

Algoritmos de Aproximação

Segundo Semestre de 2012

Relaxação vetorial

MAX CUT: Dados G completo e pesos $w_{ij} \geq 0$ para cada ij , encontrar corte $\delta(X)$ em G de peso máximo.

Relaxação vetorial

MAX CUT: Dados G completo e pesos $w_{ij} \geq 0$ para cada ij , encontrar corte $\delta(X)$ em G de peso máximo.

Formulação quadrática: encontrar vetor x que maximize $\frac{1}{2} \sum_{ij} w_{ij} (1 - x_i x_j)$ sujeito a $x_i x_i = 1$ para cada i em V .

Relaxação vetorial

MAX CUT: Dados G completo e pesos $w_{ij} \geq 0$ para cada ij , encontrar corte $\delta(X)$ em G de peso máximo.

Formulação quadrática: encontrar vetor x que maximize $\frac{1}{2} \sum_{ij} w_{ij}(1 - x_i x_j)$ sujeito a $x_i x_i = 1$ para cada i em V .

Relaxação vetorial:

encontrar matrix real Y $n \times n$, onde $n = |V|$, que maximize $\sum_{ij} w_{ij}(1 - (YY^T)_{ij})$ sujeito a $(YY^T)_{ii} = 1$ para cada i em V .

Relaxação vetorial

MAX CUT: Dados G completo e pesos $w_{ij} \geq 0$ para cada ij , encontrar corte $\delta(X)$ em G de peso máximo.

Formulação quadrática: encontrar vetor x que maximize $\frac{1}{2} \sum_{ij} w_{ij}(1 - x_i x_j)$ sujeito a $x_i x_i = 1$ para cada i em V .

Relaxação vetorial:

encontrar matrix real Y $n \times n$, onde $n = |V|$, que maximize $\sum_{ij} w_{ij}(1 - (YY^T)_{ij})$ sujeito a $(YY^T)_{ii} = 1$ para cada i em V .

Então $\frac{1}{2} \sum_{ij \in E} w_{ij}(1 - (\hat{Y}\hat{Y}^T)_{ij}) \geq \text{OPT}(G, w)$.

Algoritmo de Goemans e Williamson

MAXCUT-GW (G, w)

- 1 seja \hat{Y} uma solução ótima do programa vetorial
- 2 $r \leftarrow \text{RANDESFERA}(V(G))$
- 3 $S \leftarrow \{i \in V(G) : r \hat{Y}_{i*} > 0\}$
- 4 devolva $\delta(S)$

Algoritmo de Goemans e Williamson

MAXCUT-GW (G, w)

- 1 seja \hat{Y} uma solução ótima do programa vetorial
- 2 $r \leftarrow \text{RANDESFERA}(V(G))$
- 3 $S \leftarrow \{i \in V(G) : r \hat{Y}_{i*} > 0\}$
- 4 **devolva** $\delta(S)$

RANDESFERA: devolve um r indexado por $V(G)$ tq $\|r\| = 1$
(ou seja, um ponto na esfera unitária)
com probabilidade uniforme.

Algoritmo de Goemans e Williamson

MAXCUT-GW (G, w)

- 1 seja \hat{Y} uma solução ótima do programa vetorial
- 2 $r \leftarrow \text{RANDESFERA}(V(G))$
- 3 $S \leftarrow \{i \in V(G) : r \hat{Y}_{i*} > 0\}$
- 4 **devolva** $\delta(S)$

RANDESFERA: devolve um r indexado por $V(G)$ tq $\|r\| = 1$
(ou seja, um ponto na esfera unitária)
com probabilidade uniforme.

Teorema: O algoritmo é uma 0,878-aproximação.

Análise

Lema: Para S e \hat{Y} do algoritmo e quaisquer dois vértices i e j de G , $\Pr[ij \in \delta(S)] \geq \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$.

Análise

Lema: Para S e \hat{Y} do algoritmo e quaisquer dois vértices i e j de G , $\Pr[ij \in \delta(S)] \geq \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$.

