

3 Exaktní metody a heuristiky

Podle prohledávání stavového prostoru dělíme metody na: úplné (všechny stavy), systematické (každý stav max. 1), obojí = exaktní řešení

3.1 Lokální metody, Pojem okolí v lokálních metodách, Konstruktivní a iterativní heuristické metody, Obrana před uváznutím v lokálním minimu

Stav Necht' $X = \{x_1, x_2, \dots, x_n\}$ jsou konfigurační proměnné problému II. Necht' $Z = \{z_1, z_2, \dots, z_m\}$ jsou vnitřní proměnné algoritmu A řešícího instanci I problému II. Pak každé ohodnocení s proměnných $X \cup Z$ je stav algoritmu A řešícího I.

Stavový prostor Necht' $S = \{s_i\}$ je množina všech stavů algoritmu A řešícího I. Necht' $Q = \{q_j\}$ je množina operací $S \rightarrow S$ takových, že $q_j(s_i) \neq s_i$ pro všechna s_i, q_j . Pak dvojici (S, Q) nazveme stavovým prostorem algoritmu A řešícího I.

Okolí stavu Okolí stavu $s \in S$ je množina stavů, dosažitelných z s aplikací některé operace $q \in Q$.

k-okolí stavu k-okolí stavu $s \in S$ je množina stavů, dosažitelných z s aplikací nejméně jedné a nejvýše k operací $q \in Q$.

Sousední stav Stav $s_0 \in S$ patřící do okolí stavu $s \in S$ se nazývá *sousedním stavem* (sousedem) stavu s .

Lokální metoda má vždy jen jeden aktuální stav, který zpracovává, přičemž uvažuje sousední stavy z (relativně malého) okolí. Úplné a systematické metody uschovávají každý stav z okolí pro pozdější zpracování. Proto jsou exaktní a proto mohou mít nadpolynomiální složitost.

Konstruktivní heuristika Začne z triviální konfigurace a postupnými kroky konstruujeme řešení.

Iterativní heuristika Začne z nějakého řešení a to postupně vylepšuje.

Dvojfázové heuristiky První fáze slouží k získání řešení (konstruktivně, náhodné řešení), ve druhé fázi iterativní vylepšování.

Jednoduché heuristiky • Pouze nejlepší

- Prvé zlepšení
- Heuristiky Kernighan-Lin (mají takové to podlouhlé okolí, projdou například pět stavů a pak se podívají, který z těch pěti byl nejlepší a z něj pokračují)

Lokální heuristiky, které neřeší problém lokálních minim, uváznou hned v prvním takovém. To se projevuje tím, že výsledné řešení silně závisí na startovacím stavu. Existuje několik metod, jak uváznutí řešit. Můžeme

- zvětšit okolí,
- startovat z několika různých (náhodných) počátečních řešení,
- vracet se z větví, které nevedou k řešení (detekujeme slepou uličku),
- dočasně připustit zhoršení aktuálního stavu (zvyšuje nároky na řízení algoritmu)

3.2 Globální metody

Při řešení instancí problému globálními metodami si pomáháme dekompozicí instance na podinstance. Výsledné řešení skládáme z jednotlivých řešení podinstancí. Triviální podinstance řešíme hrubou silou. Přírozeným modelem výpočtu je rekurze.

Základní postup tedy vypadá nějak takto:

$$I \in \Pi \left\{ \begin{array}{l} I_1 \in \Pi \longrightarrow Y_1 \\ I_2 \in \Pi \longrightarrow Y_2 \end{array} \right\} Y$$

instanci problému Π rozložíme na menší instance problému Π a vyřešíme je. Získaná řešení Y_1 a Y_2 pak sloučíme do výsledného řešení Y původní instance problému Π .

Podle specifických vlastností lze dekompozice rozdělit do tří skupin.

Přibližná dekompozice Pokud jsou Y_1 resp. Y_2 optimálními řešeními instancí I_1 resp. I_2 , pak je Y řešením (ne nutně optimálním) instance I . Pokud Y_1, Y_2 neexistují, nevíme nic.

