Formální jazyky a překladače

Přednášky:
-Typy překladačů, základní struktura překladače
-Regulární gramatiky, konečné automaty a jejich využití v lexikální analýze
-Úvod do syntaktické analýzy, metoda rekurzivního sestupu
-Překlad příkazů
-Zpracování deklarací
-Přidělování paměti
-Interpretační zpracování
-Generování cílového kódu
-Vlastnosti bezkontextových gramatik
-Deterministická analýza shora dolů
-LL(1) transformace
-Deterministická analýza zdola nahoru
-Formální překlady

Cvičení:
-Opakování teoretického základu
-Generátor lexikální analýzy - LEX
-Jazyk PL0 a jeho překladač
-Rozšíření konstrukcí jazyka PL0, zadání individuálních úloh
-Příklady LL gramatik
-Příklady LR gramatik, ukázky práce s generátorem YACC

Zápočet:
Udělen na základě referátu a předvedení zadané modifikace překladače PL0

Zkouška:
Písemná forma - 2 příklady (s použitím vlastní literatury) a otázky (bez použití literatury). Výsledky budou spolu s termíny pro reklamaci, zápis do indexu či ústní přezkoušení zveřejněny na webu a nástěnce. Po uplynutí termínu bude výsledek zapsán do databáze známek i v případě, že student nepředložil index k zápisu.

Literatura: web stránky předmětu FJP
Melichar, Češka, Ježek, Rychta: Konstrukce překladačů (ČVUT)
Melichar: Jazyky a překlady (ČVUT)
Molnár a kol.: Gramatiky a jazyky (Alfa)

Doporučená (v knihovně): Aho, Sethi, Ullman: Compilers Principles Technics and Tools
Appel A.W.: Modern Compiler Implementation in Java

Formální jazyky a překladače - organizace

FJP je šestikreditový předmět doporučený pro 4. ročník oboru *Informatika a výpočetní technika*. K získání zkoušky je zapotřebí splnit požadavky cvičení a napsat zkouškový test. Celkové hodnocení se snadno zjistí z bodového zisku a následující převodní tabulky:

více než 85 bodů	**výborně**
71-85 bodů	**velmi dobře**
50-70 bodů	**dobře**
0-49 bodů	**neprospěl**

Ze cvičení je zapotřebí získat alespoň 20 bodů. Na některých cvičeních se zadává samostatné vyřešení příkladu do příštího cvičení; správné řešení je honorováno jedním bodem. V rámci cvičení vypracovávají studenti semestrální práci. Hodnocení lehké semestrální práce je 30 bodů, těžké 40 bodů. Termín odevzdání práce je do 10. 1. Za každý den prodlení se automaticky strhává 1 bod.

Zkouška probíhá písemně. Maximální hodnocení je 60 bodů. Ze zkouškového testu musí student získat alespoň 30 bodů. V polovině semestru mají studenti možnost napsat dobrovolně jednoduchý test z doposud probrané látky.

Využití teorie formálních jazyků

- **Assemblery** překlad z JSI. Hlavní problém = adresace symbolických jmen, makra
- **Kompilátory** generují kód (strojový / symbolický / jiný jazyk)
- **Interprety** provádí překlad i exekuci programu převedeného do vhodné formy
- **Strukturní editory** napovídají možné tvary konstrukcí programů, či strukturovaných textů
- **Pretty printers** provádí úpravu struktury výpisů
- **Statické odlaďovače** vyhledávání chyb bez exekuce programu
- **Reverzní překladače** převádí strojový kód do JSI / vyššího jazyka
- **Formátory textu** překladače pro sazbu textu (Tex→DVI)
- **Silikonové překladače** pro návrh integrovaných obvodů. Proměnné nereprezentují místo v paměti, ale log. proměnnou obvodu. Výstupem je návrh obvodu.
- **Příkazové interprety** pro administraci OS / sítí (viz shell Unixu)
- **Dotazovací interprety** analýza a překlad příkazů a podmínek dotazů a příkazů DB jazyků
- **Preprocesory** realizují vnořování částí programu do hostitelského jazyka (expandují makra, přidají include <něco.h> soubory apod.)
- **Analyzátory textu** kontroly pravopisu, práce s dokumenty, vyhledávání, indexace

Znalost základních principů překladače umožní i vytváření lepších programů v konkrétních jazycích, porozumění výhodám a nevýhodám konkrétních programových struktur.

