

Srovnání prohledávacích algoritmů

Srovnání prohledávacích algoritmů

● $A \rightarrow B$ znamená, že uzly prohledávacího stromu B jsou i v stromě A

● za předpokladu stejného uspořádání hodnot i proměnných

● Existuje srovnání i pro další algoritmy?

Jaké algoritmy používat pro daný problém?

● **Experimentální porovnání** na různých sadách problémů (*benchmarks*)

● reálné problémy

● nahodně vygenerované problémy

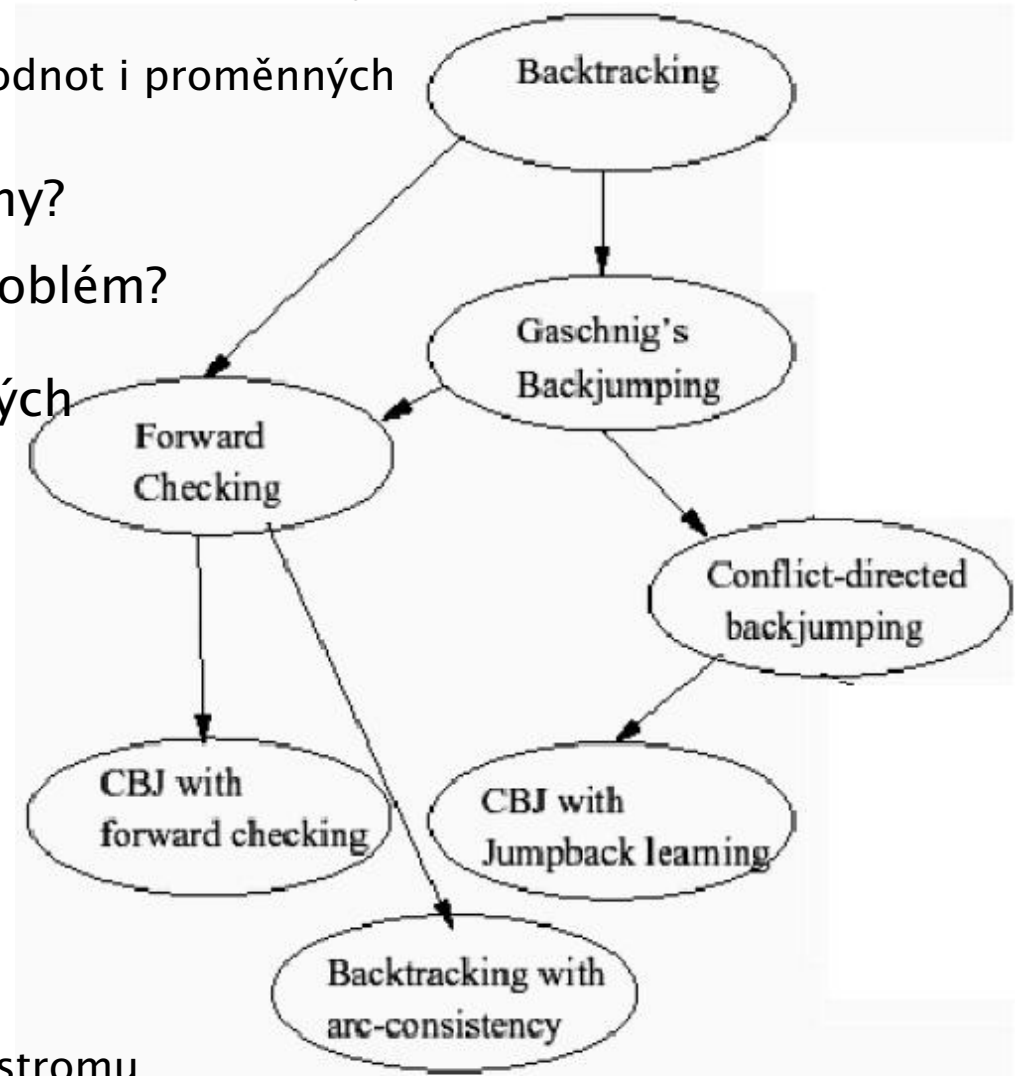
● aplikačně založené náhodné problémy

● Kriteria

● CPU čas

● velikost generovaného prohledávacího stromu

● počet volání procedury (např. Consistent)



