

Dr. Ing. Miroslav Beneš

PŘEKLADAČE

Obsah

1 Základní pojmy	1
1.1 Úvod	1
1.1.1 Vývoj technik strojového překladu	1
1.1.2 Přístupy ke strojovému překladu	2
1.1.3 Další použití překladačů	5
1.2 Struktura překladače	6
1.2.1 Lexikální analýza	7
1.2.2 Syntaktický analyzátor	8
1.2.3 Sémantická analýza	9
1.2.4 Generování mezikódu	9
1.2.5 Optimalizace kódu	10
1.2.6 Generování cílového kódu	11
1.2.7 Tabulka symbolů	11
1.2.8 Diagnostika a protokol o průběhu překladu	12
1.3 Organizace překladu	13
1.3.1 Fáze překladu	13
1.3.2 Průchody	14
1.4 Příbuzné programy	14
1.5 Automatizace výstavy překladačů	16
2 Lexikální analýza	19
2.1 Činnost lexikálního analyzátoru	19
2.2 Základní pojmy	20
2.2.1 Symboly, vzory, lexémy	20
2.2.2 Atributy symbolů	21
2.3 Vstup zdrojového textu	22
2.4 Specifikace a rozpoznavání symbolů	24
2.4.1 Regulární výrazy	25
2.4.2 Regulární definice	26
2.4.3 Konečné automaty	27
2.5 Implementace lexikálního analyzátoru	27
2.5.1 Přímá implementace	28
2.5.2 Implementace lexikálního analyzátoru jako automatu se stavovým řízením	30
2.6 Lex – generátor lexikálních analyzátorů	32
2.6.1 Činnost programu lex	32
2.6.2 Struktura zdrojového textu	33

i

2.6.3 Zápis regulárních výrazů	34
2.6.4 Komunikace s okolím	34
2.7 Zotavení po chybě v lexikální analýze	36
3 Syntaktická analýza	39
3.1 Činnost syntaktického analyzátoru	39
3.2 Syntaktická analýza shora dolů	39
3.2.1 Mnogoší FIRST a FOLLOW	40
3.2.2 Konstrukce rozkladových tabulek	41
3.2.3 LL(1) gramatiky	43
3.2.4 Transformace na LL(1) gramatiku	44
3.2.5 Analýza rekurzivním sestupem	45
3.2.6 Nerekurzivní prediktivní analýza	48
3.2.7 Zotavení po chybě při analýze shora dolů	49
4 Syntaxí řízený překlad	55
4.1 Základní pojmy teorie překladu	55
4.2 Atributový překlad	57
4.2.1 Atributové rozkladové gramatiky	58
4.2.2 Graf závislostí	61
4.2.3 Pořadí vyhodnocení pravidel	62
4.3 Vyhodnocení S-attributových definic zdola nahoru	63
4.4 L-attributové definice	67
4.5 Překlad shora dolů	68
4.5.1 Odstranění levé rekurencie z překladového schématu	68
4.5.2 Implementace prediktivního syntaxí řízeného překladače	69
4.6 Vyhodnocení dědičných atributů zdola nahoru	70
5 Tabulka symbolů	73
5.1 Informace v tabulce symbolů	73
5.2 Organizace tabulků symbolů	76
5.2.1 Operace nad tabulkou symbolů	76
5.2.2 Implementace tabulek pro jazyky bez blokové struktury	76
5.2.3 Implementace blokové strukturované tabulky symbolů	77
6 Struktura programu v době běhu	81
6.1 Podprogramy	81
6.1.1 Statická a dynamická struktura podprogramů	81
6.2 Organizace paměti	83
6.3 Strategie přidělování paměti	84
6.3.1 Statické přidělování	85
6.3.2 Přidělování na zásobníku	85
6.3.3 Přidělování k hromadě	86
6.4 Metody přístupu k nelokálním objektům	86
6.5 Předávání parametrů do podprogramů	88
6.5.1 Předávání parametrů hodnotou a výsledkem	88
6.5.2 Předávání parametrů odkazem	89

6.5.3 Předávání parametrů jménem	89
6.5.4 Předávání procedur a funkcí	90
7 Typová kontrola	91
7.1 Typové systémy	92
7.1.1 Typové výrazy	92
7.1.2 Statická a dynamická kontrola typů	96
7.1.3 Zotavení po chybě při typové kontrole	96
7.2 Ekvivalence typových výrazů	96
7.3 Typové konverze	98
7.4 Přetěžování funkcí a operátorů	98
7.5 Polymorfické procedury a funkce	99
7.5.1 Unifikace typových výrazů	100
8 Generování intermediárního kódu	101
8.1 Intermediární jazyky	101
8.1.1 Grafová reprezentace	101
8.1.2 Zásobníkův kód	102
8.1.3 Tříadresový kód	104
8.2 Deklarace	106
8.2.1 Deklarace proměnných	106
8.2.2 Deklarace v jazyčích s blokovou strukturou	107
8.3 Přiřazovací příkazy a výrazy	108
8.3.1 Přidělování dočasných proměnných	109
8.3.2 Adresování příkazů polí	109
8.3.3 Konverze typů během přiřazení	112
8.4 Booleovské výrazy	113
8.4.1 Reprezentace booleovských výrazů číslicovou hodnotou	114
8.4.2 Zkrácené vyhodnocování booleovských výrazů	114
8.5 Příkazy pro změnu toku fázení	116
8.6 Selektivní příkazy	118
8.7 Backpatching	119
8.7.1 Booleovské výrazy	120
8.7.2 Překlad řídících příkazů	122
8.7.3 Volání podprogramů	124

Kapitola 1

Základní pojmy

V této kapitole se budeme zabývat obecným popisem činnosti a struktury překladače, jeho komunikace s okolím a některými podpůrnými prostředky používanými při výstavbě překladačů.

1.1 Úvod

Překladač je obvykle program, který čte zdrojový program (source program) a převádí ho do ekvivalentního cílového programu (object program). Zdrojový program je napsán ve zdrojovém jazyce, cílový program je v cílovém jazyce. Důležitou částí tohoto procesu překladu jsou diagnostické zprávy, kterými překladač informuje uživatele například o přítomnosti chyb ve zdrojovém programu. Techniky překladače se používají i pro realizaci počítačových architektur specializovaných na vyšší programovací jazyky (Modula, Lisp, Prolog). V tomto učebním textu ale budeme pojem překladač používat pouze pro program. Typickým zdrojovým jazykem pro nás bude strojový kód nebo jazyk assembleru nějakého počítače.

1.1.1 Vývoj technik strojového překladu

První počítače byly velmi jednoduché, například počítač Mark I z roku 1948 měl pouze sedm instrukcí a 32 slov hlavní paměti. Pro takový počítač postačovalo vkládání programů pomocí posloupnosti binárních čísel. S přichodem složitějších počítačů se rozšiřovaly také instrukční soubory a koncem 40. let bylo poukázáno na to, že převod unemonických názvů instrukcí do binárního kódu může být proveden pomocí počítače. Programy, které to prováděly, se nazývaly *assemblery* a příslušný mnemonický kód *jazyk assembleru*.

Další krok spočíval v zavedení *autokódů*, které umožňovaly reprezentovat jedinou instrukci několika strojových operací. Programy zajišťující jejich překlad se již nazývaly *překladače*, nebo také *komplikátory*. Jedním z používaných autokódů byl například MAT pro počítač Minsk-22, jehož mnemonické kódy byly odvozeny z českých názvů operací.

Pojem *překladač* se používá od začátku 50. let, kdy se začaly využívat uživatelsky orientované programovací jazyky vyšší úrovně, podstatně méně závislé na strojovém kódu konkrétního počítače. V tu dobu však ještě vlastla všeobecná skpese nad použitelností "automatického programování," jak se tehdy programování ve vyšších jazycích nazývalo. První jazyky tohoto typu (např. FORTRAN) a autokódy, ze kterých se využívaly, však byly silně poznamenány

1

tehdy existujícími instrukčními soubory počítače. Například FORTRAN IV umožňoval práci pouze s trojrozměrnými poli, neboť jeho první implementace byla provedena na počítači IBM 709, který měl pouze tři indexové registry. Dokonc i jazyk C, který se objevil uprostřed 70. let, má některé konstrukce (např. operátor inkrementace `++`) zavedené díky dostupnosti ekvivalentních instrukcí původněho cílového počítače PDP-11.

Algol 60 navržený ve skutečnosti již v roce 1958, přinesl daší nový přístup. Byl navržen s ohledem na řešení konkrétních problémů a portálal orážky týkající se možností překladu na konkrétní počítače. Umožňoval například užití lokálních proměnných a rekursivních volání procedur. Již se nezabýval tím, jak provést překlad na počítač s jedním společným adresovacím prostorem a jedinou instrukcí skoku do podprogramu. Tento přístup je v moderních programovacích jazycích bežný. Jazyky jako Pascal, Modula-2 a Ada byly navrženy nezávisle na jakékoli konkurenční architektuře.

Moderní jazyky vysoké úrovně svým obvykle stručným zápisem umožňují zvýšit produktivitu práce programátora, poskytují různá semantická omezení (např. typovou kontroly), kterými se dají redukovat logické chyby v programech, a zjednoduší také ladění programů. Další velmi významnou vlastností současných programovacích jazyků je možnost vytváření strojově nezávislých programů, které se dají přenášet i mezi principiálně různými architekturami počítačů. Jejich nevýhodou je rychlosť překladu (typicky 2–10 krát nižší než u ručně psaných programů v jazyce assembleru) a velikost, jak překladače, tak přeloženého kódu. Tyto nevýhody jsou však redukovány s rozvojem moderních počítačových architektur. V oblasti návrhu a implementace jazyků se užívá často dostavování do zcela opačné situace, než jaká byla na počátku vývoje jazyků, kdy jsou navrhovány procesory již s ohledem na překlad konkrétních jazyků (existují například specializované procesory pro Lisp, Pascal nebo Modulu).

Theorie překladu a formálních jazyků dnes umožňuje bežně používané jazyky překládat bez obtíží. Pro automatickou výstavbu překladačů je k dispozici mnoho specializovaných prostředků. Zatímco na vývoj prvního překladače jazyka FORTRAN bylo třeba 18 "člověkoroků," nyní je vytvoření jednoduchého překladače jazyka Pascal zvládnutelné i pro studenta vysoké školy.

1.1.2 Přístupy ke strojovému překladu

Máme-li program napsaný v některém vyšším programovacím jazyce, existuje několik možných přístupů k jeho spuštění. Buď můžeme program převést do ekvivalentního programu ve strojovém kódu počítače – překladače tohoto typu se označuje názvem *komplikátor* nebo *komplikátor překladač*, nebo můžeme napsat program, který bude interpretovat příkazy zdrojového jazyka tak, jak jsou napsané, a přímo provádět odpovídající akce. Programy realizující druhý přístup se nazývají *interpret* nebo *interpretativní překladač*. Obrázky 1.1 a 1.2 představují schématu činnosti obou typů překladačů.

Výhodou komplikace je, že analýza zdrojového programu a jeho překlad se provádějí jen jednou, i když může jít o časově dosti náročný proces. Dále již spuštění pouze ekvivalentního programu ve strojovém kódu, který je výsledkem překladu. Nevýhodou je někdy dosti obtížné sledování chyb ve zdrojovém programu, pokud máme pouze informace o místu chyby vyjádřené v pojmech strojového jazyka (adresy, výpisy obrazu paměti). Moderní překladače však často vytvářejí zároveň s cílovým kódem i pomocné datové struktury, které umožňují provádět ladění programu přímo na úrovni zdrojového jazyka — provádět program po jednotlivých příkazech, vypisovat hodnoty proměnných nebo posloupnost volání funkcí a hodnot jejich parametrů.

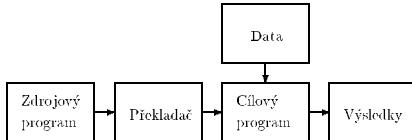
Výhodou komplikace je, že analýza zdrojového programu a jeho překlad se provádějí jen jednou, i když může jít o časově dosti náročný proces. Dále již spuštění pouze ekvivalentního programu ve strojovém kódu, který je výsledkem překladu. Nevýhodou je někdy dosti obtížné sledování chyb ve zdrojovém programu, pokud máme pouze informace o místu chyby vyjádřené v pojmech strojového jazyka (adresy, výpisy obrazu paměti). Moderní překladače však často vytvářejí zároveň s cílovým kódem i pomocné datové struktury, které umožňují provádět ladění programu přímo na úrovni zdrojového jazyka — provádět program po jednotlivých příkazech, vypisovat hodnoty proměnných nebo posloupnost volání funkcí a hodnot jejich parametrů.