Teorema: Se W é o peso do corte produzido pelo algoritmo MAXCUT-GW (G, w) então

$$\mathbb{E}[W] \geq 0,878 \text{OPT}(G, w).$$

Análise

Lema: Para S e \hat{Y} do algoritmo e quaisquer dois vértices i e j de G , $\Pr[ij \in \delta(S)] \geq \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij})$.

Teorema: Se W é o peso do corte produzido pelo algoritmo MAXCUT-GW (G, w) então

$$\mathbf{E}[W] \geq 0,878 \mathbf{OPT}(G, w).$$

Prova: Pelo lema,

$$\begin{aligned} \mathbf{E}[W] &= \sum_{ij \in E} w_{ij} \Pr[ij \in \delta(S)] \\ &\geq \sum_{ij \in E} w_{ij} \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij}) \dots \end{aligned}$$

e antes de continuar...

Análise


Cálculos elementares mostram que

$\frac{1}{\pi} \arccos(x) \geq 0,878 \frac{1}{2}(1 - x)$, para todo x no intervalo $[-1, 1]$.

Análise

Cálculos elementares mostram que

$\frac{1}{\pi} \arccos(x) \geq 0,878 \frac{1}{2}(1 - x)$, para todo x no intervalo $[-1, 1]$.



Análise

Cálculos elementares mostram que

$\frac{1}{\pi} \arccos(x) \geq 0,878 \frac{1}{2}(1 - x)$, para todo x no intervalo $[-1, 1]$.




Gráfico de $f(x) := \frac{1}{\pi} \arccos(x)$ e $g(x) := 0,878 \frac{1}{2}(1 - x)$.

Verifica-se que $f(x) \geq g(x)$ no intervalo $[-1, 1]$.

Finalizando a análise

Teorema: Se W é o peso do corte produzido pelo algoritmo MAXCUT-GW (G, w) então

$$E[W] \geq 0,878 \text{OPT}(G, w) .$$

Finalizando a análise

Teorema: Se W é o peso do corte produzido pelo algoritmo MAXCUT-GW (G, w) então

$$E[W] \geq 0,878 \text{OPT}(G, w).$$

Prova: Pelo lema,

$$\begin{aligned} E[W] &= \sum_{ij \in E} w_{ij} \Pr[ij \in \delta(S)] \\ &\geq \sum_{ij \in E} w_{ij} \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij}) \end{aligned}$$

Finalizando a análise

Teorema: Se W é o peso do corte produzido pelo algoritmo MAXCUT-GW (G, w) então

$$E[W] \geq 0,878 \text{OPT}(G, w).$$

Prova: Pelo lema e pela observação prévia,

$$\begin{aligned} E[W] &= \sum_{ij \in E} w_{ij} \Pr[ij \in \delta(S)] \\ &\geq \sum_{ij \in E} w_{ij} \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij}) \\ &\geq 0,878 \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - (\hat{Y}\hat{Y}^T)_{ij}) \end{aligned}$$

Finalizando a análise

Teorema: Se W é o peso do corte produzido pelo algoritmo MAXCUT-GW (G, w) então

$$E[W] \geq 0,878 \text{OPT}(G, w).$$

Prova: Pelo lema e pela observação prévia,

$$\begin{aligned} E[W] &= \sum_{ij \in E} w_{ij} \Pr[ij \in \delta(S)] \\ &\geq \sum_{ij \in E} w_{ij} \frac{1}{\pi} \arccos((\hat{Y}\hat{Y}^T)_{ij}) \\ &\geq 0,878 \frac{1}{2} \sum_{ij \in E} w_{ij} (1 - (\hat{Y}\hat{Y}^T)_{ij}) \\ &\geq 0,878 \text{OPT}(G, w), \end{aligned}$$

onde a última desigualdade segue da relaxação.

Algoritmo de Goemans e Williamson

MAXCUT-GW (G, w)

- 1 seja \hat{Y} uma solução ótima do programa vetorial
- 2 $r \leftarrow \text{RANDESFERA}(V(G))$
- 3 $S \leftarrow \{i \in V(G) : r \hat{Y}_{i*} > 0\}$
- 4 **devolva** $\delta(S)$

RANDESFERA: devolve um r indexado por $V(G)$ tq $\|r\| = 1$
(ou seja, um ponto na esfera unitária)
com probabilidade uniforme.

