

Úvod do aproximačních a pravděpodobnostních algoritmů

Jiří Sgall

8. ledna 2020

1 Úvod

V této přednášce se budeme zabývat dvěma moderními oblastmi teorie algoritmů: algoritmy, které hledají nikoli optimální řešení ale pouze dostatečně dobré řešení, a algoritmy, které používají náhodnost.

1.1 Těžké úlohy a přístupy k jejich řešení

Ze základních přednášek známe klasifikaci úloh na řešitelné v polynomiálním čase – ty považujeme za efektivně řešitelné – a NP -těžké – ty považujeme za těžké.

Mezi polynomiálně řešitelné úlohy patří z kombinatorických problémů hledání nejkratší cesty, hledání minimální kostry grafu, hledání minimálních řezů, toky v síti, párování v grafech a další, ale také lineární programování nebo řešení soustav lineárních rovnic.

Mezi NP -těžké problémy patří splnitelnost a její varianty, problém batohu a řada dalších úloh s dělením vážených objektů do skupin (rozvrhování, bin packing), a opět řada kombinatorických problémů: barevnost grafu a hledání nezávislé množiny, Hamiltonovská cesta a problém obchodního cestujícího, hledání maximálního řezu, možinové pokrytí atd.

Tato klasifikace je důležitá, i když samozřejmě nepostihuje všechny praktické aspekty. Některé polynomiální algoritmy jsou poměrně složité, např. pro toky nebo párování, jiné nejsou úplně uspokojivé z jiných důvodů, např. algoritmy pro lineární programování jsou polynomiální pouze v bitové velikosti vstupu. Naopak některé NP -těžké problémy jsou v praxi docela dobře řešitelné, například problém obchodního cestujícího, problém batohu nebo některé varianty rozvrhování.

Řada obtížných kombinatorických úloh ovšem patří mezi ty, které chceme v praxi řešit, a proto se studuje řada přístupů. Jmenujme některé z nich:

- **Heuristiky:** Studují se algoritmy, které je obtížné teoreticky analyzovat, nefungují nutně pro všechny vstupy, ale v různých situacích se osvědčují, což se prokazuje např. testováním na různých benchmarkových datech. Častou variantou jsou algoritmy, které se snaží chytře prohledat prostor všech řešení, např. algoritmy branch-and-bound a algoritmy lokálního prohledávání. Také sem patří algoritmy založené na metodách umělé inteligence jako simulované žíhání, genetické algoritmy apod.
- **Speciální případy:** Studují se zajímavé podproblémy, např. pro grafové problémy varianty omezené na různé třídy grafů, nebo jinak omezené množiny vstupů u jiných problémů. V jistém smyslu sem patří i studium algoritmů pro vstupy z dané náhodné distribuce.

- **Podrobnější analýza času běhu algoritmu:** V parametrizované složitosti se studuje závislost času běhu nejen na velikosti vstupu ale i na hodnotě dalšího parametru či více parametrů. Je také zajímavé studovat časovou složitost algoritmů, které nejsou polynomiální: algoritmus s časovou složitostí $O(1.5^n)$ může být mnohem užitečnější než prohledávání hrubou silou se složitostí $O(2^n)$, čas $2^{O(n)}$ je velký pokrok proti $2^{O(n \log n)}$ nebo $2^{O(n^2)}$.
- **Přibližné řešení:** U optimalizačních problémů, které měří kvalitu řešení (nejde tedy o rozhodovací problémy), se můžeme spokojit s řešením, které není optimální ale zároveň máme záruku, že se jeho kvalita od optima příliš neliší.

V naší přednášce se budeme zabývat posledním uvedeným přístupem. Budou nás zajímat algoritmy, které fungují pro všechny vstupy, vždy dají řešení, které je skoro optimální, a pracují v polynomiálním čase. Takovým algoritmům říkáme aproximační algoritmy.

Budeme se zabývat několika základními metodami a příklady návrhu aproximačních algoritmů. V první skupině půjde o kombinatorické algoritmy založené na hladových algoritmech a také na lokálním prohledávání (v případech, kdy nejde jen o heuristiku, ale umíme dokázat odhad na kvalitu řešení). Ve druhé skupině půjde o algoritmy založené na lineárním programování a různých metodách zaokrouhlování jejich řešení; v současném algoritmičtém výzkumu se jedná o jednu z nejproduktivnějších technik.

1.2 Použití náhodnosti v algoritmech

Náhodnost patří dnes ke standardním technikám návrhu algoritmů, ale má i bohatou historii. Studium stochastických jevů a statistické metody patří mezi klasické matematické obory; při studiu algoritmů se pak aplikují například při analýze rozsáhlých dat pomocí náhodného výběru vzorků, či naopak při již zmíněné analýze algoritmů při výběru vstupu z dané distribuce. Pravděpodobnost a její použití je klíčové ve von Neumannově teorii (maticových) her, kde je nutné uvažovat smíšené, tj. pravděpodobnostní, strategie. V oblasti počítačových her je náhodnost samozřejmá – deterministická hra by většinou prostě nebyla zajímavá.

V naší přednášce se budeme zabývat použitím náhodnosti, které dává zaručené výsledky pro všechny vstupy, a záruka bude mít většinou podobu odhadu na průměrnou kvalitu řešení nebo na průměrný čas běhu algoritmu. Takovým algoritmům říkáme pravděpodobnostní algoritmy.

Použití náhodnosti je z mnoha pohledů atraktivní, ale má samozřejmě svou cenu. Získat zdroj skutečné náhodnosti není snadné, z praktického hlediska skoro nemožné. Běžně se tedy náhodnost nahrazuje pseudonáhodnými generátory, které mají problémy jak praktické tak teoretické. I když pseudonáhodný generátor projde řadou testů, nemůžeme zaručit, že bude pro danou aplikaci fungovat dobře – a z historie známe řadu případů, kdy nastal problém ať už kvůli špatné konstrukci generátoru nebo kvůli jeho špatnému použití. Z teoretického hlediska není situace lepší: použitím generátoru se z pravděpodobnostního algoritmu fakticky stává deterministický a tím pádem do značné míry ztrácíme výhody použití náhodnosti.

V teorii algoritmů je tak častá situace, kdy navrhne pravděpodobnostní algoritmus, a pak studujeme, zda v něm použití náhodnosti můžeme omezit a ideálně získat deterministický algoritmus. Tomu říkáme derandomizace.

Použití náhodnosti v teorii algoritmů můžeme rozdělit do tří skupin.

- **Efektivnější algoritmy.** Nejprirozenějším cílem je navrhnout pravděpodobnostní algoritmy pro kombinatorické problémy, které budou rychlejší či jinak měřitelně lepší

než deterministické. To má ovšem základní problém: Dokázat, že dobrý deterministický algoritmus pro daný problém neexistuje, umíme jen ve velmi omezených případech. Realisticky tedy navrhujeme většinou pravděpodobnostní algoritmy, které jsou efektivnější než všechny známé deterministické algoritmy. Některé se později daří derandomizovat, příkladem může být algoritmus na testování prvočíselnosti.

- **Koncepční jednoduchost.** Často je hlavní výhodou pravděpodobnostního algoritmu jeho jednoduchost. To je analogické kombinatorickým důkazům pravděpodobnostní metodou, kdy často studium vlastností náhodně vybraného objektu je podstatně snazší než konstrukce objektu s danou vlastností. U algoritmů je pak efektivita spíše vedlejším cílem a často je spíše srovnatelná s nejlepšími deterministickými algoritmy, ne výrazně lepší. Dobrým příkladem je Karger-Steinův algoritmus na hledání minimalního řezu.
- **Situace neřešitelné deterministicky.** Pokud se vzdálíme světu kombinatorických problémů, je řada scénářů, které dokazatelně nemají deterministické řešení, jako už uvedené maticové hry. V algoritmickém světě jsou to například tyto:

- Kryptografie. Moderní kryptografie s veřejným klíčem se bez náhodnosti neobejde.
- Distribuované protokoly. Bez náhodnosti není možné vybrat jeden počítač mezi mnoha identickými. Také třeba síťové protokoly používají náhodnost.
- Interaktivní protokoly a důkazy. I mimo oblast kryptografie se studují různé varianty interaktivních protokolů, které se často neobejdou bez náhodnosti. Dobrým příkladem je PCP věta, která říká, že namísto ověřování celého důkazu nalezení slova do jazyka v NP je možné přechít jen konstantně mnoho náhodně zvolených bitů důkazu (pro pečlivě modifikovaný formát důkazů a pečlivě zvolené náhodné bity).
- Online a streamovací algoritmy. Algoritmy, které dostávají vstup a generují výstup po částech nebo mají jinak omezený přístup ke vstupu, mohou díky náhodnosti zlepšit své vlastnosti.

V naší přednášce uvedeme příklady algoritmů z řady oblastí: aproximační a paralelní algoritmy pro kombinatorické problémy, datové struktury, distribuované protokoly. Zmíníme i jednu techniku derandomizace.

2 Pravděpodobnost – základní pojmy

Definice 2.1. **Pravděpodobnostní prostor** je trojice (Ω, Σ, Pr) , kde Ω je množina, jejíž prvky nazýváme **elementární jevy**, $\Sigma \subseteq 2^\Omega$ je množina podmnožin Ω , jejíž prvky nazýváme **jevy**, a $Pr : \Sigma \rightarrow [0, 1]$ je funkce nazývaná **pravděpodobnost**.

Množina jevů vždy obsahuje Ω a je uzavřená na doplňky a spočetná (a konečná) sjednocení.

Pravděpodobnost splňuje $Pr[\Omega] = 1$ a je aditivní pro spočetné (a konečné) množiny po dvou disjunktních jevů, tedy pro posloupnost po dvou disjunktních jevů E_1, E_2, \dots platí

$$Pr \left[\bigcup_{i=1}^{\infty} E_i \right] = \sum_{i=1}^{\infty} Pr[E_i].$$

Doplňkový jev k A značíme $\bar{A} = \Omega \setminus A$.

Z definice plyne řada dalších intuitivních vztahů: $Pr[\emptyset] = 0$, a obecně $Pr[\bar{A}] = 1 - Pr[A]$, pro jevy $A \subseteq B$ platí $Pr[A] \leq Pr[B]$ a pro obecnou posloupnost jevů $Pr[\bigcup_{i=1}^{\infty} E_i] \leq \sum_{i=1}^{\infty} Pr[E_i]$.

I když to definice nevyžaduje, my budeme vždy pracovat s prostory, které obsahují všechny elementární jevy jako jevy, tj. Σ obsahuje všechny jednoprvkové podmnožiny Ω . Často nebudeme rozlišovat jednoprvkový jev a jemu odpovídající elementární jev. Většinou je množina jevů zřejmá z kontextu, pak je třeba specifikovat pouze funkci pravděpodobnosti a mluvíme o pravděpodobnostním **rozdělení**.

My se nejčastěji setkáme s diskrétními prostory, kde Ω je konečná nebo spočetná. Pak Σ obsahuje všechny podmnožiny a pravděpodobnost všech jevů je určena pravděpodobnostmi všech elementárních jevů.

Nejběžnějším příkladem konečného pravděpodobnostního prostoru je **rovnoměrné rozdělení** na konečné množině Ω , kde $Pr[A] = |A|/|\Omega|$ pro každý jev A . Příklady jsou hod kostkou nebo mincí (tj. náhodný bit), náhodná podmnožina n -prvkové množiny, náhodná permutace, náhodný graf atd. Má samozřejmě smysl uvažovat i jiná rozdělení; pokud však rozdělení nespecifikujeme, máme u konečné množiny vždy na mysli rovnoměrné.

Na spočetné množině rovnoměrné rozdělení neexistuje. Důležitým příkladem je **geometrické rozdělení** (přesněji jeho speciální případ). Pro $\Omega = \{1, 2, \dots\}$ definujeme $Pr[i] = 2^{-i}$. Toto rozdělení popisuje např. počet hodů mincí, než poprvé padne hlava.

V klasické teorii pravděpodobnosti se setkáváme především se spojitými rozděleními na $\Omega \subseteq \mathbb{R}$. Jevy jsou pak nikoliv všechny podmnožiny \mathbb{R} ale jen (např. lebesgueovsky) měřitelné množiny a pro formální vybudování pravděpodobnosti potřebujeme teorii míry. Pravděpodobnost elementárních jevů je typicky 0.

Spojitá rozdělení na \mathbb{R} se pak popisují funkcí hustoty pravděpodobnosti $f: \mathbb{R} \rightarrow [0, +\infty)$ splňující $\int_{-\infty}^{+\infty} f(t) dt = 1$, která je analogií pravděpodobnosti elementárních jevů pro diskrétní pravděpodobnostní prostory. Pro množinu A pak dostáváme $Pr[A] = \int_{-\infty}^{+\infty} \chi_A(t) f(t) dt$, kde χ_A je charakteristická funkce množiny A . Používá se také distribuční funkce $F(x) = Pr[(-\infty, x]] = \int_{-\infty}^x f(t) dt$.

Na nespočetné množině **rovnoměrné rozdělení** může existovat, např. na jednotkovém intervalu $I = [0, 1]$ je dáno funkcí hustoty $f(x) = \chi_I(x)$. Obecněji, rovnoměrné rozdělení existuje na podmnožinách \mathbb{R} , které mají konečnou míru; oproti tomu na celém \mathbb{R} nebo na intervalu $[0, +\infty)$ rovnoměrné rozdělení neexistuje.

Náhodná proměnná X je funkce, která každému elementárnímu jevu přiřadí hodnotu; speciálně reálná náhodná proměnná je funkce $X: \Omega \rightarrow \mathbb{R}$. (Mluvíme-li o jiných než diskrétních pravděpodobnostních prostorech, je potřeba přidat podmínku, že funkce je měřitelná – a tedy také je-li obor hodnot nespočetný, musíme na něm mít míru.)

Střední hodnota $E[X]$ reálné náhodné proměnné X udává její “průměrnou” hodnotu. Pro diskrétní rozdělení se definuje jako $\sum_{\omega \in \Omega} X(\omega) \cdot Pr[\omega]$ a pro spojitá rozdělení na \mathbb{R} s hustotou f jako $\int_{-\infty}^{+\infty} X(t) f(t) dt$. Přímo z definice lze odvodit dvě důležité vlastnosti střední hodnoty. Pokud X je nezáporná, platí $Pr[X \geq t \cdot E[X]] \leq 1/t$ (Markovova nerovnost). Střední hodnota je lineární, tj. $E[X + Y] = E[X] + E[Y]$ pro libovolné náhodné proměnné (a bez dalších podmínek např. na nezávislost).

Indikátorová náhodná proměnná X nabývá hodnot 0 a 1; je to vlastně jen jiný pohled na jev $A = \{\omega \mid X(\omega) = 1\}$. Platí $E[X] = Pr[A]$. Spolu s linearitou střední hodnoty jsou indikátorové proměnné dobrým nástrojem pro odhadování počtu splněných jevů v nějakém systému.

Podmíněná pravděpodobnost jevu A za podmínky B formalizuje situaci, kdy víme, že jev B nastal. Formálně definujeme pro B takové, že $Pr[B] > 0$, podmíněnou pravděpodobnost takto:

$$Pr[A|B] = \frac{Pr[A \cap B]}{Pr[B]}.$$

Pokud $\{B_i\}_{i \in I}$ je rozklad množiny elementárních jevů na jevy nenulové pravděpodobnosti, pak platí tzv. tvrzení o úplné pravděpodobnosti:

$$Pr[A] = \sum_{i \in I} Pr[A|B_i]Pr[B_i].$$

Jevy A a B jsou nezávislé, jestliže platí $Pr[A \cap B] = Pr[A] \cdot Pr[B]$. To je ekvivalentní jak tomu, že $Pr[A|B] = Pr[A]$, tak tomu, že $Pr[B|A] = Pr[B]$. Odpovídá to tedy intuitivní představě, že pravděpodobnost jednoho z jevů se nezmění, pokud víme, zda druhý jev nastane.

Pro systém více jevů nestačí požadovat, že každé dva jsou nezávislé (obdobně jako lineární nezávislost systému vektorů se nedá odvodit z lineární nezávislosti dvojic vektorů). **Jevy $\{A_i\}_{i \in I}$ jsou nezávislé**, jestliže pro každou podmnožinu $J \subseteq I$ platí

$$Pr \left[\bigcap_{i \in J} A_i \right] = \prod_{i \in J} Pr[A_i].$$

Pokud tato podmínka platí jen pro J s nejvýše k prvky, řekneme, že jevy $\{A_i\}_{i \in I}$ jsou **po k nezávislé**. To je podstatně slabší vlastnost, než nezávislost.