1.1. Úvod

3

4

KAPITOLA 1. ZÁKLADNÍ POJMY



Obrázek 1.1: Kompilační překladač

Kód generovaný komplikací překladačem nemusí být obecně ekvivalentní se strojovým kódem nějakého konkrétního počítače. Obecně můžeme cílové kódy podle jejich vztahu k určitému procesoru a operačnímu systému rozdělit takto:

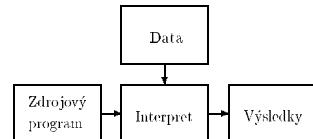
- Cistý strojový kód.** Jedná se o strojový kód konkrétního počítače bez předpokladu existence určitého operačního systému nebo knihovny. Cistý strojový kód obsahuje pouze instrukce z instrukčního souboru počítače, pro který jsou překládány programy určené. Tento přístup je velmi růžký, občas se používá pro jazyky určené k vytváření systémových programů (např. jáder operačních systémů, které pracují autonomně bez dalšího programové podpory).

- Rozšířený strojový kód.** Tento typ zahrnuje kromě instrukcí daných architekturou procesoru také podprogramy operačního systému a podpůrné knihovní podprogramy (např. pro matematické funkce). Rozšířený strojový kód se dá považovat za kód *virtuálního počítače*, tvoreného kombinací konkrétního technického a programového vybavení nějakého počítače. Poměr obou složek se může u konkrétních implementací lišit; například překladače jazyka FORTRAN obvykle využívá knihoven pouze pro vstupy a výstupy a pro matematické funkce, zatímco velká část moderních překladačů pracuje s operacemi pro bitová pole, volací posloupnosti procedur a funkcí nebo pro dynamické přidělování paměti.

- Virtuální strojový kód.** Nejobecnější forma strojového kódu obsahuje pouze virtuální instrukce, které nejsou závislé na žiadné konkrétní architektuře nebo konkrétním operačním systému. Tato forma umožňuje vytvářet *picnosítelné překladače*: při přenosu stačí pouze napsat interpret virtuálního kódu. Příkladem takového překladače je Wirthův Pascal P, jehož výstupem je tzv. *P-kód* pro virtuální zásobníkový počítač. Vélez rychlá přenositelnost takového překladače možná byla jedním z důvodů velké popularity Pascalu.

Další vlastností cílového kódu, který podstatně ovlivňuje složitost návrhu komplikáčního překladače, je jeho formát. Pro cílový kód se nejčastěji používá jeden z následujících formátů:

- Symbolický formát.** Cílový program v symbolickém formátu má obvykle tvar zdrojového souboru v jazyce assembleru. V tomto případě je značně ulehčena práce překladače, neboť se nemusí zabývat například řešením dopředných odkazů v programu nebo přidělováním adres pro data. Tento přístup je často používán v operačním systému Unix a



Obrázek 1.2: Interpretativní překladač

Interpretace je mnohem pomalejší než komplikace, neboť je třeba analyzovat zdrojový příkaz po každé, když na něj program narazí. Pro poměr mezi rychlostí interpretovaného a komplikovaného programu se uvádějí hodnoty mezi 10:1 až 100:1, v závislosti na konkrétním jazyce. Interpreti lyžují také náročně na paměťový prostor, neboť v případě programu musí být stále k dispozici celý překladač.

Interprety však mají i své výhody oproti komplikáčním překladačům. Při výskytu chyby můžeme vždy přesně informovat o jejím výskytu a můžeme poměrně rychle odhalit její příčinu. Tento přístup je tedy vhodný zvláště při ladění programů. Interpreti umožňují modifikaci textu programu i během jeho činnosti, což se využívá často v jazycích jako je Prolog nebo LISP. U jazyků, které nemají blokovou strukturu (např. BASIC, APL), se může změnit některý příkaz, anž by se musel znova překládat zbytek programu. Interpreti se daleko používají tam, kde se mohou typy objektů dynamicky měnit v průběhu provádění programu — typickým příkladem je jazyk Smalltalk-80. Jejich zpracování je pro komplikáční překladače značně

obtížném. Interpretaci překladače bývají značně strojově nezávislé, neboť negenerují strojový kód. Pro přenos na jiný počítač obvykle postačí interpret znova zkompilovat.

Uvedený dva přístupy jsou však extrémní, mnoho překladačů využívá spíše jejich kombinace. Některé interpretaci překladače například nejdříve převedou zdrojový program do nějakého vnitřního formátu (v nejednodušším případě alespoň nahradí klíčová slova jejich binární kódy) a ten potom interpretují. Výsledné řešení je kompromisem mezi časově náročným překladem komplikovaného a pomalým během interpretovaného programu.

Výběr vhodného přístupu, zda kompilovat nebo interpretovat, závisí obvykle na pouze jazyka a prostředí, ve kterém se používá. Pro časově náročné matematické výpočty se používají komplikační překladače, naopak pro účely výuky jazyků nebo na malých mikropočítačích se dává přednost interpretaci (typickými příklady takových jazyků jsou BASIC, LOGO nebo Smalltalk-80). Pro jazyk LISP se často používá zároveň obou přístupů, neboť jeho kompilace je časově značně náročná a komplikovaný program nemá dostatečné prostředky pro odstranění chyb. Interpretaci překlad se také běžně užívá v různých příkazových jazykách, když se očekává okamžitý provedení příkazu — příkladem mohou být dotazovací databázové jazyky jako SQL nebo jazyky řídících programů, umožňující spouštění programů a komunikaci s operačním systémem počítače, např. `sh` nebo `csh` v systému Unix.

Tento učební text je orientován převážně na komplikační překladače, i když mnoho uvedených algoritmů je možné použít také při psaní interpretu. V obou případech bývá stejná analýza zdrojového kódu a často bývájí podobné i metody hledání nejefektivnějšího kódu pro interpretaci s metodami generování člověkového kódu.

1.1.3 Další použití překladačů

Techniky překladačů se samozřejmě nejčastěji používají pro překladače programovacích jazyků. Mají však mnohem širší využití i v jiných oblastech. Mnoho podpůrných programových prostředků, které manipuluji se zdrojovým programem, provádí rovněž jistý druh analýzy. Tyto prostředky zahrnují například:

- *Strukturované editory*. Strukturovaný editor má jako vstup posloupnost příkazů pro vybudování zdrojového programu. Strukturovaný editor neprovádí pouze funkce pro vytváření a modifikaci textu jako běžný textový editor, ale analyzuje navíc text programu a vkládá do něj vhodnou hierarchickou strukturu. Strukturovaný editor tedy může plnit ještě další úkoly, které jsou užitečné při přípravě programu. Může například kontrolovat, zda je vstup správně syntakticky zapsán, může automaticky doplňovat klíčová slova (např. když uživatel napíše `while`, doplní editor odpovídající `do` a přípomenu uživateli, že mezi nimi musí být logický výraz) nebo může přecházet z klíčového slova `begin` nebo levé závorky na odpovídající `end` nebo pravou závorku. Navíc výstup takového editoru je často podobný výstupu analytické části překladače.
- *Formátovací programy*. Formátovací program (pretty printer) analyzuje program a tiskne ho takovým způsobem, aby byla zřetelná jeho struktura. Například poznámky mohou být vytiskeny jiným typem písma a příkazy mohou být odsazeny v závislosti na úrovní jejich zařazení v hierarchické struktuře příkazů.
- *Programy pro sazbu textů*. Programy pro sazbu textů umožňují kombinovat text knihy, článku nebo dopisu s příkazy, které zajistují členění na odstavce, kapitoly, změnu typu a velikosti písma, vytváření obsahu nebo indexu, speciální sazbu matematických textů

nebo dokonce sazbu not nebo šachových partií. Typickým zástupcem této třídy programů jsou TeX a L^AT_EX [8, 9], kterými byl připraven tento učební text.

Zdrojovým jazykem překladače nemusí být vždy nějaký programovací jazyk. Může se jednat také o některý přirozený jazyk (např. anglický), speciální jazyk popisující strukturu kremikového integrovaného obvodu nebo strukturu grafických informací, které se mají zobrazit na tiskárně. Cílovým kódem takového překladače pak může být třeba jiný přirozený jazyk, maska integrovaného obvodu nebo posloupnost příkazů pro ovládání laserové tiskárny. Programovacím jazykem tohoto typu je například PostScript [1], který se používá pro vytváření chyb, nebo Metafont [7], kterým se definují tvary znaků používaných při sazbe textu připravených programem TeX. Tyto jazyky mají i prostředky pro vytváření cyklu, podmínekých příkazů nebo pro definování vlastních procedur nebo funkcí.

V dalších kapitolách se budeme věnovat výhradně klasickým překladačům, opř. s tím, že uvedené techniky jsou použitelné i v jiných oblastech, zejména techniky analýzy zdrojového textu.

1.2 Struktura překladače

Překladač musí provádět dvě základní činnosti: analyzovat zdrojový program a vytvářet k němu odpovídající cílový program. Analýza spočívá v rozkladu zdrojového programu na jeho základní součásti, na základě kterých se během syntézy vybudují moduly cílového programu. Obě části překladače, analytická i syntetická, využívají ke své činnosti společné tabulky.

Analýza zdrojového programu při překladu probíhá na následujících třech úrovních:

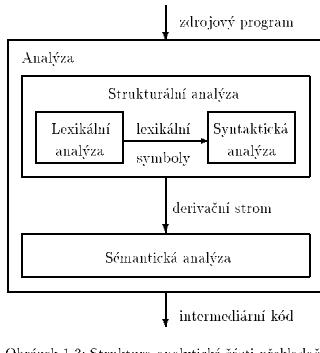
• *Lexikální (lineární) analýza*. Zdrojový program vstupuje do procesu překladu jako posloupnost znaků. Tato posloupnost se čte lineárně zleva doprava a sestavují se z ní lexikální symboly (tokens) jako konstanty, identifikátory, klíčová slova nebo operátory.

• *Syntaktická (hierarchická) analýza*. Z posloupnosti lexikálních symbolů se vytvářejí hierarchicky zařazené struktury, které mají jako celek svůj význam, např. výrazy, příkazy, deklarace nebo program.

• *Sémantická analýza*. Během sémantické analýzy se provádějí některé kontroly, zajistující správnost programu z hlediska vazeb, které nelze provádět v rámci syntaktické analýzy (např. kontrola deklarací, typová kontrola apod.).

Uvedený členění na úrovně analýzy vychází z toho, že běžné programovací jazyky jsou z hlediska Chomského klasifikace typu 1, tj. kontextové. Pro přímou analýzu kontextových jazyků dosud nebyly využity — na rozdíl od jazyků bezkontextových — dostatečně efektivní prostředky. Proto se na každou z těchto úrovní používají speciální metody specifikace i implementace, které využívají vlastnosti jazyků příslušných typů, tj. lineární analýza se provádí prostředky pro analýzu regulérních jazyků a hierarchická analýza prostředky pro analýzu bezkontextových jazyků. Pro sémantickou analýzu se obvykle využívá některá modifikace atributových gramatick, větší část sémantické analýzy však je implementována přímo prostředky jazyka, jímž je realizován překladač.

1.2. STRUKTURA PŘEKLADAČE



Obrázek 1.3: Struktura analytické části překladače

1.2.1 Lexikální analýza

Fáze lexikální analýzy (lexical analysis, scanning) čte znaky zdrojového programu a sestavuje je do posloupnosti *lexikálních symbolů*, v níž každý symbol představuje logický související posloupnost znaků jako identifikátor nebo operátor obdobný `=`. Posloupnost znaků tvořících symbol se nazývá *lexem* (lexeme).

Po lexikální analýze znaků např. v tomto příkladovacím příkazu

`pozice := počátek + rychlost * 60` (1.1)

by se vytvořily následující lexikální jednotky:

1. identifikátor `pozice`
2. symbol přiřazení `=`
3. identifikátor `počátek`
4. operátor `+`
5. identifikátor `rychlos`
6. operátor `*`
7. číslo `60`

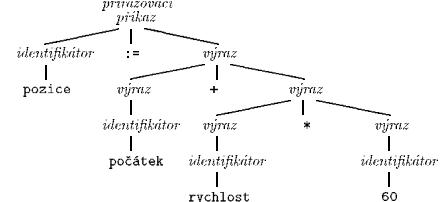
Symboly, které zahrnují celou třídu lexikálních jednotek (identifikátor, číslo, ftežec), jsou reprezentovány obvykle jako dvojice <druh symbolu, hodnota>, přičemž druhá část dvojice může být pro některé symboly prázdná. Výstupem lexikálního analyzátoru pro příkaz (1.1) by tedy mohla být posloupnost

`<id,pozice> <:=> <id,počátek> <+> <id,rychlos> <*> <num,60>`

Mezery, konce řádků a poznámky oddělující lexikální symboly se obvykle během lexikální analýzy vypoňouštějí.