Algoritmo de Goemans e Williamson

MAXCUT-GW (G, w)

- 1 seja \hat{Y} uma solução ótima do programa vetorial
- 2 $r \leftarrow \text{RANDESFERA}(V(G))$
- 3 $S \leftarrow \{i \in V(G) : r \hat{Y}_{i*} > 0\}$
- 4 **devolva** $\delta(S)$

RANDESFERA: devolve um r indexado por $V(G)$ tq $\|r\| = 1$
(ou seja, um ponto na esfera unitária)
com probabilidade uniforme.

● Como se executa a linha 1?

Algoritmo de Goemans e Williamson

MAXCUT-GW (G, w)

- 1 seja \hat{Y} uma solução ótima do programa vetorial
- 2 $r \leftarrow \text{RANDESFERA}(V(G))$
- 3 $S \leftarrow \{i \in V(G) : r \hat{Y}_{i*} > 0\}$
- 4 **devolva** $\delta(S)$

RANDESFERA: devolve um r indexado por $V(G)$ tq $\|r\| = 1$
(ou seja, um ponto na esfera unitária)
com probabilidade uniforme.

- Como se executa a linha 1?
- Como se implementa RANDESFERA?

Distribuição uniforme na esfera

Sejam x_1, \dots, x_n são variáveis aleatórias independentes, cada uma com distribuição normal.

Distribuição uniforme na esfera

Sejam x_1, \dots, x_n são variáveis aleatórias independentes, cada uma com distribuição normal.

Então o vetor s com componentes

$$s_i = \frac{x_i}{\sqrt{x_1^2 + \dots + x_n^2}}$$

tem distribuição uniforme na esfera unitária.

Distribuição uniforme na esfera

Sejam x_1, \dots, x_n são variáveis aleatórias independentes, cada uma com distribuição normal.

Então o vetor s com componentes

$$s_i = \frac{x_i}{\sqrt{x_1^2 + \dots + x_n^2}}$$

tem distribuição uniforme na esfera unitária.

Se u e v são variáveis aleatórias independentes, com distribuição uniforme em $[0, 1)$, então

$$x = \cos(2\pi v) \sqrt{-2 \ln u}$$

é uma variável aleatória com distribuição normal.

Matrizes positiva semidefinidas

Matriz real X quadrada é **positiva semidefinida** se, para todo vetor y , vale que $yXy \geq 0$.

Notação: $X \succeq 0$.

Matrizes positiva semidefinidas

Matriz real X quadrada é **positiva semidefinida** se, para todo vetor y , vale que $yXy \geq 0$.

Notação: $X \succeq 0$.

Lema: Para toda matriz quadrada **simétrica** X , as seguintes afirmações são equivalentes:

1. X é positiva semidefinida;
2. Todos os autovalores de X são não negativos;
3. Existe uma matriz quadrada Y tal que $X = Y Y^T$;
4. $X = \sum_{i=1}^n \lambda_i w_i w_i^T$ onde $\lambda_i \geq 0$ e $w_i^T w_i = 1$ para todo i , e $w_i^T w_j = 0$ para todo $j \neq i$.

Programas semidefinidos

Dados a , b e c , encontrar matrix real X $n \times n$, que

maximize $\sum_{ij} c_{ij} x_{ij}$

sujeito a $\sum_{i,j} a_{ijk} x_{ij} = b_k$ para cada k ,

$$x_{ij} = x_{ji}$$

para todo par i, j

$$X \succeq 0.$$

Programas semidefinidos

Dados a , b e c , encontrar matrix real X $n \times n$, que

maximize $\sum_{ij} c_{ij} x_{ij}$

sujeito a $\sum_{i,j} a_{ijk} x_{ij} = b_k$ para cada k ,

$$x_{ij} = x_{ji}$$

para todo par i, j

$$X \succeq 0.$$

Sob certas condições técnicas, resolve-se tal programa dentro de um erro aditivo de $\epsilon > 0$, em tempo polinomial no tamanho da entrada (soma dos tamanhos de a , b e c) e $\lg \frac{1}{\epsilon}$.

