

Interpret Prologu

Implementace Prologu (pokračování)

Základní principy:

- klauzule uloženy jako termy
- **programová databáze**
 - pro uložení klauzulí
 - má charakter haldy
 - umožňuje modifikovatelnost prologovských programů za běhu (assert)
- klauzule zřetězeny podle pořadí načtení
 - triviální zřetězení

Vyhodnocení dotazu: volání procedur řízené unifikací

Hana Rudová, Logické programování I, 20. května 2009

2

Implementace Prologu

Interpret – Základní princip

1. Vyber redukovaný literál („první“, tj. nejlevější literál cíle)
2. Lineárním průchodem od začátku databáze najdi klauzuli, jejíž hlava má stejný funkтор a stejný počet argumentů jako redukovaný literál
3. V případě nalezení klauzule založ bod volby procedury
4. Založ dále okolí první klauzule (velikost odvozena od počtu lokálních proměnných v klauzuli)
5. proved' unifikaci literálu a hlavy klauzule
6. Úspěch \Rightarrow přidej všechny literály klauzule k cíli („doleva“, tj. na místo redukovaného literálu).
Tělo prázdné \Rightarrow výpočet se s úspěchem vrací do klauzule, jejíž adresa je v aktuálním okolí.
7. Neúspěch unifikace \Rightarrow z bodu volby se obnoví stav a pokračuje se v hledání další vhodné klauzule v databázi.
8. Pokud není nalezena odpovídající klauzule, výpočet se vrací na předchozí bod volby (krátí se lokální i globální zásobník).
9. Výpočet končí neúspěchem: neexistuje již bod volby, k němuž by se výpočet mohl vrátit.
10. Výpočet končí úspěchem, jsou-li úspěšně redukovány všechny literály v cíli.

Interpret – vlastnosti

- Lokální i globální zásobník
 - při dopředném výpočtu roste
 - při zpětném výpočtu se zmenšuje
- Lokální zásobník se může zmenšit při dopředném úspěšném výpočtu deterministické procedury.
- Unifikace argumentů hlavy – obecný unifikační algoritmus
Současně poznačí adresy instanciovaných proměnných na stopu.
 - „Interpret“:

```
interpret(Query, Vars) :- call(Query), success(Query, Vars).
interpret(_,_) :- failure.
```

 - dotaz vsazen do kontextu této speciální nedeterministické procedury
 - tato procedura odpovídá za korektní reakci systému v případě úspěchu i neúspěchu

Optimalizace: Indexace

- Zřetězení klauzulí podle pořadí načtení velmi neefektivní
- Provázání klauzulí se stejným funktem a aritou hlavy (tvoří jednu **proceduru**)
 - tj., **indexace procedur**
- Hash tabulka pro vyhledání první klauzule
- Možno rozhodnout (parciálně) determinismus procedury

Indexace argumentů

- a(1) :- q(1).
- a(a) :- b(X).
- a([A|T]) :- c(A,T).
- Obecně nedeterministická
- Při volání s alespoň částečně instanciovaným argumentem vždy deterministická (pouze jedna klauzule může uspět)
- **Indexace podle prvního argumentu**
 - Základní typy zřetězení:
 - podle pořadí klauzulí (aktuální argument je volná proměnná)
 - dle konstant (aktuální je argument konstanta)
 - formální argument je seznam (aktuální argument je seznam)
 - dle struktur (aktuální argument je struktura)

Indexace argumentů II

- Složitější indexační techniky
 - podle všech argumentů
 - podle nejvíce diskriminujícího argumentu
 - kombinace argumentů (indexové techniky z databází)
 - zejména pro přístup k faktům

Tail Recursion Optimization, TRO

Iterace prováděna pomocí rekurze \Rightarrow lineární paměťová náročnost cyklu

Optimalizace koncové rekurze (Tail Recursion Optimisation), TRO:

Okolí se odstraní **před** rekurzivním voláním posledního literálu klauzule, pokud je klauzule resp. její volání deterministické.