Náhodné proměnné $\{X_i\}_{i \in I}$ na diskrétním pravděpodobnostním prostoru jsou nezávislé, jestliže pro každou podmnožinu $J \subseteq I$ a každé hodnoty $y_i, i \in J$ platí

$$Pr[(\forall i \in J)(X_i = y_i)] = \prod_{i \in J} Pr[X_i = y_i].$$

Pokud tato podmínka platí jen pro J s nejvýše k prvky, řekneme, že proměnné $\{X_i\}_{i \in I}$ jsou **po k nezávislé**. Pokud pravděpodobnostní prostor není diskrétní, je potřeba namísto jevů $X_i = y_i$ použít jevy $X_i \in Y_i$, kde Y_i je libovolná měřitelná podmnožina oboru hodnot. Pro reálné náhodné proměnné stačí uvažovat jevy $X_i \leq y_i$ pro $y_i \in \mathbb{R}$.

3 Pravděpodobnostní algoritmy – model a příklady

Obvyklým teoretickým modelem pravděpodobnostních výpočtů jsou Turingovy stroje s dodatečnou páskou, která obsahuje spočetně mnoho nezávislých náhodných bitů. Stejně dobře můžeme použít jiný výpočetní model a přidat instrukci s náhodným výběrem jedné ze dvou možností. Je i možné přidat instrukci výběru s jinými pravděpodobnostmi, kterou lze v předchozích modelech efektivně simulovat.

Kdy považujeme pravděpodobnostní algoritmus za dobrý? Rozhodně by měl být efektivní.

Pokud požadujeme, aby pravděpodobnostní algoritmus vždy běžel v polynomiálním čase, musíme připustit nějakou chybu; takové algoritmy se někdy nazývají Monte Carlo. U rozhodovacích problémů typicky připouštíme konstantní pravděpodobnost chyby. Bud' oboustranou, pak při každém vstupu požadujeme, aby pravděpodobnost správné odpovědi byla alespoň $2/3$; třída takto rozpoznatelných jazyků se nazývá *BPP*. Lepší je, pokud je chyba jednostranná. Např. algoritmus všechny vstupy mimo jazyk vždy zamítne, ale slova z jazyka přijme

s pravděpodobností alespoň $1/2$; tato třída se nazývá *RP*. (Uvědomme si, že pokud pro slova jazyka požadujeme pouze nenulovou pravděpodobnost přijetí, dostáváme třídu *NP*.) Přesné hodnoty konstant jsou tradiční ale nikoli podstatné, protože algoritmy můžeme několikrát opakovat a chybu zmenšit.

Druhá možnost je požadovat, aby algoritmus vždy odpověděl správně. Pak ale musíme oslabit požadavek na efektivitu: požadujeme, aby průměrný čas běhu byl polynomiální. Takové algoritmy se někdy nazývají Las Vegas algoritmy; třída takto rozpoznatelných jazyků se nazývá *ZPP*.

3.1 Quicksort

Známý deterministický třídící algoritmus QUICKSORT pracuje na náhodném vstupu v průměrném čase $O(n \log n)$, ale na některých vstupech potřebuje kvadratický čas. My pravděpodobnostní analýzu využijeme k tomu, abychom navrhli pravděpodobnostní variantu algoritmu, která každý jednotlivý vstup setřídí v průměrném čase $O(n \log n)$. Technicky se jedná o naprosto analogický důkaz, ale v jeho interpretaci je podstatný rozdíl.

Pro jednoduchost prezentace předpokládáme, že všechny tříděné prvky jsou různé.

ALGORITMUS QS(S)

- Pokud $|S| \leq 1$, *vystup* S (jako prázdnou nebo jednoprvkovou posloupnost).
- Vyber uniformně náhodně pivot $p \in S$.
- $A := \{a \in S \mid a < p\}$; $B := \{b \in S \mid b > p\}$.
- *Výstup*: posloupnost QS(A), p, QS(B).

Všechny náhodné volby jsou nezávislé.

Věta 3.1. *Pro každý vstup s n prvky je střední doba běhu algoritmu QUICKSORT s náhodným výběrem pivotů $O(n \log n)$. Střední počet porovnání je nejvýše $2nH_n$, kde $H_n = \sum_{k=1}^n \frac{1}{k}$ je n-té harmonické číslo.*

Důkaz. Zafixujme vstupní posloupnost. Nechť $A_{i,j}$ je jev, který nastane, když v průběhu algoritmu porovnáme i -tý a j -tý prvek ve výsledném pořadí, pro $j > i$.

Pokud jsou v dané úrovni rekurze i -tý a j -tý prvek v S , porovnáme je právě tehdy, pokud jeden z nich zvolíme za pivot, a navíc v takovém případě je porovnáme jen jednou. Pokud pivot leží mezi i -tým a j -tým prvkem, pak tyto dva prvky už nikdy neporovnáme, protože nebudou společně ani v A ani v B . Pokud je pivot menší nebo větší než oba prvky, tak naopak oba postoupí do další úrovně rekurze společně buď v A nebo v B . Máme tedy $j + 1 - i$ voleb pivota tak, že prvky spolu nepostoupí do další úrovně a jen 2 z těchto voleb vedou k porovnání. Uvážíme-li toto pro poslední úroveň rekurze, kam prvky postoupí společně, plyne z toho

$$Pr[A_{i,j}] = \frac{2}{j + 1 - i}.$$

Přesněji bychom měli argumentovat, že pro každý možný vrchol stromu rekurze je toto podmíněná pravděpodobnost porovnání za podmínky, že toto je poslední rekurzivní volání, kam postoupily oba uvažované prvky. Protože jevy v podmínkách pro různé uzly dohromady tvoří rozklad pravděpodobnostního prostoru, podle tvrzení o úplné pravděpodobnosti je stejná i nepodmíněná pravděpodobnost porovnání.

Nechť X je náhodná proměnná, která udává počet porovnání v průběhu algoritmu na daném vstupu. Nechť $X_{i,j}$ je indikátorová náhodná proměnná jevu $A_{i,j}$, tj $X_{i,j} = 1$ pokud porovnáme i -tý a j -tý prvek a $X_{i,j} = 0$ jinak. Pak střední počet porovnání odhadneme jako

$$E[X] = \sum_{i=1}^{n-1} \sum_{j=i+1}^n E[X_{i,j}] = \sum_{i=1}^{n-1} \sum_{j=i+1}^n Pr[A_{i,j}] \leq \sum_{i=1}^{n-1} \sum_{k=1}^{n-1} \frac{2}{k} < 2n \cdot \sum_{k=1}^n \frac{1}{k} = 2n \cdot H_n,$$

kde $H_n = \frac{1}{1} + \frac{1}{2} + \dots + \frac{1}{n}$ se nazývá n -té harmonické číslo a platí $H_n \approx \ln n$.

Doba běhu algoritmu je lineární v počtu porovnání. □

3.2 Konflikty v distribuovaném systému

Předpokládejme, že máme jednoduchý distribuovaný protokol, kde se n stejných procesů snaží o exkluzivní přístup ke sdílenému prostředku (paměti, databázi, ...). Přímá komunikace mezi procesy není možná. Procesy jsou synchronizované, v každém cyklu proces může požadovat přístup. Uspěje ovšem jedině tehdy, když je jediným procesem, který přístup požaduje.

Zajímá nás algoritmus, který co nejdříve uspokojí všechny procesy. Deterministické řešení neexistuje, protože všechny procesy se budou o přístup pokoušet ve stejných cyklech. Předvedeme pravděpodobnostní algoritmus, který s velkou pravděpodobností umožní přístup všem procesům v průměrném čase $O(n \log n)$ pro vhodně zvolený parametr p .

ALGORITMUS PŘÍSTUP (POPIS JEDNOHO PROCESU)

- V každém cyklu se s pravděpodobností p pokus o přístup.
- Opakuj, dokud není pokus o přístup úspěšný.

Všechny náhodné volby jsou nezávislé.

Náhodné volby všech procesů jsou nezávislé, protože spolu nekomunikují. Náhodné volby jednoho procesu v jednotlivých cyklech volíme jako nezávislé v algoritmu.

Věta 3.2. *Algoritmus PŘÍSTUP s parametrem $p = 1/n$ s pravděpodobností alespoň $1 - 1/n$ uspěje po $t = 2en \ln n$ cyklech.*

Důkaz. Především algoritmus modifikujme tak, že každý proces se pokouší o přístup neustále, i poté, co ho již jednou získal. Tato změna může jedině snížit pravděpodobnost úspěchu, ale podstatně zjednoduší analýzu.

V následujících výpočtech v plné síle využijeme nezávislost náhodných voleb, protože pravděpodobnost počítáme jako součin mnoha nezávislých jevů.

Nechť $A_{i,r}$ je jev označující, že i -tý proces uspěje v r -tém cyklu. Máme

$$Pr[A_{i,r}] = p \cdot (1 - p)^{n-1} = \frac{1}{n} \left(1 - \frac{1}{n}\right)^{n-1} \geq \frac{1}{en}.$$

Druhý krok je dosažení zvoleného parametru p ; snadno se ověří, že zvolené p je lokální maximum dané funkce. Poslední odhad $\frac{1}{e} \leq \left(1 - \frac{1}{n}\right)^{n-1}$ je standardní horní odhad na $1/e$. Často se hodí i obdobný dolní odhad $\left(1 - \frac{1}{n}\right)^n \leq \frac{1}{e}$, použijeme ho i v příštím výpočtu. Obě posloupnosti k $1/e$ monotónně konvergují.

Nechť $F_{i,t}$ je jev označující, že i -tý proces neuspěje v žádném z t cyklů. Pro $t = 2en \ln n$ máme

$$Pr[F_{i,t}] = \prod_{r=1}^t (1 - A_{i,r}) \leq \left(1 - \frac{1}{en}\right)^t = \left(\left(1 - \frac{1}{en}\right)^{en}\right)^{\frac{t}{en}} \leq e^{-\frac{t}{en}} \leq (e^{\ln n})^{-2} = n^{-2}.$$

Pravděpodobnost, že existuje proces, který neuspěje, odhadneme zdánlivě nepřesně; dá se však ukázat, že výsledek je asymptoticky správný.

$$Pr \left[\bigcup_{i=1}^n F_{i,t} \right] \leq \sum_{i=1}^n Pr[F_{i,t}] \leq n \cdot n^{-2} = n^{-1}.$$

□

3.3 Minimální řez v grafu

V této kapitole předvedeme jednoduchý pravděpodobnostní algoritmus pro hledání minimálního řezu v neváženém grafu.

MINIMÁLNÍ ŘEZ V GRAFU

Vstup: neorientovaný graf (V, E) s $|V| \geq 2$.

Výstup: řez C , tj. $C \subseteq E$ takové, že graf $G = (V, E \setminus C)$ není souvislý.

Cíl: minimalizovat velikost řezu, tj. $|C|$.

Tento problém umíme řešit za pomoci algoritmů pro toky, což vede k algoritmům s časovou složitostí $O(n^3)$. Tyto algoritmy jsou ovšem relativně komplikované, zatímco následující pravděpodobnostní algoritmus má jednoduchý popis i analýzu.

Základní idea je, že v každém kroku ztotožníme dva vrcholy původně spojené hranou a odstraníme hrany, které je spojují. Taková kontrakce může vést k násobným hranám, pracujeme tedy s multigrafy. Ve chvíli, kdy zbývají jen dva vrcholy, tak všechny zbývající hrany tvoří řez, a jim odpovídající hrany tvoří řez i v původním grafu. K implementaci tohoto postupu si pro každou hranu musíme zapamatovat, ze které hrany původního grafu vznikla; to je ovšem snadné.

ALGORITMUS CONTRACT(V,E)

Vstup: neorientovaný graf (V, E) s $|V| \geq 2$.

Dokud $|V| > 2$, opakuj následující kroky:

- vyber uniformně náhodně hranu $uv \in E$;
- z E vyjmi všechny kopie hrany uv ; ve zbývajících hranách nahraď vrchol v vrcholem u ;
- $V := V \setminus \{v\}$.

Výstup: řez C obsahující původní hrany odpovídající hranám E .

Všechny náhodné volby v algoritmu jsou nezávislé.

Budeme chtít dokázat, že pokud původní graf má řez velikosti k , pak je relativně velká pravděpodobnost, že takový řez bude na výstupu. K tomu se hodí následující lemma, které říká, že graf s malým řezem má násobně více hran mimo tento řez. To implikuje, že při kontrakci náhodné hrany se tento řez zachová s velkou pravděpodobností, a umožní jednoduchou analýzu.

Lemma 3.3. *Multigraf na $n \geq 2$ vrcholech s minimálním řezem velikosti k má alespoň $kn/2$ hran.*

Důkaz. Takový graf má minimální stupeň alespoň k , protože jinak by hrany incidentní s vrcholem menšího stupně tvořily řez menší než k . Odhad nyní plyne z toho, že počet hran je roven polovině součtu stupňů všech vrcholů a součet stupňů je alespoň nk . \square

Věta 3.4. *V grafu s n vrcholy algoritmus CONTRACT najde minimální řez s pravděpodobností alespoň $\frac{2}{n(n-1)} = \binom{n}{2}^{-1}$.*

Důkaz. Především si uvědomme, že výstup algoritmu vždy tvoří řez, jehož odebrání dělí graf na dvě souvislé komponenty. Pokud označíme V_1 a V_2 dvě množiny vrcholů, které se kontrahovaly na dva vrcholy v poslední iteraci, tak totiž výsledná množina C obsahuje všechny hrany spojující nějaký vrchol z V_1 s nějakým vrcholem z V_2 . Tedy po odebrání hran C je graf nesouvislý. Navíc množiny vrcholů V_1 a V_2 indukují souvislé podgrafy, protože byly vytvořeny kontrakcemi hran původního grafu.

Dále si uvědomme, že z obdobného důvodu se v průběhu algoritmu velikost minimálního řezu v grafu (V, E) nemůže zmenšit. Pokud totiž množina hran F tvoří řez, tak množina odpovídajících hran v původním grafu také tvoří řez.

Zvolme nyní libovolný minimální řez C v grafu (V, E) . Nechť $k = |C|$. Tvrdíme, že pokud algoritmus v žádné iteraci nevybere ke kontrakci hranu $e \in C$, pak C je výstupem algoritmu. Pokud všechny hrany C jsou v dané iteraci v množině E a algoritmus vybere hranu $uv \notin C$, tak vrcholy u a v leží ve stejné komponentě grafu $(V, E \setminus C)$. To ovšem znamená, že u a v nemohou být spojeny ani žádnou jinou hranou z C a všechny hrany z C zůstanou v E . Výstup nemůže obsahovat žádnou další hranu, protože výsledné komponenty V_1 a V_2 jsou souvislé a existence hrany mimo C spojující nějaký vrchol z V_1 s nějakým vrcholem z V_2 by byla ve sporu s tím, že C je řez.