Formálně je překladač zobrazením:

Překladač: zdrojový jazyk ⟶ cílový jazyk

Činnost assembleru: JSI ⟶ strojový kód

absolutní binární kód /přemístitelný binární kód

Činnost kompilátoru: vyšší progr. Jazyk ⟶ strojový kód
Pozn.: První překladač – Fortran IBM (Backus 1957)
pracnost 18 člověkoroků -ad hoc technologie

Činnost interpretu: vyšší progr. jazyk ⟹ výsledky
data

Dávkový překladač batchové zpracování

Konverzační překladač interaktivní

Inkrementální překladač interaktivní + překládá po úsecích
(př. Basic překlad po řádcích)

Křížový překladač překlad na jiném procesoru než exekuce (viz zabudované systémy)

Kaskádní překladač máme již A → B, ale chceme A→C, uděláme B → C. Kdy se to vyplatí? Komplikace - chybová hlášení výpočtu jsou pomíchaná

Optimalizující překladač (možnost ovlivnění optimalizace času / paměti programátorem)

Paralelizující překladač ≈ zjišťuje nezávislost úseků programu

Hlavní části překladače

Kompilátor:

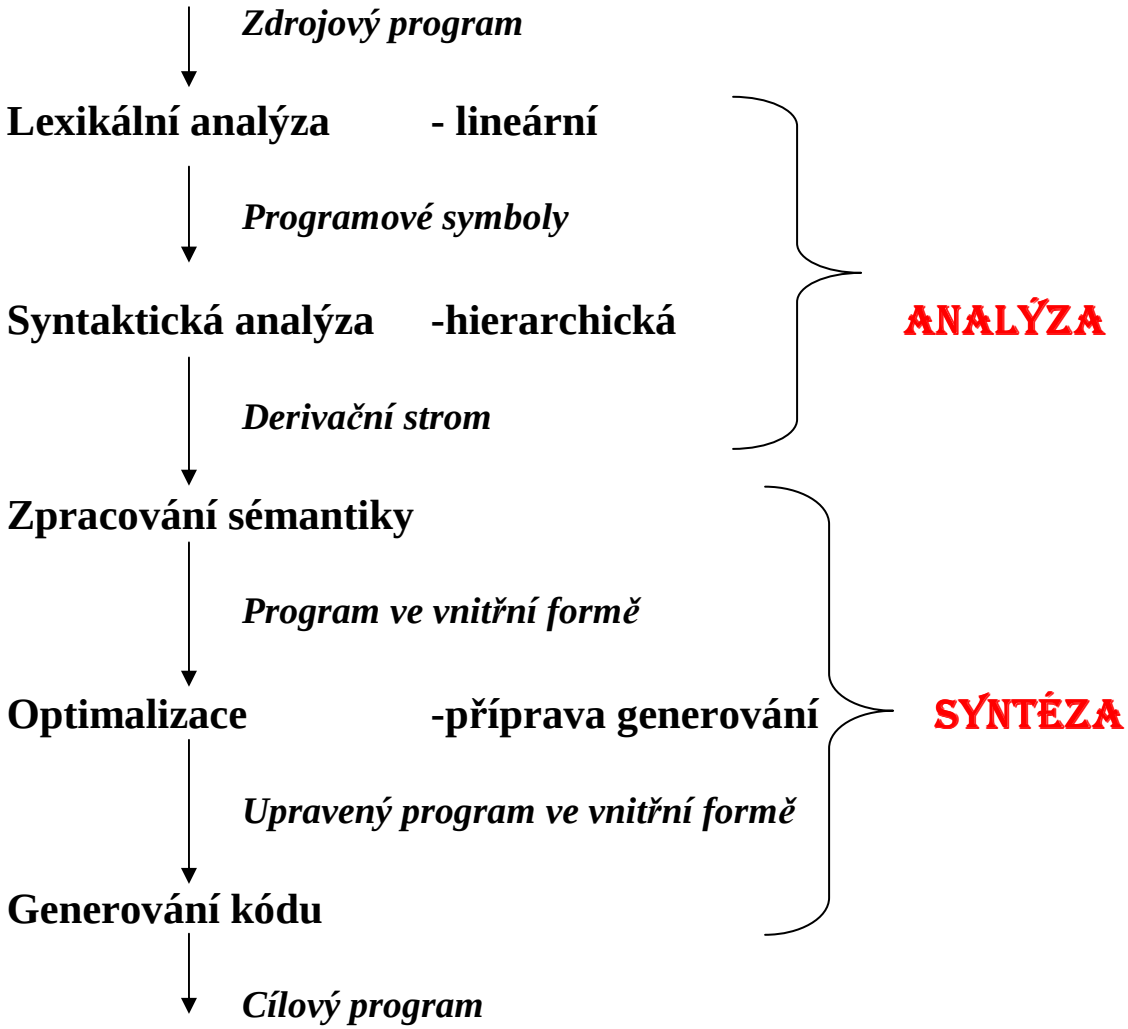

Všechny části spolupracují s pracovními tabulkami překladače.
Základní tabulkou kompilátoru i interpretu je
Tabulka symbolů

