

# Effiziente Algorithmen (SS2022)

## Chapter 4

### Lineare Programme 1

Walter Unger

Lehrstuhl für Informatik 1

— 17.05.2022 17:57:45 —

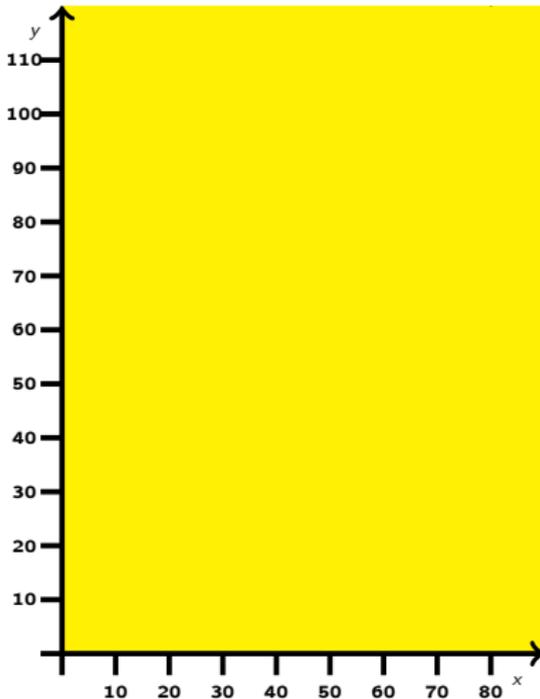
# Contents I

- 1 **Einleitung zu LPs**
  - Beispiele
  - Formen eines LP
  - Geometrische Interpretation
- 2 **Algorithmus von Seidel**
  - Details
  - Algorithmus
- 3 **Ellipsoidmethode**
  - Laufzeit
  - Einleitung
  - Ellipsoidmethode
  - Transformation
  - Laufzeit
  - Bemerkungen
  - Lösen eines LPs mit Ellipsoidmethode

# Einfaches Beispiel

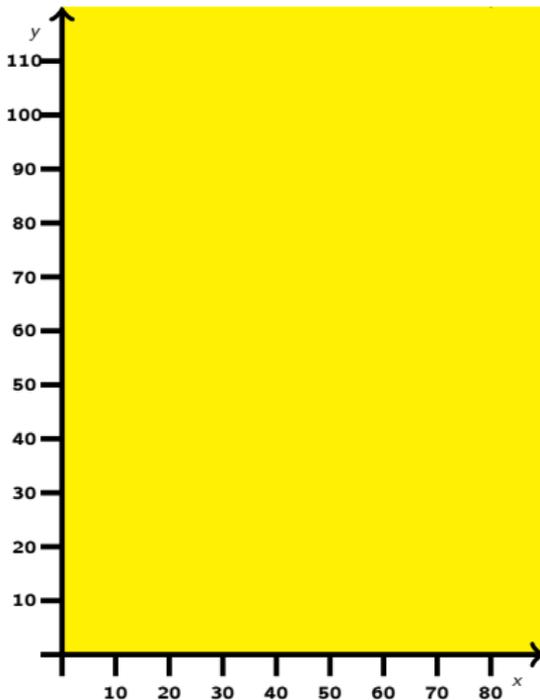


## Einfaches Beispiel



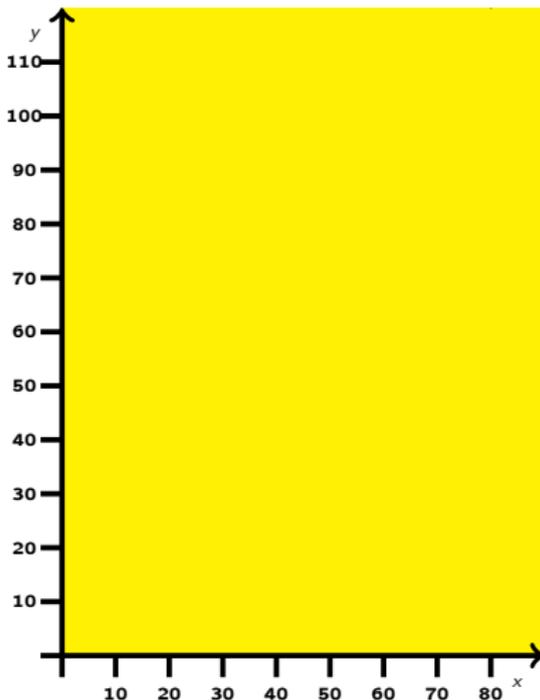
- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.

## Einfaches Beispiel



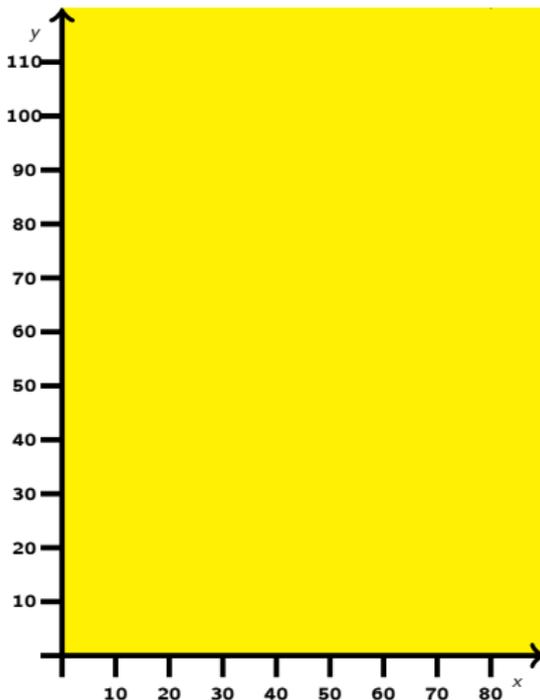
- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):

## Einfaches Beispiel



- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl

## Einfaches Beispiel



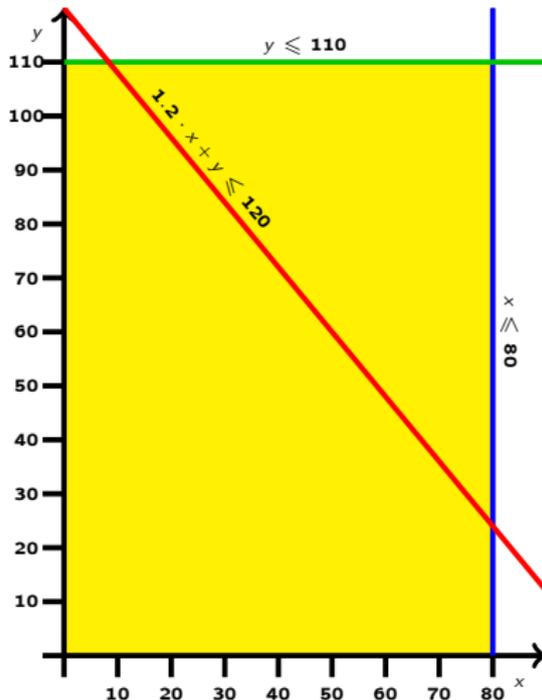
- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl
  - $y$  kg Roggenmehl





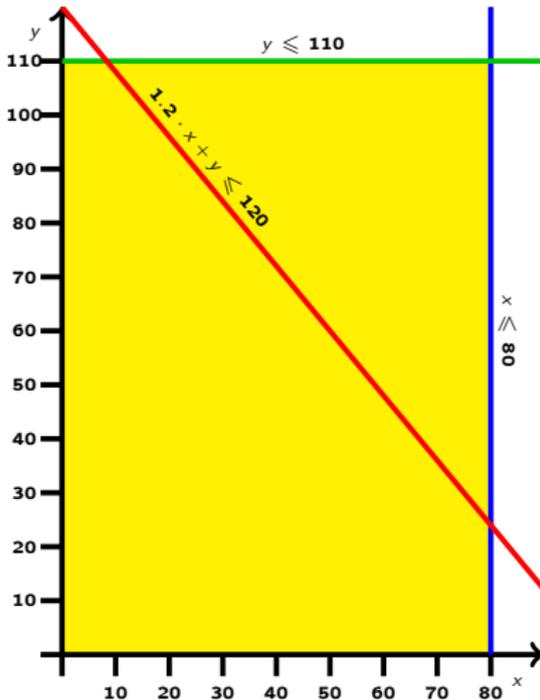


## Einfaches Beispiel



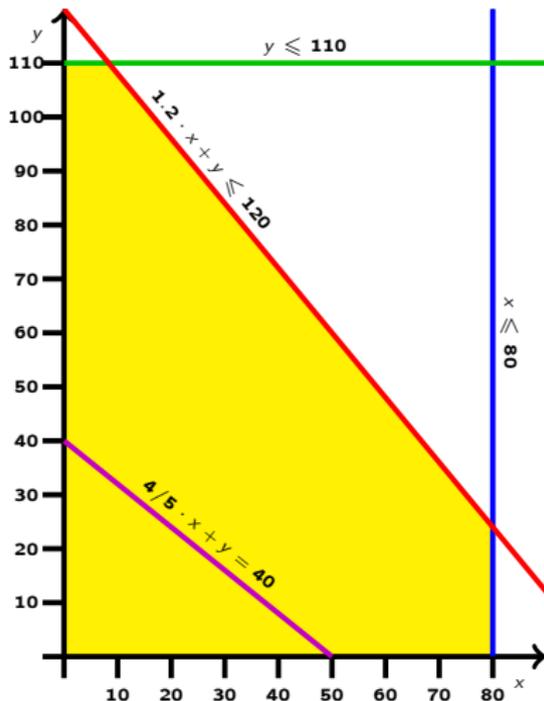
- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl
  - $y$  kg Roggenmehl
  - Maximal 80 kg Weizenmehl.
  - Maximal 110 kg Roggenmehl.
  - Mischungsverhältnis:  $1.2 \cdot x + y$ .
  - Maximale Brotmenge:  $1.2 \cdot x + y \leq 120$ .

## Einfaches Beispiel



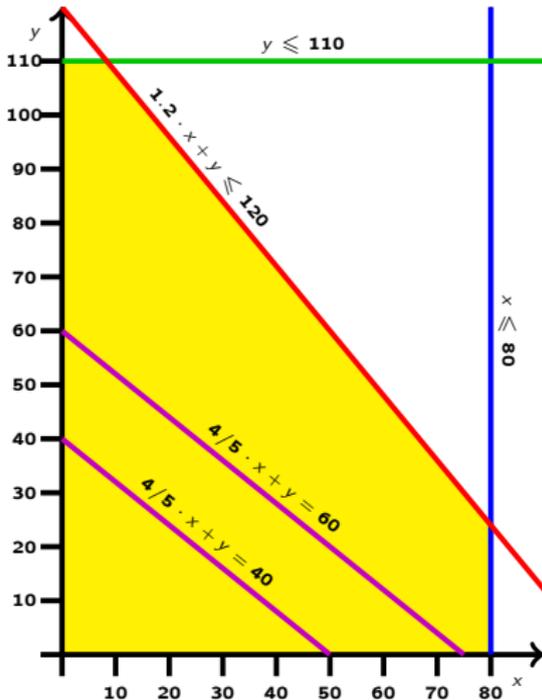
- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl
  - $y$  kg Roggenmehl
  - Maximal 80 kg Weizenmehl.
  - Maximal 110 kg Roggenmehl.
  - Mischungsverhältnis:  $1.2 \cdot x + y$ .
  - Maximale Brotmenge:  $1.2 \cdot x + y \leq 120$ .
  - Zu optimieren:  $f(x, y) = 4/5 \cdot x + y$ .

## Einfaches Beispiel



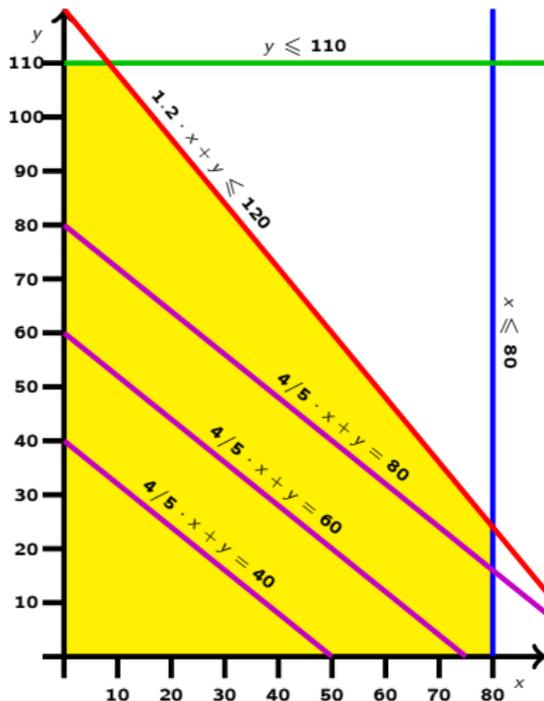
- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl
  - $y$  kg Roggenmehl
  - Maximal 80 kg Weizenmehl.
  - Maximal 110 kg Roggenmehl.
  - Mischungsverhältnis:  $1.2 \cdot x + y$ .
  - Maximale Brotmenge:  $1.2 \cdot x + y \leq 120$ .
  - Zu optimieren:  $f(x, y) = \frac{4}{5} \cdot x + y$ .

## Einfaches Beispiel



- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl
  - $y$  kg Roggenmehl
  - Maximal 80 kg Weizenmehl.
  - Maximal 110 kg Roggenmehl.
  - Mischungsverhältnis:  $1.2 \cdot x + y$ .
  - Maximale Brotmenge:  $1.2 \cdot x + y \leq 120$ .
  - Zu optimieren:  $f(x, y) = \frac{4}{5} \cdot x + y$ .

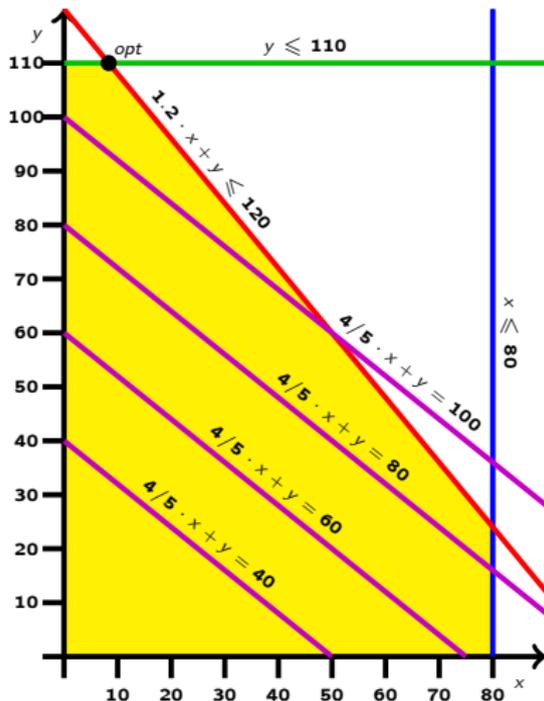
## Einfaches Beispiel



- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl
  - $y$  kg Roggenmehl
  - Maximal 80 kg Weizenmehl.
  - Maximal 110 kg Roggenmehl.
  - Mischungsverhältnis:  $1.2 \cdot x + y$ .
  - Maximale Brotmenge:  $1.2 \cdot x + y \leq 120$ .
  - Zu optimieren:  $f(x, y) = \frac{4}{5} \cdot x + y$ .

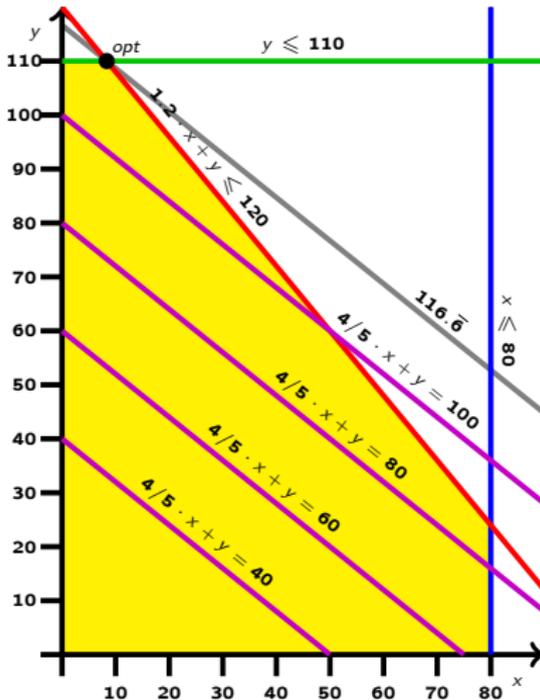


## Einfaches Beispiel



- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine “Zielfunktion” zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl
  - $y$  kg Roggenmehl
  - Maximal 80 kg Weizenmehl.
  - Maximal 110 kg Roggenmehl.
  - Mischungsverhältnis:  $1.2 \cdot x + y$ .
  - Maximale Brotmenge:  $1.2 \cdot x + y \leq 120$ .
  - Zu optimieren:  $f(x, y) = \frac{4}{5} \cdot x + y$ .

## Einfaches Beispiel



- Wir betrachten ein System von linearen Ungleichungen.
- Dabei ist eine "Zielfunktion" zu optimieren.
- Beispiel (Brotrezept):
  - $x$  kg Weizenmehl
  - $y$  kg Roggenmehl
  - Maximal 80 kg Weizenmehl.
  - Maximal 110 kg Roggenmehl.
  - Mischungsverhältnis:  $1.2 \cdot x + y$ .
  - Maximale Brotmenge:  $1.2 \cdot x + y \leq 120$ .
  - Zu optimieren:  $f(x, y) = 4/5 \cdot x + y$ .

## Beispiel: Flussproblem

- Flussproblem:

## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .

## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .
  - Maximiere den Fluss.



## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .
  - Maximiere den Fluss.
- als lineares Programm:
  - Variablen  $x_e$  für  $e \in E$ .

## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .
  - Maximiere den Fluss.
- als lineares Programm:
  - Variablen  $x_e$  für  $e \in E$ .
  - Maximiere

$$\sum_{e \in N_{out}(s) \in E} x_e.$$

## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .
  - Maximiere den Fluss.
- als lineares Programm:
  - Variablen  $x_e$  für  $e \in E$ .
  - Maximiere

$$\sum_{e \in N_{out}(s) \in E} x_e.$$

- unter Einhaltung der Bedingungen:

## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .
  - Maximiere den Fluss.

- als lineares Programm:
  - Variablen  $x_e$  für  $e \in E$ .
  - Maximiere

$$\sum_{e \in N_{out}(s) \in E} x_e.$$

- unter Einhaltung der Bedingungen:
  - Für jeden Knoten  $v \in V \setminus \{s, t\}$ :  $\sum_{e \in N_{in}(v)} x_e = \sum_{e \in N_{out}(v)} x_e$ ,

## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .
  - Maximiere den Fluss.
- als lineares Programm:
  - Variablen  $x_e$  für  $e \in E$ .
  - Maximiere

$$\sum_{e \in N_{out}(s) \in E} x_e.$$

- unter Einhaltung der Bedingungen:
  - Für jeden Knoten  $v \in V \setminus \{s, t\}$ :  $\sum_{e \in N_{in}(v)} x_e = \sum_{e \in N_{out}(v)} x_e$ ,
  - $\forall e \in E : x_e \leq c_e$ , und

## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .
  - Maximiere den Fluss.
- als lineares Programm:
  - Variablen  $x_e$  für  $e \in E$ .
  - Maximiere

$$\sum_{e \in N_{out}(s) \in E} x_e.$$

- unter Einhaltung der Bedingungen:
  - Für jeden Knoten  $v \in V \setminus \{s, t\}$ :  $\sum_{e \in N_{in}(v)} x_e = \sum_{e \in N_{out}(v)} x_e$ ,
  - $\forall e \in E : x_e \leq c_e$ , und
  - $\forall e \in E : x_e \geq 0$ .

## Beispiel: Flussproblem

- Flussproblem:
  - Gegeben  $G = (V, E, s, t, c)$  mit  $c : E \mapsto \mathbb{N}$ .
  - Maximiere den Fluss.
- als lineares Programm:
  - Variablen  $x_e$  für  $e \in E$ .
  - Maximiere

$$\sum_{e \in N_{out}(s) \in E} x_e.$$

- unter Einhaltung der Bedingungen:
  - Für jeden Knoten  $v \in V \setminus \{s, t\}$ :  $\sum_{e \in N_{in}(v)} x_e = \sum_{e \in N_{out}(v)} x_e$ ,
  - $\forall e \in E : x_e \leq c_e$ , und
  - $\forall e \in E : x_e \geq 0$ .

## Beispiel: Relaxiertes Rucksackproblem

- Relaxiertes Rucksackproblem:

## Beispiel: Relaxiertes Rucksackproblem

- Relaxiertes Rucksackproblem:
  - gegeben  $d$  teilbare Objekte mit Gewichten  $g_i$  und

## Beispiel: Relaxiertes Rucksackproblem

- Relaxiertes Rucksackproblem:
  - gegeben  $d$  teilbare Objekte mit Gewichten  $g_i$  und
  - die Gewichtsschranke  $G$  des Rucksacks.

## Beispiel: Relaxiertes Rucksackproblem

- Relaxiertes Rucksackproblem:
  - gegeben  $d$  teilbare Objekte mit Gewichten  $g_i$  und
  - die Gewichtsschranke  $G$  des Rucksacks.
  - Und  $v_i$  sei der Nutzen für  $1 \leq i \leq d$ .











## Beispiel: Relaxiertes Rucksackproblem

- Relaxiertes Rucksackproblem:
  - gegeben  $d$  teilbare Objekte mit Gewichten  $g_i$  und
  - die Gewichtsschranke  $G$  des Rucksacks.
  - Und  $v_i$  sei der Nutzen für  $1 \leq i \leq d$ .
  - Sei  $x_i$  der Anteil von Objekt  $i$ .
  - Fülle den Rucksack. Dabei soll der Nutzen maximal sein.
- Als lineares Programm:
  - Maximiere

$$\sum_{i=1}^d v_i \cdot x_i.$$

- unter den Nebenbedingungen:
  - $\sum_{i=1}^d g_i \cdot x_i \leq G,$

## Beispiel: Relaxiertes Rucksackproblem

- Relaxiertes Rucksackproblem:
  - gegeben  $d$  teilbare Objekte mit Gewichten  $g_i$  und
  - die Gewichtsschranke  $G$  des Rucksacks.
  - Und  $v_i$  sei der Nutzen für  $1 \leq i \leq d$ .
  - Sei  $x_i$  der Anteil von Objekt  $i$ .
  - Fülle den Rucksack. Dabei soll der Nutzen maximal sein.
- Als lineares Programm:
  - Maximiere

$$\sum_{i=1}^d v_i \cdot x_i.$$

- unter den Nebenbedingungen:
  - $\sum_{i=1}^d g_i \cdot x_i \leq G,$
  - $\forall i: 1 \leq i \leq d: x_i \leq 1,$  und

## Beispiel: Relaxiertes Rucksackproblem

- Relaxiertes Rucksackproblem:
  - gegeben  $d$  teilbare Objekte mit Gewichten  $g_i$  und
  - die Gewichtsschranke  $G$  des Rucksacks.
  - Und  $v_i$  sei der Nutzen für  $1 \leq i \leq d$ .
  - Sei  $x_i$  der Anteil von Objekt  $i$ .
  - Fülle den Rucksack. Dabei soll der Nutzen maximal sein.
- Als lineares Programm:
  - Maximiere

$$\sum_{i=1}^d v_i \cdot x_i.$$

- unter den Nebenbedingungen:
  - $\sum_{i=1}^d g_i \cdot x_i \leq G,$
  - $\forall i : 1 \leq i \leq d : x_i \leq 1,$  und
  - $\forall i : 1 \leq i \leq d : x_i \geq 0.$

## Beispiel: Relaxiertes Rucksackproblem

- Relaxiertes Rucksackproblem:
  - gegeben  $d$  teilbare Objekte mit Gewichten  $g_i$  und
  - die Gewichtsschranke  $G$  des Rucksacks.
  - Und  $v_i$  sei der Nutzen für  $1 \leq i \leq d$ .
  - Sei  $x_i$  der Anteil von Objekt  $i$ .
  - Fülle den Rucksack. Dabei soll der Nutzen maximal sein.
- Als lineares Programm:
  - Maximiere

$$\sum_{i=1}^d v_i \cdot x_i.$$

- unter den Nebenbedingungen:
  - $\sum_{i=1}^d g_i \cdot x_i \leq G,$
  - $\forall i : 1 \leq i \leq d : x_i \leq 1,$  und
  - $\forall i : 1 \leq i \leq d : x_i \geq 0.$

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.
  - $n = N_E + N_R$ .



## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.
  - $n = N_E + N_R$ .
  - Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
  - $m$  Anzahl der Lichtwege.

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.
  - $n = N_E + N_R$ .
  - Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
  - $m$  Anzahl der Lichtwege.
  - $E: (i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .



## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.
  - $n = N_E + N_R$ .
  - Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
  - $m$  Anzahl der Lichtwege.
  - $E: (i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
  - $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
  - $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.
  - $n = N_E + N_R$ .
  - Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
  - $m$  Anzahl der Lichtwege.
  - $E: (i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
  - $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
  - $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.
  - $\Omega_{max}$ : Congestion des Netzwerks.

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.
  - $n = N_E + N_R$ .
  - Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
  - $m$  Anzahl der Lichtwege.
  - $E: (i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
  - $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
  - $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.
  - $\Omega_{max}$ : Congestion des Netzwerks.
  - $X_{ij}^k \in \{0, 1\}$  mit:

$$X_{ij}^k = \begin{cases} 1 & \text{der } k\text{-te Weg nutzt Kante } (i, j) \in E \\ 0 & \text{sonst} \end{cases}$$

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.
  - $n = N_E + N_R$ .
  - Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
  - $m$  Anzahl der Lichtwege.
  - $E$ :  $(i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
  - $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
  - $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.
  - $\Omega_{max}$ : Congestion des Netzwerks.
  - $X_{ij}^k \in \{0, 1\}$  mit:

$$X_{ij}^k = \begin{cases} 1 & \text{der } k\text{-te Weg nutzt Kante } (i, j) \in E \\ 0 & \text{sonst} \end{cases}$$

- Wegen  $X_{ij}^k \in \{0, 1\}$  ist dies hier ein "Integer Linear Programm".

## Beispiel: Routing und Wellenlängenzuweisung

- Routing und Wellenlängenzuweisung: bestimme die Wellenlängen in einem optischen Netzwerk. In dem Netzwerk gibt es Kommunikationsanfragen für Paare von Knoten.
  - $N_E$  Endknoten.
  - $N_R$  Router mit Konverter.
  - $n = N_E + N_R$ .
  - Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
  - $m$  Anzahl der Lichtwege.
  - $E$ :  $(i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
  - $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
  - $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.
  - $\Omega_{max}$ : Congestion des Netzwerks.
  - $X_{ij}^k \in \{0, 1\}$  mit:

$$X_{ij}^k = \begin{cases} 1 & \text{der } k\text{-te Weg nutzt Kante } (i, j) \in E \\ 0 & \text{sonst} \end{cases}$$

- Wegen  $X_{ij}^k \in \{0, 1\}$  ist dies hier ein "Integer Linear Programm".

# Routing und Wellenlängenzuweisung als ILP

$$\begin{aligned}
 & n = N_E + N_R \\
 & \text{src}(k) \longleftrightarrow \text{dst}(k) : (\mathbf{1} \leq k \leq m) \\
 & X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)
 \end{aligned}$$

- Minimiere Zielfunktion  $\Omega_{max}$ .

# Routing und Wellenlängenzuweisung als ILP

$$\begin{aligned}
 & n = N_E + N_R \\
 & \text{src}(k) \longleftrightarrow \text{dst}(k) : (\mathbf{1} \leq k \leq m) \\
 & X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)
 \end{aligned}$$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .

## Routing und Wellenlängenzuweisung als ILP

$$n = N_E + N_R$$

$$src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$$

$$X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .
- Für alle  $k : 1 \leq k \leq m$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^k - \sum_{j:(j,i) \in E} X_{ji}^k = \begin{cases} 1 & \text{falls } src(k) = i \\ -1 & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

## Routing und Wellenlängenzuweisung als ILP

$$n = N_E + N_R$$

$$src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$$

$$X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .
- Für alle  $k : 1 \leq k \leq m$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^k - \sum_{j:(j,i) \in E} X_{ji}^k = \begin{cases} 1 & \text{falls } src(k) = i \\ -1 & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Dies ist eine korrekte Formulierung des Routen- und Wellenlängenzuweisungsproblems als ILP.

# Routing und Wellenlängenzuweisung als ILP

$n = N_E + N_R$   
 $src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$   
 $X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .
- Für alle  $k : 1 \leq k \leq m$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^k - \sum_{j:(j,i) \in E} X_{ji}^k = \begin{cases} 1 & \text{falls } src(k) = i \\ -1 & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Dies ist eine korrekte Formulierung des Routen- und Wellenlängenzuweisungsproblems als ILP.
- Komplexität:

## Routing und Wellenlängenzuweisung als ILP

$$n = N_E + N_R$$

$$src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$$

$$X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .
- Für alle  $k : 1 \leq k \leq m$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^k - \sum_{j:(j,i) \in E} X_{ji}^k = \begin{cases} 1 & \text{falls } src(k) = i \\ -1 & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Dies ist eine korrekte Formulierung des Routen- und Wellenlängenzuweisungsproblems als ILP.
- Komplexität:
  - $m \cdot |E|$  Variablen der Form  $X_{ij}^k$ .

## Routing und Wellenlängenzuweisung als ILP

$n = N_E + N_R$   
 $src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$   
 $X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .
- Für alle  $k : 1 \leq k \leq m$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^k - \sum_{j:(j,i) \in E} X_{ji}^k = \begin{cases} 1 & \text{falls } src(k) = i \\ -1 & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Dies ist eine korrekte Formulierung des Routen- und Wellenlängenzuweisungsproblems als ILP.
- Komplexität:
  - $m \cdot |E|$  Variablen der Form  $X_{ij}^k$ .
  - Eine Variable  $\Omega_{max}$ .

# Routing und Wellenlängenzuweisung als ILP

$n = N_E + N_R$   
 $src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$   
 $X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .
- Für alle  $k : 1 \leq k \leq m$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^k - \sum_{j:(j,i) \in E} X_{ji}^k = \begin{cases} 1 & \text{falls } src(k) = i \\ -1 & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Dies ist eine korrekte Formulierung des Routen- und Wellenlängenzuweisungsproblems als ILP.
- Komplexität:
  - $m \cdot |E|$  Variablen der Form  $X_{ij}^k$ .
  - Eine Variable  $\Omega_{max}$ .
  - Nebenbedingungen:  $|E| + n \cdot m$ .

## Routing und Wellenlängenzuweisung als ILP

$$\begin{aligned}
 & n = N_E + N_R \\
 & \text{src}(k) \longleftrightarrow \text{dst}(k) : (\mathbf{1} \leq k \leq m) \\
 & X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)
 \end{aligned}$$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .
- Für alle  $k : 1 \leq k \leq m$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^k - \sum_{j:(j,i) \in E} X_{ji}^k = \begin{cases} 1 & \text{falls } \text{src}(k) = i \\ -1 & \text{falls } \text{dst}(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Dies ist eine korrekte Formulierung des Routen- und Wellenlängenzuweisungsproblems als ILP.
- Komplexität:
  - $m \cdot |E|$  Variablen der Form  $X_{ij}^k$ .
  - Eine Variable  $\Omega_{max}$ .
  - Nebenbedingungen:  $|E| + n \cdot m$ .
  - Schon für relativ kleine Netzwerke zu aufwendig.

# Routing und Wellenlängenzuweisung als ILP

$n = N_E + N_R$   
 $src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$   
 $X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$

- Minimiere Zielfunktion  $\Omega_{max}$ .
- $\sum_{k=1}^m X_{ij}^k \leq \Omega_{max}, \forall (i, j) \in E$ .
- Für alle  $k : 1 \leq k \leq m$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^k - \sum_{j:(j,i) \in E} X_{ji}^k = \begin{cases} 1 & \text{falls } src(k) = i \\ -1 & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Dies ist eine korrekte Formulierung des Routen- und Wellenlängenzuweisungsproblems als ILP.
- Komplexität:
  - $m \cdot |E|$  Variablen der Form  $X_{ij}^k$ .
  - Eine Variable  $\Omega_{max}$ .
  - Nebenbedingungen:  $|E| + n \cdot m$ .
  - Schon für relativ kleine Netzwerke zu aufwendig.

## Routen- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.

## Routen- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).

## Ruten- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
- $m$  Anzahl der Lichtwege;  $n_{ch}$  Anzahl der Wellenlängen.

## Routen- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
- $m$  Anzahl der Lichtwege;  $n_{ch}$  Anzahl der Wellenlängen.
- $E: (i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .

## Routen- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
- $m$  Anzahl der Lichtwege;  $n_{ch}$  Anzahl der Wellenlängen.
- $E$ :  $(i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
- $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.

## Routen- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
- $m$  Anzahl der Lichtwege;  $n_{ch}$  Anzahl der Wellenlängen.
- $E$ :  $(i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
- $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
- $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.

## Ruten- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
- $m$  Anzahl der Lichtwege;  $n_{ch}$  Anzahl der Wellenlängen.
- $E$ :  $(i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
- $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
- $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.
- $\Omega_{max}$ : Congestion des Netzwerks.

## Routen- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
- $m$  Anzahl der Lichtwege;  $n_{ch}$  Anzahl der Wellenlängen.
- $E$ :  $(i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
- $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
- $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.
- $\Omega_{max}$ : Congestion des Netzwerks.
- $X_{ij}^{wk} \in \{0, 1\}$  mit:

$$X_{ij}^{wk} = \begin{cases} 1 & \text{der } k\text{-te Weg nutzt } (i, j) \in E \text{ und W.länge } w \\ 0 & \text{sonst} \end{cases}$$

## Routen- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
- $m$  Anzahl der Lichtwege;  $n_{ch}$  Anzahl der Wellenlängen.
- $E$ :  $(i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
- $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
- $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.
- $\Omega_{max}$ : Congestion des Netzwerks.
- $X_{ij}^{wk} \in \{0, 1\}$  mit:

$$X_{ij}^{wk} = \begin{cases} 1 & \text{der } k\text{-te Weg nutzt } (i, j) \in E \text{ und W.länge } w \\ 0 & \text{sonst} \end{cases}$$

- $Y_w^k \in \{0, 1\}$  mit:

$$Y_w^k = \begin{cases} 1 & \text{der } k\text{-te Weg nutzt Wellenlänge } w \\ 0 & \text{sonst} \end{cases}$$

## Routen- und Wellenlängenzuweisung

- $N_E$  Endknoten;  $N_R$  Router ohne Konverter.
- $n = N_E + N_R$ ; Namen der Knoten:  $N_i$  ( $1 \leq i \leq n$ ).
- $m$  Anzahl der Lichtwege;  $n_{ch}$  Anzahl der Wellenlängen.
- $E$ :  $(i, j) \in E \iff$  Kante von  $N_i$  nach  $N_j$ .
- $src(k)$ : ist Startknoten der  $k$ -ten Anfrage.
- $dst(k)$ : ist Endknoten der  $k$ -ten Anfrage.
- $\Omega_{max}$ : Congestion des Netzwerks.
- $X_{ij}^{wk} \in \{0, 1\}$  mit:

$$X_{ij}^{wk} = \begin{cases} 1 & \text{der } k\text{-te Weg nutzt } (i, j) \in E \text{ und W.länge } w \\ 0 & \text{sonst} \end{cases}$$

- $Y_w^k \in \{0, 1\}$  mit:

$$Y_w^k = \begin{cases} 1 & \text{der } k\text{-te Weg nutzt Wellenlänge } w \\ 0 & \text{sonst} \end{cases}$$

## ILP:

$$n = N_E + N_R$$

$$\text{src}(k) \longleftrightarrow \text{dst}(k) : (\mathbf{1} \leq k \leq m)$$

$$X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$$

$$Y_w^k : k\text{-te Weg nutzt Wellenlänge } w$$

- Minimiere Zielfunktion  $\Omega_{max}$ :

$$\sum_{w=1}^{n_{ch}} \sum_{k=1}^m X_{ij}^{wk} \leq \Omega_{max}, \forall (i, j) \in E$$

## ILP:

$$n = N_E + N_R$$

$$src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$$

$$X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$$

$$Y_w^k : k\text{-te Weg nutzt Wellenlänge } w$$

- Minimiere Zielfunktion  $\Omega_{max}$ :

$$\sum_{w=1}^{n_{ch}} \sum_{k=1}^m X_{ij}^{wk} \leq \Omega_{max}, \forall (i, j) \in E$$

- Für alle  $k, w : 1 \leq k \leq m, 1 \leq w \leq n_{ch}$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^{wk} - \sum_{j:(j,i) \in E} X_{ji}^{wk} = \begin{cases} Y_w^k & \text{falls } src(k) = i \\ -Y_w^k & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

## ILP:

$$src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$$

$$X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$$

$$Y_w^k : k\text{-te Weg nutzt Wellenlänge } w$$

- Minimiere Zielfunktion  $\Omega_{max}$ :

$$\sum_{w=1}^{n_{ch}} \sum_{k=1}^m X_{ij}^{wk} \leq \Omega_{max}, \forall (i, j) \in E$$

- Für alle  $k, w : 1 \leq k \leq m, 1 \leq w \leq n_{ch}$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^{wk} - \sum_{j:(j,i) \in E} X_{ji}^{wk} = \begin{cases} Y_w^k & \text{falls } src(k) = i \\ -Y_w^k & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Für alle  $k : 1 \leq k \leq m$ :

$$\sum_{w=1}^{n_{ch}} Y_w^k = 1$$

## ILP:

$$src(k) \longleftrightarrow dst(k) : (\mathbf{1} \leq k \leq m)$$

$$X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$$

$$Y_w^k : k\text{-te Weg nutzt Wellenlänge } w$$

- Minimiere Zielfunktion  $\Omega_{max}$ :

$$\sum_{w=1}^{n_{ch}} \sum_{k=1}^m X_{ij}^{wk} \leq \Omega_{max}, \forall (i, j) \in E$$

- Für alle  $k, w : 1 \leq k \leq m, 1 \leq w \leq n_{ch}$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^{wk} - \sum_{j:(j,i) \in E} X_{ji}^{wk} = \begin{cases} Y_w^k & \text{falls } src(k) = i \\ -Y_w^k & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Für alle  $k : 1 \leq k \leq m$ :

$$\sum_{w=1}^{n_{ch}} Y_w^k = 1$$

- Für alle  $w : 1 \leq w \leq n_{ch}$  und alle  $(i, j) \in E$ :

$$\sum_{k=1}^m X_{ij}^{wk} \leq 1$$

## ILP:

$n = N_E + N_R$   
 $src(k) \longleftrightarrow dst(k) : (1 \leq k \leq m)$   
 $X_{ij}^k : k\text{-te Weg nutzt Kante } (i, j)$   
 $Y_w^k : k\text{-te Weg nutzt Wellenlänge } w$

- Minimiere Zielfunktion  $\Omega_{max}$ :

$$\sum_{w=1}^{n_{ch}} \sum_{k=1}^m X_{ij}^{wk} \leq \Omega_{max}, \forall (i, j) \in E$$

- Für alle  $k, w : 1 \leq k \leq m, 1 \leq w \leq n_{ch}$  und alle  $i : 1 \leq i \leq n$ :

$$\sum_{j:(i,j) \in E} X_{ij}^{wk} - \sum_{j:(j,i) \in E} X_{ji}^{wk} = \begin{cases} Y_w^k & \text{falls } src(k) = i \\ -Y_w^k & \text{falls } dst(k) = i \\ 0 & \text{sonst} \end{cases}$$

- Für alle  $k : 1 \leq k \leq m$ :

$$\sum_{w=1}^{n_{ch}} Y_w^k = 1$$

- Für alle  $w : 1 \leq w \leq n_{ch}$  und alle  $(i, j) \in E$ :

$$\sum_{k=1}^m X_{ij}^{wk} \leq 1$$

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),

# Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .

# Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:

# Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:
    - $\sum_{j=1}^d a_{ij} \cdot x_j \leq b_i$  für  $i \in \{1, 2, \dots, m\}$  und

# Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:
    - $\sum_{j=1}^d a_{ij} \cdot x_j \leq b_i$  für  $i \in \{1, 2, \dots, m\}$  und
    - $x_j \geq 0$  für  $j \in \{1, 2, \dots, d\}$ .

# Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:
    - $\sum_{j=1}^d a_{ij} \cdot x_j \leq b_i$  für  $i \in \{1, 2, \dots, m\}$  und
    - $x_j \geq 0$  für  $j \in \{1, 2, \dots, d\}$ .
- Setze:

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:
      - $\sum_{j=1}^d a_{ij} \cdot x_j \leq b_i$  für  $i \in \{1, 2, \dots, m\}$  und
      - $x_j \geq 0$  für  $j \in \{1, 2, \dots, d\}$ .
- Setze:
  - $x = (x_j)$ ,  $c = (c_j)$ ,  $b = (b_i)$  und  $A = (a_{ij})$ .

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:
    - $\sum_{j=1}^d a_{ij} \cdot x_j \leq b_i$  für  $i \in \{1, 2, \dots, m\}$  und
    - $x_j \geq 0$  für  $j \in \{1, 2, \dots, d\}$ .
- Setze:
  - $x = (x_j)$ ,  $c = (c_j)$ ,  $b = (b_i)$  und  $A = (a_{ij})$ .
- Dann ist kurzgefasst die kanonische Form:

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:
      - $\sum_{j=1}^d a_{ij} \cdot x_j \leq b_i$  für  $i \in \{1, 2, \dots, m\}$  und
      - $x_j \geq 0$  für  $j \in \{1, 2, \dots, d\}$ .
- Setze:
  - $x = (x_j)$ ,  $c = (c_j)$ ,  $b = (b_i)$  und  $A = (a_{ij})$ .
- Dann ist kurzgefasst die kanonische Form:
  - Maximiere  $c^T \cdot x$  unter den Nebenbedingungen:

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:
      - $\sum_{j=1}^d a_{ij} \cdot x_j \leq b_i$  für  $i \in \{1, 2, \dots, m\}$  und
      - $x_j \geq 0$  für  $j \in \{1, 2, \dots, d\}$ .
- Setze:
  - $x = (x_j)$ ,  $c = (c_j)$ ,  $b = (b_i)$  und  $A = (a_{ij})$ .
- Dann ist kurzgefasst die kanonische Form:
  - Maximiere  $c^T \cdot x$  unter den Nebenbedingungen:
  - $A \cdot x \leq b$  und  $x \geq 0$ .

## Kanonische Form eines LP

- Ein LP ist in kanonischer Form, falls:
  - Es gibt  $d$  Variablen  $x_i \in \mathbb{R}$  ( $1 \leq i \leq d$ ),
  - Werte  $c_j \in \mathbb{R}$  für  $1 \leq j \leq d$ ,
  - Werte  $b_i \in \mathbb{R}$  für  $1 \leq i \leq m$  und
  - Werte  $a_{i,j} \in \mathbb{R}$  für  $1 \leq j \leq d$  und  $1 \leq i \leq m$ .
  - Gesucht ist eine Belegung der Variablen  $x_i \in \mathbb{R}$  mit:
    - Maximiere Zielfunktion  $\sum_{j=1}^d c_j \cdot x_j$
    - unter den Nebenbedingungen:
      - $\sum_{j=1}^d a_{ij} \cdot x_j \leq b_i$  für  $i \in \{1, 2, \dots, m\}$  und
      - $x_j \geq 0$  für  $j \in \{1, 2, \dots, d\}$ .
- Setze:
  - $x = (x_j)$ ,  $c = (c_j)$ ,  $b = (b_i)$  und  $A = (a_{ij})$ .
- Dann ist kurzgefasst die kanonische Form:
  - Maximiere  $c^T \cdot x$  unter den Nebenbedingungen:
  - $A \cdot x \leq b$  und  $x \geq 0$ .



## Umformungen zur kanonischen Form

- Minimierungsproblem in ein Maximierungsproblem:
  - $c^T \cdot x$  wird zu  $-c^T \cdot x$ .







## Umformungen zur kanonischen Form

- Minimierungsproblem in ein Maximierungsproblem:
  - $c^T \cdot x$  wird zu  $-c^T \cdot x$ .
- Eine Gleichung  $a^T \cdot x = b$  wird ersetzt durch
  - $a^T \cdot x \leq b$  und
  - $a^T \cdot x \geq b$ .
- Eine Gleichung  $a^T \cdot x \geq b$  wird ersetzt durch

## Umformungen zur kanonischen Form

- Minimierungsproblem in ein Maximierungsproblem:
  - $c^T \cdot x$  wird zu  $-c^T \cdot x$ .
- Eine Gleichung  $a^T \cdot x = b$  wird ersetzt durch
  - $a^T \cdot x \leq b$  und
  - $a^T \cdot x \geq b$ .
- Eine Gleichung  $a^T \cdot x \geq b$  wird ersetzt durch
  - $-a^T \cdot x \leq -b$ .





## Umformungen zur kanonischen Form

- Minimierungsproblem in ein Maximierungsproblem:
  - $c^T \cdot x$  wird zu  $-c^T \cdot x$ .
- Eine Gleichung  $a^T \cdot x = b$  wird ersetzt durch
  - $a^T \cdot x \leq b$  und
  - $a^T \cdot x \geq b$ .
- Eine Gleichung  $a^T \cdot x \geq b$  wird ersetzt durch
  - $-a^T \cdot x \leq -b$ .
- Eine möglicherweise negative Variable  $x \in \mathbb{R}$  wird ersetzt durch:
  - $x' - x''$  und den Nebenbedingungen:
  - $x' \geq 0$  und

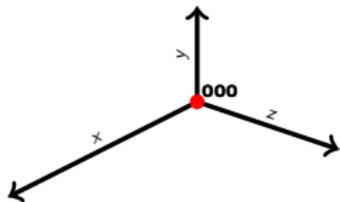
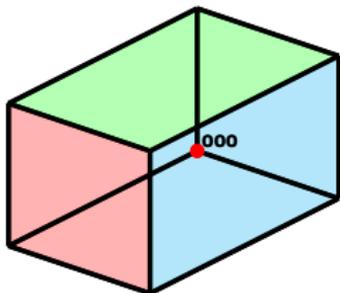
## Umformungen zur kanonischen Form

- Minimierungsproblem in ein Maximierungsproblem:
  - $c^T \cdot x$  wird zu  $-c^T \cdot x$ .
- Eine Gleichung  $a^T \cdot x = b$  wird ersetzt durch
  - $a^T \cdot x \leq b$  und
  - $a^T \cdot x \geq b$ .
- Eine Gleichung  $a^T \cdot x \geq b$  wird ersetzt durch
  - $-a^T \cdot x \leq -b$ .
- Eine möglicherweise negative Variable  $x \in \mathbb{R}$  wird ersetzt durch:
  - $x' - x''$  und den Nebenbedingungen:
  - $x' \geq 0$  und
  - $x'' \geq 0$ .





# Geometrische Interpretation



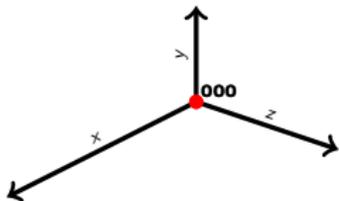
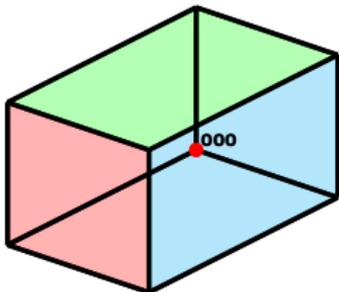
$$0 \leq x \leq t$$

$$0 \leq y \leq t$$

$$0 \leq z \leq t$$

- Eine Variablenbelegung  $x = (x_1, x_2, \dots, x_d)$  entspricht einem Punkt im  $d$ -dimensionalen Raum.