1.2.2 Syntaktický analyzátor

Syntaktická analýza (parsing, syntax analysis) spočívá v sestavování lexikálních jednotek ze zdrojového programu do gramatických frází, které překladač používá pro syntézu výstupu. Gramatické fráze zdrojového programu se obvykle reprezentují *derivačním stromem* obdobným stromu na obr. 1.4.



Obrázek 1.4: Derivační strom pro výraz `pozice:=počátek+rychlos*60`

Vé výrazu `počátek+rychlos*60` je fráze `rychlos*60` logickou jednotkou, neboť podle běžných matematických konvencí pro aritmetické výrazy se násobení provádí před sčítáním. Vzhledem k tomu, že za výrazem `počátek+rychlos` následuje `*`, nevytváří tento výraz v situaci na obr. 1.4 frázi.

Hierarchická struktura programu se obvykle vyjadruje pomocí rekurezivních pravidel, zapsaných ve formě bezkontextové gramatiky. Například pro definici části výrazu můžeme mít následující pravidla:

`výraz -> identifikátor` (1)

`výraz -> číslo` (2)

`výraz -> výraz + výraz` (3)

`výraz -> výraz * výraz` (4)

`výraz -> (výraz)` (5)

Pravidla (1) a (2) jsou (nerekurzivní) základní pravidla, zatímco (3)–(5) definují výraz pomocí operátorů aplikovaných na jiné výrazy. Podle pravidla (1) jsou tedy `počátek` a `rychlos` výrazy. Podle pravidla (2) je `60` výraz, zatímco z pravidla (4) můžeme nejprve odvodit, že `rychlos*60` je výraz a konečně z pravidla (5) také `počátek+rychlos*60` je výraz.

Podobným způsobem jsou definovány příkazy jazyka, jako např.:

```

příkaz -> identifikátor := výraz
příkaz -> while ( výraz ) do příkaz
příkaz -> if ( výraz ) then příkaz

```

(1.2)

Dělení na lexikální a syntaktickou analýzu je doslova volné. Obvykle vybíráme takové rozdělení, které zjednoduší činnost analyzátora. Jedním z faktorů, které přitom uvažujeme, je to, zda jsou konstrukce zdrojového jazyka regulární nebo ne. Lexikální jednotky lze obvykle popsat jako regulární množiny, zatímco konstrukce vytvořené z lexikálních jednotek již vyžadují obecnější přístupy.

Typickou regulární konstrukcí jsou identifikátory, popsané obvykle jako posloupnosti písmen a číslic začínající písmenem. Číselnou rozpoznávací identifikátory jednoduchým proložením vstupního textu, v němž očekáváme znak, který není písmeno ani číslice, a potom seskupinu všechna písmena a číslice nalezené až do tohoto místa do lexikální jednotky pro identifikátor. Znaky takto shrnouzáné zaznamenáme do tabulky (tabulky symbolů) a odstraníme je ze vstupu tak, aby mohlo pokračovat zpracování dalšího symbolu.

Tento způsob lineárního prohledávání na druhé straně není dostatečný pro analýzu výrazů nebo příkazů. Nemůžeme například jednoduše kontrolovat dvojice závorek nebo klínových slov **begin** a **end** v příkazech bez zavedení jakéhosi druhu hierarchické struktury na vstupu.

Derivační strom na obr. 1.4 popisuje syntaktickou strukturu vstupu, ale obsahuje informace, které nejsou důležité pro další příběh překladu. Mnohem běžnějšími vnitřními reprezentacemi této syntaktické struktury dává *syntaktický strom* na obr. 1.5(a). Syntaktický strom je značnou reprezentací derivačního stromu; operátory v něm vystupují jako vnitřní uzly a operandy těchto operátorů jsou následníky jejich příslušných uzlů.

1.2.3 Sémantická analýza

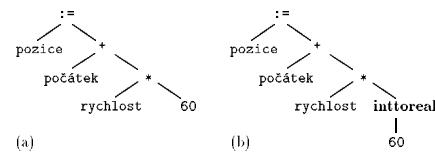
Fáze sémantické analýzy zpracovává předešlou informaci, které jsou uvedeny v *deklaracích*, ukládá je do vnitřních datových struktur a na jejich základě provádí sémantickou kontrolu příkazů a výrazů v programu. K identifikaci operátorů a operandů těchto výrazů a příkazů využívá literárníku strukturu, učenou ve fázi syntaktické analýzy.

Důležitou složkou sémantické analýzy je *typová kontrola*. Kompilátor zde kontroleje, zda všechny operátory mají operandy povolené specifikací zdrojového jazyka. Mnoho definic programovacích jazyků například vyžaduje, aby komplátor hlašil chybu, kdyžkoliv je reálné číslo použito jako index pole. Specifikace jazyka však může dovolit některé implikativní transformace operandů například při aplikaci binárního aritmetického operátoru na celočíselný a reálný operand. V tomto případě může komplátor požadovat konverzi celého čísla na reálné.

Jsou-li např. všechny proměnné v našem ukázkovém příkazu reálné, je třeba provést konverzi celočíselné konstanty 60 na reálnou, jak znázorňuje obr. 1.5(b). V tomto případě je rovněž možné typovou konverzi provést přímo a konstantu 60 nahradit hodnotou 60.0.

1.2.4 Generování mezíkódů

Po ukončení syntaktické a sémantické analýzy generují některé překladače explicitní *intermediární reprezentaci* zdrojového programu (*mezíkód*). Intermediární reprezentaci můžeme považovat za program pro nějaký abstraktní počítač. Tato reprezentace by měla mít dve důležité vlastnosti: měla by být jednoduchá pro vytváření a jednoduchá pro překlad do tvaru cílového programu.



Obrázek 1.5: Syntaktický strom

Intermediární kód slouží obvykle jako podklad pro optimalizaci a generování cílového kódu. Místo však byt také konečnou produktem překladu v interpretativním překladači, který vygenerovaný mezikód přímo provádí.

Intermediární reprezentace mohou mít různé formy. Například tříadresový kód se podobá jazyku symbolických instrukcí pro počítač, jehož každé místo v paměti může sloužit jako registr. Tříadresový kód se skládá z posloupnosti instrukcí s nejvýše třemi operandy. Zdrojový program z (1.1) by mohl v tříadresovém kódu vypadat následovně:

```

temp1 := inttoreal(60)
temp2 := rychlosť * temp1
temp3 := počátek + temp2
pozice := temp3

```

(1.3)

Intermediární reprezentace, které se využívají v překladačích, se budeme zabývat v kapitole 8. Obecně tyto reprezentace musejí dělat více než jen vypočít výrazů: musejí si například poradit s řídícimi konstrukcemi a voláním procedur.

1.2.5 Optimalizace kódů

Fáze optimalizace kódů se pokouší vylepšit intermediární kód tak, aby jeho výsledkem byl rychlejší nebo kratší strojový kód. Pojem "optimalizace" se nechápe doslovně jako nalezení nejlepší varianty, některé optimalizační algoritmy mohou ve zcela speciálních případech vést dokonce ke zhoršení vlastností původního kódu.

Některé optimalizace jsou triviální. Například přirozený algoritmus generuje intermediární kód (1.3) pomocí jedné instrukce pro každý operátor ve stručné reprezentaci po sémantické analýze, i když existuje lepší způsob provedení těchž výpočtů pomocí celkem dvou instrukcí:

```

temp1 := rychlosť * 60.0
pozice := počátek + temp1

```

(1.4)

Uvedenou optimalizaci lze bez problémů v překladači realizovat. Překladač totiž může zjistit, že konverzí hodnoty 60 z celočíselného na reálný tvar lze provést jednou provždy v čase překladu, takže operaci inttoreal je možné vypustit. Dále hodnota temp3 se používá pouze jednou pro přesnou její hodnotu do proměnné pozice. Můžeme tedy bez obav použít místo temp3 přímo proměnnou pozice, takže nemí potřebný poslední příkaz v (1.3) a dostaneme kód (1.4).

V množství různých prováděných optimalizací se jednotlivé překladače od sebe značně liší. Překladače, tzv. "optimalizující," které provádějí většinu optimalizací, stráví podstatnou

část doby překladu právě v této fázi. Existují však i jednoduché optimalizace, které podstatně zlepší dobu běhu přeloženého programu bez velkého zpomalení překladu.

1.2.6 Generování cílového kódů

Po ukončení syntaktické a sémantické analýzy generují některé překladače explicitní *intermediární reprezentaci* zdrojového programu (*mezíkód*). Intermediární reprezentaci můžeme považovat za program pro nějaký abstraktní počítač. Tato reprezentace by měla mít dve důležité vlastnosti: měla by být jednoduchá pro vytváření a jednoduchá pro překlad do tvaru cílového programu.

Překlad kódů (1.4) může například s použitím registrů 1 a 2 vypadat takto:

```

MOVF rychlosť, R2
MULF #60.0, R2
MOVF počátek, R1
ADDF R2, R1
MOVF R1, pozice

```

První operand každé instrukce je zdrojový, druhý operand cílový. Písmeno F ve všech instrukčních znamená, že pracujeme s hodnotami v polohyblivé řádové čáře. Uvedený kód přesune adresu adresy **rychlosť** (obětí jsme zatím důležitým problém přidělení paměti identifikátorem zdrojového programu) do registru 2, potom ho vynásobi reálnou konstantou 60.0. Znak # znamená, že se mi hodnota 60.0 zpracovat jako konstanta. Třetí instrukce přesnou hodnotu **počátek** do registru 1 a přičítá k němu hodnotu vypočítanou dříve v registru 2. Na konec se přesune hodnota z registru 1 na adresu **pozice**, takže tento kód implementuje přifázení z obr. 1.4.

1.2.7 Tabulka symbolů

Základní funkci tabulky symbolů je zaznamenávání identifikátorů používaných ve zdrojovém programu a sloučování informací a různých atributů každého identifikátoru. Tyto atributy mohou poskytovat informaci o paměti přidělené např. proměnné, její typu, rozsahu platnosti a v případě jmena procedur takové věci jako počet a typ argumentů, způsob předávání každého argumentu (např. odkazem) a typ vrácené hodnoty, pokud nějaká existuje.

Tabulka symbolů (symbol table) je datová struktura obsahující pro každý identifikátor jeho záznam s jeho atributy. Tato datová struktura umožňuje rychlé vyhledání záznamu pro konkrétní identifikátor a rychlé ukládání nebo vybírání příslušných dat ze záznamu. Tabulkami symbolů se budeme zabývat v kapitole 5.

Rozpozná-li lexikální analýzator ve zdrojovém programu identifikátor, může ho rovnou dobit do tabulky symbolů. Během lexikální analýzy však normálně nemůžeme všechny atributy identifikátoru určit. Například v pascalovské deklaraci

```
var pozice, počátek, rychlosť : real;
```

není typ **real** znám v okamžiku, kdy lexikální analýzator vidí identifikátory **pozice**, **počátek** a **rychlosť**.

Informace o identifikátorech ukládají do tabulky symbolů zbyvající fáze, které je také různým způsobem využívají. Během sémantické analýzy a generování intermediárního kódu například potřebujeme znát typy proměnných a funkcí, abychom mohli zkонтrolovat jejich správnou použití ve zdrojovém programu a generovat pro ně správné operace. Generátor kódů typicky ukládá a používá podrobné informace o paměti přidělené jednotlivým objektům v programu.

1.2.8 Diagnostika a protokol o průběhu překladu

Velkou část chyb zpracovávají fáze syntaktické a sémantické analýzy. Lexikální fáze odhaluje chyby v případě, že znaky na vstupu netvoří žádny symbol jazyka. Chyby, když posloupnost symbolů poruší strukturní pravidla (syntax) jazyka, se detekují během syntaktické analýzy. Během sémantické analýzy se překladač pokouší nalézt konstrukce, které mají sice syntaktickou strukturu odpovídající bezkontextové gramatice jazyka, avšak poruší kontextová omezení (např. nedeklarovaný proměnný) nebo sémantická pravidla jazyka, např. pokud se pokoušíme seřídit v Pascalu dva identifikátory, z nichž jeden je jinému pole a druhý jinému proceduře. Zpracováni chyb v jednotlivých fázích se budeme zabývat podrobněji výše v příslušné kapitole.