Výhodou kompilátoru je rychlá exekuce programu

Interpret

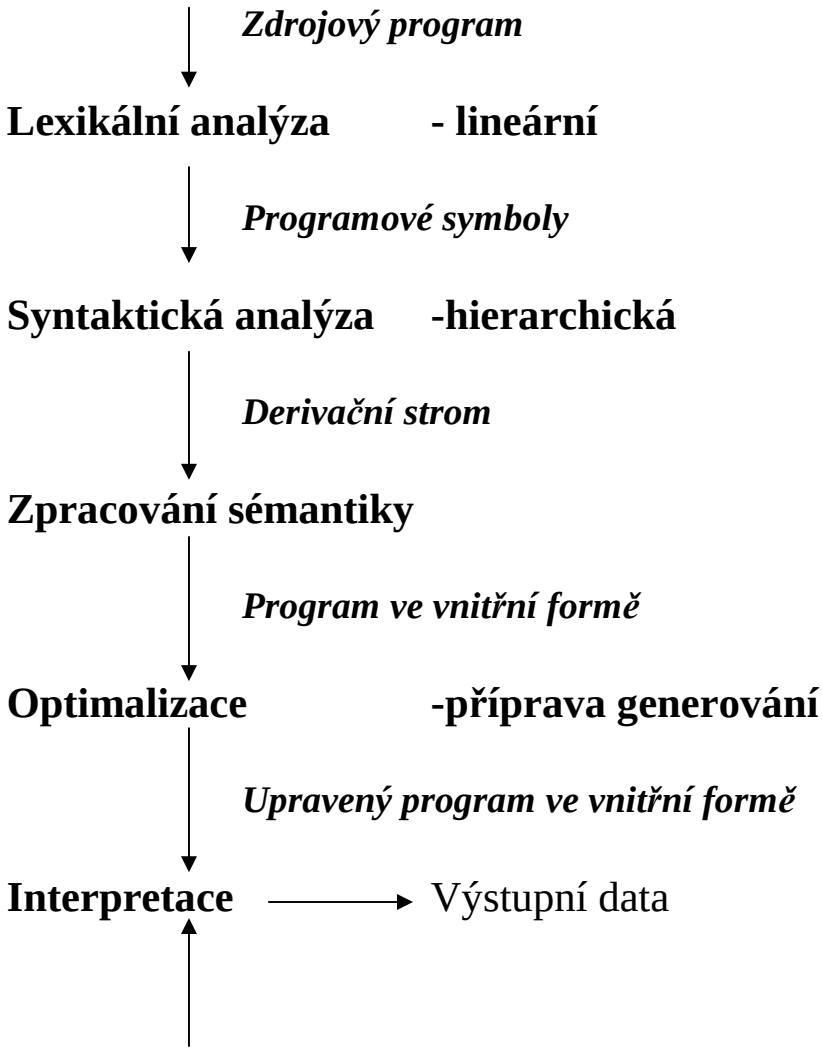

Výhodou interpretu je:
eliminace kroků cyklu (Editace→překlad→sestavení→exekuce)

Snazší realizace ladících mechanismů (zachování původních jmen symbolů)

Vícefázový / víceprůchodový překladač

Fáze = logicky dekomponovaná část,
(může obsahovat více průchodů, např. optimalizace).

Průchod = čtení vstupního řetězce,
zpracování,
zápis výstupního řetězce
(může obsahovat více fází).

Jednoprůchodový překladač =

- všechny fáze probíhají v rámci jediného čtení zdrojového textu programu,
- omezená možnost kontextových kontrol,
- omezená možnost optimalizace,
- lepší možnost zpracování chyb a ladění (pro výuku)

Co má vliv na strukturu překladače

- Vlastnosti zdrojového a cílového jazyka,
- Vlastnosti hostitelského počítače,
- Rychlost/velikost překladače,
- Rychlost/velikost cílového kódu,
- Ladicí schopnosti (detekce chyb, zotavení),
- Velikost projektu, prostředky, termíny.

Testování a údržba překladače

- Formální specifikace jazyka ⇒ možnost automatického generování testů,
- Systematické testování ⇒ regresní testy = sada testů doplňovaná o testy na odhalené chyby. Po každé změně v překladači se provedou všechny testy a porovnají se výstupy s předešlými.

Vnitřní jazyky překladače

- **Postfixová notace (operátory bezprostředně následují za svými operandy, pořadí operandů je zachováno)**
  Vyjadřuje precedenci operátorů, nepotřebuje závorky
  Př.1 a + b → a b +
  Př.2 (a + b) * (c + d) → a b + c d + *
  Postfixový zápis nepotřebuje (a nemá) závorky
  Postfix je elegantně vyhodnotitelný zásobníkem:
  1) Čti symbol postfixového řetězce,
  2) Je-li symbolem operand, ulož jej do zásobníku.
  3) Je-li symbolem operátor, proveď jeho operaci nad vrcholem zásobníku a výsledek vlož do zásobníku
  4) Jdi na 1).
  Po přečtení a vyhodnocení celého řetězce je výsledek uložen v zásobníku (princip interpretace).
  Pro př.2

čte a	čte b	čte +	čte c	čte d	čte +	čte *
				d		
	b		c	c	c+d	
a	a	a+b	a+b	a+b	a+b	(a+b)*(c+d)

  Pozn. Musíme umět vyjádřit i jiné než konstrukce pro výrazy.

- **Prefixová notace (operátory bezprostředně předchází operandy, pořadí operandů je zachováno)**
  Vyjadřuje precedenci operátorů, nepotřebuje závorky
  a + b → + a b
  (a + b) * (c + d) → * + a b + c d
  Prefixový zápis nemá závorky
  !Pozor, není to vždy zrcadlový obraz operátorů z postfixu

!!! pořadí operandů u postfixu i prefixu zůstává zachováno, mění se pořadí operátorů!!!