Programas semidefinidos

Dados a, b e c , encontrar matrix real $X \ n \times n$, que maximize $\sum_{ij} c_{ij} x_{ij}$
sujeito a $\sum_{i,j} a_{ijk} x_{ij} = b_k$ para cada k ,
 $x_{ij} = x_{ji}$ para todo par i, j
 $X \succeq 0$.

Sob certas condições técnicas, resolve-se tal programa dentro de um erro aditivo de $\epsilon > 0$, em tempo polinomial no tamanho da entrada (soma dos tamanhos de a, b e c) e $\lg \frac{1}{\epsilon}$.

Condições técnicas:

A região viável não é vazia e está contida em uma bola de tamanho polinomial (na entrada).

Matrizes positiva semidefinidas

Matriz real quadrada X é **positiva semidefinida** se existe matriz quadrada Y tal que $X = YY^T$.

Tal X é simétrica.

Matrizes positiva semidefinidas

Matriz real quadrada X é **positiva semidefinida** se existe matriz quadrada Y tal que $X = YY^T$.

Tal X é simétrica.

Lema: Para toda matriz simétrica X , vale uma e apenas uma das seguintes alternativas: existe uma matriz quadrada Y tal que $X = YY^T$ ou existe um vetor y tal que $yXy < 0$.

Matrizes positiva semidefinidas

Matriz real quadrada X é **positiva semidefinida** se existe matriz quadrada Y tal que $X = YY^T$.

Tal X é simétrica.

Lema: Para toda matriz simétrica X , vale uma e apenas uma das seguintes alternativas: existe uma matriz quadrada Y tal que $X = YY^T$ ou existe um vetor y tal que $yXy < 0$.

Prova: Primeiro, se $X = YY^T$, então

$$yXy = y(YY^T)y = (yY)(yY)^T \geq 0,$$

ou seja, no máximo uma das alternativa vale.

Continuação da prova

Lema: Para toda matriz simétrica X , vale uma e apenas uma das seguintes alternativas: existe uma matriz quadrada Y tal que $X = Y Y^T$ ou existe um vetor y tal que $y X y < 0$.

Continuação da prova

Lema: Para toda matriz simétrica X , vale uma e apenas uma das seguintes alternativas: existe uma matriz quadrada Y tal que $X = Y Y^T$ ou existe um vetor y tal que $y X y < 0$.

Prova: Autovalores $\lambda_1, \dots, \lambda_n$ de X .
(Matriz real simétrica tem todos os autovalores reais.)

Continuação da prova

Lema: Para toda matriz simétrica X , vale uma e apenas uma das seguintes alternativas: existe uma matriz quadrada Y tal que $X = Y Y^T$ ou existe um vetor y tal que $y X y < 0$.

Prova: Autovalores $\lambda_1, \dots, \lambda_n$ de X .

(Matriz real simétrica tem todos os autovalores reais.)

Λ : matriz diagonal com $\lambda_1, \dots, \lambda_n$ na diagonal.

U : matriz ortogonal cuja coluna i é autovetor de λ_i .

Continuação da prova

Lema: Para toda matriz simétrica X , vale uma e apenas uma das seguintes alternativas: existe uma matriz quadrada Y tal que $X = Y Y^T$ ou existe um vetor y tal que $y X y < 0$.

Prova: Autovalores $\lambda_1, \dots, \lambda_n$ de X .

(Matriz real simétrica tem todos os autovalores reais.)

Λ : matriz diagonal com $\lambda_1, \dots, \lambda_n$ na diagonal.

U : matriz ortogonal cuja coluna i é autovetor de λ_i .

Verifique que $X = U \Lambda U^T$.

Continuação da prova

Lema: Para toda matriz simétrica X , vale uma e apenas uma das seguintes alternativas: existe uma matriz quadrada Y tal que $X = Y Y^T$ ou existe um vetor y tal que $y X y < 0$.

Prova: Autovalores $\lambda_1, \dots, \lambda_n$ de X .

(Matriz real simétrica tem todos os autovalores reais.)

