

# Approximationsalgorithmen

**Das Ziel:**

**Das Ziel:** Bearbeite schwierige Optimierungsprobleme der Form

$\text{opt}_y f(x, y)$  so dass  $L(x, y)$ .

**Das Ziel:** Bearbeite schwierige Optimierungsprobleme der Form

$$\text{opt}_y f(x, y) \text{ so dass } L(x, y).$$

- Die **Zielfunktion**  $f(x, y)$  ist zu minimieren oder zu maximieren:

**Das Ziel:** Bearbeite schwierige Optimierungsprobleme der Form

$$\text{opt}_y f(x, y) \text{ so dass } L(x, y).$$

- Die **Zielfunktion**  $f(x, y)$  ist zu minimieren oder zu maximieren: Wir nehmen stets  $\text{opt} \in \{\text{min}, \text{max}\}$  an.

**Das Ziel:** Bearbeite schwierige Optimierungsprobleme der Form

$$\text{opt}_y f(x, y) \text{ so dass } L(x, y).$$

- Die **Zielfunktion**  $f(x, y)$  ist zu minimieren oder zu maximieren: Wir nehmen stets  $\text{opt} \in \{\text{min}, \text{max}\}$  an.
- $x$  ist die Eingabe, oder die Beschreibung des Problems.

**Das Ziel:** Bearbeite schwierige Optimierungsprobleme der Form

$$\text{opt}_y f(x, y) \text{ so dass } L(x, y).$$

- Die **Zielfunktion**  $f(x, y)$  ist zu minimieren oder zu maximieren: Wir nehmen stets  $\text{opt} \in \{\min, \max\}$  an.
- $x$  ist die Eingabe, oder die Beschreibung des Problems.  $y$  heißt eine **Lösung** für Eingabe  $x$ , wenn das Lösungsprädikat  $L$  erfüllt ist.

**Das Ziel:** Bearbeite schwierige Optimierungsprobleme der Form

$$\text{opt}_y f(x, y) \text{ so dass } L(x, y).$$

- Die **Zielfunktion**  $f(x, y)$  ist zu minimieren oder zu maximieren: Wir nehmen stets  $\text{opt} \in \{\text{min}, \text{max}\}$  an.
- $x$  ist die Eingabe, oder die Beschreibung des Problems.  $y$  heißt eine **Lösung** für Eingabe  $x$ , wenn das Lösungsprädikat  $L$  erfüllt ist.
- Eine Lösung  $y$  mit optimalem Wert  $f(x, y)$  ist zu bestimmen.

**Das Ziel:** Bearbeite schwierige Optimierungsprobleme der Form

$$\text{opt}_y f(x, y) \text{ so dass } L(x, y).$$

- Die **Zielfunktion**  $f(x, y)$  ist zu minimieren oder zu maximieren: Wir nehmen stets  $\text{opt} \in \{\text{min}, \text{max}\}$  an.
- $x$  ist die Eingabe, oder die Beschreibung des Problems.  $y$  heißt eine **Lösung** für Eingabe  $x$ , wenn das Lösungsprädikat  $L$  erfüllt ist.
- Eine Lösung  $y$  mit optimalem Wert  $f(x, y)$  ist zu bestimmen.
- Wir spezifizieren das Optimierungsproblem durch das Tripel  $(\text{opt}, f, L)$

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen.

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen. Also ist

$L(G, C) \Leftrightarrow C \subseteq V$  und je zwei Knoten in  $C$   
sind durch eine Kante in  $G$  verbunden

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen. Also ist

$L(G, C) \Leftrightarrow C \subseteq V$  und je zwei Knoten in  $C$   
sind durch eine Kante in  $G$  verbunden

- ▶  $f(G, C) = |C|$  ist die zu maximierende Zielfunktion.

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen. Also ist

$$L(G, C) \Leftrightarrow C \subseteq V \text{ und je zwei Knoten in } C \\ \text{sind durch eine Kante in } G \text{ verbunden}$$

- ▶  $f(G, C) = |C|$  ist die zu maximierende Zielfunktion.
- Im Rucksackproblem sind  $n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  gegeben.

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen. Also ist

$$L(G, C) \Leftrightarrow C \subseteq V \text{ und je zwei Knoten in } C \\ \text{sind durch eine Kante in } G \text{ verbunden}$$

- ▶  $f(G, C) = |C|$  ist die zu maximierende Zielfunktion.
- Im Rucksackproblem sind  $n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  gegeben. **Das Ziel:** Bepacke den Rucksack, so dass einerseits eine Gewichtsschranke  $G \in \mathbb{R}$  nicht überschritten wird und andererseits

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen. Also ist

$L(G, C) \Leftrightarrow C \subseteq V$  und je zwei Knoten in  $C$   
sind durch eine Kante in  $G$  verbunden

- ▶  $f(G, C) = |C|$  ist die zu maximierende Zielfunktion.
- Im Rucksackproblem sind  $n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  gegeben. **Das Ziel:** Bepacke den Rucksack, so dass einerseits eine Gewichtsschranke  $G \in \mathbb{R}$  nicht überschritten wird und andererseits der Gesamtwert der eingepackten Objekte maximal ist.

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen. Also ist

$$L(G, C) \Leftrightarrow C \subseteq V \text{ und je zwei Knoten in } C \\ \text{sind durch eine Kante in } G \text{ verbunden}$$

- ▶  $f(G, C) = |C|$  ist die zu maximierende Zielfunktion.
- Im Rucksackproblem sind  $n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  gegeben. **Das Ziel:** Bepacke den Rucksack, so dass einerseits eine Gewichtsschranke  $G \in \mathbb{R}$  nicht überschritten wird und andererseits der Gesamtwert der eingepackten Objekte maximal ist.
  - ▶ Die Eingabe  $x$  besteht aus den Gewichten, den Werten und der Gewichtsschranke.

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen. Also ist

$$L(G, C) \Leftrightarrow C \subseteq V \text{ und je zwei Knoten in } C \\ \text{sind durch eine Kante in } G \text{ verbunden}$$

- ▶  $f(G, C) = |C|$  ist die zu maximierende Zielfunktion.
- Im Rucksackproblem sind  $n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  gegeben. Das Ziel: Bepacke den Rucksack, so dass einerseits eine Gewichtsschranke  $G \in \mathbb{R}$  nicht überschritten wird und andererseits der Gesamtwert der eingepackten Objekte maximal ist.
  - ▶ Die Eingabe  $x$  besteht aus den Gewichten, den Werten und der Gewichtsschranke.
  - ▶ Lösungen werden durch die Teilmengen  $I \subseteq \{1, \dots, n\}$  eingepackter Objekte beschrieben, wobei  $L(x, I) \Leftrightarrow \sum_{i \in I} g_i \leq G$ .

- Das Clique Problem besitzt Graphen  $G = (V, E)$  als Eingaben.
  - ▶ Genau die Cliques  $C \subseteq V$  sind Lösungen. Also ist

$L(G, C) \Leftrightarrow C \subseteq V$  und je zwei Knoten in  $C$   
sind durch eine Kante in  $G$  verbunden

- ▶  $f(G, C) = |C|$  ist die zu maximierende Zielfunktion.
- Im Rucksackproblem sind  $n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  gegeben. Das Ziel: Bepacke den Rucksack, so dass einerseits eine Gewichtsschranke  $G \in \mathbb{R}$  nicht überschritten wird und andererseits der Gesamtwert der eingepackten Objekte maximal ist.
  - ▶ Die Eingabe  $x$  besteht aus den Gewichten, den Werten und der Gewichtsschranke.
  - ▶ Lösungen werden durch die Teilmengen  $I \subseteq \{1, \dots, n\}$  eingepackter Objekte beschrieben, wobei  $L(x, I) \Leftrightarrow \sum_{i \in I} g_i \leq G$ .
  - ▶  $f(x, I) = \sum_{i \in I} w_i$  ist die zu maximierende Zielfunktion.

Sei  $P = (\text{opt}, f, L)$  ein Optimierungsproblem.

Sei  $P = (\text{opt}, f, L)$  ein Optimierungsproblem.

- $y^*$  heißt eine **optimale** Lösung für Eingabe  $x$ , falls

Sei  $P = (\text{opt}, f, L)$  ein Optimierungsproblem.

- $y^*$  heißt eine **optimale** Lösung für Eingabe  $x$ , falls

$$f(x, y^*) = \text{opt} \{ f(x, y) \mid y \text{ ist eine Lösung, d.h. es gilt } L(x, y) \}.$$

Sei  $P = (\text{opt}, f, L)$  ein Optimierungsproblem.

- $y^*$  heißt eine **optimale** Lösung für Eingabe  $x$ , falls

$$f(x, y^*) = \text{opt} \{ f(x, y) \mid y \text{ ist eine Lösung, d.h. es gilt } L(x, y) \}.$$

Wir setzen  $\text{opt}_P(x) := f(x, y^*)$ .

Sei  $P = (\text{opt}, f, L)$  ein Optimierungsproblem.

- $y^*$  heißt eine **optimale** Lösung für Eingabe  $x$ , falls

$$f(x, y^*) = \text{opt} \{ f(x, y) \mid y \text{ ist eine Lösung, d.h. es gilt } L(x, y) \}.$$

Wir setzen  $\text{opt}_P(x) := f(x, y^*)$ .

- Ein Approximationsalgorithmus  $A$  für  $P$  berechnet auf jeder Eingabe  $x$  eine Lösung  $A(x)$ .

Sei  $P = (\text{opt}, f, L)$  ein Optimierungsproblem.

- $y^*$  heißt eine **optimale** Lösung für Eingabe  $x$ , falls

$$f(x, y^*) = \text{opt} \{ f(x, y) \mid y \text{ ist eine Lösung, d.h. es gilt } L(x, y) \}.$$

Wir setzen  $\text{opt}_P(x) := f(x, y^*)$ .

- Ein Approximationsalgorithmus  $A$  für  $P$  berechnet auf jeder Eingabe  $x$  eine Lösung  $A(x)$ .

Wir möchten **schnelle** Approximationsalgorithmen entwerfen, die

Sei  $P = (\text{opt}, f, L)$  ein Optimierungsproblem.

- $y^*$  heißt eine **optimale** Lösung für Eingabe  $x$ , falls

$$f(x, y^*) = \text{opt} \{ f(x, y) \mid y \text{ ist eine Lösung, d.h. es gilt } L(x, y) \}.$$

Wir setzen  $\text{opt}_P(x) := f(x, y^*)$ .

- Ein Approximationsalgorithmus  $A$  für  $P$  berechnet auf jeder Eingabe  $x$  eine Lösung  $A(x)$ .

Wir möchten **schnelle** Approximationsalgorithmen entwerfen, die **gute** Lösungen berechnen.