Experimenty na reálných problémech

- Sady reálných problémů (*benchmarks*), na kterých lze algoritmy porovnávat
- CSPLib <http://www.cspLib.org>
 - knihovna problémů pro omezující podmínky (otevřená pro nové problémy)
 - kolem 130 problémů z oblasti jako je rozvrhování, návrh a konfigurace, kombinatorika, bioinformatika, hry
 - popis problému, reference na jeho řešení, data, výsledky
někdy i řešení nebo podrobné studie různých možností řešení
 - příklady
 - dopravní signalizace v čase na zadaných křižovatkách, výrobní linka, problém batohu, sledování cíle v distribuovaných sensorických sítích, ...
- Problém: výsledky lze stále velice obtížně zobecnit na další problémy
 - pro jeden problém je lepší jeden algoritmus, pro další problém jiný algoritmus

Náhodné problémy

- Algoritmy porovnávány na umělých, náhodně vygenerovaných problémech
 - lze generovat problémy různé obtížnosti (**fáze přechodu**)
 - libovolný počet datových instancí
 - lze testovat, co se stane (např. s parametry algoritmu) při změnách problému
- **Náhodné binární CSP (*random binary CSP*)**
 - parametry (n, m, p_1, p_2)
 - n počet proměnných
 - m počet hodnot v doméně proměnných
 - p_1 pravděpodobnost, že existuje omezení na páru proměnných
 - p_2 pravděpodobnost, že omezení povoluje daný pár hodnot

Aplikačně založené náhodné problémy

● Identifikace problémové domény

- lze definovat parametrizovatelné problémy
- problémy mají přitom specifickou (z aplikace vycházející) strukturu
- problémy lze náhodně generovat s různým nastavením parametrů

● Výhody

- zaměřené na reálné problémy
- generování řady problémů umožňuje statistické porovnání

● Příklad: **shop scheduling** problémy

- m strojů
- n úloh, každá úloha se skládá z m operací prováděných na odlišných strojích
- operace jedné úlohy nesmí být prováděny zároveň
- podmínky na sekvencování operací úlohy (žádné, dáno pořadí, stejné pořadí pro všechny)
- minimalizace dokončení poslední úlohy, minimalizace největšího zpoždění úlohy, ...

Fáze přechodu

● Náhodný k -SAT problém


- formule pevné délky jsou generovány výběrem m klauzulí
- každá klauzule délky k je uniformně náhodně generována z množiny všech klauzulí

● **Obtížnost nalezení řešení**

- při malém počtu klauzulí je většina problémů splnitelná a snadno řešitelná
- při velkém počtu klauzulí je detekována snadno nespłnitelnost většiny problémů
- nalezení řešení je nejobtížnější za předpokladu, že cca 50% problémů je splnitelných

● Fenomén **fáze přechodu** (*phase transition*)

- fáze přechodu z obtížně řešitelných problémů na snadno řešitelné problémů



Využití fáze přechodu:

Ize generovat problémy různé obtížnosti

poměr počtu klauzulí vůči počtu proměnných

Optimalizace & soft omezení: modely

Optimalizační problém s podmínkami (COP)

● Problém splňování podmínek (X, D, C)

- proměnné $X = \{x_1, \dots, x_n\}$

- domény $D = \{D_1, \dots, D_n\}$

- omezení $C = \{C_1, \dots, C_n\}$

 - C_i je definováno na $Y_i \subseteq X$, $Y_i = \{x_{i_1}, \dots, x_{i_k}\}$

 - C_i je podmnožina $D_{i_1} \times \dots \times D_{i_k}$

● **Objektivní funkce** $obj : Sol \rightarrow W$

● Základní definice:

