** mathematische Optimierungsalgorithmen:
    - ▶ Oft vereinfachtes Modell  $\Rightarrow$  Nicht exponentielle Laufzeit
    - ▶ Nur für sehr kleine Problemgrößen (bei NP-Vollständigen Algorithmen)
- ▶ Später:



- ▶ Im folgenden
  - ▶ Beispiel: Abstraktes vereinfachtes Platzierungsproblem (UPP)
  - ▶ Einige **heuristische** mathematische Optimierungsalgorithmen:
    - ▶ Zur Lösung der NP-Vollständigen Probleme
    - ▶ Bestimmung einer nicht optimalen (aber hoffentlich guten) Lösung
    - ▶ Bei nicht exponentieller Laufzeit
  - ▶ Einige **exakte** mathematische Optimierungsalgorithmen:
    - ▶ Oft vereinfachtes Modell  $\Rightarrow$  Nicht exponentielle Laufzeit
    - ▶ Nur für sehr kleine Problemgrößen (bei NP-Vollständigen Algorithmen)
- ▶ Später:
  - ▶ Konkrete Varianten/Implementierungen einzelner Verfahren

# Beispielanwendung

## Unit-Size Placement Problem (UPP)



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

### Eingabe

- ▶  $1 \times 1$  Zellen
- ▶ Netzliste

# Beispielanwendung

## Unit-Size Placement Problem (UPP)



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

### Eingabe

- ▶  $1 \times 1$  Zellen
- ▶ Netzliste

### Platziere Zellen

- ▶ Auf  $1 \times 1$  Raster
- ▶ Überlappungsfrei

# Beispielanwendung

## Unit-Size Placement Problem (UPP)

### Eingabe


- ▶  $1 \times 1$  Zellen
- ▶ Netzliste

### Platziere Zellen

- ▶ Auf  $1 \times 1$  Raster
- ▶ Überlappungsfrei

### Minimiere Fläche

- ▶ Platz für Verdrahtung



$n_1$ : A, B, F, G

$n_2$ : B, E

$n_3$ : D, E


$n_4$ : A, C, D

$n_5$ : C, D, F


$n_6$ : C, E, F, G

$n_7$ : D, F


$n_8$ : F, G




Gute Platzierung mit Verdrahtung




Gute Platzierung mit Verdrahtung



Schlechte Platzierung  
Mehr Verdrahtungsspuren



Gute Platzierung mit Verdrahtung



Schlechte Platzierung  
Mehr Verdrahtungsspuren

Problem: Bestimmung der Qualität

- ▶ Komplette Verdrahtung dauert zu lange
- ▶ Abschätzen



# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problemspezifisch

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar
  - ▶ Vollständige Lösung

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar
  - ▶ Vollständige Lösung
    - ▶ Alle Unbekannten haben (immer) gültige Werte

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar
  - ▶ Vollständige Lösung
    - ▶ Alle Unbekannten haben (immer) gültige Werte
    - ▶ Algorithmus könnte beliebig beendet werden

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar
  - ▶ Vollständige Lösung
    - ▶ Alle Unbekannten haben (immer) gültige Werte
    - ▶ Algorithmus könnte beliebig beendet werden
  - ⇒ Hat ggf. nur eine schlechtere Lösung

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar
  - ▶ Vollständige Lösung
    - ▶ Alle Unbekannten haben (immer) gültige Werte
    - ▶ Algorithmus könnte beliebig beendet werden
    - ⇒ Hat ggf. nur eine schlechtere Lösung
  - ▶ Unvollständige Lösung



# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*

- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar
  - ▶ Vollständige Lösung
    - ▶ Alle Unbekannten haben (immer) gültige Werte
    - ▶ Algorithmus könnte beliebig beendet werden
    - ⇒ Hat ggf. nur eine schlechtere Lösung
  - ▶ Unvollständige Lösung
    - ▶ Einige/Alle Unbekannte sind noch unbestimmt oder ungültig

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar
  - ▶ Vollständige Lösung
    - ▶ Alle Unbekannten haben (immer) gültige Werte
    - ▶ Algorithmus könnte beliebig beendet werden
    - ⇒ Hat ggf. nur eine schlechtere Lösung
  - ▶ Unvollständige Lösung
    - ▶ Einige/Alle Unbekannte sind noch unbestimmt oder ungültig
    - ▶ Algorithmus muß weiter rechnen

# Heuristische Optimierungsalgorithmen

## Darstellung einer *Lösung*



- ▶ Problemspezifisch
- ▶ Algorithmusspezifisch
- ▶ Grundsätzlich unterscheidbar
  - ▶ Vollständige Lösung
    - ▶ Alle Unbekannten haben (immer) gültige Werte
    - ▶ Algorithmus könnte beliebig beendet werden
    - ⇒ Hat ggf. nur eine schlechtere Lösung
  - ▶ Unvollständige Lösung
    - ▶ Einige/Alle Unbekannte sind noch unbestimmt oder ungültig
    - ▶ Algorithmus muß weiter rechnen
    - ⇒ Bei vorzeitiger Beendigung gar keine Lösung



- ▶ Probleminstanz  $I = (F, c)$



- ▶ Probleminstanz  $I = (F, c)$ 
  - ▶ Lösungsraum  $F$



- ▶ Probleminstanz  $I = (F, c)$ 
  - ▶ Lösungsraum  $F$
  - ▶ Kostenfunktion  $c : F \mapsto \mathbf{R}$



- ▶ Probleminstanz  $I = (F, c)$ 
  - ▶ Lösungsraum  $F$
  - ▶ Kostenfunktion  $c : F \mapsto \mathbf{R}$
- ▶ Lösung  $\vec{f} \in F : \vec{f} = [f_1, \dots, f_n]^T$



- ▶ Probleminstanz  $I = (F, c)$ 
  - ▶ Lösungsraum  $F$
  - ▶ Kostenfunktion  $c : F \mapsto \mathbf{R}$
- ▶ Lösung  $\vec{f} \in F : \vec{f} = [f_1, \dots, f_n]^T$ 
  - ▶ Explizite Einschränkungen: Wertebereiche der  $f_i$





- ▶ Probleminstanz  $I = (F, c)$ 
  - ▶ Lösungsraum  $F$
  - ▶ Kostenfunktion  $c : F \mapsto \mathbf{R}$
- ▶ Lösung  $\vec{f} \in F : \vec{f} = [f_1, \dots, f_n]^T$ 
  - ▶ Explizite Einschränkungen: Wertebereiche der  $f_i$
  - ▶ Implizite Einschränkung: Abhängigkeiten



- ▶ Probleminstanz  $I = (F, c)$ 
  - ▶ Lösungsraum  $F$
  - ▶ Kostenfunktion  $c : F \mapsto \mathbf{R}$
- ▶ Lösung  $\vec{f} \in F : \vec{f} = [f_1, \dots, f_n]^T$ 
  - ▶ Explizite Einschränkungen: Wertebereiche der  $f_i$
  - ▶ Implizite Einschränkung: Abhängigkeiten
- ▶ Teillösung  $\vec{f}$



- ▶ Probleminstanz  $I = (F, c)$ 
  - ▶ Lösungsraum  $F$
  - ▶ Kostenfunktion  $c : F \mapsto \mathbf{R}$
- ▶ Lösung  $\vec{f} \in F : \vec{f} = [f_1, \dots, f_n]^T$ 
  - ▶ Explizite Einschränkungen: Wertebereiche der  $f_i$
  - ▶ Implizite Einschränkung: Abhängigkeiten
- ▶ Teillösung  $\vec{f}$ 
  - ▶ Einige  $f_i$  undefiniert



- ▶ Probleminstanz  $I = (F, c)$ 
  - ▶ Lösungsraum  $F$
  - ▶ Kostenfunktion  $c : F \mapsto \mathbf{R}$
- ▶ Lösung  $\vec{f} \in F : \vec{f} = [f_1, \dots, f_n]^T$ 
  - ▶ Explizite Einschränkungen: Wertebereiche der  $f_i$
  - ▶ Implizite Einschränkung: Abhängigkeiten
- ▶ Teillösung  $\vec{f}$ 
  - ▶ Einige  $f_i$  undefiniert
  - ▶ Spannt Unterraum von  $F$  auf

# Nachbarsuche Idee



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Starte mit einer vollständigen Lösung

# Nachbarsuche

## Idee



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Starte mit einer vollständigen Lösung
- ▶ Bestimme *Nachbarn* der Lösung

# Nachbarsuche

## Idee



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Starte mit einer vollständigen Lösung
- ▶ Bestimme *Nachbarn* der Lösung
  - ▶ Andere Lösungen *nahe* an existierender



- ▶ Starte mit einer vollständigen Lösung
- ▶ Bestimme *Nachbarn* der Lösung
  - ▶ Andere Lösungen *nahe* an existierender
  - ▶ Definition von *Nähe* ist problemspezifisch





- ▶ Starte mit einer vollständigen Lösung
- ▶ Bestimme *Nachbarn* der Lösung
  - ▶ Andere Lösungen *nahe* an existierender
  - ▶ Definition von *Nähe* ist problemspezifisch
- ▶ Wähle *besseren* Nachbarn aus



- ▶ Starte mit einer vollständigen Lösung
- ▶ Bestimme *Nachbarn* der Lösung
  - ▶ Andere Lösungen *nahe* an existierender
  - ▶ Definition von *Nähe* ist problemspezifisch
- ▶ Wähle *besseren* Nachbarn aus
- ▶ Wiederhole



- ▶ Problem  $I = (F, c)$

# Nachbarsuche

## Formal



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problem  $I = (F, c)$
- ▶ Lösung  $\vec{f} \in F$



- ▶ Problem  $I = (F, c)$
- ▶ Lösung  $\vec{f} \in F$
- ▶ Nachbarschaft  $N : F \mapsto 2^F$   
( $2^F$  Potenzmenge = Menge aller Teilmengen von  $F$ )



- ▶ Problem  $I = (F, c)$
- ▶ Lösung  $\vec{f} \in F$
- ▶ Nachbarschaft  $N : F \mapsto 2^F$   
( $2^F$  Potenzmenge = Menge aller Teilmengen von  $F$ )
- ▶ Nachbar  $\vec{g} \in N(\vec{f})$



- ▶ Problem  $I = (F, c)$
- ▶ Lösung  $\vec{f} \in F$
- ▶ Nachbarschaft  $N : F \mapsto 2^F$   
( $2^F$  Potenzmenge = Menge aller Teilmengen von  $F$ )
- ▶ Nachbar  $\vec{g} \in N(\vec{f})$

- ▶ Problem  $I = (F, c)$
- ▶ Lösung  $\vec{f} \in F$
- ▶ Nachbarschaft  $N : F \mapsto 2^F$   
( $2^F$  Potenzmenge = Menge aller Teilmengen von  $F$ )
- ▶ Nachbar  $\vec{g} \in N(\vec{f})$

## Beispiel UPP

- ▶  $\vec{g}$  ist Nachbar von  $\vec{f} : \Leftrightarrow \vec{g}$  ergibt sich durch Vertauschung von 2 Zellen von  $\vec{f}$ .



- ▶ Problem  $I = (F, c)$
- ▶ Lösung  $\vec{f} \in F$
- ▶ Nachbarschaft  $N : F \mapsto 2^F$   
( $2^F$  Potenzmenge = Menge aller Teilmengen von  $F$ )
- ▶ Nachbar  $\vec{g} \in N(\vec{f})$

## Beispiel UPP

- ▶  $\vec{g}$  ist Nachbar von  $\vec{f} : \Leftrightarrow \vec{g}$  ergibt sich durch Vertauschung von 2 Zellen von  $\vec{f}$ .
- ▶  $n$  Zellen,  $n - 1$  Tauschpartner  $\Rightarrow |N(\vec{f})| = \frac{n(n-1)}{2}$

- ▶ Problem  $I = (F, c)$
- ▶ Lösung  $\vec{f} \in F$
- ▶ Nachbarschaft  $N : F \mapsto 2^F$   
( $2^F$  Potenzmenge = Menge aller Teilmengen von  $F$ )
- ▶ Nachbar  $\vec{g} \in N(\vec{f})$

## Beispiel UPP

- ▶  $\vec{g}$  ist Nachbar von  $\vec{f} : \Leftrightarrow \vec{g}$  ergibt sich durch Vertauschung von 2 Zellen von  $\vec{f}$ .
- ▶  $n$  Zellen,  $n - 1$  Tauschpartner  $\Rightarrow |N(\vec{f})| = \frac{n(n-1)}{2}$
- ▶ Komplexere *Züge* möglich  
z.B. tausche 3 Zellen, tausche Regionen, ...



- ▶ Welches  $\vec{g} \in N(\vec{f})$  wählen?
- ▶ Ziel: Kostenreduzierung bezüglich  $c$
- ▶ Also wähle  $\vec{g}$  mit  $c(\vec{g}) < c(\vec{f})$
- ▶ Ende mit  $\vec{f}$  falls  $\forall \vec{g} \in N(\vec{f}) : c(\vec{g}) \geq c(\vec{f})$



Local\_search() : **begin**

Feasible\_solution f ;

Set<Feasible\_solution> G ;

f := Initial\_solution() ;

**repeat**

$G := \{g \mid g \in N(f) \wedge c(g) < c(f)\}$  ;

**if**  $G \neq \emptyset$  **then**

        f := G.pickany()

**until**  $G = \emptyset$ ;

report(f) ;

▶ Initialisierung:



Local\_search() : **begin**

Feasible\_solution f ;

Set<Feasible\_solution> G ;

f := Initial\_solution() ;

**repeat**

    G := {g | g ∈ N(f) ∧ c(g) < c(f)} ;

**if** G ≠ ∅ **then**

        f := G.pickany()

**until** G = ∅;

report(f) ;

- ▶ Initialisierung: Initial\_solution? Zufällig, triviale Lösung
- ▶ Strategien: pickany?