# Wie gut ist eine Approximation?

## Approximationsfaktoren

Eine Lösung  $y$  von  $P$  für Eingabe  $x$  heißt  $\delta$ -approximativ, wenn

# Wie gut ist eine Approximation?

## Approximationsfaktoren

Eine Lösung  $y$  von  $P$  für Eingabe  $x$  heißt  $\delta$ -approximativ, wenn

$$f(x, y) \geq \frac{\max_P(x)}{\delta} \quad \text{für ein Maximierungsproblem}$$

# Wie gut ist eine Approximation?

## Approximationsfaktoren

Eine Lösung  $y$  von  $P$  für Eingabe  $x$  heißt  $\delta$ -approximativ, wenn

$$f(x, y) \geq \frac{\max_P(x)}{\delta} \quad \text{für ein Maximierungsproblem}$$

beziehungsweise wenn

$$f(x, y) \leq \delta \cdot \min_P(x) \quad \text{für ein Minimierungsproblem.}$$

# Wie gut ist eine Approximation?

## Approximationsfaktoren

Eine Lösung  $y$  von  $P$  für Eingabe  $x$  heißt  $\delta$ -approximativ, wenn

$$f(x, y) \geq \frac{\max_P(x)}{\delta} \quad \text{für ein Maximierungsproblem}$$

beziehungsweise wenn

$$f(x, y) \leq \delta \cdot \min_P(x) \quad \text{für ein Minimierungsproblem.}$$

- Der Approximationsfaktor ist stets **mindestens** 1.

# Wie gut ist eine Approximation?

## Approximationsfaktoren

Eine Lösung  $y$  von  $P$  für Eingabe  $x$  heißt  $\delta$ -approximativ, wenn

$$f(x, y) \geq \frac{\max_P(x)}{\delta} \quad \text{für ein Maximierungsproblem}$$

beziehungsweise wenn

$$f(x, y) \leq \delta \cdot \min_P(x) \quad \text{für ein Minimierungsproblem.}$$

- Der Approximationsfaktor ist stets **mindestens** 1.
- Wenn wir den Approximationsfaktor  $\delta = 1$  erreichen, dann

# Wie gut ist eine Approximation?

## Approximationsfaktoren

Eine Lösung  $y$  von  $P$  für Eingabe  $x$  heißt  $\delta$ -approximativ, wenn

$$f(x, y) \geq \frac{\max_P(x)}{\delta} \quad \text{für ein Maximierungsproblem}$$

beziehungsweise wenn

$$f(x, y) \leq \delta \cdot \min_P(x) \quad \text{für ein Minimierungsproblem.}$$

- Der Approximationsfaktor ist stets **mindestens** 1.
- Wenn wir den Approximationsfaktor  $\delta = 1$  erreichen, dann haben wir das Optimierungsproblem exakt gelöst.

# Wie gut ist eine Approximation?

## Approximationsfaktoren

Eine Lösung  $y$  von  $P$  für Eingabe  $x$  heißt  $\delta$ -approximativ, wenn

$$f(x, y) \geq \frac{\max_P(x)}{\delta} \quad \text{für ein Maximierungsproblem}$$

beziehungsweise wenn

$$f(x, y) \leq \delta \cdot \min_P(x) \quad \text{für ein Minimierungsproblem.}$$

- Der Approximationsfaktor ist stets **mindestens** 1.
- Wenn wir den Approximationsfaktor  $\delta = 1$  erreichen, dann haben wir das Optimierungsproblem exakt gelöst.
- **Je kleiner der Approximationsfaktor,**

# Wie gut ist eine Approximation?

## Approximationsfaktoren

Eine Lösung  $y$  von  $P$  für Eingabe  $x$  heißt  $\delta$ -approximativ, wenn

$$f(x, y) \geq \frac{\max_P(x)}{\delta} \quad \text{für ein Maximierungsproblem}$$

beziehungsweise wenn

$$f(x, y) \leq \delta \cdot \min_P(x) \quad \text{für ein Minimierungsproblem.}$$

- Der Approximationsfaktor ist stets **mindestens** 1.
- Wenn wir den Approximationsfaktor  $\delta = 1$  erreichen, dann haben wir das Optimierungsproblem exakt gelöst.
- Je kleiner der Approximationsfaktor, umso besser ist die gefundene Lösung.

# Ein Beispiel: Das metrische Traveling Salesman Problem

- Wir haben die Spannbaum Heuristik für M-TSP entworfen.

# Ein Beispiel: Das metrische Traveling Salesman Problem

- Wir haben die Spannbaum Heuristik für M-TSP entworfen.
- Wenn  $L$  die Länge der von uns berechneten Tour ist

# Ein Beispiel: Das metrische Traveling Salesman Problem

- Wir haben die Spannbaum Heuristik für M-TSP entworfen.
- Wenn  $L$  die Länge der von uns berechneten Tour ist und wenn  $opt$  die minimale Länge einer Rundreise ist,

# Ein Beispiel: Das metrische Traveling Salesman Problem

- Wir haben die Spannbaum Heuristik für M-TSP entworfen.
- Wenn  $L$  die Länge der von uns berechneten Tour ist und wenn  $opt$  die minimale Länge einer Rundreise ist, dann haben wir

$$L \leq 2 \cdot opt$$

nachgewiesen.

# Ein Beispiel: Das metrische Traveling Salesman Problem

- Wir haben die Spannbaum Heuristik für M-TSP entworfen.
- Wenn  $L$  die Länge der von uns berechneten Tour ist und wenn  $opt$  die minimale Länge einer Rundreise ist, dann haben wir

$$L \leq 2 \cdot opt$$

nachgewiesen.

- Die Spannbaum Heuristik ist ein **2-approximativer Approximationsalgorithmus** für M-TSP.

# Wie gut können schwierige Optimierungsprobleme approximiert werden?

- Optimierungsprobleme mit  $\text{NP}$ -vollständigen Entscheidungsproblemen zeigen starke Variationen.

# Wie gut können schwierige Optimierungsprobleme approximiert werden?

- Optimierungsprobleme mit  $\text{NP}$ -vollständigen Entscheidungsproblemen zeigen starke Variationen.
  - ▶ Einige Probleme, wie zum Beispiel das **Rucksackproblem**, sind sehr scharf durch effiziente Algorithmen approximierbar.

# Wie gut können schwierige Optimierungsprobleme approximiert werden?

- Optimierungsprobleme mit  $NP$ -vollständigen Entscheidungsproblemen zeigen starke Variationen.
  - ▶ Einige Probleme, wie zum Beispiel das **Rucksackproblem**, sind sehr scharf durch effiziente Algorithmen approximierbar.
  - ▶ Andere, wie zum Beispiel das Problem der **Last-Verteilung** sind schon etwas schwieriger.

# Wie gut können schwierige Optimierungsprobleme approximiert werden?

- Optimierungsprobleme mit  $\text{NP}$ -vollständigen Entscheidungsproblemen zeigen starke Variationen.
  - ▶ Einige Probleme, wie zum Beispiel das **Rucksackproblem**, sind sehr scharf durch effiziente Algorithmen approximierbar.
  - ▶ Andere, wie zum Beispiel das Problem der **Last-Verteilung** sind schon etwas schwieriger.
  - ▶ Dann folgt das **Vertex Cover Problem** und das noch schwierigere **Clique Problem**.

# Wie gut können schwierige Optimierungsprobleme approximiert werden?

- Optimierungsprobleme mit NP-vollständigen Entscheidungsproblemen zeigen starke Variationen.
  - ▶ Einige Probleme, wie zum Beispiel das **Rucksackproblem**, sind sehr scharf durch effiziente Algorithmen approximierbar.
  - ▶ Andere, wie zum Beispiel das Problem der **Last-Verteilung** sind schon etwas schwieriger.
  - ▶ Dann folgt das **Vertex Cover Problem** und das noch schwierigere **Clique Problem**.
  - ▶ Zu den ganz harten Brocken gehören die **0-1 Programmierung** und die **ganzzahlige Programmierung**.

# Wie gut können schwierige Optimierungsprobleme approximiert werden?

- Optimierungsprobleme mit NP-vollständigen Entscheidungsproblemen zeigen starke Variationen.
  - ▶ Einige Probleme, wie zum Beispiel das **Rucksackproblem**, sind sehr scharf durch effiziente Algorithmen approximierbar.
  - ▶ Andere, wie zum Beispiel das Problem der **Last-Verteilung** sind schon etwas schwieriger.
  - ▶ Dann folgt das **Vertex Cover Problem** und das noch schwierigere **Clique Problem**.
  - ▶ Zu den ganz harten Brocken gehören die **0-1 Programmierung** und die **ganzzahlige Programmierung**.
- Was weiss man über die Approximationskomplexität schwieriger Probleme?

Wir haben bereits die folgenden Scheduling Probleme untersucht.

Wir haben bereits die folgenden Scheduling Probleme untersucht.

- Im (gewichteten) [Intervall Scheduling](#)

Wir haben bereits die folgenden Scheduling Probleme untersucht.

- Im (gewichteten) **Intervall Scheduling**
  - ▶ haben wir eine wertvollste Auswahl von Aufgaben bei vorgeschriebenen Start- und Terminierungszeiten auf **einem** Prozessor ausgeführt.

Wir haben bereits die folgenden Scheduling Probleme untersucht.

- Im (gewichteten) **Intervall Scheduling**
  - ▶ haben wir eine wertvollste Auswahl von Aufgaben bei vorgeschriebenen Start- und Terminierungszeiten auf **einem** Prozessor ausgeführt.
- Für das **Scheduling mit minimaler Verspätung** haben wir die maximale Verspätung bei

Wir haben bereits die folgenden Scheduling Probleme untersucht.

- Im (gewichteten) **Intervall Scheduling**
  - ▶ haben wir eine wertvollste Auswahl von Aufgaben bei vorgeschriebenen Start- und Terminierungszeiten auf **einem** Prozessor ausgeführt.
- Für das **Scheduling mit minimaler Verspätung** haben wir die maximale Verspätung bei gegebenen Fristen und Laufzeiten mit einem Greedy Algorithmus minimiert.

Wir haben bereits die folgenden Scheduling Probleme untersucht.

- Im (gewichteten) **Intervall Scheduling**
  - ▶ haben wir eine wertvollste Auswahl von Aufgaben bei vorgeschriebenen Start- und Terminierungszeiten auf **einem** Prozessor ausgeführt.
- Für das **Scheduling mit minimaler Verspätung** haben wir die maximale Verspätung bei gegebenen Fristen und Laufzeiten mit einem Greedy Algorithmus minimiert.

## Das Lastverteilungsproblem:

Wir haben bereits die folgenden Scheduling Probleme untersucht.

