

Probabilistische Algorithmen.

Algorithmus für weighted Vertex Cover:

$$E[m_{pr}(x)] = 2m^*(x) \quad \text{Sei } U^* \in S^*(F).$$

$$\text{Zufallsvariable } X_v := \begin{cases} w(v) & v \in U \\ 0 & \text{sonst.} \end{cases}$$

$$\begin{aligned} E[m_{pr}(x)] &= E\left[\sum_{v \in V} w_v\right] = E\left[\sum_{v \in V} X_v\right] \\ &= E\left[\sum_{v \in V} X_v\right] = \sum_{v \in V} E[X_v] \end{aligned}$$

und

$$m^*(x) = \sum_{v \in U^*} w(v) \geq \sum_{v \in U^*} E[X_v]$$

$$\text{Also z.Z.} \quad \sum_{v \in V} E[X_v] \leq 2 \sum_{v \in U^*} E[X_v]$$

Für Kante $e = \{u, v\}$:

e wählt v wenn

e gewählt \rightarrow im nächsten Schritt v

$$\text{Zufallsvariable } X_{e,v} := \begin{cases} w(v) & e \text{ wählt } v \\ 0 & \text{sonst} \end{cases}$$

Ist $X_{e,v} = w(v)$, bzw. $X_{e',v} = 0$ für alle $e' \neq e$ mit ' $v \in e'$ '

$$\rightarrow X_v = \sum_{e \ni v} X_{e,v}$$

$$\leadsto E[X_v] = \sum_{e \ni v} E[X_{e,v}]$$

Für $e = \{u, v\}$ ist



$$E[X_{e,v}] = E[X_{e,u}] \quad , \text{ denn}$$

$$\begin{aligned} E[X_{e,v}] &= w(v) \cdot P[e \text{ wählt } v] \\ &= w(v) \cdot P[e \text{ gewählt}] \cdot \frac{w(u)}{w(u)+w(v)} \\ &= w(u) \cdot P[e \text{ gewählt}] \cdot \frac{w(v)}{w(u)+w(v)} \\ &= w(u) \cdot P[e \text{ wählt } u] \\ &= E[X_{e,u}] \end{aligned}$$

$$\text{Also: } \sum_{v \in U^*} E[X_v] = \sum_{v \in U^*} \sum_{e \ni v} E[X_{e,v}] \quad (*)$$

$$\text{und } \sum_{v \in U^*} E[X_v] = \sum_{v \in U^*} \sum_{e \ni v} E[X_{e,v}] = \sum_{v \in U^*} \sum_{\substack{e \ni v \\ e = \{u,v\}}} E[X_{e,u}]$$

Für $v \in U^*$ ist $u \in U^*$ für alle $u \in N(v)$.

~ Für jeden Summanden $E[X_{e,u}]$ in $(**)$ ist
gleiches in $(*)$

$$\Rightarrow \sum_{v \in U^*} E[X_v] \leq \sum_{v \in U^*} E[X_v]$$

Also:

$$\sum_{v \in V} E[X_v] = \sum_{v \in U^*} E[X_v] + \sum_{v \notin U^*} E[X_v] \leq 2 \sum_{v \in U^*} E[X_v] \quad \square$$

Einfacher SAT-Algorithmus

jede Variable $x(x) = \begin{cases} 0 & \text{wahr} \\ 1 & \text{falsch} \end{cases}$

faule Methode.

Für $C = a_1 \vee \dots \vee a_k$ gilt

$$Pr[C \text{ ist falsch}] = 1 - \frac{1}{2^k}$$

$$\text{Also } E[m(F, \alpha)] = \sum_{C \in F} Pr[C \text{ ist falsch}]$$

also falls $|C| \geq k$ für alle $C \in F$, dann

$$E[m(F, \alpha)] \geq m \left(1 - \frac{1}{2^k}\right)$$

$$\begin{aligned} \leadsto E[m(F, \alpha)] &\geq \frac{1}{2} m && \boxed{2\text{-Approx}} \\ &\geq \frac{3}{4} m && \text{alle Klauseln} \geq 2 \text{ Literale} \\ &\geq \frac{7}{8} m && \geq 3 \text{ Literale} \dots \end{aligned}$$