Zbývá spočítat pravděpodobnost, že během algoritmu nikdy nevybereme hranu ze zvoleného minimálního řezu C . Nechť A_i označuje jev, že po i iteracích algoritmu E obsahuje všechny hrany z C (přesněji, obsahuje k hran, kterým odpovídají původní hrany z C). Především triviálně $Pr[A_0] = 1$. Budeme počítat podmíněnou pravděpodobnost $Pr[A_{i+1}|A_i]$, tj. pravděpodobnost, že v iteraci $i+1$ nevybereme hranu z C , za předpokladu (podmínky), že v prvních i iteracích jsme nekontrahovali žádnou hranu z C . Po i iteracích je $|V| = n - i$, minimální řez má velikost alespoň k a tedy podle Lemmatu 3.3 máme $|E| \geq (n - i)k/2$. Z toho je pouze k hran v C a tedy

$$Pr[A_{i+1} | A_i] \geq 1 - \frac{2k}{(n-i)k} = \frac{n-i-2}{n-i}.$$

Z definice podmíněné pravděpodobnosti a $A_{i+1} \subseteq A_i$ plyne $Pr[A_{i+1}] = Pr[A_{i+1} \cap A_i] = Pr[A_i] \cdot Pr[A_{i+1} | A_i]$. Pravděpodobnost, že výstup algoritmu je C , je rovna $Pr[A_{n-2}]$. Opakovaným použitím předchozí identity dostáváme

$$Pr[A_{n-2}] = Pr[A_0] \cdot \prod_{i=0}^{n-3} Pr[A_{i+1} | A_i] \geq 1 \cdot \prod_{i=0}^{n-3} \frac{n-i-2}{n-i} = \frac{2}{n(n-1)}.$$

Poslední výpočet je přehlednější expandovaný jako

$$\frac{n-2}{n} \cdot \frac{n-3}{n-1} \cdot \frac{n-4}{n-2} \cdots \frac{3}{5} \cdot \frac{2}{4} \cdot \frac{1}{3} = \frac{2 \cdot 1}{n \cdot (n-1)}.$$

S pravděpodobností alespoň $\frac{2}{n(n-1)}$ tedy algoritmus CONTRACT najde zvolený minimální řez C . \square

Dokázali jsme ve skutečnosti silnější tvrzení, že pro každý minimální řez C algoritmus vystoupí tento řez C s pravděpodobností alespoň $\binom{n}{2}^{-1}$. Protože tyto jevy pro různá C jsou po dvou disjunktní, plyne z toho, že počet minimálních řezů v (multi)grafu na n vrcholech je nejvýš $\binom{n}{2}$. Pravděpodobnostní algoritmus nám tedy pomohl jednoduše dokázat čistě kombinatorické tvrzení. Je také snadné ověřit, že tento odhad je těsný, protože cyklus na n vrcholech má právě $\binom{n}{2}$ minimálních řezů.

Pravděpodobnost úspěchu algoritmu je poměrně malá, ale dostatečně velká na to, abychom jeho opakováním získali algoritmus s konstantní pravděpodobností chyby běžící v polynomiálním čase. Konkrétně, pokud algoritmus zopakujeme $\binom{n}{2}$ -krát a vystoupíme nejmenší nalezený řez, pravděpodobnost chyby je nejvýše

$$\left(1 - \binom{n}{2}^{-1}\right)^{\binom{n}{2}} \leq \frac{1}{e}.$$

Časová složitost algoritmu při vhodné implementaci je $O(n^2)$; je třeba vhodně reprezentovat graf včetně stupňů vcholu tak, aby bylo možné implementovat jednu kontrakci v čase $O(n)$. Časová složitost algoritmu s opakováním bude tedy $O(n^4)$, což je horší než složitost algoritmů založených na maximálních tocích.

Existuje však zlepšená varianta algoritmu CONTRACT, která má časovou složitost podstatně lepší, konkrétně $O(n^2 \log^2 n)$. Základní idea je ta, že v prvních kontrakcích je pravděpodobnost chyby nízká oproti posledním kontrakcím s malým počtem vrcholů. Konkrétně, během prvních přibližně $n/\sqrt{2}$ kontrakcí je celková pravděpodobnost úspěchu přibližně $1/2$. Zlepšený algoritmus pracuje tak, že provede tento počet kontrakcí a pak rekurzivně zavolá dvě kopie algoritmu na menším grafu. Podrobnosti analýzy v tomto textu vynecháme.

4 Aproximační algoritmy – základní definice

Pokud uvažujeme o přibližných řešeních problému, musíme mít definováno, co je pro danou instanci dobré řešení. Jde tedy o podstatně jiné problémy než rozhodovací problémy v klasické složitosti, kde je odpověď binární. Potřebný typ problémů vymezuje následující definice.

Definice 4.1. Optimalizační problém je čtveřice $(\mathcal{I}, \mathcal{F}, f, g)$, kde \mathcal{I} je množina vstupů neboli instancí; funkce \mathcal{F} pro každou instanci I udává množinu přípustných řešení $\mathcal{F}(I)$, účelová funkce f pro každou instanci I a přípustné řešení dává hodnotu řešení a g je bit, který říká, zda účelovou funkci chceme maximalizovat nebo minimalizovat.

Takto obecná definice zahrnuje i spojité problémy matematického programování. Nás ale z algoritmického hlediska budou zajímat především kombinatorické problémy, kde instance i přípustná řešení jsou konečné řetězce (a tedy čísla jsou přirozená nebo racionální). Typické kombinatorické optimalizační problémy patří do třídy NP -optimalizačních problémů, pro které požadujeme, aby

- (i) délka všech přípustných řešení v $\mathcal{F}(I)$ byla polynomiálně omezená v délce instance I ,
- (ii) jazyk všech dvojic instancí a přípustných řešení $\{(I, S) \mid I \in \mathcal{I}, S \in \mathcal{F}(I)\}$ byl v P , a

(iii) účelová funkce byla počitatelná v polynomiálním čase.

Rada takových problémů je NP -těžká, pak studujeme aproximační algoritmy, které jsou efektivní, ale nenajdou vždy optimální řešení. Namísto toho ale požadujeme, aby aproximační algoritmus pro každou instanci našel v polynomiálním čase přípustné řešení s hodnotou nepříliš dalekou od optima.

Pro danou instanci I označujeme optimální přípustné řešení i jeho hodnotu $OPT(I)$, řešení algoritmu A i jeho hodnotu označujeme $A(I)$. V případě pravděpodobnostního algoritmu je $A(I)$ náhodná proměnná, která závisí na náhodných bitech použitých v algoritmu; pak nás zajímají algoritmy, u kterých je průměrná hodnota $A(I)$ blízká optimu.

Definice 4.2. Algoritmus A se nazývá R -aproximační, jestliže v polynomiálním čase pro každou instanci I najde přípustné řešení z $\mathcal{F}(I)$ a navíc:

Pro minimalizační problém platí $(\forall I) A(I) \leq R \cdot OPT(I)$, resp. pro pravděpodobnostní algoritmus $(\forall I) E[A(I)] \leq R \cdot OPT(I)$.

Pro maximalizační problém platí $(\forall I) A(I) \geq OPT(I)/R$, resp. pro pravděpodobnostní algoritmus $(\forall I) E[A(I)] \geq OPT(I)/R$.

Pro některé maximalizační problémy se tradičně uvádí aproximační poměr menší než 1, tj. jako převrácená hodnota; pak tedy požadujeme $A(I) \geq R \cdot OPT(I)$.

Poznamenejme ještě, že pro minimalizační problémy definice R -aproximačního algoritmu pro libovolné R implikuje, že lze v polynomiálním čase rozpoznat vstupy, pro které je optimum rovno nule. Je-li tento rozhodovací problém NP -těžký, nemůže aproximační algoritmus existovat.

5 Hladové algoritmy a lokální prohledávání

Přirozené heuristiky pro kombinatorické problémy se snaží najít řešení tak, aby v jednotlivých krocích vybraly lokálně nejlepší možnost. Hladové algoritmy typicky postupně doplňují řešení až jsou splněny všechny podmínky problému. Lokální prohledávání naopak začne od libovolného řešení a snaží se ho postupně zlepšovat malými úpravami.

5.1 Problém obchodního cestujícího

Problém obchodního cestujícího patří mezi nejstudovanější optimalizační problémy z mnoha teoretických i praktických pohledů. Cílem je pro dané nezáporné vzdálenosti mezi n body najít nejkratší cyklus procházející všemi n body.

Pokud chceme řešit tento problém bez dalších omezení, není žádná aproximace možná, protože je NP -těžké rozhodnout, zda optimální cyklus má délku 0. To se ukáže jednoduchou redukcí z problému hamiltonovského cyklu, kdy hranám grafu přiřadíme délku 0 a ostatním hranám délku 1. Proto se zaměříme na variantu, kdy vzdálenosti tvoří metriku.

Pro metrickou variantu si předvedeme dva aproximační algoritmy, které jsou v principu hladové, i když nepoužívají postupnou konstrukci řešení. Namísto toho využijí optimální řešení jiných grafových problémů, které lze řešit v polynomiálním čase.

Připomeňme, že metrika na množině V je nezáporná reálná funkce na dvojicích prvků V splňující symetrii $(\forall u, v)(d(u, v) = d(v, u))$, trojúhelníkovou nerovnost $(\forall u, v, w)(d(u, v) \leq d(u, w) + d(w, v))$ a axióm totožnosti $(\forall u, v)(d(u, v) = 0 \Leftrightarrow u = v)$.

METRICKÝ PROBLÉM OBCHODNÍHO CESTUJÍCÍHO

Vstup: metrika d na n vrcholech V .

Výstup: cyklus C daný permutací n vrcholů v_1, v_2, \dots, v_n , tj. obsahující hrany $v_1v_2, v_2v_3, \dots, v_{n-1}v_n, v_nv_1$.

Cíl: minimalizovat délku cyklu, t.j. $d(C) = d(v_n, v_1) + \sum_{i=1}^{n-1} d(v_i, v_{i+1})$.

Je užitečné se na vstup dívat jako na úplný graf s váženými hranami. Cílem je pak najít podmnožinu hran, která tvoří Hamiltonovský cyklus. Pokud E je množina hran grafu s vrcholy V , definici délky můžeme přirozeně rozšířit na množinu hran E tak, že jako $d(E)$ označíme součet délek jednotlivých hran. V průběhu algoritmu budeme potřebovat pracovat s multigrafem, kde se hrany mohou opakovat; definice se rozšíří přirozeným způsobem.

Pro oba naše algoritmy budeme potřebovat následující podprogram

PODPROGRAM Z (ZKRÁCENÍ)

Vstup: eulerovský neorientovaný multigraf (V, E) .

- Najdi (uzavřený) eulerovský tah s hranami E . Nechť v_1, v_2, \dots, v_n je permutace vrcholů V v pořadí podle prvního výskytu v eulerovském tahu (s jakýmkoliv začátkem).

Výstup: cyklus C daný touto permutací, tj. obsahující hrany $v_1v_2, v_2v_3, \dots, v_{n-1}v_n, v_nv_1$.

Výstup může obsahovat i hrany, které nejsou v E . Nicméně z trojúhelníkové nerovnosti plyne, že $d(Z(E)) \leq d(E)$.

KOSTROVÝ ALGORITMUS

Vstup: metrika d na n vrcholech.

- Najdi minimální kostru T v úplném grafu s vahami hran danými metrikou d .
- Nechť E je multimnožina $2n - 2$ hran vzniklých z T nahrazením každé hrany dvěma kopiemi.
- Spočítej $E' = Z(E)$.

Výstup: E' .

Lemma 5.1. $d(T) \leq OPT$.

Důkaz. Pokud z cyklu OPT vynecháme jednu hranu, dostaneme kostru a ta nemůže být menší než minimální kostra T . \square

Věta 5.2. *Kostrový algoritmus je 2-approximační pro metrický problém obchodního cestujícího.*

Důkaz. Z předchozích pozorování odhadneme hodnotu výstupu: $d(Z(E)) \leq d(E) = 2 \cdot d(T) \leq 2 \cdot OPT$. \square

CHRISTOFIDESŮV ALGORITMUS

Vstup: Metrika d na n vrcholech.

- Najdi minimální kostru T v úplném grafu s vahami hran danými metrikou d .
- W je množina vrcholů lichého stupně v T .
- Najdi M , perfektní párování minimální váhy v grafu indukovaném W .
- Spočítej $E = Z(T \dot{\cup} M)$, kde $\dot{\cup}$ označuje disjunktní sjednocení množin (tj. hrany v obou množinách se vyskytují ve sjednocení dvakrát).

Výstup: E .

Především musíme ověřit, že algoritmus je korektní a efektivní. Hledání minimální kostry, perfektního párování minimální váhy, eulerovského tahu i ostatní kroky lze implementovat v polynomiálním čase (i když pro párování to není jednoduché). Množina W má sudý počet vrcholů, perfektní párování tedy existuje. Protože párování je perfektní, $T \dot{\cup} M$ má všechny vrcholy sudého stupně; zde využíváme toho, že jde o disjunkt ní sjednocení, tedy pokud hrana je v T i M , tak ji v eulerovském tahu použijeme dvakrát. Navíc je $(V, T \dot{\cup} M)$ souvislý (multi)graf, protože obsahuje kostru.

Věta 5.3. *Christofidesův algoritmus je 3/2-aproximační pro metrický problém obchodního cestujícího.*

Důkaz. Ukážeme, že $d(M) \leq OPT/2$. Cyklus OPT zkrátíme na cyklus na W tak, že ostatní vrcholy v pořadí vynecháme; cena se tím díky trojúhelníkové nerovnosti nezvýší. Tento cyklus má sudou délku a tedy tvoří dvě párování. Jedno z nich je dlouhé nejvýš $OPT/2$ a tedy i $d(M) \leq OPT/2$.

Z předchozích pozorování odhadneme hodnotu výstupu: $d(Z(E)) \leq d(E) = d(T) + d(M) \leq OPT + OPT/2$. \square

Pro oba předchozí algoritmy lze najít příklady, které ukazují, že aproximační poměr není lepší, než jsme výše dokázali.

Pro metrický problém obchodního cestujícího dodnes není známý lepší než 3/2-aproximační algoritmus. Naopak pro eukleidovské prostory je možné se optimálnímu řešení libovolně přiblížit, pro každé $\varepsilon > 0$ existuje $(1 + \varepsilon)$ -aproximační algoritmus. Takovému systému algoritmů se říká **polynomiální aproximační schéma**. (V této definici je podstatné, že čas běhu algoritmu na ε může záviset libovolně, protože ε nepovažujeme za součást vstupu.)

Pro naše algoritmy je podstatné, že vzdálenosti tvoří metriku. Pokud neplatí symetrie ale stále platí trojúhelníková nerovnost, jde o velmi zajímavý asymetrický problém obchodního cestujícího; pro něj existuje jednoduchý aproximační algoritmus s poměrem $O(\log n)$ a teprve nedávno byl nalezen algoritmus s konstantním aproximačním poměrem.

5.2 Rozvrhování

V **rozvrhování** máme na vstupu n úloh, které je třeba rozvrhnout na jednom či více strojích. Existuje řada variant, které se liší v parametrech úloh a strojů, v požadavcích na rozvrh, či v účelové funkci.

Téměř vždy je jedním z parametrů úlohy j čas běhu, značený p_j . Většinou je třeba každou úlohu rozvrhnout na jeden z m strojů v jediném intervalu $[S_j, C_j)$ tak, že intervaly různých úloh na stejném stroji jsou po dvou disjunkt ní. Standardní konvence je, že rozvrh začíná v čase 0, tj. $S_j \geq 0$, a parametry úloh jsou celočíselné nebo alespoň racionální. Pro rozvrhování na identických strojích je $C_j = S_j + p_j$.

Jedna z nejčastějších účelových funkcí je **délka rozvrhu**, definovaná jako $\max_j C_j$ a standardně označovaná C_{\max} .

V nejjednodušších případech, jako je následující, stačí určit přiřazení na jednotlivé stroje.

ROZVRHOVÁNÍ NA IDENTICKÝCH STROJÍCH

Vstup: počet strojů m , časy běhu úloh $p_1, \dots, p_n \in \mathbb{R}^+$.

Výstup: rozvrh, tj. rozklad množiny $\{1, \dots, n\}$ na množiny I_1, \dots, I_m .

Cíl: minimalizovat délku rozvrhu, t.j. $\max_{i \in \{1, \dots, m\}} \sum_{j \in I_i} p_j$.

Časy zahájení a dokončení jednotlivých úloh lze dopočítat – nejsou ovšem určeny jednoznačně, rozvrhů se stejným přiřazením úloh na počítače je celá řada. Jeden z nich dostaneme tak, že pro každé $j \in I_i$ zvolíme čas zahájení $S_j = \sum_{k \in I_i, k < j} p_j$ a pochopitelně čas ukončení $C_j = s_j + p_j$. Definujme také **délku rozvrhu stroje i** jako $\max_{j \in I_i} C_j$. Snadno ověříme, že intervaly na jednom stroji na sebe navazují, tedy jsou disjunktní, a délka rozvrhu stroje i je rovna $\sum_{j \in I_i} p_j$. Délka rozvrhu C_{\max} je rovna největší délce rozvrhu stroje a je také rovna hodnotě z definice problému v rámečku, navíc splňuje $C_{\max} = \max_j C_j$.