- Im (gewichteten) **Intervall Scheduling**
  - ▶ haben wir eine wertvollste Auswahl von Aufgaben bei vorgeschriebenen Start- und Terminierungszeiten auf **einem** Prozessor ausgeführt.
- Für das **Scheduling mit minimaler Verspätung** haben wir die maximale Verspätung bei gegebenen Fristen und Laufzeiten mit einem Greedy Algorithmus minimiert.

**Das Lastverteilungsproblem:** Nur die Rechenzeiten der Aufgaben sind bekannt. Alle Aufgaben können sofort abgearbeitet werden.

Wir haben bereits die folgenden Scheduling Probleme untersucht.

- Im (gewichteten) **Intervall Scheduling**
  - ▶ haben wir eine wertvollste Auswahl von Aufgaben bei vorgeschriebenen Start- und Terminierungszeiten auf **einem** Prozessor ausgeführt.
- Für das **Scheduling mit minimaler Verspätung** haben wir die maximale Verspätung bei gegebenen Fristen und Laufzeiten mit einem Greedy Algorithmus minimiert.

**Das Lastverteilungsproblem:** Nur die Rechenzeiten der Aufgaben sind bekannt. Alle Aufgaben können sofort abgearbeitet werden.

**Das Ziel:** Verteile die Aufgaben so auf  $m$  identische Prozessoren, dass der **Makespan**,

Wir haben bereits die folgenden Scheduling Probleme untersucht.

- Im (gewichteten) **Intervall Scheduling**
  - ▶ haben wir eine wertvollste Auswahl von Aufgaben bei vorgeschriebenen Start- und Terminierungszeiten auf **einem** Prozessor ausgeführt.
- Für das **Scheduling mit minimaler Verspätung** haben wir die maximale Verspätung bei gegebenen Fristen und Laufzeiten mit einem Greedy Algorithmus minimiert.

**Das Lastverteilungsproblem:** Nur die Rechenzeiten der Aufgaben sind bekannt. Alle Aufgaben können sofort abgearbeitet werden.

**Das Ziel:** Verteile die Aufgaben so auf  $m$  identische Prozessoren, dass der **Makespan**, also der Zeitraum in dem **alle** Aufgaben abgearbeitet werden, **minimal** ist.

In einem realistischen Szenario muss die Last verteilt werden, „**wenn sie anfällt**“.

In einem realistischen Szenario muss die Last verteilt werden, „**wenn sie anfällt**“. Insbesondere kann die Zuweisung weiterer Aufgaben nicht abgewartet werden:

In einem realistischen Szenario muss die Last verteilt werden, „**wenn sie anfällt**“. Insbesondere kann die Zuweisung weiterer Aufgaben nicht abgewartet werden: Ein **On-line Algorithmus** muss Entscheidungen treffen ohne die Zukunft zu kennen.

In einem realistischen Szenario muss die Last verteilt werden, „wenn sie anfällt“. Insbesondere kann die Zuweisung weiterer Aufgaben nicht abgewartet werden: Ein **On-line Algorithmus** muss Entscheidungen treffen ohne die Zukunft zu kennen.

## Ein On-line Scheduling Algorithmus:

- Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1, \dots, t_n$  sind gegeben.

In einem realistischen Szenario muss die Last verteilt werden, „wenn sie anfällt“. Insbesondere kann die Zuweisung weiterer Aufgaben nicht abgewartet werden: Ein **On-line Algorithmus** muss Entscheidungen treffen ohne die Zukunft zu kennen.

## Ein On-line Scheduling Algorithmus:

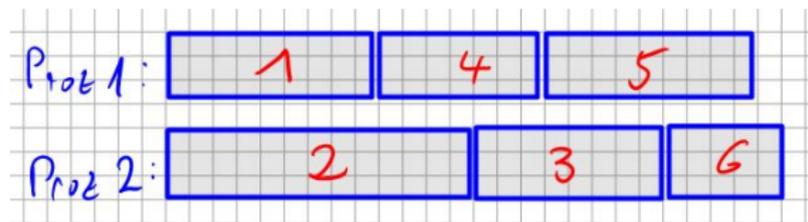
- Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1, \dots, t_n$  sind gegeben.
- Die Aufgaben werden „der Reihe nach“ abgearbeitet. Wenn Aufgabe  $i$  „dran“ ist, dann

In einem realistischen Szenario muss die Last verteilt werden, „wenn sie anfällt“. Insbesondere kann die Zuweisung weiterer Aufgaben nicht abgewartet werden: Ein **On-line Algorithmus** muss Entscheidungen treffen ohne die Zukunft zu kennen.

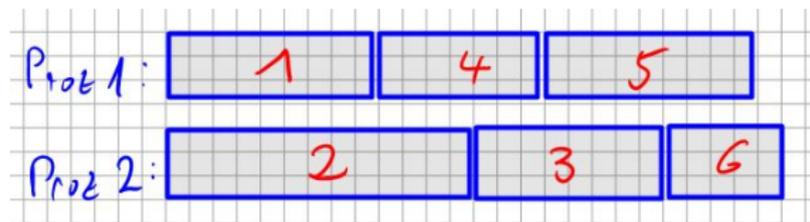
## Ein On-line Scheduling Algorithmus:

- Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1, \dots, t_n$  sind gegeben.
- Die Aufgaben werden „der Reihe nach“ abgearbeitet. Wenn Aufgabe  $i$  „dran“ ist, dann  
weise Aufgabe  $i$  dem Prozessor mit der bisher geringsten Last zu

Aufgaben für zwei Prozessoren entstehen in der Reihenfolge 1, 2, ...  
Welche ist die erste Aufgabe, die *nicht* gemäß Greedy-Online Scheduling zugewiesen wurde?

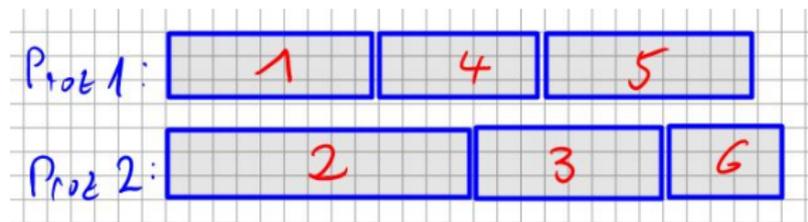


Aufgaben für zwei Prozessoren entstehen in der Reihenfolge 1, 2, ...  
Welche ist die erste Aufgabe, die *nicht* gemäß Greedy-Online Scheduling zugewiesen wurde?



Auflösung:

Aufgaben für zwei Prozessoren entstehen in der Reihenfolge 1, 2, ...  
Welche ist die erste Aufgabe, die *nicht* gemäß Greedy-Online Scheduling zugewiesen wurde?



Auflösung: (3)

Die On-line Strategie ist 2-approximativ.

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.  
Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.  
Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.  
Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“:

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.  
Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen.

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.  
Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T$$

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.  
Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T = mT - (m-1) \cdot t_j$$

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.  
Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T = mT - (m-1) \cdot t_j \geq mT - m \cdot t_j.$$

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last.  
Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T = mT - (m-1) \cdot t_j \geq mT - m \cdot t_j.$$

- ▶ Dividiere durch  $m$  und  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k$  folgt. ◀

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last. Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T = mT - (m-1) \cdot t_j \geq mT - m \cdot t_j.$$

- ▶ Dividiere durch  $m$  und  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k$  folgt. ◀

- ▶ Sei  $\text{opt}$  der optimale Makespan. Dann ist

$$T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt}$$

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last. Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T = mT - (m-1) \cdot t_j \geq mT - m \cdot t_j.$$

- ▶ Dividiere durch  $m$  und  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k$  folgt. ◀
- ▶ Sei  $\text{opt}$  der optimale Makespan. Dann ist
$$T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt} \text{ und } t_j \leq \text{opt}.$$

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last. Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T = mT - (m-1) \cdot t_j \geq mT - m \cdot t_j.$$

- ▶ Dividiere durch  $m$  und  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k$  folgt. ◀
- ▶ Sei  $\text{opt}$  der optimale Makespan. Dann ist
$$T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt} \text{ und } t_j \leq \text{opt}.$$
- ▶ Also ist  $T =$

Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last. Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T = mT - (m-1) \cdot t_j \geq mT - m \cdot t_j.$$

- ▶ Dividiere durch  $m$  und  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k$  folgt. 
- ▶ Sei  $\text{opt}$  der optimale Makespan. Dann ist
$$T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt} \text{ und } t_j \leq \text{opt}.$$
- ▶ Also ist  $T = (T - t_j) + t_j \leq$

## Die On-line Strategie ist 2-approximativ.

- Angenommen, Prozessor  $i$  trägt die größte Last. Der Makespan  $T$  ist dann die Gesamtlaufzeit von Prozessor  $i$ .
- Prozessor  $i$  möge die Aufgabe  $j$  als letzte Aufgabe ausführen.
  - ▶ Zum Zeitpunkt  $T - t_j$  sind alle Prozessoren „busy“: Ansonsten hätte eine freie Maschine die Aufgabe  $j$  früher übernommen. Also ist

$$\sum_{k=1}^n t_k \geq (m-1) \cdot (T - t_j) + T = mT - (m-1) \cdot t_j \geq mT - m \cdot t_j.$$

- ▶ Dividiere durch  $m$  und  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k$  folgt. ◀
- ▶ Sei  $\text{opt}$  der optimale Makespan. Dann ist
$$T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt} \text{ und } t_j \leq \text{opt}.$$
- ▶ Also ist  $T = (T - t_j) + t_j \leq 2 \cdot \text{opt}$ .

# Wie gut war unsere Analyse?

**Ein worst-case Beispiel:**

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor.

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor. Alle Aufgaben bis auf die letzte sind „kurze“ Aufgaben der Länge 1.

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor. Alle Aufgaben bis auf die letzte sind „kurze“ Aufgaben der Länge 1. Die letzte Aufgabe ist „lang“ und hat die Ausführungszeit  $m$ .

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor. Alle Aufgaben bis auf die letzte sind „kurze“ Aufgaben der Länge 1. Die letzte Aufgabe ist „lang“ und hat die Ausführungszeit  $m$ .
- Der optimale Makespan ist  $m$ :

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor. Alle Aufgaben bis auf die letzte sind „kurze“ Aufgaben der Länge 1. Die letzte Aufgabe ist „lang“ und hat die Ausführungszeit  $m$ .
- Der optimale Makespan ist  $m$ :
  - ▶ Ein Prozessor führt die lange Aufgabe aus.

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor. Alle Aufgaben bis auf die letzte sind „kurze“ Aufgaben der Länge 1. Die letzte Aufgabe ist „lang“ und hat die Ausführungszeit  $m$ .
- Der optimale Makespan ist  $m$ :
  - ▶ Ein Prozessor führt die lange Aufgabe aus.
  - ▶ Die verbleibenden  $m - 1$  Prozessoren teilen die  $(m - 1) \cdot m$  kurzen Aufgaben unter sich auf.