Čistá dekompozice Pokud jsou Y_1 resp. Y_2 optimálními řešeními instancí I_1 resp. I_2 , pak je Y optimálním řešením instance I . Pokud Y_1, Y_2 neexistují, Y také neexistuje.

Přesná dekompozice Taková čistá dekompozice, že každé optimální řešení Y se dá složit z nějakých optimálních řešení Y_1 a Y_2 (ze všech optimálních řešení Y_1, Y_2 se dají složit všechna optimální řešení Y).

Pokud je navíc dekompozice taková, že jedna z dekomponovaných instancí je triviální, hovoříme o *redukci* (přibližné, čisté, přesné).

Dekompozice:

- optimální $I_1..I_k \Rightarrow$ suboptimální I
 - čistá: optimální $I_1..I_k \Rightarrow$ optimální I (pokud I nemá řešení, alespoň jeden I_n taky ne)
 - přesná: optimální $I_1..I_k \Rightarrow$ všechna optimální I
- Dílčí řešení jsou optimální, páč jinak se chyba kumuluje.

3.3 Rekurze

Rekurze znamená *sebeopakování*

Def: Nechť f je funkce n proměnných a funkce g $n+2$ proměnných. Operací primitivní rekurze nazveme funkci $r(x,y)$, jestliže pro všechna x a pro $y=[y_1, \dots, y_n]$ platí

1. $r(0,y) = f(y)$
2. $r(x+1,y) = g(x, y, r(x,y))$

PRF - třída primitivně rekurzních fcí je uzávěr množiny $R=\{S(x), N(x), U_i^n(x)\}$ nad operacemi skládání a primitivní rekurze. Třída PRF zahrnuje všechny numerické fce, se kterými se setkáváme. Např.: $x+y, x.y, y^x, x!$.

Rekurzivní podprogram - podprogram Q je rekurzivní, když používá podprogramy, z nichž alespoň jeden je původním podprogramem Q . Takové použití podprogramu naz. rekurzivním voláním podprogramu. Speciálním případem je přímé rekurzivní volání, tj. případ. kdy v operační části programu dochází k volání téhož podprogramu.

Substituční metoda - odhadneme řešení a matematickou indukcí je dokážeme.

Iterační metoda - spočívá v převedení rekurentního výrazu $T(n)$ v řadu, kterou pak sečteme.

Mistrovská metoda - podle tvaru rekurentní formule vybereme známé řešení.

$$T(n)=a.T(n/b)+f(n)$$

$$T(n)=\Theta(n^k), \text{ jestliže } f(n)=O(n^{k-E}), E>0$$

$$T(n)=\Theta(n^k \cdot \log n), \text{ jestliže } f(n)=\Theta(n^k)$$

$$T(n)=\Theta(f(n)), \text{ jestliže } f(n)=\Omega(n^{k+E}), E>0 \text{ a když } a.f(n/b) \leq c.f(n) \text{ pro } c<1 \text{ a } n \text{ velké}$$

Strom rekurze - kořenový strom, v němž každý uzel reprezentuje jeden výpočet algoritmu, vzdálenost uzlu od kořene udává hloubku rekurzivního volání.

Převod rekurze na iteraci - v iteračním programu jsou třeba navíc tzv. akumulční proměnné, v nichž se hodnoty z předchozí iterace přepisují novými hodnotami. Ne vždy ovšem vystačíme s jednou proměnnou ve fci akumulátoru. Počet pomocných proměnných můžeme stanovit pomocí tzv. grafu závislosti.

implementace

při každém vnoření se na zásobníku vyhradí paměť pro datový segment (lok. proměnné) a návratová adr. Na konci procedury se provede návrat na adresu ret, ukazatel se nastaví na začátek stavových proměnných pod vrcholem zásobníku. Všechny lokální proměnné se adresují relativně vzhledem k ukazateli na datový segment procedury, která se právě provádí.