Pro rozvrhování na identických strojích nás zajímá jak uvedená varianta, kdy m je součástí vstupu, a aproximační poměr nezávisí na m , tak i varianta, kdy m je pevná konstanta.

Lokální prohledávání

Lokální prohledávání je oblíbená heuristika s mnoha variantami. V některých případech je její výsledek dokazatelně dobrý. Takový algoritmus si předvedeme pro rozvrhování na identických strojích.

Přirozené pravidlo pro lokální změnu rozvrhu je přesunout jednu úlohu na jiný stroj tak, aby se délka rozvrhu zkrátila. To má dva problémy.

První problém je to, že pokud máme více strojů s maximální délkou rozvrhu stroje, přesunutím jedné úlohy nemůžeme délku rozvrhu snížit a tedy nemůžeme udělat žádný platný krok. Nicméně přesunutím jedné úlohy můžeme snížit počet strojů s maximální délkou rozvrhu a po nejvýše m takových krocích se délka rozvrhu sníží. Budeme tedy používat tyto obecnější kroky, kdy vždy přesuneme úlohu ze stroje s maximální délkou rozvrhu stroje tak, aby nová délka rozvrhu stroje, kam je úloha přesunuta, byla menší. Pak už umíme dokázat, že ve chvíli, kdy není žádný krok možný, je rozvrh dobrou aproximací.

Druhý problém je, že neumíme odhadnout počet kroků do zastavení algoritmu. To bývá často největší problém návrhu algoritmu lokálního prohledávání. V našem případě se tomu vyhneme tak, že upřesníme pravidlo, kterou úlohu a na který stroj přesuneme.

LOKÁLNÍ PROHLEDÁVÁNÍ PRO ROZVRHOVÁNÍ NA IDENTICKÝCH STROJÍCH
Vstup: počet strojů m , časy běhu úloh $p_1, \dots, p_n \in \mathbb{R}^+$.
 (1) Rozvrhni všechny úlohy libovolně (např. na stroj 1).
 (2) Pro libovolný stroj i s maximální délkou rozvrhu stroje odeber poslední úlohu a rozvrhni ji jako poslední na (nějaký) stroj i s minimální délkou rozvrhu stroje, pokud tato operace zmenší čas dokončení dané úlohy.
 (3) Pokud v kroku (2) nedojde k přesunu úlohy, vystup aktuální rozvrh.
 Jinak opakuj krok (2).

Věta 5.4. *Výše uvedený algoritmus lokálního prohledávání pro rozvrhování na m strojích je $2 - 1/m$ -aproximační pro pevné m a 2 -aproximační je-li m částí vstupu.*

Důkaz. Nejprve ukážeme, že algoritmus skončí v polynomiálním čase. Označme C_{\min} minimální délku rozvrhu stroje. Všimněme si, že hodnota C_{\min} se v kroku (2) nezmenší. Z toho plyne, že každá úloha j bude přesunuta maximálně jednou: Po prvním přesunu je čas zahájení S_j roven předchozí hodnotě C_{\min} , v druhém přesunu by se S_j změnilo na aktuální hodnotu C_{\min} , která je alespoň tak velká, a úloha by neskončila dříve. Krok (2) se tedy opakuje nejvýše n -krát a lze ho implementovat efektivně, stejně jako nalezení počátečního rozvrhu.

Uvažujme nyní výsledný rozvrh. Algoritmus skončí tak, že v kroku (2) nepřesune úlohu; označme jako j poslední úlohu na vybraném stroji i . Z podmínky na přesunutí plyne, že $S_j \leq C_{\min}$. Navíc platí $p_j \leq OPT$, protože i optimum rozvrhne úlohu j .

Z definice C_{\min} víme, že do času C_{\min} jsou všechny stroje zaplněné a tedy $S_j \leq C_{\min} \leq OPT$, protože optimální rozvrh musí také rozvrhnout všechnu práci. Z toho okamžitě plyne $C_{\max} = S_j + p_j \leq 2 \cdot OPT$. Ve skutečnosti můžeme pro pevné m odhad o trochu zlepšit, protože algoritmus před časem S_j nepracuje na úloze j . Dostáváme

$$m \left(S_j + \frac{1}{m} p_j \right) = m \cdot S_j + p_j \leq \sum_{k=1}^n p_k \leq m \cdot OPT,$$

a tedy

$$C_{\max} = \left(S_j + \frac{1}{m} p_j \right) + \left(1 - \frac{1}{m} \right) p_j \leq OPT + \left(1 - \frac{1}{m} \right) OPT = \left(2 - \frac{1}{m} \right) OPT.$$

□

Hladové algoritmy

Hladový algoritmus probírá úlohy postupně, každou přiřadí na stroj s nejmenší délkou rozvrhu pro předchozí úlohy. (Je-li takových strojů více, volíme libovolně.) Hladový algoritmus pro rozvrhování se také nazývá *List Scheduling*. Důkaz aproximačního poměru je obdobný jako u předchozího algoritmu.

Věta 5.5. *Hladový algoritmus pro rozvrhování na m strojích je $(2 - 1/m)$ -aproximační pro pevné m a 2 -aproximační je-li m částí vstupu.*

Důkaz. Algoritmus zjevně pracuje v polynomiálním čase.

Nechť j je poslední dokončená úloha. Pak $C_{\max} - S_j = p_j \leq OPT$, protože i optimum rozvrhne úlohu j . Z definice hladového algoritmu víme, že do času S_j jsou všechny stroje zaplněné a tedy $S_j \leq OPT$, protože optimální rozvrh musí také rozvrhnout všechnu práci. Ve skutečnosti můžeme obdobně jako u lokálního prohledávání odhad o trochu zlepšit a dostáváme

$$S_j + \frac{p_n}{m} \leq \frac{\sum_{j=1}^n p_j}{m} \leq OPT,$$

a tedy

$$C_{\max} = S_j + p_j = \left(S_j + \frac{1}{m} p_j \right) + \left(1 - \frac{1}{m} \right) p_j \leq OPT + \left(1 - \frac{1}{m} \right) OPT = \left(2 - \frac{1}{m} \right) OPT.$$

□

Je zřejmé, že problematický vstup pro hladový algoritmus je takový, kdy je poslední úloha velmi dlouhá, srovnatelná se zbytkem rozvrhu. Snadno nalezneme příklad, který ukazuje, že předchozí analýza je těsná.

Pokud úlohy nejprve seřadíme sestupně podle velikosti a poté rozvrhneme hladově, získáme podstatně lepší algoritmus. Nazývá se LPT algoritmus (zkratka z “Largest Processing Time first”).

Věta 5.6. LPT algoritmus pro rozvrhování na m strojích je $(4/3 - 1/(3m))$ -aproximační pro pevné m a $4/3$ -aproximační je-li m částí vstupu.

Důkaz. Bez újmy na obecnosti můžeme předpokládat, že $p_1 \geq p_2 \geq \dots \geq p_n$ a poslední dokončená úloha je úloha n , tj. poslední rozvržená. Jinak můžeme pro účely analýzy vynechat všechny úlohy za poslední dokončenou, tím se náš rozvrh nezkrátí a OPT neprodlouží.

Rozlišíme dva případy. Pokud je $p_n \leq OPT/3$, tak počítáme analogicky jako u hladového algoritmu: $S_n \leq \sum_{j=1}^n p_j/m - p_n/m \leq OPT - p_n/m$, a tedy

$$C_n \leq S_n + p_n \leq OPT + \left(1 - \frac{1}{m}\right) p_n \leq \left(\frac{4}{3} - \frac{1}{3m}\right) OPT.$$

Pokud $p_n > OPT/3$, tak optimum rozvrhne nanejvýš dvě úlohy na každý stroj. Ukážeme, že LPT vytvoří optimální rozvrh. Uvážíme následující dolní odhady na OPT . Je-li $n \geq m+1$, platí $p_m + p_{m+1} \leq OPT$, protože optimální řešení pro prvních $m+1$ úloh má nutně dvě úlohy na stejném stroji a ty jsou alespoň tak velké jako nejmenší úlohy p_m a p_{m+1} . Je-li $n \geq m+2$, platí $p_{m-1} + p_{m+2} \leq OPT$, protože z prvních $m+2$ úloh má optimum dvě dvojice na stejném stroji, tedy alespoň jedna úloha velikosti alespoň p_{m-1} je ve dvojici. (Použili jsme také podmínku $p_n > OPT/3$, ze které plyne, že optimum nemůže mít na stejném stroji trojici úloh.) Obdobně platí $p_{m-2} + p_{m+3} \leq OPT$ atd. Nyní si všimneme, že LPT vytvoří na jednotlivých strojích právě tyto dvojice. (Použili jsme opět podmínku $p_n > OPT/3$, ze které nyní plyne, že ani LPT nerozvrhne na stejném stroji trojici úloh.) \square

Opět je možné zkonstruovat příklad, který ukazuje, že předchozí analýza je těsná.

Přesné řešení rozvrhování na identických počítačích je NP -těžké, existují redukce z problémů PARTITION a 3-PARTITION (nebo z jiné varianty problému batohu). Na druhou stranu, existují i lepší aproximační algoritmy, dokonce polynomiální aproximační schémata.

Online algoritmy

Hladový algoritmus pro rozvrhování patří mezi online algoritmy. Může dostávat vstup po jednotlivých úlohách a hned doplnit rozvrh nové úlohy tak, že máme platný rozvrh pro celou dosavadní instanci. Stejně tak hladové algoritmy pro další problémy jsou často online algoritmy ve vhodném modelu.

Pro online algoritmy mluvíme o **kompetitivním poměru** namísto aproximačního poměru. Záruka kvality řešení je pak stejná jako u aproximačních algoritmů, nepožaduje se však polynomiální čas běhu algoritmu.

Pro rozvrhování na identických strojích je snadné nahlédnout, že neexistuje lepší než $3/2$ -kompetitivní algoritmus. Na vstupu jsou nejprve dvě úlohy velikosti 1, které algoritmus musí rozvrhnout na různé stroje. Poté vstup pokračuje $m-1$ úlohami velikosti 2; algoritmus bude mít délku rozvrhu alespoň 3, ale optimum je 2.

Speciálně pro $m=2$ z předchozího dolního odhadu plyne, že hladový algoritmus je optimální online algoritmus; stejný výsledek lze dokázat i pro $m=3$. Naopak pro větší m lepší algoritmy existují. Pro velké m existuje 1.923-kompetitivní algoritmus a nejlepší dolní odhad říká, že neexistuje 1.88-kompetitivní deterministický algoritmus.

5.3 Problém bin packing

Problém bin packing je v jistém smyslu duální k rozvrhování na identických počítačích. Máme danou velikost košů, obvykle normalizovanou na 1, a chceme dané prvky naskládat do co nejmén košů. To odpovídá minimalizaci počtu strojů, je-li délka rozvrhu pevně omezená.

BIN PACKING
Vstup: prvky $a_1, \dots, a_n \in \mathbb{R}^+$.
Výstup: rozklad množiny $\{1, \dots, n\}$ na koše I_1, \dots, I_m , každý s celkovou velikostí prvků nejvýše 1, tj. $(\forall i) \sum_{j \in I_i} a_j \leq 1$.
Cíl: minimalizovat počet košů m .

Algoritmus FIRSTFIT probírá prvky popořadě, každý dá do prvního koše, kam se vejde. Nový koš vytvoří, když se prvek nevejde nikam. Algoritmus BESTFIT postupuje obdobně, ale prvek dá do nejvíce plného koše, kam se vejde. Algoritmus je ANYFIT algoritmus, pokud postupuje obdobně s libovolným výběrem koše pro nový prvek; jediné omezení je, že nový koš se tvoří, když se prvek nevejde do žádného stávajícího. FIRSTFIT a BESTFIT jsou příklady ANYFIT algoritmu.

Věta 5.7. Každý ANYFIT algoritmus je 2-aproximační.

Důkaz. Podle ANYFIT pravidla platí, že každé dva koše mají dohromady velikost větší než 1. Z toho pro $m \geq 2$ sečtením nerovnosti $\sum_{j \in I_1} a_j + \sum_{j \in I_m} a_j > 1$ a všech $m - 1$ nerovností $\sum_{j \in I_i} a_j + \sum_{j \in I_{i+1}} a_j > 1$ plyne, že celková velikost košů je větší než $m/2$. Zjevně platí, že $\sum_{j=1}^n a_j \leq OPT$. Celkově tedy $m/2 \leq \sum_{j=1}^n a_j > OPT$. \square

Pro algoritmy FIRSTFIT a BESTFIT lze ukázat, že jsou 1.7-aproximační (a ne lepší).

Je NP-těžké rozhodnout, zda $OPT \leq 2$ (z problému PARTITION), a tedy nemůže existovat lepší než 3/2-aproximační algoritmus: takový algoritmus pro všechny instance s $OPT \leq 2$ musí najít optimální řešení a proto by nám umožnil v polynomiálním čase odlišit instance s $OPT \leq 2$ od těch s $OPT \geq 3$.

Naopak existují **asymptotická aproximační schémata**, přesněji algoritmy, které dosáhnou $A(I) \leq 1 + (1 + \varepsilon)OPT(I)$.

5.4 Hledání disjunktních cest v grafu

Pokud v grafu hledáme více disjunktních cest z vrcholu s do vrcholu t , jde o problém ekvivalentní hledání maximálního toku, který je dobře řešitelný. Jakmile se ale ptáme, zda existují disjunktní cesty mezi dvojicemi (s_i, t_i) , ale nedovolujeme spojit (s_i, t_j) pro $i \neq j$, jde o NP-těžký problém, pro který v této kapitole navrhneme aproximační algoritmus.

Problém disjunktních cest lze formulovat v řadě variant. Nás budou zajímat hranově disjunktní cesty, problém pro vrcholově disjunktní cesty je ovšem velmi podobný. Algoritmy, které uvedeme, pracují stejně dobře pro orientované i neorientované grafy, ale pro neorientované grafy je v některých případech možné výraznější zlepšení.

Kromě základní varianty disjunktních cest nás bude zajímat i varianta, kde každá hrana má kapacitu c pro nějakou konstantu c , tj. každou hranu může použít c cest. Uvidíme, že tato varianta má podstatně lepší algoritmus, který používá zajímavou techniku.

HRANOVĚ DISJUNKTNÍ CESTY V GRAFU S KAPACITOU HRAN

Vstup: parametr c , neorientovaný nebo orientovaný graf $G = (V, E)$, posloupnost dvojic vrcholů $(s_1, t_1), \dots, (s_k, t_k)$.

Výstup: cesty P_i pro $I \subseteq \{1, \dots, k\}$ takové, že cesta P_i spojuje s_i a t_i a každá hrana je použita nejvýše v c cestách.

Cíl: maximalizovat počet cest $|I|$.

Nejprve analyzujeme jednoduchý hladový algoritmus pro verzi s kapacitou $c = 1$, který vždy použije nejkratší cestu ze všech možností; délkou cesty rozumíme počet hran.

HLADOVÝ ALGORITMUS PRO HLEDÁNÍ DISJUNKTNÍCH CEST

Vstup: $G = (V, E)$, dvojice vrcholů $(s_1, t_1), \dots, (s_k, t_k)$.

(1) $I := \emptyset$; $m := |E|$.

(2) Najdi nejkratší cestu P z s_i do t_i v grafu (V, E) , přes všechna $i \notin I$. Pokud P neexistuje, jdi na (4).

(3) $I := I \cup \{i\}$; $P_i := P$; $E := E \setminus P$. Jdi na (2).

(4) *Výstup:* cesty P_i , $i \in I$.

Věta 5.8. *Hladový algoritmus pro hledání disjunktálních cest (s kapacitou hran 1) je $O(\sqrt{m})$ -aproximační.*

Důkaz. Algoritmus lze implementovat v polynomiálním čase pomocí známých algoritmů pro nejkratší cestu v grafu.

Uvažujme instanci, kde $OPT \geq 1$, pak také $|I| \geq 1$. Z počtu hran plyne, že v OPT je nejvýše \sqrt{m} cest delších než \sqrt{m} .

Uvažme cestu P_i^* v OPT délky nejvýše \sqrt{m} . Jestliže dvojice (s_i, t_i) není spojena algoritmem, pak P_i^* musí mít společnou hranu s některou cestou P_j délky nejvýše \sqrt{m} vybranou algoritmem, protože jinak by algoritmus vybral cestu P^* . Jedna taková cesta P_j však může zablokovat každou hranou nejvýš jednu cestu z OPT , celkově nejvýše \sqrt{m} cest.