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor. Alle Aufgaben bis auf die letzte sind „kurze“ Aufgaben der Länge 1. Die letzte Aufgabe ist „lang“ und hat die Ausführungszeit  $m$ .
- Der optimale Makespan ist  $m$ :
  - ▶ Ein Prozessor führt die lange Aufgabe aus.
  - ▶ Die verbleibenden  $m - 1$  Prozessoren teilen die  $(m - 1) \cdot m$  kurzen Aufgaben unter sich auf.
- Unsere On-line Heuristik führt zuerst alle kurzen Aufgaben in der Zeit  $m - 1$  aus.

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor. Alle Aufgaben bis auf die letzte sind „kurze“ Aufgaben der Länge 1. Die letzte Aufgabe ist „lang“ und hat die Ausführungszeit  $m$ .
- Der optimale Makespan ist  $m$ :
  - ▶ Ein Prozessor führt die lange Aufgabe aus.
  - ▶ Die verbleibenden  $m - 1$  Prozessoren teilen die  $(m - 1) \cdot m$  kurzen Aufgaben unter sich auf.
- Unsere On-line Heuristik führt zuerst alle kurzen Aufgaben in der Zeit  $m - 1$  aus. Die lange Aufgabe wird zuletzt ausgeführt und kostet  $m$  zusätzliche Schritte.

## Ein worst-case Beispiel:

- Insgesamt  $(m - 1) \cdot m + 1$  Aufgaben liegen vor. Alle Aufgaben bis auf die letzte sind „kurze“ Aufgaben der Länge 1. Die letzte Aufgabe ist „lang“ und hat die Ausführungszeit  $m$ .
- Der optimale Makespan ist  $m$ :
  - ▶ Ein Prozessor führt die lange Aufgabe aus.
  - ▶ Die verbleibenden  $m - 1$  Prozessoren teilen die  $(m - 1) \cdot m$  kurzen Aufgaben unter sich auf.
- Unsere On-line Heuristik führt zuerst alle kurzen Aufgaben in der Zeit  $m - 1$  aus. Die lange Aufgabe wird zuletzt ausgeführt und kostet  $m$  zusätzliche Schritte.
- Unsere Heuristik hat Schwierigkeiten, wenn lange Aufgaben zuletzt abgearbeitet werden.

- (1) Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1 \geq t_2 \geq \dots \geq t_n$  sind gegeben.

# Eine Off-line Heuristik

- (1) Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1 \geq t_2 \geq \dots \geq t_n$  sind gegeben.
- (2) Die Aufgaben werden der Reihe nach abgearbeitet. Wenn Aufgabe  $i$  „dran“ ist, dann

# Eine Off-line Heuristik

- (1) Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1 \geq t_2 \geq \dots \geq t_n$  sind gegeben.
- (2) Die Aufgaben werden der Reihe nach abgearbeitet. Wenn Aufgabe  $i$  „dran“ ist, dann  
weise Aufgabe  $i$  dem Prozessor mit der bisher geringsten Last zu.

# Eine Off-line Heuristik

- (1) Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1 \geq t_2 \geq \dots \geq t_n$  sind gegeben.
- (2) Die Aufgaben werden der Reihe nach abgearbeitet. Wenn Aufgabe  $i$  „dran“ ist, dann  
weise Aufgabe  $i$  dem Prozessor mit der bisher geringsten Last zu.

## Die zentrale Beobachtung

Sei  $opt$  der minimale Makespan für  $m$  Prozessoren.

Dann ist  $2 \cdot t_{m+1} \leq opt$ .

# Eine Off-line Heuristik

- (1) Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1 \geq t_2 \geq \dots \geq t_n$  sind gegeben.
- (2) Die Aufgaben werden der Reihe nach abgearbeitet. Wenn Aufgabe  $i$  „dran“ ist, dann  
weise Aufgabe  $i$  dem Prozessor mit der bisher geringsten Last zu.

## Die zentrale Beobachtung

Sei  $opt$  der minimale Makespan für  $m$  Prozessoren.

Dann ist  $2 \cdot t_{m+1} \leq opt$ .

- Es ist  $t_1 \geq \dots \geq t_m \geq t_{m+1}$ .

# Eine Off-line Heuristik

- (1) Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1 \geq t_2 \geq \dots \geq t_n$  sind gegeben.
- (2) Die Aufgaben werden der Reihe nach abgearbeitet. Wenn Aufgabe  $i$  „dran“ ist, dann  
weise Aufgabe  $i$  dem Prozessor mit der bisher geringsten Last zu.

## Die zentrale Beobachtung

Sei  $opt$  der minimale Makespan für  $m$  Prozessoren.

Dann ist  $2 \cdot t_{m+1} \leq opt$ .

- Es ist  $t_1 \geq \dots \geq t_m \geq t_{m+1}$ .
- Um die ersten  $m + 1$  Aufgaben abzuarbeiten, muss ein Prozessor zwei Aufgaben ausführen.

# Eine Off-line Heuristik

- (1) Aufgaben  $1, \dots, n$  mit Rechenzeiten  $t_1 \geq t_2 \geq \dots \geq t_n$  sind gegeben.
- (2) Die Aufgaben werden der Reihe nach abgearbeitet. Wenn Aufgabe  $i$  „dran“ ist, dann  
weise Aufgabe  $i$  dem Prozessor mit der bisher geringsten Last zu.

## Die zentrale Beobachtung

Sei  $opt$  der minimale Makespan für  $m$  Prozessoren.

Dann ist  $2 \cdot t_{m+1} \leq opt$ .

- Es ist  $t_1 \geq \dots \geq t_m \geq t_{m+1}$ .
- Um die ersten  $m + 1$  Aufgaben abzuarbeiten, muss ein Prozessor zwei Aufgaben ausführen.
- Seine Bearbeitungszeit ist mindestens  $2 \cdot t_{m+1}$ .

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.
- Es ist  $t_j \leq t_{m+1}$ , denn wir arbeiten die Aufgaben nach fallender Bearbeitungszeit ab. Also

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.
- Es ist  $t_j \leq t_{m+1}$ , denn wir arbeiten die Aufgaben nach fallender Bearbeitungszeit ab. Also

$$2 \cdot t_j \leq 2 \cdot t_{m+1} \leq \text{opt}$$

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.
- Es ist  $t_j \leq t_{m+1}$ , denn wir arbeiten die Aufgaben nach fallender Bearbeitungszeit ab. Also

$$2 \cdot t_j \leq 2 \cdot t_{m+1} \leq \text{opt}$$

- Wir haben  $t_j \leq \text{opt}/2$  gerade nachgewiesen und wissen, dass  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt}$  gilt .

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.
- Es ist  $t_j \leq t_{m+1}$ , denn wir arbeiten die Aufgaben nach fallender Bearbeitungszeit ab. Also

$$2 \cdot t_j \leq 2 \cdot t_{m+1} \leq \text{opt}$$

- Wir haben  $t_j \leq \text{opt}/2$  gerade nachgewiesen und wissen, dass  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt}$  gilt .
- Also folgt  $T =$

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.
- Es ist  $t_j \leq t_{m+1}$ , denn wir arbeiten die Aufgaben nach fallender Bearbeitungszeit ab. Also

$$2 \cdot t_j \leq 2 \cdot t_{m+1} \leq \text{opt}$$

- Wir haben  $t_j \leq \text{opt}/2$  gerade nachgewiesen und wissen, dass  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt}$  gilt .
- Also folgt  $T = (T - t_j) + t_j \leq$

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.
- Es ist  $t_j \leq t_{m+1}$ , denn wir arbeiten die Aufgaben nach fallender Bearbeitungszeit ab. Also

$$2 \cdot t_j \leq 2 \cdot t_{m+1} \leq \text{opt}$$

- Wir haben  $t_j \leq \text{opt}/2$  gerade nachgewiesen und wissen, dass  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt}$  gilt .
- Also folgt  $T = (T - t_j) + t_j \leq \text{opt} + \text{opt}/2 =$

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.
- Es ist  $t_j \leq t_{m+1}$ , denn wir arbeiten die Aufgaben nach fallender Bearbeitungszeit ab. Also

$$2 \cdot t_j \leq 2 \cdot t_{m+1} \leq \text{opt}$$

- Wir haben  $t_j \leq \text{opt}/2$  gerade nachgewiesen und wissen, dass  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt}$  gilt .
- Also folgt  $T = (T - t_j) + t_j \leq \text{opt} + \text{opt}/2 = 3 \cdot \text{opt}/2$ .

Der Approximationsfaktor sinkt auf höchstens  $\frac{3}{2}$ , wenn Aufgaben gemäß fallender Bearbeitungszeit präsentiert werden.

- Wir betrachten wieder den Prozessor  $i$  mit größter Last. Prozessor  $i$  möge die Aufgabe  $j$  als Letzte ausführen.
- Es ist  $t_j \leq t_{m+1}$ , denn wir arbeiten die Aufgaben nach fallender Bearbeitungszeit ab. Also

$$2 \cdot t_j \leq 2 \cdot t_{m+1} \leq \text{opt}$$

- Wir haben  $t_j \leq \text{opt}/2$  gerade nachgewiesen und wissen, dass  $T - t_j \leq \frac{1}{m} \cdot \sum_{k=1}^n t_k \leq \text{opt}$  gilt .
- Also folgt  $T = (T - t_j) + t_j \leq \text{opt} + \text{opt}/2 = 3 \cdot \text{opt}/2$ .  
(Der tatsächliche Approximationsfaktor ist  $4/3$ .)

# Das Rucksackproblem

$n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  sind in einen Rucksack mit Kapazität höchstens  $G$  zu packen.

# Das Rucksackproblem

$n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  sind in einen Rucksack mit Kapazität höchstens  $G$  zu packen. Der Gesamtwert der Bepackung ist zu maximieren.

# Das Rucksackproblem

$n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  sind in einen Rucksack mit Kapazität höchstens  $G$  zu packen. Der Gesamtwert der Bepackung ist zu maximieren.

- Das Rucksackproblem ist NP-vollständig.

# Das Rucksackproblem

$n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  sind in einen Rucksack mit Kapazität höchstens  $G$  zu packen. Der Gesamtwert der Bepackung ist zu maximieren.

- Das Rucksackproblem ist NP-vollständig.
- Wir lösen ein anderes Problem, nämlich: **Bestimme**

# Das Rucksackproblem

$n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  sind in einen Rucksack mit Kapazität höchstens  $G$  zu packen. Der Gesamtwert der Bepackung ist zu maximieren.

- Das Rucksackproblem ist NP-vollständig.
- Wir lösen ein anderes Problem, nämlich: **Bestimme**

**Gewicht $_i(w)$  = das minimale Gewicht einer Bepackung aus den ersten  $i$  Objekten mit Gesamtwert  $w$ .**

# Das Rucksackproblem

$n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  sind in einen Rucksack mit Kapazität höchstens  $G$  zu packen. Der Gesamtwert der Bepackung ist zu maximieren.

