

# Algorithmen II

## Vorlesung am 28.11.2013

Randomisierte Algorithmen – Max Cut

INSTITUT FÜR THEORETISCHE INFORMATIK · PROF. DR. DOROTHEA WAGNER

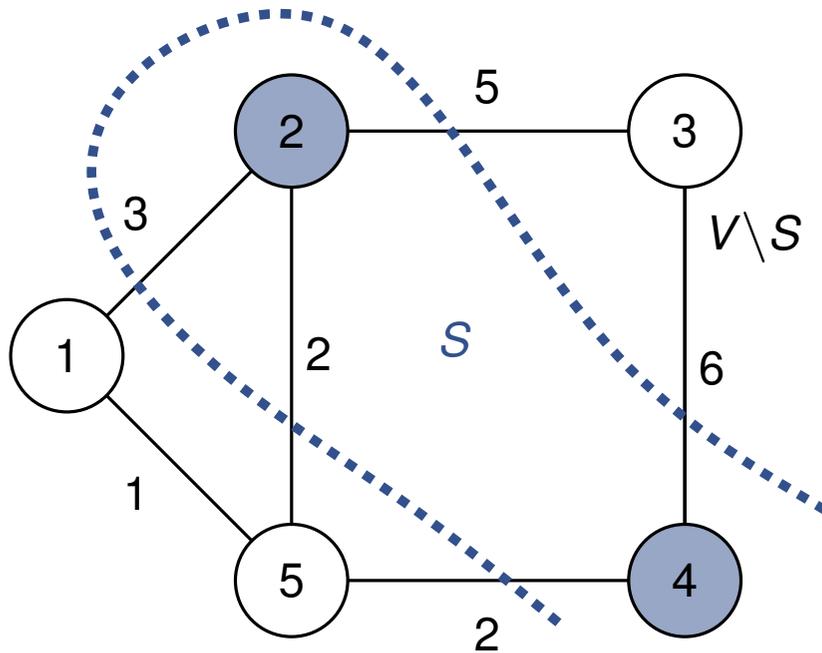


# Problemdefinition

**Problem MAXCUT:** Gegeben ist ein Graph  $G = (V, E)$  mit Gewichtsfunktion  $c: E \rightarrow \mathbb{N}$ .  
Gesucht ist ein Schnitt  $(S, V \setminus S)$  von  $G$  mit maximalem Gewicht, d.h.

$$c(S, V \setminus S) := \sum_{\substack{u, v \in E \\ u \in S \text{ und } v \in V \setminus S}} c(\{u, v\}) \quad \text{soll maximal sein.}$$

Problem ist  $\mathcal{NP}$ -schwer.



$$c(S, V \setminus S) = 18$$

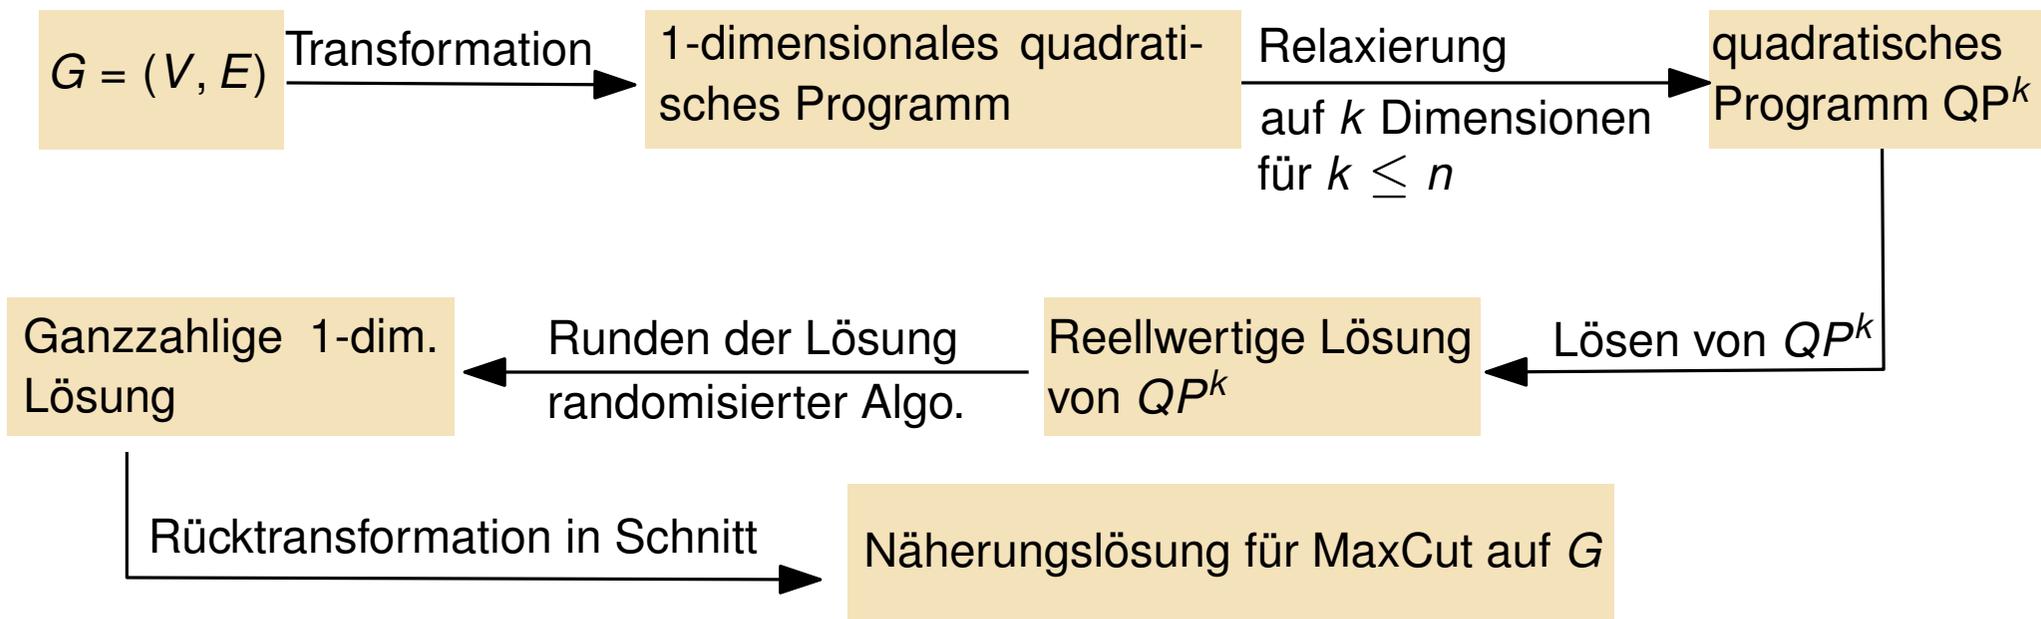
# Problemdefinition

**Problem MAXCUT:** Gegeben ist ein Graph  $G = (V, E)$  mit Gewichtsfunktion  $c: E \rightarrow \mathbb{N}$ .  
Gesucht ist ein Schnitt  $(S, V \setminus S)$  von  $G$  mit maximalem Gewicht, d.h.

$$c(S, V \setminus S) := \sum_{\substack{u, v \in E \\ u \in S \text{ und } v \in V \setminus S}} c(\{u, v\}) \quad \text{soll maximal sein.}$$

Problem ist  $\mathcal{NP}$ -schwer.

**Idee:** Berechne Lösung, die annähernd so gut ist, wie die optimale Lösung.



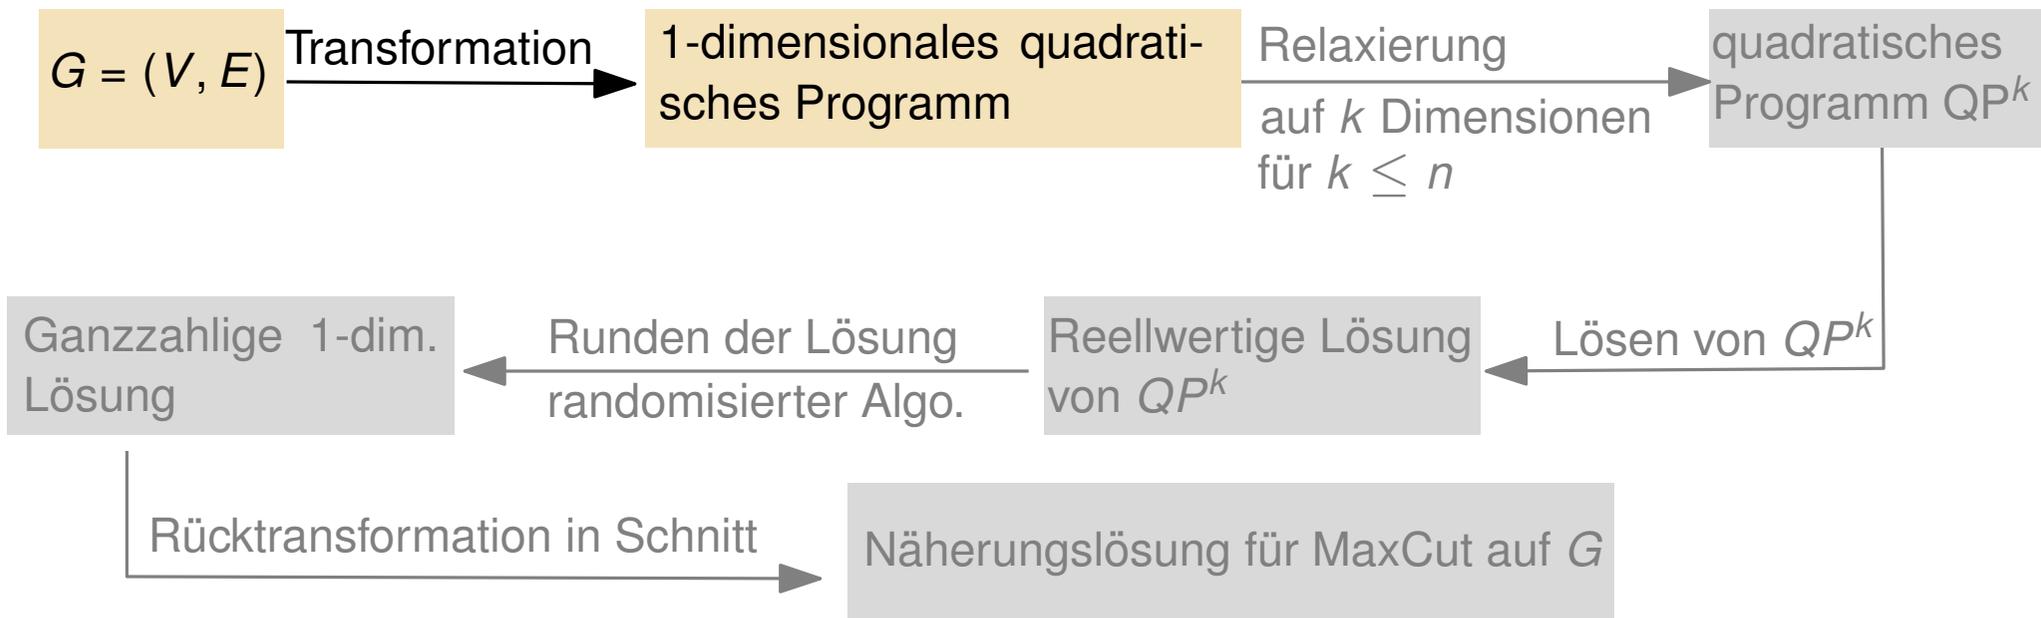
# Problemdefinition

**Problem MAXCUT:** Gegeben ist ein Graph  $G = (V, E)$  mit Gewichtsfunktion  $c: E \rightarrow \mathbb{N}$ .  
Gesucht ist ein Schnitt  $(S, V \setminus S)$  von  $G$  mit maximalem Gewicht, d.h.

$$c(S, V \setminus S) := \sum_{\substack{u, v \in E \\ u \in S \text{ und } v \in V \setminus S}} c(\{u, v\}) \quad \text{soll maximal sein.}$$

Problem ist  $\mathcal{NP}$ -schwer.