Optimalizační problém s podmínkami (*constraint optimization problem*)

- nalezení řešení \vec{d} pro (X, D, C) takové, že $obj(\vec{d})$ je optimální

 - optimální \equiv maximální nebo minimální

COP: operační výzkum

● **Pevné (hard, required) omezení** $C_h = \{C_1, \dots, C_n\}$ relace

● C_i je definováno na $Y_i \subseteq X$, $Y_i = \{x_{i_1}, \dots, x_{i_k}\}$

● C_i je podmnožina $D_{i_1} \times \dots \times D_{i_k}$

● **Měkké (soft) omezení** $C_s = \{F_1, \dots, F_l\}$ funkce

● F_j je definované nad $Q_j \subseteq X$, $Q_j = \{x_{j_1}, \dots, x_{j_l}\}$

● F_j je funkce do reálných čísel $D_{j_1} \times \dots \times D_{j_l} \rightarrow \mathbb{R}^+$ ■

● **Optimalizační problém s podmínkami (COP):** (X, D, C_h, C_s) ■

● **Objektivní funkce** zjednodušení na Σ

$$F(\vec{d}) = \sum_{j=1}^l F_j(\vec{d}[Q_j]) \quad \vec{d}[Q_j] \dots \text{projekce } \vec{d} \text{ na } Q_j \text{ ■}$$

● **Řešení COP:** \vec{d}^o splňující všechna omezení z C_h tak, že

$$F(\vec{d}^o) = \max_{\vec{d}} F(\vec{d}) \text{ nebo } F(\vec{d}^o) = \min_{\vec{d}} F(\vec{d})$$

Použití soft omezení

- Problémy optimalizační, příliš podmíněné, špatně definované problémy, ...
- Fuzzy preference, pravděpodobnosti, ceny, váhy, úrovně požadavků, ...
- **Příliš podmíněné problémy:** řešení CSP neexistuje

F_1 Prednaska < Cviceni @ 10

tj. pokud $Prednaska < Cviceni$ pak $F_1=0$
pokud $Prednaska \geq Cviceni$ pak $F_1=10$

F_2 Prednaska in 4..5 @ 6

tj. pokud $Prednaska \in \{4, 5\}$ pak $F_2=0$
pokud $Prednaska \notin \{4, 5\}$ pak $F_2=6$

F_3 Cviceni in 1..4 @ 4

● Problémy s nejistotou

- Je 0.7 nezbytné, abych přišla do středy. po..st 0.7, ct..ne 0
- Je nezbytné, abych nepřišla příliš později než ve středu. po..st 0.7, ct 0.5, pa 0.3, so..ne 0

● Špatně definované problémy: není zřejmé, která omezení definují CSP

Zitra = pekne @ 80%

Zitra = zamraceno @ 30%

Přístupy pro soft omezení

● Vybrané přístupy

- základní: MAX-CSP, omezení s váhami, fuzzy omezení
- zobecňující: omezení nad polookruhy (*semiring-based*)

● Rozlišení systémů na základě:

(v závorkách popis pro CSP)

- **omezení** – rozšíření klasického omezení ($c = \text{relace}$)
- **problém** – rozšíření CSP (trojice (V, D, C))
- **úroveň splnění** – jak přiřazení hodnot splňuje problém ($\bigwedge c\theta$)
- **řešení** – které přiřazení je (optimálním) řešením (splňují všechna omezení)
- **úroveň konzistence problému** – jak je možné nejlépe splnit problém
tj. jak (optimální) řešení splňuje problém (true)

Omezení s váhami, MAX-CSP

● Omezení s váhami:

- Váha/cena spojená s každým omezením
- Omezení – dvojice $(c, w(c))$
- Problém – trojice (V, D, C_w)
- Úroveň splnění – funkce na množině přiřazení $\omega(\theta) = \sum_{\theta \models c} w(c)$
⇒ **součet vah nesplněných omezení**
- Řešení – přiřazení θ s **minimální** $\omega(\theta)$
- Úroveň konzistence – úroveň splnění řešení