- Das Rucksackproblem ist NP-vollständig.
- Wir lösen ein anderes Problem, nämlich: **Bestimme**

**Gewicht $_i(w)$**  = das minimale Gewicht einer Bepackung aus den ersten  $i$  Objekten mit Gesamtwert  $w$ .

- Wir lösen das Rucksackproblem, wenn wir nach dem größten Wert  $w$  mit **Gewicht $_n(w) \leq G$**  suchen.

# Das Rucksackproblem

$n$  Objekte mit Gewichten  $g_1, \dots, g_n \in \mathbb{R}$  und Werten  $w_1, \dots, w_n \in \mathbb{N}$  sind in einen Rucksack mit Kapazität höchstens  $G$  zu packen. Der Gesamtwert der Bepackung ist zu maximieren.

- Das Rucksackproblem ist NP-vollständig.
- Wir lösen ein anderes Problem, nämlich: **Bestimme**

**Gewicht $_i(w)$**  = das minimale Gewicht einer Bepackung aus den ersten  $i$  Objekten mit Gesamtwert  $w$ .

- Wir lösen das Rucksackproblem, wenn wir nach dem größten Wert  $w$  mit **Gewicht $_n(w) \leq G$**  suchen.
- Wir wenden dynamisches Programmieren an, um **Gewicht $_n(w)$**  für alle möglichen Werte  $w \leq \sum_{i=1}^n w_i$  zu bestimmen.

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?

# Bestimmung von Gewicht $_i(w)$

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.
  - ▶ Oder aber das  $i$ te Objekt wird nicht in den Rucksack gepackt und der Wert  $w$  ist mit Hilfe der ersten  $i - 1$  Objekte zu erbringen.

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.
  - ▶ Oder aber das  $i$ te Objekt wird nicht in den Rucksack gepackt und der Wert  $w$  ist mit Hilfe der ersten  $i - 1$  Objekte zu erbringen.
  - ▶ Wir erhalten die Rekursionsgleichungen

$$\text{Gewicht}_i(w) := \min \{$$

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.
  - ▶ Oder aber das  $i$ te Objekt wird nicht in den Rucksack gepackt und der Wert  $w$  ist mit Hilfe der ersten  $i - 1$  Objekte zu erbringen.
  - ▶ Wir erhalten die Rekursionsgleichungen

$$\text{Gewicht}_i(w) := \min \{ \text{Gewicht}_{i-1}(w - w_i) + g_i, \dots \}$$

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.
  - ▶ Oder aber das  $i$ te Objekt wird nicht in den Rucksack gepackt und der Wert  $w$  ist mit Hilfe der ersten  $i - 1$  Objekte zu erbringen.
  - ▶ Wir erhalten die Rekursionsgleichungen

$$\text{Gewicht}_i(w) := \min \{ \text{Gewicht}_{i-1}(w - w_i) + g_i, \text{Gewicht}_{i-1}(w) \}.$$

# Bestimmung von $\text{Gewicht}_i(w)$

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.
  - ▶ Oder aber das  $i$ te Objekt wird nicht in den Rucksack gepackt und der Wert  $w$  ist mit Hilfe der ersten  $i - 1$  Objekte zu erbringen.
  - ▶ Wir erhalten die Rekursionsgleichungen

$$\text{Gewicht}_i(w) := \min \{ \text{Gewicht}_{i-1}(w - w_i) + g_i, \text{Gewicht}_{i-1}(w) \}.$$

- Sei  $W = \sum_{i=1}^n w_i$ .

# Bestimmung von $\text{Gewicht}_i(w)$

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.
  - ▶ Oder aber das  $i$ te Objekt wird nicht in den Rucksack gepackt und der Wert  $w$  ist mit Hilfe der ersten  $i - 1$  Objekte zu erbringen.
  - ▶ Wir erhalten die Rekursionsgleichungen

$$\text{Gewicht}_i(w) := \min \{ \text{Gewicht}_{i-1}(w - w_i) + g_i, \text{Gewicht}_{i-1}(w) \}.$$

- Sei  $W = \sum_{i=1}^n w_i$ . Wir bestimmen  $\text{Gewicht}_i(w)$  für alle  $w \leq W$ .

# Bestimmung von $\text{Gewicht}_i(w)$

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.
  - ▶ Oder aber das  $i$ te Objekt wird nicht in den Rucksack gepackt und der Wert  $w$  ist mit Hilfe der ersten  $i - 1$  Objekte zu erbringen.
  - ▶ Wir erhalten die Rekursionsgleichungen

$$\text{Gewicht}_i(w) := \min \{ \text{Gewicht}_{i-1}(w - w_i) + g_i, \text{Gewicht}_{i-1}(w) \}.$$

- Sei  $W = \sum_{i=1}^n w_i$ . Wir bestimmen  $\text{Gewicht}_i(w)$  für alle  $w \leq W$ .
  - ▶ Es gibt insgesamt  $n \cdot W$  Teilprobleme  $\text{Gewicht}_i(W)$ .

# Bestimmung von Gewicht $_i(w)$

- Wie kann das Gewicht minimiert werden, wenn Wert  $w$  zu erbringen ist?
  - ▶ Wenn das  $i$ te Objekt in den Rucksack gepackt wird, dann erhöht sich das Gewicht um  $g_i$  und der Restwert  $w - w_i$  ist von den ersten  $i - 1$  Objekten zu erbringen.
  - ▶ Oder aber das  $i$ te Objekt wird nicht in den Rucksack gepackt und der Wert  $w$  ist mit Hilfe der ersten  $i - 1$  Objekte zu erbringen.
  - ▶ Wir erhalten die Rekursionsgleichungen

$$\text{Gewicht}_i(w) := \min \{ \text{Gewicht}_{i-1}(w - w_i) + g_i, \text{Gewicht}_{i-1}(w) \}.$$

- Sei  $W = \sum_{i=1}^n w_i$ . Wir bestimmen Gewicht $_i(w)$  für alle  $w \leq W$ .
  - ▶ Es gibt insgesamt  $n \cdot W$  Teilprobleme Gewicht $_i(W)$ .
  - ▶ Da jedes Teilproblem in Zeit  $O(1)$  gelöst wird, erhalten wir die Laufzeit  $O(n \cdot W)$ .

## Schnelle Algorithmen bei kleinen Werten

Das Rucksackproblem für  $n$  Objekte und Wertesumme  $W = \sum_{i=1}^n w_i$  kann in Zeit  $O(n \cdot W)$  gelöst werden.

## Schnelle Algorithmen bei kleinen Werten

Das Rucksackproblem für  $n$  Objekte und Wertesumme  $W = \sum_{i=1}^n w_i$  kann in Zeit  $O(n \cdot W)$  gelöst werden.

- Problematisch sind Objekte mit sehr großen Werten.

## Schnelle Algorithmen bei kleinen Werten

Das Rucksackproblem für  $n$  Objekte und Wertesumme  $W = \sum_{i=1}^n w_i$  kann in Zeit  $O(n \cdot W)$  gelöst werden.

- Problematisch sind Objekte mit sehr großen Werten.
- Die Idee:

## Schnelle Algorithmen bei kleinen Werten

Das Rucksackproblem für  $n$  Objekte und Wertesumme  $W = \sum_{i=1}^n w_i$  kann in Zeit  $O(n \cdot W)$  gelöst werden.

- Problematisch sind Objekte mit sehr großen Werten.
- Die Idee:
  - ▶ Skalieren die Werte herunter.

## Schnelle Algorithmen bei kleinen Werten

Das Rucksackproblem für  $n$  Objekte und Wertesumme  $W = \sum_{i=1}^n w_i$  kann in Zeit  $O(n \cdot W)$  gelöst werden.

- Problematisch sind Objekte mit sehr großen Werten.
- Die Idee:
  - ▶ Skaliere die Werte herunter.
  - ▶ Löse das neue Rucksackproblem mit den jetzt kleinen Werten exakt.

## Schnelle Algorithmen bei kleinen Werten

Das Rucksackproblem für  $n$  Objekte und Wertesumme  $W = \sum_{i=1}^n w_i$  kann in Zeit  $O(n \cdot W)$  gelöst werden.

- Problematisch sind Objekte mit sehr großen Werten.
- Die Idee:
  - ▶ Skaliere die Werte herunter.
  - ▶ Löse das neue Rucksackproblem mit den jetzt kleinen Werten exakt.
- Wie gut ist die Approximation?

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot W_{\max}}{n}.$$

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot W_{\max}}{n}.$$

- (3) Berechne eine exakte Lösung für die neuen Werte  $(w_1^*, \dots, w_n^*)$ .

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot w_{\max}}{n}.$$

- (3) Berechne eine exakte Lösung für die neuen Werte  $(w_1^*, \dots, w_n^*)$ .
- (4) Bestimme für die nach neuen Werten ausgewählten Objekte den Gesamtwert  $\tilde{w}$  gemäß alter Werte und gib  $\max\{\tilde{w}, w_{\max}\}$  aus.

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot w_{\max}}{n}.$$

- (3) Berechne eine exakte Lösung für die neuen Werte  $(w_1^*, \dots, w_n^*)$ .
- (4) Bestimme für die nach neuen Werten ausgewählten Objekte den Gesamtwert  $\tilde{w}$  gemäß alter Werte und gib  $\max\{\tilde{w}, w_{\max}\}$  aus.  
// Wir erhalten den Wert  $w_{\max}$ , wenn wir nur das Objekt mit  
// maximalen Wert einpacken. ◀

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot w_{\max}}{n}.$$

- (3) Berechne eine exakte Lösung für die neuen Werte  $(w_1^*, \dots, w_n^*)$ .
- (4) Bestimme für die nach neuen Werten ausgewählten Objekte den Gesamtwert  $\tilde{w}$  gemäß alter Werte und gib  $\max\{\tilde{w}, w_{\max}\}$  aus.  
// Wir erhalten den Wert  $w_{\max}$ , wenn wir nur das Objekt mit  
// maximalen Wert einpacken. ◀

- Der größte neue Wert ist  $w_{\max}^* =$

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot w_{\max}}{n}.$$

- (3) Berechne eine exakte Lösung für die neuen Werte  $(w_1^*, \dots, w_n^*)$ .
- (4) Bestimme für die nach neuen Werten ausgewählten Objekte den Gesamtwert  $\tilde{w}$  gemäß alter Werte und gib  $\max\{\tilde{w}, w_{\max}\}$  aus.  
// Wir erhalten den Wert  $w_{\max}$ , wenn wir nur das Objekt mit  
// maximalen Wert einpacken. ◀

- Der größte neue Wert ist  $w_{\max}^* = \lfloor \frac{w_{\max}}{s} \rfloor =$

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot w_{\max}}{n}.$$

- (3) Berechne eine exakte Lösung für die neuen Werte  $(w_1^*, \dots, w_n^*)$ .
- (4) Bestimme für die nach neuen Werten ausgewählten Objekte den Gesamtwert  $\tilde{w}$  gemäß alter Werte und gib  $\max\{\tilde{w}, w_{\max}\}$  aus.  
// Wir erhalten den Wert  $w_{\max}$ , wenn wir nur das Objekt mit  
// maximalen Wert einpacken. ◀

- Der größte neue Wert ist  $w_{\max}^* = \lfloor \frac{w_{\max}}{s} \rfloor = \lfloor \frac{n}{\varepsilon} \rfloor$ .