**Idee:** Berechne Lösung, die annähernd so gut ist, wie die optimale Lösung.



# 1-Dimensionales Quadratisches Programm

Zu  $i$  und  $j \in V := \{1, \dots, n\}$  definiere  $c_{ij} := \begin{cases} c(\{i, j\}) & \text{falls } \{i, j\} \in E \\ 0 & \text{sonst} \end{cases}$

**QP(I):**

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter den Nebenbedingungen:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

**Idee:**

Jede Variable  $x_i$  steht für einen Knoten. Es gilt:  $x_i \in \{1, -1\}$

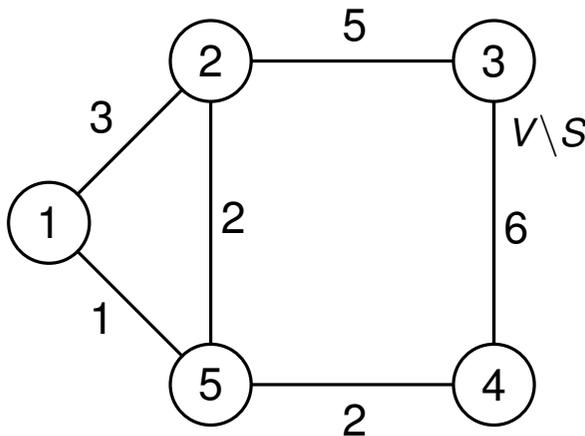
**Es gilt für zwei Knoten  $i$  und  $j$ :**

$x_i = x_j$  Knoten in der selben Partition.

$x_i = -x_j$  Knoten in unterschiedlichen Partitionen.

$$c_{ij} \cdot (1 - x_i \cdot x_j) = \begin{cases} 2 & , \text{wenn } x_i = -x_j \\ 0 & , \text{wenn } x_i = x_j \end{cases}$$

$\Rightarrow c_{ij}$  geht nur in Zielfunktion ein, wenn  $\{i, j\} \in E$  und Knoten befinden sich in unterschiedlichen Partitionen.



# 1-Dimensionales Quadratisches Programm

Zu  $i$  und  $j \in V := \{1, \dots, n\}$  definiere  $c_{ij} := \begin{cases} c(\{i, j\}) & \text{falls } \{i, j\} \in E \\ 0 & \text{sonst} \end{cases}$

**QP(I):**

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter den Nebenbedingungen:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

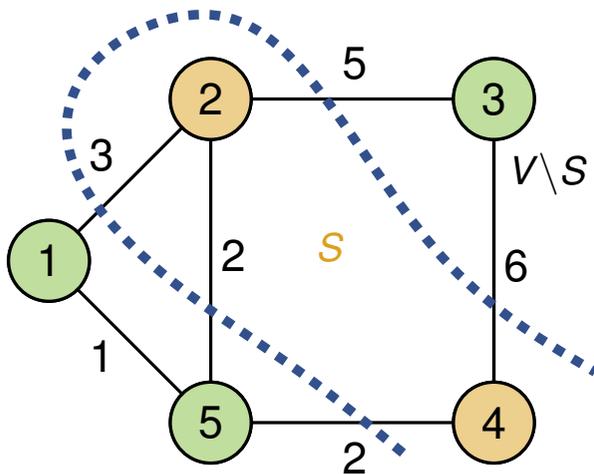
**Gewichtungsmatrix:  $c_{ij}$**

	1	2	3	4	5
1					1
2	3		5		2
3		5	6		
4			6		2
5	1	2		2	

**Lösung:**

$$x_2 = x_4 = 1$$

$$x_1 = x_5 = x_3 = -1$$



# 1-Dimensionales Quadratisches Programm

Zu  $i$  und  $j \in V := \{1, \dots, n\}$  definiere  $c_{ij} := \begin{cases} c(\{i, j\}) & \text{falls } \{i, j\} \in E \\ 0 & \text{sonst} \end{cases}$

**QP(I):**

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter den Nebenbedingungen:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

**Gewichtungsmatrix:  $c_{ij}$**

	1	2	3	4	5
1					1
2	3		5		2
3		5	6		
4			6		2
5	1	2		2	

**Lösung:**

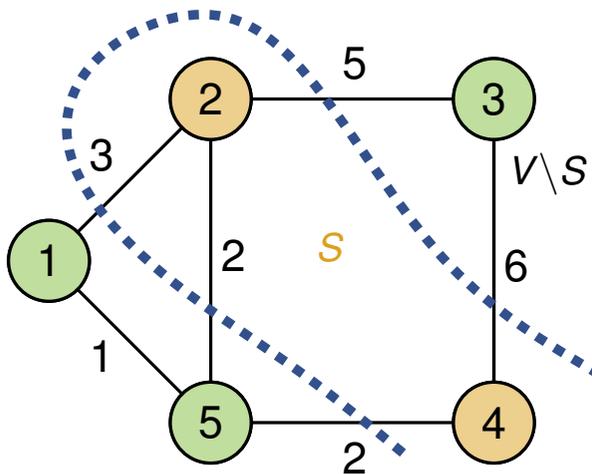
$$x_2 = x_4 = 1$$

$$x_1 = x_5 = x_3 = -1$$

**Problem:**

Lösen von QP(I) ist  $\mathcal{NP}$ -schwer.

Ansonsten wäre MAXCUT nicht  $\mathcal{NP}$ -schwer.



# 1-Dimensionales Quadratisches Programm

Zu  $i$  und  $j \in V := \{1, \dots, n\}$  definiere  $c_{ij} := \begin{cases} c(\{i, j\}) & \text{falls } \{i, j\} \in E \\ 0 & \text{sonst} \end{cases}$

**QP(I):**

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - \underline{x_i \cdot x_j})$$

unter den Nebenbedingungen:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

**Gewichtungsmatrix:  $c_{ij}$**

	1	2	3	4	5
1					1
2	3		5		2
3		5	6		
4			6		2
5	1	2		2	

**Beachte:**

$x_i$  und  $x_j$  sind 1-dimensionale Vektoren.

**Lösung:**

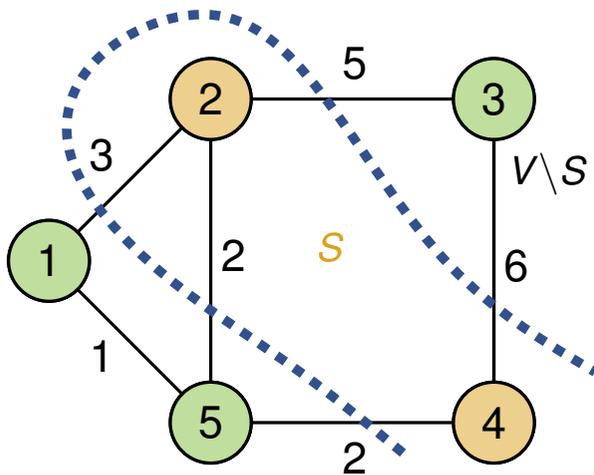
$$x_2 = x_4 = 1$$

$$x_1 = x_5 = x_3 = -1$$

**Problem:**

Lösen von QP(I) ist  $\mathcal{NP}$ -schwer.

Ansonsten wäre MAXCUT nicht  $\mathcal{NP}$ -schwer.

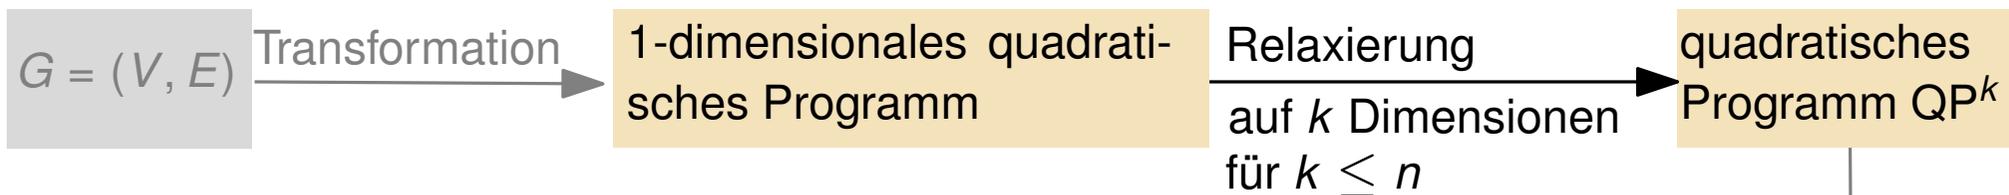


**Problem MAXCUT:** Gegeben ist ein Graph  $G = (V, E)$  mit Gewichtsfunktion  $c: E \rightarrow \mathbb{N}$ .  
Gesucht ist ein Schnitt  $(S, V \setminus S)$  von  $G$  mit maximalem Gewicht, d.h.

$$c(S, V \setminus S) := \sum_{\substack{u, v \in E \\ u \in S \text{ und } v \in V \setminus S}} c(\{u, v\}) \quad \text{soll maximal sein.}$$

Problem ist  $\mathcal{NP}$ -schwer.

**Idee:** Berechne Lösung, die annähernd so gut ist, wie die optimale Lösung.



Betrachte den Fall  $k = 2$ .

**Vorteil:** Prinzip leichter ersichtlich.

**Nachteil:** Nicht bekannt ob  $QP^2$  optimal in poly. Zeit gelöst werden kann.

Entsprechendes  $QP^n$  kann in poly. Zeit gelöst werden (später).

Ganzzahlige 1-d  
Lösung

von  $QP^k$

Rücktransfo

# Relaxierung von IQP(I)

**QP<sup>2</sup>(I)**: Sei  $x^i = (x_1^i, x_2^i) \in \mathbb{R}^2$  normierter Vektor.

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter den Nebenbedingungen  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren

# Relaxierung von IQP(I)

**QP<sup>2</sup>(I)**: Sei  $x^i = (x_1^i, x_2^i) \in \mathbb{R}^2$  normierter Vektor.

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter den Nebenbedingungen  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren

Für das Produkt von  $x^i$  und  $x^j$  gilt:  $x^i \cdot x^j = x_1^i \cdot x_1^j + x_2^i \cdot x_2^j = \cos(\alpha_{ij})$  mit  $0 \leq \alpha_{ij} \leq \pi$

Damit wird  $\frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - \cos(\alpha_{ij}))$  über Winkel  $\alpha_{ij}$  maximiert.