## Geometrische Interpretation



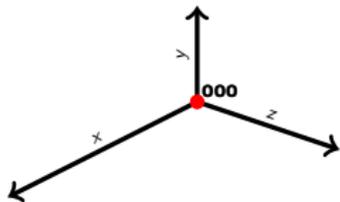
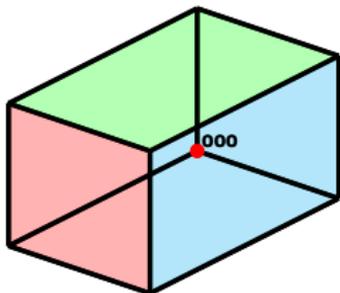
$$0 \leq x \leq t$$

$$0 \leq y \leq t$$

$$0 \leq z \leq t$$

- Eine Variablenbelegung  $x = (x_1, x_2, \dots, x_d)$  entspricht einem Punkt im  $d$ -dimensionalen Raum.
- Eine Nebenbedingung  $a_i \cdot x \leq b_i$  definiert einen Halbraum.

## Geometrische Interpretation



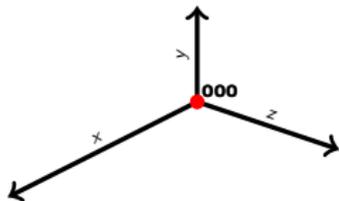
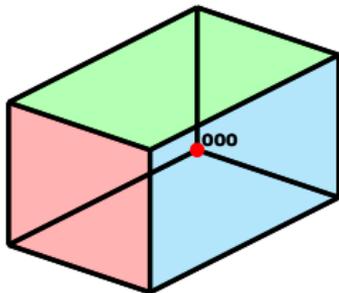
$$0 \leq x \leq t$$

$$0 \leq y \leq t$$

$$0 \leq z \leq t$$

- Eine Variablenbelegung  $x = (x_1, x_2, \dots, x_d)$  entspricht einem Punkt im  $d$ -dimensionalen Raum.
- Eine Nebenbedingung  $a_i \cdot x \leq b_i$  definiert einen Halbraum.
- Die Grenze des Halbraums ist die Hyperebene  $a_i \cdot x = b_i$ .

## Geometrische Interpretation



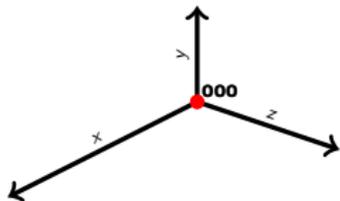
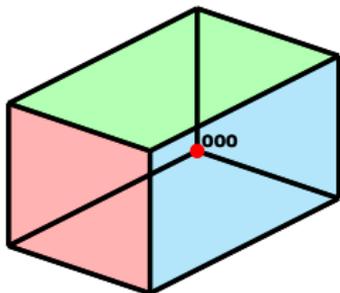
$$0 \leq x \leq t$$

$$0 \leq y \leq t$$

$$0 \leq z \leq t$$

- Eine Variablenbelegung  $x = (x_1, x_2, \dots, x_d)$  entspricht einem Punkt im  $d$ -dimensionalen Raum.
- Eine Nebenbedingung  $a_i \cdot x \leq b_i$  definiert einen Halbraum.
- Die Grenze des Halbraums ist die Hyperebene  $a_i \cdot x = b_i$ .
- Der Schnitt aller Halbräume ist der Raum der zulässigen Lösungen.

## Geometrische Interpretation



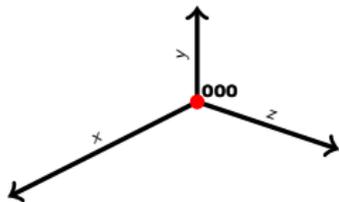
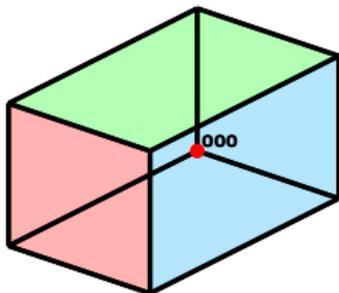
$$0 \leq x \leq t$$

$$0 \leq y \leq t$$

$$0 \leq z \leq t$$

- Eine Variablenbelegung  $x = (x_1, x_2, \dots, x_d)$  entspricht einem Punkt im  $d$ -dimensionalen Raum.
- Eine Nebenbedingung  $a_i \cdot x \leq b_i$  definiert einen Halbraum.
- Die Grenze des Halbraums ist die Hyperebene  $a_i \cdot x = b_i$ .
- Der Schnitt aller Halbräume ist der Raum der zulässigen Lösungen.
- Ein LP wird als zulässig bezeichnet, wenn es zulässige Lösungen gibt.

## Geometrische Interpretation



$$0 \leq x \leq t$$

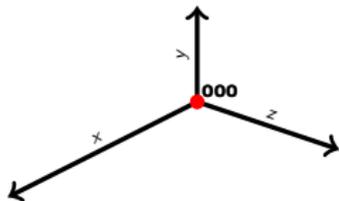
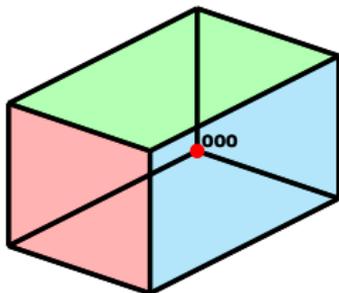
$$0 \leq y \leq t$$

$$0 \leq z \leq t$$

- Eine Variablenbelegung  $x = (x_1, x_2, \dots, x_d)$  entspricht einem Punkt im  $d$ -dimensionalen Raum.
- Eine Nebenbedingung  $a_i \cdot x \leq b_i$  definiert einen Halbraum.
- Die Grenze des Halbraums ist die Hyperebene  $a_i \cdot x = b_i$ .
- Der Schnitt aller Halbräume ist der Raum der zulässigen Lösungen.
- Ein LP wird als zulässig bezeichnet, wenn es zulässige Lösungen gibt.
- Schnittmengen von Halbräumen bilden ein Polyhedron.



## Geometrische Interpretation



$$0 \leq x \leq t$$

$$0 \leq y \leq t$$

$$0 \leq z \leq t$$

- Eine Variablenbelegung  $x = (x_1, x_2, \dots, x_d)$  entspricht einem Punkt im  $d$ -dimensionalen Raum.
- Eine Nebenbedingung  $a_i \cdot x \leq b_i$  definiert einen Halbraum.
- Die Grenze des Halbraums ist die Hyperebene  $a_i \cdot x = b_i$ .
- Der Schnitt aller Halbräume ist der Raum der zulässigen Lösungen.
- Ein LP wird als zulässig bezeichnet, wenn es zulässige Lösungen gibt.
- Schnittmengen von Halbräumen bilden ein Polyhedron.
- Damit bilden die zulässigen Lösungen ein Polyhedron.

## Konvexität

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

## Konvexität

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .
- Ein Halbraum ist konvex.

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .
- Ein Halbraum ist konvex.
- Ein Polyhedron ist der Schnitt von Halbräumen.

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .
- Ein Halbraum ist konvex.
- Ein Polyhedron ist der Schnitt von Halbräumen.
- Zeige: Der Schnitt von konvexen Mengen ist konvex.

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .
- Ein Halbraum ist konvex.
- Ein Polyhedron ist der Schnitt von Halbräumen.
- Zeige: Der Schnitt von konvexen Mengen ist konvex.
- D.h. aus  $A, B$  konvex folgt  $A \cap B$  konvex.

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .
- Ein Halbraum ist konvex.
- Ein Polyhedron ist der Schnitt von Halbräumen.
- Zeige: Der Schnitt von konvexen Mengen ist konvex.
- D.h. aus  $A, B$  konvex folgt  $A \cap B$  konvex.
- Damit gilt:  $\forall a, b \in A : I(a, b) \in A$  und

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .
- Ein Halbraum ist konvex.
- Ein Polyhedron ist der Schnitt von Halbräumen.
- Zeige: Der Schnitt von konvexen Mengen ist konvex.
- D.h. aus  $A, B$  konvex folgt  $A \cap B$  konvex.
- Damit gilt:  $\forall a, b \in A : I(a, b) \in A$  und
- weiter  $\forall a, b \in B : I(a, b) \in B$ .

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .
- Ein Halbraum ist konvex.
- Ein Polyhedron ist der Schnitt von Halbräumen.
- Zeige: Der Schnitt von konvexen Mengen ist konvex.
- D.h. aus  $A, B$  konvex folgt  $A \cap B$  konvex.
- Damit gilt:  $\forall a, b \in A : I(a, b) \in A$  und
- weiter  $\forall a, b \in B : I(a, b) \in B$ .
- Es folgt:  $\forall a, b \in A \cap B : I(a, b) \in A \cap B$ .

## Lemma

*Ein Polyhedron  $P$  ist konvex.*

Beweis:

- Konvex:  $\forall a, b \in P : I(a, b) \in P$  mit:
- $I(a, b) = \{\lambda a + (1 - \lambda)b \mid 0 \leq \lambda \leq 1\}$ .
- Ein Halbraum ist konvex.
- Ein Polyhedron ist der Schnitt von Halbräumen.
- Zeige: Der Schnitt von konvexen Mengen ist konvex.
- D.h. aus  $A, B$  konvex folgt  $A \cap B$  konvex.
- Damit gilt:  $\forall a, b \in A : I(a, b) \in A$  und
- weiter  $\forall a, b \in B : I(a, b) \in B$ .
- Es folgt:  $\forall a, b \in A \cap B : I(a, b) \in A \cap B$ .

## Lokales und globales Optimum

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

## Lokales und globales Optimum

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

## Lokales und globales Optimum

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .
- Nach Definition von  $I$  gibt  $\lambda > 0$  mit:  $y = \lambda x + (1 - \lambda)z$ .

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .
- Nach Definition von  $I$  gibt  $\lambda > 0$  mit:  $y = \lambda x + (1 - \lambda)z$ .
- Es folgt:

$$c^T y = c^T(\lambda x + (1 - \lambda)z)$$

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .
- Nach Definition von  $I$  gibt  $\lambda > 0$  mit:  $y = \lambda x + (1 - \lambda)z$ .
- Es folgt:

$$c^T y = c^T(\lambda x + (1 - \lambda)z)$$

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .
- Nach Definition von  $I$  gibt  $\lambda > 0$  mit:  $y = \lambda x + (1 - \lambda)z$ .
- Es folgt:

$$\begin{aligned} c^T y &= c^T(\lambda x + (1 - \lambda)z) \\ &= \lambda c^T x + (1 - \lambda)c^T z \end{aligned}$$

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .
- Nach Definition von  $I$  gibt  $\lambda > 0$  mit:  $y = \lambda x + (1 - \lambda)z$ .
- Es folgt:

$$\begin{aligned} c^T y &= c^T(\lambda x + (1 - \lambda)z) \\ &= \lambda c^T x + (1 - \lambda)c^T z \\ &> \lambda c^T x + (1 - \lambda)c^T x \end{aligned}$$

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .
- Nach Definition von  $I$  gibt  $\lambda > 0$  mit:  $y = \lambda x + (1 - \lambda)z$ .
- Es folgt:

$$\begin{aligned}
 c^T y &= c^T(\lambda x + (1 - \lambda)z) \\
 &= \lambda c^T x + (1 - \lambda)c^T z \\
 &> \lambda c^T x + (1 - \lambda)c^T x \\
 &= c^T x
 \end{aligned}$$

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .
- Nach Definition von  $I$  gibt  $\lambda > 0$  mit:  $y = \lambda x + (1 - \lambda)z$ .
- Es folgt:

$$\begin{aligned}
 c^T y &= c^T(\lambda x + (1 - \lambda)z) \\
 &= \lambda c^T x + (1 - \lambda)c^T z \\
 &> \lambda c^T x + (1 - \lambda)c^T x \\
 &= c^T x
 \end{aligned}$$

## Lemma

Ein lokales Optimum ist auch ein globales Optimum.

## Lemma

Sei  $z, x \in P$  und  $c^T z > c^T x$ .

Dann existiert für  $\varepsilon > 0$  ein  $y \in P$  mit:  $\|x - y\| \leq \varepsilon$  und  $c^T y > c^T x$ .

Beweis:

- $P$  ist konvex, gilt  $I(x, z) \in P$ .
- Wähle  $y \in I(x, z)$  mit  $x \neq y$  und  $\|x - y\| \leq \varepsilon$ .
- Nach Definition von  $I$  gibt  $\lambda > 0$  mit:  $y = \lambda x + (1 - \lambda)z$ .
- Es folgt:

$$\begin{aligned}
 c^T y &= c^T(\lambda x + (1 - \lambda)z) \\
 &= \lambda c^T x + (1 - \lambda)c^T z \\
 &> \lambda c^T x + (1 - \lambda)c^T x \\
 &= c^T x
 \end{aligned}$$

## Lemma

Ein lokales Optimum ist auch ein globales Optimum.

# Unterräume

- Eine Hyperebene wird beschrieben durch:

$$\alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_d x_d = \beta.$$

# Unterräume

- Eine Hyperebene wird beschrieben durch:

$$\alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_d x_d = \beta.$$

- Es sind  $d - 1$  Variablen frei wählbar.

# Unterräume

- Eine Hyperebene wird beschrieben durch:

$$\alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_d x_d = \beta.$$

- Es sind  $d - 1$  Variablen frei wählbar.
- Der Wert der  $d$ -ten Variable ist dann festgelegt.

# Unterräume

- Eine Hyperebene wird beschrieben durch:

$$\alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_d x_d = \beta.$$

- Es sind  $d - 1$  Variablen frei wählbar.
- Der Wert der  $d$ -ten Variable ist dann festgelegt.
- Der durch die Hyperebene beschriebene affine Unterraum ist ein Unterraum der Dimension  $d - 1$ .



# Unterräume

- Eine Hyperebene wird beschrieben durch:

$$\alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_d x_d = \beta.$$

- Es sind  $d - 1$  Variablen frei wählbar.
- Der Wert der  $d$ -ten Variable ist dann festgelegt.
- Der durch die Hyperebene beschriebene affine Unterraum ist ein Unterraum der Dimension  $d - 1$ .
- Ein Unterraum, der als Schnittmenge von  $k$  linear unabhängigen Hyperräumen beschrieben wird, hat Dimension  $d - k$ .
- Falls mehr als  $d$  Nebenbedingungen (Hyperebenen) sich in einem Punkt treffen, so ist das LP degeneriert.

## Unterräume

- Eine Hyperebene wird beschrieben durch:

$$\alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_d x_d = \beta.$$

- Es sind  $d - 1$  Variablen frei wählbar.
- Der Wert der  $d$ -ten Variable ist dann festgelegt.
- Der durch die Hyperebene beschriebene affine Unterraum ist ein Unterraum der Dimension  $d - 1$ .
- Ein Unterraum, der als Schnittmenge von  $k$  linear unabhängigen Hyperräumen beschrieben wird, hat Dimension  $d - k$ .
- Falls mehr als  $d$  Nebenbedingungen (Hyperebenen) sich in einem Punkt treffen, so ist das LP degeneriert.
- Ein degeneriertes LP kann in ein nicht-degeneriertes LP umgeformt werden, ohne die Form (Zusammensetzung) der Lösung signifikant zu verändern.

## Unterräume

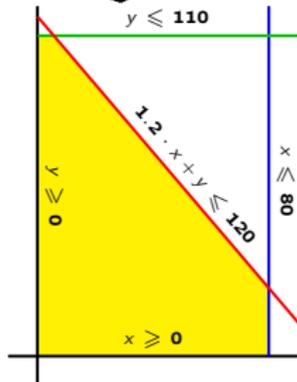
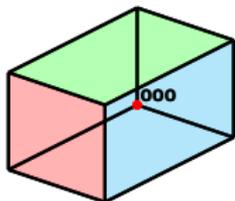
- Eine Hyperebene wird beschrieben durch:

$$\alpha_1 x_1 + \alpha_2 x_2 + \alpha_3 x_3 + \dots + \alpha_d x_d = \beta.$$

- Es sind  $d - 1$  Variablen frei wählbar.
- Der Wert der  $d$ -ten Variable ist dann festgelegt.
- Der durch die Hyperebene beschriebene affine Unterraum ist ein Unterraum der Dimension  $d - 1$ .
- Ein Unterraum, der als Schnittmenge von  $k$  linear unabhängigen Hyperräumen beschrieben wird, hat Dimension  $d - k$ .
- Falls mehr als  $d$  Nebenbedingungen (Hyperebenen) sich in einem Punkt treffen, so ist das LP degeneriert.
- Ein degeneriertes LP kann in ein nicht-degeneriertes LP umgeformt werden, ohne die Form (Zusammensetzung) der Lösung signifikant zu verändern.



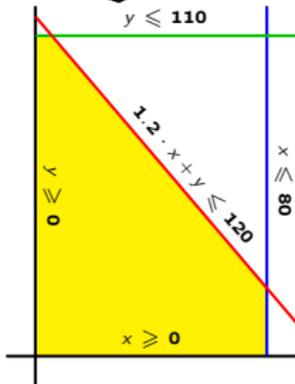
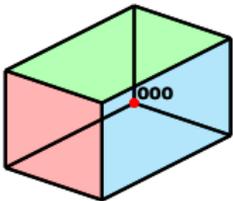
# Oberfläche eines Polyhedrons



- Die Oberfläche eines Polyhedrons besteht aus Facetten.

# Oberfläche eines Polyhedrons

$P$  Polyhedron



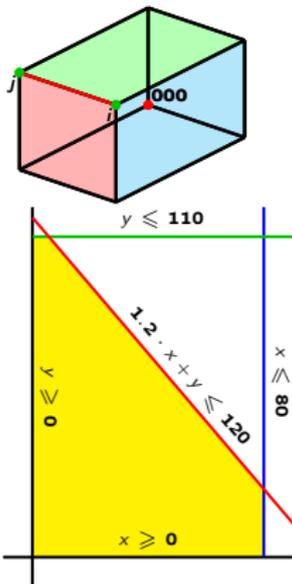
- Die Oberfläche eines Polyhedrons besteht aus Facetten.
  - Sei  $P$  ein Polyhedron und  $H$  eine Hyperebene und sei  $P$  komplett auf einer Seite der Hyperebene  $H$ .





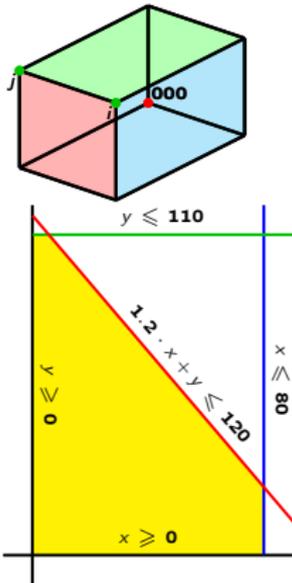
# Oberfläche eines Polyhedrons

$P$  Polyhedron



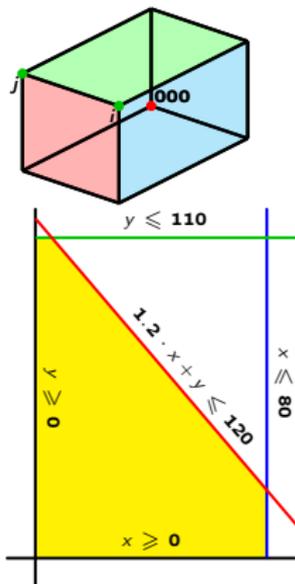
- Die Oberfläche eines Polyhedrons besteht aus Facetten.
  - Sei  $P$  ein Polyhedron und  $H$  eine Hyperebene und sei  $P$  komplett auf einer Seite der Hyperebene  $H$ .
  - Falls  $f = P \cap H$  nicht leer ist, so
  - ist  $f$  eine Facette von  $P$ .
  
- Eine Facette der Dimension  $d - 1$  heißt Face.

# Oberfläche eines Polyhedrons



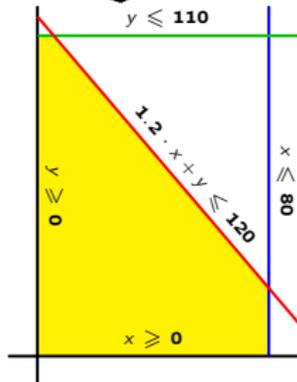
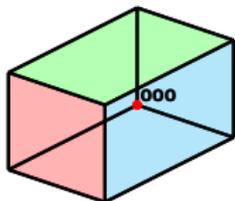
- Die Oberfläche eines Polyhedrons besteht aus Facetten.
  - Sei  $P$  ein Polyhedron und  $H$  eine Hyperebene und sei  $P$  komplett auf einer Seite der Hyperebene  $H$ .
  - Falls  $f = P \cap H$  nicht leer ist, so
  - ist  $f$  eine Facette von  $P$ .
- Eine Facette der Dimension  $d - 1$  heißt Face.
- Eine Kante entspricht dem Schnitt von  $d - 1$  Hyperebenen (Facette der Dimension 1).

## Oberfläche eines Polyhedrons



- Die Oberfläche eines Polyhedrons besteht aus Facetten.
  - Sei  $P$  ein Polyhedron und  $H$  eine Hyperebene und sei  $P$  komplett auf einer Seite der Hyperebene  $H$ .
  - Falls  $f = P \cap H$  nicht leer ist, so
  - ist  $f$  eine Facette von  $P$ .
- Eine Facette der Dimension  $d - 1$  heißt Face.
- Eine Kante entspricht dem Schnitt von  $d - 1$  Hyperebenen (Facette der Dimension 1).
- Ein Knoten entspricht dem Schnitt von  $d$  Hyperebenen (Facette der Dimension 0).

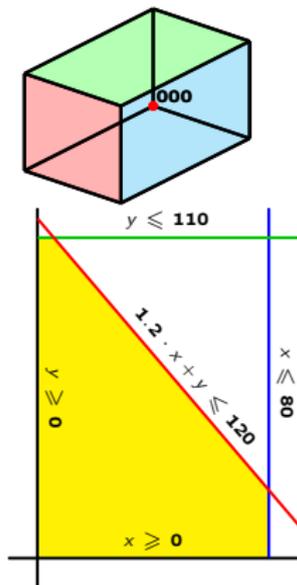
## Oberfläche eines Polyhedrons



- Die Oberfläche eines Polyhedrons besteht aus Facetten.
  - Sei  $P$  ein Polyhedron und  $H$  eine Hyperebene und sei  $P$  komplett auf einer Seite der Hyperebene  $H$ .
  - Falls  $f = P \cap H$  nicht leer ist, so
  - ist  $f$  eine Facette von  $P$ .
- Eine Facette der Dimension  $d - 1$  heißt Face.
- Eine Kante entspricht dem Schnitt von  $d - 1$  Hyperebenen (Facette der Dimension 1).
- Ein Knoten entspricht dem Schnitt von  $d$  Hyperebenen (Facette der Dimension 0).
- Zwei Knoten sind benachbart, wenn sie durch eine Kante verbunden sind.



## Oberfläche eines Polyhedrons



- Die Oberfläche eines Polyhedrons besteht aus Facetten.
  - Sei  $P$  ein Polyhedron und  $H$  eine Hyperebene und sei  $P$  komplett auf einer Seite der Hyperebene  $H$ .
  - Falls  $f = P \cap H$  nicht leer ist, so
  - ist  $f$  eine Facette von  $P$ .
- Eine Facette der Dimension  $d - 1$  heißt Face.
- Eine Kante entspricht dem Schnitt von  $d - 1$  Hyperebenen (Facette der Dimension 1).
- Ein Knoten entspricht dem Schnitt von  $d$  Hyperebenen (Facette der Dimension 0).
- Zwei Knoten sind benachbart, wenn sie durch eine Kante verbunden sind.
- Falls  $P$  unbeschränkt ist, so kann es unbeschränkte Kanten geben.
- Solche Kanten haben nur einen oder keinen Endpunkt.



# Zielfunktion

- Die Zielfunktion  $c^T x$  (Vektor) gibt eine Richtung in  $\mathbb{R}^d$  vor.

## Zielfunktion

- Die Zielfunktion  $c^T x$  (Vektor) gibt eine Richtung in  $\mathbb{R}^d$  vor.
- Falls die Nebenbedingungen den Zielwert nach oben beschränken, so wird das LP als beschränkt bezeichnet.

# Zielfunktion

- Die Zielfunktion  $c^T x$  (Vektor) gibt eine Richtung in  $\mathbb{R}^d$  vor.
- Falls die Nebenbedingungen den Zielwert nach oben beschränken, so wird das LP als beschränkt bezeichnet.
  - Falls der Zielwert nicht beschränkt ist, so heißt das LP unbeschränkt.