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot w_{\max}}{n}.$$

- (3) Berechne eine exakte Lösung für die neuen Werte  $(w_1^*, \dots, w_n^*)$ .
- (4) Bestimme für die nach neuen Werten ausgewählten Objekte den Gesamtwert  $\tilde{w}$  gemäß alter Werte und gib  $\max\{\tilde{w}, w_{\max}\}$  aus.  
// Wir erhalten den Wert  $w_{\max}$ , wenn wir nur das Objekt mit  
// maximalen Wert einpacken. ◀

- Der größte neue Wert ist  $w_{\max}^* = \lfloor \frac{w_{\max}}{s} \rfloor = \lfloor \frac{n}{\varepsilon} \rfloor$ .
- Die Wertesumme der neuen Werte ist also höchstens  $O(\frac{n^2}{\varepsilon})$ .

# Der Approximationsalgorithmus

- (1) Der Approximationsfaktor  $1 + \varepsilon$  sei vorgegeben. Entferne alle Objekte, deren Gewicht die Gewichtsschranke  $G$  übersteigt.
- (2) Die Werte werden nach unten skaliert, nämlich setze

$$w_i^* = \lfloor \frac{w_i}{s} \rfloor \text{ für den Skalierungsfaktor } s = \frac{\varepsilon \cdot w_{\max}}{n}.$$

- (3) Berechne eine exakte Lösung für die neuen Werte  $(w_1^*, \dots, w_n^*)$ .
- (4) Bestimme für die nach neuen Werten ausgewählten Objekte den Gesamtwert  $\tilde{w}$  gemäß alter Werte und gib  $\max\{\tilde{w}, w_{\max}\}$  aus.  
// Wir erhalten den Wert  $w_{\max}$ , wenn wir nur das Objekt mit  
// maximalen Wert einpacken. ◀

- Der größte neue Wert ist  $w_{\max}^* = \lfloor \frac{w_{\max}}{s} \rfloor = \lfloor \frac{n}{\varepsilon} \rfloor$ .
- Die Wertesumme der neuen Werte ist also höchstens  $O(\frac{n^2}{\varepsilon})$ .
- Die Laufzeit ist also durch  $O(\frac{n^3}{\varepsilon})$  beschränkt.

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein.

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq$$

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq$$

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein.  
Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

denn  $B$  ist die beste Bepackung für die neuen Werte.

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

denn  $B$  ist die beste Bepackung für die neuen Werte. Also ist

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B} w_i .$$

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

denn  $B$  ist die beste Bepackung für die neuen Werte. Also ist

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B} w_i .$$

- Es ist  $s \cdot n =$

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

denn  $B$  ist die beste Bepackung für die neuen Werte. Also ist

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B} w_i .$$

- Es ist  $s \cdot n = \frac{\varepsilon \cdot w_{\text{max}}}{n} \cdot n =$

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

denn  $B$  ist die beste Bepackung für die neuen Werte. Also ist

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B} w_i .$$

- Es ist  $s \cdot n = \frac{\varepsilon \cdot w_{\text{max}}}{n} \cdot n = \varepsilon \cdot w_{\text{max}}$ .

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

denn  $B$  ist die beste Bepackung für die neuen Werte. Also ist

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B} w_i .$$

- Es ist  $s \cdot n = \frac{\varepsilon \cdot w_{\text{max}}}{n} \cdot n = \varepsilon \cdot w_{\text{max}}$ . Wenn  $w_{\text{max}} \leq \sum_{i \in B} w_i$ , dann

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

denn  $B$  ist die beste Bepackung für die neuen Werte. Also ist

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B} w_i .$$

- Es ist  $s \cdot n = \frac{\varepsilon \cdot w_{\text{max}}}{n} \cdot n = \varepsilon \cdot w_{\text{max}}$ . Wenn  $w_{\text{max}} \leq \sum_{i \in B} w_i$ , dann

$$\sum_{i \in B_{\text{opt}}} w_i \leq \varepsilon \cdot w_{\text{max}} + \sum_{i \in B} w_i$$

# Wie gut ist die Approximation?

Der Skalierungsalgorithmus ist  $(1 + \varepsilon)$ -approximativ mit Laufzeit  $O(\frac{1}{\varepsilon} \cdot n^3)$ .

- Angenommen, die optimale Bepackung für die **neuen** Werte packt genau die Objekte in der Menge  $B \subseteq \{1, \dots, n\}$  ein. Sei  $B_{\text{opt}}$  die optimale Bepackung für die **alten** Werte.

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B_{\text{opt}}} s \cdot \lfloor \frac{w_i}{s} \rfloor \leq sn + \sum_{i \in B} s \cdot \lfloor \frac{w_i}{s} \rfloor$$

denn  $B$  ist die beste Bepackung für die neuen Werte. Also ist

$$\sum_{i \in B_{\text{opt}}} w_i \leq sn + \sum_{i \in B} w_i .$$

- Es ist  $s \cdot n = \frac{\varepsilon \cdot w_{\text{max}}}{n} \cdot n = \varepsilon \cdot w_{\text{max}}$ . Wenn  $w_{\text{max}} \leq \sum_{i \in B} w_i$ , dann

$$\sum_{i \in B_{\text{opt}}} w_i \leq \varepsilon \cdot w_{\text{max}} + \sum_{i \in B} w_i \leq (1 + \varepsilon) \cdot \sum_{i \in B} w_i .$$

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.
- Jetzt gibt der Skalierungsalgorithmus den Wert  $w_{\max}$  aus. 

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.
- Jetzt gibt der Skalierungsalgorithmus den Wert  $w_{\max}$  aus.  Wie gut ist diese Bepackung im Vergleich zur optimalen Bepackung?

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.
- Jetzt gibt der Skalierungsalgorithmus den Wert  $w_{\max}$  aus. ▶ Wie gut ist diese Bepackung im Vergleich zur optimalen Bepackung?

$$\sum_{i \in B_{\text{opt}}} w_i \leq \varepsilon \cdot w_{\max} + \sum_{i \in B} w_i$$

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.
- Jetzt gibt der Skalierungsalgorithmus den Wert  $w_{\max}$  aus. ▶ Wie gut ist diese Bepackung im Vergleich zur optimalen Bepackung?

$$\sum_{i \in B_{\text{opt}}} w_i \leq \varepsilon \cdot w_{\max} + \sum_{i \in B} w_i \leq \varepsilon \cdot w_{\max} + w_{\max}$$

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.
- Jetzt gibt der Skalierungsalgorithmus den Wert  $w_{\max}$  aus. ▶ Wie gut ist diese Bepackung im Vergleich zur optimalen Bepackung?

$$\sum_{i \in B_{\text{opt}}} w_i \leq \varepsilon \cdot w_{\max} + \sum_{i \in B} w_i \leq \varepsilon \cdot w_{\max} + w_{\max} = (1 + \varepsilon) \cdot w_{\max}.$$

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.
- Jetzt gibt der Skalierungsalgorithmus den Wert  $w_{\max}$  aus.  Wie gut ist diese Bepackung im Vergleich zur optimalen Bepackung?

$$\sum_{i \in B_{\text{opt}}} w_i \leq \varepsilon \cdot w_{\max} + \sum_{i \in B} w_i \leq \varepsilon \cdot w_{\max} + w_{\max} = (1 + \varepsilon) \cdot w_{\max}.$$

Wir haben also in Zeit  $O(\frac{1}{\varepsilon} \cdot n^3)$  einen  $(1 + \varepsilon)$ -approximativen Algorithmus erhalten.

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.
- Jetzt gibt der Skalierungsalgorithmus den Wert  $w_{\max}$  aus.  Wie gut ist diese Bepackung im Vergleich zur optimalen Bepackung?

$$\sum_{i \in B_{\text{opt}}} w_i \leq \varepsilon \cdot w_{\max} + \sum_{i \in B} w_i \leq \varepsilon \cdot w_{\max} + w_{\max} = (1 + \varepsilon) \cdot w_{\max}.$$

Wir haben also in Zeit  $O(\frac{1}{\varepsilon} \cdot n^3)$  einen  $(1 + \varepsilon)$ -approximativen Algorithmus erhalten. Wir müssen also nur moderat mit Laufzeit bezahlen, um eine gute Approximation zu erhalten.

# Und wenn der maximale Wert sehr groß ist?

- Wir müssen nur noch den Fall  $w_{\max} > \sum_{i \in B} w_i$  betrachten.
- Jetzt gibt der Skalierungsalgorithmus den Wert  $w_{\max}$  aus.  Wie gut ist diese Bepackung im Vergleich zur optimalen Bepackung?

$$\sum_{i \in B_{\text{opt}}} w_i \leq \varepsilon \cdot w_{\max} + \sum_{i \in B} w_i \leq \varepsilon \cdot w_{\max} + w_{\max} = (1 + \varepsilon) \cdot w_{\max}.$$

Wir haben also in Zeit  $O(\frac{1}{\varepsilon} \cdot n^3)$  einen  $(1 + \varepsilon)$ -approximativen Algorithmus erhalten. Wir müssen also nur moderat mit Laufzeit bezahlen, um eine gute Approximation zu erhalten.

Man sagt deshalb auch, dass unser Approximationsalgorithmus ein **volles Approximationsschema** ist.