# Relaxierung von IQP(I)

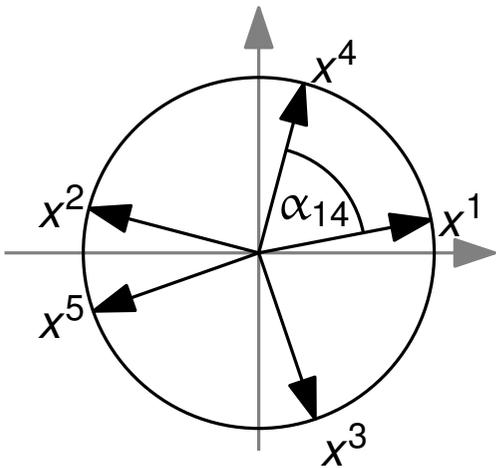
**QP<sup>2</sup>(I):** Sei  $x^i = (x_1^i, x_2^i) \in \mathbb{R}^2$  normierter Vektor.

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter den Nebenbedingungen  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren

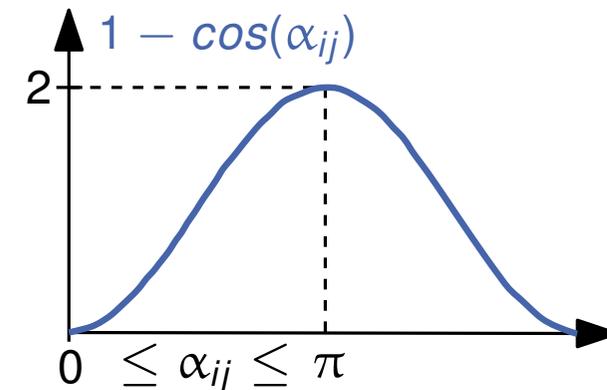
Für das Produkt von  $x^i$  und  $x^j$  gilt:  $x^i \cdot x^j = x_1^i \cdot x_1^j + x_2^i \cdot x_2^j = \cos(\alpha_{ij})$  mit  $0 \leq \alpha_{ij} \leq \pi$

Damit wird  $\frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - \cos(\alpha_{ij}))$  über Winkel  $\alpha_{ij}$  maximiert.



## Beobachtung:

Je größer der Winkel  $\alpha_{ij}$  zwischen  $x_i$  und  $x_j$  ist, umso mehr trägt  $c_{ij}$  zur Summe bei.



# Relaxierung von IQP(I)

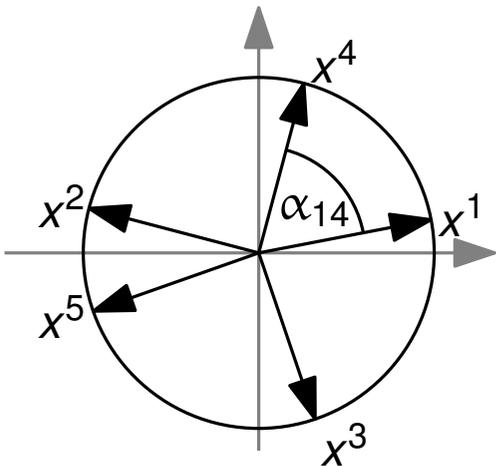
**QP<sup>2</sup>(I):** Sei  $x^i = (x_1^i, x_2^i) \in \mathbb{R}^2$  normierter Vektor.

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter den Nebenbedingungen  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren

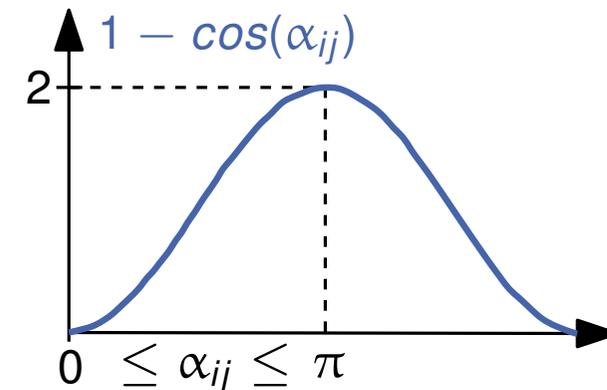
Für das Produkt von  $x^i$  und  $x^j$  gilt:  $x^i \cdot x^j = x_1^i \cdot x_1^j + x_2^i \cdot x_2^j = \cos(\alpha_{ij})$  mit  $0 \leq \alpha_{ij} \leq \pi$

Damit wird  $\frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - \cos(\alpha_{ij}))$  über Winkel  $\alpha_{ij}$  maximiert.



## Beobachtung:

Je größer der Winkel  $\alpha_{ij}$  zwischen  $x_i$  und  $x_j$  ist, umso mehr trägt  $c_{ij}$  zur Summe bei.



Lösung  $(x_1, \dots, x_n)$  von QP(I) induziert Lösung  $(x^1, \dots, x^n)$  von QP<sup>2</sup>(I) mittels  $x^i = (x_i, 0)$ .  
 $\Rightarrow$  **QP<sup>2</sup>(I) ist Relaxierung von QP(I)**

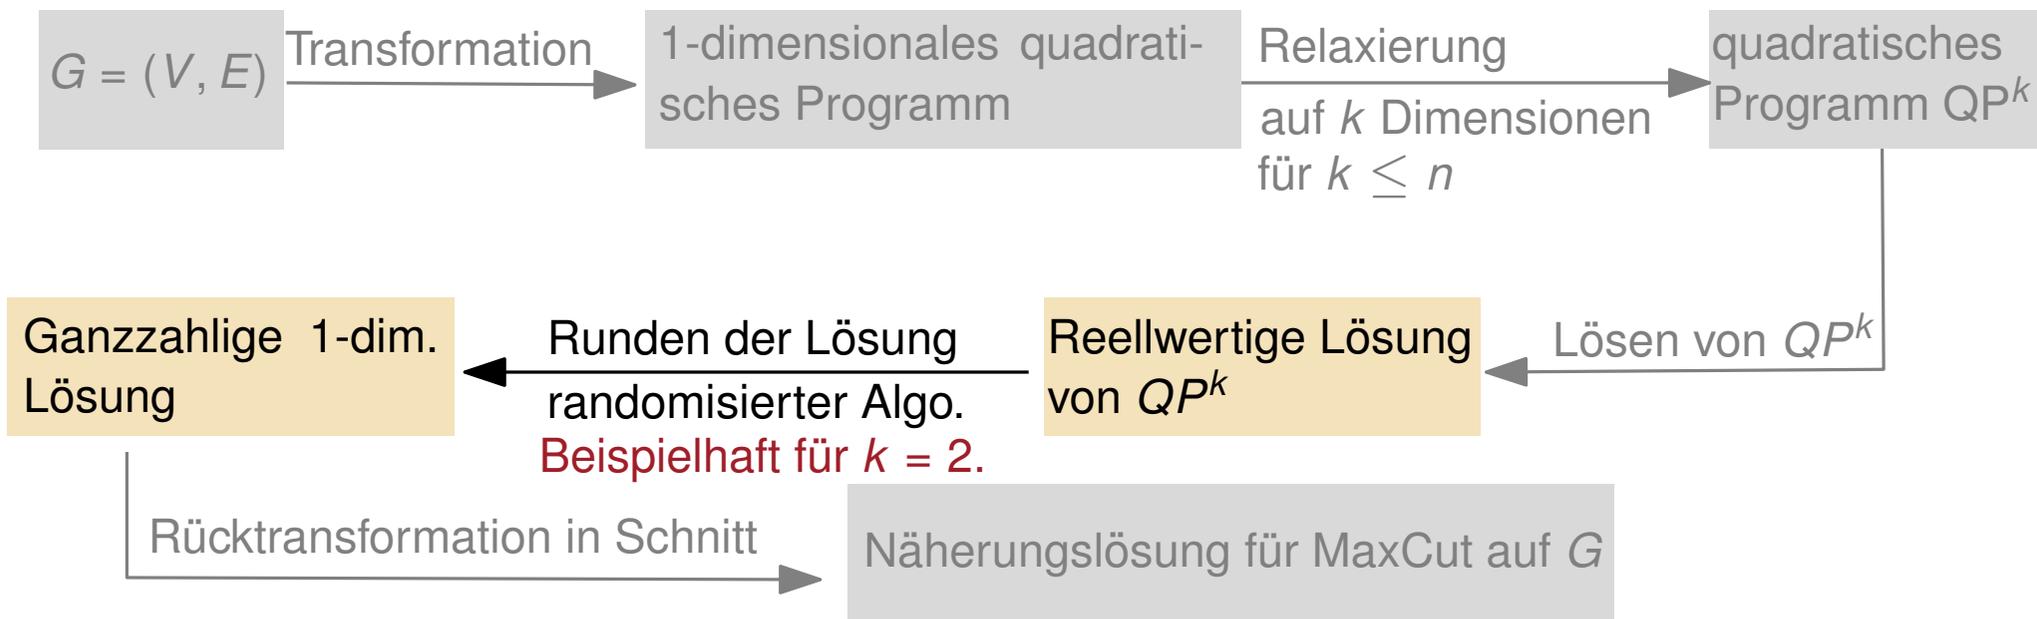
# Problemdefinition

**Problem MAXCUT:** Gegeben ist ein Graph  $G = (V, E)$  mit Gewichtsfunktion  $c: E \rightarrow \mathbb{N}$ .  
Gesucht ist ein Schnitt  $(S, V \setminus S)$  von  $G$  mit maximalem Gewicht, d.h.

$$c(S, V \setminus S) := \sum_{\substack{u, v \in E \\ u \in S \text{ und } v \in V \setminus S}} c(\{u, v\}) \quad \text{soll maximal sein.}$$

Problem ist  $\mathcal{NP}$ -schwer.