Každá cesta v OPT je buď dlouhá, anebo její terminály jsou spojené i algoritmem, anebo je zablokována krátkou cestou vybranou algoritmem. Je tedy $OPT \leq \sqrt{m} + |I| + \sqrt{m}|I| \leq (2\sqrt{m} + 1)|I| = O(\sqrt{m})|I|$. \square

Příklad s poměrem $\Theta(\sqrt{m})$ lze snadno zkonstruovat: Graf bude strom sestávající z jedné cesty v_1, v_2, \dots, v_{k-1} a z dalších k disjunktálních cest délky $k - 1$ z v_{i+1} do listu t_i pro $i = 1, \dots, k - 1$. Zvolíme dále $s_k = v_1$, $t_k = v_k$ a $s_i = v_i$ pro $i = 1, \dots, k - 1$. Algoritmus použije cestu z s_k do t_k délky $k - 1$, čímž rozpojí všechny ostatní dvojice (které mají vzdálenost k), optimum naopak spojí všechny ostatní dvojice. Aproximační poměr je $k - 1$, počet vrcholů i hran je $\Theta(k^2)$.

Pro obecnou kapacitu c , kde c je libovolná konstanta, potřebujeme použít trochu složitější postup. Myšlenka je taková, že hrany, jejichž kapacita je částečně vyčerpána, považujeme při hledání nejkratší cesty za dostatečně dlouhé. V analýze se ukáže, že správné zvyšování délek hran je exponenciální v počtu jejich použití, tj. při použití hrany její délku vynásobíme vhodným faktorem. Podobný postup se používá i v řadě dalších algoritmů pro směřování v sítích a jiné podobné problémy.

Délku hrany e budeme značit $d(e)$. Pro množinu hran F označme $d(F) = \sum_{e \in F} d(e)$. Délka cesty P je tedy $d(P)$ a $d(E)$ označuje celkovou délku všech hran v grafu.

HLADOVÝ ALGORITMUS PRO HLEDÁNÍ CEST V GRAFU S KAPACITOU c
Vstup: $G = (V, E)$, dvojice vrcholů $(s_1, t_1), \dots, (s_k, t_k)$.
(1) $I := \emptyset$; $m := |E|$; $\beta := \lceil m^{1/(c+1)} \rceil$; $d(e) := 1$ pro všechny hrany $e \in E$.
(2) Najdi nejkratší cestu P z s_i do t_i vzhledem k délkám d , přes všechna $i \notin I$. Pokud P neexistuje nebo spolu s cestami $P_i, i \in I$, porušuje podmínku kapacity c , jdi na (4).
(3) $I := I \cup \{i\}$; $P_i := P$; pro všechny hrany $e \in P$, $d(e) := \beta \cdot d(e)$. Jdi na (2).
(4) *Výstup:* cesty $P_i, i \in I$.

Věta 5.9. *Hladový algoritmus pro hledání cest v grafu s kapacitou c je $O(m^{1/(c+1)})$ -aproximační.*

Důkaz. Algoritmus lze implementovat v polynomiálním čase. To plyne i z toho, že jsme β zvolili celočíselné nejvýše rovné m . (Bez zaokrouhlení β není zjevné, jak hledat nejkratší cestu v polynomiálním čase.)

Uvažujme instanci, kde $OPT \geq 1$, pak také $|I| \geq 1$. Řekneme, že cesta je krátká, pokud její délka vzhledem k aktuálním délkám d v algoritmu je menší než β^c . Dokud algoritmus vybírá krátké cesty, neporuší podmínku kapacity c , protože každá použitá hrana má délku menší než β^c a tedy je použita méně než c cestami před použitím pro novou cestu.

Odted' budeme pracovat s délkami \bar{d} takovými jako po poslední iteraci algoritmu, kdy byla vybrána krátká cesta.

Pokud OPT spojí (s_i, t_i) cestou P_i^* a algoritmus je nespojí, pak $\bar{d}(P_i^*) \geq \beta^c$. Takových i je nejvýše $OPT - |I|$ a každou hranu z E používá maximálně c cest P_i^* . Celkově tedy máme $\bar{d}(E) \geq \beta^c(OPT - |I|)/c$.

Nyní omezíme $\bar{d}(E)$ shora pomocí $|I|$. Na počátku algoritmu je $\bar{d}(E) = m \leq \beta^{c+1}$. V iteraci, kdy přidáme krátkou cestu, zvýšíme její délku nejvýše na $\beta \cdot \bar{d}(P_i) \leq \beta \cdot \beta^c = \beta^{c+1}$. Celkově tedy máme $\bar{d}(E) \leq (1 + |I|)\beta^{c+1}$.

Kombinací obou odhadů dostáváme $\beta^c(OPT - |I|)/c \leq \bar{d}(E) \leq (1 + |I|)\beta^{c+1}$ a tedy $OPT \leq (1 + |I|)c\beta + |I|$. Z toho, že c je konstanta a $|I| \geq 1$, plyne aproximační poměr $O(\beta) = O(m^{1/(c+1)})$. \square

Pro problémy hledání cest existují i lepší (a složitější) algoritmy, studuje se také jak řada speciálních případů tak i závislost na počtu vrcholů namísto počtu hran. Pro variantu orientovaných grafů bez kapacit je ale možné dokázat, že poměr $\Theta(\sqrt{m})$ je nejlepší možný v závislosti na počtu hran.

6 Algoritmy založené na lineárním programování

Nyní se budeme věnovat algoritmům založeným na lineárním programování. Základním krokem takových algoritmů je zformulovat daný kombinatorický problém jako lineární program, u kterého celočíselná přípustná řešení přesně odpovídají přípustným řešením kombinatorického problému. Následující krok je řešení tohoto lineárního programu bez omezení na celočíselnost řešení; tento lineární program se pak nazývá **lineární relaxace** daného problému.

U některých problému nastane šťastná situace, že optimální řešení lineárního programu je celočíselné, a pak máme i optimální řešení kombinatorického problému. Na tom jsou založeny např. některé algoritmy pro párování nebo toky v sítích.

U obtížnějších problémů však mívá relaxace neceločíselná řešení, která mají účelovou funkci lepší, než je celočíselné optimum. Pak optimum lineárního programu můžeme využít dvojím způsobem. Jednak jako odhad na celočíselné optimum, a jednak jako základ pro konstrukci nepříliš vzdáleného celočíselného řešení. V některých případech jde o koncepčně jednoduché zaokrouhlování, jako využijeme u algoritmů pro splnitelnost, jindy jde o podstatně složitější metody. Časté je také využití duality lineárního programování; jednoduché použití předvedeme u problému množinového pokrytí.

Poznamenejme ještě, že u jednoho problému můžeme pracovat s různými relaxacemi, často je pro dosažení dobrého výsledku klíčové zesílení relaxace například tím, že pomocí dalších podmínek zajistíme, že optimum relaxace nemůže být příliš vzdálené od celočíselného optima.

6.1 Splnitelnost

Splnitelnost je základní rozhodovací problém, a není tedy překvapivé že i jeho optimalizační varianta má důležité místo mezi optimalizačními problémy. Jde o následující variantu, kdy se snažíme najít ohodnocení, které maximalizuje počet splněných klauzulí.

MAXSAT

Vstup: konjunkce klauzulí $C_1 \wedge \dots \wedge C_m$, každá klauzule C_j je disjunkce k_j literálů, každý literál je proměnná x_1, \dots, x_n nebo její negace $\neg x_1, \dots, \neg x_n$.

Výstup: ohodnocení $(a_1, \dots, a_n) \in \{0, 1\}^n$.

Cíl: maximalizovat počet splněných klauzulí.

Budeme předpokládat, že každá klauzule je neprázdná, že se literály v klauzuli neopakují a že žádná klauzule neobsahuje některou proměnnou i její negaci jako literál. To není nijak omezující, protože prázdná klauzule je pro každé ohodnocení nesplněná a klauzule obsahující $x_i \vee \neg x_i$ je pro každé ohodnocení splněná. Přípustné řešení instance, kde tyto klauzule vynecháme, pak dává stejně dobré nebo lepší řešení i pro původní instanci.

Pro klauzuli C a ohodnocení \vec{a} označuje $C(\vec{a})$ pravdivostní hodnotu klauzule C , tedy 1, je-li splněná, a 0 jinak. Poznamenejme ještě, že MAX-SAT patří k těm maximalizačním problémům, pro které je zvykem uvádět aproximační poměr jako číslo menší než 1.

Obdobně jako u rozhodovacího problému SAT, varianty MAXSAT získáme omezením klauzulí na vstupu. Jestliže $k_j \leq k$ pro všechna j , mluvíme o MAX- k SAT, jestliže dokonce $k_j = k$ pro všechna j , pak mluvíme o MAX- k SAT. Optimum MAX-SAT je počet všech klauzulí, právě když je celá formule splnitelná; MAX-SAT i MAX-3SAT je tedy také NP -těžká úloha. Poněkud překvapivé je, že i MAX-2SAT je NP -těžký problém, přestože 2SAT je polynomiálně řešitelný.

Uvedené aproximační problémy mají aproximační algoritmy s konstantním aproximačním poměrem, které si předvedeme. Pro žádný z nich však neexistují aproximační schémata, naopak pro nějaký konstantní poměr R různý od 1 by R -aproximační algoritmus implikoval $P = NP$. Podobné je to s obtížností aproximace např. pro problém obchodního cestujícího.

Nyní navrhneme několik pravděpodobnostních algoritmů, později v kapitole 6.2 si ukážeme, jak je modifikovat na deterministické algoritmy. Ve všech případech bude zásadní odhadnout pro každou klauzuli pravděpodobnost jejího splnění. Počet splněných klauzulí je pak součet příslušných indikátorových proměnných, který snadno odhadneme z linearity střední hodnoty. Pro tento výpočet si všimněme, že pro ohodnocení \vec{a} vybrané pravděpodobnostním algoritmem

A je $C_j(\vec{a})$ zároveň indikátorová proměnná jevu, že C_j je splněná. Pro počet splněných klauzulí tedy máme

$$E[A] = E \left[\sum_{j=1}^m C_j(\vec{a}) \right] = \sum_{j=1}^m E[C_j(\vec{a})] = \sum_{j=1}^m \Pr[C_j(\vec{a}) = 1].$$

Začneme dvěma algoritmy, které nevyužívají lineární programování. První z nich jednoduše zvolí náhodné ohodnocení bez ohledu na vstupní formuli.

RAND-SAT

Vstup: konjunkce klauzulí $C_1 \wedge \dots \wedge C_m$.

Vyber ohodnocení $(a_1, \dots, a_n) \in \{0, 1\}^n$ uniformně náhodně.

Výstup: $\vec{a} = (a_1, \dots, a_n)$.

Lemma 6.1. Pro každou klauzuli C_j s k_j literály je $\Pr[C_j(\vec{a}) = 1] = 1 - 2^{-k_j}$.

Důkaz. Pro klauzuli existuje jediné ohodnocení, kdy není splněna, a to má při k_j literálech pravděpodobnost 2^{-k_j} . \square

Věta 6.2. Algoritmus RAND-SAT je $1/2$ -aproximační pro MAX-SAT a $7/8$ -aproximační pro MAX-E3SAT.

Důkaz. Algoritmus evidentně běží v lineárním čase.

Pro MAX-SAT je $k_j \geq 1$ pro všechna i , tedy podle Lemmatu 6.1 máme $\Pr[C_j(\vec{a})] \geq 1/2$ a celkově $E[A] = \sum_{j=1}^m \Pr[C_j(\vec{a}) = 1] \geq m/2 \geq OPT/2$, protože $OPT \leq m$ pro jakoukoliv instanci.

Pro MAX-E3SAT je $k_j = 3$ pro všechna i , tedy podle Lemmatu 6.1 máme $\Pr[C_j(\vec{a})] = 7/8$ a celkově $E[A] = \sum_{j=1}^m \Pr[C_j(\vec{a}) = 1] = \frac{7}{8}m \geq \frac{7}{8}OPT$. \square

Je pozoruhodné, že RAND-SAT je nejlepší možný aproximační algoritmus pro MAX-E3SAT; víme, že $7/8 + \varepsilon$ -aproximační algoritmus pro libovolné $\varepsilon > 0$ implikuje $P = NP$.

Pro RAND-SAT je paradoxně obtížné splnit klauzule s jediným literálem. To se dá snadno zlepšit následující modifikací, která zajistí, že každá klauzule, kterou může splnit optimum, je splněna alespoň s pravděpodobností rovnou poměru zlatého řezu.

BIASED-SAT

Vstup: konjunkce klauzulí $C_1 \wedge \dots \wedge C_m$.

Vyber $a_i \in \{0, 1\}$ nezávisle náhodně takto:

- Jestliže x_i se vyskytuje jako jednoprvková klauzule častěji než $\neg x_i$, pak zvol $a_i = 1$ s pravděpodobností $\phi - 1 = (\sqrt{5} - 1)/2 \approx 0.618$ a $a_i = 0$ jinak.
- Pro zbývající i zvol $a_i = 0$ s pravděpodobností $\phi - 1 = (\sqrt{5} - 1)/2$ a $a_i = 1$ jinak.

Výstup: $\vec{a} = (a_1, \dots, a_n)$.

Věta 6.3. Algoritmus BIASED-SAT je $(\phi - 1)$ -aproximační algoritmus pro MAXSAT, kde $\phi - 1 = (\sqrt{5} - 1)/2 \approx 0.618$.

Důkaz. Algoritmus běží v polynomiálním čase.

Z dvojice klauzulí x_i a $\neg x_i$ je při každém ohodnocení právě jedna splněná, můžeme tedy pro účely analýzy každou takovou dvojici vynechat.

Zbývající klauzule délky 1 jsou splněny s pravděpodobností přesně $\phi - 1$. Klauzule délky $k \geq 2$ jsou splněny s pravděpodobností alespoň $1 - (\phi - 1)^k \geq 1 - (\phi - 1)^2 = \phi - 1$.

Výpočet pomocí indikátorových proměnných a linearity střední hodnoty je obdobný jako u RAND-SAT. \square

Pro použití lineárního programování potřebujeme MAX-SAT zformulovat jako celočíselný lineární program. To není úplně přímočaré, použijeme dva druhy proměnných. Proměnné y_i odpovídají ohodnocením jednotlivých proměnných, proměnné z_j odpovídají hodnotám jednotlivých klauzulí.

Zavedeme značení $x_i \in C_j$ resp. $\neg x_i \in C_j$, které znamená, že x_i resp. $\neg x_i$ se v klauzuli C_j vyskytuje jako literál. Položme

$$f(C_j) = \sum_{i: x_i \in C_j} y_i + \sum_{i: \neg x_i \in C_j} (1 - y_i).$$

Uvažme následující lineární program:

$$\begin{aligned} & \text{maximalizuj} && \sum_{j=1}^m z_j \\ & \text{pro} && y_1, \dots, y_n \in [0, 1], \quad z_1, \dots, z_m \in [0, 1] \\ & \text{za podmíněk} && f(C_j) \geq z_j \quad \text{pro } j = 1, \dots, m \end{aligned} \tag{6.1}$$

Potom optimální splňující ohodnocení přesně odpovídají optimálním celočíselným řešením. Přesněji, každé ohodnocení pro formuli odpovídá celočíselným hodnotám y_1, \dots, y_n , a pokud z_1, \dots, z_m nastavíme na maximální hodnoty dané podmínkami lineárního programu, tak máme celočíselné řešení s účelovou funkcí rovnou počtu splněných klauzulí. Jiné nastavení z_1, \dots, z_m vede k nižší hodnotě účelové funkce a nemůže tedy být optimální.

LP-SAT
Vstup: konjunkce klauzulí $C_1 \wedge \dots \wedge C_m$.
 (i) Nechtě $y_1^*, \dots, y_n^*, z_1^*, \dots, z_m^*$ je optimum lineární relaxace (6.1).
 (ii) Vyber $a_i \in \{0, 1\}$ nezávisle náhodně tak, že $a_i = 1$ s pravděpodobností y_i^* a $a_i = 0$ jinak.
Výstup: $\vec{a} = (a_1, \dots, a_n)$.