Wenn die approximative Lösung nur 10 Prozent schlechter als das Optimum sein darf, dann braucht der gerade vorgestellte Algorithmus folgende Laufzeit:

- (1)  $\Theta(n^2)$
- (2)  $\Theta(n^3)$
- (3)  $\Theta(n^{3+1/10})$
- (4)  $\Theta(n^{10})$

Wenn die approximative Lösung nur 10 Prozent schlechter als das Optimum sein darf, dann braucht der gerade vorgestellte Algorithmus folgende Laufzeit:

- (1)  $\Theta(n^2)$
- (2)  $\Theta(n^3)$
- (3)  $\Theta(n^{3+1/10})$
- (4)  $\Theta(n^{10})$

Auflösung:

Wenn die approximative Lösung nur 10 Prozent schlechter als das Optimum sein darf, dann braucht der gerade vorgestellte Algorithmus folgende Laufzeit:

- (1)  $\Theta(n^2)$
- (2)  $\Theta(n^3)$
- (3)  $\Theta(n^{3+1/10})$
- (4)  $\Theta(n^{10})$

Auflösung: (2)  $\Theta(\frac{1}{\varepsilon} \cdot n^3)$  mit  $\varepsilon = 0.1$

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung,

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ ,

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.
- **Die Idee:**

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.
- **Die Idee:** Wir berechnen ein **nicht vergrößeres Matching  $M$**  und

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.
- **Die Idee:** Wir berechnen ein **nicht vergrößerbare** Matching  $M$  und definieren  $\tilde{U}$  als die Menge **aller** Endpunkte von Kanten aus  $M$ .

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.
- **Die Idee:** Wir berechnen ein **nicht vergrößerbares** Matching  $M$  und definieren  $\tilde{U}$  als die Menge **aller** Endpunkte von Kanten aus  $M$ .
  - ▶ Behauptung:  $\tilde{U}$  ist eine Überdeckung.

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.
- **Die Idee:** Wir berechnen ein **nicht vergrößerbare** Matching  $M$  und definieren  $\tilde{U}$  als die Menge **aller** Endpunkte von Kanten aus  $M$ .
  - ▶ Behauptung:  $\tilde{U}$  ist eine Überdeckung.
  - ▶ Warum?

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.
- **Die Idee:** Wir berechnen ein **nicht vergrößerbares** Matching  $M$  und definieren  $\tilde{U}$  als die Menge **aller** Endpunkte von Kanten aus  $M$ .
  - ▶ Behauptung:  $\tilde{U}$  ist eine Überdeckung.
  - ▶ Warum? Wenn die Kante  $e = \{u, v\}$  keinen Endpunkt in  $\tilde{U}$  besitzt, dann ist weder  $u$  noch  $v$  Endpunkt einer Kante aus  $M$ .

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.
- **Die Idee:** Wir berechnen ein **nicht vergrößerbares** Matching  $M$  und definieren  $\tilde{U}$  als die Menge **aller** Endpunkte von Kanten aus  $M$ .
  - ▶ Behauptung:  $\tilde{U}$  ist eine Überdeckung.
  - ▶ Warum? Wenn die Kante  $e = \{u, v\}$  keinen Endpunkt in  $\tilde{U}$  besitzt, dann ist weder  $u$  noch  $v$  Endpunkt einer Kante aus  $M$ . Also ist  $M \cup \{e\}$  ein größeres Matching.

# Das (ungewichtete) Vertex Cover Problem

Für einen ungerichteten Graphen  $G = (V, E)$  suchen wir eine kleinstmögliche Überdeckung, also eine Menge  $\tilde{U}$  von Knoten, so dass alle Kanten einen Endpunkt in  $\tilde{U}$  besitzen.

- Angenommen ein Matching  $M \subseteq E$ , also eine Menge von **knoten-disjunkten Kanten**, ist gegeben.  
Dann muss jede Überdeckung  $\tilde{U}$  für jede Kante in  $M$  einen Endpunkt enthalten und  $|\tilde{U}| \geq |M|$  folgt.
- **Die Idee:** Wir berechnen ein **nicht vergrößerbares** Matching  $M$  und definieren  $\tilde{U}$  als die Menge **aller** Endpunkte von Kanten aus  $M$ .
  - ▶ Behauptung:  $\tilde{U}$  ist eine Überdeckung.
  - ▶ Warum? Wenn die Kante  $e = \{u, v\}$  keinen Endpunkt in  $\tilde{U}$  besitzt, dann ist weder  $u$  noch  $v$  Endpunkt einer Kante aus  $M$ . Also ist  $M \cup \{e\}$  ein größeres Matching.
- Wie berechnet man ein nicht vergrößerbares Matching?

- (1) Die Eingabe besteht aus einem ungerichteten Graphen  $G = (V, E)$ . Setze  $M := \emptyset$ .

# Die Matching Heuristik

- (1) Die Eingabe besteht aus einem ungerichteten Graphen  $G = (V, E)$ . Setze  $M := \emptyset$ .
- (2) while ( $E \neq \emptyset$ )

# Die Matching Heuristik

- (1) Die Eingabe besteht aus einem ungerichteten Graphen  $G = (V, E)$ . Setze  $M := \emptyset$ .
- (2) while ( $E \neq \emptyset$ )
  - ▶ Wähle eine Kante  $e \in E$  und füge  $e$  zu  $M$  hinzu.

# Die Matching Heuristik

- (1) Die Eingabe besteht aus einem ungerichteten Graphen  $G = (V, E)$ . Setze  $M := \emptyset$ .
- (2) while ( $E \neq \emptyset$ )
  - ▶ Wähle eine Kante  $e \in E$  und füge  $e$  zu  $M$  hinzu.
  - ▶ **Entferne** alle Kanten aus  $E$ , die einen Endpunkt mit  $e$  gemeinsam haben.

# Die Matching Heuristik

- (1) Die Eingabe besteht aus einem ungerichteten Graphen  $G = (V, E)$ . Setze  $M := \emptyset$ .
- (2) while ( $E \neq \emptyset$ )
  - ▶ Wähle eine Kante  $e \in E$  und füge  $e$  zu  $M$  hinzu.
  - ▶ **Entferne** alle Kanten aus  $E$ , die einen Endpunkt mit  $e$  gemeinsam haben.
- (3) Gib die Knotenmenge  $\dot{U} = \{v \in V \mid v \text{ ist Endpunkt einer Kante in } M\}$  aus.

# Die Matching Heuristik

- (1) Die Eingabe besteht aus einem ungerichteten Graphen  $G = (V, E)$ . Setze  $M := \emptyset$ .
- (2) while ( $E \neq \emptyset$ )
  - ▶ Wähle eine Kante  $e \in E$  und füge  $e$  zu  $M$  hinzu.
  - ▶ **Entferne** alle Kanten aus  $E$ , die einen Endpunkt mit  $e$  gemeinsam haben.
- (3) Gib die Knotenmenge  $\dot{U} = \{v \in V \mid v \text{ ist Endpunkt einer Kante in } M\}$  aus.  
// Wir wissen bereits, dass  $\dot{U}$  eine Überdeckung ist.

# Die Matching Heuristik

- (1) Die Eingabe besteht aus einem ungerichteten Graphen  $G = (V, E)$ . Setze  $M := \emptyset$ .
- (2) while ( $E \neq \emptyset$ )
  - ▶ Wähle eine Kante  $e \in E$  und füge  $e$  zu  $M$  hinzu.
  - ▶ **Entferne** alle Kanten aus  $E$ , die einen Endpunkt mit  $e$  gemeinsam haben.
- (3) Gib die Knotenmenge  $\dot{U} = \{v \in V \mid v \text{ ist Endpunkt einer Kante in } M\}$  aus.  
// Wir wissen bereits, dass  $\dot{U}$  eine Überdeckung ist.  
// Desweiteren muss jede Überdeckung mindestens  $|M| \geq |\dot{U}|/2$   
// Knoten besitzen.

# Die Matching Heuristik

- (1) Die Eingabe besteht aus einem ungerichteten Graphen  $G = (V, E)$ . Setze  $M := \emptyset$ .
- (2) while ( $E \neq \emptyset$ )
  - ▶ Wähle eine Kante  $e \in E$  und füge  $e$  zu  $M$  hinzu.
  - ▶ **Entferne** alle Kanten aus  $E$ , die einen Endpunkt mit  $e$  gemeinsam haben.
- (3) Gib die Knotenmenge  $\dot{U} = \{v \in V \mid v \text{ ist Endpunkt einer Kante in } M\}$  aus.  
// Wir wissen bereits, dass  $\dot{U}$  eine Überdeckung ist.  
// Desweiteren muss jede Überdeckung mindestens  $|M| \geq |\dot{U}|/2$   
// Knoten besitzen.

Die Matching Heuristik ist ein 2-Approximationsalgorithmus für VC.

Welche Laufzeit hat die Matching-Heuristik?

- (1)  $\Theta(n + m)$
- (2)  $\Theta(n \log n + m)$
- (3)  $\Theta((n + m) \log n)$
- (4)  $\Theta((n + m)^2)$

Welche Laufzeit hat die Matching-Heuristik?

- (1)  $\Theta(n + m)$
- (2)  $\Theta(n \log n + m)$
- (3)  $\Theta((n + m) \log n)$
- (4)  $\Theta((n + m)^2)$

Auflösung:

Welche Laufzeit hat die Matching-Heuristik?

- (1)  $\Theta(n + m)$
- (2)  $\Theta(n \log n + m)$
- (3)  $\Theta((n + m) \log n)$
- (4)  $\Theta((n + m)^2)$

Auflösung: (1), arbeite mit Adjazenzlisten.

# Besitzt die Matching Heuristik vielleicht bessere Approximationsfaktoren als 2?

Betrachte den vollständigen bipartiten Graphen mit  $n$  Knoten „auf jeder Seite“.

# Besitzt die Matching Heuristik vielleicht bessere Approximationsfaktoren als 2?

Betrachte den vollständigen bipartiten Graphen mit  $n$  Knoten „auf jeder Seite“.

- Eine optimale Überdeckung wählt die  $n$  Knoten einer Seite aus.

# Besitzt die Matching Heuristik vielleicht bessere Approximationsfaktoren als 2?

Betrachte den vollständigen bipartiten Graphen mit  $n$  Knoten „auf jeder Seite“.

- Eine optimale Überdeckung wählt die  $n$  Knoten einer Seite aus.
- Jedes nicht vergrößerbare Matching besteht aus  $n$  Kanten, weil

# Besitzt die Matching Heuristik vielleicht bessere Approximationsfaktoren als 2?

Betrachte den vollständigen bipartiten Graphen mit  $n$  Knoten „auf jeder Seite“.

- Eine optimale Überdeckung wählt die  $n$  Knoten einer Seite aus.
- Jedes nicht vergrößerbare Matching besteht aus  $n$  Kanten, weil sonst mindestens ein Endpunkt auf jeder Seite frei bleibt.

# Besitzt die Matching Heuristik vielleicht bessere Approximationsfaktoren als 2?

Betrachte den vollständigen bipartiten Graphen mit  $n$  Knoten „auf jeder Seite“.

- Eine optimale Überdeckung wählt die  $n$  Knoten einer Seite aus.
- Jedes nicht vergrößerbare Matching besteht aus  $n$  Kanten, weil sonst mindestens ein Endpunkt auf jeder Seite frei bleibt.
- Damit wählt die Matching Heuristik alle  $2n$  Knoten als Überdeckung.

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ .

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung.