**Idee:** Berechne Lösung, die annähernd so gut ist, wie die optimale Lösung.



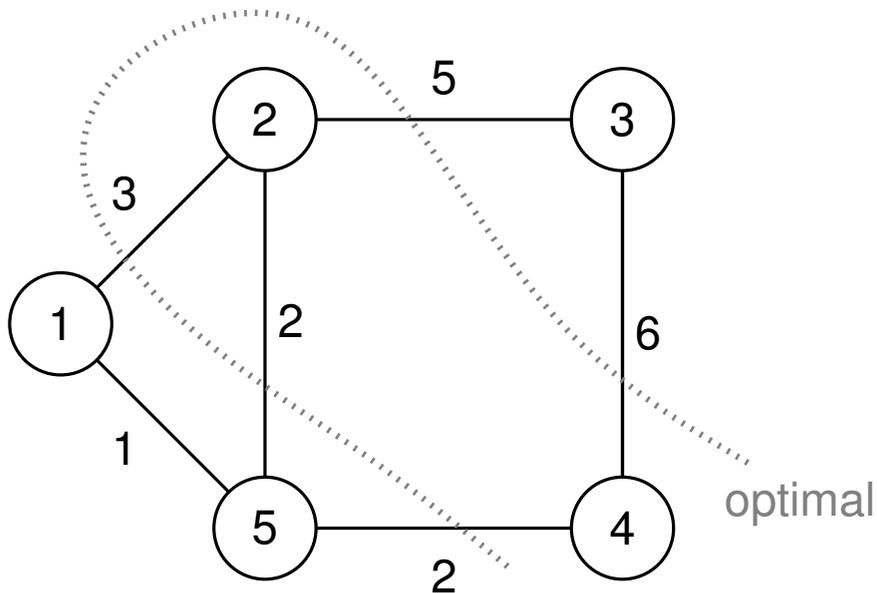
# Random MaxCut

**Eingabe:** Graph  $G = (V, E)$  mit einer Gewichtsfunktion  $c : E \rightarrow \mathbb{N}$

**Ausgabe:** Ein Schnitt  $(S, V \setminus S)$  in  $G$

1. Berechne optimale Lösung  $(\tilde{x}^1, \dots, \tilde{x}^n)$  für  $QP^2(G, c)$
2. Wähle zufällig einen zweidimensionalen Vektor  $r$  mit Norm 1
3.  $S \leftarrow \{i \in V : \tilde{x}^i \cdot r \geq 0\}$

→  $\tilde{x}_i$  liegt oberhalb der zu  $r$  senkrechten Linie  $\ell$



# Random MaxCut

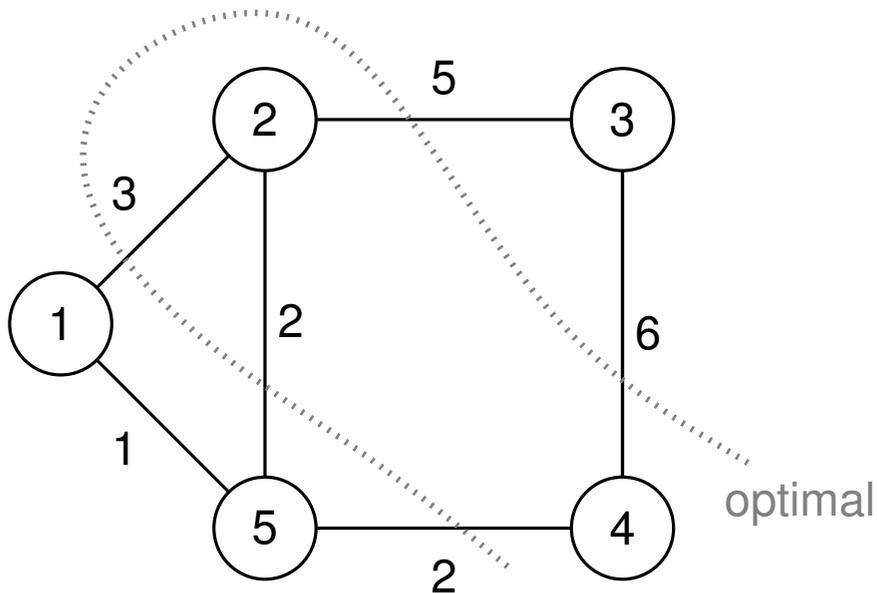
**Eingabe:** Graph  $G = (V, E)$  mit einer Gewichtsfunktion  $c : E \rightarrow \mathbb{N}$

**Ausgabe:** Ein Schnitt  $(S, V \setminus S)$  in  $G$

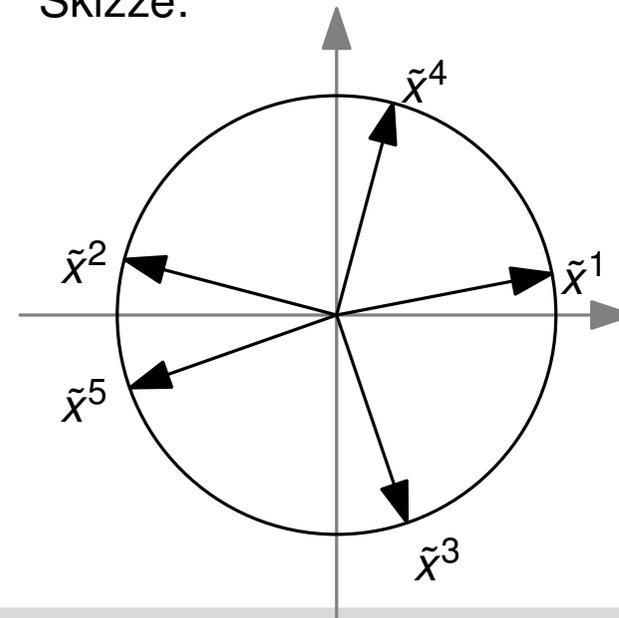
1. Berechne optimale Lösung  $(\tilde{x}^1, \dots, \tilde{x}^n)$  für  $QP^2(G, c)$
2. Wähle zufällig einen zweidimensionalen Vektor  $r$  mit Norm 1
3.  $S \leftarrow \{i \in V : \tilde{x}^i \cdot r \geq 0\}$

→  $\tilde{x}_i$  liegt oberhalb der zu  $r$  senkrechten Linie  $\ell$

## 1. Schritt: Berechne Lösung für $QP^2$ :



Skizze:



# Random MaxCut

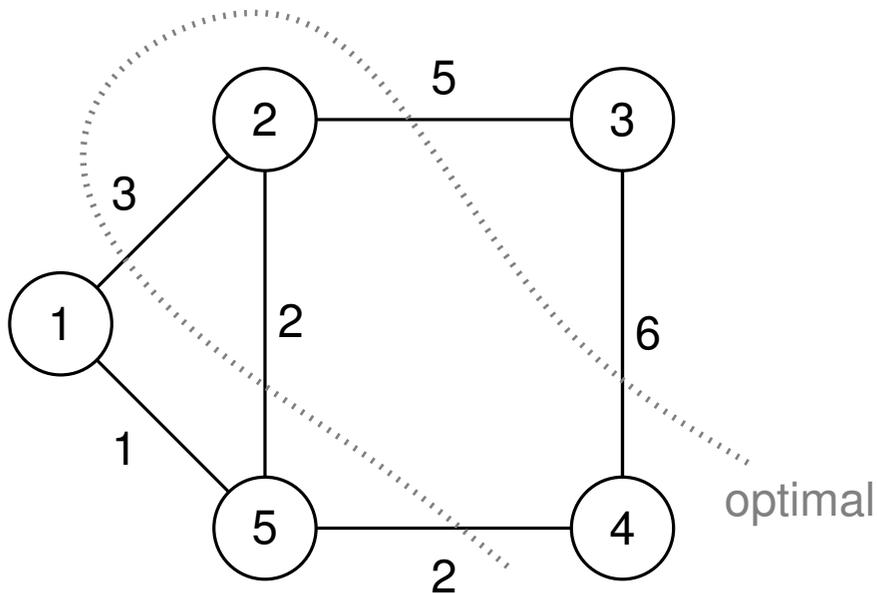
**Eingabe:** Graph  $G = (V, E)$  mit einer Gewichtsfunktion  $c : E \rightarrow \mathbb{N}$

**Ausgabe:** Ein Schnitt  $(S, V \setminus S)$  in  $G$

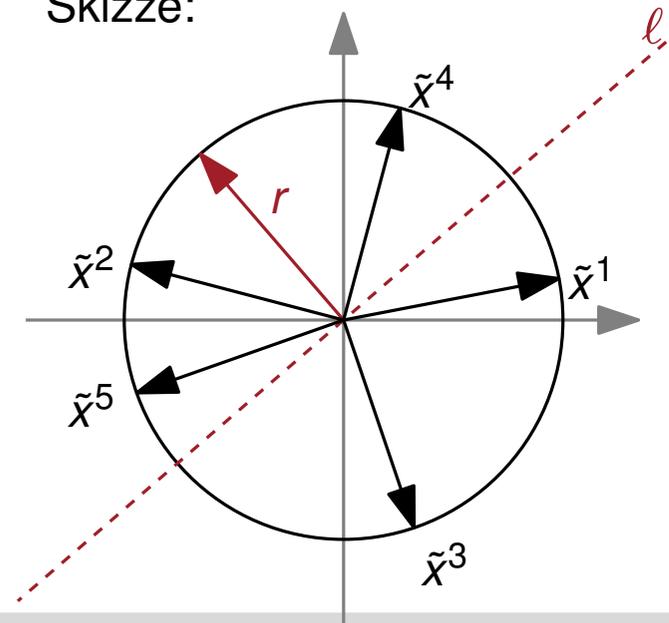
1. Berechne optimale Lösung  $(\tilde{x}^1, \dots, \tilde{x}^n)$  für  $QP^2(G, c)$
2. Wähle zufällig einen zweidimensionalen Vektor  $r$  mit Norm 1
3.  $S \leftarrow \{i \in V : \tilde{x}^i \cdot r \geq 0\}$

→  $\tilde{x}_i$  liegt oberhalb der zu  $r$  senkrechten Linie  $\ell$

## 2. Schritt: Rate Vektor $r$



Skizze:



# Random MaxCut

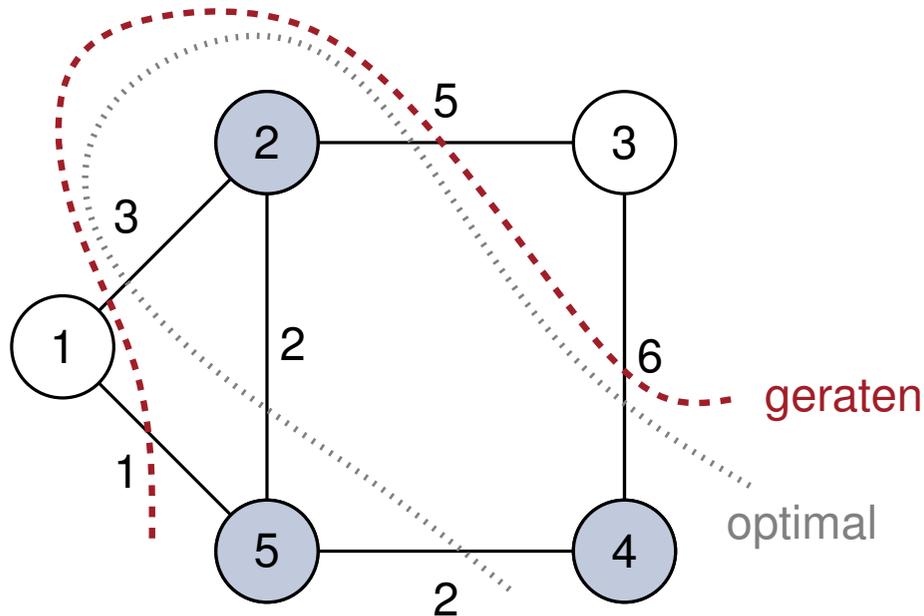
**Eingabe:** Graph  $G = (V, E)$  mit einer Gewichtsfunktion  $c : E \rightarrow \mathbb{N}$