Lemma 6.4. *Pro každou klauzuli C_j s k_j literály je*

$$\Pr[C_j(\vec{a}) = 1] \geq \left(1 - \left(1 - \frac{1}{k_j}\right)^{k_j}\right) z_j^* \geq \left(1 - \frac{1}{e}\right) z_j^*.$$

Důkaz. Optimum lineárního programu (6.1) a pravděpodobnosti $\Pr[C_j(\vec{a}) = 1]$ se nezmění při přejmenování proměnných a také při výměně proměnné za její negaci. Přesněji, pokud instancí I' získáme z instance I tak, že změním všechny literály x_i na $\neg x_i$ a naopak, pak z každého přípustného řešení (6.1) pro I získáme přípustné řešení (6.1) pro I' tak, že hodnotu

y_i změněme na $1 - y_i$. Tato změna nezmění ani hodnotu účelové funkce ani pravděpodobnosti $Pr[C_j(\vec{a}) = 1]$ v algoritmu.

Z této symetrie plyne, že stačí důkaz provést pro $C_j = x_1 \vee x_2 \vee \dots \vee x_{k_j}$. Pak příslušná podmínka lineárního programu dává $y_1^* + \dots + y_{k_j}^* \geq z_j^*$ a za pomoci nerovnosti mezi aritmetickým a geometrickým průměrem v první nerovnosti dostáváme

$$Pr[C_j(\vec{a}) = 0] = \prod_{i=1}^{k_j} (1 - y_i^*) \leq \left(\frac{1}{k_j} \sum_{i=1}^{k_j} (1 - y_i^*) \right)^{k_j} = \left(1 - \frac{1}{k_j} \sum_{i=1}^{k_j} y_i^* \right)^{k_j} \leq \left(1 - \frac{z_j^*}{k_j} \right)^{k_j}.$$

Nyní si všimneme, že funkce $f_k(t) = 1 - (1 - t/k)^k$ je na intervalu $[0, 1]$ konkávní, protože její druhá derivace podle t je záporná. Můžeme ji tedy zdola odhadnout lineární funkcí procházející příslušnými dvěma krajními body. Ty spočítáme: $f_k(0) = 0$ a $f_k(1) = 1 - (1 - 1/k)^k$. Pro $z_j^* \in [0, 1]$ tak dostáváme

$$Pr[C_j(\vec{a}) = 1] \geq 1 - \left(1 - \frac{z_j^*}{k_j} \right)^{k_j} \geq \left(1 - \left(1 - \frac{1}{k_j} \right)^{k_j} \right) z_j^*.$$

Poslední nerovnost ve znění lemmatu je standardní odhad na $1/e$. □

Věta 6.5. *Algoritmus LP-SAT je $1 - 1/e \approx 0.63$ -aproximační algoritmus pro MAXSAT.*

Důkaz. Algoritmus lze implementovat v polynomiálním čase za pomoci polynomiálního algoritmu pro lineární programování.

Podle Lemmatu 6.4 máme $Pr[C_j(\vec{a})] \geq (1 - 1/e)z_j^*$ a celkově $E[A] = \sum_{j=1}^m Pr[C_j(\vec{a}) = 1] \geq (1 - 1/e) \sum_{j=1}^m z_j^* \geq (1 - 1/e)OPT$. V poslední nerovnosti jsme využili toho, že optimum lineární relaxace je rovno nebo větší než celočíselné optimum, které je také přípustným řešením. □

V předchozím důkazu jsme ukázali, že řešení dané algoritmem je blízké nejen optimu, ale dokonce optimu lineární relaxace. Použili jsme tedy optimum lineární relaxace jako horní odhad na optimum kombinatorického problému, zatímco pro algoritmus RAND-SAT jsme použili jen triviální horní odhad m .

Aproximační poměr algoritmu LP-SAT je jen nepatrně lepší než u BIASED-SAT. Můžeme si ale všimnout, že algoritmu LP-SAT nečiní problémy krátké klauzule, zatímco na delších klauzulích jsou naše odhady dokonce horší než pro RAND-SAT. Následující algoritmus zkombinuje LP-SAT a RAND-SAT tak, že odhady pro klauzule všech délek jsou přibližně stejné.

BEST-SAT

Vstup: konjunkce klauzulí $C_1 \wedge \dots \wedge C_m$.

- S pravděpodobností $1/2$ použij algoritmus RAND-SAT a jinak algoritmus LP-SAT.

Věta 6.6. *Algoritmus BEST-SAT je $3/4$ -aproximační algoritmus pro MAX-SAT.*

Důkaz. Algoritmus lze implementovat v polynomiálním čase stejně jako předchozí algoritmy.

Pro klauzuli C_j s k_j literály dostáváme z Lemmat 6.1 a 6.4

$$Pr[C_j(\vec{a}) = 1] \geq \frac{1}{2} (1 - 2^{-k_j}) + \frac{1}{2} \left(1 - \left(1 - \frac{1}{k_j} \right)^{k_j} \right) z_j^* \geq \frac{3}{4} z_j^*.$$

Poslední nerovnost používá nerovnost $z_j^* \leq 1$ a rozbor případů podle hodnoty k_j podle následující tabulky:

k_j	RAND-SAT	LP-SAT	BEST-SAT
1	0.5	1	0.75
2	0.75	0.75	0.75
≥ 3	≥ 0.875	$\geq 1 - 1/e \approx 0.632$	> 0.75

Celkově máme $E[A] = \sum_{j=1}^m Pr[C_j(\vec{a}) = 1] \geq \frac{3}{4} \sum_{j=1}^m z_j^* \geq \frac{3}{4} OPT$. □

Nabízí se otázka, zda je možné aproximační poměr $3/4$ pro MAX-SAT dále zlepšit. Ukážeme, že to není možné na základě odhadu daného naší lineární relaxací. Uvážíme-li jako vstup formuli se dvěma proměnnými a všemi čtyřmi možnými klauzulemi, tj. $(x_1 \vee x_2) \wedge (x_1 \vee \neg x_2) \wedge (\neg x_1 \vee x_2) \wedge (\neg x_1 \vee \neg x_2)$, je zřejmé, že $OPT = 3$, protože pro každé ohodnocení je jedna klauzule nesplněná. Naproti tomu lineární relaxace má přípustné řešení $y_1 = y_2 = 1/2$, $z_1 = z_2 = z_3 = z_4 = 1$ s účelovou funkcí rovnou 4. V tomto případě je tedy poměr mezi optimem kombinatorického problému a optimem lineární relaxace $3/4$. Minimum tohoto poměru přes všechny instance (anebo maximum pro minimalizační problémy) se nazývá **mezera celočíselnosti** (integrality gap) lineární relaxace. Pokud nepoužijeme silnější odhad na optimum než je optimum dané lineární relaxace, nemůže být aproximační faktor lepší než mezera celočíselnosti.

Pro MAX-SAT existují lepší aproximační algoritmy, ty jsou však založené na podstatně náročnější technice semidefinitivního programování a semidefinitních relaxací.

6.2 Odstranění náhodnosti metodou podmíněných pravděpodobností

6.3 Množinové pokrytí

6.3.1 Formulace problému a souvisejících lineárních programů

SET COVER

Vstup: Systém množin $S_1, \dots, S_m \subseteq \{1, \dots, n\}$, jejich ceny $c_1, \dots, c_m \geq 0$.

Výstup: Podsystem $S_i, i \in I, I \subseteq \{1, \dots, m\}$ takový, že $\bigcup_{i \in I} S_i = \{1, \dots, n\}$.

Cíl: minimalizovat cenu I , tj. $\sum_{i \in I} c_i$.

Důležité parametry problému: $g = \max_j |S_j|$, $f = \max_e |\{j \mid e \in S_j\}|$.

Pro analýzu i formulaci algoritmů pro množinové pokrytí využijeme lineární programování a dualitu. Primární lineární program je:

$$\begin{aligned}
 & \text{minimalizuj} && \sum_{i=1}^m c_i x_i \\
 & \text{pro} && x_1, \dots, x_m \geq 0 \\
 & \text{za podmíněk} && \sum_{j: e \in S_j} x_j \geq 1 \quad \text{pro } e = 1, \dots, n
 \end{aligned} \tag{6.2}$$

a duální lineární program je:

$$\begin{aligned}
 & \text{maximalizuj} && \sum_{e=1}^n y_e \\
 & \text{pro} && y_1, \dots, y_n \geq 0 \\
 & \text{za podmíněk} && \sum_{e \in S_j} y_e \leq c_j \quad \text{pro } j = 1, \dots, m
 \end{aligned} \tag{6.3}$$

Intuitivní význam duality...

Slabá věta o dualitě...

Podmínky komplementarity...

6.3.2 Hladový algoritmus

GREEDY-SC
Vstup: Systém množin $S_1, \dots, S_m \subseteq \{1, \dots, n\}$, jejich ceny $c_1, \dots, c_m \geq 0$.
 (1) $I := \emptyset, E := \emptyset$.
 (2) Dokud nejsou pokryté všechny prvky, tj. $E \subsetneq \{1, \dots, n\}$ opakuj:
 Pro $j \in \{1, \dots, m\}$ s $S_j \not\subseteq E$ polož $p_j := c_j / |S_j \setminus E|$.
 Nechť j_0 je takové, že p_{j_0} je definované a minimální.
 Polož $q_e := p_{j_0}$ pro všechna $e \in |S_{j_0} \setminus E|$; polož $I := I \cup \{j_0\}$ a $E := E \cup S_{j_0}$.
Výstup: I .

Ukážeme, že hladový algoritmus má aproximační poměr $H_g \leq H_n$. Nejdříve příklad, že nemůže být lepší. Systém má n jednoprvkových množin $S_j = \{j\}$ s cenou $c_j = 1/j$ a jednu n -prvkovou $S_{n+1} = \{1, \dots, n\}$ s cenou $c_{n+1} = 1 + \varepsilon$ pro malé $\varepsilon > 0$. GREEDY-SC postupně vybere množiny S_n, \dots, S_1 s celkovou cenou H_n , zatímco optimum vybere jedinou množinu S_{n+1} .

Věta 6.7. Algoritmus GREEDY-SC je H_g -aproximační algoritmus pro množinové pokrytí.

Důkaz. Algoritmus běží v polynomiálním čase.

Uvážíme vektor \mathbf{q} a ukážeme, že je nejvýše H_g -krát větší než přípustné řešení duálního programu. Přesněji, ukážeme, že $\mathbf{q}' = \frac{1}{H_g} \mathbf{q}$ je přípustné řešení duálního programu. Evidentně jsou q_e nezáporná.

Dále potřebujeme pro každé $j = 1, \dots, m$ ukázat platnost podmínky

$$\sum_{e \in S_j} q'_e \leq c_j. \tag{6.4}$$

Označme prvky $S_j = \{e_1, \dots, e_k\}$ tak, že algoritmus pokryje nejprve prvek e_k , pak e_{k-1} atd., až nakonec e_1 . (Prvky pokryté ve stejné iteraci uspořádáme libovolně.) Z definice g platí $k \leq g$.

Pro $e_i \in S_j$ platí, že jsme ho v iteraci, kdy bylo pokryto, mohli pokrýt také množinou S_j s cenou $p_j \leq c_j/i$, protože ještě alespoň i prvků e_1, \dots, e_i z S_j není pokryto. Je tedy $q_{e_i} \leq c_j/i$. Nyní odhadneme levou stranu (6.4) a podmínku dokážeme:

$$\sum_{e \in S_j} q'_e = \frac{1}{H_g} \sum_{i=1}^k q_{e_i} \leq \frac{1}{H_g} \sum_{i=1}^k \frac{c_j}{i} = \frac{1}{H_g} \cdot c_j \cdot H_k \leq c_j.$$

Dokázali jsme, že \mathbf{q}' je přípustné řešení duálního programu.

Z konstrukce algoritmu vidíme, že $\sum_{j \in I} c_j = \sum_{e=1}^n q_e$. Navíc podle duální účelová funkce přípustného řešení \mathbf{q}' je dolním odhadem optima lineárního programu a tedy i optimálního celočíselného řešení. Dostáváme $\sum_{e=1}^n q_e = H_g \sum_{e=1}^n q'_e \leq H_g \cdot OPT$, a tedy výsledné řešení je H_g -aproximace. \square

6.3.3 Zaokrouhlování LP a primárně-duální algoritmus

LP-SC

Vstup: Systém množin $S_1, \dots, S_m \subseteq \{1, \dots, n\}$, jejich ceny $c_1, \dots, c_m \geq 0$.

Nechť x_1^*, \dots, x_m^* je optimum lineárního programu (6.2).

Výstup: $I = \{j \mid x_j^* \geq 1/f\}$.

PRIMÁRNĚ-DUÁLNÍ SC

Vstup: Systém množin $S_1, \dots, S_m \subseteq \{1, \dots, n\}$, jejich ceny $c_1, \dots, c_m \geq 0$.

(1) $y_1, \dots, y_n := 0$. $I := \emptyset$. $E := \emptyset$.

(2) Dokud existuje $e \notin E$, pro nějaké takové e proved'

$$\delta := \min_{j: e \in S_j} \left(c_j - \sum_{e \in S_j} y_e \right).$$

$$y_e := y_e + \delta.$$

Pro všechna j taková, že $e \in S_j$ a $\sum_{e \in S_j} y_e = c_j$ polož $I := I \cup \{j\}$ a $E := E \cup S_j$.

Výstup: I .

6.4 Vrcholové pokrytí

VERTEX COVER

Vstup: Graf $G = (V, N)$, ceny vrcholů $c_v \geq 0$, $v \in V$.

Výstup: Podmnožina vrcholů $W \subseteq V$ taková, že $(\forall e \in E) e \cap W \neq \emptyset$.

Cíl: minimalizovat cenu W , tj. $\sum_{v \in W} c_v$.

Vrcholové pokrytí je speciálním případem množinového pokrytí, kde $f = 2$ a $g \leq n$ je maximální stupeň grafu.

Kombinatorický aproximační algoritmus pro neváženou verzi...

Vztah k nezávislé množině, rozdílnost aproximačního poměru...

Převod na množinové pokrytí...

LP a algoritmus pro váženou verzi...

$$\begin{aligned} & \text{minimalizuj} && \sum_{v \in V} c_v x_v \\ & \text{pro} && x_v \geq 0 \\ & \text{za podmíněk} && x_u + x_v \geq 1 \quad \text{pro } \{u, v\} \in E \end{aligned} \tag{6.5}$$

7 Hašování a implementace slovníku

7.1 Hašovací funkce

Definice 7.1. Nechť U a V jsou množiny, $m = |U|$ a $n = |V|$ jejich velikosti a H systém funkcí zobrazujících U do V .

System H se nazývá *2-univerzální systém hašovacích funkcí* jestliže pro každé $x_1, x_2 \in U$, $x_1 \neq x_2$ a pro h uniformně náhodně vybrané z H platí

$$\Pr_{h \in H}[h(x_1) = h(x_2)] \leq \frac{1}{n}.$$

System H se nazývá *silně 2-univerzální systém hašovacích funkcí* jestliže pro každé $x_1, x_2 \in U$, $x_1 \neq x_2$, $y_1, y_2 \in V$ a pro h uniformně náhodně vybrané z H platí

$$\Pr_{h \in H}[h(x_1) = y_1 \wedge h(x_2) = y_2] = \frac{1}{n^2}.$$

Silně 2-univerzální systém hašovacích funkcí se také někdy nazývají po dvou nezávislé hašovací funkce. To odpovídá tomu, že náhodné proměnné $h(x)$ indexované $x \in U$, kde h je uniformně náhodně vybraná funkce z H , jsou po dvou nezávislé. (Tedy po dvou nezávislé jsou hodnoty h v různých bodech, ne různé funkce h .)

Pozorování 7.2. Pro každý systém H existují $x_1, x_2 \in U$, $x_1 \neq x_2$ takové, že

$$\Pr_{h \in H}[h(x_1) = h(x_2)] \geq \frac{1}{n} - \frac{1}{m}.$$

Lemma 7.3.

7.2 Dynamický slovník

7.3 Statický slovník

8 Paralelní algoritmy pro maximální nezávislou množinu v grafu

Nechť d_v značí aktuální stupeň vrcholu v v průběhu algoritmu a $N(v)$ množinu jeho sousedů.