● MAX-CSP (maximální CSP)

- Váha je rovna jedné ⇒ **maximalizace počtu splněných omezení**

Omezení s váhami: příklad

Prednaska < Cviceni @ 10

Prednaska in 4..5 @ 6

Cviceni in 1..4 @ 4

- Přiřazení: $\sigma = \{\text{Prednaska}/3, \text{Cviceni}/4\}$
- Úroveň splnění σ odpovídá součtu vah nesplněných omezení při σ , tj. 6
- Řešení: $\theta = \{\text{Prednaska}/4, \text{Cviceni}/5\}$
- Úroveň splnění θ : 4
- Úroveň konzistence odpovídá úrovni splnění θ : 4

Fuzzy CSP

- **Fuzzy množiny:** příslušnost prvku k množině zadána číslem z intervalu $[0, 1]$
- **Fuzzy omezení:** fuzzy relace $\mu_c(d_1, \dots, d_k) \in \langle 0, 1 \rangle$ udává **úroveň preference**

$$D_A = D_B = \{1, 2, 3\}$$

$$c1: A = 1 @ (1, 0.7) \quad \text{tj. pokud } A=1, \text{ pak } \mu_{c1}=1$$

$$\text{pokud } A \neq 1, \text{ pak } \mu_{c1}=0.7$$

$$c2: \min(\text{abs}(A - B)), \text{abs}(A - B) = 0 \Rightarrow @1 \quad \text{tj. } \mu_{c2}=1$$

$$= 1 \Rightarrow @0.5 \quad \text{tj. } \mu_{c2}=0.5$$

$$= 2 \Rightarrow @0.1 \quad \text{tj. } \mu_{c2}=0.1$$

$$c3: \max(A + B) @ (A + B)/10 \quad \text{tj. } \mu_{c3}=(A + B)/10$$

- **Fuzzy CSP** (X, D, C_f)

- C_f je množina fuzzy omezení

- X uspořádaná množina proměnných

Kombinace a projekce omezení

● **Projekce n-tic** $(d_1, \dots, d_l) \downarrow_X^Y$ příklad: $(1, 2, 3, 4, 5) \downarrow_{(D,A,E)}^{(A,B,C,D,E)} = (4, 1, 5)$ ■

● **Kombinace** $c = c_X \oplus c_Y$, $dom(c) = Z = X \cup Y$ c, c_X, c_Y omezení nad Z, X, Y

$$\mu_c(d_1, \dots, d_k) = \min(\mu_{c_X}((d_1, \dots, d_k) \downarrow_X^Z), \mu_{c_Y}((d_1, \dots, d_k) \downarrow_Y^Z))$$

● udává, jaká je úroveň splnění všech přiřazení Z vzhledem k c_X a c_Y

● příklad (pokračování): kombinace $c_1 \oplus c_2 \oplus c_3$ pro $(1, 3)$

$$\mu_{c_1 \oplus c_2 \oplus c_3}(1, 3) = \min(\mu_{c_1}((1)), \mu_{c_2}((1, 3)), \mu_{c_3}((1, 3))) = \min(1, 0.1, 0.4) = 0.1$$
 ■

● **Projekce** $c = c_Y \downarrow_X$, $dom(c) = X, X \subseteq Y$ c, c_X, c_Y omezení nad X, X, Y

$$\mu_c(d_{x1}, \dots, d_{xk}) = \max_{((d_{y1}, \dots, d_{yl}) \in D_{y1} \times \dots \times D_{yl}) \wedge ((d_{y1}, \dots, d_{yl}) \downarrow_X^Y = (d_{x1}, \dots, d_{xk}))} \mu_{c_Y}(d_{y1}, \dots, d_{yl})$$