Řízení se nemusí vracet:

- v případě úspěchu se rovnou pokračuje
- v případě neúspěchu se vrací na předchozí bod volby („nad“ aktuální klauzulí)
 - aktuální klauzule nemá dle předpokladu bod volby

Rekurzivně volaná klauzule může být volána přímo z kontextu volající klauzule.

TRO – příklad

Program:

```
append([], L, L).  
append([A|X], L, [A|Y]) :- append(X, L, Y).
```

Dotaz:

```
?- append([a,b,c], [x], L).
```

append volán rekurzivně 4krát

- bez TRO: 4 okolí, lineární paměťová náročnost
- s TRO: 1 okolí, konstantní paměťová náročnost

Optimalizace posledního volání

TRO pouze speciální případ

obecné optimalizace posledního volání (*Last Call Optimization*), LCO

Okolí (před redukcí posledního literálu)

odstraňováno vždy, když leží na vrcholu zásobníku.

Nutné úpravy interpretu

- disciplina směrování ukazatelů
 - vždy „mladší“ ukazuje na „starší“ („mladší“ budou odstraneny dříve)
 - z lokálního do globálního zásobníku
- vyhneme se vzniku „visících odkazů“ při předčasném odstranění okolí
- „globalizace“ lokálních proměnných: lokální proměnné posledního literálu
 - nutno přesunout na globální zásobník
 - pouze pro neinstanciované proměnné

Překlad

Motivace:

- dosažení vyšší míry optimalizace
- kompaktní kód
- částečná nezávislost na hardware

Etapy překladu:

1. zdrojový text ⇒ kód abstraktního počítače
2. kód abstraktního počítače ⇒ kód (instrukce) cílového počítače

Výhody:

- snazší přenos jazyka (nutno přepsat jen druhou část)
- kód abstraktního počítače možno navrhnout s ohledem na jednoduchost překladu; prostor pro strojově nezávislou optimalizaci

▪ Překlad Prologu založen na principu existence abstraktního počítače
V dalším se věnujeme jeho odvození a vlastnostem

Parciální vyhodnocení

- Jak navrhnut Warrenův abstraktní počítač?

- prostřednictvím parciálního vyhodnocení

■ Parciální vyhodnocení

- forma zpracování programu,
tzv. transformace na úrovni zdrojového kódu
 - dosazení známých hodnot vstupních parametrů
a vyhodnocení všech operací nad nimi
 - příklad: vyhodnocení aritmetických výrazů nad konstantami

Parciální vyhodnocení II

Konstrukce překladače: parciálním vyhodnocením interpretu

Problémy:

- příliš složitá operace
 - vyhodnocení se musí provést vždy znovu pro každý nový program
- výsledný program příliš rozsáhlý
- nedostatečná dekompozice
 - zejména při použití zdrojového jazyka jako implementačního jazyka interpretu

Vhodnější:

- využití („ručního“) parciálního vyhodnocení pro návrh abstraktního počítače
 1. nalezení operací zdrojového jazyka, které lze dekomponovat do jednodušších operací
 2. dekomponujeme tak dlouho, až jsou výsledné operace dostatečně jednoduché nebo již neexistují informace pro parciální vyhodnocení

Parciální vyhodnocení – příklad

$a(X, Y) :- b(X), c(X, Y).$ $a(X, Y) :- b(Y), c(Y, X).$

$b(1).$ $b(2).$ $b(3).$ $b(4).$

$c(1, 2).$ $c(1, 3).$ $c(1, 4).$ $c(2, 3).$ $c(2, 4).$ $c(3, 4).$

Dotaz $?- a(2, Z).$

Ize společně s uvedeným programem parciálně vyhodnotit na nový program

$a'(3).$ $a'(4).$ $a'(1).$

a nový dotaz

$?- a'(Z).$

Je evidentní, že dotaz nad parciálně vyhodnoceným programem bude zpracován mnohem rychleji (efektivněji) než v případě původního programu.