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

$$\text{minimiere } \sum_{v \in V} w_v \cdot x_v$$

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

$$\text{minimiere } \sum_{v \in V} w_v \cdot x_v \quad \text{so dass } x_u + x_v \geq 1 \text{ für alle } \{u, v\} \in E$$

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

$$\text{minimiere } \sum_{v \in V} w_v \cdot x_v \quad \text{so dass } x_u + x_v \geq 1 \text{ für alle } \{u, v\} \in E$$
$$\text{und } x_u \geq 0 \text{ für alle } u \in V.$$

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

$$\text{minimiere } \sum_{v \in V} w_v \cdot x_v \quad \text{so dass } x_u + x_v \geq 1 \text{ für alle } \{u, v\} \in E$$
$$\text{und } x_u \geq 0 \text{ für alle } u \in V.$$

- Wenn  $U \subseteq \{1, \dots, n\}$  eine Überdeckung ist, dann ist der Inzidenzvektor  $x_U$  von  $U$  eine Lösung.

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

$$\text{minimiere } \sum_{v \in V} w_v \cdot x_v \quad \text{so dass } x_u + x_v \geq 1 \text{ für alle } \{u, v\} \in E$$
$$\text{und } x_u \geq 0 \text{ für alle } u \in V.$$

- Wenn  $U \subseteq \{1, \dots, n\}$  eine Überdeckung ist, dann ist der Inzidenzvektor  $x_U$  von  $U$  eine Lösung. Aber es gibt unerwünschte fraktionale Lösungen.

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

$$\text{minimiere } \sum_{v \in V} w_v \cdot x_v \quad \text{so dass } x_u + x_v \geq 1 \text{ für alle } \{u, v\} \in E$$
$$\text{und } x_u \geq 0 \text{ für alle } u \in V.$$

- Wenn  $U \subseteq \{1, \dots, n\}$  eine Überdeckung ist, dann ist der Inzidenzvektor  $x_U$  von  $U$  eine Lösung. Aber es gibt unerwünschte fraktionale Lösungen.
  - ▶ Jede Überdeckung für den vollständigen Graphen (mit Gewichten  $w_v = 1$ )

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

$$\text{minimiere } \sum_{v \in V} w_v \cdot x_v \quad \text{so dass } x_u + x_v \geq 1 \text{ für alle } \{u, v\} \in E$$
$$\text{und } x_u \geq 0 \text{ für alle } u \in V.$$

- Wenn  $U \subseteq \{1, \dots, n\}$  eine Überdeckung ist, dann ist der Inzidenzvektor  $x_U$  von  $U$  eine Lösung. Aber es gibt unerwünschte fraktionale Lösungen.
  - ▶ Jede Überdeckung für den vollständigen Graphen (mit Gewichten  $w_v = 1$ ) benötigt mindestens  $n - 1$  Knoten, aber

# Das gewichtete Vertex Cover Problem

Jeder Knoten  $v$  des Graphen  $G = (\{1, \dots, n\}, E)$  erhält das Gewicht  $w_v$ . Gesucht ist eine Überdeckung mit **minimalem Gewicht**.

- Wir benutzen die lineare Programmierung. Das gewichtete Vertex Cover Problem kann wie folgt formuliert werden:

$$\text{minimiere } \sum_{v \in V} w_v \cdot x_v \quad \text{so dass } x_u + x_v \geq 1 \text{ für alle } \{u, v\} \in E$$
$$\text{und } x_u \geq 0 \text{ für alle } u \in V.$$

- Wenn  $U \subseteq \{1, \dots, n\}$  eine Überdeckung ist, dann ist der Inzidenzvektor  $x_U$  von  $U$  eine Lösung. Aber es gibt unerwünschte fraktionale Lösungen.
  - ▶ Jede Überdeckung für den vollständigen Graphen (mit Gewichten  $w_v = 1$ ) benötigt mindestens  $n - 1$  Knoten, aber
  - ▶ das lineare Programm hat die fraktionale Lösung  $x = (\frac{1}{2}, \dots, \frac{1}{2})$  mit Zielwert  $n/2$ .

- **Unser Approximationsalgorithmus:**

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ ,

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\tilde{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\tilde{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\tilde{U}$  ist tatsächlich eine Überdeckung,

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\tilde{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\tilde{U}$  ist tatsächlich eine Überdeckung, denn für jede Kante  $\{u, v\}$  von  $G$  ist  $x_u^* + x_v^* \geq 1$ .

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\ddot{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\ddot{U}$  ist tatsächlich eine Überdeckung, denn für jede Kante  $\{u, v\}$  von  $G$  ist  $x_u^* + x_v^* \geq 1$ . Also ist  $x_u^* \geq \frac{1}{2}$  oder  $x_v^* \geq \frac{1}{2}$ .

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\ddot{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\ddot{U}$  ist tatsächlich eine Überdeckung, denn für jede Kante  $\{u, v\}$  von  $G$  ist  $x_u^* + x_v^* \geq 1$ . Also ist  $x_u^* \geq \frac{1}{2}$  oder  $x_v^* \geq \frac{1}{2}$ .  
 $u \in \ddot{U}$  oder  $v \in \ddot{U}$  folgt.

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\ddot{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\ddot{U}$  ist tatsächlich eine Überdeckung, denn für jede Kante  $\{u, v\}$  von  $G$  ist  $x_u^* + x_v^* \geq 1$ . Also ist  $x_u^* \geq \frac{1}{2}$  oder  $x_v^* \geq \frac{1}{2}$ .  
 $u \in \ddot{U}$  oder  $v \in \ddot{U}$  folgt.
- Wie gut ist die Approximation?

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\tilde{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\tilde{U}$  ist tatsächlich eine Überdeckung, denn für jede Kante  $\{u, v\}$  von  $G$  ist  $x_u^* + x_v^* \geq 1$ . Also ist  $x_u^* \geq \frac{1}{2}$  oder  $x_v^* \geq \frac{1}{2}$ .  
 $u \in \tilde{U}$  oder  $v \in \tilde{U}$  folgt.
- Wie gut ist die Approximation?  
Wenn  $\text{opt} = \sum_{v=1}^n w_v \cdot x_v^*$ , dann hat jede Überdeckung mindestens die Größe  $\text{opt}$ .

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\tilde{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\tilde{U}$  ist tatsächlich eine Überdeckung, denn für jede Kante  $\{u, v\}$  von  $G$  ist  $x_u^* + x_v^* \geq 1$ . Also ist  $x_u^* \geq \frac{1}{2}$  oder  $x_v^* \geq \frac{1}{2}$ .  
 $u \in \tilde{U}$  oder  $v \in \tilde{U}$  folgt.
- Wie gut ist die Approximation?  
Wenn  $\text{opt} = \sum_{v=1}^n w_v \cdot x_v^*$ , dann hat jede Überdeckung mindestens die Größe  $\text{opt}$ . Also folgt

$$\sum_{v \in \tilde{U}} w_v \leq \sum_{v \in V} w_v \cdot (2x_v^*) =$$

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\tilde{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\tilde{U}$  ist tatsächlich eine Überdeckung, denn für jede Kante  $\{u, v\}$  von  $G$  ist  $x_u^* + x_v^* \geq 1$ . Also ist  $x_u^* \geq \frac{1}{2}$  oder  $x_v^* \geq \frac{1}{2}$ .  
 $u \in \tilde{U}$  oder  $v \in \tilde{U}$  folgt.
- Wie gut ist die Approximation?  
Wenn  $\text{opt} = \sum_{v=1}^n w_v \cdot x_v^*$ , dann hat jede Überdeckung mindestens die Größe  $\text{opt}$ . Also folgt

$$\sum_{v \in \tilde{U}} w_v \leq \sum_{v \in V} w_v \cdot (2x_v^*) = 2 \cdot \sum_{v \in V} w_v \cdot x_v^* =$$

- **Unser Approximationsalgorithmus:**

- (1) Bestimme eine optimale Lösung  $x^*$  des linearen Programms.
- (2) Runde die im Allgemeinen fraktionale Lösung  $x^*$ , nämlich setze

$$\tilde{U} = \{v \in V \mid x_v^* \geq \frac{1}{2}\}.$$

- $\tilde{U}$  ist tatsächlich eine Überdeckung, denn für jede Kante  $\{u, v\}$  von  $G$  ist  $x_u^* + x_v^* \geq 1$ . Also ist  $x_u^* \geq \frac{1}{2}$  oder  $x_v^* \geq \frac{1}{2}$ .  $u \in \tilde{U}$  oder  $v \in \tilde{U}$  folgt.
- Wie gut ist die Approximation?  
Wenn  $\text{opt} = \sum_{v=1}^n w_v \cdot x_v^*$ , dann hat jede Überdeckung mindestens die Größe  $\text{opt}$ . Also folgt

$$\sum_{v \in \tilde{U}} w_v \leq \sum_{v \in V} w_v \cdot (2x_v^*) = 2 \cdot \sum_{v \in V} w_v \cdot x_v^* = 2 \cdot \text{opt}$$

## Die Rundung fraktionaler Lösungen

Nach Rundung erhalten wir eine 2-approximative Lösung für das gewichtete Vertex-Cover Problem.

## Die Rundung fraktionaler Lösungen

Nach Rundung erhalten wir eine 2-approximative Lösung für das gewichtete Vertex-Cover Problem.

- Wir haben verschiedene, für Optimierungsprobleme wichtige Entwurfsmethoden eingesetzt.

## Die Rundung fraktionaler Lösungen

Nach Rundung erhalten wir eine 2-approximative Lösung für das gewichtete Vertex-Cover Problem.

- Wir haben verschiedene, für Optimierungsprobleme wichtige Entwurfsmethoden eingesetzt.
  - ▶ In der Lastverteilung haben wir mit [Greedy Algorithmen](#) gearbeitet.

## Die Rundung fraktionaler Lösungen

Nach Rundung erhalten wir eine 2-approximative Lösung für das gewichtete Vertex-Cover Problem.

- Wir haben verschiedene, für Optimierungsprobleme wichtige Entwurfsmethoden eingesetzt.
  - ▶ In der Lastverteilung haben wir mit **Greedy Algorithmen** gearbeitet.
  - ▶ Für das Rucksackproblem haben wir die **dynamische Programmierung** und

## Die Rundung fraktionaler Lösungen

Nach Rundung erhalten wir eine 2-approximative Lösung für das gewichtete Vertex-Cover Problem.

- Wir haben verschiedene, für Optimierungsprobleme wichtige Entwurfsmethoden eingesetzt.
  - ▶ In der Lastverteilung haben wir mit **Greedy Algorithmen** gearbeitet.
  - ▶ Für das Rucksackproblem haben wir die **dynamische Programmierung** und
  - ▶ für das gewichtete Vertex Cover Problem die **lineare Programmierung** eingesetzt.