dokážte, že součet je rekurzivní funkce

$A(x,y)=x+y$ je PRF neboť $A(0,y)=0+y=y$; $A(x+1,y)=(x+1)+y=(x+y)+1=A(x,y)+1$

jak zjistit složitost rekurze

Paměťová složitost $S_p=h \cdot L_S+L_G$. Při výpočtu oper. sloz. či čas. sloz. $T(n)$ vycházíme z toho, že v každé nižší hladině rekurze se rozsah řešeného problému snižuje. Např. Merge sort $T(n)=O(1) \ n=1$; $2 \cdot T(n/2)+O(n)$. Dále substituční, iterační a mistrovskou metodou.

Mistrovská: $T(n)=aT(n/b)+f(n)$, kde a, b jsou konst. a $f(n)$ je asympt. pozit. funkce.

mechanismus detekce rekurze při překladu

je třeba zkoumat strukturu volání celého programu (SVCP), např. sestavením relace $\rho \subseteq P \times P$, $\rho = \{[P_i, P_j] : P_i \text{ volá proceduru } P_j\}$, kde P je množina všech procedur. Proc. P_i je rekurzivní, když $[P_i, P_i] \in \rho^*$, neboli když strukt. SVCP vyjádříme orientovaným grafem G , kde uzly budou reprezentovat procedury a hrany volání proc., pak P_i bude rekurze volána, jestliže leží v některém z cyklu grafu G .

3.4 Iterace

Iterace v programování znamená opakované volání funkce v počítačovém programu. Zvláštní formou iterace je rekurze.

Ukázka iterace:

```
var i, a := 0           // inicializace před iterací
for i from 1 to 3 {    // smyčka se opakuje třikrát
    a := a + i         // zvýšit hodnotu o hodnotu i
}
print a                // vytisknout číslo 6
```

V tomto úseku programu se hodnota proměnné i postupně mění a nabývá hodnot 1, 2 a 3. Taková postupná změna je charakteristickým znakem iterace.

3.5 Rozděli a panuj

Algoritmy rozděli a panuj jsou založeny na přibližné dekompozici. Opakované řešení dekomponovaných instancí je řídké. Zvláštním případem jsou metody zmenši a panuj, kdy je potřeba řešit jen jednu z dekomponovaných instancí.

Příklady: Quick sort, Merge sort

Předpoklady: Rovnoměrné rozdělení na k podprostorů, sloučením jednotlivých řešení $V(i)$ dostaneme výsledné řešení $V(n)$.

1. Rozděli prostor $P(n)$ na prostory $P(i)$, Sjednocení $P(i)$ je $P(n)$
2. Aplikuj algoritmus A na podprostory $P(i)$ a dostaneš řešení $V(i)$
3. Sloučením $V(i)$ vznikne řešení $V(n)$

Oper. sloz. $T(n)=T_{\text{Rozdělení}} + kT(n/k) + T_{\text{Sloučení}}$

3.6 Algoritmy pro prohledávání stavového prostoru

3.6.1 S návratem

Pro grafové algoritmy – stromy

prohledávám do hloubky, když uzel nevyhovuje nějaké podmínce, vrátím se a jedu v jiném následníkovi = prohledávání do hloubky (programuje se rekurzí).

Označuje se jako algoritmus „POKUS OMYL“ a řeší se jím problém pokrytí, vzájemného vyloučení (šachovnice 8 dam), optimálního výběru a problém vzájemného přiřazení.

3.6.2 Metoda větví a hranic)

Odřezávají se neperspektivní větve na základě znalostí optimalizačního kritéria a omezujících podmínek. (Jedná se o jistou verzi prohledávání do šířky.)

Příklad:

Máme funkci, kterou chceme maximalizovat a omezující podmínky pro hledané řešení.

Hledáme konfiguraci (ohodnocení vstupních veličin), která je maximální a vyhovuje omezujícím podmínkám.