Parciální vyhodnocení Prologu

Cílová operace: **unifikace.** Důvod:

- řízení výpočtu poměrně podrobné i v interpretu
- unifikace v interpretu atomickou operací
- unifikace v interpretu nahrazuje řadu podstatně jednodušších operací (testy, přiřazení, předání a převzetí parametrů ...)
- většina unifikací nevyžaduje obecnou unifikaci a lze je nahradit jednoduššími operacemi

Zviditelnění unifikace: transformací zdrojového programu

- termy reprezentujeme kopírováním struktur na globálním zásobníku
- parametry procedur jsou vždy umístěny na globální zásobník (predikátem put/2) a předávány jsou pouze adresy
- formálním parametrem procedury jsou pouze volné proměnné, které se v hlavě vyskytují pouze jednou
- všechny unifikace jsou explicitně zachyceny voláním predikátu unify/2

Explicitní unifikace

Příklad: append/3 s explicitní unifikací:

```
append(A1, A2, A3) :- unify(A1,[]),      | append([],L,L).  
          unify(A2,L),  
          unify(A3,L).  
  
append(A1, A2, A3) :- unify(A1,[A|X]),   | append([A|X],L,[A|Y]):-  
          unify(A2,L),  
          unify(A3,[A|Y]),  
          put(X,B1),  
          put(L,B2),  
          put(Y,B3),  
          append(B1,B2,B3). | append(X,L,Y).
```

Cíl: parciálně vyhodnotit predikáty unify/2 a put/2

Pomocné termy a predikáty

- term \$addr\$(A) – odkaz na objekt s adresou A
- predikát is_addr(P,V) – je-li P ve tvaru \$addr\$(A), pak V se unifikuje s hodnotou slova na adresu A (jinak predikát selže)
- predikát :=(X,T) – přiřadí volné proměnné X term T;
X musí být volná proměnná.
- predikát repres(A,Tag,V) – uloží do proměnné Tag příznak a do proměnné V hodnotu slova na adresu A.
A musí být adresa na globálním zásobníku,
Tag i V musí být volné proměnné.
 - příznak: informace o struktuře součástí objektu
volná proměnná FREE, konstanta CONST, celé číslo INT, odkaz REF, složený term FUNCT
- je-li A adresa a i celočíselná konstanta, pak výraz A+i reprezentuje adresu o i slov vyšší (ukazatelová aritmetika)

unify pro volnou proměnnou

unify(A,T) unifikuje term na adresu A (aktuální parametr) s termem T (formální parametr). Podle hodnoty T mohou nastat následující 4 případy:

1) T je volná proměnná: výsledkem je instanciace

```
unify(A,T) :- var(T),  
           ( var(A), create_var(A)  
           ; true ),  
           T := $addr$(A).
```

Disjunkce garantuje, že A je korektní adresa na globálním zásobníku: nutný run-time test, tedy nelze využít při parc. překladu. Lze proto přepsat na

```
unify(A,T) :- var(T),  
           unify_var(A,T).
```

kde unify_var/2 vloží do T odkaz nebo založí novou proměnnou.

unify pro konstantu

2) T je konstanta: výsledkem je test nebo přiřazení

```
unify(A,T) :-  
           atomic(T),  
           ( ( var(A), create_var(A), instantiate_const(A,T) )  
           ; ( repres(A,Tag,Value), Tag == 'FREE', instantiate_const(A,T)  
           ; Tag == 'CONST', Value == T )  
           ).
```

kde instantiate_const/2 uloží do slova s adresou A hodnotu T.

Opět možno přepsat do kompaktního tvaru

```
unify(A,T) :-  
           atomic(T),  
           unify_const(A,T).
```

kde unify_const/2 provede příslušný test nebo přiřazení.

unify pro složený term

3) T je složený term: dvoufázové zpracování, v první fázi test nebo založení funkторu, v druhé rekurzivní unifikace argumentů

```
unify(A,T) :-  
    struct(T),  
    functor(T,F,N),  
    unify_struct(F,N,A),  
    T =.. [_,T1],  
    unify_args(T1,A+1).
```

Predikát `unify_struct/3` je analogický výše použitým predikátům `unify_var/2` a `unify_const/2`.