Zkusme na tabuli př. A = - B * C + D

- **Víceadresové instrukce (čtveřice / trojice)**
  Čtveřice **operátor, operand, operand, výsledek**
  Např. +, a, b, Vysledek
  Potřeba přidělovat paměť pomocným prom.

  Př 2) **(a + b) * (c + d)**

  +, a, b, Pom1
  +, c. d. Pom2
  ***, Pom1, Pom2, Vysl**

Trojice odkládají potřebu přidělovat paměť pomocným proměnným v době generování víceadresových instrukcí. Vztahují výsledek operace k číslu trojice

Př 2)	**1)**	**+,**	**a,**	**b**
	2)	**+,**	**c,**	**d**
	3)	***,**	**(1),**	**(2)**

Vyjadřují abstraktní syntaktický strom

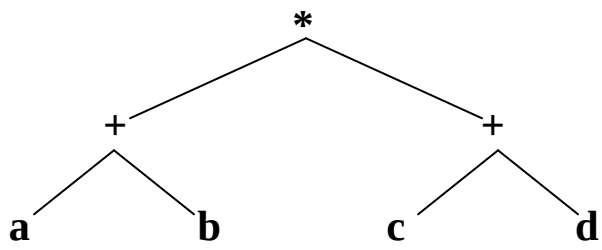

Optimalizace

- **Optimalizace cyklů**
- **Redukce počtu registrů**
- **…a další**

Př optimalizace paměti.

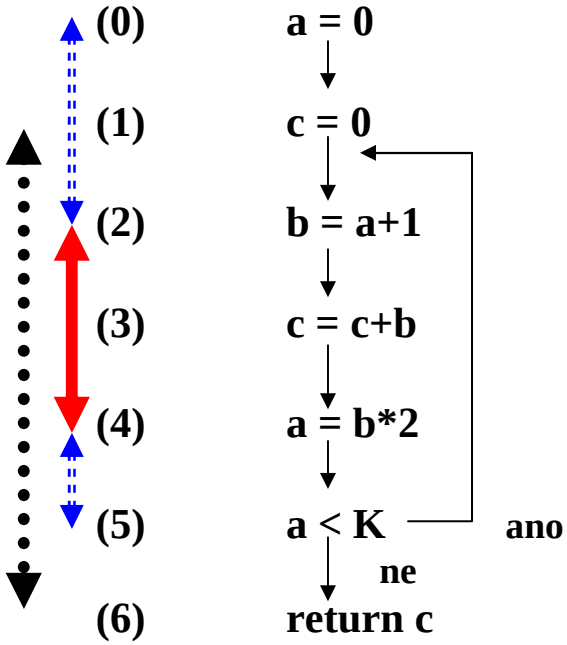

program

```
      a = 0; c = 0;
L :   b = a + 1;
      c = c + b;
      a = b * z;
      if a < K goto L;
      return c;
```

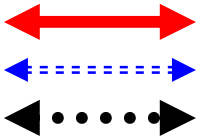

živé b (2) → (3) → (4)

živé a (0) → (1) → (2), (4) → (5) → (2)

živé c (1) → (2) → (3) → (4) → (5) → (2)

(5) → (6)

?Kolik potřebujeme registrů pro proměnné a, b, c. K je konstanta.

-zjištění živých a neživých proměnných v data flow diagramu,

-vytvoření interferenčního grafu,

-barvení grafu.

