Interpret SQL
Semestrální práce z předmětu 36PJ

Martin Tůma, 4/44

10.1.2006

Obsah

1 Zadání

Úkolem semestrální práce je navrhnout interpret podmnožiny jazyka SQL.

1.1 Jazyk

Jazyk byl zvolen tak, aby obsahoval všechny hlavní příkazy SQL, jmenovitě tedy: CREATE, INSERT, SELECT, UPDATE, DELETE, DROP. Jejich syntaxe je však maximálně zjednodušena.

Zvolená množina jazyka je daná následující EBNF:

```
sql_příkaz ::=

  CREATE TABLE jméno_tabulky
    '('jméno_sloupce typ_sloupce ['('velikost_sloupce')']
      {, jméno_sloupce typ_sloupce ['('velikost_sloupce')']}')';

  | INSERT INTO jméno_tabulky
      ['('jméno_sloupce {, jméno_sloupce}')']
    VALUES
      '('výraz {, výraz}')';

  | UPDATE jméno_tabulky
    SET jméno_sloupce = výraz {, jméno_sloupce = výraz}
    [WHERE podmínka];

  | DELETE FROM jméno_tabulky
    [WHERE podmínka];

  | SELECT
      * | jméno_sloupce {, jméno_sloupce}
    FROM jméno_tabulky
    [WHERE podmínka];

  | DROP TABLE jméno_tabulky;


výraz ::= řetězec | aritmetický_výraz | NULL
podmínka ::= jméno_sloupce (<> | != | = | < | <= | > | >=) výraz

aritmetický_výraz ::= [-] term {(+|-) term}
term ::= faktor {(*|/) faktor}
faktor ::= celé_číslo | '('aritmetický_výraz')'
```

```
velikost_sloupce ::= aritmetický_výraz
typ_sloupce ::= INTEGER | CHAR
jméno_sloupce, jméno tabulky ::= identifikátor
```

Doplňující pravidla:

- Jazyk může obsahovat komentáře. Komentář je posloupnost znaků začínající `--` a končící znakem konce řádky (jedná se tedy o „jednořádkové“ komentáře).
- Jména klíčových slov (CREATE, SELECT, ...) jsou „case-insensitive“, jména identifikátorů „case-sensitive“.
- Porovnávat lze jen obsah sloupec s výrazem shodného typu a všechny typy sloupců na rovnost a nerovnost s hodnotou NULL.
- Při operaci insert musí být zadány hodnoty všech sloupců.

1.2 Interpretace

Nad výše popsaným jazykem je implementována syntaktická a sémantická analýza, skutečně interpretované jsou však pouze příkazy CREATE, INSERT, SELECT a DROP. Příkazy UPDATE a DELETE interpretovány(prováděny) nejsou. Je to z toho důvodu, že implementace diskových operací nad daty je poměrně náročná a jelikož překračuje rámec předmětu, je zvolena nejmenší možná množina příkazů, na které je možné „smysluplně“ ověřit funkci interpretu.

2 Implementace

2.1 Lexikální analyzátor

Lexikální analyzátor je implementován klasickou formou konečného automatu realizovaného řídící strukturou. Lexikální analyzátor rozpoznává tyto lexikální elementy: identifikátor, klíčová slova (součástí LA je i tabulka klíčových slov), řetězec, celé číslo, jednotlivé porovnávací a aritmetické operátory a speciální znaky (závorky, čárka...). Schéma příslušného konečného automatu je na obrázku 1.

Poznámka: Jak jména jednotlivých identifikátorů, tak řetězce mohou obsahovat pouze znaky anglické abecedy.