**Ausgabe:** Ein Schnitt  $(S, V \setminus S)$  in  $G$

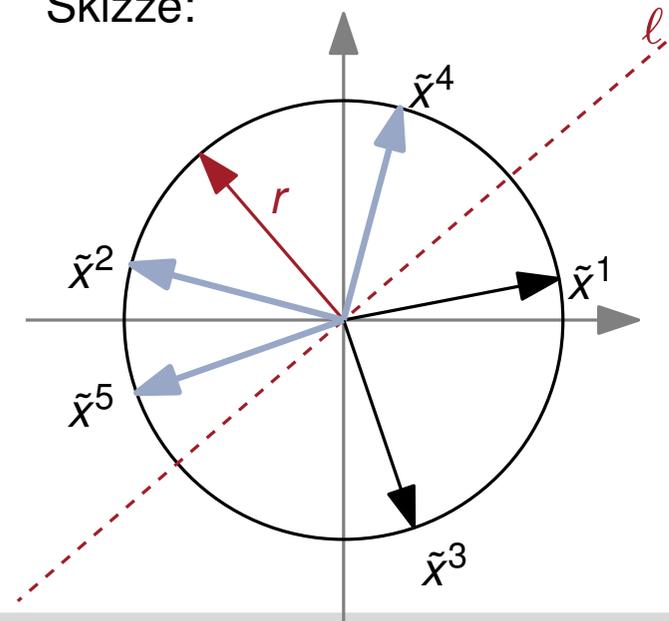
1. Berechne optimale Lösung  $(\tilde{x}^1, \dots, \tilde{x}^n)$  für  $QP^2(G, c)$
2. Wähle zufällig einen zweidimensionalen Vektor  $r$  mit Norm 1
3.  $S \leftarrow \{i \in V : \tilde{x}^i \cdot r \geq 0\}$

→  $\tilde{x}_i$  liegt oberhalb der zu  $r$  senkrechten Linie  $\ell$

## 3. Schritt: Berechne $S$

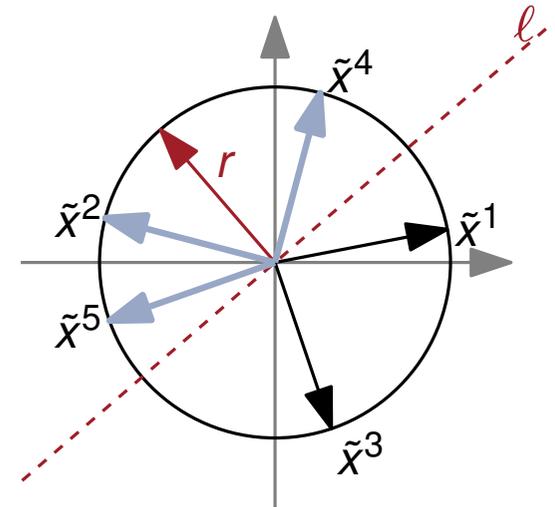


Skizze:



**Satz 8.18:** Sei  $I$  eine Instanz für MAXCUT und  $C_{\text{RMC}}(I)$  der Wert der Lösung, die RANDOM MAXCUT für  $I$  berechnet. Wenn die Vektoren  $r$  gleichverteilt angenommen werden, so gilt:

$$E[C_{\text{RMC}}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \arccos(\tilde{x}^i \cdot \tilde{x}^j)$$



**Eingabe:** Graph  $G = (V, E)$  mit einer Gewichtsfunktion  $c : E \rightarrow \mathbb{N}$

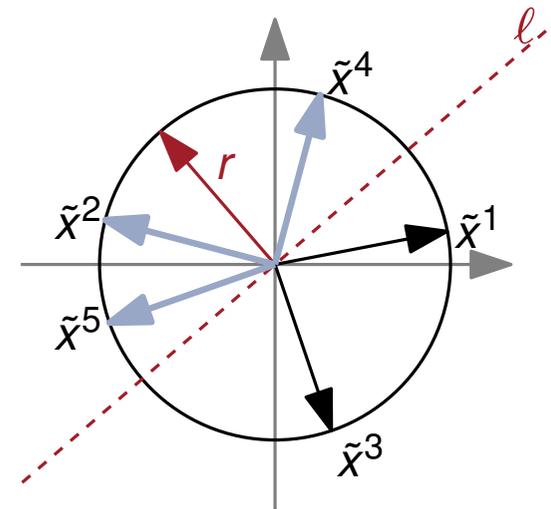
**Ausgabe:** Ein Schnitt  $(S, V \setminus S)$  in  $G$

1. Berechne optimale Lösung  $(\tilde{x}^1, \dots, \tilde{x}^n)$  für  $\text{QP}^2(G, c)$
2. Wähle zufällig einen zweidimensionalen Vektor  $r$  mit Norm 1
3.  $S \leftarrow \{i \in V : \tilde{x}^i \cdot r \geq 0\}$

**Satz 8.18:** Sei  $I$  eine Instanz für MAXCUT und  $C_{\text{RMC}}(I)$  der Wert der Lösung, die RANDOM MAXCUT für  $I$  berechnet. Wenn die Vektoren  $r$  gleichverteilt angenommen werden, so gilt:

$$E[C_{\text{RMC}}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \arccos(\tilde{x}^i \cdot \tilde{x}^j)$$

**Beweis:**  $\text{sgn}(x) := \begin{cases} 1 & \text{falls } x \geq 0 \\ -1 & \text{sonst} \end{cases}$



**Eingabe:** Graph  $G = (V, E)$  mit einer Gewichtsfunktion  $c : E \rightarrow \mathbb{N}$

**Ausgabe:** Ein Schnitt  $(S, V \setminus S)$  in  $G$

1. Berechne optimale Lösung  $(\tilde{x}^1, \dots, \tilde{x}^n)$  für  $\text{QP}^2(G, c)$
2. Wähle zufällig einen zweidimensionalen Vektor  $r$  mit Norm 1
3.  $S \leftarrow \{i \in V : \tilde{x}^i \cdot r \geq 0\}$

**Satz 8.18:** Sei  $I$  eine Instanz für MAXCUT und  $C_{\text{RMC}}(I)$  der Wert der Lösung, die RANDOM MAXCUT für  $I$  berechnet. Wenn die Vektoren  $r$  gleichverteilt angenommen werden, so gilt:

$$E[C_{\text{RMC}}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \arccos(\tilde{x}^i \cdot \tilde{x}^j)$$

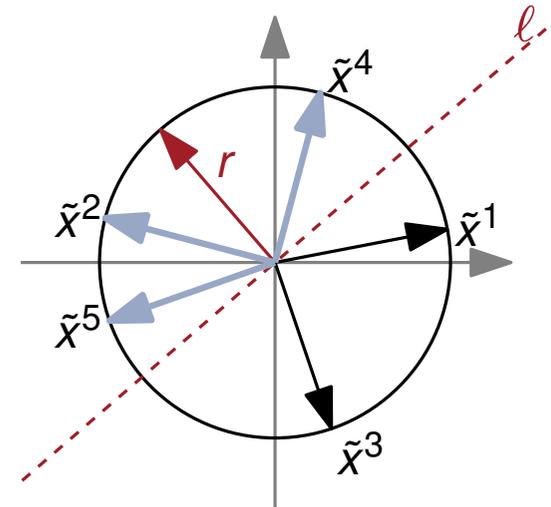
**Beweis:**

$$\text{sgn}(x) := \begin{cases} 1 & \text{falls } x \geq 0 \\ -1 & \text{sonst} \end{cases}$$

**Es gilt:**

$$E(C_{\text{RMC}}(I)) = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \Pr[\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r)]$$

wobei  $r$  gleichverteilt zufällig gewählt wird.



**Eingabe:** Graph  $G = (V, E)$  mit einer Gewichtsfunktion  $c : E \rightarrow \mathbb{N}$

**Ausgabe:** Ein Schnitt  $(S, V \setminus S)$  in  $G$

1. Berechne optimale Lösung  $(\tilde{x}^1, \dots, \tilde{x}^n)$  für  $\text{QP}^2(G, c)$
2. Wähle zufällig einen zweidimensionalen Vektor  $r$  mit Norm 1
3.  $S \leftarrow \{i \in V : \tilde{x}^i \cdot r \geq 0\}$

**Satz 8.18:** Sei  $I$  eine Instanz für MAXCUT und  $C_{\text{RMC}}(I)$  der Wert der Lösung, die RANDOM MAXCUT für  $I$  berechnet. Wenn die Vektoren  $r$  gleichverteilt angenommen werden, so gilt:

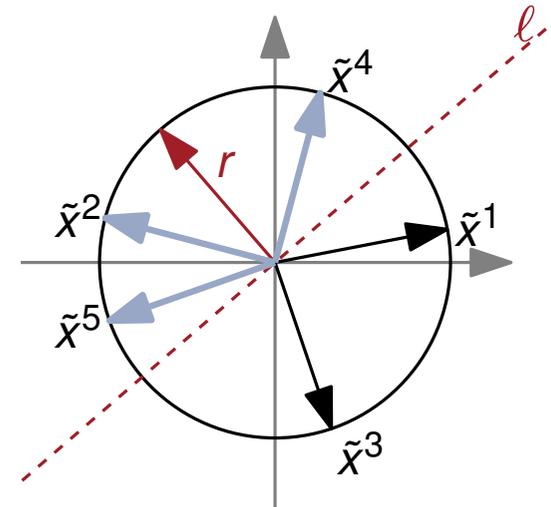
$$E[C_{\text{RMC}}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \arccos(\tilde{x}^i \cdot \tilde{x}^j)$$

**Beweis:**  $\text{sgn}(x) := \begin{cases} 1 & \text{falls } x \geq 0 \\ -1 & \text{sonst} \end{cases}$

**Es gilt:**  $E(C_{\text{RMC}}(I)) = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \Pr[\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r)]$

wobei  $r$  gleichverteilt zufällig gewählt wird.

**Zeige:**  $\Pr[\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r)] = \frac{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}{\pi}$



**Eingabe:** Graph  $G = (V, E)$  mit einer Gewichtsfunktion  $c : E \rightarrow \mathbb{N}$

**Ausgabe:** Ein Schnitt  $(S, V \setminus S)$  in  $G$

1. Berechne optimale Lösung  $(\tilde{x}^1, \dots, \tilde{x}^n)$  für  $\text{QP}^2(G, c)$
2. Wähle zufällig einen zweidimensionalen Vektor  $r$  mit Norm 1
3.  $S \leftarrow \{i \in V : \tilde{x}^i \cdot r \geq 0\}$

**Satz 8.18:** Sei  $I$  eine Instanz für MAXCUT und  $C_{\text{RMC}}(I)$  der Wert der Lösung, die RANDOM MAXCUT für  $I$  berechnet. Wenn die Vektoren  $r$  gleichverteilt angenommen werden, so gilt:

$$E[C_{\text{RMC}}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \arccos(\tilde{x}^i \cdot \tilde{x}^j)$$

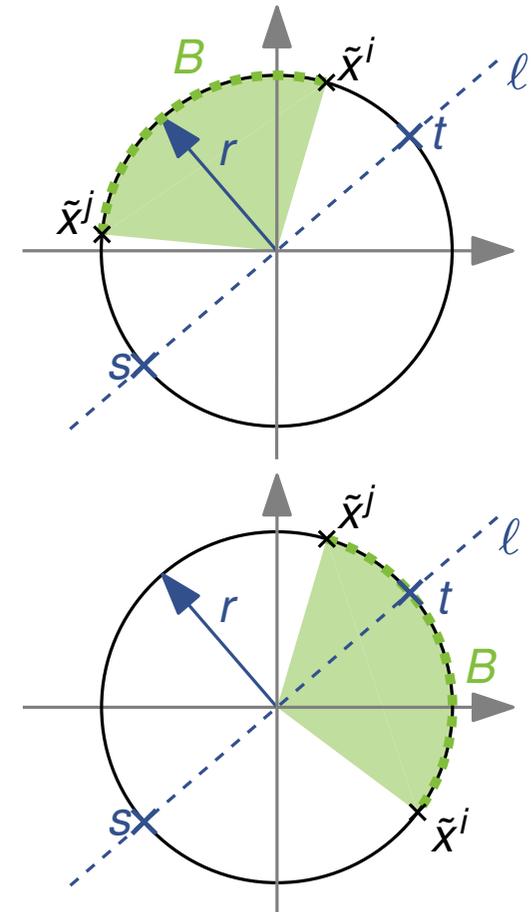
Zeige:

$$\Pr[\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r)] = \frac{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}{\pi}$$

$\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r) \Leftrightarrow \ell$  trennt  $\tilde{x}^i$  und  $\tilde{x}^j$

$\ell$  = Senkrechte Gerade zu  $r$

$s, t$  = Schnittpunkte von  $\ell$  und Einheitskreis.