Λ : matriz diagonal com $\lambda_1, \dots, \lambda_n$ na diagonal.

U : matriz ortogonal cuja coluna i é autovetor de λ_i .

Verifique que $X = U \Lambda U^T$.

Se X é positiva semidefinida, $\lambda_i \geq 0$ para todo i , e

$X = U \sqrt{\Lambda} \sqrt{\Lambda} U^T = (U \sqrt{\Lambda})(U \sqrt{\Lambda})^T$, ou seja, $Y = U \sqrt{\Lambda}$.

Continuação da prova

Lema: Para toda matriz simétrica X , vale uma e apenas uma das seguintes alternativas: existe uma matriz quadrada Y tal que $X = Y Y^T$ ou existe um vetor y tal que $y X y < 0$.

Prova: Autovalores $\lambda_1, \dots, \lambda_n$ de X .

(Matriz real simétrica tem todos os autovalores reais.)

Λ : matriz diagonal com $\lambda_1, \dots, \lambda_n$ na diagonal.

U : matriz ortogonal cuja coluna i é autovetor de λ_i .

Verifique que $X = U \Lambda U^T$.

Se X é positiva semidefinida, $\lambda_i \geq 0$ para todo i , e

$$X = U \sqrt{\Lambda} \sqrt{\Lambda} U^T = (U \sqrt{\Lambda})(U \sqrt{\Lambda})^T, \text{ ou seja, } Y = U \sqrt{\Lambda}.$$

Se X não é positiva semidefinida, $\lambda_i < 0$ para algum i .

Logo $X u_i = \lambda_i u_i$ e $u_i X u_i = \lambda_i u_i u_i = \lambda_i < 0$.

Matrizes positiva semidefinidas

Programa vetorial:

encontrar matrix real Y $n \times n$, onde $n = |V|$, que

maximize $\sum_{ij} w_{ij}(1 - (YY^T)_{ij})$

sujeito a $(YY^T)_{ii} = 1$ para cada i em V .

Matrizes positiva semidefinidas

Programa vetorial:

encontrar matrix real Y $n \times n$, onde $n = |V|$, que
maximize $\sum_{ij} w_{ij}(1 - (YY^T)_{ij})$
sujeito a $(YY^T)_{ii} = 1$ para cada i em V .

Programa semidefinido correspondente:

encontrar matrix real X $n \times n$, onde $n = |V|$, que
maximize $\sum_{ij} w_{ij}(1 - x_{ij})$
sujeito a $x_{ii} = 1$ para cada i em V ,
 $x_{ij} = x_{ji}$ para todo par i, j em V ,
 $X \succeq 0$.

Matrizes positiva semidefinidas

Programa vetorial:

encontrar matrix real Y $n \times n$, onde $n = |V|$, que
maximize $\sum_{ij} w_{ij}(1 - (YY^T)_{ij})$
sujeito a $(YY^T)_{ii} = 1$ para cada i em V .

Programa semidefinido correspondente:

encontrar matrix real X $n \times n$, onde $n = |V|$, que
maximize $\sum_{ij} w_{ij}(1 - x_{ij})$
sujeito a $x_{ii} = 1$ para cada i em V ,
 $x_{ij} = x_{ji}$ para todo par i, j em V ,
 $X \succeq 0$.

As condições técnicas estão satisfeitas.

O lema anterior dá um algoritmo de separação.

Correlational clustering

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Correlational clustering

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Dado um clustering \mathcal{C} ,

$\delta(\mathcal{C})$: arestas com extremos em conjuntos distintos de \mathcal{C}

$E(\mathcal{C})$: arestas com extremos num mesmo conjunto de \mathcal{C} .

Correlational clustering

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Dado um clustering \mathcal{C} ,

$\delta(\mathcal{C})$: arestas com extremos em conjuntos distintos de \mathcal{C}

$E(\mathcal{C})$: arestas com extremos num mesmo conjunto de \mathcal{C} .

Problema: Dados G , w^+ e w^- , encontrar um clustering \mathcal{C} que maximize $w^+(E(\mathcal{C})) + w^-(\delta(\mathcal{C}))$.