● udává, jaká je úroveň splnění všech přiřazení X vzhledem k c_Y

● příklad (pokračování): projekce $c_3 \downarrow_{(B)}$ na (1)

$$\mu_{c_3 \downarrow_{(B)}}(1) = \max(\mu_{c_3}(1, 1), \mu_{c_3}(2, 1), \mu_{c_3}(3, 1)) = \max(0.2, 0.3, 0.4) = 0.4$$

Řešení fuzzy CSP

- **Úroveň splnění** přiřazení (d_1, \dots, d_n) dána jako $\mu_{\oplus C}(d_1, \dots, d_n)$ ■
- **Řešení** – přiřazení (d_1, \dots, d_n) takové, že

$$\max_{(d_1, \dots, d_n) \in D_1 \times \dots \times D_n} \mu_{\oplus C}(d_1, \dots, d_n) = \mathbb{C}(P_\mu) \blacksquare$$

- příklad: $\oplus C = c1 \oplus c2 \oplus c3$ pro všechna (A, B)

$(3, 3) \dots 0.6, (2, 2) \dots 0.4, (1, 1) \dots 0.2$

$(2, 3)$ a $(3, 2) \dots 0.5, (2, 1)$ a $(1, 2) \dots 0.3$

$(1, 3)$ a $(3, 1) \dots 0.1 \blacksquare$

$\Rightarrow (3, 3)$ je řešení, $\mathbb{C}(P_\mu) = 0.6 \blacksquare$

- **Úroveň nekonzistence** $1 - \mathbb{C}(P_\mu)$

- $\mathbb{C}(P_\mu)$ je **úroveň konzistence**

také jako projekce na prázdnou množinu proměnných $\oplus C \downarrow \emptyset$

Příklad: řešení fuzzy CSP

- Viz dříve: $\bigoplus C = c1 \oplus c2 \oplus c3$ pro všechna (A, B)

(3, 3) ... 0.6, (2, 2) ... 0.4, (1, 1) ... 0.2,

(2, 3) a (3, 2) ... 0.5, (2, 1) a (1, 2) ... 0.3, (1, 3) a (3, 1) ... 0.1

- $\bigoplus C = \bigoplus C \downarrow_{\{A,B\}}$

$\bigoplus C \downarrow_{\{A,B\}} (3, 3) = \max(\mu_{\bigoplus C}(3, 3)) = 0.6,$

$\bigoplus C \downarrow_{\{A,B\}} (2, 2) = 0.4, \dots$ ■

- $\bigoplus C \downarrow_{\{A\}}$

$\bigoplus C \downarrow_{\{A\}} (1) = \max(\mu_{\bigoplus C}(1, 1), \mu_{\bigoplus C}(1, 2), \mu_{\bigoplus C}(1, 3)) = \max(0.2, 0.3, 0.1) = 0.3$

$\bigoplus C \downarrow_{\{A\}} (2) = \max(\mu_{\bigoplus C}(2, 1), \mu_{\bigoplus C}(2, 2), \mu_{\bigoplus C}(2, 3)) = \max(0.3, 0.4, 0.5) = 0.5$

$\bigoplus C \downarrow_{\{A\}} (3) = \max(\mu_{\bigoplus C}(3, 1), \mu_{\bigoplus C}(3, 2), \mu_{\bigoplus C}(3, 3)) = \max(0.1, 0.5, 0.6) = 0.6$ ■

- $\bigoplus C \downarrow_{\emptyset}$

$\bigoplus C \downarrow_{\emptyset} () = \max(\mu_{\bigoplus C}(1, 1), \mu_{\bigoplus C}(1, 2), \mu_{\bigoplus C}(1, 3), \mu_{\bigoplus C}(2, 1), \mu_{\bigoplus C}(2, 2),$

$\mu_{\bigoplus C}(2, 3), \mu_{\bigoplus C}(3, 1), \mu_{\bigoplus C}(3, 2), \mu_{\bigoplus C}(3, 3)) = 0.6$