Princip:


Budeme vytvářet strom stavového prostoru od kořene. Jednotlivé uzly jsou konfigurací nějakého řešení a mají ohodnocení podle nejlepšího možného (teoreticky dosažitelného – bez ohledu na omezující podmínky) řešení z daného stavu. Pro průchod do dalšího uzlu si vybíráme vždy podle nejlepšího ohodnocení daného uzlu. Uzly, které nevyhovují omezující podmínce, dále nerozvíjíme (ořezáváme celé větve).

3.6.3 Zametací technika – Plane sweep

Hlavně pro geometrické úlohy.

Myšlenka:

Prostorem P na němž probíhá řešení, proložíme zametací nadrovinu (v 2E je to přímka, v 3E rovina), tuto nadrovinu posouváme mezi krajními body P . Nadrovinou rozdělujeme P na levý (v něm již byla úloha vyřešena) a pravý (v něm se teprve bude hledat) poloprostor. Spolu se zametací nadrovinou udržujeme strukturu S , která obsahuje všechny informace o stavu řešení úlohy v levém polop. (řešení v levém polop. je relevantní pro řešení v pravém polop). Stav struktury S se tedy mění s polohou nadrovinou. Nadrovinu se posouvá do pozic, kde se stavy řešení mění. Tyto pozice se nazývají postupový plán, který se může s polohou zametací nadrovinou měnit.



obr. 8.3 Nalezení průsečíku 3 přímek zametací technikou

Řešení zahájíme pro polohu zametací přímky x_{min} . Pro tuto polohu vytvoříme počáteční y -strukturu. Každé dvě sousední přímky v y -struktuře se mohou protínat. Pokud jejich průsečíky leží vpravo od zametací přímky, zařadíme je do x -struktury. V každé poloze zametací přímky pak postupujeme takto:

1. Opakující se bod v y -struktuře je průsečík dvou přímek nebo více přímek a generuje jeden nebo více výstupů.
2. Pro opakující se body zaměníme pořadí odpovídajících přímek v y -struktuře. Zaměněné přímky se mohou se svými novými sousedy protnout pouze vpravo od zametací přímky, neboť vlevo již byly všechny průsečíky nalezeny. Tyto průsečíky zařadíme do x -struktury.

Popsaný algoritmus nalezení 3 průsečíků zametací technikou má složitost řádově $O(n^2 \cdot \log_2 n)$, neboť zametací přímka bude mít v nejhorším případě $n \cdot (n - 1) / 2$ poloh a složitost kroku 1 a 2 v každé poloze zametací přímky je dána hledáním ve vyváženém binárním stromu y -struktury. Inicializační fáze má operační složitost řádově $O(n \cdot \log_2 n)$, takže celkovou asymptotickou složitost neovlivní.

3.7 Princip a vlastnosti dynamického programování

Postupujeme zdola nahoru (od dílčích úloh), tabelujeme výsledky (uchovávané) dílčích úloh a používáme je – nedochází k opakovaným výpočtům, paměťově náročné.

1. Najdeme a uložíme řešení dílčích úloh,
2. Kombinací těchto získáme celé řešení

Např. věci v batohu:

$cena(i+1, w)$

- $cena(i, w)$ – bez předmětu i

- $cena(i, w-w_i)$ – s předmětem i

Hodnoty jsou tabelované podle i a w .

Dynamické programování je čistá dekompozice. Dekomponované instance se dají charakterizovat malým počtem hodnot a řešení dekomponovaných instancí lze těmito hodnotami indexovat. Zároveň se dají dekomponované instance rozdělit do disjunktních tříd (stupňů) tak, že k výpočtu instancí jednoho stupně je třeba jen instancí právě jednoho jiného stupně.

Dynamické programování lze formulovat dvěma způsoby. *Rekurzivní* způsob vyjde ze zadané instance, stanoví, které podinstance je třeba řešit, až dosáhne triviálních instancí. V praxi se tento způsob nepoužívá.