Correlational clustering

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Dado um clustering \mathcal{C} ,

$\delta(\mathcal{C})$: arestas com extremos em conjuntos distintos de \mathcal{C}

$E(\mathcal{C})$: arestas com extremos num mesmo conjunto de \mathcal{C} .

Problema: Dados G , w^+ e w^- , encontrar um clustering \mathcal{C} que maximize $w^+(E(\mathcal{C})) + w^-(\delta(\mathcal{C}))$.

$\frac{1}{2}$ -aproximação:

devolva o melhor entre $\mathcal{C}_1 = \{V\}$ e $\mathcal{C}_2 = \{\{v\} : v \in V\}$.

Correlational clustering

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Dado um clustering \mathcal{C} ,

$\delta(\mathcal{C})$: arestas com extremos em conjuntos distintos de \mathcal{C}

$E(\mathcal{C})$: arestas com extremos num mesmo conjunto de \mathcal{C} .

Problema: Dados G , w^+ e w^- , encontrar um clustering \mathcal{C} que maximize $w^+(E(\mathcal{C})) + w^-(\delta(\mathcal{C}))$.

$\frac{1}{2}$ -aproximação:

devolva o melhor entre $\mathcal{C}_1 = \{V\}$ e $\mathcal{C}_2 = \{\{v\} : v \in V\}$.

$$\text{OPT} \leq \sum_{ij \in E} (w_{ij}^+ + w_{ij}^-) = w^+(E(\mathcal{C}_1)) + w^-(\delta(\mathcal{C}_2))$$

Uma formulação

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Vamos mostrar uma $\frac{3}{4}$ -**aproximação** para o problema.

Uma formulação

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Vamos mostrar uma $\frac{3}{4}$ -**aproximação** para o problema.

e_k : vetor com k -ésima coordenada 1, zero nas demais.

Uma formulação

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Vamos mostrar uma $\frac{3}{4}$ -**aproximação** para o problema.

e_k : vetor com k -ésima coordenada 1, zero nas demais.

Ideia: $x_k = e_k$ sse v_k está no cluster k .

Uma formulação

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Vamos mostrar uma $\frac{3}{4}$ -**aproximação** para o problema.

e_k : vetor com k -ésima coordenada 1, zero nas demais.

Ideia: $x_k = e_k$ sse v_k está no cluster k .

Formulação alternativa:

Dados G , w^+ e w^- , encontrar x_1, \dots, x_n , onde $n = |V_G|$, que

maximizem $\sum_{ij} (w_{ij}^+(x_i x_j) + w_{ij}^-(1 - x_i x_j))$

sujeito a $x_i \in \{e_1, \dots, e_n\}$ para $i = 1, \dots, n$.

Relaxação vetorial

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Formulação alternativa:

Dados G , w^+ e w^- , encontrar x_1, \dots, x_n , onde $n = |V_G|$, que maximizem $\sum_{ij} (w_{ij}^+(x_i x_j) + w_{ij}^-(1 - x_i x_j))$ sujeito a $x_i \in \{e_1, \dots, e_n\}$ para $i = 1, \dots, n$.

Relaxação vetorial

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Formulação alternativa:

Dados G , w^+ e w^- , encontrar x_1, \dots, x_n , onde $n = |V_G|$, que maximizem $\sum_{ij} (w_{ij}^+(x_i x_j) + w_{ij}^-(1 - x_i x_j))$ sujeito a $x_i \in \{e_1, \dots, e_n\}$ para $i = 1, \dots, n$.

Relaxação vetorial:

Dados G , w^+ e w^- , encontrar vetores v_1, \dots, v_n que maximizem $\sum_{ij} (w_{ij}^+(v_i v_j) + w_{ij}^-(1 - v_i v_j))$ sujeito a $v_i v_i = 1$ para $i = 1, \dots, n$
 $v_i v_j \geq 0$ para $i, j = 1, \dots, n$
 $v_i \in \mathbb{R}^n$ para $i = 1, \dots, n$.