## Zielfunktion

- Die Zielfunktion  $c^T x$  (Vektor) gibt eine Richtung in  $\mathbb{R}^d$  vor.
- Falls die Nebenbedingungen den Zielwert nach oben beschränken, so wird das LP als beschränkt bezeichnet.
  - Falls der Zielwert nicht beschränkt ist, so heißt das LP unbeschränkt.
- Das Polyhedron muss dabei nur in der Richtung von  $c^T x$  beschränkt sein.
- Ist das Polyhedron in alle Richtungen beschränkt (in einer Kugel enthalten), so wird es als Polytop bezeichnet.

## Zielfunktion

- Die Zielfunktion  $c^T x$  (Vektor) gibt eine Richtung in  $\mathbb{R}^d$  vor.
- Falls die Nebenbedingungen den Zielwert nach oben beschränken, so wird das LP als beschränkt bezeichnet.
  - Falls der Zielwert nicht beschränkt ist, so heißt das LP unbeschränkt.
- Das Polyhedron muss dabei nur in der Richtung von  $c^T x$  beschränkt sein.
- Ist das Polyhedron in alle Richtungen beschränkt (in einer Kugel enthalten), so wird es als Polytop bezeichnet.

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.
- Damit gibt es  $t \in \mathbb{R}$  mit:  $\mathcal{H} = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .



## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.
- Damit gibt es  $t \in \mathbb{R}$  mit:  $\mathcal{H} = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Setze  $\mathcal{H}_t = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Sei  $\mathcal{H}$  so gewählt, dass  $P \cap \mathcal{H} \neq \emptyset$  gilt.

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.
- Damit gibt es  $t \in \mathbb{R}$  mit:  $\mathcal{H} = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Setze  $\mathcal{H}_t = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Sei  $\mathcal{H}$  so gewählt, dass  $P \cap \mathcal{H} \neq \emptyset$  gilt.
- Wähle  $z$  maximal mit  $P \cap \mathcal{H}_z \neq \emptyset$ .

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.
- Damit gibt es  $t \in \mathbb{R}$  mit:  $\mathcal{H} = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Setze  $\mathcal{H}_t = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Sei  $\mathcal{H}$  so gewählt, dass  $P \cap \mathcal{H} \neq \emptyset$  gilt.
- Wähle  $z$  maximal mit  $P \cap \mathcal{H}_z \neq \emptyset$ .
- Ein beliebiger Punkt  $x^* \in P \cap \mathcal{H}_z$  ist eine optimale Lösung des LPs.

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.
- Damit gibt es  $t \in \mathbb{R}$  mit:  $\mathcal{H} = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Setze  $\mathcal{H}_t = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Sei  $\mathcal{H}$  so gewählt, dass  $P \cap \mathcal{H} \neq \emptyset$  gilt.
- Wähle  $z$  maximal mit  $P \cap \mathcal{H}_z \neq \emptyset$ .
- Ein beliebiger Punkt  $x^* \in P \cap \mathcal{H}_z$  ist eine optimale Lösung des LPs.
- Beobachtungen:

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.
- Damit gibt es  $t \in \mathbb{R}$  mit:  $\mathcal{H} = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Setze  $\mathcal{H}_t = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Sei  $\mathcal{H}$  so gewählt, dass  $P \cap \mathcal{H} \neq \emptyset$  gilt.
- Wähle  $z$  maximal mit  $P \cap \mathcal{H}_z \neq \emptyset$ .
- Ein beliebiger Punkt  $x^* \in P \cap \mathcal{H}_z$  ist eine optimale Lösung des LPs.
- Beobachtungen:
  - $P \cap \mathcal{H}_z$  ist eine Facette  $f$  von  $P$ .

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.
- Damit gibt es  $t \in \mathbb{R}$  mit:  $\mathcal{H} = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Setze  $\mathcal{H}_t = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Sei  $\mathcal{H}$  so gewählt, dass  $P \cap \mathcal{H} \neq \emptyset$  gilt.
- Wähle  $z$  maximal mit  $P \cap \mathcal{H}_z \neq \emptyset$ .
- Ein beliebiger Punkt  $x^* \in P \cap \mathcal{H}_z$  ist eine optimale Lösung des LPs.
- Beobachtungen:
  - $P \cap \mathcal{H}_z$  ist eine Facette  $f$  von  $P$ .
  - Falls  $f$  nicht in allen Richtungen unbeschränkt ist, so gibt es mindestens einen optimalen Knoten.

## Geometrische Bestimmung des Optimums

- Betrachte beschränktes LP in kanonischer Form mit Lösungspolyhedron  $P$  und Zielfunktion  $c^T x$ ,
- Sei  $\mathcal{H}$  eine zum Vektor  $c$  orthogonale Hyperebene.
- Damit gibt es  $t \in \mathbb{R}$  mit:  $\mathcal{H} = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Setze  $\mathcal{H}_t = \{x \in \mathbb{R}^d \mid c^T \cdot x = t\}$ .
- Sei  $\mathcal{H}$  so gewählt, dass  $P \cap \mathcal{H} \neq \emptyset$  gilt.
- Wähle  $z$  maximal mit  $P \cap \mathcal{H}_z \neq \emptyset$ .
- Ein beliebiger Punkt  $x^* \in P \cap \mathcal{H}_z$  ist eine optimale Lösung des LPs.
- Beobachtungen:
  - $P \cap \mathcal{H}_z$  ist eine Facette  $f$  von  $P$ .
  - Falls  $f$  nicht in allen Richtungen unbeschränkt ist, so gibt es mindestens einen optimalen Knoten.

# Die Idee

- Kann eine zufällige Auswahl helfen?

## Die Idee

- Kann eine zufällige Auswahl helfen?
- Können effiziente Algorithmen noch schneller gemacht werden?

## Die Idee

- Kann eine zufällige Auswahl helfen?
- Können effiziente Algorithmen noch schneller gemacht werden?
- Kann bei schweren Problemen mit ausreichender Wahrscheinlichkeit ein gutes Ergebnis erreicht werden?

## Die Idee

- Kann eine zufällige Auswahl helfen?
- Können effiziente Algorithmen noch schneller gemacht werden?
- Kann bei schweren Problemen mit ausreichender Wahrscheinlichkeit ein gutes Ergebnis erreicht werden?

# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.

# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:

# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:
  - Gegeben sind  $d$  Variablen.



# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:
  - Gegeben sind  $d$  Variablen.
  - Gegeben sind  $m$  lineare Ungleichungen (Nebenbedingungen).
  - Gegeben ist eine lineare Zielfunktion  $f$  über die  $d$  Variablen.



# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:
  - Gegeben sind  $d$  Variablen.
  - Gegeben sind  $m$  lineare Ungleichungen (Nebenbedingungen).
  - Gegeben ist eine lineare Zielfunktion  $f$  über die  $d$  Variablen.
- Gesucht:
  - Maximiere  $f$  unter Berücksichtigung aller Nebenbedingungen.

# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:
  - Gegeben sind  $d$  Variablen.
  - Gegeben sind  $m$  lineare Ungleichungen (Nebenbedingungen).
  - Gegeben ist eine lineare Zielfunktion  $f$  über die  $d$  Variablen.
- Gesucht:
  - Maximiere  $f$  unter Berücksichtigung aller Nebenbedingungen.
- Das ist ein LP (lineares Programm)

# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:
  - Gegeben sind  $d$  Variablen.
  - Gegeben sind  $m$  lineare Ungleichungen (Nebenbedingungen).
  - Gegeben ist eine lineare Zielfunktion  $f$  über die  $d$  Variablen.
- Gesucht:
  - Maximiere  $f$  unter Berücksichtigung aller Nebenbedingungen.
- Das ist ein LP (lineares Programm)
- Obere Schranke für Laufzeit:  $O\left(\binom{m}{d}\right) = O(n^d)$ .

# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:
  - Gegeben sind  $d$  Variablen.
  - Gegeben sind  $m$  lineare Ungleichungen (Nebenbedingungen).
  - Gegeben ist eine lineare Zielfunktion  $f$  über die  $d$  Variablen.
- Gesucht:
  - Maximiere  $f$  unter Berücksichtigung aller Nebenbedingungen.
- Das ist ein LP (lineares Programm)
- Obere Schranke für Laufzeit:  $O\left(\binom{m}{d}\right) = O(n^d)$ .
  - Untersuche für jede  $d$ -elementige Teilmenge der  $m$  Ungleichungen den jeweiligen Schnittpunkt (Basislösung).

# Einleitung

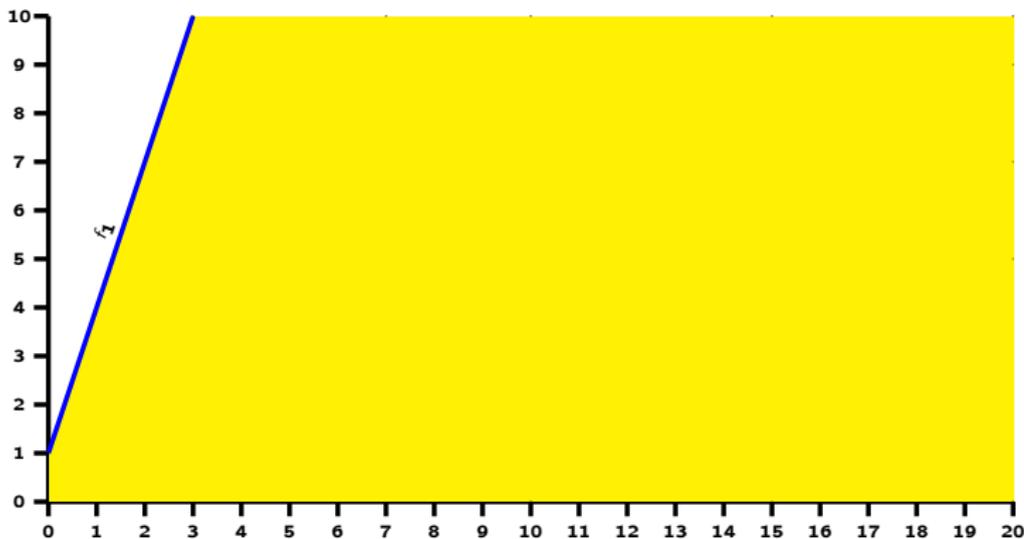
- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:
  - Gegeben sind  $d$  Variablen.
  - Gegeben sind  $m$  lineare Ungleichungen (Nebenbedingungen).
  - Gegeben ist eine lineare Zielfunktion  $f$  über die  $d$  Variablen.
- Gesucht:
  - Maximiere  $f$  unter Berücksichtigung aller Nebenbedingungen.
- Das ist ein LP (lineares Programm)
- Obere Schranke für Laufzeit:  $O\left(\binom{m}{d}\right) = O(n^d)$ .
  - Untersuche für jede  $d$ -elementige Teilmenge der  $m$  Ungleichungen den jeweiligen Schnittpunkt (Basislösung).
- Hier nun Algorithmus mit erwarteter linearer Laufzeit (d.h. linear in  $m$ ).

# Einleitung

- Bestimme Extrempunkt eines Polyhedrons bezüglich einer Zielfunktion.
- Eingabe:
  - Gegeben sind  $d$  Variablen.
  - Gegeben sind  $m$  lineare Ungleichungen (Nebenbedingungen).
  - Gegeben ist eine lineare Zielfunktion  $f$  über die  $d$  Variablen.
- Gesucht:
  - Maximiere  $f$  unter Berücksichtigung aller Nebenbedingungen.
- Das ist ein LP (lineares Programm)
- Obere Schranke für Laufzeit:  $O\left(\binom{m}{d}\right) = O(n^d)$ .
  - Untersuche für jede  $d$ -elementige Teilmenge der  $m$  Ungleichungen den jeweiligen Schnittpunkt (Basislösung).
- Hier nun Algorithmus mit erwarteter linearer Laufzeit (d.h. linear in  $m$ ).



## Beispiel

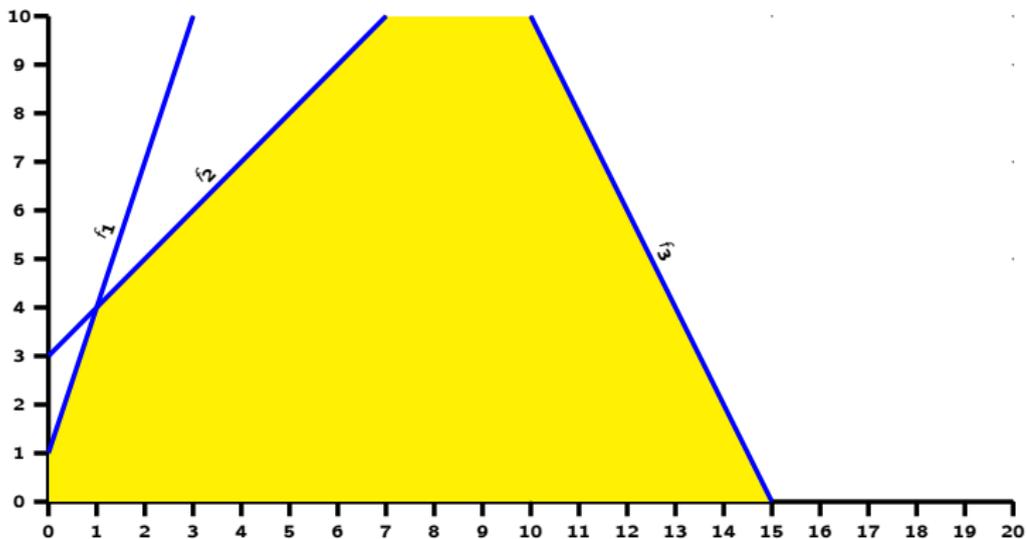
*d* Variablen, *m* Nebenbedingungen, Dimension *n*

Maximiere  $y$  unter den Nebenbedingungen  $0 \leq x \leq 20$ ,  $0 \leq y \leq 10$ , und:

$$f_1 : y \leq 3 \cdot x + 1$$



## Beispiel

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

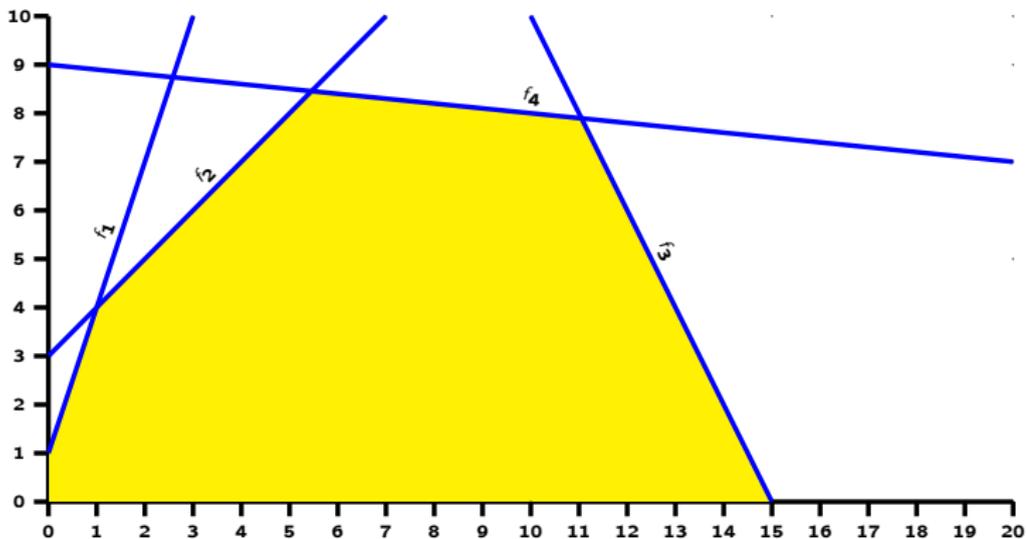
Maximiere  $y$  unter den Nebenbedingungen  $0 \leq x \leq 20$ ,  $0 \leq y \leq 10$ , und:

$$f_1 : y \leq 3 \cdot x + 1$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

## Beispiel

*d* Variablen, *m* Nebenbedingungen, Dimension *n*

Maximiere  $y$  unter den Nebenbedingungen  $0 \leq x \leq 20$ ,  $0 \leq y \leq 10$ , und:

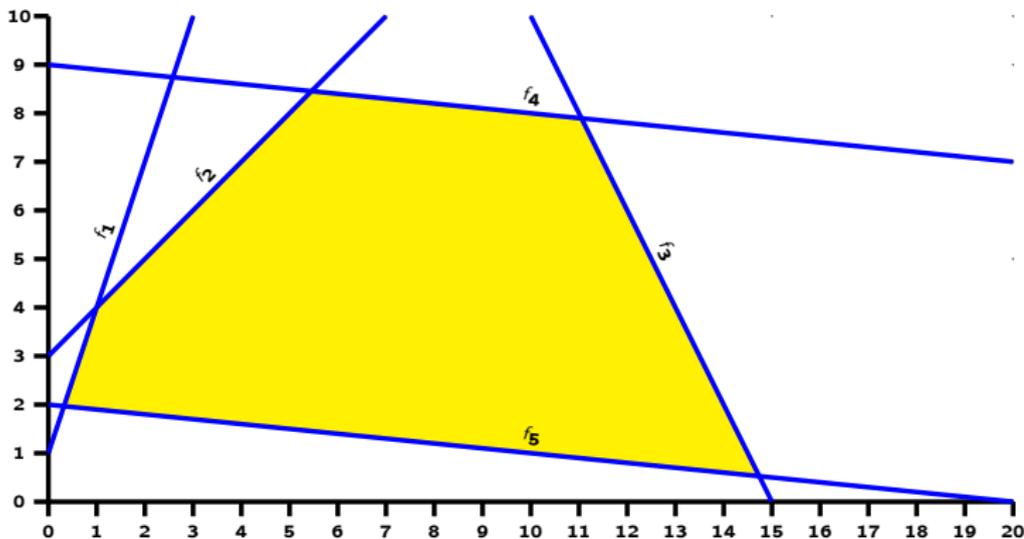
$$f_1 : y \leq 3 \cdot x + 1$$

$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

## Beispiel

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Maximiere  $y$  unter den Nebenbedingungen  $0 \leq x \leq 20$ ,  $0 \leq y \leq 10$ , und:

$$f_1 : y \leq 3 \cdot x + 1$$

$$f_4 : y \leq -0.9 \cdot x + 9$$

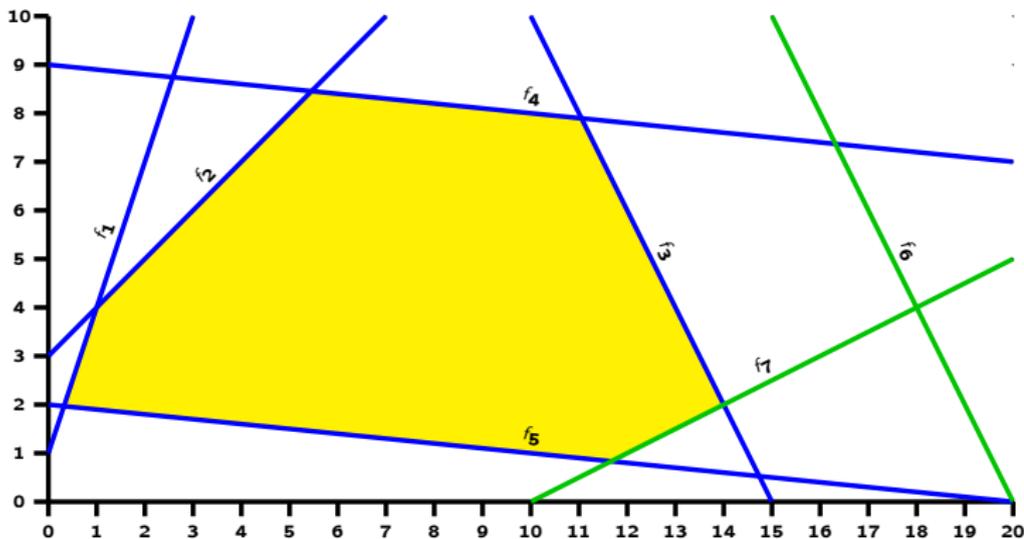
$$f_2 : y \leq 1 \cdot x + 2$$

$$f_5 : y \geq -0.9 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$



## Beispiel

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Maximiere  $y$  unter den Nebenbedingungen  $0 \leq x \leq 20$ ,  $0 \leq y \leq 10$ , und:

$$\begin{array}{lll}
 f_1 : y \leq 3 \cdot x + 1 & f_4 : y \leq -0.9 \cdot x + 9 & f_7 : y \geq 0.5 \cdot x - 5 \\
 f_2 : y \leq 1 \cdot x + 2 & f_5 : y \geq -0.9 \cdot x + 2 & \\
 f_3 : y \leq -2 \cdot x + 30 & f_6 : y \leq -2 \cdot x + 40 & 
 \end{array}$$







## Vorgaben

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Variablen:  $x_1, x_2, \dots, x_d$  mit:
  - $x = (x_1, x_2, \dots, x_d)^T$  und





## Vorgaben

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Variablen:  $x_1, x_2, \dots, x_d$  mit:
  - $x = (x_1, x_2, \dots, x_d)^T$  und
- Nebenbedingungen:  $A \cdot x \leq b$  mit:
  - $A$  ist eine  $m \times d$  Matrix und
  - $b = (b_1, b_2, \dots, b_d)^T$ .