Local\_search() : **begin**

Feasible\_solution f ;

Set<Feasible\_solution> G ;

f := Initial\_solution() ;

**repeat**

$G := \{g \mid g \in N(f) \wedge c(g) < c(f)\}$  ;

**if**  $G \neq \emptyset$  **then**

        f := G.pickany()

**until**  $G = \emptyset$ ;

report(f) ;

- ▶ Initialisierung: Initial\_solution? Zufällig, triviale Lösung
- ▶ Strategien: pickany? Erste Verbesserung, Steilster Abstieg




- ▶ *Form der Kostenfunktion:*




- ▶ *Form* der Kostenfunktion:




- ▶ *Form* der Kostenfunktion:



► *Form* der Kostenfunktion:




Gut geeignet




Schlecht geeignet

- ▶ *Form* der Kostenfunktion:




Gut geeignet

- ▶ Steckenbleiben in lokalen Minima




Schlecht geeignet

- ▶ *Form* der Kostenfunktion:




Gut geeignet

- ▶ Steckenbleiben in lokalen Minima
- ▶ Mögliche Lösungen:




Schlecht geeignet

- ▶ *Form* der Kostenfunktion:




Gut geeignet

- ▶ Steckenbleiben in lokalen Minima
- ▶ Mögliche Lösungen:
  - ▶ Mehrere Läufe mit anderen Startlösungen




Schlecht geeignet

- ▶ *Form der Kostenfunktion:*




Gut geeignet




Schlecht geeignet

- ▶ Steckenbleiben in lokalen Minima
- ▶ Mögliche Lösungen:
  - ▶ Mehrere Läufe mit anderen Startlösungen
  - ▶ Größere Nachbarschaft

- ▶ *Form* der Kostenfunktion:



Gut geeignet



Schlecht geeignet

- ▶ Steckenbleiben in lokalen Minima
- ▶ Mögliche Lösungen:
  - ▶ Mehrere Läufe mit anderen Startlösungen
  - ▶ Größere Nachbarschaft
  - ▶ Adaptiere Größe der Nachbarschaft

# Simulated Annealing

## Idee



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Akzeptiere verschlechternde Züge  
Aber bessere Strategie als reiner Zufall



# Simulated Annealing

## Idee



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Akzeptiere verschlechternde Züge  
Aber bessere Strategie als reiner Zufall
- ▶ Simulated Annealing

# Simulated Annealing

## Idee



- ▶ Akzeptiere verschlechternde Züge  
Aber bessere Strategie als reiner Zufall
- ▶ Simulated Annealing
  - ▶ Simuliertes Erstarren von Metallen

# Simulated Annealing

## Idee



- ▶ Akzeptiere verschlechternde Züge  
Aber bessere Strategie als reiner Zufall
- ▶ Simulated Annealing
  - ▶ Simuliertes Erstarren von Metallen
  - ▶ Inspiriert von physikalischen Erstarrungsprozessen

# Simulated Annealing

## Idee



- ▶ Akzeptiere verschlechternde Züge  
Aber bessere Strategie als reiner Zufall
- ▶ Simulated Annealing
  - ▶ Simuliertes Erstarren von Metallen
  - ▶ Inspiriert von physikalischen Erstarrungsprozessen
    - ▶ Schnelles Erstarren (*Schockfrosten*)  
Hohe innere Spannung = hohe innere Energie

# Simulated Annealing

## Idee

- ▶ Akzeptiere verschlechternde Züge  
Aber bessere Strategie als reiner Zufall
- ▶ Simulated Annealing
  - ▶ Simuliertes Erstarren von Metallen
  - ▶ Inspiriert von physikalischen Erstarrungsprozessen
    - ▶ Schnelles Erstarren (*Schockfrosten*)  
Hohe innere Spannung = hohe innere Energie
    - ▶ Langsames Abkühlen Niedrige innere Spannung = niedrige innere Energie

# Simulated Annealing

## Physikalischer Hintergrund



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Hohe Anfangstemperatur (flüssiges Material)

# Simulated Annealing

## Physikalischer Hintergrund



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Hohe Anfangstemperatur (flüssiges Material)
- ▶ Moleküle können sich frei anordnen

# Simulated Annealing

## Physikalischer Hintergrund



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Hohe Anfangstemperatur (flüssiges Material)
- ▶ Moleküle können sich frei anordnen
- ▶ Langsames Abkühlen



# Simulated Annealing

## Physikalischer Hintergrund



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Hohe Anfangstemperatur (flüssiges Material)
- ▶ Moleküle können sich frei anordnen
- ▶ Langsames Abkühlen
- ▶ Bewegungsfreiheit wird schrittweise weiter eingeschränkt

# Simulated Annealing

## Physikalischer Hintergrund



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Hohe Anfangstemperatur (flüssiges Material)
- ▶ Moleküle können sich frei anordnen
- ▶ Langsames Abkühlen
- ▶ Bewegungsfreiheit wird schrittweise weiter eingeschränkt
- ▶ Moleküle ordnen sich in Konfiguration niedrigster Energie an

# Simulated Annealing

## Physikalischer Hintergrund



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Hohe Anfangstemperatur (flüssiges Material)
- ▶ Moleküle können sich frei anordnen
- ▶ Langsames Abkühlen
- ▶ Bewegungsfreiheit wird schrittweise weiter eingeschränkt
- ▶ Moleküle ordnen sich in Konfiguration niedrigster Energie an
- ▶ Am besten bei sehr langsamer Abkühlung

# Simulated Annealing für die Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Energie entspricht Kostenfunktion

# Simulated Annealing für die Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Energie entspricht Kostenfunktion
- ▶ Bewegung der Moleküle entspricht Zügen

# Simulated Annealing für die Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Energie entspricht Kostenfunktion
- ▶ Bewegung der Moleküle entspricht Zügen
- ▶ Temperatur entspricht Kontrollparameter  $T$

# Simulated Annealing für die Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Energie entspricht Kostenfunktion
- ▶ Bewegung der Moleküle entspricht Zügen
- ▶ Temperatur entspricht Kontrollparameter  $T$ 
  - ▶ Wie frei dürfen sich Moleküle bewegen?  
= Welche Züge sind noch akzeptabel?

# Simulated Annealing für die Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Energie entspricht Kostenfunktion
- ▶ Bewegung der Moleküle entspricht Zügen
- ▶ Temperatur entspricht Kontrollparameter  $T$ 
  - ▶ Wie frei dürfen sich Moleküle bewegen?  
= Welche Züge sind noch akzeptabel?
  - ▶ Niedrigere Energie/Kosten: Immer akzeptiert  
 $c(\vec{g}) \leq c(\vec{f})$





- ▶ Energie entspricht Kostenfunktion
- ▶ Bewegung der Moleküle entspricht Zügen
- ▶ Temperatur entspricht Kontrollparameter  $T$ 
  - ▶ Wie frei dürfen sich Moleküle bewegen?  
= Welche Züge sind noch akzeptabel?
  - ▶ Niedrigere Energie/Kosten: Immer akzeptiert  
 $c(\vec{g}) \leq c(\vec{f})$
  - ▶ Höhere Energie/Kosten:  
Akzeptiert mit Wahrscheinlichkeit  $e^{\frac{-\Delta c}{T}}$  mit  $\Delta c = c(\vec{g}) - c(\vec{f})$

# Simulated Annealing

## Temperatur



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

$$e^{\frac{-\Delta c}{T}} = \frac{1}{e^{\frac{\Delta c}{T}}}$$

- ▶ Hohe Temperaturen  
Akzeptiere fast alle schlechten Züge

# Simulated Annealing

## Temperatur

$$e^{\frac{-\Delta c}{T}} = \frac{1}{e^{\frac{\Delta c}{T}}}$$

- ▶ Hohe Temperaturen  
Akzeptiere fast alle schlechten Züge
- ▶ Niedrige Temperaturen  
Akzeptiere fast keine schlechten Züge mehr

# Simulated Annealing

## Temperatur

$$e^{\frac{-\Delta c}{T}} = \frac{1}{e^{\frac{\Delta c}{T}}}$$

- ▶ Hohe Temperaturen  
Akzeptiere fast alle schlechten Züge
- ▶ Niedrige Temperaturen  
Akzeptiere fast keine schlechten Züge mehr
- ▶ Physik: Boltzmann-Verteilung  
Statistische Mechanik

# Simulated Annealing Algorithmus



```
Simulated_annealing(): begin
```

```
    Feasible_solution f, g, bsf ;
```

```
    float T ;
```

```
    T := Initial_temperature() ;
```

```
    f := Initial_solution() ;
```

```
    bsf := f ;
```

```
    repeat
```

```
        repeat
```

```
            g := N(f).pickany() ;
```

```
            if Accept(f, g) then f := g ;
```

```
        until Thermal_equilibrium(T);
```

```
        T := New_temperature(T) ;
```

```
    until Stop();
```

```
    report(bsf) ;
```

```
int Accept(Feasible_solution f, g):
```

```
    begin
```

```
        float DeltaC ;
```

```
        DeltaC := c(g) - c(f) ;
```

```
        if DeltaC ≤ 0 then
```

```
            if c(g) < c(bsf) then bsf := g ;
```

```
            return (1);
```

```
        else
```

```
            return (exp(-DeltaC/T) >
```

```
                random(1))
```

# Simulated Annealing

## Zusätzliche Funktionen

`Initial_temperature()`

Bestimmt ausreichend hohe Starttemperatur

`Initial_solution()`

- ▶ Bestimmt Startlösung
- ▶ Zufällige, aber gültige Lösung OK!

`Thermal_equilibrium()`

Gleichgewicht auf einer Temperaturstufe

`New_temperature()`

Bestimmt nächsten Temperaturschritt

`Stop()`

Abbruchkriterium

**BSF:** *Best so far*

- ▶ Beste bisherige Lösung
- ▶ Letzte Lösung ist nicht immer die beste!



- ▶ Bei geeigneter Cooling Schedule



- ▶ Bei geeigneter Cooling Schedule
  - ▶ SA findet immer die optimale Lösung





- ▶ Bei geeigneter Cooling Schedule
  - ▶ SA findet immer die optimale Lösung
  - ▶ Praktisch aber nicht relevant (zu langsam)



- ▶ Bei geeigneter Cooling Schedule
  - ▶ SA findet immer die optimale Lösung
  - ▶ Praktisch aber nicht relevant (zu langsam)
- ▶ Viele Variationsmöglichkeiten



- ▶ Bei geeigneter Cooling Schedule
  - ▶ SA findet immer die optimale Lösung
  - ▶ Praktisch aber nicht relevant (zu langsam)
- ▶ Viele Variationsmöglichkeiten
  - ▶ stop() abhängig von accept()



- ▶ Bei geeigneter Cooling Schedule
  - ▶ SA findet immer die optimale Lösung
  - ▶ Praktisch aber nicht relevant (zu langsam)
- ▶ Viele Variationsmöglichkeiten
  - ▶ stop() abhängig von accept()
  - ▶ Adaptive Cooling Schedules



- ▶ Bei geeigneter Cooling Schedule
  - ▶ SA findet immer die optimale Lösung
  - ▶ Praktisch aber nicht relevant (zu langsam)
- ▶ Viele Variationsmöglichkeiten
  - ▶ stop() abhängig von accept()
  - ▶ Adaptive Cooling Schedules
- ▶ Bibliotheken: ASA, EBSA



- ▶ Bei geeigneter Cooling Schedule
  - ▶ SA findet immer die optimale Lösung
  - ▶ Praktisch aber nicht relevant (zu langsam)
- ▶ Viele Variationsmöglichkeiten
  - ▶ stop() abhängig von accept()
  - ▶ Adaptive Cooling Schedules
- ▶ Bibliotheken: ASA, EBSA
- ▶ SA ist allgemein verwendbar



- ▶ Bei geeigneter Cooling Schedule
  - ▶ SA findet immer die optimale Lösung
  - ▶ Praktisch aber nicht relevant (zu langsam)
- ▶ Viele Variationsmöglichkeiten
  - ▶ stop() abhängig von accept()
  - ▶ Adaptive Cooling Schedules
- ▶ Bibliotheken: ASA, EBSA
- ▶ SA ist allgemein verwendbar
- ▶ Aber: Spezialisierte Lösungen sind besser



- ▶ Simulated Annealing





- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden immer akzeptiert



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden immer akzeptiert
  - ▶ Gehe immer zu  $\vec{g} \in N(\vec{f})$  mit
$$c(\vec{g}) = \min_{\vec{h} \in N(\vec{f})} c(\vec{h})$$



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden immer akzeptiert
  - ▶ Gehe immer zu  $\vec{g} \in N(\vec{f})$  mit
$$c(\vec{g}) = \min_{\vec{h} \in N(\vec{f})} c(\vec{h})$$
  - ▶ Auch wenn  $c(\vec{g}) > c(\vec{f})!$



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden immer akzeptiert
  - ▶ Gehe immer zu  $\vec{g} \in N(\vec{f})$  mit
$$c(\vec{g}) = \min_{\vec{h} \in N(\vec{f})} c(\vec{h})$$
  - ▶ Auch wenn  $c(\vec{g}) > c(\vec{f})!$
  - ▶ Problem: Zyklen



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden immer akzeptiert
  - ▶ Gehe immer zu  $\vec{g} \in N(\vec{f})$  mit
$$c(\vec{g}) = \min_{\vec{h} \in N(\vec{f})} c(\vec{h})$$
  - ▶ Auch wenn  $c(\vec{g}) > c(\vec{f})!$
  - ▶ Problem: Zyklen
    - ▶ Ständige Wiederholung der letzten Züge



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden **immer** akzeptiert
  - ▶ Gehe immer zu  $\vec{g} \in N(\vec{f})$  mit
$$c(\vec{g}) = \min_{\vec{h} \in N(\vec{f})} c(\vec{h})$$
  - ▶ Auch wenn  $c(\vec{g}) > c(\vec{f})!$
  - ▶ Problem: Zyklen
    - ▶ Ständige Wiederholung der letzten Züge
- ▶ Lösung: Verbiete letzten  $k$  Lösungen





- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden immer akzeptiert
  - ▶ Gehe immer zu  $\vec{g} \in N(\vec{f})$  mit
$$c(\vec{g}) = \min_{\vec{h} \in N(\vec{f})} c(\vec{h})$$
  - ▶ Auch wenn  $c(\vec{g}) > c(\vec{f})!$
  - ▶ Problem: Zyklen
    - ▶ Ständige Wiederholung der letzten Züge
- ▶ Lösung: Verbiete letzten  $k$  Lösungen
  - ▶ Lösungen sind als *tabu* markiert