PARA-MIS
Vstup: Graf $G = (V, E)$.
 $I := \emptyset$. Dokud $V \neq \emptyset$, opakuj následující kroky.
 (1) Paralelně pro každý vrchol $v \in V$: Jestliže $d_v = 0$, pak $I := I \cup \{v\}$ a $V := V \setminus \{v\}$.
 (2) Paralelně pro každý vrchol $v \in V$: Označ v s pravděpodobností $p_v = 1/(2d_v)$. Pravděpodobnosti pro různé vrcholy a iterace jsou nezávislé.
 (3) Paralelně pro každou hranu $\{u, v\} \in E$: Jestliže oba u a v jsou označeny, odeber značku z vrcholu nižšího stupně z nich (libovolnou značku pro $d_u = d_v$).
 (4) Nechť S je množina označených vrcholů a $N(S)$ množina jejich sousedů. $I := I \cup S$ a $V := V \setminus (S \cup N(S))$; z E odeber všechny hrany incidentní s vrcholem v $S \cup N(S)$.

Definice 8.1. Nechť je dán graf $G = (V, E)$. Vrchol v se nazývá *dobry*, jestliže má alespoň $d_v/3$ sousedů stupně nejvýše d_v . Ostatní vrcholy jsou *špatné*. Hrana je *dobrá*, obsahuje-li dobrý vrchol. Hrana je *špatná*, jestliže má oba vrcholy špatné.

Lemma 8.2. Existuje konstanta $\alpha > 0$ taková, že pro každý dobrý vrchol platí, že v jedné iteraci algoritmu je odstraněn s pravděpodobností alespoň α .

Důkaz. Všimněme si, že vrchol je jistě odstraněn, jestliže některý z jeho sousedů je vybrán do množiny S .

Nejprve ukážeme, že pro každý dobrý vrchol v je pravděpodobné, že některý z jeho sousedů bude v kroku (2) označený. Podle definice má vrchol v alespoň $d_v/3$ sousedů stupně nejvýše d_v . Pravděpodobnost, že algoritmus alespoň jeden z nich označí je alespoň

$$1 - \prod_{w \in N(v)} (1 - p_w) \geq 1 - \left(1 - \frac{1}{2d_v}\right)^{\frac{d_v}{3}} \geq 1 - e^{-\frac{1}{6}} > 0,1535.$$

Jestliže je libovolný (ne nutně dobrý) vrchol w označen, ukážeme, že s pravděpodobností alespoň $1/2$ zůstane označen i po kroku (3). Označení můžeme odebrat jedině, jestliže má označeného souseda stejného nebo vyššího stupně; ten je však označen s pravděpodobností nejvýše $1/(2d_w)$. Vzhledem k tomu, že w má nejvýše d_w takových sousedů, celková pravděpodobnost odebrání označení je nejvýše $d_w \cdot 1/(2d_w) = 1/2$.

Spojením obou odhadů dostáváme, že dobrý vrchol je odstraněn s pravděpodobností alespoň α pro $\alpha = (1 - e^{-1/6})/2 > 0,0767$. \square

Lemma 8.3. *V každém grafu je alespoň polovina hran dobrá.*

Důkaz. Zorientujme všechny hrany směrem ke koncovému vrcholu většího stupně; mají-li oba vrcholy stejný stupeň, vyberme libovolně. Označme d_v^{in} počet hran vcházejících do v a d_v^{out} počet hran vycházejících z v . Z definice špatného vrcholu a orientace pro každý špatný vrchol v plyne, že $d_v^{in} \leq d_v/3$, a tedy $d_v^{out} \geq 2d_v/3$ a $d_v^{in} \leq d_v^{out}/2$. Necht' B a E_B označují množinu špatných vrcholů a hran. Z definice plyne, že každá špatná hrana vede do špatného vrcholu, a proto dostáváme:

$$|E_B| \leq \sum_{v \in B} d_v^{in} \leq \sum_{v \in B} \frac{d_v^{out}}{2} \leq \frac{|E|}{2}.$$

Dokázali jsme, že nejvýše polovina hran je špatných. Alespoň polovina hran je tedy dobrých. \square

Věta 8.4. *Pravděpodobnostní algoritmus PARA-MIS najde maximální nezávislou množinu v grafu o n vrcholech v průměrném čase $(\log n)^{O(1)}$ na polynomiálně mnoha procesorech.*

8.1 Derandomizace pomocí po dvou nezávislých proměnných

Necht' A_w označuje jev, že algoritmus v kroku (2) označí vrchol w . V původním algoritmu jsme tyto jevy volili nezávislé, s $Pr[A_w] = p_w$. V modifikovaném algoritmu tyto jevy zvolíme při každém kroku (2) pouze po dvou nezávislé, přičemž pravděpodobnosti zachováme.

Výhoda tohoto postupu je ta, že nyní algoritmus můžeme derandomizovat. Pro n nezávislých jevů potřebujeme exponenciálně veliký pravděpodobnostní prostor, zatímco pro n po dvou nezávislých jevů A_1, \dots, A_n vystačíme s pravděpodobnostním prostorem velikosti polynomiální v n . Takové prostory zkonstruujeme například jako systém silně 2-univerzálních hashovacích funkcí z minulé kapitoly, tedy například jako systém všech lineárních funkcí v tělese o něco větším než n ; jev A_i je pak vhodně určen hodnotou náhodně vybrané hashovací funkce v bodě i . (Pokud jevy mají pravděpodobnost $1/2$, stačí dokonce prostor velikosti $O(n)$ daný Sylvestrovou maticí.) Namísto náhodné volby v algoritmu pak můžeme prostě vyzkoušet všech polynomiálně mnoho možností, v případě paralelního algoritmu samozřejmě paralelně

na různých procesorech. Tato metoda derandomizace je poměrně obecná a použitelná i pro další problémy a algoritmy.

Prvním drobným technickým problémem u našeho algoritmu je to, že konstrukce pomocí hashovacích funkcí umožní jako pravděpodobnosti jen násobky $1/N$ pro $N = n^{O(1)}$. To vyřešíme tím, že nedosáhneme přesně požadovaných pravděpodobností p_w ale jen jejich dostatečně přesné aproximace. Tato změna je pro analýzu nepodstatná.

Druhým problémem je to, že volby v různých fázích algoritmu potřebujeme plně nezávislé. Můžeme ovšem derandomizovat každou fázi zvlášť, čemuž ostatně odpovídá výše uvedený popis. Po dvou nezávislé je označení různých vrcholů v dané fázi, zde v rámci fáze vyzkoušíme paralelně všechny volby a pokračujeme s tou, kde na konci fáze máme nejméně hran.

Zbývá tedy provést analýzu jedné fáze, tedy Lemma 8.2. Ostatní části důkazu včetně kombinatorického Lemmatu 8.3 zůstávají beze změn. Původní důkaz Lemmatu 8.2 pro nezávislé proměnné je založen na faktu, že pravděpodobnost označení některého souseda vrcholu v je rovna $1 - \prod_{w \in N(v)} (1 - p_w)$. Tento výraz jsme odhadli tím, že jsme odhadli všechny členy odpovídající sousedům malého stupně. Jiný a v podstatě ekvivalentní pohled je, že po roznásobení je dominantním členem polynomu lineární člen $\sum_{w \in N(v)} p_w$ a pravděpodobnost označení souseda je tomuto členu blízká. Obdobné tvrzení dokážeme i v případě po dvou nezávislých proměnných.

Důkaz Lemmatu 8.2. Nechť v je dobrý vrchol a $D \subseteq N(v)$ je množina jeho sousedů stupně nejvýše d_v . Z toho, že v je dobrý, plyne $|D| \geq d_v/3$ a tedy

$$\sum_{w \in D} p_w \geq \frac{d_v}{3} \cdot \frac{1}{2d_v} = \frac{1}{6}.$$

Vezměme nyní za $D' \subseteq D$ nějakou na inkluzi minimální podmnožinu takovou, že $\sum_{w \in D'} p_w \geq 1/6$; ta existuje, protože $D' = D$ nerovnost splňuje. Jestliže $|D'| \geq 2$, pak minimalita D' implikuje, že pro všechna $w \in D'$ je $p_w < 1/6$. Jestliže $|D'| \geq 3$, pak minimalita D' navíc implikuje, že pro nějaké $w \in D'$ je $p_w < 1/12$, a protože toto w nelze z D' odebrat, je $\sum_{w \in D'} p_w < 1/6 + 1/12 = 1/4$.

Ukážeme, že $Pr[\bigcup_{w \in D'} A_w] \geq 1/8$. K tomu odhadneme pravděpodobnost sjednocení pomocí principu inkluze a exkluze takto (polovina u druhého členu je proto, že každá neuspořádaná dvojice vrcholů $\{w, u\}$ se v sumě přes uspořádané dvojice vyskytuje dvakrát):

$$\begin{aligned} Pr[\bigcup_{w \in D'} A_w] &\geq \sum_{w \in D'} Pr[A_w] - \frac{1}{2} \sum_{\substack{w, u \in D', \\ u \neq w}} Pr[A_w \cap A_u] \\ &= \sum_{w \in D'} p_w - \frac{1}{2} \sum_{\substack{w, u \in D', \\ u \neq w}} p_w \cdot p_u \geq \sum_{w \in D'} p_w \left(1 - \frac{1}{2} \sum_{u \in D'} p_u \right). \end{aligned}$$

Rovnost ve výpočtu využívá fakt, že jevy A_w a A_u jsou nezávislé, k čemuž přesně stačí to, že celý systém jevů je po dvou nezávislý.

Nyní rozlišíme několik případů. Pro $D' = \{u\}$ je $Pr[\bigcup_{w \in D'} A_w] = p_u \geq 1/6$. Pro $D' = \{u, v\}$ je $Pr[\bigcup_{w \in D'} A_w] = (p_u + p_v) - p_u \cdot p_v \geq 1/6 - 1/36 > 1/8$. Pro $|D'| \geq 3$ je

$$Pr[\bigcup_{w \in D'} A_w] \geq \sum_{w \in D'} p_w \left(1 - \frac{1}{2} \sum_{u \in D'} p_u \right) \geq \frac{1}{6} \left(1 - \frac{1}{4} \right) = \frac{1}{8}.$$

Ve všech případech jsme ukázali, že pro každý dobrý vrchol v je pravděpodobnost označení některého jeho souseda v kroku (2) alespoň $Pr[\bigcup_{w \in N(v)} A_w] \geq Pr[\bigcup_{w \in D'} A_w] \geq 1/8 = 0,125$.

Pravděpodobnost, že vrchol w (soused) zůstane označený v kroku (3) je alespoň $1/2$. To plyne ze stejného výpočtu jako pro nezávislé pravděpodobnosti. Zde využijeme nezávislost dvou jevů pro w a jeho souseda, pro různé sousedy w používáme pouze odhad na sjednocení pomocí součtu a ten nezávislost nepotřebuje.

Celkově tedy dobrý vrchol odstraníme s pravděpodobností alespoň $\alpha = 0,125/2 = 0,0625$. \square

Všimněme si, že jsme dostali skoro stejně silný odhad jako pro nezávislé jevy. Pozorný čtenář si všimne, že pro horší odhad bychom v důkaz mohli zjednodušit a rozebírat méně případů velikosti D' , naopak rozebráním více případů bychom se mohli ještě o trochu přiblížit odhadu pro nezávislé jevy.

9 Pravděpodobnostní testování identit s maticemi a polynomy

9.1 Matice

9.2 Polynomy

Nyní se budeme zabývat pravděpodobnostním testováním identit s polynomy, tedy rovnosti polynomů více proměnných. Podobně jako u matic stačí testovat rovnost daného polynomu nulovému polynomu.

Stejně jako u testování identit s maticemi se efektivita algoritmu odlišuje podle zadání polynomu. Pokud by polynom byl dán explicitně jako součet monomů, je jednoduché ověřit, zda součet koeficientů u monomů se stejnými mocninami proměnných je vždy 0. Zajímavější je případ, kdy je polynom dán jinak, třeba nějakou krátkou formulí nebo procedurou, která umožňuje vyhodnocení v libovolném bodě. Pak můžeme krátce zakódovat polynom s exponenciálně mnoha různými monomy, např. $(1 + x_1)(1 + x_2) \cdots (1 + x_n)$ a rozvinutí polynomu a porovnání všech monomů není efektivní. Tomuto problému se říká testování polynomiálních identit, zkráceně PIT (z anglického “polynomial identity testing”). V našich aplikacích budou polynomy často dány ve formě symbolického determinantu.

Pokud pracujeme nad konečnými tělesy, je testování polynomiálních identit jiný problém než testování, zda se polynom rovná nule pro všechny hodnoty proměnných. Například nad dvouprvkovým tělesem se polynom $x^2 - x$ vždy vyhodnotí na 0, i když se o nulový polynom nejedná. (Je-li polynom roven nulovému, pak ovšem i jeho hodnota je vždy 0. Pro polynomy více proměnných je složitost obou problémů podstatně různá. Na problém testování, zda je polynom všude nula, nad dvouprvkovým tělesem se dá zredukovat jazyk výrokových tautologií, a to je *coNP*-úplný problém. Pro testování polynomiálních identit si předvedeme efektivní pravděpodobnostní algoritmus. Tento rozdíl ovšem existuje jen u konečných těles; je-li těleso nekonečné, pak polynom všude rovný 0 je rovný nulovému polynomu. Jak uvidíme, totéž platí i v konečném tělese, které je dostatečně velké v závislosti na stupni polynomu.

V našem algoritmu budeme ve skutečnosti testovat, zda je polynom rovný nule pro náhodně vybraný bod z dostatečně velké množiny. K tomu je nutné umět odhadnout počet kořenů. U polynomů s jednou proměnnou je to jednoduché: Polynom stupně nejvýše d má nejvýše d kořenů. Obdobný odhad platí i pro polynomy více proměnných. Řekneme, že **celkový stupeň** polynomu je nejvýše d jestliže v každém monomu (v explicitní reprezentaci) je součet stupňů všech proměnných nejvýše d .

Lemma 9.1. *Nechť $P(x_1, \dots, x_n)$ je polynom v n proměnných celkového stupně d nad tělesem K , který není identicky nulový. Nechť $S \subseteq K$ je konečná neprázdná a nechť $r_1, \dots, r_n \in S$ jsou nezávislé uniformně náhodné proměnné. Pak*

$$\Pr[P(r_1, \dots, r_n) = 0] \leq \frac{d}{|S|}$$

Důkaz. Indukcí podle n . Napišme polynom P jako $P(x_1, \dots, x_n) = x_1^k A(x_2, \dots, x_n) + B(x_1, \dots, x_n)$, kde x_1^k je nejvyšší mocnina x_1 v P a polynom B má stupeň v x_1 menší než k (tj. A sdružuje všechny monomy P s x_1^k).

Uvědomme si, že pro každé dva jevy E a F platí $\Pr[E] \leq \Pr[F] + \Pr[E \mid \neg F]$. Použijeme tuto nerovnost pro jevy $E \iff P(r_1, \dots, r_n) = 0$ a $F \iff A(r_2, \dots, r_n) = 0$.

Protože stupeň A je nejvýše $d - k$ a $A \not\equiv 0$, z indukčního předpokladu plyne $\Pr[F] = \Pr[A(r_2, \dots, r_n) = 0] \leq (d - k)/|S|$.

Pro každou konkrétní hodnotu r_2, \dots, r_n , pro kterou $A(r_2, \dots, r_n) \neq 0$, je $P(x_1, r_2, \dots, r_n)$ polynom stupně právě k a tedy má nejvýše k kořenů mezi $|S|$ možnými hodnotami pro r_1 . Náhodné r_1 je tedy kořenem s pravděpodobností nejvýše $k/|S|$. Průměrováním přes všechny hodnoty r_2, \dots, r_n dostaneme $\Pr[E \mid \neg F] = \Pr[P(r_1, \dots, r_n) = 0 \mid A(r_2, \dots, r_n) \neq 0] \leq k/|S|$.

Celkově tedy $\Pr[P(r_1, \dots, r_n) = 0] \leq (d - k)/|S| + k/|S| = d/|S|$. \square

Algoritmus je zřejmý...

Pokud by existoval deterministický algoritmus pracující v polynomiálním čase, plynulo by z toho, že buď některé problémy v NEXP nelze počítat polynomiálními booleovskými obvody nebo permanent nelze počítat polynomiálními aritmetickými obvody.