Dopředná formulace také vyjde ze zadané instance, spočítá všechny složitější podinstance, až dosáhne zadané instance.

Řešení jednotlivých podinstancí se samozřejmě v obou případech zaznamenávají a jsou tak vždy počítány nejvýše jednou.

3.8 Princip a kostra – simulované ochlazování

Vyváznutí z lok.extrémů: Jsem ochoten přijmout i horší řešení, ale jen s nějakou pravděpodobností (ta záleží na velikosti zhoršení a aktuální teploty).

- | | | |
|-----------------------------|-------------------------|----------------------------------------------------------------|
| $\delta \rightarrow 0$ | $p_{new} \rightarrow 1$ | nepatrné zhoršení se přijme vždy |
| $\delta \rightarrow \infty$ | $p_{new} \rightarrow 0$ | velké zhoršení se přijme zřídka |
| $T \rightarrow 0$ | $p_{new} \rightarrow 0$ | při nízké teplotě se zhoršení přijmou s malou pravděpodobností |
| $T \rightarrow \infty$ | $p_{new} \rightarrow 1$ | při vysoké teplotě se přijmou i velká zhoršení |

```
t=t0
repeat
  repeat
    state=try(state, t)
    if (state.better(best))
      best = state;
  until rovnováha();
  t=ochlad(t);
until zmrazeno();
```

t_0 – počáteční teplota. Na počátku velká. Buď to náhodně nebo určeno jinou heuristikou.

try – Vyberu náhodně souseda, pokud je lepší než state, beru ho. Když je horší, beru s pravděpodobností $e^{-\delta/T}$, kde δ je velikost zhoršení ($new.cost() - state.cost()$) a T je aktuální teplota.

Rovnováha() – pevný počet iterací nebo počet iterací je funkcí teploty

Ochlazení – nelineární $t=0,9.t$ nebo (Hajek) $t_k = 1 / \log(1+k)$, kde k je číslo kroku a c je hloubka lokálního minima

Podle počtu přijatých změn, lze i ohřívát (ven z lok. minima)

Zmrazeno() – pevná mez teploty nebo počet nových přijatých stavů je malý,

Hikův teorém (známe hloubku lok. minima, pst vyvedení $< \epsilon$)

Modifikace: - jednodušší vztah pro pst (lehčí výpočet) $p=1-\delta/T$

- pro malé t prohlížím sousedy systematicky ne náhodně (moc odmítnutých kandidátů)

- paralelizace

3.9 Princip a kostra – genetické algoritmy

Beru více stavů najednou – pravděpodobnost, že uvážnu v lok.extr. je menší.

Zachovává rysy „dobrých“ řešení – funkce fitness. Genetické operace křížení a mutace.



Iterace:

```
repeat G=new_generation(G) until hotovo();
```

Překrytí generací:

- žádné – nahradí se celá G potomky a mutanty
- částečné – vyhodím horší část (např. půlku) generace a doplním potomky na pův. velikost
- úplné – nahradím jednoho (2) jedince novými potomky

Funkce fitness_select():

- přímo optimalizační kritérium (moc rychle konverguje)
- ranking – jedince beru s psí závesející na jeho fitness
- scaling – „změkčím“ optimalizační kritérium $g(x) = a \cdot f(x) + b$; zachovám střední hodnotu! (jedince seřadím dle fitness a udělám si novou lineární funkci podle fitness jedince a výběr provádím na upravené funkci)

Modifikace – messy GA – kříží se různá lokální minima získaná konstruktivní metodou; složitější křížení na základě vlastností dobrých jedinců

3.10 Princip a kostra – tabu prohledávání

tabu je historie dané délky;

ovlivňuje okolí stavu, příp. heuristickou fci;

na modif. okolí zpravidla best-first

tabu – kritérium odmítání operací (nových stavů), např. historie inverzních ops, již prohledané stavy, četnost nějaké operace

aspirační fce – nový stav beru, i když je tabu; nejlepší výsledek, nejlepší lok. výsledek, všechny jsou tabu, tak tahle