Druhá fáze:

```
unify_args([],_).  
unify_args([T|T1], A) :-  
    unify(A,T),  
    unify_args(T1,A+1).
```

unify pro odkaz

4) T je odkazem: nutno použít obecnou unifikaci (není žádná informace pro parciální vyhodnocení)

```
unify(A,T) :-  
    is_addr(T,P),  
    unification(A,P).
```

Parametry procedur jsou vždy umístěny na globální zásobník predikátem `put/2` a předávány jsou pouze adresy.
Predikát `put/2` je jednodušší (nikdy nepotřebuje unifikaci)

```
put(T,B) :-  
    is_addr(T,B). % T je odkaz  
put(T,B) :-  
    var(T), % T je proměnná  
    create_var(B),  
    T := $addr$(B).  
put(T,B) :-  
    atomic(T), % T je konstanta  
    create_const(B,T).  
put(T,B) :-  
    struct(T), % T je struktura  
    create_struct(B,T).
```

put

První klauzule append/3

Parciální vyhodnocení první klauzule programu `append/3`

```
append(A1, A2, A3) :- unify(A1,[]), | append([],L,L).  
          unify(A2,L), |  
          unify(A3,L). |
```

upraví

```
unify(A1,[]) na unify_const(A1,[])  
unify(A2,L) na L:=$addr$(A2)  
unify(A3,L) na is_addr(L,T), unification(T,A3)  
posloupnost L:=$addr$(A2), is_addr(L,T) odpovídá přejmenování T na A2  
⇒ není nutné vytvářet novou proměnnou T  
⇒ stačí provést unification(A2,A3)
```

Výsledný tvar append/3

```
append(A1, A2, A3) :-  
    unify_const(A1, []),  
    unification(A2, A3).  
  
append(A1, A2, A3) :-  
    unify_struct('. ', 2, A1),  
    unify_var(A, A1+1),  
    unify_var(X, A1+2),  
    unify_var(L, A2),  
    unify_struct('. ', 2, A3),  
    unification(A1+1, A3+1),  
    unify_var(Y, A3+2),  
    put(X, B1), put(L, B2), put(Y, B3),  
    append(B1, B2, B3).  
  
append(A1+2, A2, A3+2).
```

Většina původních unifikací převedena na jednoduší operace;
unifikace v posledním kroku je nezbytná (důsledkem dvojího výskytu proměnné)

```
append(A1, A2, A3) :-  
    unify(A1, []),  
    unify(A2, L), unify(A3, L).  
  
append(A1, A2, A3) :-  
    unify(A1, [A|X]),  
    unify(A2, L),  
    unify(A3, [A|Y]),  
    put(X, B1), put(L, B2), put(Y, B3),  
    append(B1, B2, B3).
```

a(c, s(f), d, X) :- g(X).

Procedurální pseudokód (testy a přiřazení) a kód abstraktního počítače:

```
procedure a(X, Y, Z, A) is  
    if ( X == 'c' &&  
        ( is_struct(Y, 's', 1) &&  
        first_arg(Y) == 'f' ) &&  
        Z == 'd' )  
    then  
        call g(A)  
    else  
        call fail  
    end procedure
```

tj. posloupnost testů jako v procedurálním jazyce

Vyzkoušejte si: delete(X, [Y|T], [Y|T1]) :- delete(X, T, T1).

Warrenův abstraktní počítač, WAM I.

Navržen D.H.D. Warrenem v roce 1983, modifikace do druhé poloviny 80. let

Datové oblasti:

- **Oblast kódu (programová databáze)**
 - separátní oblasti pro uživatelský kód (modifikovatelný) a vestavěné predikáty (nemění se)
 - obsahuje rovněž všechny statické objekty (texty atomů a funktorů apod.)
- **Lokální zásobník (Stack)**
- **Stopa (Trail)**
- **Globální zásobník n. halda(Heap)**
- **Pomocný zásobník (Push Down List, PDL)**
 - pracovní paměť abstraktního počítače
 - použitý v unifikaci, syntaktické analýze apod.