**Satz 8.18:** Sei  $I$  eine Instanz für MAXCUT und  $C_{\text{RMC}}(I)$  der Wert der Lösung, die RANDOM MAXCUT für  $I$  berechnet. Wenn die Vektoren  $r$  gleichverteilt angenommen werden, so gilt:

$$E[C_{\text{RMC}}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \arccos(\tilde{x}^i \cdot \tilde{x}^j)$$

**Zeige:**

$$\Pr[\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r)] = \frac{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}{\pi}$$

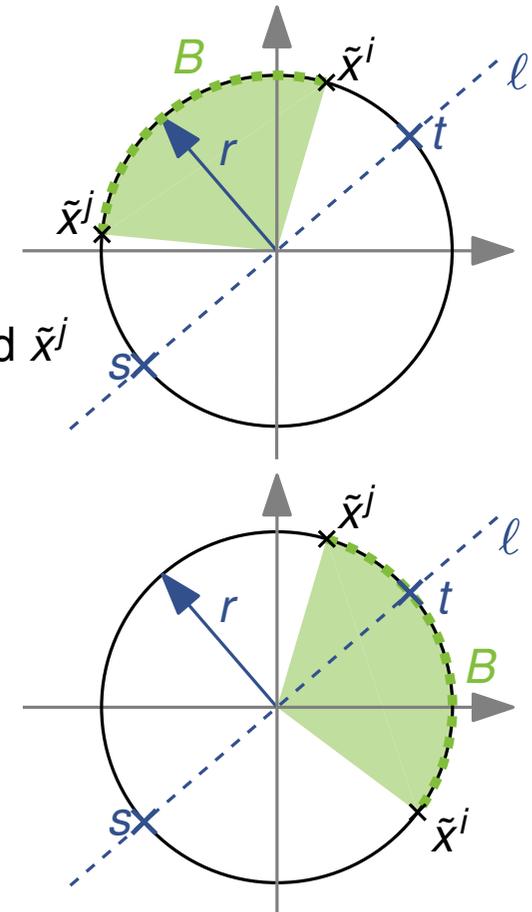
$\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r) \Leftrightarrow \ell$  trennt  $\tilde{x}^i$  und  $\tilde{x}^j$

$\Leftrightarrow s$  oder  $t$  liegt auf dem kürzeren Kreisbogen  $B$  zwischen  $\tilde{x}^i$  und  $\tilde{x}^j$

$B$  hat Länge  $\arccos(\tilde{x}^i \cdot \tilde{x}^j)$

$\ell$ =Senkrechte Gerade zu  $r$

$s, t$ = Schnittpunkte von  $\ell$  und Einheitskreis.



**Satz 8.18:** Sei  $I$  eine Instanz für MAXCUT und  $C_{\text{RMC}}(I)$  der Wert der Lösung, die RANDOM MAXCUT für  $I$  berechnet. Wenn die Vektoren  $r$  gleichverteilt angenommen werden, so gilt:

$$E[C_{\text{RMC}}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \arccos(\tilde{x}^i \cdot \tilde{x}^j)$$

**Zeige:**

$$\Pr[\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r)] = \frac{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}{\pi}$$

$\text{sgn}(\tilde{x}^i \cdot r) \neq \text{sgn}(\tilde{x}^j \cdot r) \Leftrightarrow \ell$  trennt  $\tilde{x}^i$  und  $\tilde{x}^j$

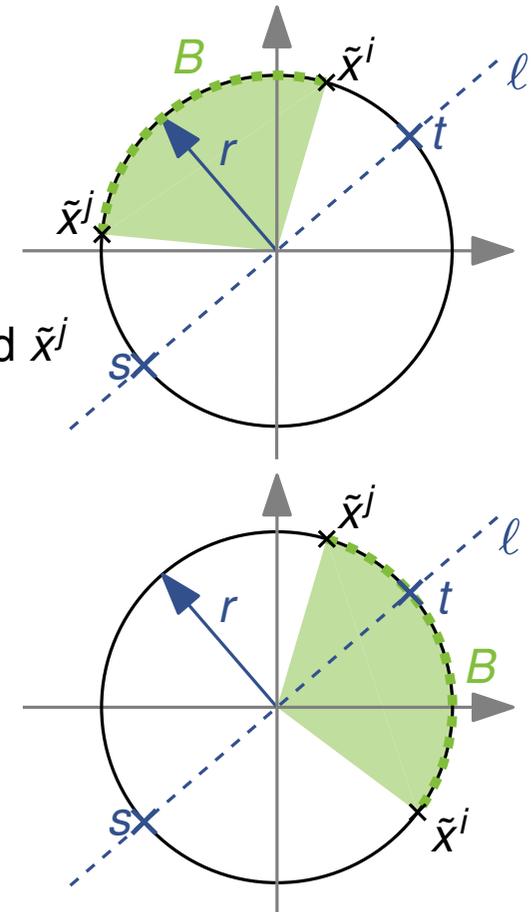
$\Leftrightarrow s$  oder  $t$  liegt auf dem kürzeren Kreisbogen  $B$  zwischen  $\tilde{x}^i$  und  $\tilde{x}^j$

$B$  hat Länge  $\arccos(\tilde{x}^i \cdot \tilde{x}^j)$

$$\begin{aligned} \Pr[s \text{ oder } t \text{ liegt auf } B] &= \frac{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}{2 \cdot \pi} + \frac{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}{2 \cdot \pi} \\ &= \frac{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}{\pi} \end{aligned}$$

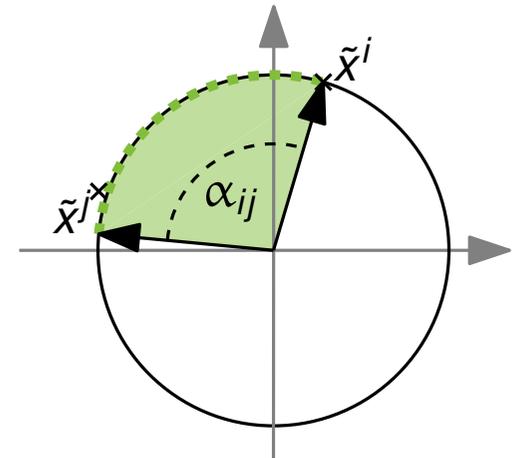
$\ell$ =Senkrechte Gerade zu  $r$

$s, t$ = Schnittpunkte von  $\ell$  und Einheitskreis.



**Satz 8.19:** Für eine Instanz  $I$  von MAXCUT berechnet RANDOM MAXCUT eine Lösung mit dem Wert  $C_{\text{RMC}}(I)$ , für die gilt

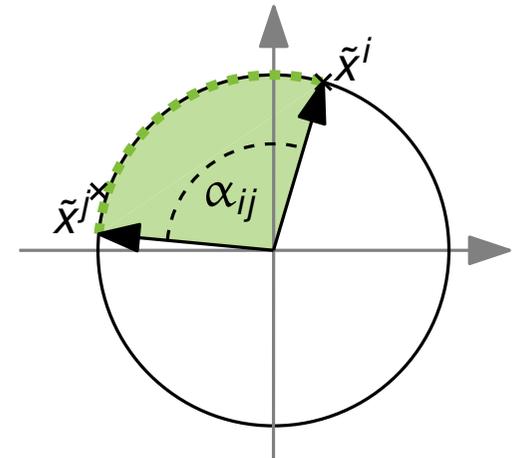
$$\frac{E[C_{\text{RMC}}(I)]}{OPT(I)} \geq 0,8785 .$$



**Satz 8.19:** Für eine Instanz  $I$  von MAXCUT berechnet RANDOM MAXCUT eine Lösung mit dem Wert  $C_{RMC}(I)$ , für die gilt

$$\frac{E[C_{RMC}(I)]}{OPT(I)} \geq 0,8785 .$$

$$E[C_{RMC}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \underbrace{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}_{\alpha_{ij}} = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \frac{\alpha_{ij}}{\pi}$$



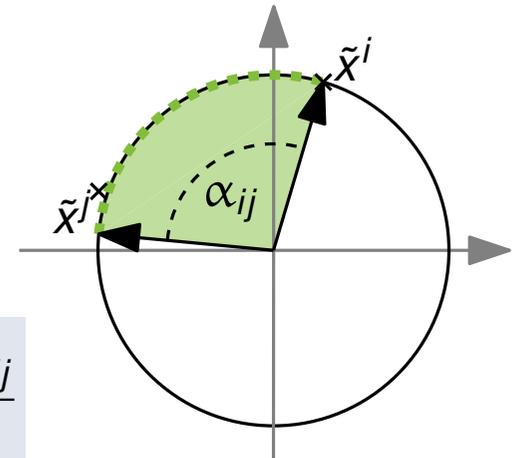
**Satz 8.19:** Für eine Instanz  $I$  von MAXCUT berechnet RANDOM MAXCUT eine Lösung mit dem Wert  $C_{\text{RMC}}(I)$ , für die gilt

$$\frac{E[C_{\text{RMC}}(I)]}{\text{OPT}(I)} \geq 0,8785 .$$

$$E[C_{\text{RMC}}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \underbrace{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}_{\alpha_{ij}} = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \frac{\alpha_{ij}}{\pi}$$

Sei  $\tilde{x}^1, \dots, \tilde{x}^n$  eine optimale Lösung von  $QP^2(I)$  mit dem Wert

$$C(QP^2(I)) = \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} (1 - \tilde{x}^i \cdot \tilde{x}^j) = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \frac{1 - \cos \alpha_{ij}}{2}$$



**Satz 8.19:** Für eine Instanz  $I$  von MAXCUT berechnet RANDOM MAXCUT eine Lösung mit dem Wert  $C_{RMC}(I)$ , für die gilt

$$\frac{E[C_{RMC}(I)]}{OPT(I)} \geq 0,8785 .$$

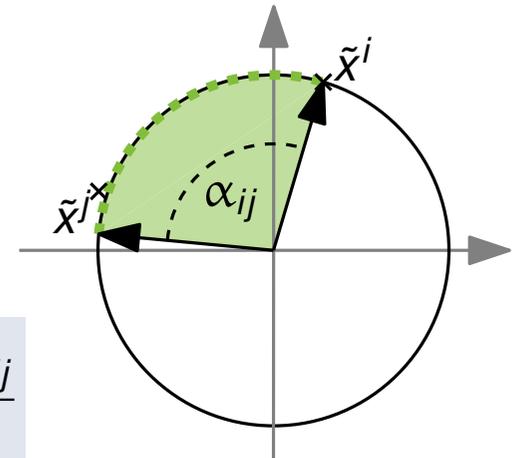
$$E[C_{RMC}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \underbrace{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}_{\alpha_{ij}} = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \frac{\alpha_{ij}}{\pi}$$