počet potřebných barev = počet potřebných registrů

Matice interferencí

	a	b	c
			x
			x
	x	x	

Př. překladu příkazu

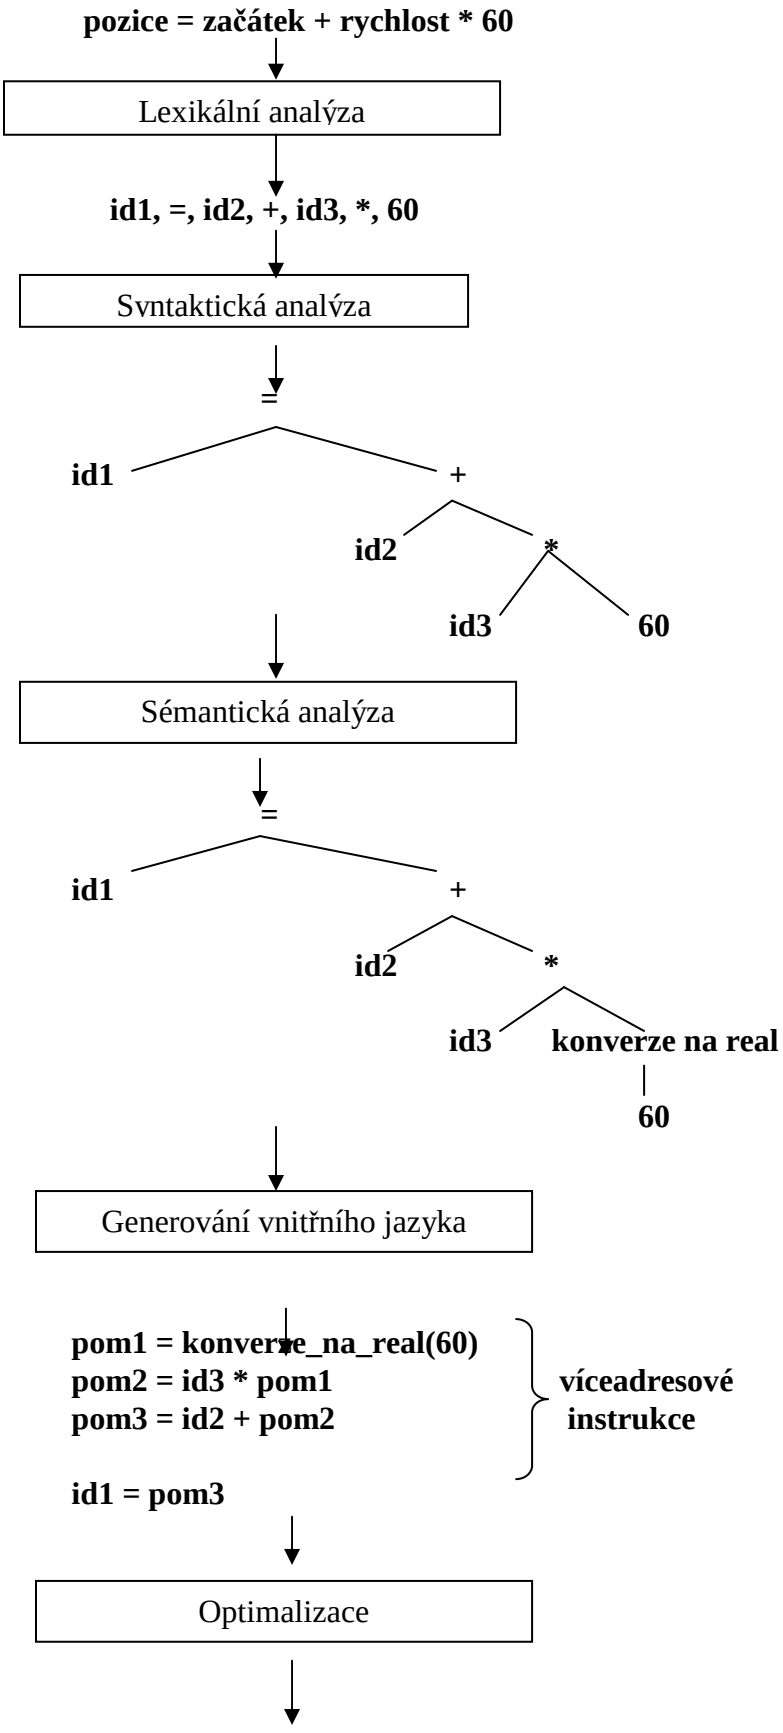

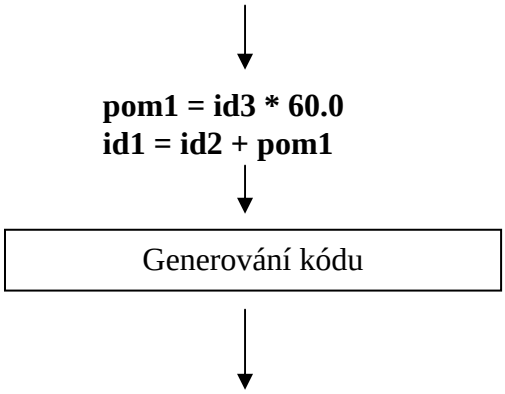

MOVF id3, R2
MULF #60.0, R2
MOVF id2, R1
ADDF R2, R1
MOVF R1, id1

Tabulka symbolů

1	**pozice**	**…**
2	**zacatek**	**…**