Analyse von LP-SAT

$$E[m(F, \alpha)] = \sum_{C \in F} Pr[C \text{ ist falsch}]$$

$$= \sum_{C_j \in F} \left(1 - \prod_{x \in C_j} (1 - y_i) \prod_{\bar{x} \in C_j} y_i\right)$$

$$\geq \sum_{C_j \in F} \alpha_k z_j^k \geq \alpha_k \sum z_i^k$$

$$\alpha_k \cdot m^*(LP(F)) \geq \alpha_k \cdot m^*(F) \quad \square$$

Lemma:

Beweis des Lemmas

obdA $C_j = x_{jA}^k - v x_{jB}^k$ positiv.

also z.z.:

$$1 - \prod_{i=1}^k (1 - \frac{C_{j,i}^k}{x_{j,i}^k}) \geq a_k z_j^k$$

$$\begin{aligned} 1 - \prod_{i=1}^k (1 - \frac{C_{j,i}^k}{x_{j,i}^k}) &\geq 1 - \left(\frac{\sum_{i=1}^k (1 - \frac{C_{j,i}^k}{x_{j,i}^k})}{k} \right)^k \\ &= 1 - \left(\frac{k - \sum_{i=1}^k \frac{C_{j,i}^k}{x_{j,i}^k}}{k} \right)^k \\ &= 1 - \left(1 - \frac{\sum_{i=1}^k \frac{C_{j,i}^k}{x_{j,i}^k}}{k} \right)^k \\ &= 1 - \left(1 - \frac{z_j^k}{k} \right)^k \geq a_k z_j^k \end{aligned}$$

da $f(y) = 1 - (1 - \frac{y}{k})^k$ ist konkav auf $(0, 1]$

und \Rightarrow gilt für $y=0$ und $y=1$:

$$1 - (1 - \frac{0}{k})^k \geq a_k \cdot 0 \quad \checkmark$$

$$1 - (1 - \frac{1}{k})^k \geq a_k \cdot 1 \quad \checkmark \quad \square$$

Alu. Performance für $k \in \mathbb{Z} \rightarrow \frac{4}{3}$

Für $k \geq 3$... mind. 1.587 ...

$$x_1 = \frac{1}{2} \quad a_1 = 1 \quad \rightarrow \quad x_1 + a_1 = \frac{3}{2}$$

$$x_2 = \frac{3}{4} \quad a_2 = \frac{3}{4} \quad \rightarrow \quad x_2 + a_2 = \frac{3}{2}$$

für $k \geq 3$ ist $x_k \geq \frac{3}{8}$

und $a_k \geq 1 - \frac{1}{e}$

| |
|----------------------------|
| $e = 2.7183$ |
| $\frac{1}{e} = 0.3679$ |
| $1 - \frac{1}{e} = 0.6321$ |

$$x_k + a_k \geq \frac{3}{8} + \left(1 - \frac{1}{e}\right) \geq \frac{3}{2}$$

Also

$$\frac{w_1 + w_n}{2} \geq \sum_{k \geq 1} \sum_{j \in F_k} \frac{3}{4} z_j^k \geq \frac{3}{4} \sum_{k \geq 1} \sum_{j \in F_k} z_j^k$$

$$\geq \frac{3}{4} \sum_{j \in F} z_j^k$$

$$= \frac{3}{4} \text{MK}(\text{LPT})$$

□

Also: Performance von Kombi SAT

ist mind.

$$\left| \frac{4}{3} \right|$$

Analyse von KombiSAT:

$$w_1 := E[m(F, \kappa_1)]$$

$$w_2 := E[m(F, \kappa_2)]$$

$$E[m(F, \kappa)] = \max(w_1, w_2)$$

$$\text{z.z.: } \max(w_1, w_2) \geq \frac{3}{4} m^*(F)$$

$$\text{Es gilt } \max(w_1, w_2) \geq (w_1 + w_2) / 2$$

$$\text{und } m^*(F) \leq m^*(LP(F))$$

$$\text{also reicht z.z. } \frac{w_1 + w_2}{2} \geq \frac{3}{4} m^*(LP(F))$$

$$\text{Sei } \gamma_k := \left(1 - \frac{1}{2^k}\right) \quad F_k := \{C \in F, |C| = k\}$$

$$w_1 \geq \sum_{k \geq 1} \sum_{C \in F_k} \gamma_k \geq \sum_{k \geq 1} \sum_{C \in F_k} \gamma_k z_j^k \quad *$$

nach Lemma

$$w_2 \geq \sum_{k \geq 1} \sum_{C \in F_k} a_k z_j^k \quad **$$

(*) + (**):

$$\frac{w_1 + w_2}{2} \geq \sum_{k \geq 1} \sum_{C \in F_k} \frac{\gamma_k + a_k}{2} z_j^k$$

Symmetrische Matrizen, positiv semidefinit

(2) \rightarrow (1)

Sei λ Eigenwert von A , also $Av = \lambda v$ für ein $v \in \mathbb{R}^n$.