Sei  $\tilde{x}^1, \dots, \tilde{x}^n$  eine optimale Lösung von  $QP^2(I)$  mit dem Wert

$$C(QP^2(I)) = \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} (1 - \tilde{x}^i \cdot \tilde{x}^j) = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \frac{1 - \cos \alpha_{ij}}{2}$$

Da  $QP^2(I)$  Relaxierung von  $IQP(I)$  ist, gilt  $OPT(I) \leq C(QP^2(I))$

$$\frac{E[C_{RMC}(I)]}{OPT(I)} \geq \frac{E[C_{RMC}(I)]}{C(QP^2(I))}$$



**Satz 8.19:** Für eine Instanz  $I$  von MAXCUT berechnet RANDOM MAXCUT eine Lösung mit dem Wert  $C_{RMC}(I)$ , für die gilt

$$\frac{E[C_{RMC}(I)]}{OPT(I)} \geq 0,8785 .$$

$$E[C_{RMC}(I)] = \frac{1}{\pi} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \underbrace{\arccos(\tilde{x}^i \cdot \tilde{x}^j)}_{\alpha_{ij}} = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot \frac{\alpha_{ij}}{\pi}$$

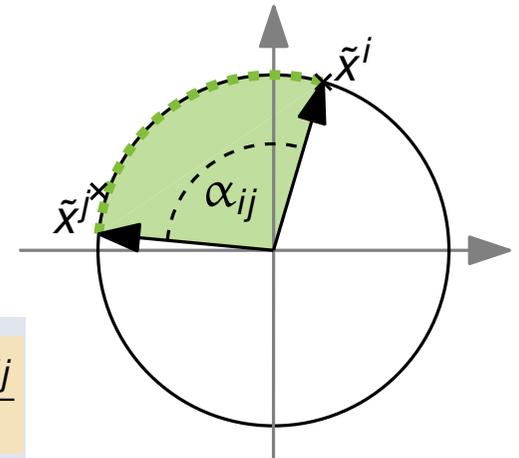
Sei  $\tilde{x}^1, \dots, \tilde{x}^n$  eine optimale Lösung von  $QP^2(I)$  mit dem Wert

$$C(QP^2(I)) = \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} (1 - \tilde{x}^i \cdot \tilde{x}^j) = \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \frac{1 - \cos \alpha_{ij}}{2}$$

Da  $QP^2(I)$  Relaxierung von  $IQP(I)$  ist, gilt  $OPT(I) \leq C(QP^2(I))$

$$\frac{E[C_{RMC}(I)]}{OPT(I)} \geq \frac{E[C_{RMC}(I)]}{C(QP^2(I))}$$

**Zeige:**  $\frac{\alpha_{ij}}{\pi} \geq \frac{1 - \cos \alpha_{ij}}{2} \cdot 0.8785$

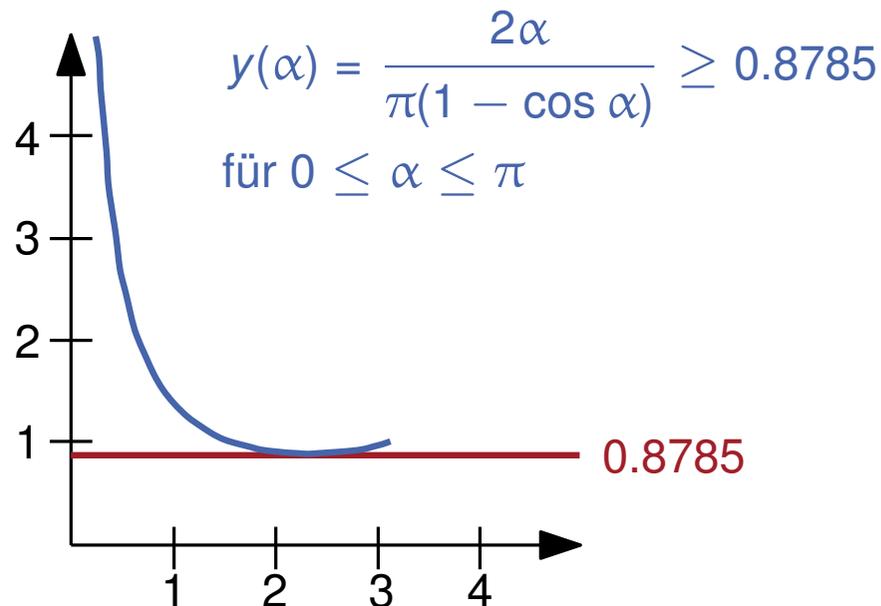


# Random MaxCut – Qualität

**Satz 8.19:** Für eine Instanz  $I$  von MAXCUT berechnet RANDOM MAXCUT eine Lösung mit dem Wert  $C_{\text{RMC}}(I)$ , für die gilt

$$\frac{E[C_{\text{RMC}}(I)]}{\text{OPT}(I)} \geq 0,8785 .$$

Man kann zeigen:



$E[C_{\text{RMC}}(I)]$

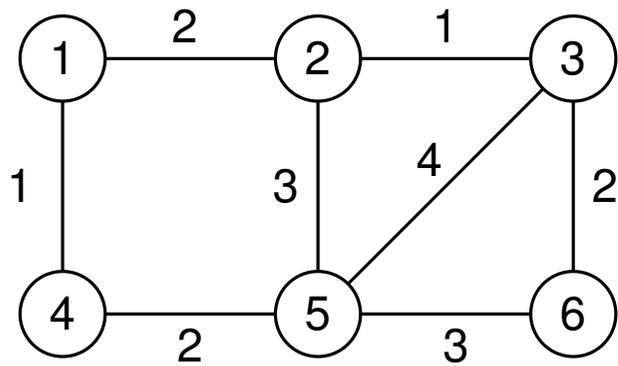
Sei  $\tilde{x}^1, \dots$

$C(G)$

Da  $QP^2(I)$

**Zeige:**  $\frac{\alpha_{ij}}{\pi} \geq \frac{1 - \cos \alpha_{ij}}{2} \cdot 0.8785$

# Beispiel



# Beispiel

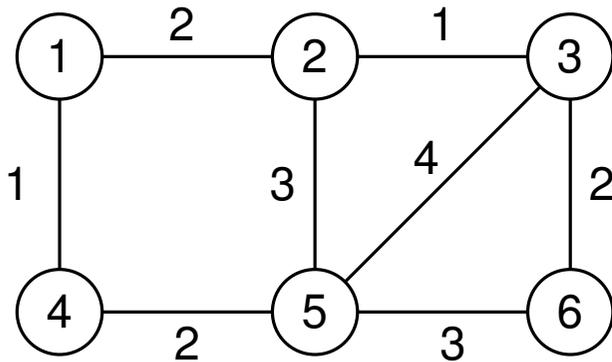
## 1. Schritt: Bestimme QP

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter NB:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

## Gewichtungsmatrix: $c_{ij}$

	1	2	3	4	5	6
1		2		1		
2	2		1		3	
3		1			4	2
4	1				2	
5		3	4	2		3
6			2		3	



# Beispiel

1. Schritt: Bestimme QP

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter NB:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

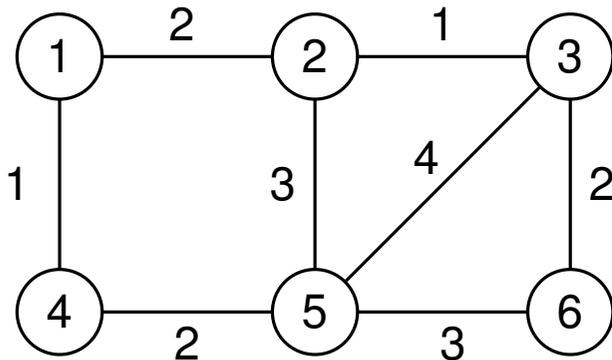
Gewichtungsmatrix:  $c_{ij}$

	1	2	3	4	5	6
1		2		1		
2	2		1		3	
3		1			4	2
4	1				2	
5		3	4	2		3
6			2		3	

2. Schritt: Relaxiere QP  $\rightarrow$  QP<sup>2</sup>

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter NB:  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren



# Beispiel

## 1. Schritt: Bestimme QP

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter NB:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

## Gewichtungsmatrix: $c_{ij}$

	1	2	3	4	5	6
1		2		1		
2	2		1		3	
3		1			4	2
4	1				2	
5		3	4	2		3
6			2		3	

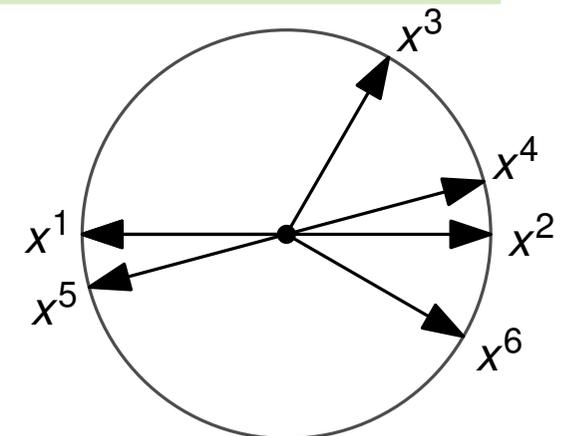
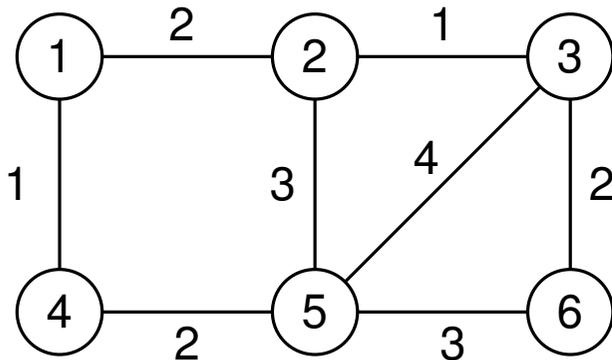
## 2. Schritt: Relaxiere QP $\rightarrow$ QP<sup>2</sup>

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter NB:  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren

## 3. Schritt: Löse QP<sup>2</sup>

Variable	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$	$x^6$
Winkel	0	180	120	165	345	210



# Beispiel

## 1. Schritt: Bestimme QP

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter NB:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

## Gewichtungsmatrix: $c_{ij}$

	1	2	3	4	5	6
1		2		1		
2	2		1		3	
3		1			4	2
4	1				2	
5		3	4	2		3
6			2		3	

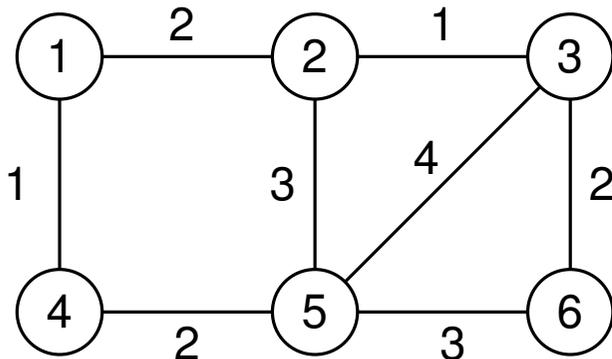
## 2. Schritt: Relaxiere QP $\rightarrow$ QP<sup>2</sup>