3	**rychlost**	**…**
4		
5		

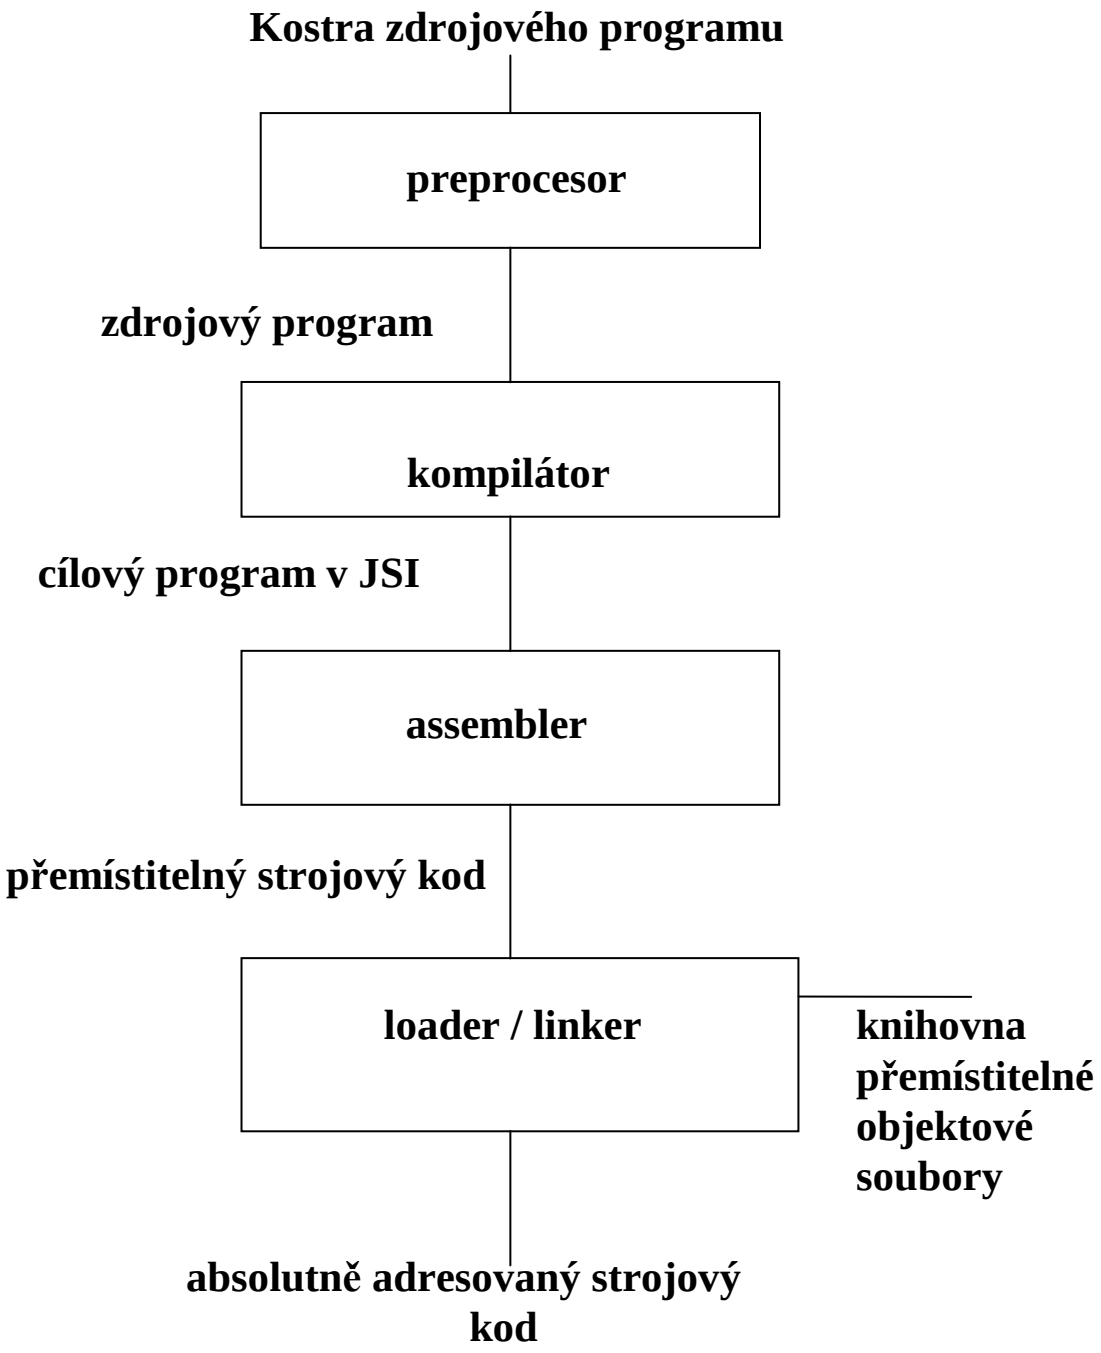

Obr. Systém zpracování jazyka

Principiální možnost automatizace konstrukce překladače

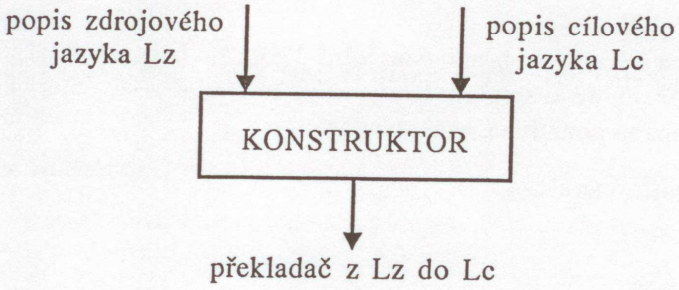

Obr. 1.12: Struktura dokonalého systému pro konstrukci překladače

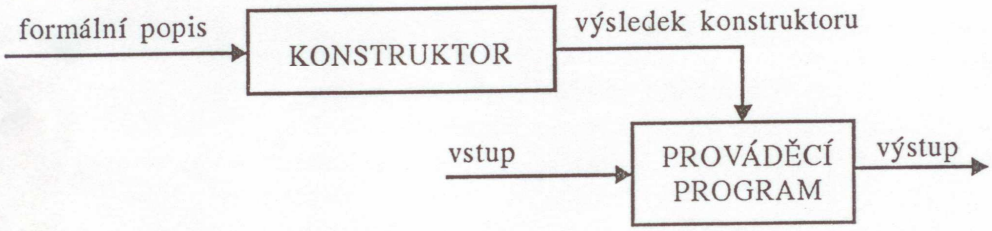

Obr. 1.13: Dvojice *konstruktor—prováděcí program*