Dann ist $0 \leq v^T Av = \lambda v^T v$.

Da $v^T v \geq 0$, folgt $\lambda \geq 0$ \square

(1) \rightarrow (3)

$\lambda_1, \dots, \lambda_n$ Eigenwerte v_1, \dots, v_n Eigenvektoren orthonormal.
basis.

$$Q := (v_1 \dots v_n) \quad \Lambda := \begin{pmatrix} \lambda_1 & & 0 \\ & \ddots & \\ 0 & & \lambda_n \end{pmatrix}$$

$Av_i = \lambda_i v_i$ für alle i , also $AQ = Q\Lambda$

Q orthogonal $\rightarrow QQ^T = I \rightarrow Q^T = Q^{-1}$

also $A = Q\Lambda Q^T$

$$D := \begin{pmatrix} \sqrt{\lambda_1} & & 0 \\ & \ddots & \\ 0 & & \sqrt{\lambda_n} \end{pmatrix} \rightarrow \Lambda = DD^T$$

also $A = QDD^TQ^T = (QD)(QD)^T$ \square

(3) \rightarrow (2) Sei $x \in \mathbb{R}^n$

$$x^T Ax = x^T W^T W x = (Wx)^T (Wx) \geq 0 \quad \square$$

Konstruktion im Beweis (1)-(3) braucht Eigenwerte $\lambda_1, \dots, \lambda_n$,
(Spektrum) dies ist exponentiell zu berechnen.

Gibt es einen besseren Algorithmus:

Cholesky :

Rekursion nach Dimension :

$$\det M = 1$$

$$M = (a)$$

$$a > 0 \quad \sim \sqrt{a} \text{ ok.}$$

$$(\sqrt{a})(\sqrt{a}) = (a) \quad \checkmark$$

$$\text{Ist } M = \begin{pmatrix} a & q^T \\ q & N \end{pmatrix},$$

$$\text{dann ist } N - \frac{1}{a} q q^T \succeq 0. \quad (\text{i.B.})$$

$$\text{Sei } V \text{ mit } V^T V = N - \frac{1}{a} q q^T.$$

$$\begin{pmatrix} \sqrt{a} & 0^T \\ \frac{1}{\sqrt{a}} q & V^T \end{pmatrix} \begin{pmatrix} \sqrt{a} & \frac{1}{\sqrt{a}} q^T \\ 0 & V \end{pmatrix}$$

$$\Rightarrow \begin{pmatrix} a & q^T \\ q & \frac{1}{a} q q^T + V^T V \end{pmatrix}$$

$$= \begin{pmatrix} a & q^T \\ q & \frac{1}{a} q q^T + N - \frac{1}{a} q q^T \end{pmatrix}$$

$$= \begin{pmatrix} a & q^T \\ q & N \end{pmatrix}$$

Semidefinite Programmierung

Verallgemeinerung von LP.

Alle Constraints sind linear, außer

$$X \succeq 0. \quad \cong \quad \text{unendlich viele lineare} \\ \text{Constraints} \quad y^T X y \geq 0 \quad \forall y \in \mathbb{R}^n.$$

Exakte Lösung nicht effizient möglich
(oder überhaupt nicht.)

aber beliebig gute Näherung?

Laufzeit abhängig von $|P|$ und $\frac{1}{\epsilon}$ (Näherung)

und r ! In allen Anwendungen r

(Norm der Lösungen) klein.

MAXIMUM CUT

↳ lokale Suche

Analyse des Algorithmus:

Betrachte $e = \{u, v\}$

$$\begin{aligned} \Pr[e \text{ durchtrennt}] &= \Pr[u \in V_0, v \in V_1] + \Pr[u \in V_1, v \in V_0] \\ &= \frac{1}{4} + \frac{1}{4} = \frac{1}{2} \end{aligned}$$

$$E[m_p] = \sum_{e \in E} \Pr[e \text{ durchtrennt}] = \sum_{e \in E} \frac{1}{2} = \frac{1}{2} |E| \geq \frac{1}{2} m^k. \quad \square$$