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden **immer** akzeptiert
  - ▶ Gehe immer zu  $\vec{g} \in N(\vec{f})$  mit
$$c(\vec{g}) = \min_{\vec{h} \in N(\vec{f})} c(\vec{h})$$
  - ▶ Auch wenn  $c(\vec{g}) > c(\vec{f})!$
  - ▶ Problem: Zyklen
    - ▶ Ständige Wiederholung der letzten Züge
- ▶ Lösung: Verbiete letzten  $k$  Lösungen
  - ▶ Lösungen sind als *tabu* markiert
  - ▶ Vermeidet Zyklen bis zu der Länge  $k$



- ▶ Simulated Annealing
  - ▶ Verschlechternde Züge zu Beginn akzeptiert
- ▶ Tabu-Suche (TS)
  - ▶ Verschlechternde Züge werden **immer** akzeptiert
  - ▶ Gehe immer zu  $\vec{g} \in N(\vec{f})$  mit
$$c(\vec{g}) = \min_{\vec{h} \in N(\vec{f})} c(\vec{h})$$
  - ▶ Auch wenn  $c(\vec{g}) > c(\vec{f})!$
  - ▶ Problem: Zyklen
    - ▶ Ständige Wiederholung der letzten Züge
- ▶ Lösung: Verbiete letzten  $k$  Lösungen
  - ▶ Lösungen sind als *tabu* markiert
  - ▶ Vermeidet Zyklen bis zu der Länge  $k$
  - ▶ Realisierung: FIFO mit Lösungen der Länge  $k$



Tabu\_search(): **begin**

```
Feasible_solution f, g, bsf ;
Set<Feasible_solution> G ;
FIFO<Feasible_solution,k> Q ;
f := Initial_solution(); bsf := f; Q :=  $\emptyset$  ;
repeat
  G := {s | s  $\in$  N(f)  $\wedge$  s  $\notin$  Q} ;
  if G  $\neq \emptyset$  then
    g := G.findmin(c) ;
    Q.shiftin(g) ;
    f := g ;
    if c(f) < c(bsf) then bsf := f;
until (G  $\neq \emptyset$ ) or Stop();
report(bsf);
```



- ▶ stop()  
*Keine Verbesserung in den letzten  $k$  Zügen*



- ▶ stop()  
*Keine Verbesserung in den letzten  $k$  Zügen*

## UPP-Beispiel



- ▶ stop()  
*Keine Verbesserung in den letzten  $k$  Zügen*

## UPP-Beispiel

- ▶ 10.000 Zellen Lösung beschreibt 10.000 Koordinatenpaare



- ▶ stop()  
*Keine Verbesserung in den letzten  $k$  Zügen*

## UPP-Beispiel

- ▶ 10.000 Zellen Lösung beschreibt 10.000 Koordinatenpaare
- ▶ Sehr große Tabu-Liste





- ▶ stop()

*Keine Verbesserung in den letzten  $k$  Zügen*

## UPP-Beispiel

- ▶ 10.000 Zellen Lösung beschreibt 10.000 Koordinatenpaare
- ▶ Sehr große Tabu-Liste
- ▶ Abhilfe: Setze nur einzelne Züge Tabu

- ▶ stop()  
*Keine Verbesserung in den letzten  $k$  Zügen*

## UPP-Beispiel

- ▶ 10.000 Zellen Lösung beschreibt 10.000 Koordinatenpaare
- ▶ Sehr große Tabu-Liste
- ▶ Abhilfe: Setze nur einzelne Züge Tabu
- ▶ Aber: Einschränkung des Lösungsraumes



- ▶ stop()  
*Keine Verbesserung in den letzten  $k$  Zügen*

## UPP-Beispiel

- ▶ 10.000 Zellen Lösung beschreibt 10.000 Koordinatenpaare
  - ▶ Sehr große Tabu-Liste
  - ▶ Abhilfe: Setze nur einzelne Züge Tabu
  - ▶ Aber: Einschränkung des Lösungsraumes
- 
- ▶ Viele Variationsmöglichkeiten

- ▶ stop()  
*Keine Verbesserung in den letzten  $k$  Zügen*

## UPP-Beispiel

- ▶ 10.000 Zellen Lösung beschreibt 10.000 Koordinatenpaare
  - ▶ Sehr große Tabu-Liste
  - ▶ Abhilfe: Setze nur einzelne Züge Tabu
  - ▶ Aber: Einschränkung des Lösungsraumes
- 
- ▶ Viele Variationsmöglichkeiten
    - ▶ Kein theoretischer Hintergrund Erreichen des Optimums?



- ▶ stop()  
*Keine Verbesserung in den letzten  $k$  Zügen*


## UPP-Beispiel

- ▶ 10.000 Zellen Lösung beschreibt 10.000 Koordinatenpaare
  - ▶ Sehr große Tabu-Liste
  - ▶ Abhilfe: Setze nur einzelne Züge Tabu
  - ▶ Aber: Einschränkung des Lösungsraumes
- 
- ▶ Viele Variationsmöglichkeiten
    - ▶ Kein theoretischer Hintergrund Erreichen des Optimums?
    - ▶ Wie stop() oder  $k$  wählen?

# Genetische Algorithmen

## Idee

- ▶ Inspiriert aus der Biologie




Basiert auf einem Bild der NIH

# Genetische Algorithmen

## Idee

- ▶ Inspiriert aus der Biologie
- ▶ Kodierung von Informationen in einem Chromosom




Basiert auf einem Bild der NIH

# Genetische Algorithmen

## Idee

- ▶ Inspiriert aus der Biologie
- ▶ Kodierung von Informationen in einem Chromosom
- ▶ Modifikation der Informationen durch Crossover



Basiert auf einem Bild der NIH



# Genetische Algorithmen

## Idee



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Bisher: Algorithmen arbeiten auf *einer* vollständigen Lösung

# Genetische Algorithmen

## Idee



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Bisher: Algorithmen arbeiten auf *einer* vollständigen Lösung
- ▶ Nun: Gleichzeitig auf *mehreren* Lösungen

# Genetische Algorithmen

## Idee



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Bisher: Algorithmen arbeiten auf *einer* vollständigen Lösung
- ▶ Nun: Gleichzeitig auf *mehreren* Lösungen
  - ▶ Menge  $P$  von Lösungen: Population

# Genetische Algorithmen

## Idee



- ▶ Bisher: Algorithmen arbeiten auf *einer* vollständigen Lösung
- ▶ Nun: Gleichzeitig auf *mehreren* Lösungen
  - ▶ Menge  $P$  von Lösungen: Population
  - ▶ Iterationszähler  $k$ : Generation

# Genetische Algorithmen

## Idee



- ▶ Bisher: Algorithmen arbeiten auf *einer* vollständigen Lösung
- ▶ Nun: Gleichzeitig auf *mehreren* Lösungen
  - ▶ Menge  $P$  von Lösungen: Population
  - ▶ Iterationszähler  $k$ : Generation
  - ▶ Ersetze  $P^{(k)}$  durch  $P^{(k+1)}$  während Optimierung

# Genetische Algorithmen

## Idee

- ▶ Bisher: Algorithmen arbeiten auf *einer* vollständigen Lösung
- ▶ Nun: Gleichzeitig auf *mehreren* Lösungen
  - ▶ Menge  $P$  von Lösungen: Population
  - ▶ Iterationszähler  $k$ : Generation
  - ▶ Ersetze  $P^{(k)}$  durch  $P^{(k+1)}$  während Optimierung
- ▶ Bestimmung von  $\vec{f}^{(k+1)} \in P^{(k+1)}$  mittels

- ▶ Bisher: Algorithmen arbeiten auf *einer* vollständigen Lösung
- ▶ Nun: Gleichzeitig auf *mehreren* Lösungen
  - ▶ Menge  $P$  von Lösungen: Population
  - ▶ Iterationszähler  $k$ : Generation
  - ▶ Ersetze  $P^{(k)}$  durch  $P^{(k+1)}$  während Optimierung
- ▶ Bestimmung von  $\vec{f}^{(k+1)} \in P^{(k+1)}$  mittels
  - ▶ Crossover von zwei Eltern  $\vec{f}^{(k)}, \vec{g}^{(k)} \in P^{(k)}$   
Vererbung von Eigenschaften von  $\vec{f}^{(k)}$  und  $\vec{g}^{(k)}$

- ▶ Bisher: Algorithmen arbeiten auf *einer* vollständigen Lösung
- ▶ Nun: Gleichzeitig auf *mehreren* Lösungen
  - ▶ Menge  $P$  von Lösungen: Population
  - ▶ Iterationszähler  $k$ : Generation
  - ▶ Ersetze  $P^{(k)}$  durch  $P^{(k+1)}$  während Optimierung
- ▶ Bestimmung von  $\vec{f}^{(k+1)} \in P^{(k+1)}$  mittels
  - ▶ Crossover von zwei Eltern  $\vec{f}^{(k)}, \vec{g}^{(k)} \in P^{(k)}$   
Vererbung von Eigenschaften von  $\vec{f}^{(k)}$  und  $\vec{g}^{(k)}$
  - ▶ Ggf. Mutation von  $\vec{f}^{(k+1)}$



# Genetische Algorithmen

## Darstellung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

# Genetische Algorithmen

## Darstellung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

## UPP Kodierung



- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster



- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster
  - ▶ 4 Bit pro Koordinate



- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster
  - ▶ 4 Bit pro Koordinate
  - ▶ 8 Bit pro Koordinatenpaar



- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster
  - ▶ 4 Bit pro Koordinate
  - ▶ 8 Bit pro Koordinatenpaar
  - ▶  $100 \times 8 \text{ Bit} = 800 \text{ Bit}$  lange Bitfolge als Chromosom



- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster
  - ▶ 4 Bit pro Koordinate
  - ▶ 8 Bit pro Koordinatenpaar
  - ▶  $100 \times 8$  Bit = 800 Bit lange Bitfolge als Chromosom
  - ▶  $L$  Länge des Chromosoms in Bit



- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster
  - ▶ 4 Bit pro Koordinate
  - ▶ 8 Bit pro Koordinatenpaar
  - ▶  $100 \times 8 \text{ Bit} = 800 \text{ Bit}$  lange Bitfolge als Chromosom
  - ▶  $L$  Länge des Chromosoms in Bit
- ▶ Wichtige Unterscheidung zwischen



- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster
  - ▶ 4 Bit pro Koordinate
  - ▶ 8 Bit pro Koordinatenpaar
  - ▶  $100 \times 8$  Bit = 800 Bit lange Bitfolge als Chromosom
  - ▶  $L$  Länge des Chromosoms in Bit
- ▶ Wichtige Unterscheidung zwischen  
**Lösung** Biologie: Phänotyp

- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster
  - ▶ 4 Bit pro Koordinate
  - ▶ 8 Bit pro Koordinatenpaar
  - ▶  $100 \times 8 \text{ Bit} = 800 \text{ Bit}$  lange Bitfolge als Chromosom
  - ▶  $L$  Länge des Chromosoms in Bit
- ▶ Wichtige Unterscheidung zwischen  
Lösung Biologie: Phänotyp  
Kodierung der Lösung Biologie: Genotyp



- ▶ Kodierung für Chromosom  
Bitfolge für Lösungsvektor

### UPP Kodierung

- ▶ 100 Zellen,  $10 \times 10$  Raster
  - ▶ 4 Bit pro Koordinate
  - ▶ 8 Bit pro Koordinatenpaar
  - ▶  $100 \times 8$  Bit = 800 Bit lange Bitfolge als Chromosom
  - ▶  $L$  Länge des Chromosoms in Bit
- ▶ Wichtige Unterscheidung zwischen  
Lösung Biologie: Phänotyp  
Kodierung der Lösung Biologie: Genotyp
- ▶ Hier im Beispiel äquivalent benutzt

# Genetische Algorithmen

## Vererbung mit dem Crossover-Operator



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Kombiniere die Bitfolgen der Eltern

# Genetische Algorithmen

## Vererbung mit dem Crossover-Operator



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Kombiniere die Bitfolgen der Eltern
- ▶ Verschiedene Realisierungen möglich

# Genetische Algorithmen

## Vererbung mit dem Crossover-Operator



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Kombiniere die Bitfolgen der Eltern
- ▶ Verschiedene Realisierungen möglich

### Beispiel

# Genetische Algorithmen

## Vererbung mit dem Crossover-Operator



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Kombiniere die Bitfolgen der Eltern
- ▶ Verschiedene Realisierungen möglich

### Beispiel

1. Wähle zufällig Crossover-Position  $1 \leq r \leq L$

# Genetische Algorithmen

## Vererbung mit dem Crossover-Operator



- ▶ Kombiniere die Bitfolgen der Eltern
- ▶ Verschiedene Realisierungen möglich

### Beispiel

1. Wähle zufällig Crossover-Position  $1 \leq r \leq L$
2. Kopiere Bits  $1 \dots (r - 1)$  aus  $\vec{f}^{(k)}$  nach  $\vec{f}^{(k+1)}$



# Genetische Algorithmen

## Vererbung mit dem Crossover-Operator

- ▶ Kombiniere die Bitfolgen der Eltern
- ▶ Verschiedene Realisierungen möglich

### Beispiel

1. Wähle zufällig Crossover-Position  $1 \leq r \leq L$
2. Kopiere Bits  $1 \dots (r - 1)$  aus  $\vec{f}^{(k)}$  nach  $\vec{f}^{(k+1)}$
3. Kopiere Bits  $r \dots L$  aus  $\vec{g}^{(k)}$  nach  $\vec{f}^{(k+1)}$

# Genetische Algorithmen

## Vererbung mit dem Crossover-Operator




- ▶ Kombiniere die Bitfolgen der Eltern
- ▶ Verschiedene Realisierungen möglich

### Beispiel

1. Wähle zufällig Crossover-Position  $1 \leq r \leq L$
2. Kopiere Bits  $1 \dots (r - 1)$  aus  $\vec{f}^{(k)}$  nach  $\vec{f}^{(k+1)}$
3. Kopiere Bits  $r \dots L$  aus  $\vec{g}^{(k)}$  nach  $\vec{f}^{(k+1)}$
4. Ggf. erzeuge 2. Kind  $\vec{g}^{(k+1)}$  mit vertauschten Rollen

10 × 10 Raster, platziere einzelne Zelle



# Genetische Algorithmen

## Problem



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Crossover erzeugt ungültige Lösungen

# Genetische Algorithmen

## Problem



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Crossover erzeugt ungültige Lösungen
- ⇒ Abhilfe: Mehr Struktur als einfache Bitfolge

# Genetische Algorithmen

## Problem



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Crossover erzeugt ungültige Lösungen
- ⇒ Abhilfe: Mehr Struktur als einfache Bitfolge

Bei UPP-Beispiel



- ▶ Crossover erzeugt ungültige Lösungen
- ⇒ Abhilfe: Mehr Struktur als einfache Bitfolge

### Bei UPP-Beispiel

- ▶ Folgen von 4-bit Koordinaten



- ▶ Crossover erzeugt ungültige Lösungen
- ⇒ Abhilfe: Mehr Struktur als einfache Bitfolge

### Bei UPP-Beispiel

- ▶ Folgen von 4-bit Koordinaten
- ▶ Nun zwar intern konsistente Koordinaten





- ▶ Crossover erzeugt ungültige Lösungen
- ⇒ Abhilfe: Mehr Struktur als einfache Bitfolge

### Bei UPP-Beispiel

- ▶ Folgen von 4-bit Koordinaten
- ▶ Nun zwar intern konsistente Koordinaten
- ▶ Reicht im allgemeinen Fall aber nicht aus!