Relaxação vetorial

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Relaxação vetorial:

Dados G , w^+ e w^- , encontrar vetores v_1, \dots, v_n que

maximizem $\sum_{ij} (w_{ij}^+(v_i v_j) + w_{ij}^-(1 - v_i v_j))$

sujeito a $v_i v_i = 1$ para $i = 1, \dots, n$

$v_i v_j \geq 0$ para $i, j = 1, \dots, n$

$v_i \in \mathbb{R}^n$ para $i = 1, \dots, n$.

Relaxação vetorial

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Relaxação vetorial:

Dados G , w^+ e w^- , encontrar vetores v_1, \dots, v_n que

maximizem $\sum_{ij} (w_{ij}^+(v_i v_j) + w_{ij}^-(1 - v_i v_j))$

sujeito a $v_i v_i = 1$ para $i = 1, \dots, n$

$v_i v_j \geq 0$ para $i, j = 1, \dots, n$

$v_i \in \mathbb{R}^n$ para $i = 1, \dots, n$.

Como é uma relaxação do problema, vale que $z_{CC}^* \geq \text{OPT}$.

Relaxação vetorial

Dados $G = (V, E)$ e pesos $w_{ij}^+ \geq 0$ e $w_{ij}^- \geq 0$ para cada ij em E , um **clustering** é uma partição de V .

Relaxação vetorial:

Dados G , w^+ e w^- , encontrar vetores v_1, \dots, v_n que

maximizem $\sum_{ij} (w_{ij}^+(v_i v_j) + w_{ij}^-(1 - v_i v_j))$

sujeito a $v_i v_i = 1$ para $i = 1, \dots, n$

$v_i v_j \geq 0$ para $i, j = 1, \dots, n$

$v_i \in \mathbb{R}^n$ para $i = 1, \dots, n$.

Como é uma relaxação do problema, vale que $z_{CC}^* \geq \text{OPT}$.

Pode ser resolvida (dentro de um erro aditivo) em tempo polinomial.

Algoritmo

Dados G , w^+ e w^- , encontrar vetores v_1, \dots, v_n que

maximizem $\sum_{ij} (w_{ij}^+(v_i v_j) + w_{ij}^-(1 - v_i v_j))$

sujeito a $v_i v_i = 1$ para $i = 1, \dots, n$

$v_i v_j \geq 0$ para $i, j = 1, \dots, n$

$v_i \in \mathbb{R}^n$ para $i = 1, \dots, n$.

Algoritmo

Dados G , w^+ e w^- , encontrar vetores v_1, \dots, v_n que

maximizem $\sum_{ij} (w_{ij}^+(v_i v_j) + w_{ij}^-(1 - v_i v_j))$

sujeito a $v_i v_i = 1$ para $i = 1, \dots, n$

$v_i v_j \geq 0$ para $i, j = 1, \dots, n$

$v_i \in \mathbb{R}^n$ para $i = 1, \dots, n$.

MAXCC (G, w^+, w^-)

1 seja v uma solução ótima do programa vetorial

2 $r_1 \leftarrow \text{RANDESFERA}(V(G))$ $r_2 \leftarrow \text{RANDESFERA}(V(G))$

3 $R_1 \leftarrow \{i \in V(G) : r_1 v_i \geq 0 \text{ e } r_2 v_i \geq 0\}$

4 $R_2 \leftarrow \{i \in V(G) : r_1 v_i \geq 0 \text{ e } r_2 v_i < 0\}$

5 $R_3 \leftarrow \{i \in V(G) : r_1 v_i < 0 \text{ e } r_2 v_i \geq 0\}$

6 $R_4 \leftarrow \{i \in V(G) : r_1 v_i < 0 \text{ e } r_2 v_i < 0\}$

7 devolva $\{R_1, R_2, R_3, R_4\}$

Análise

Lema: Para x em $[0, 1]$,

$$\frac{\left(1 - \frac{1}{\pi} \arccos(x)\right)^2}{x} \geq 0,75 \quad \mathbf{e} \quad \frac{1 - \left(1 - \frac{1}{\pi} \arccos(x)\right)^2}{1 - x} \geq 0,75.$$