## Vorgaben

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Variablen:  $x_1, x_2, \dots, x_d$  mit:
  - $x = (x_1, x_2, \dots, x_d)^T$  und
- Nebenbedingungen:  $A \cdot x \leq b$  mit:
  - $A$  ist eine  $m \times d$  Matrix und
  - $b = (b_1, b_2, \dots, b_d)^T$ .
- Zielfunktion  $f(x) = c^T \cdot x$  mit:
  - $c = (c_1, c_2, \dots, c_d)$ .
- O.B.d.A. gibt es eine zulässige Lösung.
- O.B.d.A. ist die Lösung eindeutig.
  - Falls nicht, so setze:
  - $c_i = c_i + \varepsilon^i$  für ein  $\varepsilon > 0$ .
  - Zielfunktion wird virtuell perturbiert (durcheinander wirbeln, stören).
  - D.h. es wird lexikographisch kleinste Basislösung gewählt.













































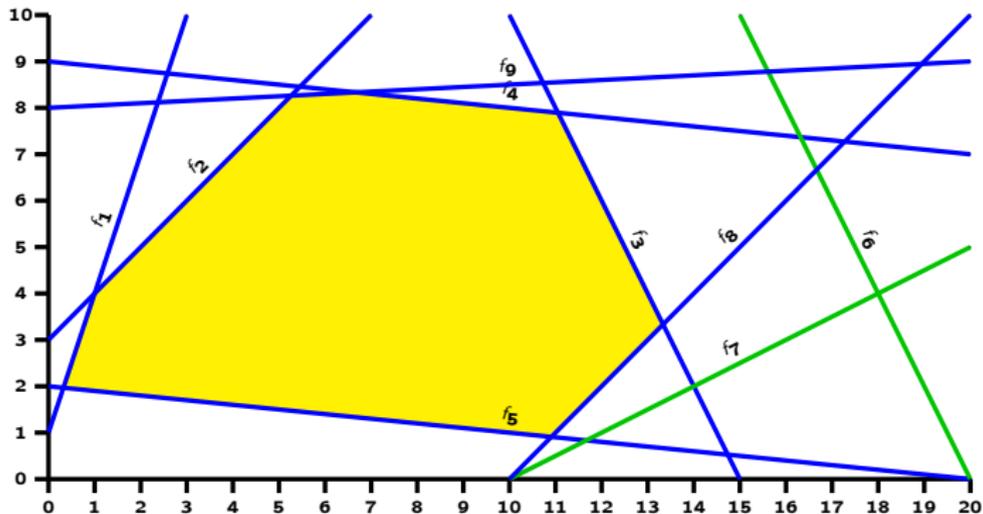


## Algorithmus von Seidel (1991)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Idee:
  - Sei  $H$  die Menge der Nebenbedingungen (Ohne Box-Bedingungen).
  - Wähle zufällig  $h \in H$  aus, und
  - löse dann rekursiv.
- Für  $H' \subset H$  sei  $LP(H')$  das LP, bei dem alle Nebenbedingungen aus  $H \setminus H'$  gestrichen wurden.
- Die optimale Basislösung von  $LP(H')$  wird mit  $opt(H')$  bezeichnet.
- Algorithmus von Seidel:
  - ① Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
  - ② Ansonsten wähle uniform eine Nebenbedingung  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
  - ③ Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
  - ④ Ansonsten berechne den Schnitt des Lösungspolyhedrons mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der ersten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Entferne nacheinander

$$f_1 : y \leq 3 \cdot x + 1$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_5 : y \geq -0.9 \cdot x + 2$$

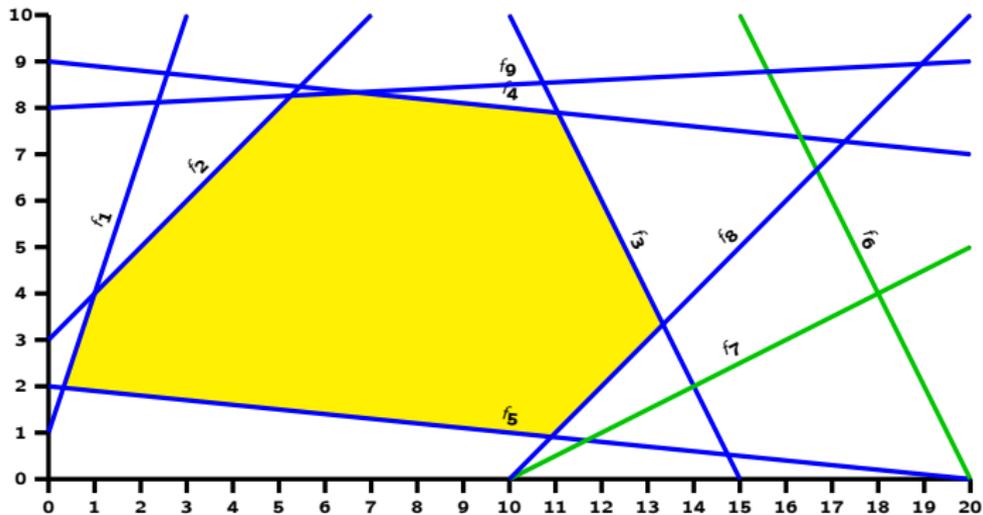
$$f_6 : y \leq -2 \cdot x + 40$$

$$f_7 : y \geq 0.5 \cdot x - 5$$

$$f_8 : y \geq 1 \cdot x - 10$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

## Beispiel (Abstieg der ersten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_8$ ,

$$f_1 : y \leq 3 \cdot x + 1$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_5 : y \geq -0.9 \cdot x + 2$$

$$f_6 : y \leq -2 \cdot x + 40$$

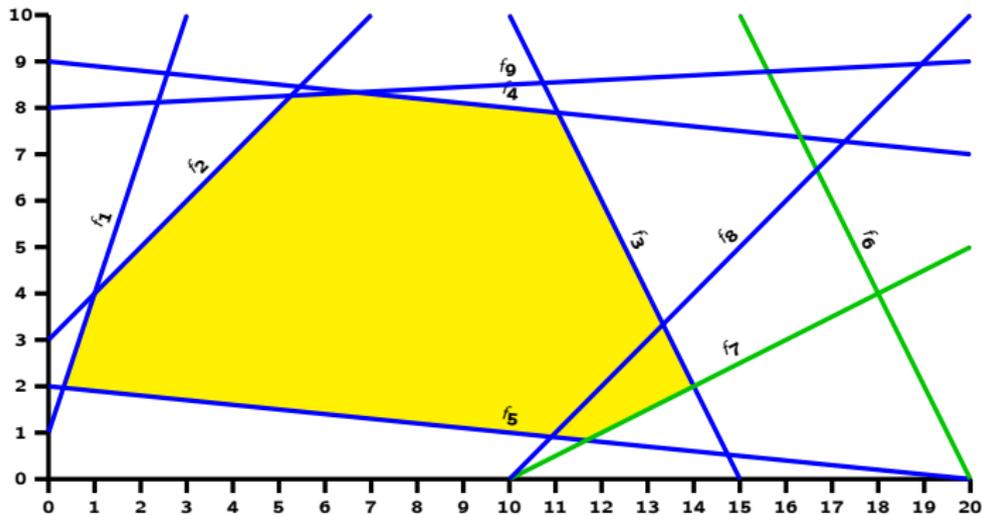
$$f_7 : y \geq 0.5 \cdot x - 5$$

$$f_8 : y \geq 1 \cdot x - 10$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der ersten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_8$ ,

$$f_1 : y \leq 3 \cdot x + 1$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_5 : y \geq -0.9 \cdot x + 2$$

$$f_6 : y \leq -2 \cdot x + 40$$

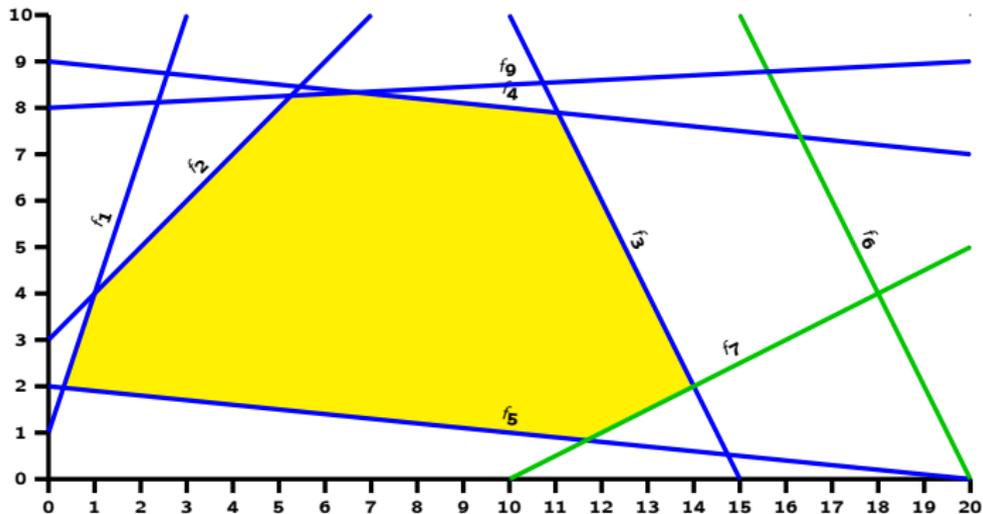
$$f_7 : y \geq 0.5 \cdot x - 5$$

$$f_8 : y \geq 1 \cdot x - 10$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der ersten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_8, f_1$ ,

$$f_1 : y \leq 3 \cdot x + 1$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_5 : y \geq -0.9 \cdot x + 2$$

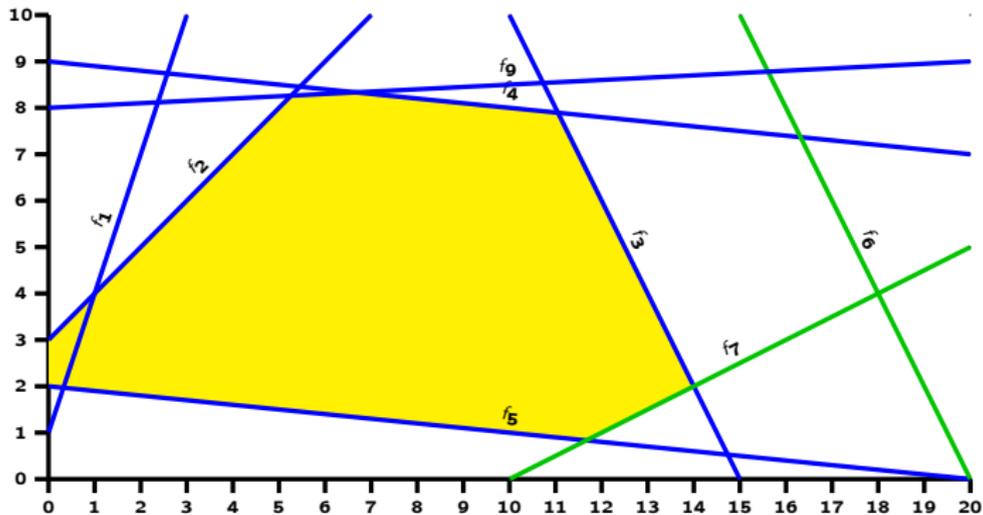
$$f_6 : y \leq -2 \cdot x + 40$$

$$f_7 : y \geq 0.5 \cdot x - 5$$

$$f_8 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der ersten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_8, f_1$ ,

$$f_1 : y \leq 3 \cdot x + 1$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_5 : y \geq -0.9 \cdot x + 2$$

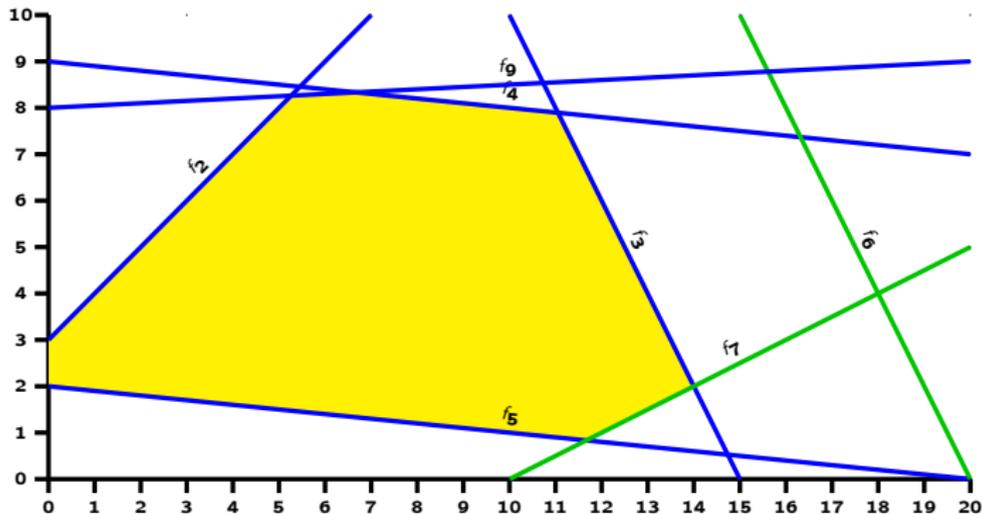
$$f_6 : y \leq -2 \cdot x + 40$$

$$f_7 : y \geq 0.5 \cdot x - 5$$

$$f_8 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der ersten vier Rekursionen)

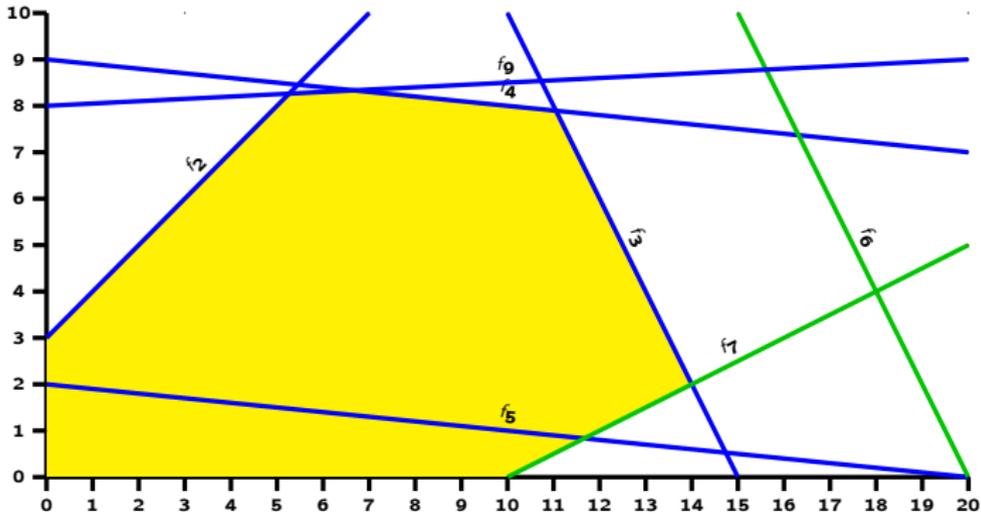
 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_8$ ,  $f_1$ ,  $f_5$ 

$$\begin{array}{lll}
 f_2 : y \leq 1 \cdot x + 2 & f_4 : y \leq -0.9 \cdot x + 9 & f_7 : y \geq 0.5 \cdot x - 5 \\
 f_3 : y \leq -2 \cdot x + 30 & f_5 : y \geq -0.9 \cdot x + 2 & f_8 : y \leq -2 \cdot x + 40 \\
 & f_6 : y \leq -2 \cdot x + 40 & f_9 : y \leq 1.05 \cdot x + 8
 \end{array}$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

# Beispiel (Abstieg der ersten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

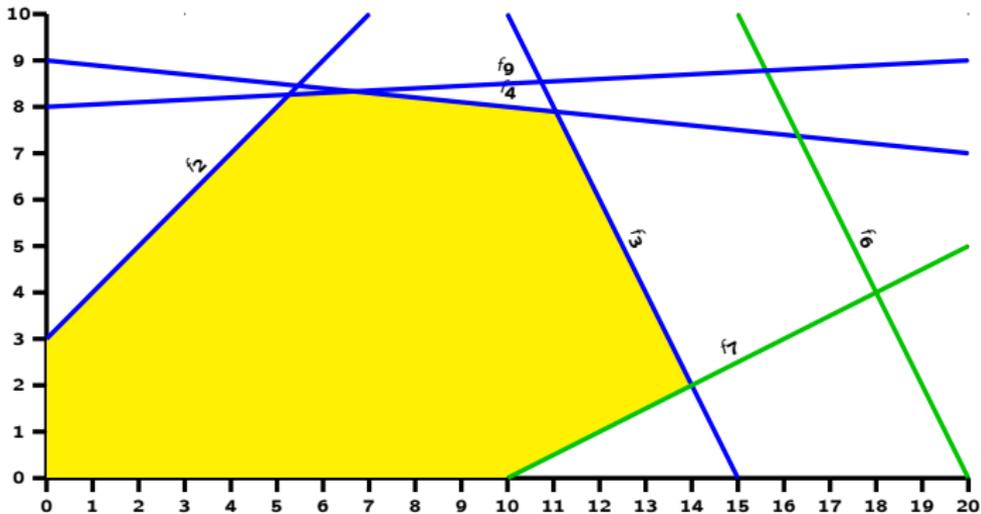


Entferne nacheinander  $f_8, f_1, f_5$

$$\begin{aligned}
 f_2 : y &\leq 1 \cdot x + 2 & f_4 : y &\leq -0.9 \cdot x + 9 & f_7 : y &\geq 0.5 \cdot x - 5 \\
 f_3 : y &\leq -2 \cdot x + 30 & f_5 : y &\geq -0.9 \cdot x + 2 & f_8 : y &\geq 0.5 \cdot x - 5 \\
 f_6 : y &\leq -2 \cdot x + 40 & f_9 : y &\leq 1.05 \cdot x + 8 & & 
 \end{aligned}$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der ersten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

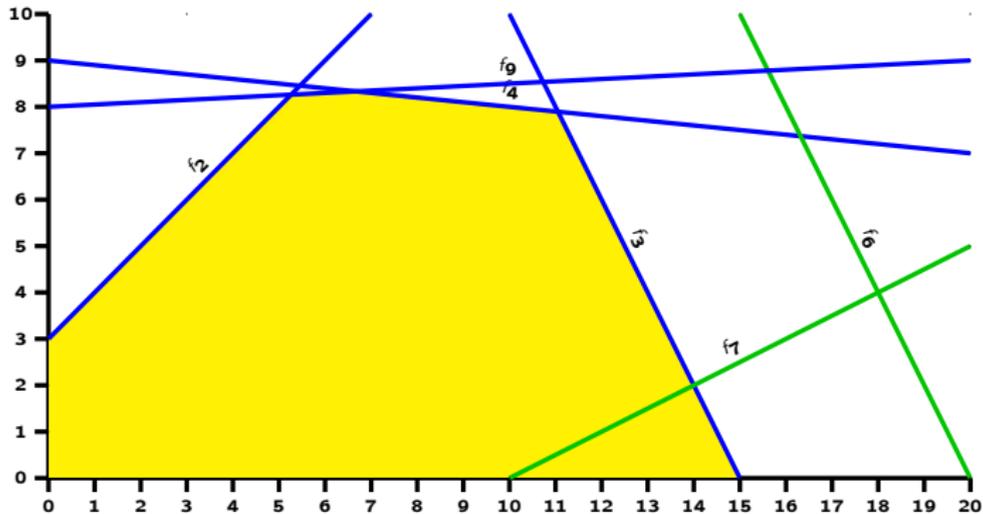
Entferne nacheinander  $f_8$ ,  $f_1$ ,  $f_5$  und  $f_7$  und löse jeweils rekursiv.

$$f_4 : y \leq -0.9 \cdot x + 9 \quad f_7 : y \geq 0.5 \cdot x - 5$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

## Beispiel (Abstieg der ersten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

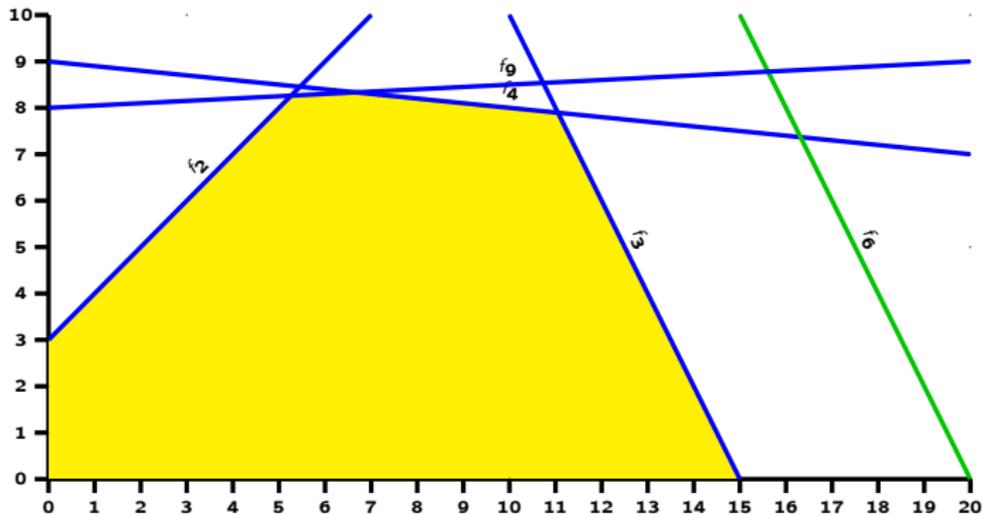
Entferne nacheinander  $f_8$ ,  $f_1$ ,  $f_5$  und  $f_7$  und löse jeweils rekursiv.

$$f_4 : y \leq -0.9 \cdot x + 9 \quad f_7 : y \geq 0.5 \cdot x - 5$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

## Beispiel (Abstieg der nächsten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Entferne nacheinander

$$f_4 : y \leq -0.9 \cdot x + 9$$

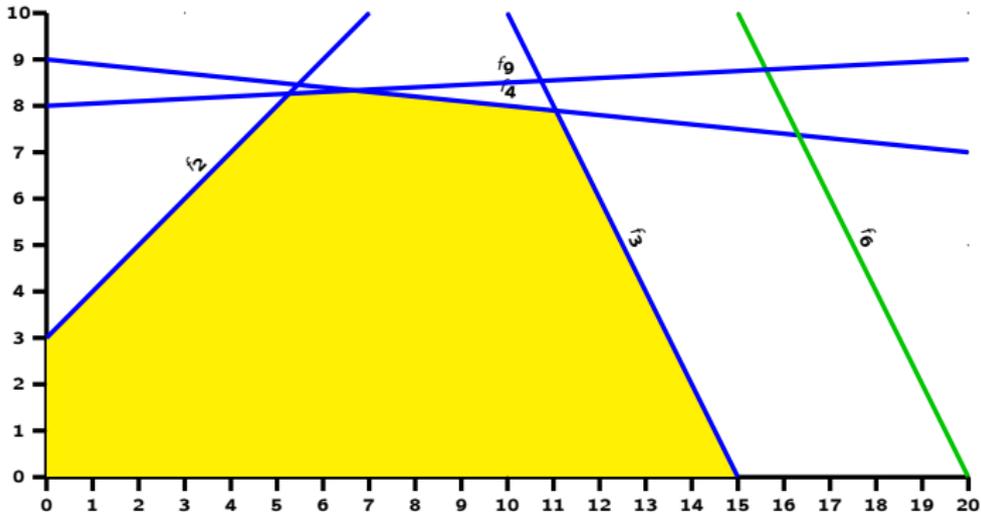
$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

# Beispiel (Abstieg der nächsten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimention  $n$



Entferne nacheinander  $f_4$ ,

$$f_4 : y \leq -0.9 \cdot x + 9$$

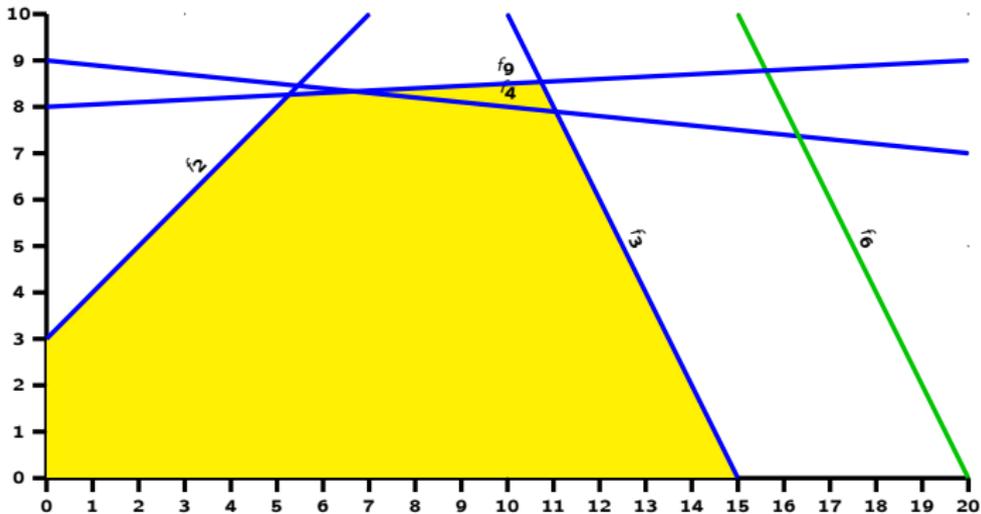
$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