- ▶ Crossover erzeugt ungültige Lösungen
- ⇒ Abhilfe: Mehr Struktur als einfache Bitfolge

### Bei UPP-Beispiel

- ▶ Folgen von 4-bit Koordinaten
- ▶ Nun zwar intern konsistente Koordinaten
- ▶ Reicht im allgemeinen Fall aber nicht aus!
- ⇒ Problemspezifisches Crossover



- ▶ Bisher noch keine Optimierung  
Nur neue Lösungen erzeugt



- ▶ Bisher noch keine Optimierung  
Nur neue Lösungen erzeugt
- ▶ Bevorzuge gute Lösungen vor schlechten



- ▶ Bisher noch keine Optimierung  
Nur neue Lösungen erzeugt
- ▶ Bevorzuge gute Lösungen vor schlechten
  - ▶ Wähle *gute* Eltern aus: Niedrige Kosten



- ▶ Bisher noch keine Optimierung  
Nur neue Lösungen erzeugt
- ▶ Bevorzuge gute Lösungen vor schlechten
  - ▶ Wähle *gute* Eltern aus: Niedrige Kosten
  - ▶ Kombiniere gute Eigenschaften in Nachwuchs



- ▶ Bisher noch keine Optimierung  
Nur neue Lösungen erzeugt
- ▶ Bevorzuge gute Lösungen vor schlechten
  - ▶ Wähle *gute* Eltern aus: Niedrige Kosten
  - ▶ Kombiniere gute Eigenschaften in Nachwuchs
  - ▶ Aber: Auch Gegenteil möglich (Crossoverposition  $r$  zufällig)



- ▶ Bisher noch keine Optimierung  
Nur neue Lösungen erzeugt
- ▶ Bevorzuge gute Lösungen vor schlechten
  - ▶ Wähle *gute* Eltern aus: Niedrige Kosten
  - ▶ Kombiniere gute Eigenschaften in Nachwuchs
  - ▶ Aber: Auch Gegenteil möglich (Crossoverposition  $r$  zufällig)
    - ▶ Vererbung schlechter Eigenschaften





- ▶ Bisher noch keine Optimierung  
Nur neue Lösungen erzeugt
- ▶ Bevorzuge gute Lösungen vor schlechten
  - ▶ Wähle *gute* Eltern aus: Niedrige Kosten
  - ▶ Kombiniere gute Eigenschaften in Nachwuchs
  - ▶ Aber: Auch Gegenteil möglich (Crossoverposition  $r$  zufällig)
    - ▶ Vererbung schlechter Eigenschaften
    - ▶ Idee: Schlechte Nachkommen sterben in nächster Generation



Genetic\_Algorithm(int popsize) : **begin**

Set<chromosome> pop, newpop ;

Chromosome parent1, parent2, child ;

pop :=  $\emptyset$  ;

**for**  $i:=1 \dots popsize$  **do** pop := pop  $\cup$  {Chromosom einer zufälligen Lösung} ;

**repeat**

    newpop :=  $\emptyset$  ;

**for**  $i:=1 \dots popsize$  **do**

        parent1 := pop.select() ; parent2 := pop.select() ;

        child := crossover(parent1, parent2) ;

        newpop := newpop  $\cup$  { child } ;

    pop := newpop;

**until** Stop();

report(pop.findmin(c));



▶ Stop()



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftkommende Fehler beim Kopieren/durch Fremdeinwirkungen



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftkommende Fehler beim Kopieren/durch Fremdeinwirkungen
  - ▶ Vermeidet Steckenbleiben in lokalen Minima





- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftretende Fehler beim Kopieren/durch Fremdeinwirkungen
  - ▶ Vermeidet Steckenbleiben in lokalen Minima
- ▶ Sehr viele Variationsmöglichkeiten



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftretende Fehler beim Kopieren/durch Fremdeinwirkungen
  - ▶ Vermeidet Steckenbleiben in lokalen Minima
- ▶ Sehr viele Variationsmöglichkeiten
  - ▶ Komplexere Crossover (mehrere  $r, \dots$ )



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftretende Fehler beim Kopieren/durch Fremdeinwirkungen
  - ▶ Vermeidet Steckenbleiben in lokalen Minima
- ▶ Sehr viele Variationsmöglichkeiten
  - ▶ Komplexere Crossover (mehrere  $r, \dots$ )
  - ▶ Zusätzliche Funktionen: Mutation, Inversion



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftretende Fehler beim Kopieren/durch Fremdeinwirkungen
  - ▶ Vermeidet Steckenbleiben in lokalen Minima
- ▶ Sehr viele Variationsmöglichkeiten
  - ▶ Komplexere Crossover (mehrere  $r, \dots$ )
  - ▶ Zusätzliche Funktionen: Mutation, Inversion
  - ▶ Mehrere Generationen gleichzeitig



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftkommende Fehler beim Kopieren/durch Fremdeinwirkungen
  - ▶ Vermeidet Steckenbleiben in lokalen Minima
- ▶ Sehr viele Variationsmöglichkeiten
  - ▶ Komplexere Crossover (mehrere  $r, \dots$ )
  - ▶ Zusätzliche Funktionen: Mutation, Inversion
  - ▶ Mehrere Generationen gleichzeitig
  - ▶ Elite-Selektion



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftretende Fehler beim Kopieren/durch Fremdeinwirkungen
  - ▶ Vermeidet Steckenbleiben in lokalen Minima
- ▶ Sehr viele Variationsmöglichkeiten
  - ▶ Komplexere Crossover (mehrere  $r, \dots$ )
  - ▶ Zusätzliche Funktionen: Mutation, Inversion
  - ▶ Mehrere Generationen gleichzeitig
  - ▶ Elite-Selektion
  - ▶ Meta-Genetische Algorithmen



- ▶ Stop()
  - ▶ Keine Verbesserung in den letzten  $m$  Iterationen
  - ▶  $m$  problemspezifischer Parameter
- ▶ Mutation
  - ▶ Modelliert in Natur auftretende Fehler beim Kopieren/durch Fremdeinwirkungen
  - ▶ Vermeidet Steckenbleiben in lokalen Minima
- ▶ Sehr viele Variationsmöglichkeiten
  - ▶ Komplexere Crossover (mehrere  $r, \dots$ )
  - ▶ Zusätzliche Funktionen: Mutation, Inversion
  - ▶ Mehrere Generationen gleichzeitig
  - ▶ Elite-Selektion
  - ▶ Meta-Genetische Algorithmen

...

**Stop():** 10.000 Generationen ohne Verbesserung der BSF-Lösung

**Initiale Population:** Anzahl: Hunderte

25% Zufällig, 75% sequentiell angeordnet

**.select():** Zufällig mit Gewichtung auf *fitness* ( $< \infty$  nie)

**Resultat:** Ähnlich gut wie TimberWolf


(Tendenziell bessere Ergebnisse auf Kosten der Laufzeit)



# Ameisenalgorithmus

## Idee


- ▶ Inspiriert von Ameisenpfaden



# Ameisenalgorithmus

## Idee


- ▶ Inspiriert von Ameisenpfaden
- ▶ Ameisen hinterlassen beim marschieren Pheromone



# Ameisenalgorithmus

## Idee


- ▶ Inspiriert von Ameisenpfaden
- ▶ Ameisen hinterlassen beim marschieren Pheromone
- ▶ Kurze Wege akkumulieren stärkere Pheromonkonzentration



# Ameisenalgorithmus

## Idee


- ▶ Inspiriert von Ameisenpfaden
  - ▶ Ameisen hinterlassen beim marschieren Pheromone
  - ▶ Kurze Wege akkumulieren stärkere Pheromonkonzentration
- ⇒ werden entsprechend attraktiver für andere Ameisen



# Ameisenalgorithmus

## Idee

- ▶ Inspiriert von Ameisenpfaden
- ▶ Ameisen hinterlassen beim marschieren Pheromone
- ▶ Kurze Wege akkumulieren stärkere Pheromonkonzentration
- ⇒ werden entsprechend attraktiver für andere Ameisen
- ▶ Agentenbasierter Ansatz: Finden von besten Wegen im Graph



# Ameisenalgorithmus

## Anwendung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

# Ameisenalgorithmus

## Anwendung

- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

# Ameisenalgorithmus

## Anwendung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen



# Ameisenalgorithmus

## Anwendung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen

$l \in L$  Orte



- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen

$l \in L$  Orte

$d(l_1, l_2)$  Distanz zwischen zwei Orten ( $d : L \times L \mapsto R$ )

# Ameisenalgorithmus

## Anwendung

- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen

$l \in L$  Orte

$d(l_1, l_2)$  Distanz zwischen zwei Orten ( $d : L \times L \mapsto R$ )

$w(f_1, f_2)$  Fluß zwischen zwei Einrichtungen ( $w : F \times F \mapsto R$ )

# Ameisenalgorithmus

## Anwendung

- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen

$l \in L$  Orte

$d(l_1, l_2)$  Distanz zwischen zwei Orten ( $d : L \times L \mapsto R$ )

$w(f_1, f_2)$  Fluß zwischen zwei Einrichtungen ( $w : F \times F \mapsto R$ )

# Ameisenalgorithmus

## Anwendung



- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen

$l \in L$  Orte

$d(l_1, l_2)$  Distanz zwischen zwei Orten ( $d : L \times L \mapsto R$ )

$w(f_1, f_2)$  Fluß zwischen zwei Einrichtungen ( $w : F \times F \mapsto R$ )

Gesucht: Zuordnung  $a : F \mapsto L$  bei der  $\sum_{f_1, f_2 \in F} w(f_1, f_2) \cdot d(a(f_1), a(f_2))$  minimal wird

# Ameisenalgorithmus

## Anwendung



- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen

$l \in L$  Orte

$d(l_1, l_2)$  Distanz zwischen zwei Orten ( $d : L \times L \mapsto R$ )

$w(f_1, f_2)$  Fluß zwischen zwei Einrichtungen ( $w : F \times F \mapsto R$ )

Gesucht: Zuordnung  $a : F \mapsto L$  bei der  $\sum_{f_1, f_2 \in F} w(f_1, f_2) \cdot d(a(f_1), a(f_2))$  minimal wird

- ▶ Lösung wird iterativ in jedem *Agenten* (Ameise) aufgebaut

# Ameisenalgorithmus

## Anwendung

- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen

$l \in L$  Orte

$d(l_1, l_2)$  Distanz zwischen zwei Orten ( $d : L \times L \mapsto R$ )

$w(f_1, f_2)$  Fluß zwischen zwei Einrichtungen ( $w : F \times F \mapsto R$ )

Gesucht: Zuordnung  $a : F \mapsto L$  bei der  $\sum_{f_1, f_2 \in F} w(f_1, f_2) \cdot d(a(f_1), a(f_2))$  minimal wird

- ▶ Lösung wird iterativ in jedem *Agenten* (Ameise) aufgebaut
- ▶ Jede Ameise läuft zufälligen Weg  
Wahrscheinlichkeit bei Weg mit vielen Pheromonen höher

# Ameisenalgorithmus

## Anwendung

- ▶ Oft benutzt bei *TSP* (Travelling-Salesman-Problem) oder QAP

## QAP (Quadratic-Assignment-Problem)

Gegeben:

$f \in F$  Einrichtungen

$l \in L$  Orte

$d(l_1, l_2)$  Distanz zwischen zwei Orten ( $d : L \times L \mapsto R$ )

$w(f_1, f_2)$  Fluß zwischen zwei Einrichtungen ( $w : F \times F \mapsto R$ )

Gesucht: Zuordnung  $a : F \mapsto L$  bei der  $\sum_{f_1, f_2 \in F} w(f_1, f_2) \cdot d(a(f_1), a(f_2))$  minimal wird

- ▶ Lösung wird iterativ in jedem *Agenten* (Ameise) aufgebaut
- ▶ Jede Ameise läuft zufälligen Weg  
Wahrscheinlichkeit bei Weg mit vielen Pheromonen höher
- ▶ Nach Konstruktion des Wege, entsprechend der Kosten Pheromongehalt der Wege aller Ameisen aktualisieren



# Ameisenalgorithmus

## UPP-Beispiel



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Zellen  $\mapsto$  Einrichtungen

# Ameisenalgorithmus

## UPP-Beispiel



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Zellen  $\mapsto$  Einrichtungen
- ▶ Orte  $\mapsto$  Positionen im Raster

# Ameisenalgorithmus

## UPP-Beispiel



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Zellen  $\mapsto$  Einrichtungen
- ▶ Orte  $\mapsto$  Positionen im Raster
- ▶ Fluß  $\mapsto$  Anzahl der adjazenten Zellen

# Ameisenalgorithmus

## UPP-Beispiel



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Zellen  $\mapsto$  Einrichtungen
- ▶ Orte  $\mapsto$  Positionen im Raster
- ▶ Fluß  $\mapsto$  Anzahl der adjazenten Zellen
- ▶ Distanz  $\mapsto$  Distanz

# Ameisenalgorithmus

## Algorithmus



Ant\_colony\_optimization:

**begin**

```
Init_heuristics() ;  
repeat  
  forall the Ants i do  
    Ant i.generate_solution()  
  Update_pheromons() ;  
until Stop();
```

Ant.generate\_solution():

**begin**

```
for NumberCells do  
  Select_cell() ;  
  Assign_cell_to_location()  
  Improve_solution() ;  
if solution < bsf then  
  bsf := solution
```

