

Analýza textu pomocí nástrojů lex/yacc

Miroslav Beneš


Katedra informatiky FEI VŠB-TU Ostrava

Miroslav.Benes@vsb.cz



Co chceme analyzovat?

- Konfigurační soubory
- Soubory příkazů (skripty)
- Strukturovaná data



Popis struktury textu

- Zpracovávaný text musí splňovat pravidla daná vlastnostmi *jazyka*
 - **lexikální struktura**
(z jakých základních symbolů se text skládá – čísla, identifikátory, operátory, ...)
 - **syntaktická struktura**
(jak jsou tyto základní symboly organizovány do větších celků – výrazy, příkazy, ...)



Popis lexikální struktury

- gramatika


cislo	→	cis zbytek
zbytek	→	cis zbytek
		ϵ
cis	→	'0'
		...
		'9'

cislo → **cis zbytek** ⇒ **cis** ⇒ '0'



Popis lexikální struktury

- konečný automat



Popis lexikální struktury


- regulární výrazy
 - znaky: x “print” “/*” * \n
 - množiny znaků: [\n\t] [0-9] [0-9a-zA-Z] [^]
 - volitelnost: x?
 - opakování: x* x+ [0-9]+
 - varianty: (x|y|z) [a-z]([0-9] | [a-z])*

[1-9][0-9]* | 0[0-7]* | 0x[0-9a-f]*+



Program lex (flex)

- Vstup: Regulární definice + akce
- Výstup: Program v C (C++)



int yylex();



Formát souboru pro lex

```
/* Použití jako filtr */
%{
# include "defs.h"
%
cislice [0-9]
pismeno [a-zA-Z0-9]
%%
[ \n\t]+ ;
{cislice}+ printf("%s\n", yytext);
%%
int yywrap(void) { return 1; }
int main(void) { yylex(); return 0; }
```




Formát souboru pro lex

```
/* Použití jako lexikální analyzátor */
%{
# include "y.tab.h"
# include "defs.h"
%}
%%
[ \n\t]+ ;
[0-9]+    return CISLO;
div        return DIV;
mod        return MOD;
.          return yytext[0];
```



Popis syntaktické struktury

- syntaktický graf



Popis syntaktické struktury

- gramatika


```
vyraz → vyraz + vyraz  
      |  
      ( vyraz )  
      |  
      CISLO
```

vyraz \Rightarrow **vyraz+vyraz** \Rightarrow **CISLO+vyraz** \Rightarrow
CISLO+(vyraz) \Rightarrow **CISLO+(CISLO)**



Program yacc (bison)

- Vstup: Gramatika + akce v C/C++
- Výstup: Program v C/C++, záhlaví s definicemi pro lex



Formát souboru pro yacc

```
%{  
# include "defs.h"  
%}  
%term CISLO  
%%  
vyraz:      vyraz '+' vyraz  
            | '(' vyraz ')' '  
            | CISLO  
%%  
void yyerror(char* txt) {...}  
int main(void) { yyparse(); return 0; }
```



Atributy

```
%{  
# define YYSTYPE double  
%}  
%%  
prog:      prog vyraz ';'  
                  { printf("%g\n", $2); }  
                  | /* e */  
vyraz:    vyraz '+' vyraz { $$=$1+$3; }  
                  | '(' vyraz ')' { $$=$2; }  
                  | CISLO
```



YYSTYPE yyval; - nastavuje lex. analyzátor

Atributy

```
%union {
    int i;
    double d;
}
%term <i> INUM
%term <d> DNUM
%type <d> vyraz
%%
vyraz:   vyraz '+' vyraz { $$=$1+$3; }
          | '(' vyraz ')' { $$=$2; }
          | INUM { $$ = (double)$1; }
          | DNUM
```



Další zdroje informací

- <http://www.cs.vsb.cz/benes/vyuka/pre>
 - stránky předmětu Překladače (PRE)
- <http://epaperpress.com/lexandyacc/index.html>
 - A Compact Guide to Lex&Yacc
- <http://www.geocities.com/SiliconValley/Campus/3754/index.htm>
 - Lex&Yacc Tutorial