Při výskytu chyb ve zdrojovém textu (případně chyb způsobených využitím okolností, jako např. netipický zápis do pracovního souboru v důsledku zaplnění disku) musí překladač nějakým způsobem reagovat. Možné reakce překladače můžeme obecně shrmout do následujícího sečtu:

I. Nepřijatelné reakce

(a) Nesprávné reakce (bez ohlášení chyb)

- Překladač *zhavaruje* nebo *cyclí*.
- Překladač *polaže*, ale generuje nesprávný cílový program.

(b) Správné reakce (ale nepoužitelné)

- Překladač nahlásí první chybu a *zastaví se*.

II. Přijatelné reakce

(a) Možné reakce

- Překladač nahlásí chybu a *zotaví se*, pokračuje v hledání dalších možných chyb.
- Překladač nahlásí a *odstraní chybu*, pokračuje v generování správného cílového kódu.

(b) Nemožné reakce (se současnými metodami)

- Překladač nahlásí a *opraví chybu*, pokračuje v generování programu odpovídajícího přesně záměru programátora.

Nejproblematicčejší je případ, kdy překladač na chybu nezareaguje a vytvoří cílový kód. Taková chyba se může projevit až po delší době a míté způsobit i vážnou ztrátu dat. Přeložený program může mít neocíkávané chování, které není vysvětlitelné na základě jeho zdrojového kódu. Ukončení překladu po první nalezené chybě značně prodlužuje proces ladění programu a nutnosti neustálé opakování překladače. Tento typ reakce je snad ještě možný v integrovaných vývojových prostředích, kdy se oprava a nové spuštění programu provede velmi jednoduše, ale obecně lze říci, že minimální přijatelnou reakcí překladače na chybu je zotavení. Algoritmy, které umožňují odstraňení chyb (modifikaci zdrojového textu nebo vnitřního tvaru programu) jsou časově náročné a tedy nevhodné pro interaktivní prostředí. Navíc umožňují spuštění nesprávně modifikovaného programu s možnými důsledky jako při neohlášení chyb.

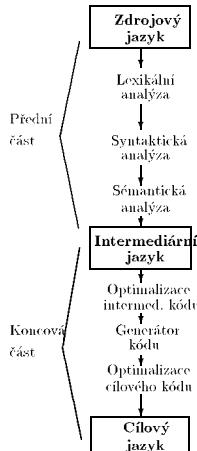
1.3 Organizace překladu

1.3.1 Fáze překladu

Obecné schéma překladače z hlediska jeho členění na fáze je uvedeno na obr. 1.6. Toto členění odpovídá logické struktuře překladače, která však nemusí přímo odpovídat skutečné implementaci.

Jednotlivé fáze se často rozdělují na *přední část* (front end) a *koncovou část* (back end). Přední část se skládá z též fází nebo jejich částí, které závisí převážně na zdrojovém jazyku a jsou dosti nezávislé na cílovém počítači. Obykle zahrnuje lexicální a syntaktickou analýzu, vytváření tabulkových symbolů, sémantickou analýzu a generování intermediárního kódu. V přední části překladače lze provést rovněž jistou část optimalizace kódů. Obsahuje také obsluhu chyb, které vznikají během analýzy.

Koncová část zahrnuje ty části překladače, které již závisí na cílovém počítači, a obecně nezávisí na zdrojovém jazyku, ale na intermediárním kódu. V koncové části překladače nalezneme prvky fází optimalizace kódů a generování kódů společně s nutnými operacemi pro obsluhu chyb a operace s tabulkovými symboly. Dělení na přední a koncovou část obvykle koresponduje s dělením na analytickou a syntetickou část překladu, i když přední část také provádí syntézu intermediárního kódů a koncová část zase tento kód analyzuje.



Obrázek 1.6: Fáze překladače

Při přenosu překladače na jiný cílový počítač se při dobrém provedení návrhu pouze převezejí přední části, ke které se připojí nově vytvořená koncová část. Je-li koncová část vhodně navržena, nemusí dokonce být nutné ji přefís ménit. V rozsáhlějších návrhových systémech s více jazyky se někdy také snažíme překládat několik různých programovacích jazyků do téhož intermediárního jazyka a použít pro různé přední části jedinou koncovou část. Vzhledem k tomu, že ale mezi koncepcemi různých jazyků existují mnohé rozdíly, má tento postup jen omezené možnosti. Uvedený postup zvolila např. firma JPI ve své řadě překladačů TopSpeed (C, C++, Pascal, Modula-2).

1.3.2 Průchody

Několik fází překladače se obvykle implementuje do jediného *průchodu* (pass) skládajícího se ze čtení vstupního souboru a zápisu výstupního souboru. V praxi existuje mnoho variací ve způsobu rozdělení fází překladače do průchodu, které závisí především na následujících okolnostech:

- Vlastnosti zdrojového a cílového jazyka.
- Velikost dostupné paměti pro překlad.
- Rychlosť a velikosť překladače.
- Rychlosť a velikosť cílového programu.
- Požadované informace a prostředky pro ladění.
- Požadované techniky detekce chyb a zotavení.
- Rozsah projektu – velikost programátorského týmu, časové možnosti.

Překladače určené především pro výkonný jazyk ovšem mají využívají jednopříchoďové. Neprovádějí mnoho optimalizací, neboť se předpokládá, že častěji spouštění překladače než samotného přeloženého programu. Větší drážez se u nich klade na zpracování chyb a možnosti ladění. Naopak v překladačích používaných pro vytváření uživatelských aplikací je důležitá dílčí optimalizace, která se obvykle provádí ve vše přichodeč. Některé jazyky dokonce nemají překládat v jednom příchoďu z principiálně dřívodí, neboť například umožňují volat procedury dříve, než jsou známy typy jejich parametrů.

Cinnost fází, které vytvářejí jeden příchoď, se často nazývají překrývají. Například lexicální, syntaktická a sémantická analýza mohou vytvářet jeden příchoď. Posloupnost symbolů po lexicální analýze pak může překladače přivést do intermediárního kódu. Syntaktický analyzátor může mít při podrobnějším pohledu brát jako řídicí prvek. Pokouší se odkrýt gramatickou strukturu symbolů, které vidí: symboly získáva tehdy, když je potřebuje, voláním lexikálního analyzátoru. Po rozpozání gramatické struktury syntaktický analyzátor volá generátor intermediárního kódů, aby provedl sémantickou analýzu a vygeneroval část kódů. Následně na návrh překladače bude směřovat právě k tomuto způsobu organizace.

1.4 Příbuzné programy

K překladači mohou být navíc nutné pro vytvoření proveditelného programu i některé další pomocné programy (viz obr. 1.7). Typický proces zpracování zdrojového programu v sobě

- Údržba knihoven podprogramů.
- Specializované editory.

Při návrhu překladače je třeba mít použití těchto prostředků na paměti tak, aby jich mohl uživatel co nejvíce využívat. Překladač například musí zajistit generování dostatečných informací pro symbolické ladění programu (jména a umístění proměnných a procedur, odkazy na začátky zdrojových řádků apod.) nebo musí do generovaného programu vkládat volání speciálních služeb pro výhodnocování statistik o činnosti programu.

1.5 Automatizace výstavby překladačů

V rámci teorie a praktických aplikací byla využita řada programových nástrojů, které usnadňují implementaci překladače. Jde o spektrem zahrnující jednoduché generátory (konstruktory) lexicálních a syntaktických analyzátorů, ale i komplexní systémy nazývané generátory překladačů (compiler-generators), komplidátory komplidátorů (compiler-compilers) nebo systémové pro posuvné překladače (translating systems). Tyto systémy na základě specifikace zdrojového jazyka a cílového počítače generují překladače pro daný jazyk. Vstupní specifikace může zahrnovat

- popis lexicální a syntaktické struktury zdrojového jazyka,
- popis, co se má generovat pro každou konstrukci zdrojového jazyka,
- popis pořítače, pro který má být generován kód.

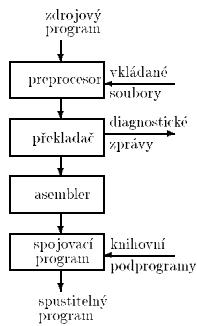
V mnoha případech jsou tyto specifikace v podstatě souborem programů, které generátor komplidátoru vhodně „spojí.“ Některé generátory však umožňují, aby části specifikací měly neprocedurální charakter, t.j. aby například namísto syntaktického analyzátoru mohl tvůrce zadat pouze bezkontextovou gramatiku a generátor sám převede tu gramatiku na program realizující syntaktickou analýzu zdrojového jazyka. Všechny tyto systémy však mají určitá omezení. Problem spočívá v kompromisu mezi množstvím práce, které dělá generátor komplidátoru automaticky, a pružnosti celého systému. Ilustrujeme tento problém na příkladě lexicálního analyzátoru.

Většina systémů pro psaní překladačů dodává ve skutečnosti tentýž podprogram lexicální analýzy pro generovány komplidátor. Běží se pouze v seznamu klíčových slov specifikovaných uživatelem. Pro většinu případů je toto řešení vycouvací, problém však nastane v případě nestandardní lexicální jednotky, např. identifikatoru, který může kromě číslic a písmen obsahovat i jiné znaky. I když existuje obecnější přístup k automatické konstrukci tohoto analyzátoru (reprezentovaný například generátorem `lex`, kterému se bude věnovat podrobněji v článku 2.6), větší pružnost systému vyžaduje podrobnější specifikaci a tudíž i více práce.

K základnímu možnostem existujících generátorů překladačů patří:

- generátor lexicálního analyzátoru,
- generátor syntaktického analyzátoru a
- prostředky pro generování kódů.

může zahrnovat spuštění preprocessoru, který zpracuje makrodefinice, příkazy pro podmíněný překlad nebo příkazy pro vložení textu z jiného souboru do zdrojového programu. Po překladu vznikne cílový kód, který může mít buď tvar přemístitelného binárního modulu, nebo v některých jednodušších překladačích může být výstupem program, který je třeba dále zpracovat assemblerem. Přeložené moduly musí dalek zpracovat spojovací program, který k nim připojí knihovny podprogramy a obvykle i část kódů, která zajišťuje různé pomocné činnosti v době běhu programu (tzv. run-time systém). Výsledkem činnosti spojovacího programu je již spustitelný program.



Obrázek 1.7: Postup při vytváření spustitelného programu

Některé rozsáhlější vývojové systémy obsahují kromě uvedených základních prostředků ještě různé podpůrné programy, zařízení například tyto činnosti:

- Ladění programu na symbolické nebo strojové úrovni.
- Zkontrolení uschovaného obsahu paměti po havárii programu.
- Zpětný překlad cílového programu do zdrojového tvaru.
- Formátování programu pro tisk.
- Tisk seznamu klížových referencí.
- Generování statistik o činnosti programu (profilování) – např. počet volání každé procedury, využití operační paměti, časů procesoru apod.
- Archivace vývojových verzí programu.
- Údržba aktuální verze programu – automatické spouštění překladu změněných programových modulů a budování spustitelného programu (programy typu `make`).

Principy činnosti a výstavy obou generátorů analyzátorů jsou založeny na teorii formálních jazyků a gramatik. Podstatnou výhodou použití téhoto generátoru je zvýšení spolehlivosti překladače. Mechanicky generované části překladače jsou daleko méně zdrojem chyb než části programované ručně.

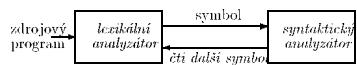
Jako prostředků usnadňujících generování kódu se v téhoto systémach obvykle používá vysoko programovacího jazyka. Slouží ke specifikaci generování jak intermedijního kódu, tak i symbolických instrukcí nebo strojového jazyka. Ve tvaru např. sémantických podprogramů jsou pak tyto specifikace volány automaticky generovaným syntaktickým analyzátorem na vhodných místech. Mnoho systémů pro psaní překladačů používá také mechanismus pro zpracování rozhodovacích tabulek, které vybírají generovaný člověký kód. Tyto tabulky jsou spolu s jejich interpretem generovány na základě popisu vlastností cílového jazyka a tvoří součást výsledného komplítátoru.

Kapitola 2

Lexikální analýza

2.1 Činnost lexikálního analyzátoru

Lexikální analyzátor je první fází překladače. Jeho hlavním úkolem je čist znaky ze vstupu a na svůj výstup dávat symboly, které dále používá syntaktický analyzátor. Tato interakce, schematicky shrnutá na obr. 2.1, se běžně implementuje tak, že lexikální analyzátor vytvoříme jako podprogram nebo koprogram syntaktického analyzátoru. Po přijetí příkazu "dej další symbol" od syntaktického analyzátoru čte lexikální analyzátor vstupní znaky až do té doby, než může identifikovat další symbol.