■ Příklad konfigurace



■ Halda i lokální zásobník musí růst stejným směrem

- lze jednoduše porovnat stáří dvou proměnných srovnáním adres využívá se při zabránění vzniku visících odkazů

Jiný příklad

Registry WAMu

- **Stavové registry:**

P čítač adres (Program counter)

CP adresa návratu (Continuation Pointer)

E ukazatel na nejmladší okolí (Environment)

B ukazatel na nejmladší bod volby (Backtrack point)

TR vrchol stopy (TRail)

H vrchol haldy (Heap)

HB vrchol haldy v okamžiku založení posledního bodu volby (Heap on Backtrack point)

S ukazatel, používaný při analýze složených termů (Structure pointer)

CUT ukazatel na bod volby, na který se řezem zařizne zásobník

- **Argumentové registry:** A1, A2, ... (při předávání parametrů n. pracovní registry)

- **Registry pro lokální proměnné:** Y1, Y2, ...

- abstraktní znázornění lok. proměnných na zásobníku

Instrukce put a get: příklad

Příklad: a(X,Y,Z) :- b(f,X,Y,Z).

get_var A1,A5

get_var A2,A6

get_var A3,A7

put_const A1,f

put_value A2,A5

put_value A3,A6

put_value A4,A7

execute b/4

Typy instrukcí WAMu

- **put instrukce** – příprava argumentů před voláním podcíle

- žádná z těchto instrukcí nevolá obecný unifikační algoritmus

- **get instrukce** – unifikace aktuálních a formálních parametrů

- vykonávají činnost analogickou instrukcím unify u parc. vyhodnocení
- obecná unifikace pouze při get_value

- **unify instrukce** – zpracování složených termů

- jednoargumentové instrukce, používají registr S jako druhý argument
- počáteční hodnota S je odkaz na 1. argument
- volání instrukce unify zvětší hodnotu S o jedničku
- obecná unifikace pouze při unify_value a unify_local_value

- **Indexační instrukce** – indexace klausulí a manipulace s body volby

- **Instrukce řízení běhu** – předávání řízení a explicitní manipulace s okolím

Instrukce WAMu

get instrukce	put instrukce	unify instrukce
get_var Ai,Y	put_var Ai,Y	unify_var Y
get_value Ai,Y	put_value Ai,Y	unify_value Y
get_const Ai,C	put_unsafe_value Ai,Y	unify_local_value Y
get_nil Ai	put_const Ai,C	unify_const C
get_struct Ai,F/N	put_nil Ai	unify_nil
get_list Ai	put_struct Ai,F/N	unify_void N
	put_list Ai	

instrukce řízení	indexační instrukce
allocate	try_me_else Next
deallocate	retry_me_else Next
call Proc/N,A	trust_me_else fail
execute Proc/N	trust fail
proceed	cut_last switch_on_term Var,Const,List,Struct
	save_cut Y switch_on_const Table
	load_cut Y switch_on_struct Table

Instrukce unify, get, put

- Větší počet typů objektů
 - rozlišeny atomy, čísla, nil ≡ prázdný seznam, seznam speciální druh složeného termu
- unify_void umožní přeskočit anonymních proměnných ve složených termech
- put_unsafe_value pro optimalizaci práce s lokálními proměnnými při TRO
 - a(X) :- b(X,Y), !, a(Y).
při TRO nesmí být lokální proměnné posledního literálu (Y) na lokálním zásobníku
 - komplikátor může všechny nebezpečné (*unsafe*) výskyty lok. proměnných detekovat při překladu (jsou to poslední výskyty lok. proměnných) a generuje složitější instrukce put_unsafe_value, které provádějí test umístění
- unify_local_value kvůli TRO jako put_unsafe_value
 - a(X) :- d(X), b(s(Y),X). objekt přístupný přes Y opět nesmí být na lok. zásobníku doba života s/1 může být delší než doba života okolí na něž se Y odkazuje
 - unify_local_value testují umístění a pokud nutné přesouvají objekty na haldu

WAM – indexace

- Provázání klauzulí: instrukce XX_me_else:
 - první klauzule: try_me_else; založí bod volby
 - poslední klauzule: trust_me_else; zruší nejmladší bod volby
 - ostatní klauzule: retry_me_else; znova použije nejmladší bod volby po neúspěchu
- Provázání podmnožiny klauzulí (podle argumentu):
 - try
 - retry
 - trust
- „Rozskokové“ instrukce (dle typu a hodnoty argumentu):
 - switch_on_term Var, Const, List, Struct
výpočet následuje uvedeným návštěvám podle typu prvního argumentu
 - switch_on_YY: hashovací tabulka pro konkrétní typ (konstanta, struktura)

Příklad indexace instrukcí

Proceduře

```
a(atom) :- body1.  
a(1) :- body2.  
a(2) :- body3.
```

a([X|Y]) :- body4.
a([X|Y]) :- body5.
a(s(N)) :- body6.
a(f(N)) :- body7.