# Beispiel (Abstieg der nächsten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimention  $n$



1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

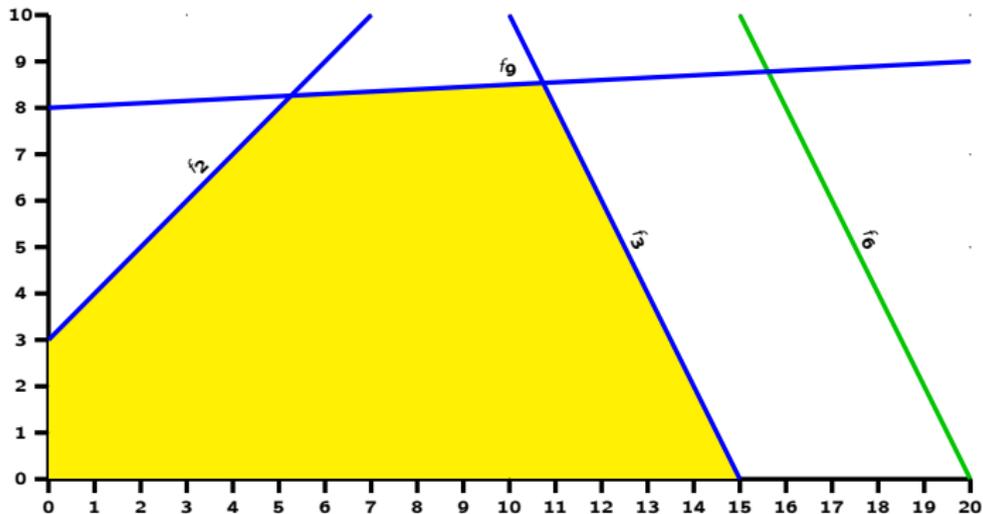
Entferne nacheinander  $f_4$ ,

$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

## Beispiel (Abstieg der nächsten vier Rekursionen)

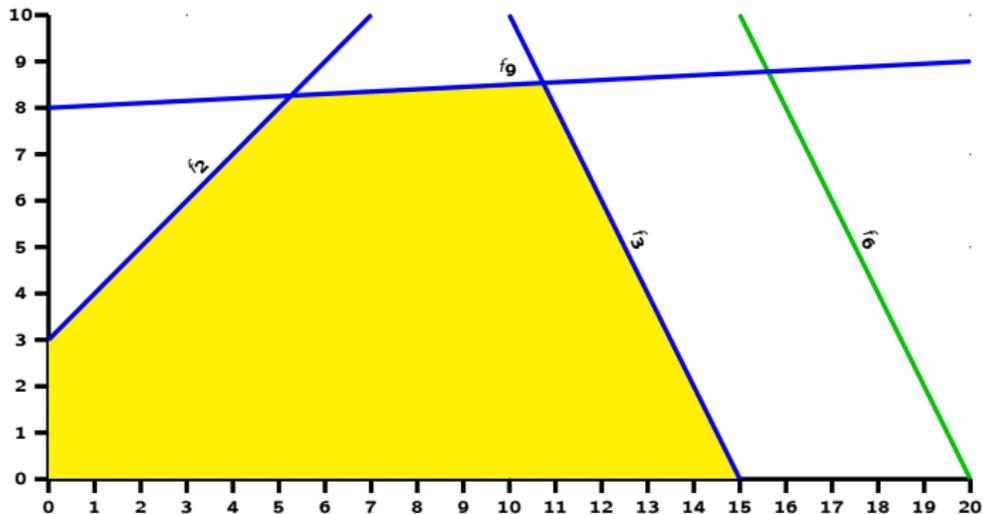
 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_4$ ,  $f_6$ ,

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der nächsten vier Rekursionen)

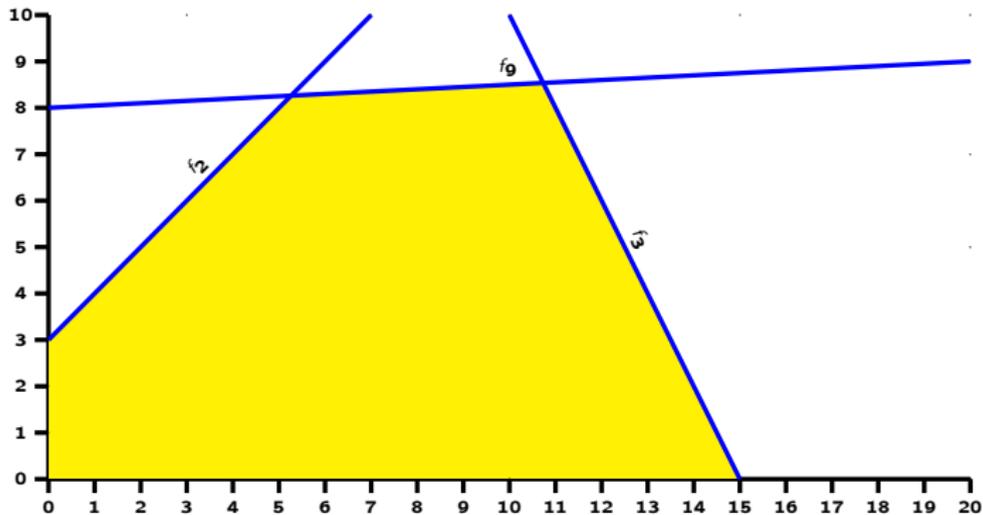
 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_4$ ,  $f_6$ ,

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der nächsten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_4$ ,  $f_6$ ,  $f_3$ 

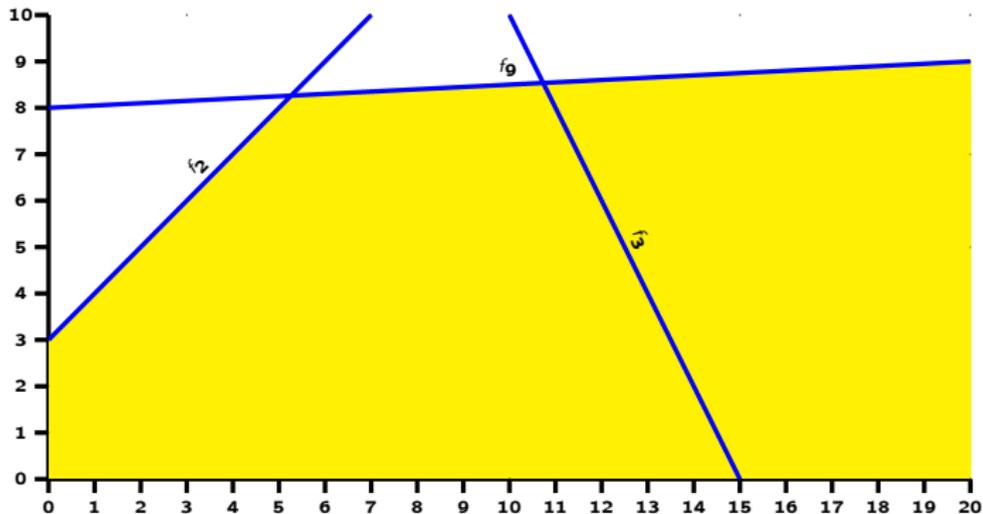
$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der nächsten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Entferne nacheinander  $f_4$ ,  $f_6$ ,  $f_3$ 

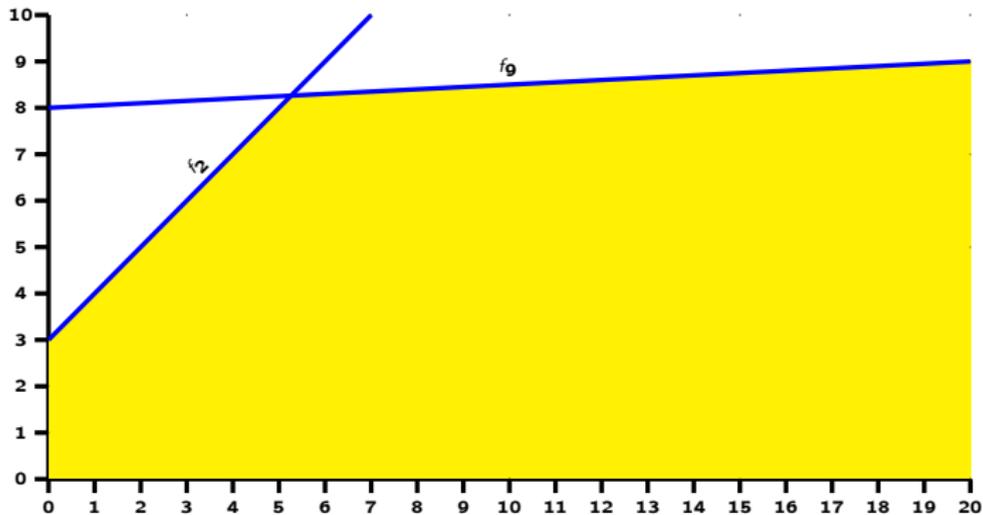
$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der nächsten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

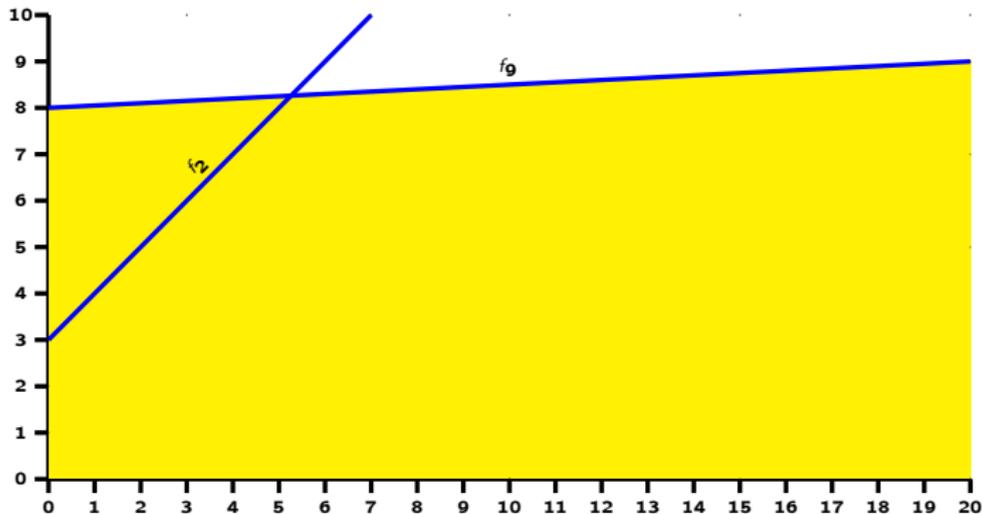
Entferne nacheinander  $f_4$ ,  $f_6$ ,  $f_3$  und  $f_2$  und löse jeweils rekursiv.

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der nächsten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

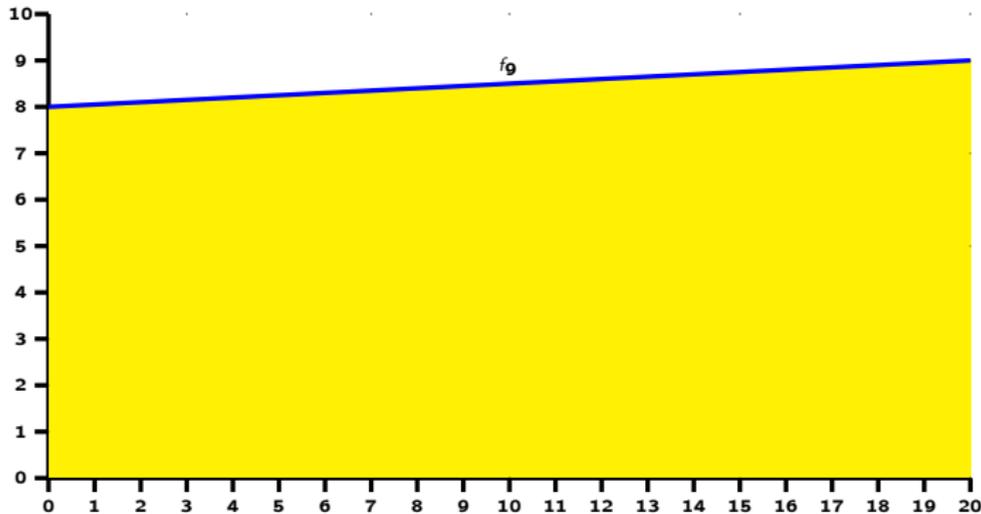
Entferne nacheinander  $f_4$ ,  $f_6$ ,  $f_3$  und  $f_2$  und löse jeweils rekursiv.

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Abstieg der nächsten vier Rekursionen)

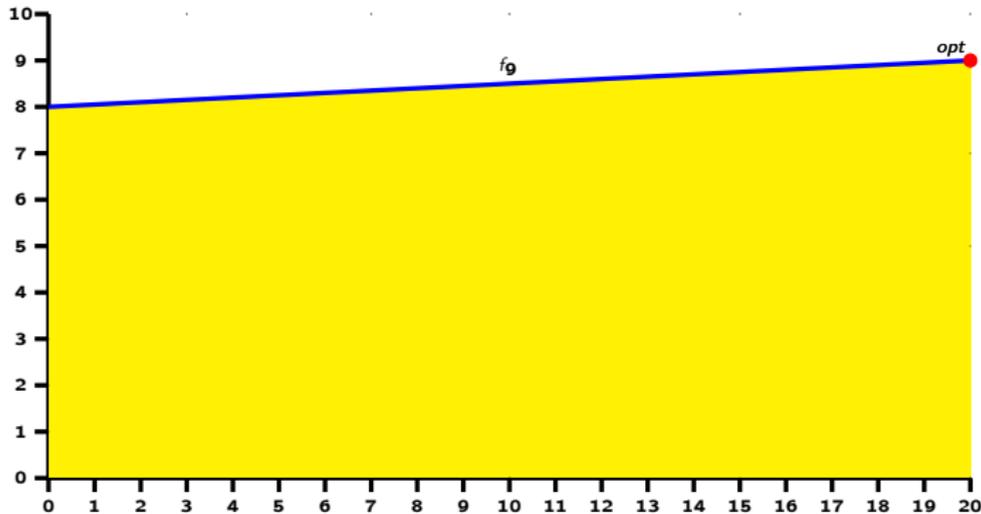
 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Entferne nacheinander  $f_4$ ,  $f_6$ ,  $f_3$  und  $f_2 - 1$  und löse jeweils rekursiv.

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

$$f_9 : y \leq 1.05 \cdot x + 8$$

## Beispiel (Abstieg der nächsten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

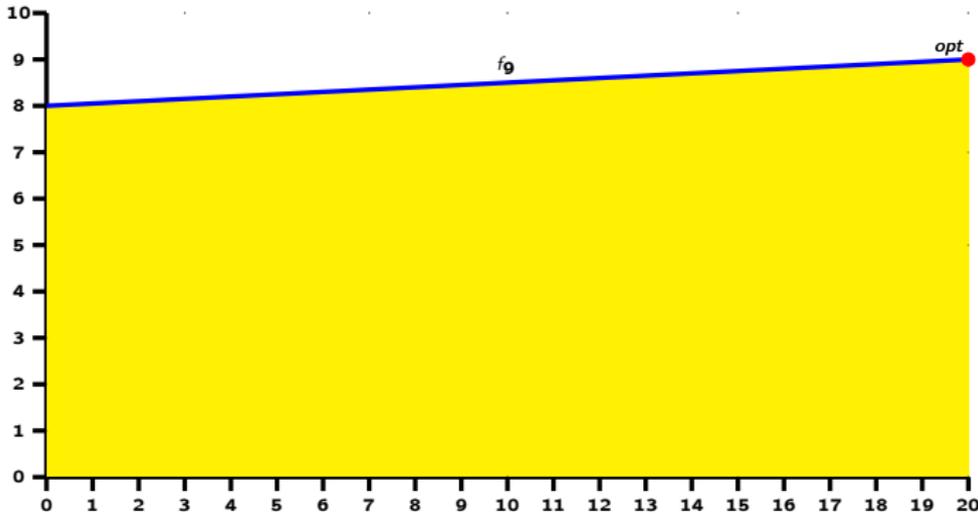
Entferne nacheinander  $f_4$ ,  $f_6$ ,  $f_3$  und  $f_2 - 1$  und löse jeweils rekursiv.

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

$$f_9 : y \leq 1.05 \cdot x + 8$$

# Beispiel (Aufstieg der letzten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

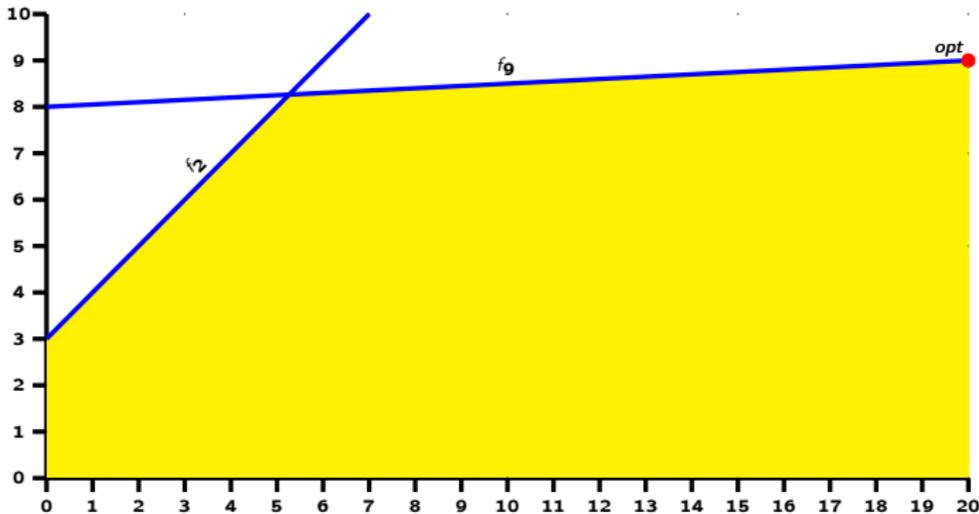


Füge nacheinander wieder ein:

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

$$f_9 : y \leq 1.05 \cdot x + 8$$

## Beispiel (Aufstieg der letzten vier Rekursionen)

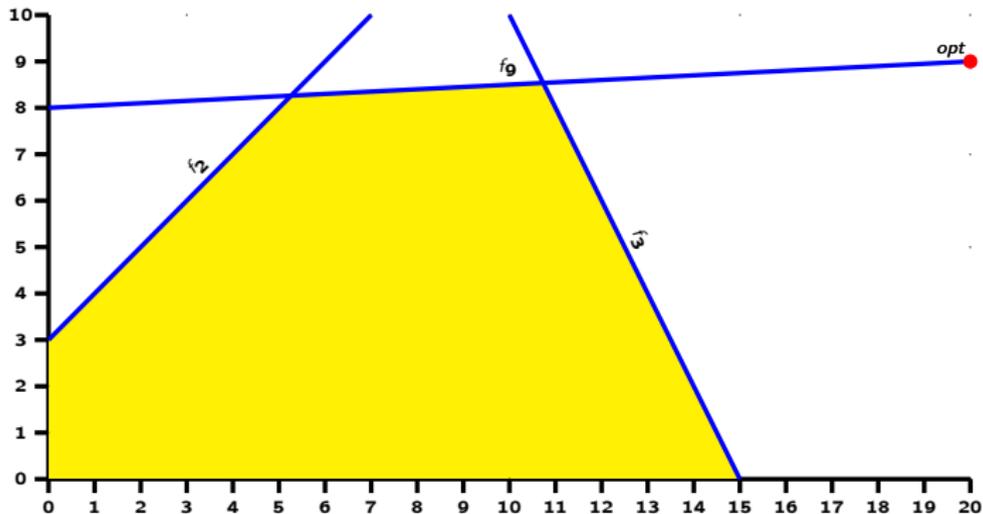
 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Füge nacheinander wieder ein:  $f_2$ ,

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Aufstieg der letzten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Füge nacheinander wieder ein:  $f_2$ ,  $f_3$ ,

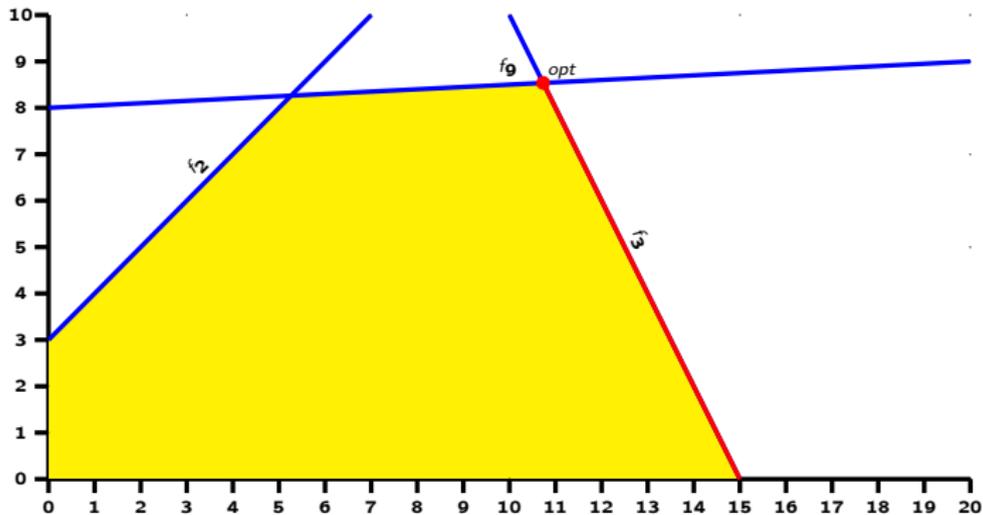
$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Aufstieg der letzten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Füge nacheinander wieder ein:  $f_2$ ,  $f_3$ ,

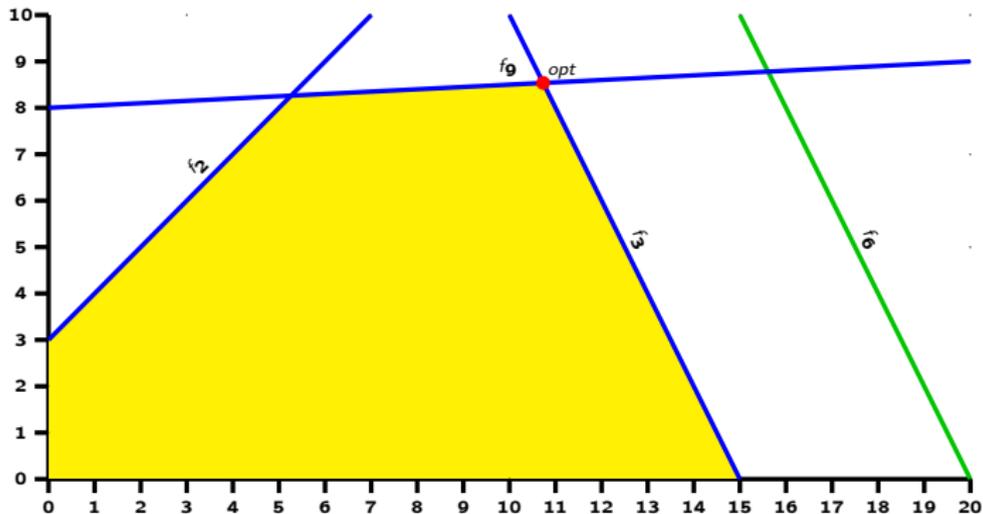
$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30$$

$$f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

## Beispiel (Aufstieg der letzten vier Rekursionen)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ Füge nacheinander wieder ein:  $f_2$ ,  $f_3$ ,  $f_6$ 

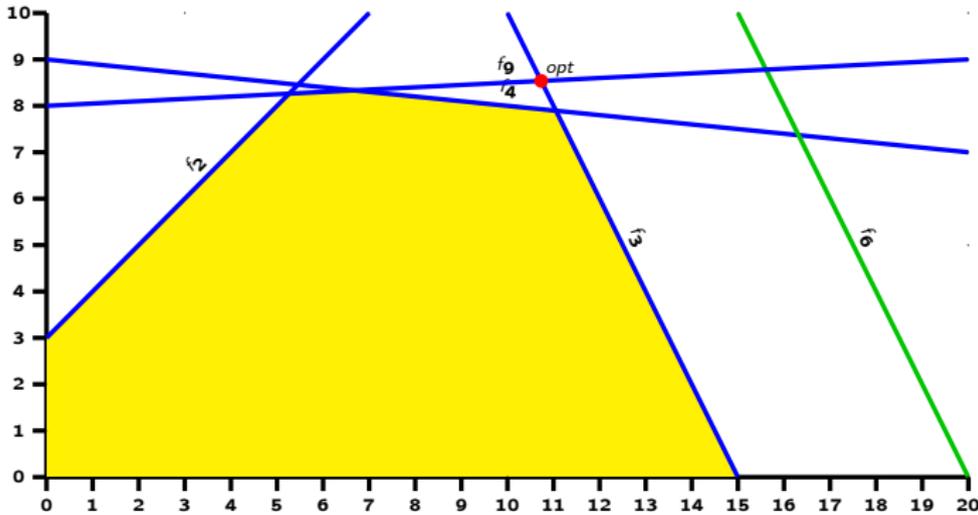
$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

# Beispiel (Aufstieg der letzten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$



1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Füge nacheinander wieder ein:  $f_2, f_3, f_6$  und  $f_4$ .