Obrázek 2.1: Interakce lexikálního a syntaktického analyzátoru

Vzhledem k tomu, že lexikální analyzátor je tou částí překladače, která čte zdrojový text, může na uživatelském rozhraní provádět i další úkoly. Jedním takovým úkolem je odstraňování poznámek a odsavačů (mezer, tabulerek a konců řádků) ze zdrojového programu. Dalším úkolem je udržování konzistence chybových hlášení překladače a zdrojového textu. Lexikální analyzátor může například sledovat počet načtených znaků koncem řádku a umožnit ke každému chybovému hlášení připojení říši příslušného řádku s chybou. V některých překladačích je lexikální analyzátor pověřen prováděním opisu zdrojového programu s vyznačenými chybovými hlášeniami. Pokud zdrojový jazyk obsahuje některé funkce makroprocesoru, potom tyto funkce mohou být implementovány během lexikální analýzy.

Pro rozdělení analytické fáze překladu na lexikální analýzu a syntaktickou analýzu existuje několik důvodů.

1. Zřejmě nejpodstatnějším důvodem je jednodušší návrh překladače. Oddělení lexikální a syntaktické analýzy často umožňuje jednu nebo obě fáze zjednodušit. Například syntaktický analyzátor zahrnuje i konverzi po poznamkách a mezery je podstatně složitější než analyzátor, který předpokládá, že poznamky a mezery už byly odstraněny lexikálním analyzátem.

SYMBOL	PŘÍKLADY LEXÉMU	NEFORMÁLNÍ POPIS VZORU
const	const	const
if	if	if
relation	<, <=, =, >, >=	< nebo <= nebo = nebo > nebo >= nebo >
id	pi, count, D2	písmeno následované písmeny a číslicemi
num	3.1416, 0, 6.02E23	libovolná číselná konstanta
literal	"core dumped"	libovolné znaky v uvozovkách kromě uvozovek

Obrázek 2.2: Příklady symbolů

2. Zlepší se efektivita překladače. Oddělený lexikální analyzátor umožňuje použít speciální a potenciálně mnohem efektivnější algoritmy. Čtením zdrojového programu a jeho rozdělováním do symbolů se ztrácí mnoho času. Specializované techniky práce s využíváním paměti při čtení vstupních znaků mohou podstatně zvýšit výkonnost překladače.

3. Zvýší se průnositelnost překladače. Zvláštnosti vstupní abecedy a jiné anomálie konkrétních vstupních zařízení se mohou omezovat pouze na lexikální analyzátor. Například jazyk C umožňuje použití speciálních tříznačkových kombinací pro znaky, které nevybírají dostupné na některých klávesnicích (‘?’ pro ‘?’, ‘?’< pro ‘!`’ apod.).

Pro podporu automatizace vytváření oddělených lexikálních a syntaktických analyzátorů byly vytvorené specializované prostředky. S programem Lex se seznámité v této kapitole, program Yacc bude věnována část kapitoly následující.

2.2 Základní pojmy

2.2.1 Symboly, vzory, lexém

Když hovoříme o lexikální analýze, používáme výrazů *symbol*, *vzor* a *lexém* se specifickým významem. Příklady jejich použití ukazuje obrázek 2.2. Obecně existuje množina vstupních řetězců, pro které se na výstup dává typ symbolu. Tato množina je popsána pravidlem zvaným *vzor symbolu*. Lexém je posloupnost znaků zdrojového programu, která odpovídá vzoru pro konkrétní symbol. Například v příkladu jazyka Pascal

const pi = 3.1416;

je podřízenec *pi* lexémem pro symbol *identifikátor*.

Symboly považujeme za terminální symboly gramatiky zdrojového jazyka. Lexém odpovídající vzoru pro symboly představují řetězce znaků zdrojového programu, které můžeme považovat za jedinou lexikální jednotku.

V mnoha programovacích jazycích se za symboly považují následující konstrukce: klíčová slova, operátory, identifikátory, konstanty, řetězce (ve smyslu literálů) a interpunkční symboly (závorky, čárky a středníky). Ve výše uvedeném příkladu se při výskytu posloupnosti znaků *pi* ve zdrojovém programu vrátí syntaktický analyzátoru symbol reprezentující identifikátor. Vracený symbol se často implementuje jako vrácení celých čísel, která jsou symbolům přidělena (případně hodnoty výčtového typu), pokud to implementační jazyk umožňuje).

Vzor je pravidlo popisující množinu lexém, které mohou představovat ve zdrojovém programu konkrétní symbol. Vzor pro symbol *const* na obr. 2.2 je právě jediný řetězec *const*.

jímž je klíčové slovo označeno. Vzor pro symbol **relation** je možností relačních operátorů jazyka Pascal. Pro přesný popis mnohem složitějších symbolů jako je **id** (pro identifikátor) a **num** (pro číslo) bude muset používat regulařní výrazy.

Některé jazykové konvence mají dopad na složitost lexikální analýzy. Jazyky jako Fortran vyžadují, aby určité konstrukce byly na pevné pozici ve vstupním ráduku. Umístění lexému může být tedy důležité při určování správnosti zdrojového programu. Trend tvorbě moderních programovacích jazyků směřuje ke vstupu ve volném formátu, který umožňuje umístění konstrukcí kdekoliv na vstupním ráduku, takže tento aspekt lexikální analýzy se stává stále méně důležitým.

Zpracování mezer se značně liší od jazyka C. V některých jazyčcích jako je Fortran, Basic nebo Algol 68 jsou mezery v příkazech programu významné, až na mezery uvnitř literálůvých řetězců. Mohou být doplněny pro zvýšení čitelnosti programu. Konvence týkající se mezer mohou značně komplikovat úkol identifikace symbolů.

Populárním příkladem, který dokumentuje potenciální obtíže při rozpoznávání symbolů, je příkaz **DO** ve Fortranu. V příkazu

DO I = 1,25

až do okamžiku, než uvidíme desetičíselnou číselku, nemůžeme poznat, že **DO** není klíčové slovo, ale část identifikátoru **DO51**. Na druhé straně v příkazu

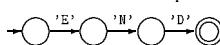
DO I = 1,25

máme sedm symbolů, které odpovídají klíčovému slovu **DO**, návěsti příkazu **5**, identifikátoru **I**, operátoru **=**, konstantě **1**, čárce a konstantě **25**. Zde si nemůžeme být až do výskytu čárky jistí, zda je **DO** klíčové slovo.

V mnoha jazyčcích jsou některé řetězce rezervovány, tj. jejich význam je předdefinován a nemůže být užívatelem změněn. Nejsou-li klíčová slova rezervována, musí klíčové slovo od uživatele definovanou identifikátorem rozlišit lexikální analyzátor. V jazyce PL/I nejsou klíčová slova rezervovaná; pravidla pro rozlišení klíčových slov od identifikátorů jsou tedy začleněny komplikovaně, jak ukazuje následující příkaz PL/I:

IF THEN THEN = ELSE; ELSE ELSE = THEN;

Pro analýzu klíčových slov můžeme použít v podstatě dvou přístupů. Můžeme je definovat jako samostatné symboly se svou vlastní strukturou, např. klíčové slovo **END** jako řetězec



nebo můžeme pro klíčová slova použít stejněho vzoru jako pro identifikátory a teprve po rozpoznání identifikátoru otestovat na základě tabulky klíčových slov, zda se jedná skutečně o identifikátor nebo o klíčové slovo a podle toho vrátit příslušný kód symbolu. Druhý přístup je výhodnější z hlediska složitosti automatu a pro většinu moderních jazyků zřejmě nemá smysl používat přístup první.

2.2.2 Atributy symbolů

Odpovídá-li vzoru více jak jeden lexém, musí lexikální analyzátor následujícím fázím překládat poskytnout informaci o tom, který konkrétní lexém byl rozpoznán. Například řetězci **0** a **1** odpovídají vzor pro **num**, avšak pro generátor kódu je podstatně znát, o který řetězec se skutečně jedná.

- v případě, že jazyk umožňuje vkládání částí zdrojového textu z jiných souborů, podmíněný překlad nebo práci s makrodefinicemi (např. jazyk C), je třeba tuto činnost, která může být začleněna složitá, provést bud jako samostatný přechod před lexikální analýzou, nebo se musí provést zařazení s činností lexikálního analyzátoru, a to právě během čtení znaku.
- během analýzy často potřebujeme provést návrat ve vstupním souboru; v případě, že nám implementační jazyk návrat neumožňuje nebo jsou-li možnosti navracení omezeny (např. funkce **ungetc()** jazyka C umožňuje vrátit pouze jeden znak), je třeba tuto akci provádět ve vlastní režii.

Ctení zdrojového textu je vhodné implementovat jako samostatný programový modul komunikující s lexikálním analyzátem přes určité rozhraní. Oddělení činností spojených se čtením zdrojového textu může dosáhnout větší přenositelnosti překladače, neboť většina systémově závislých operací se soustředí právě do vstupního modulu.

Příklad 2.2. Následující program je vělní jednoduchým příkladem implementace vstupu do modulu. Definuje funkci **getch()**, která poskytuje následující znak ve vstupním souboru, a funkci **ungetch()** pro návrat o znak zpět. Dále jsou k dispozici pronájemné obsahující číslo současného zdrojového ráduku, text tohoto ráduku a ukazatel na znak, který bude zpracován jako následující. Tento informace lze dále využít pro hlášení chyb.

```

int line = 0; /* číslo zdrojového ráduku */
char source[256]; /* zdrojový rádek */
char *gchptr = source; /* ukazatel současné pozice */

int getch( void ) /* čtení jednoho znaku */
{
    char ch;
    if( *gchptr == '\0' ) { /* jsme za koncem ráduku */
        gchptr = gets( source );
        if( gchptr == NULL ) /* konec zdrojového souboru */
            return( EOF );
        line++;
    }
    return( *gchptr++ ? ch : '\n' );
}

void ungetch( void ) /* návrat o znak zpět */
{
    if( gchptr != source ) /* nejsme na začátku ráduku */
        gchptr--;
}

```

V některých programovacích jazyčcích je často třeba, aby měl lexikální analyzátor možnost si prohlédnout několik znaků za lexémem ještě před tím, než může spolehlivě ohlášit, o který symbol se jedná. Podprogramy **getch** a **ungetch** z příkladu 2.2 například umožňovaly přečíst znaky nejvýše do konce ráduku a pak je zase vrátit zpět. Vzhledem k tomu, že neustálym

Lexikální analyzátor skromňuje informace o symbolech v atributech symbolů. Symboly mají vliv na rozhodování syntaktického analyzátoru; atributy ovlivňují překlad symbolů. V praxi má symbol často pouze jeden atribut — ukazatel na položku tabulky symbolů, která obsahuje informace o symbolu. Pro účely diagnostiky nás může zajímat jak lexem identifikátoru, tak i číslo ráduku, na kterém se poprvé objevil. Obě tyto informace mohou být rovněž uloženy v položce tabulky symbolů pro identifikátor.

Příklad 2.1. Symboly a k nim příslušné hodnoty atributů pro příkaz jazyka Fortran ačné důležitým

jsou uvedeny dále jako posloupnost dvojic:

```

<id, ukazatel na položku tabulky symbolů pro E>
<assign_op,>
<id, ukazatel na položku tabulky symbolů pro M>
<mult_op,>
<id, ukazatel na položku tabulky symbolů pro C>
<exp_op,>
<num, celočíselná hodnota 2>

```

Povinněste si, že některé dvojice nemusí obsahovat hodnotu atributu: první složka je dostatečná pro identifikaci lexému. V tomto malém příkladu dost symbol **num** atribut s celočíselnou hodnotou. Překladač také může uložit řetězec znaků, který tvorí číslo, do tabulky symbolů a jako atribut symbolu **num** ponechat ukazatel na položku tabulky.