Bezkontextová gramatika

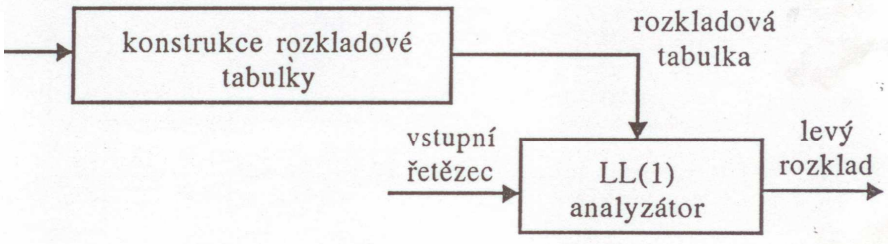

Obr. 1.14: Systém pro konstrukci $LL(1)$ analyzátoru

Jaké prostředky k tomu máme a co bychom chtěli

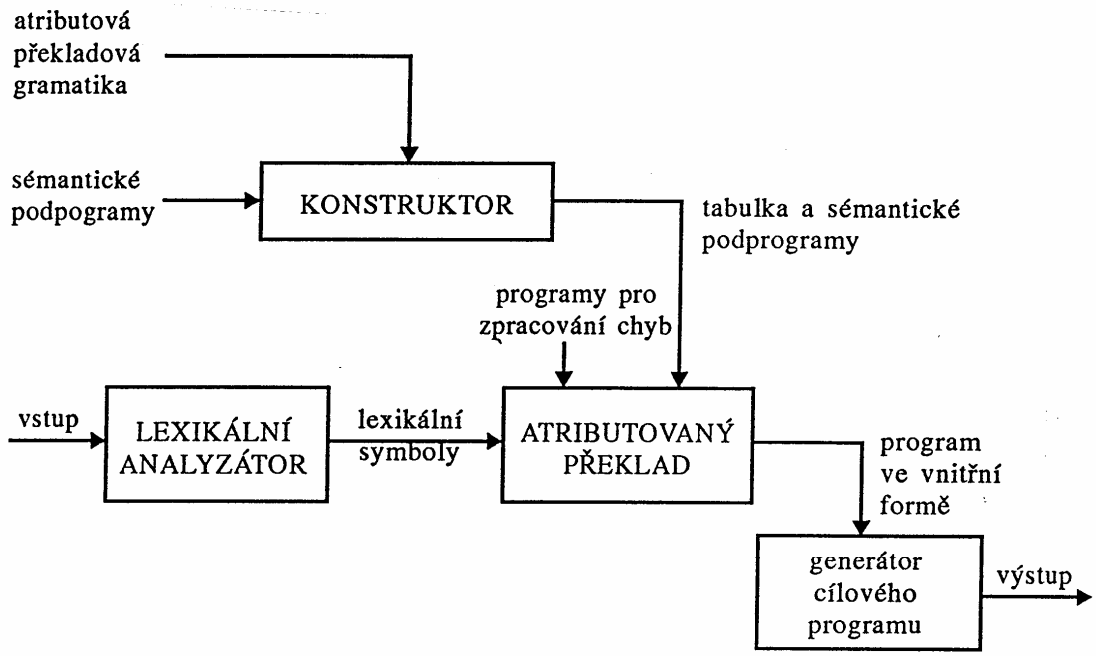

Obr. Systém automatické konstrukce syntaktického analyzátoru s připojeným zpracování sémantiky