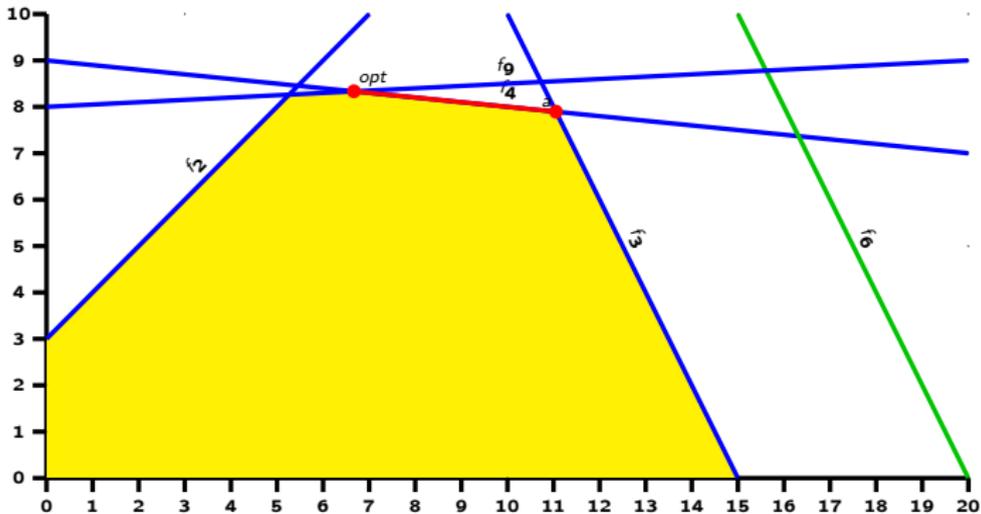
$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

# Beispiel (Aufstieg der letzten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$



1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Füge nacheinander wieder ein:  $f_2, f_3, f_6$  und  $f_4$ .

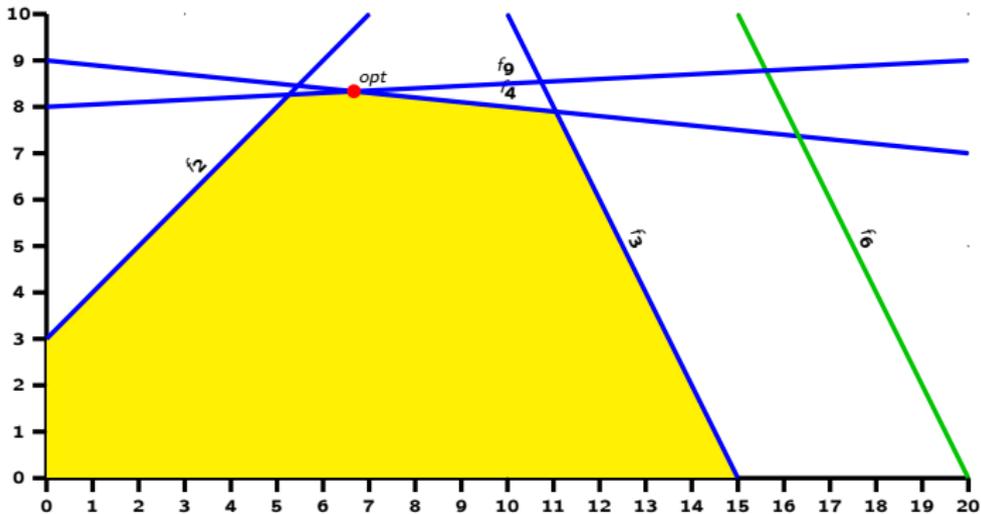
$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

# Beispiel (Aufstieg der letzten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$



1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Füge nacheinander wieder ein:  $f_2, f_3, f_6$  und  $f_4$ .

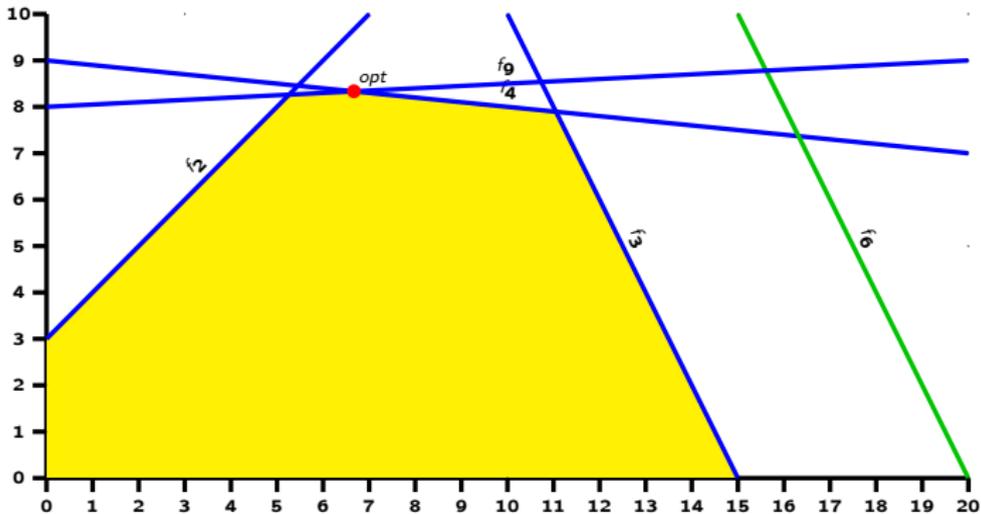
$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

# Beispiel (Aufstieg der ersten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$



1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Füge nacheinander wieder ein:

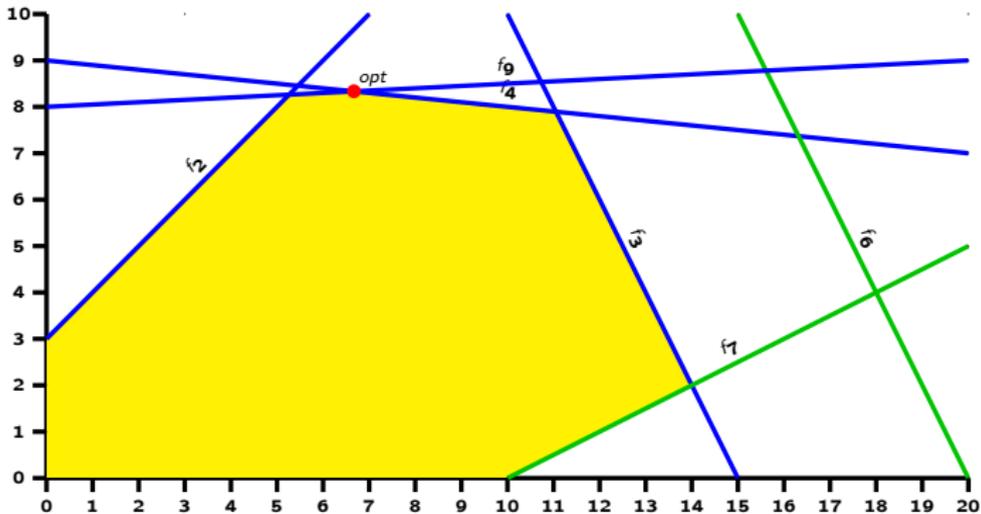
$$f_4 : y \leq -0.9 \cdot x + 9$$

$$f_2 : y \leq 1 \cdot x + 2$$

$$f_3 : y \leq -2 \cdot x + 30 \quad f_6 : y \leq -2 \cdot x + 40 \quad f_9 : y \leq 1.05 \cdot x + 8$$

# Beispiel (Aufstieg der ersten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$



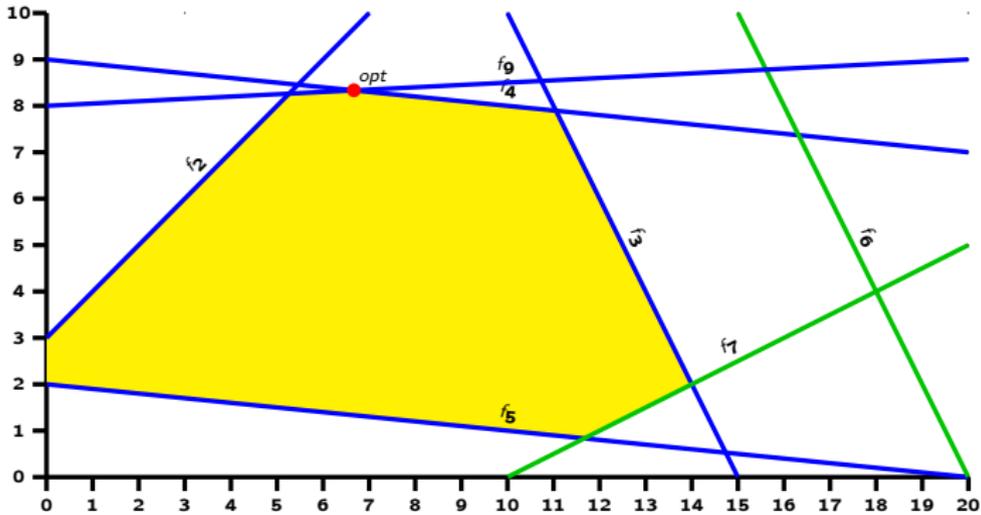
1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Füge nacheinander wieder ein:  $f_7$ ,

$$\begin{aligned}
 f_2 &: y \leq 1 \cdot x + 2 & f_4 &: y \leq -0.9 \cdot x + 9 & f_7 &: y \geq 0.5 \cdot x - 5 \\
 f_3 &: y \leq -2 \cdot x + 30 & f_6 &: y \leq -2 \cdot x + 40 & f_9 &: y \leq 1.05 \cdot x + 8
 \end{aligned}$$

# Beispiel (Aufstieg der ersten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$



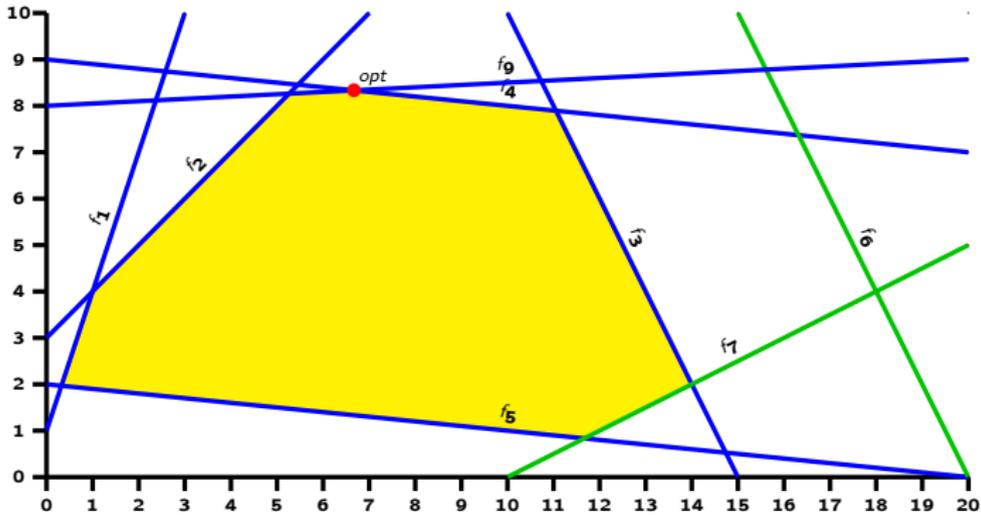
1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Füge nacheinander wieder ein:  $f_7, f_5,$

$$\begin{array}{lll}
 f_2 : y \leq 1 \cdot x + 2 & f_4 : y \leq -0.9 \cdot x + 9 & f_7 : y \geq 0.5 \cdot x - 5 \\
 f_3 : y \leq -2 \cdot x + 30 & f_5 : y \geq -0.9 \cdot x + 2 & \\
 & f_6 : y \leq -2 \cdot x + 40 & f_9 : y \leq 1.05 \cdot x + 8
 \end{array}$$

# Beispiel (Aufstieg der ersten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimention  $n$



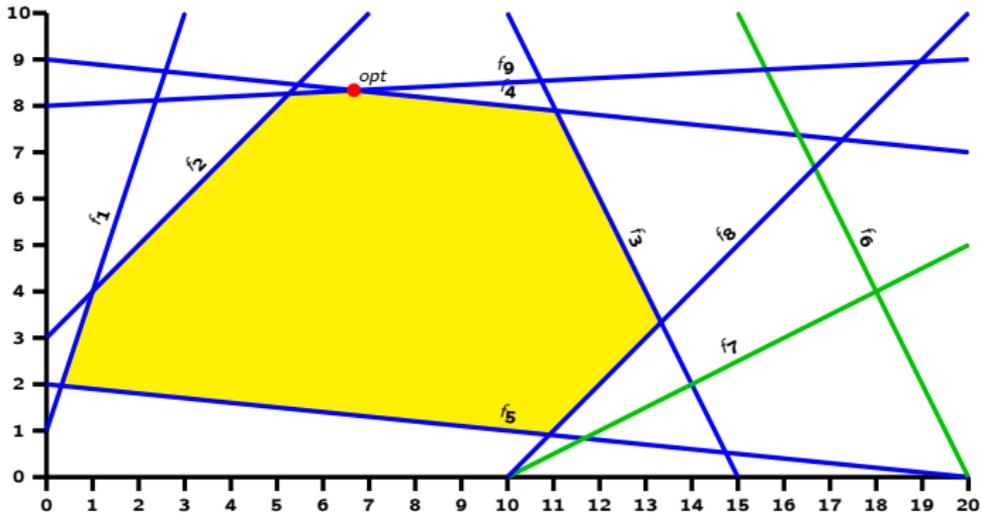
1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Füge nacheinander wieder ein:  $f_7, f_5, f_1$

$f_1 : y \leq 3 \cdot x + 1$	$f_4 : y \leq -0.9 \cdot x + 9$	$f_7 : y \geq 0.5 \cdot x - 5$
$f_2 : y \leq 1 \cdot x + 2$	$f_5 : y \geq -0.9 \cdot x + 2$	
$f_3 : y \leq -2 \cdot x + 30$	$f_6 : y \leq -2 \cdot x + 40$	$f_9 : y \leq 1.05 \cdot x + 8$

# Beispiel (Aufstieg der ersten vier Rekursionen)

$d$  Variablen,  $m$  Nebenbedingungen, Dimention  $n$



1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $opt(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $opt(H \setminus \{h\})$  rekursiv.
3. Falls  $opt(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $opt(H \setminus \{h\}) = opt(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.

Füge nacheinander wieder ein:  $f_7, f_5, f_1$  und  $f_8$ .

$f_1 : y \leq 3 \cdot x + 1$	$f_4 : y \leq -0.9 \cdot x + 9$	$f_7 : y \geq 0.5 \cdot x - 5$
$f_2 : y \leq 1 \cdot x + 2$	$f_5 : y \geq -0.9 \cdot x + 2$	$f_8 : y \geq 1 \cdot x - 10$
$f_3 : y \leq -2 \cdot x + 30$	$f_6 : y \leq -2 \cdot x + 40$	$f_9 : y \leq 1.05 \cdot x + 8$

## Laufzeiten und Details (Schritt 1 bis 3)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .

## Laufzeiten und Details (Schritt 1 bis 3)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.

## Laufzeiten und Details (Schritt 1 bis 3)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.

## Laufzeiten und Details (Schritt 1 bis 3)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.
  - Falls  $x_i \in \{-t, t\}$  ist das LP ohne Box-Bedingungen unbeschränkt.

## Laufzeiten und Details (Schritt 1 bis 3)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.
  - Falls  $x_i \in \{-t, t\}$  ist das LP ohne Box-Bedingungen unbeschränkt.
  - Ansonsten ist  $-t < x_i < t$  die optimale Lösung.





# Laufzeiten und Details (Schritt 1 bis 3)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.
  - Falls  $x_i \in \{-t, t\}$  ist das LP ohne Box-Bedingungen unbeschränkt.
  - Ansonsten ist  $-t < x_i < t$  die optimale Lösung.
- Falls  $m = 1$  gilt, gibt es nur eine Nebenbedingung neben den Box-Bedingungen.
  - Damit haben wir ein relaxiertes Rucksackproblem.
  - Dies kann optimal mittels Greedy gelöst werden.

# Laufzeiten und Details (Schritt 1 bis 3)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.
  - Falls  $x_i \in \{-t, t\}$  ist das LP ohne Box-Bedingungen unbeschränkt.
  - Ansonsten ist  $-t < x_i < t$  die optimale Lösung.
- Falls  $m = 1$  gilt, gibt es nur eine Nebenbedingung neben den Box-Bedingungen.
  - Damit haben wir ein relaxiertes Rucksackproblem.
  - Dies kann optimal mittels Greedy gelöst werden.
  - Laufzeit:  $O(d \log d) = O(d^2)$ .

# Laufzeiten und Details (Schritt 1 bis 3)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.
  - Falls  $x_i \in \{-t, t\}$  ist das LP ohne Box-Bedingungen unbeschränkt.
  - Ansonsten ist  $-t < x_i < t$  die optimale Lösung.
- Falls  $m = 1$  gilt, gibt es nur eine Nebenbedingung neben den Box-Bedingungen.
  - Damit haben wir ein relaxiertes Rucksackproblem.
  - Dies kann optimal mittels Greedy gelöst werden.
  - Laufzeit:  $O(d \log d) = O(d^2)$ .
- In Schritt 2 wird rekursiv ein Problem gelöst, bei dem  $m$  um eins verringert ist.

# Laufzeiten und Details (Schritt 1 bis 3)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.
  - Falls  $x_i \in \{-t, t\}$  ist das LP ohne Box-Bedingungen unbeschränkt.
  - Ansonsten ist  $-t < x_i < t$  die optimale Lösung.
- Falls  $m = 1$  gilt, gibt es nur eine Nebenbedingung neben den Box-Bedingungen.
  - Damit haben wir ein relaxiertes Rucksackproblem.
  - Dies kann optimal mittels Greedy gelöst werden.
  - Laufzeit:  $O(d \log d) = O(d^2)$ .
- In Schritt 2 wird rekursiv ein Problem gelöst, bei dem  $m$  um eins verringert ist.
- In Schritt 3 wird getestet, ob die gewählte Hyperebene  $h$  nicht die Lösung  $opt(H \setminus \{h\})$  verletzt.

# Laufzeiten und Details (Schritt 1 bis 3)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.
  - Falls  $x_i \in \{-t, t\}$  ist das LP ohne Box-Bedingungen unbeschränkt.
  - Ansonsten ist  $-t < x_i < t$  die optimale Lösung.
- Falls  $m = 1$  gilt, gibt es nur eine Nebenbedingung neben den Box-Bedingungen.
  - Damit haben wir ein relaxiertes Rucksackproblem.
  - Dies kann optimal mittels Greedy gelöst werden.
  - Laufzeit:  $O(d \log d) = O(d^2)$ .
- In Schritt 2 wird rekursiv ein Problem gelöst, bei dem  $m$  um eins verringert ist.
- In Schritt 3 wird getestet, ob die gewählte Hyperebene  $h$  nicht die Lösung  $opt(H \setminus \{h\})$  verletzt.
  - Das kann in  $O(d)$  gelöst werden.

# Laufzeiten und Details (Schritt 1 bis 3)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Falls  $d = 1$  gilt, gibt es nur noch eine Variable  $x_i$ .
  - Es gibt noch  $m$  Nebenbedingungen.
  - Damit kann  $x_i$  in Zeit  $O(m)$  bestimmt werden.
  - Falls  $x_i \in \{-t, t\}$  ist das LP ohne Box-Bedingungen unbeschränkt.
  - Ansonsten ist  $-t < x_i < t$  die optimale Lösung.
- Falls  $m = 1$  gilt, gibt es nur eine Nebenbedingung neben den Box-Bedingungen.
  - Damit haben wir ein relaxiertes Rucksackproblem.
  - Dies kann optimal mittels Greedy gelöst werden.
  - Laufzeit:  $O(d \log d) = O(d^2)$ .
- In Schritt 2 wird rekursiv ein Problem gelöst, bei dem  $m$  um eins verringert ist.
- In Schritt 3 wird getestet, ob die gewählte Hyperebene  $h$  nicht die Lösung  $opt(H \setminus \{h\})$  verletzt.
  - Das kann in  $O(d)$  gelöst werden.

## Laufzeiten und Details (Schritt 4)

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Fasse die Nebenbedingung  $h$  als Gleichung auf.







## Laufzeiten und Details (Schritt 4)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Fasse die Nebenbedingung  $h$  als Gleichung auf.
- Löse  $h$  zu einer beliebigen Variablen  $x_k$  auf ( $k \in \{1, 2, \dots, d\}$ ).
- D.h.  $x_k = s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$ .
- Ersetze jedes Auftreten von  $x_k$  durch  $s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  in:
  - allen Nebenbedingungen aus  $H \setminus \{h\}$ ,





## Laufzeiten und Details (Schritt 4)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Fasse die Nebenbedingung  $h$  als Gleichung auf.
- Löse  $h$  zu einer beliebigen Variablen  $x_k$  auf ( $k \in \{1, 2, \dots, d\}$ ).
- D.h.  $x_k = s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$ .
- Ersetze jedes Auftreten von  $x_k$  durch  $s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  in:
  - allen Nebenbedingungen aus  $H \setminus \{h\}$ ,
  - in der Zielfunktion, und
  - in der Box-Bedingung für  $h_k^- \leq x_k \leq h_k^+$ :
    - $h_k^- \leq s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  und

# Laufzeiten und Details (Schritt 4)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Fasse die Nebenbedingung  $h$  als Gleichung auf.
- Löse  $h$  zu einer beliebigen Variablen  $x_k$  auf ( $k \in \{1, 2, \dots, d\}$ ).
- D.h.  $x_k = s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$ .
- Ersetze jedes Auftreten von  $x_k$  durch  $s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  in:
  - allen Nebenbedingungen aus  $H \setminus \{h\}$ ,
  - in der Zielfunktion, und
  - in der Box-Bedingung für  $h_k^- \leq x_k \leq h_k^+$ :
    - $h_k^- \leq s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  und
    - $h_k^+ \geq s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$ .

# Laufzeiten und Details (Schritt 4)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Fasse die Nebenbedingung  $h$  als Gleichung auf.
- Löse  $h$  zu einer beliebigen Variablen  $x_k$  auf ( $k \in \{1, 2, \dots, d\}$ ).
- D.h.  $x_k = s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$ .
- Ersetze jedes Auftreten von  $x_k$  durch  $s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  in:
  - allen Nebenbedingungen aus  $H \setminus \{h\}$ ,
  - in der Zielfunktion, und
  - in der Box-Bedingung für  $h_k^- \leq x_k \leq h_k^+$ :
    - $h_k^- \leq s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  und
    - $h_k^+ \geq s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$ .
- Nenne diese beiden letzten Bedingungen  $h'$  und  $h''$ .





# Laufzeiten und Details (Schritt 4)

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Fasse die Nebenbedingung  $h$  als Gleichung auf.
- Löse  $h$  zu einer beliebigen Variablen  $x_k$  auf ( $k \in \{1, 2, \dots, d\}$ ).
- D.h.  $x_k = s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$ .
- Ersetze jedes Auftreten von  $x_k$  durch  $s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  in:
  - allen Nebenbedingungen aus  $H \setminus \{h\}$ ,
  - in der Zielfunktion, und
  - in der Box-Bedingung für  $h_k^- \leq x_k \leq h_k^+$ :
    - $h_k^- \leq s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$  und
    - $h_k^+ \geq s_k(x_1, x_2, \dots, x_{k-1}, x_{k+1}, \dots, x_d)$ .
  - Nenne diese beiden letzten Bedingungen  $h'$  und  $h''$ .
- Setze nun  $H' = H \cup \{h', h''\} \setminus \{h\}$  und löse  $H'$  rekursiv.
- Beachte:  $H'$  hat  $m + 1$  Nebenbedingungen, aber nur  $d - 1$  Variablen.







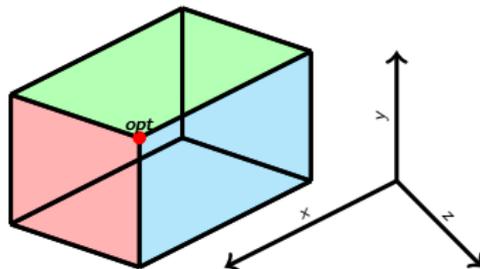
Beispiel Schritt 4 ( $d = 3$ ) $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Nebenbedingungen:

$$0 \leq x, \quad x \leq 10 \quad x + y + z \leq 25$$

$$0 \leq y, \quad y \leq 10$$

$$0 \leq z, \quad z \leq 10$$



- Gegeben seien die sechs einfachen Nebenbedingungen
- Zu maximieren sei die Funktion  $f(x, y, z) = 0.99 \cdot x + 0.974 \cdot y + z$ .
- Das Maximum wird bei  $f(10, 10, 10)$  erreicht.