2.3 Vstup zdrojového textu

Na začátku této kapitoly jsme uvedli, že jedním z úkolů lexikálního analyzátoru je čtení znaků ze vstupního (zdrojového) souboru. Čtení znaků můžeme realizovat v nejednodušším případě např. voláním standardní funkce **getchar()** jazyka C nebo procedury **read()** jazyka Pascal. Obecně se však jedná o podstatně složitější problém, a to z následujících důvodů:

- čtení po jednotlivých znacích může být značně neefektivní ve srovnání se čtením po ráduch nebo po velkých blocích textu, např. může představovat volání funkce jádra operačního systému se všemi kontrolami, které k tomu přísluší. Analyzátor tedy musí zajistit nějakou správnou vyrovnávací paměť, ze které se budou dále jednotlivé znaky odobírat. Ani prostředky vyrovnávacího vstupu dat, které poskytují standardní knihovny jazyka C nejsou z hlediska efektivity dostatečné v mnoha implementacích se čtená data kopírují až třikrát před tím, než je obdrží uživatelský program (z disku do vyrovnávací paměti operačního systému, dále do vyrovnávací paměti, která je částí struktury FILE, a nakonec do řetězce, který obsahuje lexém).
- při čtení zdrojového textu se může provádět jeho opis do výstupní řádkové sestavy, přičemž tento opis se může dále doplňovat o informace získané při překladu (úrovni zanoření závorkových struktur, adresy instrukcí apod.). I tehdy, když se opis celého zdrojového textu neprovádí, musí lexikální analyzátor udržovat pro účely hlášení coby alespoň informaci o čísle zdrojového ráduku, případně text aktuálního ráduku a současnou pozici).

přesouvání znaků může docházet ke značným časovým ztrátám, používají se specializované techniky pracující s vyrovnávacími paměti (v příkladu 2.2 jsme měli vyrovnávací paměť na jeden zdrojový rádek). Tyto techniky jsou obvykle značně závislé na vlastnostech konkrétního operačního systému, proto pouze naznačme jednu z možností.

Při vstupu zdrojového textu můžeme využít vyrovnávací paměti rozdělené na dvě části o velikosti **N** znaků (viz obr. 2.3). Typická hodnota **N** je daná velikostí diskového bloku, např. 1024 nebo 4096 slabik. Do každé poloviny načteme **N** znaků textu, a to vždy jedním voláním operace čtení pro celý blok, ne pro jednotlivé znaky. Zbývá-li na vstupu méně než **N** znaků, uloží se do vyrovnávací paměti za poslední načtený znak speciální znak **eof**.



Obrázek 2.3: Rozdělená vstupní vyrovnávací paměť

Při přístupu do vyrovnávací paměti budeme udržovat dva ukazatele. Na počátku budou oba ukazatele ukazovat na tentýž znak; během analýzy bude jeden ukazatel označovat pozici prvního znaku lexému a druhý se bude přesouvat tak dlouho, až se naleze konec lexému. Řetězec znaků mezi oběma ukazateli potom predstavuje současný lexém; po jeho zpracování se oba ukazatele přesunou za konec lexému a činnost se opakuje.

Jestliže se ukazatele konec lexému mísí přesunout do právě poloviny vyrovnávací paměti, například se pravá polovina dalšími **N** znaky. Ma-li se ukazatel přesunout za právý konec vyrovnávací paměti, například se levá polovina dalšími **N** znaky a ukazatel se přesune cyklicky na začátek vyrovnávací paměti.

Toto schéma umožňuje jen omezenou délku pohledu vpřed ve vstupním textu — omezení je dano velikostí vyrovnávací paměti. Pokud však délka prohlédaného řetězce nepřekročí velikost vyrovnávací paměti, je vždy zajistěno, že se můžeme vrátit na začátek lexému. To je výhodou například tehdy, jestliže pro rozpoznání určité konstrukce potřebujeme znát širší kontext, v němž je tato konstrukce uvedena. V praxi se mohou používat některé další modifikace, které dále zvýšují efektivitu čtení zdrojového textu.

2.4 Specifikace a rozpoznávání symbolů

Při implementaci lexikálního analyzátoru vždy vycházíme z více či méně formálního popisu struktury jednotlivých lexikálních jednotek. Tento popis může být v jednom z následujících tvarů:

1. slovní popis,
2. regulární nebo lineární gramatika,
3. graf přechodů konečného automatu,
4. regulární výraz, resp. regulární definice.

Všechny tyto možnosti se v praxi vyskytují až na případně možnou nejednoznačnost slovního popisu jsem rovnocenné. V dalších dvoch odstavcích se budeme zabývat posledními dvěma variantami. Regulární nebo obecně lineární gramatiky lze snadno převést na konečný automat, podobně jako slovní popis struktury jazyka.

2.4.1 Regulární výrazy

Regulární výrazy jsou důležitou notaci pro specifikaci vzorů symbolů. Každý vzor odpovídá množině řetězců, takže regulární výraz slouží vlastně jako pojmenování množiny řetězců. Článek 2.6 tuto notaci rozšiřuje na jazyk pro specifikaci lexikálních analyzátorů.

Regulární množiny byly formálně definovány v [12]. Pro naše účely si definici rozšíříme o některé velmi často se vyskytující konstrukce. Regulární výrazy nad abecedou Σ a jazyky jimi označovanou budeme definovat následujícím způsobem:

1. je regulární výraz označující $\{\epsilon\}$, tj. množinu obsahující prázdny řetězec.
2. Je-li a symbol v Σ , potom je regulární výraz označující $\{a\}$, tj. množinu obsahující řetězec a . Ačkoliv pro tři různé významy používáme stejný zápis, je ve skutečnosti regulární výraz a odlišný od řetězce a nebo od symbolu a . Z kontextu bude vždy zřejmě, zda hovoříme o regulárním výrazu, řetězci nebo symbolu.
3. Jsou-li a, b, c, \dots symboly v Σ , potom $[abc\dots]$ je regulární výraz označující jazyk $\{a, b, c, \dots\}$. Tvoří-li symboly posloupnost, lze je zapsat jako interval, např. $[a-z]$.
4. Předpokládejme, že r a s jsou regulární výrazy, které označují jazyky $L(r)$ a $L(s)$. Potom
 - a) $(r)s$ je regulární výraz označující $L(r) \cup L(s)$,
 - b) $(r)s$ je regulární výraz označující $L(r)L(s)$,
 - c) $(r)*$ je regulární výraz označující $(L(r))^*$,
 - d) $(r)^+$ je regulární výraz označující $(L(r))^+$,
 - e) $(r)^?$ je regulární výraz označující $L(r) \cup \{\epsilon\}$.
 - f) (r) je regulární výraz označující $L(r)$. (Toto pravidlo říká, že kolem regulárního výrazu můžeme podle potřeby napsat dvojici závorek.)

Příklad 2.3. Jazyk tvořený řetězci null a jedniček s lichou paritou (tj. s lichým počtem jedniček) můžeme popsat regulárním výrazem

$$0*1(0*10*1)*0*$$

Regulární výrazy mohou popisovat pouze relativně jednoduché konstrukce. Některé jazyky nelze regulárními výrazy popsat, například v následujících situacích:

- Regulární výrazy nelze použít k popisu vyvážených nebo vnořených konstrukcí. Například množina všech řetězců s vyváženými závorkami se nedá regulárním výrazem popsat, stejně jako zařazení poznámky v jazyce Modula-2. Na druhé straně lze takovou množinu popsat bezkontextovou gramatikou.

$$\begin{aligned} digits &\rightarrow [0-9]^+ \\ optional_fraction &\rightarrow (, digits)? \\ optional_exponent &\rightarrow (E (+|-)? digits)? \\ num &\rightarrow digits optional_fraction optional_exponent \end{aligned}$$

Tato definice říká, že *optional_fraction* je buď desetinná tečka následovaná jedinou nebo více číslicemi, nebo čísla (je to prázdny řetězec). *Optional_exponent*, pokud nedchybí, je E následované volitelným + nebo - a jedinou nebo více číslicemi. Povídáme si, že ze tečkou musí být alespoň jedna číslice, takže *num* neodpovídá řetězci 1., ale odpovídá řetězci 1.0. ■

Regulární výrazy a regulární definice tvoří základní prostředek pro specifikaci lexikální struktury jazyka v systémech pro podporu návrhu překladačů, konkrétně v tzv. konstruktorech lexikálních analyzátorů. Na základě regulárních definic tyto konstruktory obvykle vytvoří odpovídající deterministický konečný automat reprezentovaný buď tabulkou přechodů a jeho interpretem nebo přímo programem realizujícím lexikální analýzu.

2.4.3 Konečné automaty

Dalším prostředkem, který lze využít jak pro specifikaci, tak i pro implementaci lexikálních analyzátorů, jsou konečné automaty. Pro naše potřeby výjdeme z definice rozšířeného konečného automatu (viz [12]) jako pětice

$$(Q, \Sigma, f, q_0, F),$$

kde Q je konečná množina vnitřních stavů, Σ (neprázdná) vstupní abeceda, f přechodová funkce $f : Q \times (\Sigma \cup \{\epsilon\}) \rightarrow 2^Q$, $q_0 \in Q$ počáteční stav a $F \subset Q$ množina konečných stavů.

Pro všechny symboly jazyka můžeme sestrojit samostatný (obecně nedeterministický) automat: všechny částečné automaty pak můžeme spojit do jediného automatu tak, že vytvoříme nový počáteční stav a pomocí ϵ -přechodů jej propojíme s počátečními stavami jednotlivých výchozích automátů. Takto získaný automat pak převedeme na deterministický, např. algoritmem uvedeným v [13]. Dostaneme výsledný deterministický konečný automat, který pak můžeme implementovat některou z dale uvedených metod.

Příklad 2.6. Jazyk obsahující identifikátory, celá čísla bez znaménka, operátory '+' a '-', poznámky a mezery můžeme popsat částečnými automaty podle obr. 2.4. Výsledný automat, který získáme jejich spojením, je uveden na obr. 2.5.

2.5 Implementace lexikálního analyzátoru

Výběr konkrétní metody implementace je závislý spíše na tom, zda máme k dispozici a chceme použít nějaký konstraktor (v tom případě bude zřejmě nejvhodnější popis regulárními výrazy) nebo zda budeme analyzátor psát přímo v některém programovacím jazyku; dalším kritériem (někdy i rozhodujícím) mohou být i požadavky na efektivitu lexikálního analyzátoru, neboť lexikální analyzátor zpracovává zdrojový program znak po znaku a často tedy přímo určuje rychlosť celého překladu. Pro vlastní implementaci můžeme použít jednu z následujících metod:

- Regulární výrazy nelze popsat opakováním řetězce. Množina

$$\{ww|w \text{ je řetězec symbolů } a \text{ a } b\}$$

se nedá popsat regulárním výrazem ani bezkontextovou gramatikou.

- Regulární výrazy lze použít pouze k popisu pevného počtu opakování nebo nespecifikovaného počtu opakování dané konstrukce. Nelze povorout dvě libovolná čísla, zda jsou stejná. Nemůžeme tedy pomocí regulárních výrazů popsat hollerithovský řetězec tvaru $nHn1a2\dots an$ z prvních verzí jazyka Fortran, neboť počet znaků následujících za H musí odpovídat desítkovému číslu před H.

Vzhledem k tomu, že většina lexikálních konstrukcí běžných programovacích jazyků patří do třídy regulárních jazyků, je použití regulárních výrazů typické právě pro tuhle oblast, neboť jejich analýza je podstatně jednodušší než analýza jazyků bezkontextových nebo kontextových.

2.4.2 Regulární definice

Pro účely zápisu bychom chtěli regulární výrazy pojmenovat a jejich jména použít v jiných regulárních významech, jako by to byly symboly. Je-li Σ abeceda základních symbolů, potom regulární definice je posloupnost definicí ve tvaru

$$\begin{aligned} d_1 &\longrightarrow r_1 \\ d_2 &\longrightarrow r_2 \\ &\dots \\ d_n &\longrightarrow r_n \end{aligned}$$

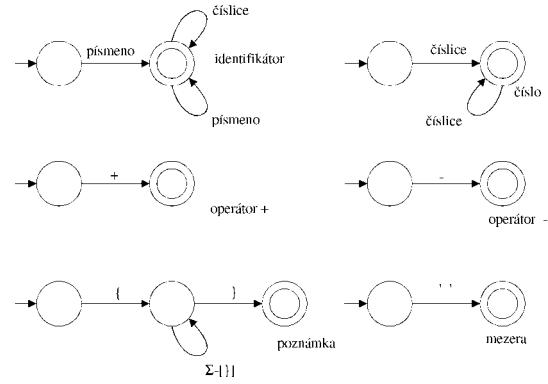
kde d_i jsou navzájem odlišná jména a r_i jsou regulární výrazy nad abecedou $\Sigma \cup \{d_1, d_2, \dots, d_{i-1}\}$, t.j. z množiny základních symbolů a dříve definovaných jmen. Omezení r_i pouze na symboly množiny Σ a dříve definovaná jména můžeme vytvořit regulární výraz nad Σ pro každou r_i opakováním nahrazování jmen regulárních výrazů výrazu, které označují. Je-li r_i použito v d_j pro největší $j \geq i$, potom by mohlo být r_i definováno rekursivně a tento proces nahrazování by se nezastavil.