**Stop():** Abbruchkriterium: Anzahl Iterationen abhängig von Problemgröße, keine Änderung der BSF, ...

**Improve\_solution():** Lokale Suche zum verbessern des Ergebnisses

**Select\_cell():** Zufällig, feste Reihenfolge  
(z.B. sortiert nach Summe der inzidenten Flüße)

# Ameisenalgorithmus

## Initialisierung



► Heuristische Information

$$\eta_{ij} = \frac{1}{f_i \cdot d_j}$$

$f_i$  *Flußpotenzial* der Zelle (Anzahl verbundener Zellen)

$d_j$  *Distanzpotenzial* einer Position

(Summe der Distanzen zu allen anderen Positionen)

# Ameisenalgorithmus

## Initialisierung



- ▶ Heuristische Information

$$\eta_{ij} = \frac{1}{f_i \cdot d_j}$$

$f_i$  *Flußpotential* der Zelle (Anzahl verbundener Zellen)

$d_j$  *Distanzpotential* einer Position

(Summe der Distanzen zu allen anderen Positionen)

- ▶ Setzen sonstiger Parameter:

# Ameisenalgorithmus

## Initialisierung



- ▶ Heuristische Information

$$\eta_{ij} = \frac{1}{f_i \cdot d_j}$$

$f_i$  *Flußpotential* der Zelle (Anzahl verbundener Zellen)

$d_j$  *Distanzpotential* einer Position

(Summe der Distanzen zu allen anderen Positionen)

- ▶ Setzen sonstiger Parameter:

$k$  Anzahl Ameisen



# Ameisenalgorithmus

## Initialisierung



- ▶ Heuristische Information

$$\eta_{ij} = \frac{1}{f_i \cdot d_j}$$

$f_i$  *Flußpotential* der Zelle (Anzahl verbundener Zellen)

$d_j$  *Distanzpotential* einer Position

(Summe der Distanzen zu allen anderen Positionen)

- ▶ Setzen sonstiger Parameter:

$k$  Anzahl Ameisen

$Q$  Wert der Pheromonerhöhung (abhängig von Zielfunktion)

# Ameisenalgorithmus

## Initialisierung

- ▶ Heuristische Information

$$\eta_{ij} = \frac{1}{f_i \cdot d_j}$$

$f_i$  *Flußpotential* der Zelle (Anzahl verbundener Zellen)

$d_j$  *Distanzpotential* einer Position

(Summe der Distanzen zu allen anderen Positionen)

- ▶ Setzen sonstiger Parameter:

$k$  Anzahl Ameisen

$Q$  Wert der Pheromonenerhöhung (abhängig von Zielfunktion)

$\alpha, \beta > 0$  Gewichtung der Pheromone ( $\alpha$ ) und heuristischen Information ( $\beta$ )

# Ameisenalgorithmus

## Initialisierung

- ▶ Heuristische Information

$$\eta_{ij} = \frac{1}{f_i \cdot d_j}$$

$f_i$  *Flußpotential* der Zelle (Anzahl verbundener Zellen)

$d_j$  *Distanzpotential* einer Position

(Summe der Distanzen zu allen anderen Positionen)

- ▶ Setzen sonstiger Parameter:

$k$  Anzahl Ameisen

$Q$  Wert der Pheromonenerhöhung (abhängig von Zielfunktion)

$\alpha, \beta > 0$  Gewichtung der Pheromone ( $\alpha$ ) und heuristischen Information ( $\beta$ )

$\rho$  Persistenz der Pheromone

# Ameisenalgorithmus

## Initialisierung

- ▶ Heuristische Information

$$\eta_{ij} = \frac{1}{f_i \cdot d_j}$$

$f_i$  *Flußpotential* der Zelle (Anzahl verbundener Zellen)

$d_j$  *Distanzpotential* einer Position

(Summe der Distanzen zu allen anderen Positionen)

- ▶ Setzen sonstiger Parameter:

$k$  Anzahl Ameisen

$Q$  Wert der Pheromonenerhöhung (abhängig von Zielfunktion)

$\alpha, \beta > 0$  Gewichtung der Pheromone ( $\alpha$ ) und heuristischen Information ( $\beta$ )

$\rho$  Persistenz der Pheromone

$\tau_{ij}$  Pheromone, Initialisierung mit Wert  $> 0$

# Ameisenalgorithmus

## Zuweisung Zelle $\mapsto$ Position

Wahrscheinlichkeit das Zelle  $i$  Position  $j$  zugewiesen wird  
(in Iteration  $t$  der Ameise  $k$ ):

$$p_{ij}^k = \frac{\tau_{ij}(t)^\alpha \cdot \eta_{ij}^\beta}{\sum_{l \in N_i^k} \tau_{il}(t)^\alpha \cdot \eta_{il}^\beta}$$

- ▶  $N_i^k$  ist die Nachbarschaft von Knoten  $i$

# Ameisenalgorithmus

## Zuweisung Zelle $\mapsto$ Position

Wahrscheinlichkeit das Zelle  $i$  Position  $j$  zugewiesen wird  
(in Iteration  $t$  der Ameise  $k$ ):

$$p_{ij}^k = \frac{\tau_{ij}(t)^\alpha \cdot \eta_{ij}^\beta}{\sum_{l \in N_i^k} \tau_{il}(t)^\alpha \cdot \eta_{il}^\beta}$$

- ▶  $N_i^k$  ist die Nachbarschaft von Knoten  $i$
- ▶  $\sum_{l \in N_i^k} p_{il}(t) = 1$

# Ameisenalgorithmus

## Zuweisung Zelle $\mapsto$ Position

Wahrscheinlichkeit das Zelle  $i$  Position  $j$  zugewiesen wird  
(in Iteration  $t$  der Ameise  $k$ ):

$$p_{ij}^k = \frac{\tau_{ij}(t)^\alpha \cdot \eta_{ij}^\beta}{\sum_{l \in N_i^k} \tau_{il}(t)^\alpha \cdot \eta_{il}^\beta}$$

- ▶  $N_i^k$  ist die Nachbarschaft von Knoten  $i$
- ▶  $\sum_{l \in N_i^k} p_{il}(t) = 1$
- ▶  $\tau_{ij}$  Pheromonwerte,  $\eta_{ij}$  heuristische Information

$$\tau_{ij}(t+1) = \rho \cdot \tau_{ij}(t) + \sum_{k=1}^m \Delta\tau_{ij}^k$$

Mit

$$\Delta\tau_{ij}^k = \begin{cases} Q/\text{cost}(\text{solution}) & \text{Zelle } i \text{ ist Position } j \text{ zugeordnet} \\ 0 & \text{sonst} \end{cases}$$

$Q$  Menge der Pheromone einer Ameise

$0 < \rho < 1$  Persistenz der Pheromone ( $(1 - \rho)$  Evaporation)  
Modelliert verdampfen von Pheromonen (gegen lokale Minima)



# Ameisenalgorithmus

## Zusammenfassung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel

# Ameisenalgorithmus

## Zusammenfassung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel
- ▶ Schlechte Skalierung

# Ameisenalgorithmus

## Zusammenfassung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel
- ▶ Schlechte Skalierung
- ▶ Qualität und Laufzeit vergleichbar mit Simulated Annealing

# Ameisenalgorithmus

## Zusammenfassung



- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel
- ▶ Schlechte Skalierung
- ▶ Qualität und Laufzeit vergleichbar mit Simulated Annealing
- ▶ Ähnlich zu SA: Theoretisch optimal

# Ameisenalgorithmus

## Zusammenfassung



- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel
- ▶ Schlechte Skalierung
- ▶ Qualität und Laufzeit vergleichbar mit Simulated Annealing
- ▶ Ähnlich zu SA: Theoretisch optimal
- ▶ Kann dynamisch auf Graphänderungen reagieren

# Ameisenalgorithmus

## Zusammenfassung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel
- ▶ Schlechte Skalierung
- ▶ Qualität und Laufzeit vergleichbar mit Simulated Annealing
- ▶ Ähnlich zu SA: Theoretisch optimal
- ▶ Kann dynamisch auf Graphänderungen reagieren
- ▶ Viele Varianten: AS, ANTS, MAX-MIN, FANT, HAS-QAP, ... Hauptunterschied sind andere ...

# Ameisenalgorithmus

## Zusammenfassung

- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel
- ▶ Schlechte Skalierung
- ▶ Qualität und Laufzeit vergleichbar mit Simulated Annealing
- ▶ Ähnlich zu SA: Theoretisch optimal
- ▶ Kann dynamisch auf Graphänderungen reagieren
- ▶ Viele Varianten: AS, ANTS, MAX-MIN, FANT, HAS-QAP, ...  
Hauptunterschied sind andere ...
  - ▶ heuristische Informationen

# Ameisenalgorithmus

## Zusammenfassung

- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel
- ▶ Schlechte Skalierung
- ▶ Qualität und Laufzeit vergleichbar mit Simulated Annealing
- ▶ Ähnlich zu SA: Theoretisch optimal
- ▶ Kann dynamisch auf Graphänderungen reagieren
- ▶ Viele Varianten: AS, ANTS, MAX-MIN, FANT, HAS-QAP, ...  
Hauptunterschied sind andere ...
  - ▶ heuristische Informationen
  - ▶ Pheromon Updates




# Ameisenalgorithmus

## Zusammenfassung

- ▶ Schlechte Konvergenz in der Nähe des Optimums, da kaum ein Unterschied im Pheromonlevel
- ▶ Schlechte Skalierung
- ▶ Qualität und Laufzeit vergleichbar mit Simulated Annealing
- ▶ Ähnlich zu SA: Theoretisch optimal
- ▶ Kann dynamisch auf Graphänderungen reagieren
- ▶ Viele Varianten: AS, ANTS, MAX-MIN, FANT, HAS-QAP, ...  
Hauptunterschied sind andere ...
  - ▶ heuristische Informationen
  - ▶ Pheromon Updates
  - ▶ Wahrscheinlichkeitsfunktion

# Ameisenalgorithmus

## Beispiel UPP



$n_1$ : A, B, F, G

$n_2$ : B, E

$n_3$ : D, E

$n_4$ : A, C, D

$n_5$ : C, D, F

$n_6$ : C, E, F, G

$n_7$ : D, F

$n_8$ : F, G

$$\vec{f} = \begin{pmatrix} 5 \\ 4 \\ 7 \\ 6 \\ 5 \\ 10 \\ 7 \end{pmatrix}, \vec{d} = \begin{pmatrix} 18 \\ 15 \\ 18 \\ 15 \\ 12 \\ 15 \\ 18 \\ 15 \\ 18 \end{pmatrix}$$

Zellen sortiert nach Flußpotential: F, C, G, D, A, E, B

# Ameisenalgorithmus

## Beispiel UPP – Init

$$\eta = \begin{pmatrix} 0.0111 & 0.0139 & 0.0079 & 0.0093 & 0.0111 & 0.0056 & 0.0079 \\ 0.0133 & 0.0167 & 0.0095 & 0.0111 & 0.0133 & 0.0067 & 0.0095 \\ 0.0111 & 0.0139 & 0.0079 & 0.0093 & 0.0111 & 0.0056 & 0.0079 \\ 0.0133 & 0.0167 & 0.0095 & 0.0111 & 0.0133 & 0.0067 & 0.0095 \\ 0.0167 & 0.0208 & 0.0119 & 0.0139 & 0.0167 & 0.0083 & 0.0119 \\ 0.0133 & 0.0167 & 0.0095 & 0.0111 & 0.0133 & 0.0067 & 0.0095 \\ 0.0111 & 0.0139 & 0.0079 & 0.0093 & 0.0111 & 0.0056 & 0.0079 \\ 0.0133 & 0.0167 & 0.0095 & 0.0111 & 0.0133 & 0.0067 & 0.0095 \\ 0.0111 & 0.0139 & 0.0079 & 0.0093 & 0.0111 & 0.0056 & 0.0079 \end{pmatrix}$$

$$Q = 2, \alpha = \beta = 1, \rho = 0.8$$

# Ameisenalgorithmus

## Beispiel UPP – Init

$$\tau = \begin{pmatrix} 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \end{pmatrix}$$

$$Q = 2, \alpha = \beta = 1, \rho = 0.8$$

# Ameisenalgorithmus

## Beispiel UPP – Auswahl

$$p_{ij} = \frac{\tau_{ij} \cdot \eta_{ij}}{\sum_{l \in N_i^k} \tau_{il} \cdot \eta_{il}}$$

Platziere Zelle F

$\eta_{Fi}$	0.0056	0.0067	0.0056	0.0067	0.0083	0.0067	0.0056	0.0067	0.0056
$\tau_{Fi}$	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1
$\tau_{Fi} \cdot \eta_{Fi}$	0.00056	0.00067	0.00056	0.00067	0.00083	0.00067	0.00056	0.00067	0.00056

$$\Sigma = 0.00575$$

$p_{Fi}$	0.0973	0.1165	0.0973	0.1165	0.1443	0.1165	0.0973	0.1165	0.0973
----------	--------	--------	--------	--------	--------	--------	--------	--------	--------

# Ameisenalgorithmus

## Beispiel UPP – Auswahl

$$p_{ij} = \frac{\tau_{ij} \cdot \eta_{ij}}{\sum_{l \in N_i^k} \tau_{il} \cdot \eta_{il}}$$

Platziere Zelle C

$\eta_{Ci}$	0.0079	0.0095	0.0079	0.0095	0.0079	0.0095	0.0079	0.0095	0.0079
$\tau_{Ci}$	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1	0.1
$\tau_{Ci} \cdot \eta_{Ci}$	0.00079	0.00095	0.00079	0.00095	0.00079	0.00095	0.00079	0.00095	0.00079


$$\Sigma = 0.00696$$

$p_{Ci}$	0.1135	0.1365	0.1135	0.1365	0.1135	0.1365	0.1135	0.1365	0.1135
----------	--------	--------	--------	--------	--------	--------	--------	--------	--------

# Ameisenalgorithmus

## Beispiel UPP


- ▶ Analog G, D, A, E, B



# Ameisenalgorithmus

## Beispiel UPP

- ▶ Analog G, D, A, E, B




- ▶ Kosten (HPWL): 24



# Ameisenalgorithmus

## Beispiel UPP

- ▶ Analog G, D, A, E, B



- ▶ Kosten (HPWL): 24
- ▶ Nächster Schritt: Pheromone aktualisieren

# Ameisenalgorithmus

## Beispiel UPP – Update

$$\tau = \begin{pmatrix} 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \\ 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 & 0.1 \end{pmatrix}$$