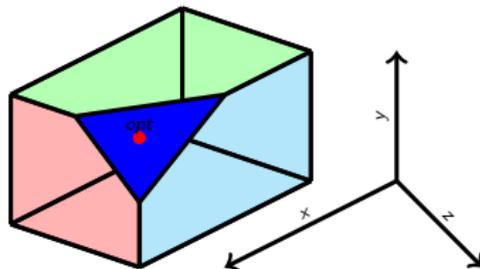
Beispiel Schritt 4 ( $d = 3$ ) $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Nebenbedingungen:

$$0 \leq x, \quad x \leq 10 \quad x + y + z \leq 25$$

$$0 \leq y, \quad y \leq 10$$

$$0 \leq z, \quad z \leq 10$$



- Gegeben seien die sechs einfachen Nebenbedingungen
- Zu maximieren sei die Funktion  $f(x, y, z) = 0.99 \cdot x + 0.974 \cdot y + z$ .
- Das Maximum wird bei  $f(10, 10, 10)$  erreicht.
- Die zusätzliche Nebenbedingung  $x + y + z \leq 25$  widerspricht diesem Maximum

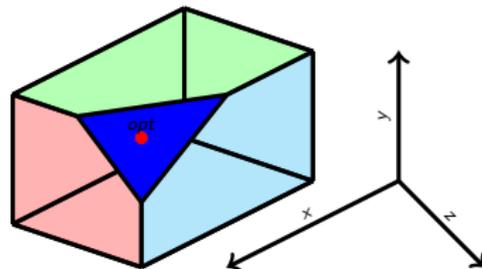
Beispiel Schritt 4 ( $d = 3$ ) $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Nebenbedingungen:

$$0 \leq x, \quad x \leq 10 \quad x + y + z \leq 25$$

$$0 \leq y, \quad y \leq 10$$

$$0 \leq z, \quad z \leq 10$$



- Gegeben seien die sechs einfachen Nebenbedingungen
- Zu maximieren sei die Funktion  $f(x, y, z) = 0.99 \cdot x + 0.974 \cdot y + z$ .
- Das Maximum wird bei  $f(10, 10, 10)$  erreicht.
- Die zusätzliche Nebenbedingung  $x + y + z \leq 25$  widerspricht diesem Maximum
- Das neue Maximum liegt damit auf der blauen Fläche.

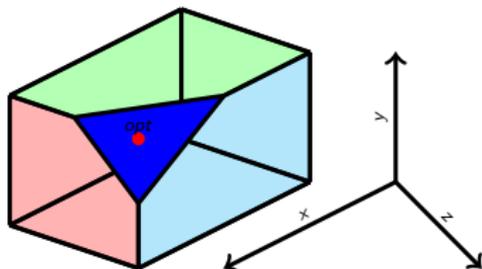
Beispiel Schritt 4 ( $d = 3$ ) $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Nebenbedingungen:

$$0 \leq x, \quad x \leq 10 \quad x + y + z \leq 25$$

$$0 \leq y, \quad y \leq 10$$

$$0 \leq z, \quad z \leq 10$$



- Gegeben seien die sechs einfachen Nebenbedingungen
- Zu maximieren sei die Funktion  $f(x, y, z) = 0.99 \cdot x + 0.974 \cdot y + z$ .
- Das Maximum wird bei  $f(10, 10, 10)$  erreicht.
- Die zusätzliche Nebenbedingung  $x + y + z \leq 25$  widerspricht diesem Maximum
- Das neue Maximum liegt damit auf der blauen Fläche.
- Wir lösen nach  $z$  auf:  $z = 25 - x - y$ . Damit verbleibt:

$$0 \leq x, \quad x \leq 10, \quad x + y \leq 25 \quad f(x, y) = -0.01 \cdot x - 0.026 \cdot y + 25$$

$$0 \leq y, \quad y \leq 10, \quad 15 \leq x + y$$

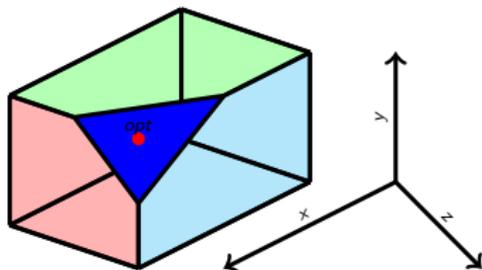
Beispiel Schritt 4 ( $d = 3$ ) $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

Nebenbedingungen:

$$0 \leq x, \quad x \leq 10 \quad x + y + z \leq 25$$

$$0 \leq y, \quad y \leq 10$$

$$0 \leq z, \quad z \leq 10$$



- Gegeben seien die sechs einfachen Nebenbedingungen
- Zu maximieren sei die Funktion  $f(x, y, z) = 0.99 \cdot x + 0.974 \cdot y + z$ .
- Das Maximum wird bei  $f(10, 10, 10)$  erreicht.
- Die zusätzliche Nebenbedingung  $x + y + z \leq 25$  widerspricht diesem Maximum
- Das neue Maximum liegt damit auf der blauen Fläche.
- Wir lösen nach  $z$  auf:  $z = 25 - x - y$ . Damit verbleibt:

$$0 \leq x, \quad x \leq 10, \quad x + y \leq 25 \quad f(x, y) = -0.01 \cdot x - 0.026 \cdot y + 25$$

$$0 \leq y, \quad y \leq 10, \quad 15 \leq x + y$$





## Korrektheit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Setze  $k(d, m) = 2 \cdot d + m$ .
- Pro rekursiven Aufruf wird  $k(d, m)$  um eins verringert.

1. Falls  $d = 1$  oder  $m = 0$ , so gebe  $\text{opt}(H)$  aus.
2. Ansonsten wähle  $h \in H$  aus, und berechne  $\text{opt}(H \setminus \{h\})$  rekursiv.
3. Falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  nicht verletzt, so gebe  $\text{opt}(H \setminus \{h\}) = \text{opt}(H)$  aus.
4. Ansonsten berechne den Schnitt mit der Hyperebene  $h$ , und löse das so entstandene  $(d - 1)$ -dimensionale LP rekursiv.



















## Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Sei  $T(m, d)$  eine obere Schranke für die erwartete Laufzeit.
- Falls  $m > 0$  und  $d > 1$  ergibt sich folgende Abschätzung für die Laufzeiten der vier Schritte:

## Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Sei  $T(m, d)$  eine obere Schranke für die erwartete Laufzeit.
- Falls  $m > 0$  und  $d > 1$  ergibt sich folgende Abschätzung für die Laufzeiten der vier Schritte:
  - Schritt 1:  $T_1 = O(1)$ .

## Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Sei  $T(m, d)$  eine obere Schranke für die erwartete Laufzeit.
- Falls  $m > 0$  und  $d > 1$  ergibt sich folgende Abschätzung für die Laufzeiten der vier Schritte:
  - Schritt 1:  $T_1 = O(1)$ .
  - Schritt 2:  $T_2 = T(m - 1, d)$ .

## Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Sei  $T(m, d)$  eine obere Schranke für die erwartete Laufzeit.
- Falls  $m > 0$  und  $d > 1$  ergibt sich folgende Abschätzung für die Laufzeiten der vier Schritte:
  - Schritt 1:  $T_1 = O(1)$ .
  - Schritt 2:  $T_2 = T(m - 1, d)$ .
  - Schritt 3:  $T_3 = O(d)$ .

## Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Sei  $T(m, d)$  eine obere Schranke für die erwartete Laufzeit.
- Falls  $m > 0$  und  $d > 1$  ergibt sich folgende Abschätzung für die Laufzeiten der vier Schritte:
  - Schritt 1:  $T_1 = O(1)$ .
  - Schritt 2:  $T_2 = T(m - 1, d)$ .
  - Schritt 3:  $T_3 = O(d)$ .
  - Schritt 4:  $T_4 = T(m + 1, d - 1) + O(d \cdot m)$ .

## Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Sei  $T(m, d)$  eine obere Schranke für die erwartete Laufzeit.
- Falls  $m > 0$  und  $d > 1$  ergibt sich folgende Abschätzung für die Laufzeiten der vier Schritte:
  - Schritt 1:  $T_1 = O(1)$ .
  - Schritt 2:  $T_2 = T(m - 1, d)$ .
  - Schritt 3:  $T_3 = O(d)$ .
  - Schritt 4:  $T_4 = T(m + 1, d - 1) + O(d \cdot m)$ .
- Dabei wird der Schritt 4 nicht immer ausgeführt.

## Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Sei  $T(m, d)$  eine obere Schranke für die erwartete Laufzeit.
- Falls  $m > 0$  und  $d > 1$  ergibt sich folgende Abschätzung für die Laufzeiten der vier Schritte:
  - Schritt 1:  $T_1 = O(1)$ .
  - Schritt 2:  $T_2 = T(m - 1, d)$ .
  - Schritt 3:  $T_3 = O(d)$ .
  - Schritt 4:  $T_4 = T(m + 1, d - 1) + O(d \cdot m)$ .
- Dabei wird der Schritt 4 nicht immer ausgeführt.
- Im Folgenden schätzen wir diese Wahrscheinlichkeit ab.



## Aussage

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

## Aussage

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

## Aussage

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

- Sei  $x^* = \text{opt}(H)$ .

## Aussage

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

- Sei  $x^* = \text{opt}(H)$ .
- $x^*$  ist damit auf dem Schnitt von  $d$  Hyperebenen.

## Aussage

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

- Sei  $x^* = \text{opt}(H)$ .
- $x^*$  ist damit auf dem Schnitt von  $d$  Hyperebenen.
- Diese  $d$  Hyperebenen sind Nebenbedingungen oder Box-Bedingungen.

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

- Sei  $x^* = \text{opt}(H)$ .
- $x^*$  ist damit auf dem Schnitt von  $d$  Hyperebenen.
- Diese  $d$  Hyperebenen sind Nebenbedingungen oder Box-Bedingungen.
- Sei  $D$  eine Auswahl mit  $|D| = d$  dieser  $x^*$  bestimmenden Hyperebenen.

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

- Sei  $x^* = \text{opt}(H)$ .
- $x^*$  ist damit auf dem Schnitt von  $d$  Hyperebenen.
- Diese  $d$  Hyperebenen sind Nebenbedingungen oder Box-Bedingungen.
- Sei  $D$  eine Auswahl mit  $|D| = d$  dieser  $x^*$  bestimmenden Hyperebenen.
- Damit gilt:  $\text{opt}(D) = x^*$ .

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

- Sei  $x^* = \text{opt}(H)$ .
- $x^*$  ist damit auf dem Schnitt von  $d$  Hyperebenen.
- Diese  $d$  Hyperebenen sind Nebenbedingungen oder Box-Bedingungen.
- Sei  $D$  eine Auswahl mit  $|D| = d$  dieser  $x^*$  bestimmenden Hyperebenen.
- Damit gilt:  $\text{opt}(D) = x^*$ .
- Schritt 4 wird ausgeführt, falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  verletzt.



## Aussage

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

- Sei  $x^* = \text{opt}(H)$ .
- $x^*$  ist damit auf dem Schnitt von  $d$  Hyperebenen.
- Diese  $d$  Hyperebenen sind Nebenbedingungen oder Box-Bedingungen.
- Sei  $D$  eine Auswahl mit  $|D| = d$  dieser  $x^*$  bestimmenden Hyperebenen.
- Damit gilt:  $\text{opt}(D) = x^*$ .
- Schritt 4 wird ausgeführt, falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  verletzt.
- D.h. Schritt 4 wird ausgeführt, falls  $h \in D$ .
- Damit ist die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird:

$$\Pr[h \in D] = \frac{|D \cap H|}{|H|} \leq \frac{d}{m}.$$

## Aussage

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

*Die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird, ist höchstens  $d/m$ .*

Beweis:

- Sei  $x^* = \text{opt}(H)$ .
- $x^*$  ist damit auf dem Schnitt von  $d$  Hyperebenen.
- Diese  $d$  Hyperebenen sind Nebenbedingungen oder Box-Bedingungen.
- Sei  $D$  eine Auswahl mit  $|D| = d$  dieser  $x^*$  bestimmenden Hyperebenen.
- Damit gilt:  $\text{opt}(D) = x^*$ .
- Schritt 4 wird ausgeführt, falls  $\text{opt}(H \setminus \{h\})$  die Nebenbedingung  $h$  verletzt.
- D.h. Schritt 4 wird ausgeführt, falls  $h \in D$ .
- Damit ist die Wahrscheinlichkeit, dass Schritt 4 ausgeführt wird:

$$\Pr[h \in D] = \frac{|D \cap H|}{|H|} \leq \frac{d}{m}.$$

## Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Im Falle  $m > 0$  und  $d > 1$  gilt:  $T(m, d) = T_1 + T_2 + T_3 + \frac{d}{m} \cdot T_4$ .

# Abschätzung der Laufzeit

$d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$

- Im Falle  $m > 0$  und  $d > 1$  gilt:  $T(m, d) = T_1 + T_2 + T_3 + \frac{d}{m} \cdot T_4$ .
- Unter Vernachlässigung der konstanten Faktoren:

## Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Im Falle  $m > 0$  und  $d > 1$  gilt:  $T(m, d) = T_1 + T_2 + T_3 + \frac{d}{m} \cdot T_4$ .
- Unter Vernachlässigung der konstanten Faktoren:
- Im Falle  $m > 0$  und  $d > 1$  gilt:

$$T(m, d) \leq T(m-1, d) + d^2 + \frac{d}{m} \cdot T(m+1, d-1).$$



## Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

- Im Falle  $m > 0$  und  $d > 1$  gilt:  $T(m, d) = T_1 + T_2 + T_3 + \frac{d}{m} \cdot T_4$ .
- Unter Vernachlässigung der konstanten Faktoren:
- Im Falle  $m > 0$  und  $d > 1$  gilt:

$$T(m, d) \leq T(m-1, d) + d^2 + \frac{d}{m} \cdot T(m+1, d-1).$$

- Im Falle  $m = 0$  oder  $d = 1$  gilt:

$$T(m, d) \leq d^2 + m.$$

- Wir definieren nun  $f(1) = 1$  und für  $d > 1$ :

$$f(d) = d \cdot f(d-1) + 3 \cdot d^3$$











## Finale Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

Es gilt:  $T(m, d) \leq (m - 1) \cdot f(d) + 2 \cdot d^2$ .

Beweis:

- Induktionsanfang:  $m = 1$

$$T(m, d) \leq d^2 + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

## Finale Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

Es gilt:  $T(m, d) \leq (m - 1) \cdot f(d) + 2 \cdot d^2$ .

Beweis:

- Induktionsanfang:  $m = 1$

$$T(m, d) \leq d^2 + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Induktionsanfang:  $d = 1$

$$T(m, d) \leq m + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$



## Finale Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

Es gilt:  $T(m, d) \leq (m - 1) \cdot f(d) + 2 \cdot d^2$ .

Beweis:

- Induktionsanfang:  $m = 1$

$$T(m, d) \leq d^2 + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Induktionsanfang:  $d = 1$

$$T(m, d) \leq m + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Für den Induktionsschritt setzen wir:

- $k = 2 \cdot d + m$

## Finale Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

Es gilt:  $T(m, d) \leq (m - 1) \cdot f(d) + 2 \cdot d^2$ .

Beweis:

- Induktionsanfang:  $m = 1$

$$T(m, d) \leq d^2 + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Induktionsanfang:  $d = 1$

$$T(m, d) \leq m + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Für den Induktionsschritt setzen wir:

- $k = 2 \cdot d + m$
- Es sei nun  $m \geq 2$  und  $d \geq 2$ .

## Finale Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

Es gilt:  $T(m, d) \leq (m - 1) \cdot f(d) + 2 \cdot d^2$ .

Beweis:

- Induktionsanfang:  $m = 1$

$$T(m, d) \leq d^2 + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Induktionsanfang:  $d = 1$

$$T(m, d) \leq m + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Für den Induktionsschritt setzen wir:

- $k = 2 \cdot d + m$
- Es sei nun  $m \geq 2$  und  $d \geq 2$ .
- Behauptung sei gezeigt für alle  $d'$  und  $m'$  mit  $2 \cdot d' + m' < k$ .

## Finale Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

Es gilt:  $T(m, d) \leq (m - 1) \cdot f(d) + 2 \cdot d^2$ .

Beweis:

- Induktionsanfang:  $m = 1$

$$T(m, d) \leq d^2 + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Induktionsanfang:  $d = 1$

$$T(m, d) \leq m + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Für den Induktionsschritt setzen wir:

- $k = 2 \cdot d + m$
- Es sei nun  $m \geq 2$  und  $d \geq 2$ .
- Behauptung sei gezeigt für alle  $d'$  und  $m'$  mit  $2 \cdot d' + m' < k$ .
- Also auch für  $(m - 1, d)$  und  $(m + 1, d - 1)$ .

## Finale Abschätzung der Laufzeit

 $d$  Variablen,  $m$  Nebenbedingungen, Dimension  $n$ 

## Lemma

Es gilt:  $T(m, d) \leq (m - 1) \cdot f(d) + 2 \cdot d^2$ .

Beweis:

- Induktionsanfang:  $m = 1$

$$T(m, d) \leq d^2 + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Induktionsanfang:  $d = 1$

$$T(m, d) \leq m + 1 \leq (m - 1) \cdot f(d) + 2 \cdot d^2.$$

- Für den Induktionsschritt setzen wir:

- $k = 2 \cdot d + m$
- Es sei nun  $m \geq 2$  und  $d \geq 2$ .
- Behauptung sei gezeigt für alle  $d'$  und  $m'$  mit  $2 \cdot d' + m' < k$ .
- Also auch für  $(m - 1, d)$  und  $(m + 1, d - 1)$ .

## Induktionsschluss

$$T(m, d) \leq (m - 1) \cdot f(d) + 2 \cdot d^2$$
$$f(d) = d \cdot f(d - 1) + 3 \cdot d^3$$

$$T(m, d) \leq T(m - 1, d) + d^2 + \frac{d}{m} \cdot T(m + 1, d - 1)$$

## Induktionsschluss

$$T(m, d) \leq (m-1) \cdot f(d) + 2 \cdot d^2$$

$$f(d) = d \cdot f(d-1) + 3 \cdot d^3$$

$$T(m, d) \leq T(m-1, d) + d^2 + \frac{d}{m} \cdot T(m+1, d-1)$$

$$\leq (m-2) \cdot f(d) + 2 \cdot d^2 + d^2 + \frac{d}{m} \cdot T(m+1, d-1)$$

## Induktionsschluss

$$T(m, d) \leq (m-1) \cdot f(d) + 2 \cdot d^2$$

$$f(d) = d \cdot f(d-1) + 3 \cdot d^3$$

$$\begin{aligned}
 T(m, d) &\leq T(m-1, d) + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\
 &\leq (m-2) \cdot f(d) + 2 \cdot d^2 + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\
 &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot (d-1)^2
 \end{aligned}$$

## Induktionsschluss

$$T(m, d) \leq (m-1) \cdot f(d) + 2 \cdot d^2$$

$$f(d) = d \cdot f(d-1) + 3 \cdot d^3$$

$$\begin{aligned} T(m, d) &\leq T(m-1, d) + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\ &\leq (m-2) \cdot f(d) + 2 \cdot d^2 + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\ &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot (d-1)^2 \\ &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot d^2 \end{aligned}$$

## Induktionsschluss

$$T(m, d) \leq (m-1) \cdot f(d) + 2 \cdot d^2$$

$$f(d) = d \cdot f(d-1) + 3 \cdot d^3$$

$$\begin{aligned}
 T(m, d) &\leq T(m-1, d) + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\
 &\leq (m-2) \cdot f(d) + 2 \cdot d^2 + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\
 &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot (d-1)^2 \\
 &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot d^2 \\
 &= (m-2) \cdot f(d) + 3 \cdot d^2 + d \cdot \frac{f(d)-3 \cdot d^3}{d} + 2 \cdot d^2
 \end{aligned}$$

## Induktionsschluss

$$T(m, d) \leq (m-1) \cdot f(d) + 2 \cdot d^2$$

$$f(d) = d \cdot f(d-1) + 3 \cdot d^3$$

$$\begin{aligned}
 T(m, d) &\leq T(m-1, d) + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\
 &\leq (m-2) \cdot f(d) + 2 \cdot d^2 + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\
 &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot (d-1)^2 \\
 &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot d^2 \\
 &= (m-2) \cdot f(d) + 3 \cdot d^2 + d \cdot \frac{f(d)-3 \cdot d^3}{d} + 2 \cdot d^2 \\
 &= (m-2) \cdot f(d) + 3 \cdot d^2 + f(d) - 3 \cdot d^3 + 2 \cdot d^2
 \end{aligned}$$

## Induktionsschluss

$$T(m, d) \leq (m-1) \cdot f(d) + 2 \cdot d^2$$

$$f(d) = d \cdot f(d-1) + 3 \cdot d^3$$

$$\begin{aligned}
 T(m, d) &\leq T(m-1, d) + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\
 &\leq (m-2) \cdot f(d) + 2 \cdot d^2 + d^2 + \frac{d}{m} \cdot T(m+1, d-1) \\
 &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot (d-1)^2 \\
 &\leq (m-2) \cdot f(d) + 3 \cdot d^2 + \frac{d}{m} \cdot m \cdot f(d-1) + 2 \cdot d^2 \\
 &= (m-2) \cdot f(d) + 3 \cdot d^2 + d \cdot \frac{f(d)-3 \cdot d^3}{d} + 2 \cdot d^2 \\
 &= (m-2) \cdot f(d) + 3 \cdot d^2 + f(d) - 3 \cdot d^3 + 2 \cdot d^2 \\
 &\leq (m-1) \cdot f(d) + 2 \cdot d^2
 \end{aligned}$$

## Aussage

## Theorem

*Der Algorithmus von Seidel löst ein zulässiges  $d$ -dimensionales LP mit  $m$  Nebenbedingungen in erwarteter Laufzeit von  $O(m \cdot d!)$ .*

## Aussage

## Theorem

*Der Algorithmus von Seidel löst ein zulässiges  $d$ -dimensionales LP mit  $m$  Nebenbedingungen in erwarteter Laufzeit von  $O(m \cdot d!)$ .*

- Ist  $d$  konstant, so ist die erwartete Laufzeit  $O(m)$ .

## Aussage

## Theorem

*Der Algorithmus von Seidel löst ein zulässiges  $d$ -dimensionales LP mit  $m$  Nebenbedingungen in erwarteter Laufzeit von  $O(m \cdot d!)$ .*

- Ist  $d$  konstant, so ist die erwartete Laufzeit  $O(m)$ .
- Ist  $d > 10$  so ist die Konstante aber ein wenig unpraktisch.

## Aussage

## Theorem

*Der Algorithmus von Seidel löst ein zulässiges  $d$ -dimensionales LP mit  $m$  Nebenbedingungen in erwarteter Laufzeit von  $O(m \cdot d!)$ .*

- Ist  $d$  konstant, so ist die erwartete Laufzeit  $O(m)$ .
- Ist  $d > 10$  so ist die Konstante aber ein wenig unpraktisch.

## Literatur

- B. Korte, J. Vygen. Combinatorial Optimization: Theory and Algorithms, 2nd Edition, Springer, 2002.

## Literatur

- B. Korte, J. Vygen. Combinatorial Optimization: Theory and Algorithms, 2nd Edition, Springer, 2002.
- E. Lawler. Combinatorial Optimization: Networks and Matroids. Dover Publications, 1976.

## Literatur

- B. Korte, J. Vygen. Combinatorial Optimization: Theory and Algorithms, 2nd Edition, Springer, 2002.
- E. Lawler. Combinatorial Optimization: Networks and Matroids. Dover Publications, 1976.
- C. Papadimitriou und K. Steiglitz. Combinatorial Optimization: Algorithms and Complexity. Prentice Hall, 1982.

## Literatur

- B. Korte, J. Vygen. Combinatorial Optimization: Theory and Algorithms, 2nd Edition, Springer, 2002.
- E. Lawler. Combinatorial Optimization: Networks and Matroids. Dover Publications, 1976.
- C. Papadimitriou und K. Steiglitz. Combinatorial Optimization: Algorithms and Complexity. Prentice Hall, 1982.
- A. Schrijver. Combinatorial Optimization: Polyhedra and Efficiency. Springer, 2003.