Pro odlišení jmen od symbolů budeme psát jména v regulárních definicích kurzívou.

Příklad 2.4. Identifikátory jazyka Pascal můžeme popsat následující regulární definicí:

$$\begin{aligned} letter &\longrightarrow [A-Za-z] \\ digit &\longrightarrow [0-9] \\ id &\longrightarrow letter(letter|digit)^* \end{aligned}$$

Příklad 2.5. Čísla bez znaménka v Pascalu jsou řetězce jako 5280, 39.37, 6.336E4 nebo 1.894E-4. Následující regulární definice je přesnou specifikaci této třídy řetězců:



Obrázek 2.4: Grafy částečných konečných automatů

1. přímá implementace s využitím všech prostředků, které poskytuje implementační jazyk.

2. implementace konečného automatu nebo

3. vytvoření analyzátoru konstruktorem.

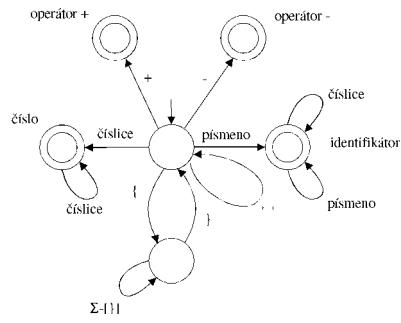
Z hlediska jednoduchosti je nejjednodušší ponížit konstruktora a nejúrovnější přímá implementace, ovšem z hlediska efektivity překladu je pořád obvykle přesnější opačně. Z tohoto důvodu se často pro vývojové verze překladače použije konstruktora, avšak pro definitivní překladat se lexikální analyzátor implementuje přímo.

V následujících odstavcích si převedeme první dvě techniky na příkladu jazyka z obr. 2.5. Tento jazyk obsahuje identifikátory, celočíselné konstanty, operátory + a -, mezery a poznámky tvořené posloupností znaků uzavřených ve složených závorkách.

2.5.1 Přímá implementace

Přímá implementace lexikálního analyzátoru vychází z požadavků na maximální efektivitu jeho činnosti: využívá všechny vhodné prostředky implementačního programovacího jazyka.

Příklad 2.7. Pro jazyk definovaný na obr. 2.5 užijeme jednu z možných implementací lexikálního analyzátoru. Analyzátor bude představován funkcí `yylex` bez parametrů, která



Obrázek 2.5: Specifikace lexikálního analyzátoru pomocí DFA

po každém zavolání vrátí kód následujícího symbolu. V případě identifikátoru ponechá v proměnné `ytext` příslušný lexém a v proměnné `yylen` jeho délku ve znacích, pro číselnou konstantu ponechá v proměnné `yyval` její binární hodnotu. (Použité názvy s výjimkou `yyval` jsou převzaty ze pojmenování zavedeného v konstruktoru `lex`).

```
#include <stdio.h>
#include <ctype.h>
#define IDENT 256
#define NUM 257
char ytext[ 256 ]; /* lexém pro identifikátor */
int yylen; /* délka identifikátoru */
int yyval; /* hodnota čísla */
int yylex(void)
{
    int ch; /* přečtený znak */
START:
    while( (ch = getchar()) == ' ') /* vypuštění mezer */
        if (isalpha(ch)) { /* zpracování identifikátoru */
            yylen = 0;
            do {
                ytext[ yylen++ ] = ch;
            } while (isalnum(ch = getchar()));
            ytext[ yylen ] = '\0';
            ungetc( ch, stdin ); /* vrácení posledního znaku */
            return( IDENT );
        }
}
```

```
}
else if (isdigit(ch)) { /* zpracování čísla */
    yyval = 0;
    do {
        yyval = 10 * yyval + (ch - '0');
    } while (isdigit(ch = getchar()));
    ungetc( ch, stdin ); /* vrácení posledního znaku */
    return( NUM );
}
else if (ch == '{') { /* zpracování poznámky */
    while ((ch = getchar()) != '}' && ch != EOF) {
        if (ch == EOF) {
            yyerror("Neukončená poznámka");
            return( EOF );
        }
    }
    goto START; /* pokračujeme dalším symbolem */
}
else /* ostatní znaky */
    return( ch );
}
```

Kódování symbolů je zvoleno tak, aby jednoznačkové symboly mohly být reprezentovány přímo kódem odpovídajícímu znaku. Složené symboly pak mají přidělený kód počínaje hodnotou 256. Analyzátor předlívá informaci o konci zdvojrovného souboru rovněž jako symbol — jeho kód (EOF) je převzat ze standardního záhlavi `<stdio.h>` jazyka C. Je-li na vstupu zjištěn znak, který nezářiná žádoucí z definovaných symbolů, je analyzátorom jeho kód vrácen a chyba není hlášena — ollási se až při syntaktické analýze (neboť vrácený kód nemůže odpovídat kódů žádoucího z odkáváných symbolů na vstupu). Rovněž bylo možné zjistit, zda se jedná o znak '+' nebo '-' a v případě, že tomu tak není, nahlásit chybu (např. "Neplatný znak"). znak vynedbat a pokračovat v analýze. ■

2.5.2 Implementace lexikálního analyzátoru jako automatu se stavovým řízením

V případě, že je lexikální struktura jazyka popsána konečným automatem, můžeme implementovat přímo činnost tohoto automatu, a to buď pomocí tabulky přechodové funkce automatu nebo přímo přípěsem automatu do programu. Konstruktory lexikálních analyzátorů používají předešlým první variantu, neboť jak formát tabulky, tak i příslušný interpretativní program mohou být standardizovány.

Příklad 2.8. Ukažeme implementaci lexikálního analyzátoru pro jazyk z obr. 2.5 do programu v jazyce C formou automatu.

```
#include <stdio.h>
#include <ctype.h>
#define IDENT 256
#define NUM 257
```

```
char ytext[ 256 ]; /* lexém pro identifikátor */
int yylen; /* délka identifikátoru */
int yyval; /* hodnota čísla */

static int state; /* současný stav automatu */

int next( int newst ) /* přechod do nového stavu */
{
    state = newst;
    return getchar();
}

int yylex( void )
{
    int ch = next(0); /* současný znak na vstupu */
    for ( ; ; )
        switch (state) {
            case 0: /* stav 0 - startovací stav */
                if (ch == ' ')
                    ch = next(0);
                else if (isalpha(ch)) {
                    yylen = 1;
                    ytext[ yylen ] = ch;
                    ch = next(1);
                }
                else if (isdigit(ch)) {
                    yyval = ch - '0';
                    ch = next(2);
                }
                else if (ch == '{')
                    ch = next(3);
                else {
                    return (ch);
                }
            case 1: /* stav 1 - analýza identifikátoru */
                if (isalnum(ch)) {
                    ytext[ yylen++ ] = ch;
                    ch = next(1);
                }
                else {
                    ytext[ yylen ] = '\0';
                    ungetc( ch, stdin );
                    return( IDENT );
                }
            case 2: /* stav 2 - analýza čísla */
                if (isdigit(ch)) {
                    yyval = 10 * yyval + (ch - '0');
                    ch = next(2);
                }
        }
}
```

```

        }
        else {
            ungetc( ch, stdin );
            return( NUM );
        }
    case 3: /* stav 3 - analýza poznámky */
        if (ch == EOF) {
            yyerror("Neukončená poznámka");
            return( EOF );
        }
        else if (ch == '}') {
            ch = next(0);
        }
        else
            ch = next(3);
    }
}
```

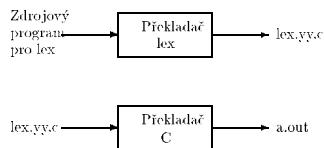
Volání funkce `next()` reprezentuje jednu hranu grafu přechodů: tato funkce nastaví nový stav automatu a přečte další znak ze vstupu. Povídáme si, že uvedená implementace není celá přesná, neboť zde nejsou realizovány koncové stavy reprezentující operátory '+' a '-'; v tomto smyslu se vlastně jedná o částečně optimalizovaný automat. I přesto je tato implementace mnohem méně efektivní než ta, která byla uvedena v předešlém odstavci. Je to způsobeno zejména neustálým rozhodováním o současném stavu a přechodech, které nemění stav — např. ve stavu 0 při mezeře.

2.6 Lex — generátor lexikálních analyzátorů

2.6.1 Činnost programu lex

Pro vytváření lexikálních analyzátorů na základě speciálního zápisu založeného na regulárních výrazech bylo vytvořeno mnoho prostředků. S povrchním regulárních výrazů a automatů pro specifikaci symbolů jsme se již seznámili. Nyní si uvedeme příklad prostředku, který by byl schopen vytvářet lexikální analyzátor pouze na základě specifikace jazyka, konkrétně prostředek zvaný `lex`, který se sice využívá pro specifikaci lexikálních analyzátorů před fázi jazyků. Budeme jej nazývat překladač `lex` a jeho vstupní specifikaci jazyk `lex`. Diskuse kolem tohoto jazyka nám umožní ukázat, jak lze specifikaci vztahů pomocí regulárních výrazů kombinovat s akcemi, tj. např. s vytvářením položek tabulky symbolů. Překladač `lex` byl implementován pod operačním systémem Unix (dále budeme popisovat právě tu verzi), dnes je však dostupný i pod jinými operačními systémy, dokonce i v různých zdrojově kódových variantách.

`lex` se obecně používá způsobem, který je znázorněn na obr. 2.6. Nejprve připravíme specifikaci lexikálního analyzátoru vytvořenou zdrojovým textem (např. v souboru `lex.1`) v jazyku `lex`. Potom soubor `lex.1` zpracujeme programem `lex` a tím vytvoříme program v C pod názvem `lex.yy.c`. Program `lex.yy.c` se skládá z tabulkové reprezentace grafu přechodů vytvořeného na základě regulárních výrazů obsažených v `lex.1` zároveň se standardními podprogramy, které tyto tabulky používají pro rozpoznávání symbolů. Akce spojené s regulárními výrazy v `lex.1` jsou reprezentovány úsekům kódu v C: překladač `lex` je okopíruje přímo do



Obrázek 2.6: Vytvoření lexikálního analyzátoru programem lex

soubor `lex.yy.c`. Konečně se soubor `lex.yy.c` zpracuje překladačem C jazyka C, který vytvoří modul lexikálního analyzátoru a případně jej i sestaví s ostatními moduly do cílového programu překládače.

2.6.2 Struktura zdrojového textu

Program v jazyku lex se skládá ze tří částí, které jsou odděleny dvěma znaky % na začátku samostatného řádku:

```

deklarace
%
pravidla
%
pomocné procedury

```

Oddíl deklarací obsahuje deklarace proměnných, pojmenovaných konstant a regulárních definičí. Deklarace, které se mají kopírovat do výstupního textu, musejí být uvedeny do závorce % a %. Uvedené deklarace budou globální pro všechny funkce obsažené ve vygenerovaném programu. Regulární definice jsou příkazy ke tvaru

jmeno výraz

kde jmeno je označení uvedeného regulárního výrazu, který může být v dalších výrazech použito ke tvaru (jmeno). Poznámějme, že tyto definice jsou implementovány jako makra, takže případné chyby v jejich zápisu se projeví až při rozvoji v překladových pravidlech.

Druhý oddíl obsahuje vlastní definice lexikální struktury jazyka a činnosti analyzátoru formou překladových pravidel. Překladová pravidla pro lex jsou příkazy ke tvaru

```

p1 action1
p2 action2
...
pn actionn

```

kde `pi` jsou regulární výrazy a `actioni`, jsou části programu popisující činnost lexikálního analyzátora po rozpoznání lexému odpovídajícího vzoru `pi` (jedný příkaz jazyka C nebo blok příkazů ve složených závorkách). V jazyku lex se akce zapisují jako příkazy jazyka C, obecně by však zde mohly být libovolný jiný implementační jazyk. Regulární výrazy jsou v pravidle zapsány bezprostředně od začátku řádku a bez mezer, od akce jsou odděleny alespoň jednou mezerou nebo tabulátorem.