Quadratisches Programm

$$y_i \in \{\pm 1\} \quad \Leftrightarrow \quad y_i^2 = 1$$

$\{v_i, v_j\}$ durchheunt
nicht

$$y_i y_j = -1$$

$$y_i y_j = 1$$

$$m \quad \frac{1}{2} \sum_{\{v_i, v_j\}} (1 - y_i y_j)$$

Vektorprogramm

ersetze $y_i \in \mathbb{Z}$ durch $z_i \in \mathbb{R}^n$

Produkt $y_i y_j \rightsquigarrow$ Skalarprodukt $z_i^T z_j$
 $y_i^2 = 1 \rightsquigarrow \|z_i\| = 1$ (Einheitsvektor)

$y_1 \dots y_n$ Lösung für Max (ut)

$\rightsquigarrow z := \begin{pmatrix} y_1 \\ 0 \\ \vdots \\ 0 \end{pmatrix}$ Lösung für Vek(G)

$$z_i^T z_j = y_i y_j, \quad \text{also}$$

$$m(z_1 \dots z_n) = m(y_1 \dots y_n)$$

Optimale Lsg $y_1^* \dots y_n^* \rightsquigarrow$ Lösung mit gleichem Wert für Vek(G)

Optimum für Vek(G) höchstens besser! \blacktriangleright

$$m^*(\text{Vek}(G)) \geq m^*(G).$$

SDP(G) äquivalent zu Vek(G)

Sei z_1, \dots, z_n Lösung von Vek(G).

Matrix $X = (x_{ij})$ definiert durch $x_{ij} = z_i^T z_j$

also $Z = (z_1 \dots z_n) \rightsquigarrow X = Z^T Z$

\rightsquigarrow Lösung von SDP(G), da

$x_{ii} = 1$, da $\|z_i\| = 1$

X pos. semidefinit nach Satz 0

Umgekehrt

X Lösung von SDP(G), Cholesky-Faktorisierung $X = Z^T Z$

$Z = (z_1 \dots z_n)$ z_i : Spaltenvektoren von Z .

$z_i^T z_j = x_{ij}$ \rightsquigarrow Lösung von Vek(G), d.


$\|z_i\| = 1$, da $x_{ii} = z_i^T z_i = 1$ \square

Algorithmus von G.-W.

Aus Lösung z_1, \dots, z_n von Vek(G)

Lösung von MAX CUT für G .

In 2D:



z_1, \dots, z_n Vektoren auf der $n-1$ -dimensionalen Einheitskugel

Teil durch Hyperebene H
2 Halbkugeln

Hyperebene $H \equiv$ Orthogonaler Vektor \vec{p}

oberhalb von $H \iff \vec{p}^T z_i \geq 0$


unterhalb $\iff \vec{p}^T z_i < 0$

\rightsquigarrow Schritt

Analyse:

Die Wahrscheinlichkeit, dass x_i, x_j in verschiedenen Mengen liegen, also $\{x_i, x_j\}$ getrennt wird, ist

$$\frac{1}{\pi} \arccos(u_i^T u_j)$$



$$\cos(\alpha) = u_i^T u_j, \text{ also}$$

$$\alpha := \arccos(u_i^T u_j)$$

p' = Projektion von p auf $\text{span}(u_i, u_j)$

$$p^T u_i = p'^T u_i \quad \text{und} \quad p^T u_j = p'^T u_j$$

Liefer verschiedene \sqrt{z} , wenn p' in grauen Segment.

p gleichverteilt in S^{n-1} \rightarrow p' gleichverteilt (Radley).

$$\rightarrow \text{Wahrscheinlichkeit} = \frac{2\alpha}{2\pi} = \frac{1}{\pi} \arccos u_i^T u_j \quad \square$$

Lemma $\forall z \in [-1, 1] \quad \frac{1}{\pi} \arccos z \geq 0.87856 \frac{1-z}{2}$

$$\text{Also } E(m_{\text{getrennt}}) = \sum_{(x_i, x_j) \in E} \mathbb{P}[(x_i, x_j) \text{ getrennt}]$$

$$= \sum_{(x_i, x_j) \in E} \frac{1}{\pi} \arccos(u_i^T u_j)$$

$$\geq 0.878567 \cdot \sum_{(x_i, x_j) \in E} \frac{1}{2} (1 - u_i^T u_j)$$

$$\text{für } \epsilon \ll 7 \cdot 10^{-6}$$

$$\geq 0.878567 (m^* - \epsilon) \geq 0.87856 m^* \quad \square$$