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

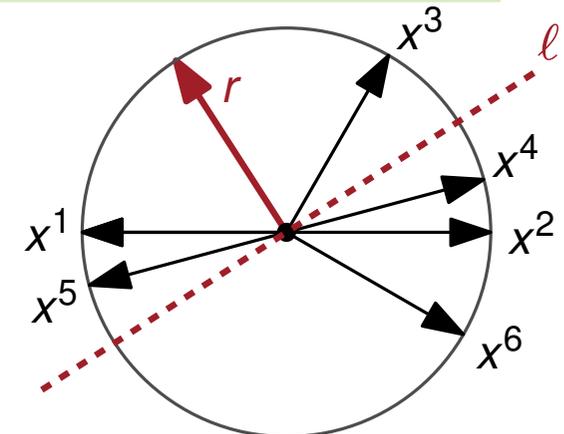
unter NB:  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren

## 3. Schritt: Löse QP<sup>2</sup>

Variable	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$	$x^6$
Winkel	0	180	120	165	345	210



## 4. Schritt: Rate Vektor $r$ .



# Beispiel

## 1. Schritt: Bestimme QP

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter NB:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

## Gewichtungsmatrix: $c_{ij}$

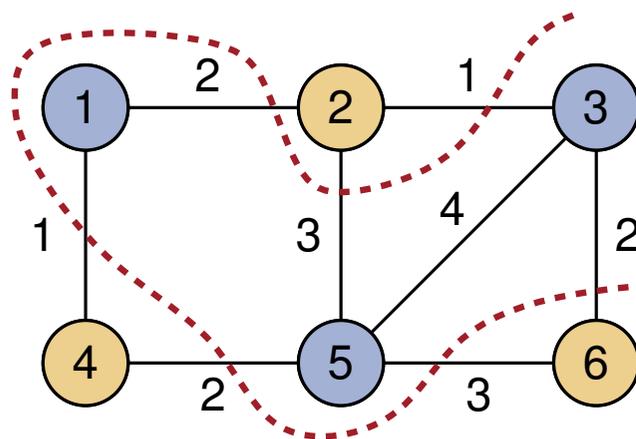
	1	2	3	4	5	6
1		2		1		
2	2		1		3	
3		1			4	2
4	1				2	
5		3	4	2		3
6			2		3	

## 2. Schritt: Relaxiere QP $\rightarrow$ QP<sup>2</sup>

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter NB:  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren

## 3. Schritt: Löse QP<sup>2</sup>

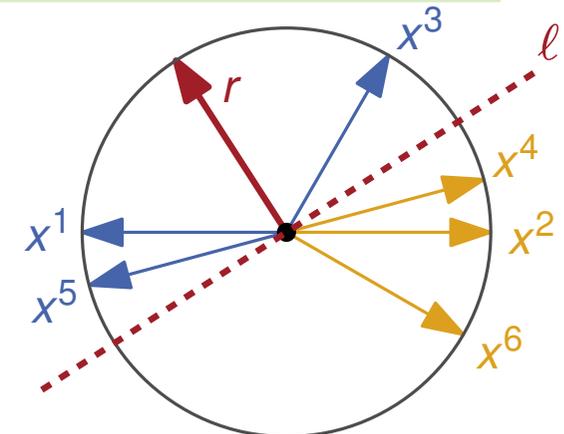


Variable	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$	$x^6$
Winkel	0	180	120	165	345	210

## 4. Schritt: Rate Vektor $r$ .

## 5. Schritt: Bestimme Schnitt

Gewicht 14



# Beispiel

## 1. Schritt: Bestimme QP

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x_i \cdot x_j)$$

unter NB:  $x_i^2 = 1$  für  $1 \leq i \leq n$ .

## Gewichtungsmatrix: $c_{ij}$

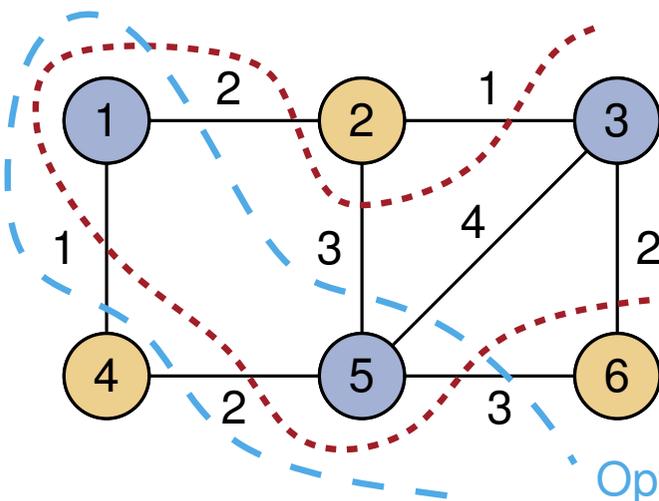
	1	2	3	4	5	6
1		2		1		
2	2		1		3	
3		1			4	2
4	1				2	
5		3	4	2		3
6			2		3	

## 2. Schritt: Relaxiere QP $\rightarrow$ QP<sup>2</sup>

$$\max \frac{1}{2} \cdot \sum_{j=1}^6 \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter NB:  $x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren

## 3. Schritt: Löse QP<sup>2</sup>

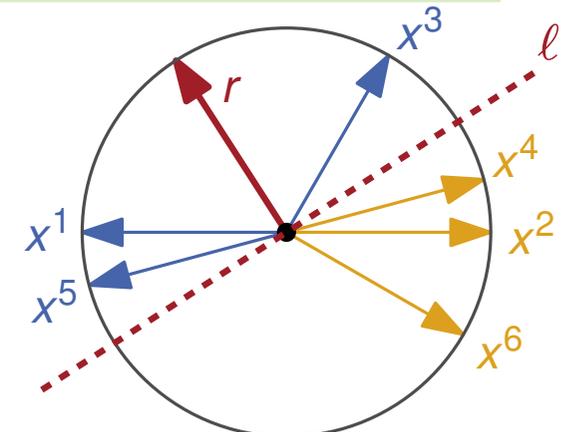


Variable	$x^1$	$x^2$	$x^3$	$x^4$	$x^5$	$x^6$
Winkel	0	180	120	165	345	210

## 4. Schritt: Rate Vektor $r$ .

## 5. Schritt: Bestimme Schnitt

Gewicht 14



# Problemdefinition

**Problem MAXCUT:** Gegeben ist ein Graph  $G = (V, E)$  mit Gewichtsfunktion  $c: E \rightarrow \mathbb{N}$ .  
Gesucht ist ein Schnitt  $(S, V \setminus S)$  von  $G$  mit maximalem Gewicht, d.h.

$$c(S, V \setminus S) := \sum_{\substack{u, v \in E \\ u \in S \text{ und } v \in V \setminus S}} c(\{u, v\}) \quad \text{soll maximal sein.}$$

Problem ist  $\mathcal{NP}$ -schwer

**Idee:** Berechne

$G = (V, E)$  Trans

**Bisher:**  $k=2$

**Problem:**

Nicht bekannt, ob  $QP^2$  optimal in poly. Zeit gelöst werden kann.

Entsprechendes  $QP^n$  kann in poly. Zeit gelöst werden.

ing.

ionen

quadratisches  
Programm  $QP^k$

Ganzzahlige 1-dim.  
Lösung

Runden der Lösung  
randomisierter Algo.

Reellwertige Lösung  
von  $QP^k$

Lösen von  $QP^k$

Rücktransformation in Schnitt

Näherungslösung für MaxCut auf  $G$

# Effiziente Lösung

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter den Nebenbedingungen

$x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren.

wird zu

$$QP^n \quad \max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - m_{ij})$$

mit  $m_{ij} = x^i \cdot x^j$  und  $m_{ij} = 1$  und unter den Nebenbedingungen

$x^i, x^j \in \mathbb{R}^n$  sind normierte Vektoren.

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter den Nebenbedingungen

$x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren.

wird zu

$$QP^n \quad \max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - m_{ij})$$

mit  $m_{ij} = x^i \cdot x^j$  und  $m_{ii} = 1$  und unter den Nebenbedingungen

$x^i, x^j \in \mathbb{R}^n$  sind normierte Vektoren.

**Definition 8.20:** Eine  $n \times n$ -Matrix  $M$  heißt *positiv semidefinit*, falls für jeden Vektor  $x \in \mathbb{R}^n$  gilt:

$$x^T \cdot M \cdot x \geq 0$$

**Die Matrix  $M := (m_{ij})$  ist positiv semidefinit.**

**Denn:** Symmetrische Matrix  $M$  ist genau dann positiv semidefinit, wenn es  $m \times n$ -Matrix  $P$  ( $m \leq n$ ) gibt, sodass

$$M = P^T \cdot P$$

( $P$  ist in polynomieller Zeit berechenbar, falls  $M$  positiv semidefinit.)

(Für jede positiv semidefinite  $n \times n$ -Matrix  $M$  mit  $m_{ii} = 1$  gilt, dass  $n$  normierte Vektoren  $x^1, \dots, x^n \in \mathbb{R}^n$  mit  $m_{ij} = x^i \cdot x^j$  in polynomieller Zeit berechnet werden können.)

$$\max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - x^i \cdot x^j)$$

unter den Nebenbedingungen

$x^i, x^j \in \mathbb{R}^2$  sind normierte Vektoren.

wird zu

$$QP^n \quad \max \frac{1}{2} \cdot \sum_{j=1}^n \sum_{i=1}^{j-1} c_{ij} \cdot (1 - m_{ij})$$

mit  $m_{ij} = x^i \cdot x^j$  und  $m_{ii} = 1$  und unter den Nebenbedingungen

$x^i, x^j \in \mathbb{R}^n$  sind normierte Vektoren.

**Definition 8.20:** Eine  $n \times n$ -Matrix  $M$  heißt *positiv semidefinit*, falls für jeden Vektor  $x \in \mathbb{R}^n$  gilt:

$$x^T \cdot M \cdot x \geq 0$$

**Die Matrix  $M := (m_{ij})$  ist positiv semidefinit.**

Damit entspricht  $QP^n(I)$  dem Problem SEMI-DEFINIT-CUT(I).

**Satz:** Es gibt Algorithmus  $\mathcal{A}_\epsilon$  für jedes  $\epsilon$ , sodass  $\mathcal{A}_\epsilon$  polynomiell in Eingabegröße und  $\log(\frac{1}{\epsilon})$  ist und

$$\mathcal{A}_\epsilon(I) \geq OPT_{SD}(I) - \epsilon,$$

wobei  $OPT_{SD}(I)$  optimaler Lösungswert von SEMI-DEFINIT-CUT(I).

**(Ohne Beweis)**

➔ **Man kann zeigen:** Für  $\epsilon = 10^{-5}$  wird Approximationsgüte von RANDOM MAXCUT erreicht.