Odpovídají instrukce

```
a: switch_on_term L1, L2, L3, L4 L5a: body2  
L2: switch_on_const atom :L1a L6: retry_me_else L7  
1 :L5a L6a: body3  
2 :L6a L7: retry_me_else L8  
L3: try L7a L7a: body4  
trust L8a L8: retry_me_else L9  
L4: switch_on_struct s/1 :L9a L8a: body5  
f/1 :L10a L9: retry_me_else L10  
L1: try_me_else L5 L9a: body6  
L1a: body1 L10: trust_me_else fail  
L5: retry_me_else L6 L10a: body7
```

WAM – řízení výpočtu

- execute Proc: ekvivalentní příkazu goto
- proceed: zpracování faktů
- allocate: alokuje okolí (pro některé klauzule netřeba, proto explicitně generováno)
- deallocate: uvolní okolí (je-li to možné, tedy leží-li na vrcholu zásobníku)
- call Proc,N: zavolá Proc, N udává počet lok. proměnných (odpovídá velikosti zásobníku)
Možná optimalizace: vhodným uspořádáním proměnných
lze dosáhnout postupného zkracování lokálního zásobníku
a(A,B,C,D) :- b(D), c(A,C), d(B), e(A), f.
generujeme instrukce allocate
call b/1,4
call c/2,3
call d/1,2
call e/1,1
deallocate
execute f/0

WAM – řez

Implementace řezu (opakování): odstranění bodů volby mezi současným vrcholem zásobníku a bodem volby procedury, která řez vyvolala (včetně bodu volby procedury s řezem)

Indexační instrukce znemožňují v době překladu rozhodnout, zda bude alokován bod volby

- příklad: `?- a(X).` může být nedeterministické, ale `?- a(1).` může být deterministické

`cut_last: B := CUT` `save_cut Y: Y := CUT` `load_cut Y: B := Y`

Hodnota registru B je uchovávána v registru CUT instrukcemi `call` a `execute`.

Je-li řez prvním predikátem klauzule, použije se rovnou `cut_last`. V opačném případě se použije jako první instrukce `save_cut` Y a v místě skutečného volání řezu se použije `load_cut` Y.

Příklad: `a(X,Z) :- b(X), !, c(Z).`

`a(2,Z) :- !, c(Z).`

`a(X,Z) :- d(X,Z).` odpovídá

`save_cut Y2; get A2,Y1; call b/1,2; load_cut Y2; put Y1,A1; execute c/1`

`get_const A1,2; cut_last; put A2,A1; execute c/1`

`execute d/2`

WAM – optimalizace

1. Indexace klauzulí

2. Generování optimální posloupnosti instrukcí WAMu

3. Odstranění redundancí při generování cílového kódu.

- Příklad: `a(X,Y,Z) :- b(f,X,Y,Z).`

naivní kód (vytvoří komplilátor pracující striktně zleva doprava) vs.

optimalizovaný kód (počet registrů a tedy i počet instrukcí/přesunů v paměti snížen):

<code>get_var</code>	<code>A1,A5</code>		<code>get_var</code>	<code>A3,A4</code>
<code>get_var</code>	<code>A2,A6</code>		<code>get_var</code>	<code>A2,A3</code>
<code>get_var</code>	<code>A3,A7</code>		<code>get_var</code>	<code>A1,A2</code>
<code>put_const</code>	<code>A1,f</code>		<code>put_const</code>	<code>A1,f</code>
<code>put_value</code>	<code>A2,A5</code>		<code>execute</code>	<code>b/4</code>
<code>put_value</code>	<code>A3,A6</code>			
<code>put_value</code>	<code>A4,A7</code>			
<code>execute</code>	<code>b/4</code>			