- nebo na základě sledování atributů stavu, ovlivňují aspir. fci nebo optim. kritérium (intenzifikace)

tabu-lhůta – staticky, dynamicky podle atributů

- mohou prohledávat i stavy, co nejsou řešení (s nějakou penailzací)

Paměť:

základ adaptace a učení: jaké prvky

(rysy) řešení mají podstatný vliv na

- kvalitu řešení

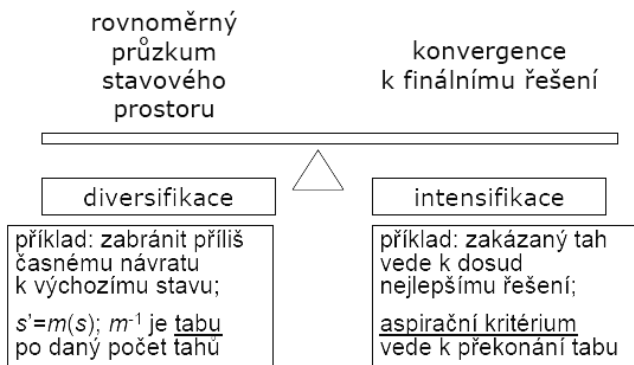
- strukturu řešení

špatné strategické rozhodnutí může

přinést více informace než dobré

náhodné rozhodnutí (Glover, Laguna)

Cíle řízení



Práce s pamětí

- úplný záznam všech tahů není možný
- často potřebné zakázat tahy s podobnými vlastnostmi
- vyhledávání musí být rychlé
- ⇒ abstrakce
 - tah nebo skupinu tahů popsat pomocí atributů
 - skladovat omezený počet elitních řešení resp. jejich sousedů (explicitní paměť)
 - skladovat historii po omezený počet tahů (implicitní krátkodobá paměť)
 - skladovat omezené statistiky pro celý průběh (implicitní dlouhodobá paměť)

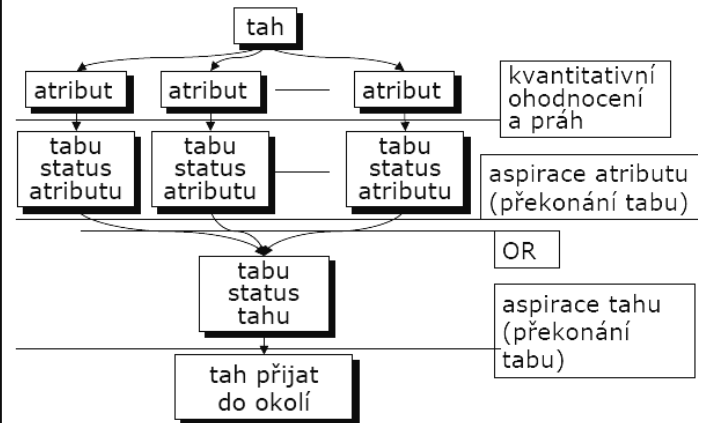
Volba tabu lhůty

- statická: $t=7$, $t=\sqrt{n}$
- dynamická: $t=5..9$, $t=(0,5..2).\sqrt{n}$
- strategie změny?

Intenzifikace a diverzifikace

- obě metody (řízení okolí a modifikace heuristické funkce) mohou sloužit oběma cílům
- řízení okolí: zpravidla vyloučení stavů, které nechceme prohledávat
 - které jsou příliš podobné známým stavům
 - které nejsou dost podobné známým stavům
- modifikace heuristické funkce:
 - pokutování příliš podobných / odměňování nepodobných
 - odměňování podobných / pokutování nepodobných

Řízení okolí



Aspirační kritéria

- základní možnost: jestliže všechny tahy jsou tabu, přijmout „nejméně tabu“ tah
- aspirace tahu:
 - vede k dosud nejlepšímu řešení
 - vede k odlišnému řešení