# Ameisenalgorithmus

## Beispiel UPP – Update

$$\tau = \begin{pmatrix} 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \end{pmatrix}$$

$\rho = 0.8$  Evaporation

# Ameisenalgorithmus

## Beispiel UPP – Update



$$\tau = \begin{pmatrix} 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.163 \\ 0.08 & 0.163 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.163 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.163 & 0.08 \\ 0.163 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.163 & 0.08 & 0.08 & 0.08 \\ 0.08 & 0.08 & 0.08 & 0.08 & 0.163 & 0.08 & 0.08 \end{pmatrix}$$

$\frac{2}{24}$  auf genommenen Pfad hinzufügen



- ▶ Erschöpfende Suche



- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums



- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums
  - ▶ Beispiel: Backtracking



- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums
  - ▶ Beispiel: Backtracking
- ▶ Eliminierung *schlechter* Ansätze





- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums
  - ▶ Beispiel: Backtracking
- ▶ Eliminierung *schlechter* Ansätze
  - ▶ Abschätzung aus Teillösung



- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums
  - ▶ Beispiel: Backtracking
- ▶ Eliminierung *schlechter* Ansätze
  - ▶ Abschätzung aus Teillösung
  - ▶ Beispiel: Branch-and-Bound



- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums
  - ▶ Beispiel: Backtracking
- ▶ Eliminierung *schlechter* Ansätze
  - ▶ Abschätzung aus Teillösung
  - ▶ Beispiel: Branch-and-Bound
- ▶ Wiederverwendung alter Ergebnisse



- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums
  - ▶ Beispiel: Backtracking
- ▶ Eliminierung *schlechter* Ansätze
  - ▶ Abschätzung aus Teillösung
  - ▶ Beispiel: Branch-and-Bound
- ▶ Wiederverwendung alter Ergebnisse
  - ▶ Beispiel: Dynamic Programming



- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums
  - ▶ Beispiel: Backtracking
- ▶ Eliminierung *schlechter* Ansätze
  - ▶ Abschätzung aus Teillösung
  - ▶ Beispiel: Branch-and-Bound
- ▶ Wiederverwendung alter Ergebnisse
  - ▶ Beispiel: Dynamic Programming
- ▶ Mathematisches Modell



- ▶ Erschöpfende Suche
  - ▶ Durchlaufen des gesamten Lösungsraums
  - ▶ Beispiel: Backtracking
- ▶ Eliminierung *schlechter* Ansätze
  - ▶ Abschätzung aus Teillösung
  - ▶ Beispiel: Branch-and-Bound
- ▶ Wiederverwendung alter Ergebnisse
  - ▶ Beispiel: Dynamic Programming
- ▶ Mathematisches Modell
  - ▶ Beispiel: Linear Programming

- ▶ Den gesamten Lösungsraum enumerieren

```
float bsfCost ;  
solution_element current[n], bsf[n] ;  
main(): begin  
    bsfCost :=  $\infty$  ;  
    backtrack(0) ;  
    report(bsf) ;
```

```
backtrack(int k): begin  
    float newCost ;  
    solution_element sol_el ;  
    if  $k = n$  then  
        new_cost := cost(current) ;  
        if  $newCost < bsfCost$  then  
            bsfCost := newCost ;  
            bsf := copy(bsf) ;  
    else  
        foreach ( $sol\_el \in$   
             $allowed(current, k)$ ) do  
            current[k] := sol_el ;  
            backtrack(k+1) ;
```

- ▶ Den gesamten Lösungsraum enumerieren
- ▶ Jede Lösung wird dabei schrittweise aufgebaut ( $f_1, f_2, \dots$ )

```
float bsfCost ;  
solution_element current[n], bsf[n] ;  
main(): begin  
    bsfCost :=  $\infty$  ;  
    backtrack(0) ;  
    report(bsf) ;
```

```
backtrack(int k): begin  
    float newCost ;  
    solution_element sol_el ;  
    if  $k = n$  then  
        new_cost := cost(current) ;  
        if  $newCost < bsfCost$  then  
            bsfCost := newCost ;  
            bsf := copy(bsf) ;  
    else  
        foreach ( $sol\_el \in$   
             $allowed(current, k)$ ) do  
            current[k] := sol_el ;  
            backtrack(k+1) ;
```



- ▶ Den gesamten Lösungsraum enumerieren
- ▶ Jede Lösung wird dabei schrittweise aufgebaut ( $f_1, f_2, \dots$ )
- ▶ Zu jeder Lösung die Kosten bestimmen und ggf. BSF aktualisieren

```
float bsfCost ;  
solution_element current[n], bsf[n] ;  
main(): begin  
    bsfCost :=  $\infty$  ;  
    backtrack(0) ;  
    report(bsf) ;
```

```
backtrack(int k): begin  
    float newCost ;  
    solution_element sol_el ;  
    if  $k = n$  then  
        new_cost := cost(current) ;  
        if  $newCost < bsfCost$  then  
            bsfCost := newCost ;  
            bsf := copy(bsf) ;  
    else  
        foreach ( $sol\_el \in$   
             $allowed(current, k)$ ) do  
            current[k] := sol_el ;  
            backtrack(k+1) ;
```

- ▶ Den gesamten Lösungsraum enumerieren
- ▶ Jede Lösung wird dabei schrittweise aufgebaut ( $f_1, f_2, \dots$ )
- ▶ Zu jeder Lösung die Kosten bestimmen und ggf. BSF aktualisieren
- ▶ Üblicherweise: Rekursiv

```
float bsfCost ;  
solution_element current[n], bsf[n] ;  
main(): begin  
    bsfCost :=  $\infty$  ;  
    backtrack(0) ;  
    report(bsf) ;
```

```
backtrack(int k): begin  
    float newCost ;  
    solution_element sol_el ;  
    if  $k = n$  then  
        new_cost := cost(current) ;  
        if  $newCost < bsfCost$  then  
            bsfCost := newCost ;  
            bsf := copy(bsf) ;  
    else  
        foreach ( $sol\_el \in$   
             $allowed(current, k)$ ) do  
            current[k] := sol_el ;  
            backtrack(k+1) ;
```

# Backtracking

## UPP Beispiel



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:

$$\vec{f} = [f_1, \dots, f_n]^T$$

Zelle  $i$  wird auf Position  $f_i$  platziert

# Backtracking

## UPP Beispiel



- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:  
 $\vec{f} = [f_1, \dots, f_n]^T$   
Zelle  $i$  wird auf Position  $f_i$  platziert
- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$

# Backtracking

## UPP Beispiel



- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:

$$\vec{f} = [f_1, \dots, f_n]^T$$

Zelle  $i$  wird auf Position  $f_i$  platziert

- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$
- ▶ Implizite Einschränkungen:  $i \neq j \Rightarrow f_i \neq f_j$

# Backtracking

## UPP Beispiel



- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:  
 $\vec{f} = [f_1, \dots, f_n]^T$   
Zelle  $i$  wird auf Position  $f_i$  platziert
- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$
- ▶ Implizite Einschränkungen:  $i \neq j \Rightarrow f_i \neq f_j$
- ▶ Konkretes Beispiel:  $n = 3, m = 4$ , HPWL-Kosten

# Backtracking

## UPP Beispiel




- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:  
 $\vec{f} = [f_1, \dots, f_n]^T$   
Zelle  $i$  wird auf Position  $f_i$  platziert
- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$
- ▶ Implizite Einschränkungen:  $i \neq j \Rightarrow f_i \neq f_j$
- ▶ Konkretes Beispiel:  $n = 3, m = 4$ , HPWL-Kosten

# Backtracking

## UPP Beispiel

- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:  
 $\vec{f} = [f_1, \dots, f_n]^T$   
Zelle  $i$  wird auf Position  $f_i$  platziert
- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$
- ▶ Implizite Einschränkungen:  $i \neq j \Rightarrow f_i \neq f_j$
- ▶ Konkretes Beispiel:  $n = 3, m = 4$ , HPWL-Kosten






# Backtracking

## UPP Beispiel

- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:  
 $\vec{f} = [f_1, \dots, f_n]^T$   
Zelle  $i$  wird auf Position  $f_i$  platziert
- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$
- ▶ Implizite Einschränkungen:  $i \neq j \Rightarrow f_i \neq f_j$
- ▶ Konkretes Beispiel:  $n = 3, m = 4$ , HPWL-Kosten




Netzliste:

# Backtracking

## UPP Beispiel

- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:  
 $\vec{f} = [f_1, \dots, f_n]^T$   
Zelle  $i$  wird auf Position  $f_i$  platziert
- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$
- ▶ Implizite Einschränkungen:  $i \neq j \Rightarrow f_i \neq f_j$
- ▶ Konkretes Beispiel:  $n = 3, m = 4$ , HPWL-Kosten



A

C

B


Netzliste:

$n_1$  : A, B, C

# Backtracking

## UPP Beispiel

- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:  
 $\vec{f} = [f_1, \dots, f_n]^T$   
Zelle  $i$  wird auf Position  $f_i$  platziert
- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$
- ▶ Implizite Einschränkungen:  $i \neq j \Rightarrow f_i \neq f_j$
- ▶ Konkretes Beispiel:  $n = 3, m = 4$ , HPWL-Kosten



A

C

B

Netzliste:


$n_1$  : A, B, C

$n_2$  : A, B

# Backtracking

## UPP Beispiel

- ▶ Lösung: Bei  $n$  Zellen auf  $m$  möglichen Positionen:  
 $\vec{f} = [f_1, \dots, f_n]^T$   
Zelle  $i$  wird auf Position  $f_i$  platziert
- ▶ Explizite Einschränkungen:  $f_i \in 1, \dots, m$
- ▶ Implizite Einschränkungen:  $i \neq j \Rightarrow f_i \neq f_j$
- ▶ Konkretes Beispiel:  $n = 3, m = 4$ , HPWL-Kosten




Netzliste:




$n_1$  : A, B, C




$n_2$  : A, B




$n_3$  : B, C

# Backtracking UPP Suchbaum



Lsg.	$\vec{f}$	Kosten
	123	5
	124	5
	132	5

	134	4
	142	5
	143	5

	213	4
	214	5
	124	5
⋮	⋮	⋮



- ▶ Branch = Verzweigen des Suchbaums



- ▶ Branch = Verzweigen des Suchbaums
- ▶ Bound = Beschneiden der Äste wenn möglich



- ▶ Branch = Verzweigen des Suchbaums
- ▶ Bound = Beschneiden der Äste wenn möglich
- ▶ Teillösung  $\underline{f}^{(k)} = [f_1, \dots, f_k, \perp, \dots, \perp]$





- ▶ Branch = Verzweigen des Suchbaums
- ▶ Bound = Beschneiden der Äste wenn möglich
- ▶ Teillösung  $\underline{f}^{(k)} = [f_1, \dots, f_k, \perp, \dots, \perp]$
- ▶  $D(\underline{f}^{(k)})$ : Menge aus  $\underline{f}^{(k)}$  herleitbarer Lösungen



- ▶ Branch = Verzweigen des Suchbaums
- ▶ Bound = Beschneiden der Äste wenn möglich
- ▶ Teillösung  $\vec{f}^{(k)} = [f_1, \dots, f_k, \perp, \dots, \perp]$
- ▶  $D(\vec{f}^{(k)})$ : Menge aus  $\vec{f}^{(k)}$  herleitbarer Lösungen
- ▶ Minimale mögliche Kosten cost einer Teillösung  $\vec{f}^{(k)}$  abschätzen  
Verwerfe  $\vec{f}^{(k)}$  falls  $\text{cost}(\vec{f}^{(k)}) > \text{cost}(BSF)$   
⇒ Suchbaum wird gestutzt

# Branch-and-Bound

## Abschätzfunktion cost



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Effekt der Abschätzung

# Branch-and-Bound

## Abschätzfunktion cost



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten

# Branch-and-Bound

## Abschätzfunktion cost



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)

# Branch-and-Bound

## Abschätzfunktion cost



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)
    - ⇒ Überflüssige Schritte

# Branch-and-Bound

## Abschätzfunktion cost



- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)
    - ⇒ Überflüssige Schritte
  - ▶ Reale Kosten niedriger als geschätzte Kosten

# Branch-and-Bound

## Abschätzfunktion cost



- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)
    - ⇒ Überflüssige Schritte
  - ▶ Reale Kosten niedriger als geschätzte Kosten
    - ⇒ Zu pessimistisch (“Nein, das bringt nichts mehr”)



# Branch-and-Bound

## Abschätzfunktion cost



- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)
    - ⇒ Überflüssige Schritte
  - ▶ Reale Kosten niedriger als geschätzte Kosten
    - ⇒ Zu pessimistisch (“Nein, das bringt nichts mehr”)
    - ⇒ Optimum wird möglicherweise weggestutzt

# Branch-and-Bound

## Abschätzfunktion cost

- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)
    - ⇒ Überflüssige Schritte
  - ▶ Reale Kosten niedriger als geschätzte Kosten
    - ⇒ Zu pessimistisch (“Nein, das bringt nichts mehr”)
    - ⇒ Optimum wird möglicherweise weggestutzt
    - ⇒ **Keine exakte Lösung mehr!**

# Branch-and-Bound

## Abschätzfunktion cost



- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)
    - ⇒ Überflüssige Schritte
  - ▶ Reale Kosten niedriger als geschätzte Kosten
    - ⇒ Zu pessimistisch (“Nein, das bringt nichts mehr”)
    - ⇒ Optimum wird möglicherweise weggestutzt
    - ⇒ Keine exakte Lösung mehr!
  - ▶ cost sollte möglichst genau sein

# Branch-and-Bound

## Abschätzfunktion cost



- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)
    - ⇒ Überflüssige Schritte
  - ▶ Reale Kosten niedriger als geschätzte Kosten
    - ⇒ Zu pessimistisch (“Nein, das bringt nichts mehr”)
    - ⇒ Optimum wird möglicherweise weggestutzt
    - ⇒ Keine exakte Lösung mehr!
  - ▶ cost sollte möglichst genau sein