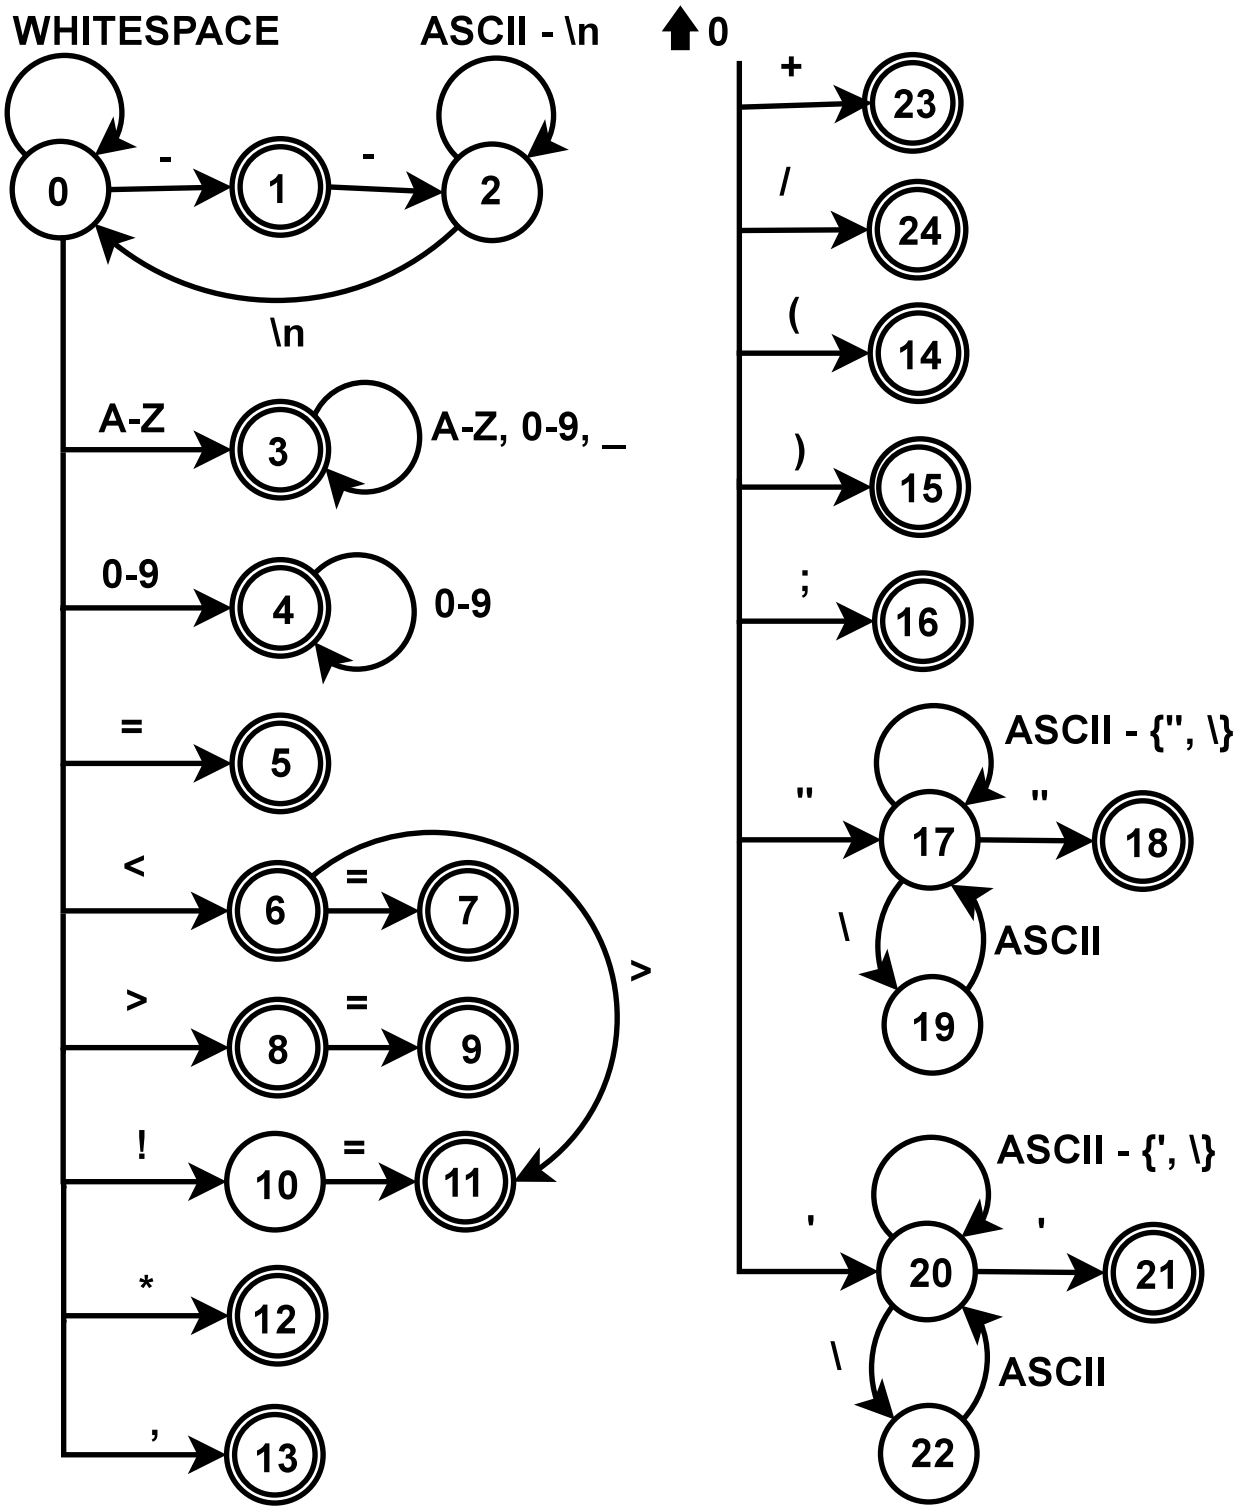

Obrázek 1: Schéma lexikálního analyzátoru

2.2 Syntaktický a sémantický analyzátor

Syntaktický analyzátor je zkonstruován formou rekurzivního sestupu. Použitou (LL1) gramatiku udává následující odstavec. Tučně jsou zvýrazněny neterminální symboly, italikou výstupní symboly.