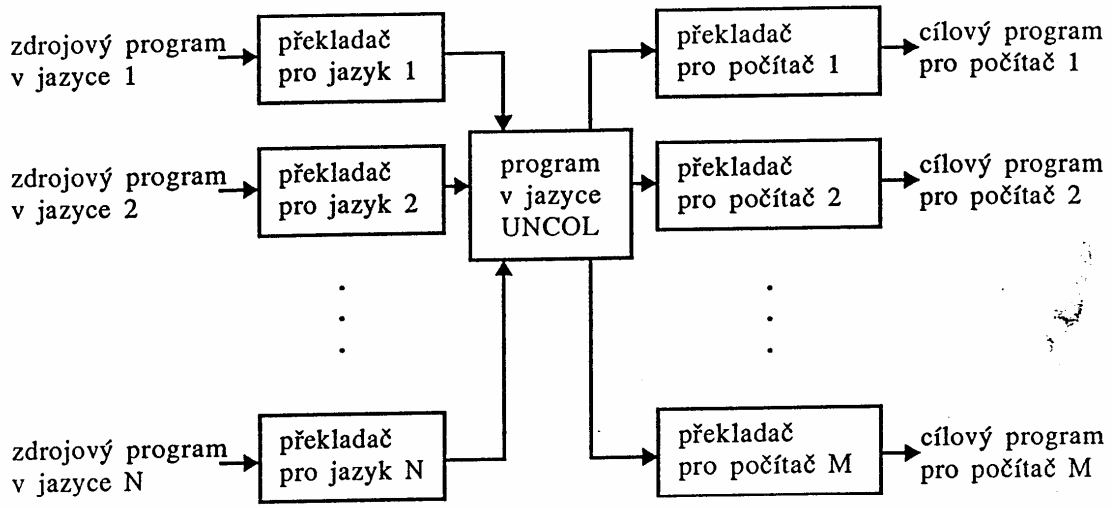

Obr. Základní myšlenka univerzálního vnitřního jazyka UNCOL

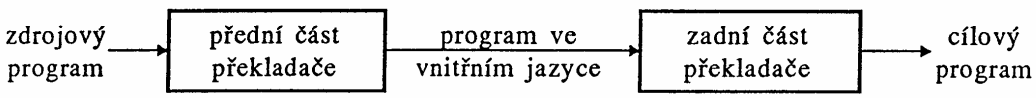

Obr. Přední a zadní část překladače

http://osteele.com/tools/reanimator/ **animace regulárních výrazů**
http://osteele.com/tools/rework/# **Javascript, Python, PHP, Ruby**
http://dinosaur.compilertools.net/ **Lex, Flex, Yacc, Bizon stránky**

The Lex & Yacc Page

Overview | Lex | Yacc | Flex | Bison | Tools | Books

OVERVIEW

A compiler or interptreter for a programminning language is often decomposed into two parts:

1. Read the source program and discover its structure.
2. Process this structure, e.g. to generate the target program.

Lex and *Yacc* can generate program fragments that solve the first task.

The task of discovering the source structure again is decomposed into subtasks:

1. Split the source file into tokens (*Lex*).
2. Find the hierarchical structure of the program (*Yacc*).

- A First Example: A Simple Interpreter

LEX

Lex - A Lexical Analyzer Generator

M. E. Lesk and E. Schmidt

Lex source is a table of regular expressions and corresponding program fragments. The table is translated to a program which reads an input stream, copying it to an output stream and partitioning the input into strings which match the given expressions. As each such string is recognized the corresponding program fragment is executed. The recognition of the expressions is performed by a deterministic finite automaton generated by Lex. The program fragments written by the user are executed in the order in which the corresponding regular expressions occur in the input stream.

- Online Manual
- PostScript
- Lex Manual Page

YACC

Yacc: Yet Another Compiler-Compiler

Stephen C. Johnson

Computer program input generally has some structure; in fact, every computer program that does input can be thought of as defining an ``input language" which it accepts. An input language may be as complex as a programming language, or as simple as a sequence of numbers. Unfortunately, usual input facilities are limited, difficult to use, and often are lax about checking their inputs for validity.

Yacc provides a general tool for describing the input to a computer program. The Yacc user specifies the structures of his input, together with code to be invoked as each such structure is recognized. Yacc turns such a specification into a subroutine that han- dles the input process; frequently, it is convenient and appropriate to have most of the flow of control in the user's application handled by this subroutine.

- Online Manual
- PostScript
- Yacc Manual Page

FLEX

Flex, A fast scanner generator

Vern Paxson

flex is a tool for generating scanners: programs which recognized lexical patterns in text. flex reads the given input files, or its standard input if no file names are given, for a description of a scanner to generate. The description is in the form of pairs of regular expressions and C code, called rules. flex generates as output a C source file,

- Online Manual
- PostScript
- Flex Manual Page
- Download Flex from ftp://prep.ai.mit.edu/pub/gnu/

BISON

Bison, The YACC-compatible Parser Generator

Charles Donnelly and Richard Stallman

Bison is a general-purpose parser generator that converts a grammar description for an LALR(1) context-free grammar into a C program to parse that grammar. Once you are proficient with Bison, you may use it to develop a wide range of language parsers, from those used in simple desk calculators to complex programming languages.

- Online Manual
- PostScript

- Bison Manual Page
- Download Bison from ftp://prep.ai.mit.edu/pub/gnu/

TOOLS

Other tools for compiler writers:

- Compiler Construction Kits http://catalog.compilertools.net/kits.html
- Lexer and Parser Generators http://catalog.compilertools.net/lexparse.html
- Attribute Grammar Systems http://catalog.compilertools.net/attribute.html
- Transformation Tools http://catalog.compilertools.net/trafo.html
- Backend Generators http://catalog.compilertools.net/backend.html
- Program Analysis and Optimisation http://catalog.compilertools.net/optim.html
- Environment Generators http://catalog.compilertools.net/env.html
- Infrastructure, Components, Tools http://catalog.compilertools.net/infra.html
- Compiler Construction with Java http://catalog.compilertools.net/java.html

BOOKS

Lex & Yacc
John R. Levine, Tony Mason, Doug Brown
Paperback - 366 pages 2nd/updated edition
O'Reilly & Associates
ISBN: 1565920007

Compilers: Principles, Techniques, and Tools
Alfred V. Aho, Ravi Sethi, Jeffrey D. Ullman
Addison-Wesley Pub Co
ISBN: 0201100886

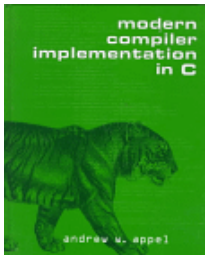

Modern Compiler Implementation in C
Andrew W. Appel, Maia Ginsburg
Hardcover - 560 pages Rev expand edition
Cambridge University Press
ISBN: 052158390X