# Branch-and-Bound

## Abschätzfunktion cost


- ▶ Effekt der Abschätzung
  - ▶ Reale Kosten höher als geschätzte Kosten
    - ⇒ Zu optimistisch (“Ja, es lohnt sich weiterzumachen”)
    - ⇒ Überflüssige Schritte
  - ▶ Reale Kosten niedriger als geschätzte Kosten
    - ⇒ Zu pessimistisch (“Nein, das bringt nichts mehr”)
    - ⇒ Optimum wird möglicherweise weggestutzt
    - ⇒ Keine exakte Lösung mehr!
  - ▶ cost sollte möglichst genau sein




## UPP Beispiel: Kostenabschätzung




- ▶ Gute Abschätzung: Minimal mögliche Kosten eines Netzes,




# Branch-and-Bound

## UPP Beispiel



Lsg.	$\vec{f}$	Kosten
	123	5
	124	5
	132	5

	134	4
	142	5
	143	5

	213	4
	214	5
	124	5
⋮	⋮	⋮



- ▶ Wiederverwenden von Lösungen
- ▶ Prinzip der Optimalität:
  - ▶ Annahme: Lösung eines komplex Problems kann optimal aus dem optimalen Lösungen von Teilproblemen zusammengesetzt werden (ebenfalls Idee bei Teile-Und-Herrsche)
  - ▶ Gilt aber nicht für alle Probleme!
- ▶  $p$  Parameter für Problemkomplexität
  - $p = k$ : Gesamtproblem
  - $p < k$ : Teilproblem
  - $p = 0$  oder  $= 1$ : Kleinstes Problem
- ▶ Für viele Probleme anwendbar. Beispielsweise:
  - ▶ Klassisches Beispiel: Fibonacci-Zahlen
  - ▶ Dijkstra SP
  - ▶ Aber auch für NP-vollständige Probleme

# Dynamisches Programmieren

## Beispiel Fibonacci-Zahlen



- ▶ Fibonacci-Zahlen: 0, 1, 1, 2, 3, 5, ...
- ▶  $F_n = F_{n-1} + F_{n-2}$  mit  $F_0 = 0, F_1 = 1$

### Klassische Implementierung:

fib(int n): **begin**

**if** ( $n=0$ ) **then**

    └ return 0

**if** ( $n=1$ ) **then**

    └ return 1

**else**

    └ return (fib( $n-1$ ))+fib( $n-2$ ))

- ▶  $\frac{F_{n+1}}{F_n} \rightarrow 1.6$  (genau  $\frac{1+\sqrt{5}}{2}$ )  $\Rightarrow F_n > 1.6^n$
- ▶ Da immer 1 aufsummiert werden  $\Rightarrow \mathcal{O}(1.6^n)$

### Dynamisches Programmieren

fib(int n): **begin**

  Fib[0] := 0 ;

  Fib[1] := 1 ;

**for** ( $i=2; i \leq n; i++$ ) **do**

    └ Fib[i] := Fib[i-1] + Fib[ i-2 ]

  return Fib[n] ;

- ▶ Teillösungen bei  $p = i$
- ▶ Gesamtlösung bei  $p = n$





- ▶ Nahezu alle Probleme Optimierungsprobleme
- ▶ Entsprechende mathematische Modelle wählen und bekannte mathematische Verfahren anwenden

# Mathematische Optimierung

## Lineare Programmierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Verfahren aus dem Operations Research

# Mathematische Optimierung

## Lineare Programmierung

- ▶ Verfahren aus dem Operations Research
- ▶ Beispiel:

	Produkt 1	Produkt 2	Liefermenge
Rohstoff A	42	14	100
Rohstoff B	23	53	200
Preis	550	250	

Ziel: Optimierte auf maximalen Umsatz

# Mathematische Optimierung

## Lineare Programmierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Modell:  $x_1, x_2$  Anzahl Produkte 1 und 2

# Mathematische Optimierung

## Lineare Programmierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Modell:  $x_1, x_2$  Anzahl Produkte 1 und 2
- ▶ Kanonische Form (üblicherweise max und  $x_i \geq 0$  implizit)

$$\text{max: } 550x_1 + 250x_2$$

$$\text{subject to: } 42x_1 + 14x_2 \leq 100$$

$$23x_1 + 53x_2 \leq 200$$

$$\text{and } x_i \geq 0$$

# Mathematische Optimierung

## Lineare Programmierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Modell:  $x_1, x_2$  Anzahl Produkte 1 und 2
- ▶ Kanonische Form (üblicherweise max und  $x_i \geq 0$  implizit)

$$\text{max: } 550x_1 + 250x_2$$

$$\text{subject to: } 42x_1 + 14x_2 \leq 100$$

$$23x_1 + 53x_2 \leq 200$$

$$\text{and } x_i \geq 0$$

- ▶ Lineares Programm

# Mathematische Optimierung

## Lineare Programmierung

- ▶ Modell:  $x_1, x_2$  Anzahl Produkte 1 und 2
- ▶ Kanonische Form (üblicherweise max und  $x_i \geq 0$  implizit)

$$\begin{aligned} \max: & 550x_1 + 250x_2 \\ \text{subject to:} & 42x_1 + 14x_2 \leq 100 \\ & 23x_1 + 53x_2 \leq 200 \end{aligned}$$

$$\text{and } x_i \geq 0$$

- ▶ Lineares Programm
- ▶ Matrixformulierung:

$$\begin{aligned} \max: & \vec{c} \cdot \vec{x} \\ \text{s. t. :} & A\vec{x} \leq \vec{b}, x_i \geq 0 \end{aligned}$$



- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11



- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11

- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum
  - ▶ Restriktionen bilden ein Simplex (Polyeder), Lösung eine der Ecken

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11

- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum
  - ▶ Restriktionen bilden ein Simplex (Polyeder), Lösung eine der Ecken
  - ▶ Worst-Case-Komplexität: Exponentiell

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11

- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum
  - ▶ Restriktionen bilden ein Simplex (Polyeder), Lösung eine der Ecken
  - ▶ Worst-Case-Komplexität: Exponentiell
  - ▶ Praktisch immer Polynomial

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11

# Mathematische Optimierung

## Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum
  - ▶ Restriktionen bilden ein Simplex (Polyeder), Lösung eine der Ecken
  - ▶ Worst-Case-Komplexität: Exponentiell
  - ▶ Praktisch immer Polynomial
- ▶ Problem ist in **P**

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11

# Mathematische Optimierung

## Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum
  - ▶ Restriktionen bilden ein Simplex (Polyeder), Lösung eine der Ecken
  - ▶ Worst-Case-Komplexität: Exponentiell
  - ▶ Praktisch immer Polynomial
- ▶ Problem ist in **P**
  - ▶ Ellipsoid-Verfahren (1979)

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11



- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum
  - ▶ Restriktionen bilden ein Simplex (Polyeder), Lösung eine der Ecken
  - ▶ Worst-Case-Komplexität: Exponentiell
  - ▶ Praktisch immer Polynomial
- ▶ Problem ist in **P**
  - ▶ Ellipsoid-Verfahren (1979)
  - ▶ Innere Punkte Methoden (1984)  
wandern nicht die Ecken ab, sondern gehen durch den Simplex

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11

- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum
  - ▶ Restriktionen bilden ein Simplex (Polyeder), Lösung eine der Ecken
  - ▶ Worst-Case-Komplexität: Exponentiell
  - ▶ Praktisch immer Polynomial
- ▶ Problem ist in **P**
  - ▶ Ellipsoid-Verfahren (1979)
  - ▶ Innere Punkte Methoden (1984)  
wandern nicht die Ecken ab, sondern gehen durch den Simplex
- ▶ Lösung durch *LP Solver*

## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11



# Mathematische Optimierung

## Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Lösung mittels Simplex-Verfahren (Danzig, 1947)
  - ▶ Darstellung der Kostenfunktion und Restriktionen als Hyperebene im Raum
  - ▶ Restriktionen bilden ein Simplex (Polyeder), Lösung eine der Ecken
  - ▶ Worst-Case-Komplexität: Exponentiell
  - ▶ Praktisch immer Polynomial
- ▶ Problem ist in **P**
  - ▶ Ellipsoid-Verfahren (1979)
  - ▶ Innere Punkte Methoden (1984)  
wandern nicht die Ecken ab, sondern gehen durch den Simplex
- ▶ Lösung durch *LP Solver*
  - ▶ Ip\_solve, GLPK, CLP, CPLEX, ...


## Beispiel

Optimum:  $x_1 = 1.31303$ ,  $x_2 = 3.20378$

Umsatz: 1523.11


# Mathematische Optimierung

## Lineare Programmierung



# Mathematische Optimierung

## Lineare Programmierung



# Mathematische Optimierung

## Integer Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problem: Oft nur ganzzahlige Variablen erlaubt!  
Es lassen sich nicht 1.31303 Produkte herstellen/verkaufen

## Beispiel

$$x_1 = 2, x_2 = 1$$

Umsatz: 1350

# Mathematische Optimierung

## Integer Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problem: Oft nur ganzzahlige Variablen erlaubt!  
Es lassen sich nicht 1.31303 Produkte herstellen/verkaufen
- ⇒ Integer Lineare Programmierung (ILP)

## Beispiel

$$x_1 = 2, x_2 = 1$$

Umsatz: 1350

# Mathematische Optimierung

## Integer Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problem: Oft nur ganzzahlige Variablen erlaubt!  
Es lassen sich nicht 1.31303 Produkte herstellen/verkaufen
- ⇒ Integer Lineare Programmierung (ILP)
- ▶ Lösungsmethoden komplizierter  
Lösungsverfahren NP-vollständig

## Beispiel

$$x_1 = 2, x_2 = 1$$

Umsatz: 1350

# Mathematische Optimierung

## Integer Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problem: Oft nur ganzzahlige Variablen erlaubt!  
Es lassen sich nicht 1.31303 Produkte herstellen/verkaufen
- ⇒ Integer Lineare Programmierung (ILP)
  - ▶ Lösungsmethoden komplizierter  
Lösungsverfahren NP-vollständig
  - ▶ Einfachste Heuristik: Rundung

## Beispiel

$$x_1 = 2, x_2 = 1$$

Umsatz: 1350

# Mathematische Optimierung

## Integer Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problem: Oft nur ganzzahlige Variablen erlaubt!  
Es lassen sich nicht 1.31303 Produkte herstellen/verkaufen
- ⇒ Integer Lineare Programmierung (ILP)
  - ▶ Lösungsmethoden komplizierter  
Lösungsverfahren NP-vollständig
  - ▶ Einfachste Heuristik: Rundung
  - ▶ Nicht sinnvoll

## Beispiel

$$x_1 = 2, x_2 = 1$$

Umsatz: 1350



# Mathematische Optimierung

## Integer Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problem: Oft nur ganzzahlige Variablen erlaubt!  
Es lassen sich nicht 1.31303 Produkte herstellen/verkaufen
- ⇒ Integer Lineare Programmierung (ILP)
  - ▶ Lösungsmethoden komplizierter  
Lösungsverfahren NP-vollständig
  - ▶ Einfachste Heuristik: Rundung
  - ▶ Nicht sinnvoll
    - ▶ Sub-Optimal

## Beispiel

$$x_1 = 2, x_2 = 1$$

Umsatz: 1350

# Mathematische Optimierung

## Integer Lineare Optimierung



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Problem: Oft nur ganzzahlige Variablen erlaubt!  
Es lassen sich nicht 1.31303 Produkte herstellen/verkaufen
- ⇒ Integer Lineare Programmierung (ILP)
  - ▶ Lösungsmethoden komplizierter  
Lösungsverfahren NP-vollständig
  - ▶ Einfachste Heuristik: Rundung
  - ▶ Nicht sinnvoll
    - ▶ Sub-Optimal
    - ▶ Unzulässige Lösung

## Beispiel

$$x_1 = 2, x_2 = 1$$

Umsatz: 1350



- ▶ Lösungsverfahren:



- ▶ Lösungsverfahren:
  - ▶ LP kombiniert mit branch-and-bound (auf- und abrunden)



- ▶ Lösungsverfahren:
  - ▶ LP kombiniert mit branch-and-bound (auf- und abrunden)
  - ▶ SAT (Erfüllbarkeitsproblem) (nur bei 0 – 1-ILP)



▶ Lösungverfahren:

- ▶ LP kombiniert mit branch-and-bound (auf- und abrunden)
- ▶ SAT (Erfüllbarkeitsproblem) (nur bei 0 – 1-ILP)
- ▶ Schnittebenenverfahren (Cutting-Planes)  
Wiederholt normales LP lösen und Restriktionen für Ganzzahligkeit hinzufügen



▶ Lösungverfahren:

- ▶ LP kombiniert mit branch-and-bound (auf- und abrunden)
- ▶ SAT (Erfüllbarkeitsproblem) (nur bei 0 – 1-ILP)
- ▶ Schnittebenenverfahren (Cutting-Planes)  
Wiederholt normales LP lösen und Restriktionen für Ganzzahligkeit hinzufügen
- ▶ Manchmal durch Matrixstruktur implizit garantiert, dass Lösung ganzzahlig ist:  
[Total unimodulare Matrizen](#)

⇒ Standard Löser benutzen



### ▶ Lösungsverfahren:

- ▶ LP kombiniert mit branch-and-bound (auf- und abrunden)
- ▶ SAT (Erfüllbarkeitsproblem) (nur bei 0 – 1-ILP)
- ▶ Schnittebenenverfahren (Cutting-Planes)  
Wiederholt normales LP lösen und Restriktionen für Ganzzahligkeit hinzufügen
- ▶ Manchmal durch Matrixstruktur implizit garantiert, dass Lösung ganzzahlig ist:  
Total unimodulare Matrizen

## Beispiele

⇒ Standard Löser benutzen





### ▶ Lösungsverfahren:

- ▶ LP kombiniert mit branch-and-bound (auf- und abrunden)
- ▶ SAT (Erfüllbarkeitsproblem) (nur bei 0 – 1-ILP)
- ▶ Schnittebenenverfahren (Cutting-Planes)  
Wiederholt normales LP lösen und Restriktionen für Ganzzahligkeit hinzufügen
- ▶ Manchmal durch Matrixstruktur implizit garantiert, dass Lösung ganzzahlig ist:  
**Total unimodulare Matrizen**

## Beispiele

- ▶ Inzidenzmatrix eines bipartiten Graphen

⇒ Standard Löser benutzen



### ▶ Lösungsverfahren:

- ▶ LP kombiniert mit branch-and-bound (auf- und abrunden)
- ▶ SAT (Erfüllbarkeitsproblem) (nur bei 0 – 1-ILP)
- ▶ Schnittebenenverfahren (Cutting-Planes)  
Wiederholt normales LP lösen und Restriktionen für Ganzzahligkeit hinzufügen
- ▶ Manchmal durch Matrixstruktur implizit garantiert, dass Lösung ganzzahlig ist:  
**Total unimodulare Matrizen**

## Beispiele

- ▶ Inzidenzmatrix eines bipartiten Graphen
- ▶ Restriktionsmatrix von Max-Flow-Problemen

⇒ Standard Löser benutzen

# Mathematische Optimierung

## LP Varianten



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

Häufige Varianten:

- ▶ Variablen nur 0 oder 1:  
0 – 1-ILP

# Mathematische Optimierung

## LP Varianten



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

Häufige Varianten:

- ▶ Variablen nur 0 oder 1:  
0 – 1-ILP
- ▶ Gemischt LP und ILP:  
Mixed Linear Programm (MLP)

Häufige Varianten:

- ▶ Variablen nur 0 oder 1:  
0 – 1-ILP
- ▶ Gemischt LP und ILP:  
Mixed Linear Programm (MLP)
- ▶ Quadratische Zielfunktion (weiterhin Restriktionen linear):  
Quadratisches Programmieren (QP)  
Vorteil bei Quadratisch-Konvexen-Funktionen: Lokale Extrema = Globale

# ILP

## UPP Beispiel



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

► Modell:

# ILP

## UPP Beispiel



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

► Modell:

$x_{ij} \in \mathbf{B}$ : Zelle  $i = 1, \dots, N$  wird auf Position  $j = 1, \dots, M$  platziert.