C -> `CREATE TABLE id (` **CD** `);` *CREATE*
C -> `SELECT` **CL** `FROM id` **WD**`;` *SELECT*
C -> `INSERT INTO id` **IC** `VALUES (` **VL** `);` *INSERT*
C -> `DELETE FROM id` **WD**`;` *DELETE*
C -> `UPDATE id SET` **UD WD**`;` *UPDATE*
C -> `DROP TABLE id;` *DROP*
C -> ε

CD -> `id` **DT DS CD'**
CD' -> `,` **CD** | ε

DS -> `(` **E** `)` | ε
DT -> `CHAR | INTEGER`

CL -> `*` | **CN**
CN -> `id` **CN'**
CN' -> `,` **CN** | ε

IC -> `(` **CN** `)` | ε
VL -> **V VL'**
VL' -> `,` **VL** | ε
V -> **E** | `řetězec | NULL`

UD -> `id =` **V UD'**
UD' -> `,` **UD** | ε

WD -> `WHERE id` **CO V** | ε

E -> **T E'**
E' -> `+` **T E'** | `-` **T E'** | ε
T -> **F T'**
T' -> `*` **F T'** | `/` **F T'** | ε
F -> `int | (` **E** `)`

CO -> `= | != | < | <= | > | >=`

Gramatika je atributovaná. Jednotlivé atributy jsou uvedeny v následující tabulce.

Tabulka atributů:

Symboly	Syntetizované atributy	Dědičné atributy
CL, CN, CN', UD, UD', IC, UPDATE, SELECT	columns, col_num	columns, col_num
UD, UD', VL, VL', V, INSERT, UPDATE,	values	values
VL, VL',V, UPDATE	val_num	val_num
DT	type	
DS	size	
WD, SELECT, UPDATE, DELETE	condition	
E, T, F	int_value	
E', T'	int_value	operand
int	int_value	
řetězec	string_value	
NULL	null_value	
CO	operator	

Jak je vidět, atributy slouží zejména k získání seznamu sloupců/hodnot pro výstupní symboly v pravidlech pro neterminál C (Command). Tam kde to lze je v implementaci neterminálů se stejným sntetizovaným a dědičným parametrem využito možnosti předávaní parametrů funkcí odkazem, kdy postačuje jeden atribut pro oba směry „posunu“ informací derivačním stromem. Typickým příkladem je právě získávání seznamů sloupců/hodnot. Směrem „dolů“ jsou do seznamu přidávány nové prvky a upravována pozice pro nový prvek. Směrem „nahoru“ pak „putuje“ vytvářený seznam. Pravidla pro práci s atributy neuvádím, měly by však být zřejmé z implementace.

Kromě výše uvedených atributů, je v syntaktickém analyzátoru ještě globální (a tudíž dostupné ve všech funkcích implementujících jednotlivé neterminály) pole s definicí sloupců, jakási obdoba tabulky symbolů. Oproti tomuto seznamu jsou pak prováděny kontroly existence sloupců, datových typů hodnot a funkce `create_table()` pomocí něj vytváří novou tabulku.

2.3 Databázový modul

Poslední součástí interpretu je modul implementující jednotlivé diskové operace nad „databází“. Obsahuje implementaci pro vytvoření tabulky, získání informací (definic jednotlivých sloupců) o tabulce, vložení řádky do tabulky, výpis řádků tabulky a smazání tabulky.

3 Instalace a použití interpretu

Interpret je napsán v programovacím jazyce C a ke svému běhu potřebuje pouze pár základních knihoven, které by měly být dostupné na každém POSIX kompatabilním systému. Program lze automaticky sestavit pomocí přiloženého `Makefile`.

Použití interpretu je velice jednoduché – je-li programu zadán vstupní parametr, je interpretován soubor se jménem parametru. Je li program spuštěn bez parametru, je vstup čten ze standartního vstupu.

Funkci programu lze vyskoušet na 2 přiložených souborech. První, `test.sql`, je komplexní test interpretu, druhý (`test2.sql`) slouží pouze k vytvoření a naplnění testovací tabulky, nad kterou lze posléze v „interaktivním“ módu provádět libovolné příkazy.

4 Závěr

Výsledný program úspěšně realizuje zvolenou podmnožinu jazyka SQL. Pokud by však měl být použitelný i jinak, než jako semestrální úloha na 36PJ, bylo by potřeba zcela jinak koncipovat způsob práce s daty. Jako praktické seznámení s problémy implementace interpretu programovacího jazyka a problémů s tím spojených nicméně implementace funguje velice dobře...