Análise

Lema: Para x em $[0, 1]$,

$$\frac{\left(1 - \frac{1}{\pi} \arccos(x)\right)^2}{x} \geq 0,75 \quad \text{e} \quad \frac{1 - \left(1 - \frac{1}{\pi} \arccos(x)\right)^2}{1 - x} \geq 0,75.$$

Teorema: Se W é o peso do clustering \mathcal{C} produzido pelo algoritmo MAXCC (G, w^+, w^-) então

$$E[W] \geq 0,75 \text{OPT}(G, w^+, w^-).$$

Análise

Lema: Para x em $[0, 1]$,

$$\frac{(1 - \frac{1}{\pi} \arccos(x))^2}{x} \geq 0,75 \quad \text{e} \quad \frac{1 - (1 - \frac{1}{\pi} \arccos(x))^2}{1 - x} \geq 0,75.$$

Teorema: Se W é o peso do clustering \mathcal{C} produzido pelo algoritmo MAXCC (G, w^+, w^-) então

$$E[W] \geq 0,75 \text{OPT}(G, w^+, w^-).$$

Prova: Seja X_{ij} a v.a. que vale 1 se i e j estão no mesmo cluster em \mathcal{C} , 0 caso contrário. Então

Análise

Lema: Para x em $[0, 1]$,

$$\frac{(1 - \frac{1}{\pi} \arccos(x))^2}{x} \geq 0,75 \quad \text{e} \quad \frac{1 - (1 - \frac{1}{\pi} \arccos(x))^2}{1 - x} \geq 0,75.$$

Teorema: Se W é o peso do clustering \mathcal{C} produzido pelo algoritmo MAXCC (G, w^+, w^-) então

$$\mathbb{E}[W] \geq 0,75 \text{OPT}(G, w^+, w^-).$$

Prova: Seja X_{ij} a v.a. que vale 1 se i e j estão no mesmo cluster em \mathcal{C} , 0 caso contrário. Então

$$\mathbb{E}[W] = \sum_{ij \in E} (w_{ij}^+ \mathbb{E}[X_{ij}] + w_{ij}^- (1 - \mathbb{E}[X_{ij}])).$$

Vamos calcular $\mathbb{E}[X_{ij}]$.

Análise

A probabilidade um hiperplano aleatório deixar v_i e v_j do mesmo lado é $1 - \frac{1}{\pi} \arccos(v_i v_j)$.

Análise

A probabilidade um hiperplano aleatório deixar v_i e v_j do mesmo lado é $1 - \frac{1}{\pi} \arccos(v_i v_j)$.

A probabilidade de v_i e v_j estarem no mesmo lado dos hiperplanos dados por r_1 e de r_2 é $(1 - \frac{1}{\pi} \arccos(v_i v_j))^2$, ou seja, $E[X_{ij}] = (1 - \frac{1}{\pi} \arccos(v_i v_j))^2$.

Análise

A probabilidade um hiperplano aleatório deixar v_i e v_j do mesmo lado é $1 - \frac{1}{\pi} \arccos(v_i v_j)$.

A probabilidade de v_i e v_j estarem no mesmo lado dos hiperplanos dados por r_1 e de r_2 é $(1 - \frac{1}{\pi} \arccos(v_i v_j))^2$, ou seja, $\mathbf{E}[X_{ij}] = (1 - \frac{1}{\pi} \arccos(v_i v_j))^2$.

Segue que

$$\begin{aligned} \mathbf{E}[W] &= \sum_{ij \in E} (w_{ij}^+ \mathbf{E}[X_{ij}] + w_{ij}^- (1 - \mathbf{E}[X_{ij}])) \\ &= \sum_{ij \in E} \left[w_{ij}^+ \left(1 - \frac{1}{\pi} \arccos(v_i v_j)\right)^2 \right. \\ &\quad \left. + w_{ij}^- \left(1 - \left(1 - \frac{1}{\pi} \arccos(v_i v_j)\right)^2\right) \right] \\ &\geq 0,75 \sum_{ij \in E} (w_{ij}^+ (v_i v_j) + w_{ij}^- (1 - v_i v_j)) \\ &\geq 0,75 \text{ OPT.} \end{aligned}$$