# ILP

## UPP Beispiel

► Modell:

$x_{ij} \in \mathbf{B}$ : Zelle  $i = 1, \dots, N$  wird auf Position  $j = 1, \dots, M$  platziert.

$n_k \in \mathbf{R}$ : Kosten für ein Netz  $k = 1, \dots, K$ .



# ILP

## UPP Beispiel

► Modell:

$x_{ij} \in \mathbf{B}$ : Zelle  $i = 1, \dots, N$  wird auf Position  $j = 1, \dots, M$  platziert.

$n_k \in \mathbf{R}$ : Kosten für ein Netz  $k = 1, \dots, K$ .

Zielfunktion:  $\min: \sum_k n_k$

# ILP

## UPP Beispiel

► Modell:

$x_{ij} \in \mathbf{B}$ : Zelle  $i = 1, \dots, N$  wird auf Position  $j = 1, \dots, M$  platziert.

$n_k \in \mathbf{R}$ : Kosten für ein Netz  $k = 1, \dots, K$ .

Zielfunktion:  $\min: \sum_k n_k$

# ILP

## UPP Beispiel

► Modell:

$x_{ij} \in \mathbf{B}$ : Zelle  $i = 1, \dots, N$  wird auf Position  $j = 1, \dots, M$  platziert.

$n_k \in \mathbf{R}$ : Kosten für ein Netz  $k = 1, \dots, K$ .

Zielfunktion:  $\min: \sum_k n_k$

Restriktionen: ► Alle Platzieren:  $\forall i \sum_j x_{ij} = 1$  (2N Restriktionen)



► Modell:

$x_{ij} \in \mathbf{B}$ : Zelle  $i = 1, \dots, N$  wird auf Position  $j = 1, \dots, M$  platziert.

$n_k \in \mathbf{R}$ : Kosten für ein Netz  $k = 1, \dots, K$ .

Zielfunktion:  $\min: \sum_k n_k$

Restriktionen:

- Alle Platzieren:  $\forall i \sum_j x_{ij} = 1$  (2N Restriktionen)
- Überlappungsfreiheit:  $\forall j : \sum_i x_{ij} \leq 1$  (M Restriktionen)
- Kostenfunktion:  $n_k = c_{kV} + c_{kH}$

► Modell:

$x_{ij} \in \mathbf{B}$ : Zelle  $i = 1, \dots, N$  wird auf Position  $j = 1, \dots, M$  platziert.

$n_k \in \mathbf{R}$ : Kosten für ein Netz  $k = 1, \dots, K$ .

Zielfunktion:  $\min: \sum_k n_k$

Restriktionen: ► Alle Platzieren:  $\forall i \sum_j x_{ij} = 1$  (2N Restriktionen)

► Überlappungsfreiheit:  $\forall j : \sum_i x_{ij} \leq 1$  (M Restriktionen)

► Kostenfunktion:  $n_k = c_{kV} + c_{kH}$

► Netz  $k$ :

$$c_{kV} = c_{kMaxV} - c_{kMinV}$$

$$c_{kMaxV} = \max_{i \in \text{Netz } k} \{x_{ij} \cdot \text{'zu } j \text{ gehöriger } x\text{-Wert'}\}$$

$$c_{kMinV} = \min_{i \in \text{Netz } k} \{x_{ij} \cdot \text{'zu } j \text{ gehöriger } x\text{-Wert'}\}$$

$c_{kH}$  analog

( $2K(2 + 2 \cdot \sum_k |\text{Netz } k|)$  Restriktionen)

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren (CG)



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Eigentlich benutzt um große LGS zu lösen

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren (CG)



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Eigentlich benutzt um große LGS zu lösen
- ▶ Vorteilhaft bei dünnbesetzten (sparse) Matrizen



# Mathematische Optimierung

## Konjugiertes Gradientenverfahren (CG)



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Eigentlich benutzt um große LGS zu lösen
- ▶ Vorteilhaft bei dünnbesetzten (sparse) Matrizen
- ▶ Minimieren einer Funktion  $f(\vec{x}) = \frac{1}{2} \cdot \vec{x}^T A \vec{x} - b \cdot \vec{x} + c$ ,  
A symmetrisch, positiv definit

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren (CG)



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Eigentlich benutzt um große LGS zu lösen
- ▶ Vorteilhaft bei dünnbesetzten (sparse) Matrizen
- ▶ Minimieren einer Funktion  $f(\vec{x}) = \frac{1}{2} \cdot \vec{x}^T A \vec{x} - b \cdot \vec{x} + c$ ,  
 $A$  symmetrisch, positiv definit
- ▶ Gradient: Vektor der partiellen Ableitungen  $\nabla f(\vec{x}) = \left( \frac{\partial f}{\partial x_1}, \frac{\partial f}{\partial x_2}, \frac{\partial f}{\partial x_3}, \dots \right)$   
in unserem Fall  $f'(\vec{x}) = A\vec{x} - b$ .

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren (CG)




- ▶ Eigentlich benutzt um große LGS zu lösen
- ▶ Vorteilhaft bei dünnbesetzten (sparse) Matrizen
- ▶ Minimieren einer Funktion  $f(\vec{x}) = \frac{1}{2} \cdot \vec{x}^T A \vec{x} - b \cdot \vec{x} + c$ ,  
 $A$  symmetrisch, positiv definit
- ▶ Gradient: Vektor der partiellen Ableitungen  $\nabla f(\vec{x}) = \left( \frac{\partial f}{\partial x_1}, \frac{\partial f}{\partial x_2}, \frac{\partial f}{\partial x_3}, \dots \right)$   
in unserem Fall  $f'(\vec{x}) = A\vec{x} - b$ .
- ▶  $f'(\vec{x}) = 0 \Leftrightarrow$  lösen des LGS  $Ax = b$

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren

- ▶ Krylow-Unterraum-Verfahren
  - ▶ Steilster Anstieg in Punkt  $x_k$  ist Gradient  
 $f'(\vec{x}_k) = A\vec{x}_k - b$
  - ▶ Residuum  $r_k := -(A\vec{x}_k - b)$
  - ▶ Minimiere Funktion in Richtung  $d_k$   
 $d_i$  sind bzgl.  $A$  orthogonal zueinander  
(konjugiert)
- ⇒  $\alpha_k$  in entsprechende Richtung gehen
- ⇒ Neues  $x_k$
- ▶ Neues Residuum  $r_{k+1}$  aus Altem und der  
Richtung  $d_k$  (mit zugehöriger Schrittweite  $\beta_k$   
bestimmen)



[Quelle: Wikimedia]

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren

cg(A,b) begin

Wähle  $x_0 \in \mathbf{R}^n$  ;

$r_0 := b - Ax_0$  ;  $d_0 := r_0$  ;

$k := 0$  ;

**repeat**

$$\alpha_k := \frac{r_k^T r_k}{d_k^T A d_k} ;$$

$$x_{k+1} := x_k + \alpha_k \cdot d_k ;$$

$$r_{k+1} := r_k + \alpha_k \cdot A d_k ;$$

$$\beta_k := \frac{r_{k+1}^T r_{k+1}}{r_k^T r_k} ;$$

$$d_{k+1} := r_{k+1} + \beta_k \cdot d_k ;$$

$k++$  ;

**until** Residuum  $\|r_k\| < \epsilon$  ;

**return**  $x_k$  ;

- ▶  $x_0$  beliebig  
schnellere Konvergenz, falls  $x_0$  nahe  
an Lösung
- ▶ Optimierung: In der Schleife  $A \cdot d_k$   
nur einmal berechnen
- ▶ Auch andere Abbruchbedingungen  
möglich:
  - ▶  $\Delta x_k < \epsilon$
  - ▶ Max. Anzahl Iterationen
  - ▶ ...

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren (nichtlinear)

cg(A,b) **begin**

Wähle  $x_0 \in \mathbf{R}^n$  ;

$r_0 := -\nabla f(x_0)$  ;  $d_0 := r_0$  ;

$k := 0$  ;

**repeat**

$$\alpha_k := \frac{r_k^T r_k}{d_k^T \nabla^2(f(x_k)) d_k} ;$$

$$x_{k+1} := x_k + \alpha \cdot d_k ;$$

$$r_{k+1} := -\nabla f(x_{k+1}) ;$$

$$\beta_k := \frac{r_{k+1}^T r_{k+1}}{r_k^T r_k} ;$$

$$d_{k+1} := r_{k+1} + \beta_{k+1} \cdot d_k ;$$

$k++$  ;

**until** Residuum  $\|r_k\| < \epsilon$  ;

**return**  $x_k$  ;

- ▶ Hesse-Matrix zur  $\alpha$ -Bestimmung  
Üblicherweise  $\mathcal{O}(n^2)$ ,  
problemabhängig ggf. nur  $\mathcal{O}(n)$
- ▶ Andere Möglichkeit:  
 $\alpha$  mittels Linearesearch
- ▶ Andere Abbruchbedingungen

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:



# Mathematische Optimierung

## Konjugiertes Gradientenverfahren



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:

**Theoretisch:** Nach  $n$  Schritten

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:

**Theoretisch:** Nach  $n$  Schritten

**Praktisch I:** Numerische Ungenauigkeiten machen mehr notwendig

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:

**Theoretisch:** Nach  $n$  Schritten

**Praktisch I:** Numerische Ungenauigkeiten machen mehr notwendig

**Praktisch II:** Schneller, abhängig von Anzahl verschiedener  
Eigenwerte

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:
  - Theoretisch:** Nach  $n$  Schritten
  - Praktisch I:** Numerische Ungenauigkeiten machen mehr notwendig
  - Praktisch II:** Schneller, abhängig von Anzahl verschiedener Eigenwerte
- ▶ Wenn nötig Matrix konditionieren  
⇒ Preconditioner

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren



TECHNISCHE  
UNIVERSITÄT  
DARMSTADT

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:
  - Theoretisch: Nach  $n$  Schritten
  - Praktisch I: Numerische Ungenauigkeiten machen mehr notwendig
  - Praktisch II: Schneller, abhängig von Anzahl verschiedener Eigenwerte
- ▶ Wenn nötig Matrix konditionieren
  - ⇒ Preconditioner
- ▶ Verschiedene Varianten, andere Bestimmung von  $\beta$ 
  - ⇒ ggf. besseres Konvergenzverhalten

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:
  - Theoretisch:** Nach  $n$  Schritten
  - Praktisch I:** Numerische Ungenauigkeiten machen mehr notwendig
  - Praktisch II:** Schneller, abhängig von Anzahl verschiedener Eigenwerte
- ▶ Wenn nötig Matrix konditionieren
  - ⇒ Preconditioner
- ▶ Verschiedene Varianten, andere Bestimmung von  $\beta$ 
  - ⇒ ggf. besseres Konvergenzverhalten
- ▶ Optimierung von Funktionen mit Nebenbedingungen:

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:
  - Theoretisch:** Nach  $n$  Schritten
  - Praktisch I:** Numerische Ungenauigkeiten machen mehr notwendig
  - Praktisch II:** Schneller, abhängig von Anzahl verschiedener Eigenwerte
- ▶ Wenn nötig Matrix konditionieren
  - ⇒ Preconditioner
- ▶ Verschiedene Varianten, andere Bestimmung von  $\beta$ 
  - ⇒ ggf. besseres Konvergenzverhalten
- ▶ Optimierung von Funktionen mit Nebenbedingungen:
  - ▶ Lagrange-Multiplikatoren

# Mathematische Optimierung

## Konjugiertes Gradientenverfahren

- ▶ Konvergenz abhängig von Matrix (Konditionszahl)
- ▶ Konvergenz:
  - Theoretisch:** Nach  $n$  Schritten
  - Praktisch I:** Numerische Ungenauigkeiten machen mehr notwendig
  - Praktisch II:** Schneller, abhängig von Anzahl verschiedener Eigenwerte
- ▶ Wenn nötig Matrix konditionieren
  - ⇒ Preconditioner
- ▶ Verschiedene Varianten, andere Bestimmung von  $\beta$ 
  - ⇒ ggf. besseres Konvergenzverhalten
- ▶ Optimierung von Funktionen mit Nebenbedingungen:
  - ▶ Lagrange-Multiplikatoren
  - ▶ Nebenbedingungen werden mittels Kostenfunktion berücksichtigt



- ▶ Metriken
  - ▶ 1-/2-Norm, HPWL, RSMT, RMST, LSE, Star+
- ▶ Timing-Analyse
- ▶ UPP
- ▶ Allgemeine Heuristiken
  - ▶ Nachbarsuche, Simulated Annealing, Tabu-Suche, Genetische Algorithmen, Ameisenalgorithmus
- ▶ Exakte Lösungsverfahren
  - ▶ Backtracking, Branch-and-Bound, Dynamic Programming, Linear Programming