10 Perfektní párování

Nyní algoritmus pro testování identit polynomů použijeme k testování existence perfektního párování a později postup modifikujeme pro nalezení párování.

Testovat budeme ve skutečnosti nenulovost určitých symbolických determinantů. Nyní definujeme potřebné matice a dokážeme jejich základní strukturální vlastnosti.

Edmondsova matice bipartitního grafu $G = (U, V, E)$ na vrcholech $U = \{u_1, \dots, u_n\}$ a $V = \{v_1, \dots, v_n\}$ je matice polynomů B rozměru $n \times n$ definována předpisem

$$B_{ij} = \begin{cases} x_{ij} & \text{pro } (u_i, v_j) \in E \\ 0 & \text{jinak.} \end{cases}$$

Věta 10.1. *Nechť B je Edmondsova matice bipartitního grafu $G = (U, V, E)$. Pak platí*

- (i) *rank(B) je roven velikosti největšího párování v G .*
- (ii) *Graf G má perfektní párování právě když je matice B regulární.*

Tutleho matice grafu $G = (V, E)$ na n vrcholech $V = \{v_1, \dots, v_n\}$ je matice polynomů B rozměru $n \times n$ definována předpisem

$$B_{ij} = \begin{cases} x_{\{i,j\}} & \text{pro } \{v_i, v_j\} \in E \text{ a } i < j \\ -x_{\{i,j\}} & \text{pro } \{v_i, v_j\} \in E \text{ a } i > j \\ 0 & \text{jinak.} \end{cases}$$

Definice 10.2. Necht q je monom polynomu s proměnnými x_e , $e \in E$. Pak $F(q)$ označuje multimnožinu hran z E , kde hrana e se vyskytuje tolikrát, kolik je stupeň proměnné x_e v q .

Lemma 10.3. Necht q je monom, který má v determinantu Tutteho matice grafu $G = (V, E)$ nenulový koeficient. Pak multigrafu $(V, F(q))$ je disjunktním sjednocením sudých cyklů a každý vrchol má stupeň 2.

Věta 10.4. Necht B je Tutteho matice grafu $G = (V, E)$. Pak platí:

- (i) $\text{rank}(B)$ je roven dvojnásobku velikosti největšího párování v G .
- (ii) Graf G má perfektní párování právě když je matice B regulární.

10.1 Testování existence perfektního párování

Počítat determinanty umíme v polynomiálním čase (nejlepší známé algoritmy potřebují $n^{2.3727}$ aritmetických operací).

10.2 Paralelní algoritmus pro nalezení perfektního párování

Determinant umíme počítat rychle i na paralelních strojích. Determinant matice s k -bitovými čísly umíme počítat v čase $O(\log^2 n)$ na $O(n^{3.5k})$ procesorech.

Naivní algoritmus, jeho korektnost pokud existuje jediné párování...

Následující důležité lemma ukazuje, že pro náhodně zvolené váhy hran je v grafu jediné perfektní párování minimální váhy. Vhodná modifikací Edmondsovy či Tutteho matice nám pak umožní navrhnout rychlý paralelní algoritmus pro hledání tohoto párování.

Lemma je formulováno pro obecné systémy množin daného univerza, pro naše použití bude vhodné univerzum množina hran daného grafu. V lemmatu je pozoruhodné jednak to, že váhy stačí volit z malé množiny, konkrétně stačí lineární v počtu prvků univerza, a jednak to, že odhad pravděpodobnosti vůbec nezávisí na počtu množin v systému.

Lemma 10.5 (Izolující lemma). Necht je dán systém množin $S_1, \dots, S_N \subseteq \{a_1, \dots, a_m\}$ a množina vah $R \subseteq \mathbb{R}$, $|R| = r$. Předpokládejme, že volíme váhy prvků univerza $w(a_1), \dots, w(a_m) \in R$ uniformně a nezávisle. Označme váhu množiny S jako $w(S) = \sum_{a \in S} w(a)$. Pak

$$\Pr[(\exists i, j \in \{1, \dots, N\}, i \neq j)(w(S_i) = w(S_j) = \min_{k=1}^N w(S_k))] \leq \frac{m}{r}.$$

Modifikovaná verze Tutteho matice bipartitního a obecného grafu...

PARALELNÍ PERFEKTNÍ PÁROVÁNÍ

Vstup: Graf $G = (V, E)$.

- (1) $M := \emptyset$. Pro každou hranu $uv \in E$ vyber nezávisle uniformně náhodně váhu $w(uv) \in \{1, \dots, 2|E|\}$.
- (2) Necht C je Tutteho matice grafu G po substituci $2^{w(uv)}$ za x_{uv} .
- (3) Spočítej $\det(C)$ a W takové, že 2^W je nejvyšší mocnina dvojky, která dělí $\det(C)$.
- (4) Pro každou hranu $\{u, v\} \in E$ paralelně spočítej $d = \det(C^{\{u,v\}})$, kde $C^{\{u,v\}}$ je matice, která vznikne z C vynecháním dvou řádků a dvou sloupců odpovídajících u a v . Jestliže $d \cdot 2^{2w(uv)} / 2^W$ je liché celé číslo, přidej $\{u, v\}$ do M .
- (5) Paralelně pro každý vrchol zkontroluj, zda jeho stupeň je 1. Pokud ano, vystup M .

Lemma 10.6. (i) Jestliže 2^W je největší mocnina dvojky, která dělí $\det(C)$, pak v grafu G existuje perfektní párování M s váhou nejvýše $W/2$.

(ii) Jestliže graf G má jediné perfektní párování M minimální váhy $W/2$, pak

(a) 2^W je největší mocnina dvojky, která dělí $\det(C)$ a

(b) hrana $uv \in E$ je v M právě když největší mocnina dvojky, která dělí $\det(C^{\{u,v\}})$, je $2^{W-2w(uv)}$.

Důkaz. Nechť q je monom, který má v rozvoji determinantu Tutteho matice nenulový koeficient a $F(q)$ jemu odpovídající multimnožina hran. Příspěvek monomu q k determinantu modifikované Tutteho matice B je $\pm 2^{w(F(q))}$. Nejprve ukážeme pozorování, že v grafu G existuje párování váhy nejvýše $w(F(q))/2$.

Pozorování je triviální, pokud $F(q)$ odpovídá perfektnímu párování, tj. q obsahuje x_{uv} ve druhé mocnině pro každou hranu uv v párování a $F(q)$ je tvořeno párováním s hranami zdvojenými do cyklů délky 2. Obecně tomu tak být nemusí. Podle Lemmatu 10.3 tvoří $F(q)$ hrany sudých cyklů. To znamená, že můžeme $F(q)$ rozložit na dvě perfektní párování M_1 a M_2 tak, že z každého cyklu rozdělíme na dvě párování z nichž jedno přidáme do M_1 a druhé do M_2 . Jestliže $F(q)$ obsahuje cyklus délky 2, tak tato hrana bude v obou párováních. Protože v $F(q)$ má každý vrchol stupeň 2, jsou výsledná párování perfektní. Nyní je $w(M_1) + w(M_2) = w(F(q))$ a tedy buď $w(M_1) \leq w(F(q))/2$ nebo $w(M_2) \leq w(F(q))/2$, což dokazuje pozorování.

(i): Pokud 2^W je nejvyšší mocnina dvojky, která dělí $\det(C)$, pak existuje monom q s nenulovým příspěvkem $\pm 2^{w(F(q))}$ takovým, že $w(F(q)) \leq W$. Podle dokázaného pozorování pak v grafu G existuje párování váhy nejvýše $w(F(q))/2 \leq W/2$.

(ii): Předpokládejme, že G má jediné perfektní párování M minimální váhy $W/2$.

(a): Monom s x_{uv} ve druhé mocnině pro každou hranu $uv \in M$ přispívá $\pm 2^W$ v rozvoji $\det(C)$. Ukážeme, že pro každý jiný monom q s nenulovým koeficientem v rozvoji je $w(F(q)) > W/2$. Pro spor předpokládejme, že $w(F(q)) \leq W/2$. Pak z konstrukce v pozorování dostaneme dvě párování M_1 a M_2 taková, že $w(M_1) + w(M_2) \leq W$. Protože M má minimální váhu, tak $W = 2w(M) \leq w(M_1) + w(M_2) \leq W$. Nastávají tedy rovnosti a protože M je jediné párování minimální váhy, tak platí $M = M_1 = M_2$ a monom q je nutně monom odpovídající párování M . V rozvoji $\det(C)$ je tedy jediný monom s příspěvkem $\pm 2^W$, všechny ostatní nenulové příspěvky jsou dělitelné větší mocninou dvojky. Z toho plyne, že 2^W je nejvyšší mocnina dvojky, která dělí $\det(C)$.

(b): Pro hranu $uv \in E$ označme $G^{\{u,v\}}$ podgraf G indukovaný vrcholy $V \setminus \{u,v\}$. Pak $C^{\{u,v\}}$ je Tutteho matice grafu $G^{\{u,v\}}$. Rozlišíme dva případy.

Nechť $uv \in M$. Graf G má jediné perfektní párování minimální váhy, a tedy $G^{\{u,v\}}$ má jediné perfektní párování minimální váhy, a to $M \setminus \{uv\}$ s váhou $W/2 - w_{uv}$. Podle části (a) lemmatu použité pro $G^{\{u,v\}}$ je maximální mocnina dvojky, která dělí $\det(C^{\{u,v\}})$ rovna $2^{W-2w(uv)}$.

Nechť $uv \in E \setminus M$. Z předpokladu o M že $G^{\{u,v\}}$ nemá žádné perfektní párování s váhou $W/2 - w(uv)$ nebo menší, protože jinak by spolu s hranou uv tvořilo perfektní párování v G váhy nejvýše $W/2$ různé od M . Podle části (i) lemmatu použité pro $G^{\{u,v\}}$ je $\det(C^{\{u,v\}})$ dělitelný $2^{1+W-2w(uv)}$. \square

Věta 10.7. Algoritmus najde perfektní párování s pravděpodobností alespoň $1/2$ a pracuje v čase $O(\log^2 n)$ na $n^{O(1)}$ procesorech.

Existence deterministického paralelního algoritmu podobné efektivity je otevřená.

11 Rozvrhování na počítačích s nezávislými časy

Nyní budeme studovat následující zobecnění rozvrhování na identických strojích. Vstupem je matice hodnot p_{ij} , kde p_{ij} udává dobu trvání úlohy j na stroji i . Tyto hodnoty jsou na sobě zcela nezávislé. Cílem je opět minimalizovat délku rozvrhu.

ROZVRHOVÁNÍ NA STROJÍCH S NEZÁVISLÝMI ČASY

Vstup: Počet strojů m , časy běhu úloh $p_{ij} \in \mathbb{R}^+, i = 1, \dots, m, j = 1, \dots, n$.

Výstup: Rozvrh, tj. rozklad množiny $\{1, \dots, n\}$ na množiny I_1, \dots, I_m .

Cíl: minimalizovat délku rozvrhu, t.j. $\max_{i \in \{1, \dots, m\}} \sum_{j \in I_i} p_{ij}$.

Následující lineární program je přirozenou relaxací problému a celočíselná řešení přesně odpovídají rozvrhům.

$$\begin{aligned}
 & \text{minimalizuj} && T \\
 & \text{pro} && T \geq 0, \quad x_{ij} \geq 0, \quad i = 1, \dots, m, \quad j = 1, \dots, n \\
 & \text{za podmíněk} && \sum_{i=1}^m x_{ij} = 1 \quad \text{pro } j = 1, \dots, n \\
 & && \sum_{j=1}^n p_{ij} x_{ij} \leq T \quad \text{pro } i = 1, \dots, m
 \end{aligned} \tag{11.1}$$

Bohužel ale jeho optimum může být libovolně vzdálené celočíselnému optimu, takže ho pro aproximaci nemůžeme použít. Příklad...

Lépe nám poslouží následující lineární program pro rozhodovací verzi problému s parametrem T udávajícím požadovanou délku rozvrhu. Všechna přípustná celočíselná řešení odpovídají přesně všem rozvrhům délky nejvýše T . Navíc bude mít tu vlastnost, že pokud má přípustné zlomkové řešení, tak existuje celočíselné řešení s délkou rozvrhu nejvýše $2T$.

$$\begin{aligned}
 & \text{minimalizuj} && 0 \\
 & \text{pro} && x_{ij} \geq 0, \quad i = 1, \dots, m, \quad j = 1, \dots, n \\
 & \text{za podmíněk} && \sum_{i=1}^m x_{ij} = 1 \quad \text{pro } j = 1, \dots, n \\
 & && \sum_{j=1}^n p_{ij} x_{ij} \leq T \quad \text{pro } i = 1, \dots, m \\
 & && x_{ij} = 0 \quad \text{pro } p_{ij} > T
 \end{aligned} \tag{11.2}$$

Pro dané řešení lineárního programu definujme *graf zlomkových proměnných* jako bipartitní graf G , kde vrcholy jedné partity jsou stroje $\{1, \dots, m\}$, vrcholy druhé partity jsou úlohy $\{1, \dots, n\}$ a stroj i je spojen hranou s úlohou j právě když x_{ij} je neceločíselná.

Lemma 11.1. *Pokud je lineární program (11.2) přípustný, tak existuje optimální řešení takové, že graf neceločíselných proměnných G je les. Navíc takové řešení lze nalézt v polynomiálním čase.*

Důkaz. Pokud G obsahuje cyklus, ukážeme, že můžeme upravit hodnoty proměnných odpovídajícím hranám cyklu tak, že neceločíselných proměnných bude méně. ... \square

LP-UNRELATED

Vstup: Časy $p_{ij} \in \mathbb{R}^+, i = 1, \dots, m, j = 1, \dots, n$.

- (1) Najdi počáteční přípustný rozvrh tak, že každá úloha j se rozvrhne na počítač i s minimálním p_{ij} ; nechť jeho délka je τ .
- (2) V intervalu $[\tau/m, \tau]$ najdi minimální hodnotu T , pro kterou má lineární program (11.2) přípustné řešení.
- (3) Nechť $x_{ij}, i = 1, \dots, m, j = 1, \dots, n$ je přípustné řešení lineárního programu (11.2) takové, že graf neceločíselných proměnných G je les.
- (4) Dokud existuje neceločíselná proměnná x_{ij} , proved':
Nechť i a j jsou takové, že x_{ij} je jediná neceločíselná z $x_{ij'}, j' = 1, \dots, n$. Přiřaď úlohu j celočíselně na stroj i , tj. $x_{ij} := 1$ a $x_{i'j} := -0$ pro $i' \neq i$.

Výstup: Rozklad definovaný jako $I_i := \{j \mid x_{ij} = 1\}$.

Věta 11.2. *Algoritmus LP-UNRELATED lze implementovat v polynomiálním čase a výsledek je 2-aproximační algoritmus pro rozvrhování s nezávislými časy.*

Důkaz. Především musíme ověřit, že algoritmus lze provést v polynomiálním čase, což u kroků (2) a (4) není zřejmé.

V kroku (2) a (3) použijeme polynomiální algoritmus pro lineární programování. Dále si uvědomíme, že struktura lineárního programu (11.2) se v závislosti na T mění jedině v bodech, kde $T = p_{ij}$ pro nějaké i a j .

Jestliže les G je neprázdný, tak obsahuje list. List nemůže být úloha, protože součet proměnných u úlohy j je vždy 1, tj. $\sum_{i=1, \dots, m} x_{ij} = 1$; tedy nemůže být z proměnných $x_{ij}, i = 1, \dots, m$, právě jedna neceločíselná. List je tedy vždy stroj a můžeme provést krok (4). V kroku (4) se zachová celočíselnost proměnných, které už celočíselné byly. Pro každý stroj i se tedy provede nejvýše jedna iterace kroku (4), protože po ní jsou všechny proměnné $x_{ij'}, j' = 1, \dots, n$, celočíselné. Krok (4) tedy lze provést v polynomiálním čase.

... Zároveň alespoň jedna zlomková proměnná se stane celočíselnou.

Krok (4) provedeme pro každý stroj i nejvýše jednou a čas úloh přiřazených na stroj i se tím zvýší nejvýše o T . čelková délka rozvrhu je tedy na konci nejvýše $2T$. \square