Lexikální analyzátor vraci syntaktickému analyzátoru jedinou hodnotu — kód symbolu. Pro předání hodnoty atributu s informacemi o lexému jsou k dispozici další proměnné:

```

int yylineno; /* číslo současného vstupního řádku */
char yytext[]; /* text naposledy přečteného lexému */
int yyleng; /* délka naposledy přečteného lexému */

```

Navíc jsou zprístupněny další proměnné, které umožňují měnit přířazení vstupního a výstupního souboru po lexikální analyzátoru:

```

FILE *yyin; /* vstupní soubor - implicitně stdin */
FILE *yyout; /* výstupní soubor - implicitně stdout */

```

Pro čtení jednoho znaku ze vstupního souboru a zápis jednoho znaku na výstup jsou k dispozici makra `input()` a `output()`, která je možno podle potřeby předefinovat. Výstupní soubor má význam tedy, jestliže používáme lex pro vytvoření tzv. filtru, tj. programu, který čte vstupní soubor, provádí v něm určité transformace a transformovaný text zapisuje na výstup. Analyzátor vytvořený programem lex v případě, že část vstupního textu nelze přiřadit žádné z uvedených regulárních výrazů, tento text opise do výstupního souboru `yyout`. Na to je třeba napomenout při návrhu skutečného lexikálního analyzátoru, kdy musí být pokryty skutečně všechny možné posloupnosti znaků na vstupu regulačními definicemi. Jinak by se např. v případě chybějící zapsaného symbolu mohly na standardním výstupu objevit neocíkavé texty.

Příklad 2.9. Poslední příklad této kapitoly ukazuje zápis lexikálního analyzátoru jazyka z obr. 2.5 prostředky konstruktuora lex.

```

%{
#include <stdlib.h> /* pro funkci atoi() */
#define IDENT 256
#define NUM 257
int yyval; /* atribut symbolu NUM */
%}
/* regulární výrazy */
delim [ \t\n]
ws {delim}+|[([t])*\r\]
letter [A-Za-z]
digit [0-9]
id {letter}({letter}|{digit})*
number {digit}+
%{
/* zádná akce a bez návratu */
{id} return(IDENT);
{number} {yyval = atoi(yytext); return(NUM);}
.
return(yytext[0]);
}

```

Obrázek 2.8: Program v jazyce lex

První výraz v části překladových pravidel udává, že po rozpoznání ws, tj. maximální posloupnosti mezer, tabulátorů, konců řádků a poznámek, se neprovede žádná akce a tedy že se bude

VÝRAZ	POPIŠ	PRÍKLAD
const	const	const
c	libovolný znak c, jež není operátorem	a
\c	libovolný znak c	*
"s"	řetězec s libovolnými znaky	"**"
.	jakýkoliv znak kromě konce řádku	a.*b
\$	koniec řádku	abc\$
[s]	libovolný znak z minožiny s	[abc]
[^s]	libovolný znak, který není v minožině s	[^abc]
r*	0 nebo více r	a*
r+	1 nebo více r	a+
r?	0 nebo jeden r	a?
r{m,n}	m až n vyskytů r	a{1,5}
r ₁ r ₂	r ₁ následovaný r ₂	ab
r ₁ r ₂	r ₁ nebo r ₂	alb
(r)	r	(ab)
r ₁ /r ₂	r ₁ , pokud za ním následuje r ₂	abc/123

Obrázek 2.7: Regulární výrazy jazyka lex

Třetí oddíl obsahuje libovolně pomocné procedury potřebné pro akce: překladač lex pouze zkopíruje veškerý text ze třetího oddílu do výstupního souboru. Tyto procedury se mohou také překládat samostatně a potom spojit s lexikálním analyzátem.

2.6.3 Zápis regulárních výrazů

Jazyk lex umožňuje podstatně komplikovanější zápis regulárních výrazů, jak ukazuje tabulka na obr. 2.7. Symbol v tabulce označuje jeden znak, r regulární výraz a s řetězem znaků. Zápis \c, resp. "s" se používá tedy, jestliže potřebujeme uvést některý ze speciálních znaků jazyka lex v jeho původním významu: jedná se o znaky \n, ^, \$ [] * + ? { } | a / . Zápis se zpětným lomítkem rovněž umožňuje zadat speciální řídicí znaky písmenem (např. \t, \n) nebo osmikovým kódem (\011, \015).

2.6.4 Komunikace s okolím

Lexikální analyzátor vytvořený programem lex spolupracuje se syntaktickým analyzátem následujícím způsobem. Po využití funkce `yylex()` ze syntaktického analyzátoru začne lexikální analyzátor čist zblýžující vstup po znacích až do okamžiku, kdy najde nejdéle prefix vstupního textu odpovídající jednomu z regulárních výrazů `pi`. Potom provede akci `actioni`. Obvykle `actioni` provede na konci příkaz `return(symbol)`, který vrátí řízení syntaktickému analyzátoru a zároveň předá kód přefenčního symbolu. Pokud akce nekončí příkazem návratu, pokračuje lexikální analyzátor ve vyhledávání dalších symbolů až po dosažení akce, která způsobí návrat do syntaktického analyzátoru, nebo do nalezení konce vstupního souboru. Opakování vyhledávání lexému až do explicitního návratu umožňuje lexikálnímu analyzátoru výhodně zpracovávat mezery a poznámky.

pokračovat čtením dalšího symbolu. V pravidle pro id obsahuje příslušná akce pouze návrat z lexikální analýzy a předání kódu symbolu IDENT jako návratové hodnoty. Pravidlo pro number nejprve převede textovou reprezentaci čísla z proměnné yytext na binární hodnotu standardní funkce atoi(), a vrátí kód symbolu NUM. Poznámějme, že proměnná yyval, do níž se hodnota čísla ukládá, není definována programem lex a její definice tedy musí být uvedena v části deklarací.

Příklad 2.10. V příkladu 2.9 jsme si předvedli zápis lexikálního analyzátoru, u něhož jsme předpokládali opakování volání, vždy pro získání jediného vstupního symbolu. Poukážíme jiným způsobem se v jazyku lex vytvářejí filtry, které — jak jsme již uvedli — pouze transformují vstupní text a zapisují jej na výstup. Celá činnost filtrování se tedy může provést v rámci jediného volání funkce `yylex()`. Následující program bude představovat filtr, který ze vstupního souboru vypustí všechny nadbytečné mezery a tabulátory.

```

%#
[ \t]+ { output(''); }

```

Tato specifikace ze vstupního souboru vybírá pouze posloupnosti mezer a tabulátorů, které zkracuje na jedinou mezitu. Všechny ostatní znaky se přenáší bez změny na výstup.

2.7 Zotavení po chybě v lexikální analýze

Přímo v lexikální analýze se rozpoznává pouze málo chyb, neboť lexikální analyzátor má na zdrojový program příliš omezený pohled. Pokud se ve zdrojovém programu v jazyce C objeví poprvé řetězec fi v kontextu

```

fi ( a == f(x) ) ...

```

neumíže lexikální analyzátor říci, zda fi je chybě napsané klíčové slovo if nebo neodeklarován identifikátor funkce. Vzhledem k tomu, že fi je platný identifikátor, musí lexikální analyzátor vrátit symbol pro identifikátor a nechat zpracování chyby na některé další fázi překladače.

Předpokládejme však, že se naskytla situace, ve které není lexikální analyzátor schopen pracovat, nebož žádny ze vzorů pro symboly neodpovídá prefiksu zblýžujícího vstupu. Snad nejsnadnější strategií zotavení je metoda, kdy ze zblýžujícího vstupu vypočítáme znaky tak dlelohu, až se lexikálnímu analyzátoru podaří rozpoznat další správně vytvořený symbol. Další možností je, že lexikálnímu analyzátoru aniž nahlásí chybu, vrátí kód speciálního terminálního symbolu, který není obsažen v gramatice jazyka, a nechá hlkášeny chyby a zotavení na syntaktický analyzátor. Obě metody se v praxi běžně používají a jsou obvykle dostatečně účinné.

Jiné možné činnosti při zotavení z chyby jsou:

- vypuštění přebývajícího znaku,
- vložení chybějícího znaku,
- nahrazení nesprávného znaku správným,
- vzájemná výměna dvou sousedních znaků.

Podobnými chybouvými transformacemi se můžeme pokoušet opravit chybu. Nejjednodušší takovou strategii je zjíšťování, zda se nedá použít pravé jedné transformace převést zblýžující vstup na platný lexém. Tato strategie předpokládá, že většina lexikálních chyb je výsledkem jedné chybouvé transformace (např. překlep pri pořizování zdrojového textu); takový předpoklad obvykle (ale ne vždy) odpovídá praxi.

Jedním ze způsobů nalezení chyb v programu je výpočet minimálního počtu chybových transformací požadovaných pro převod chyboucího programu na syntakticky správný program. Říkáme, že chyboucí program obsahuje k chyb, pokud nejkratší posloupnost chybových transformací, která jej zobrazuje na nějaký platný program, má délku k . Oprava chyb pomocí minimální vzdálenosti je vhodný teoretický nástroj, avšak v praxi se obecně nepoužívá pro její velmi náročnou implementaci. Několik experimentálních překladačů však používá kritéria minimální vzdálenost pro lokální opravy.

Kapitola 3

Syntaktická analýza

3.1 Činnost syntaktického analyzátoru

Během syntaktické analýzy se překladač snaží zjistit, zda zdrojový text tvorí větu odpovídající gramatickému překládanému jazyku. K tomu využívá posloupnost lexikálních symbolů získanou jako výsledek lexikální analýzy. Pokud text obsahuje nějaké chyby, překladač je nahlásí a obvykle provede určité zotavení tak, aby i při výskytu chyb mohl pokračovat dále v činnosti a odhalit případně další chyby.

Při implementaci překladače se obvykle používá jednoho ze dvou základních přístupů překladu *shora dolů* nebo *zdele nahoru*. Tyto názvy odpovídají postupu při vytváření derivacího stromu: při překladu shora dolů vycházíme ze startovacího symbolu gramatiky a snažíme se postupnou expozícií nonterminálních symbolů dospět až k terminálním symbolům odpovídající posloupnosti lexikálních symbolů na vstupu; při překladu zdele nahoru se naopak snažíme posloupnost terminálních symbolů ze vstupu redukovat až na startovací nonterminál. Uvedeným dvojicím přístupů odpovídají také dvě základní třídy gramatik, konkrétně LL a LR gramatiky, které popisují určité dosudštěné velké podmožiny bezkontextových jazyků. Často se pro analyzátor implementované ručně využívá LL gramatik: analyzátor větší třídy LR jazyků se obvykle vytváří automatizovanými prostředky.

V praktické implementaci syntaktického analyzátoru obvykle požadujeme více než jenom informaci o syntaktické správnosti zdrojového programu. Výstupem analyzátoru bude určitá reprezentace zdrojového textu, která bude obsahovat pouze informace podstatné pro další příslušný překlad. Touto reprezentací může být například deriváční strom nebo obecně určitá posloupnost akcí, které vytvářejí vnitřní reprezentaci struktury zdrojového programu a uchovávají informace o semantice této struktury (atributy – jmena identifikátorů, hodnoty literálů apod.). Uchovávané informace pak využívá sémantická analýza pro vyhodnocení těch závislostí, které nelze popsat prostředky bezkontextových gramatik.

3.2 Syntaktická analýza shora dolů

V této části se budeme zabývat základními principy překladu shora dolů a implementaci odpočívajícího syntaktického analyzátoru, nazývaného často prediktivní syntaktický analyzátor.

Překlad shora dolů můžeme popsat buď jako proces hledání levé derivace vstupního řetězce, nebo jako proces vytváření deriváčního stromu počínaje jeho kořenem. Tento proces může být realizován obecně metodou "pokusu a omyleb", kdy se snažíme v určitém bodě pre-

kladu aplikovat postupně jednotlivá pravidla gramatiky a v případě, že je aplikace určitého pravidla neúspěšná, provedeme návrat do bodu, ze kterého lze pokračovat dále volbou jiné varianty. Tento rekurezní postup se nazývá *syntaktická analýza s návraty*; je znacně neefektivní a pro řešení překladačů programovacích jazyků nevhodný. Naštěstí většina běžných konstrukcí programovacích jazyků je taková, že umožňují přímočarou analýzu bez návratů.

3.2.1 Množiny FIRST a FOLLOW

Konstrukce prediktivního analyzátoru je založena na dvou funkciích spojených s gramatikou G . Tyto funkce, *FIRST* a *FOLLOW*, umožňují definovat řídici tabulku pro deterministický zásobníkový automat. Množiny symbolů získané funkcí *FIRST* i *FOLLOW* lze také použít jako synchronizační množiny pro zotavení.

Je-li α řetězec symbolů gramatiky, potom $FIRST(\alpha)$ je množina terminálních symbolů, jimiž mohou začínat řetězec derivovaný z α . Pokud $\alpha \xrightarrow{*} \epsilon$, je ϵ rovněž ve *FIRST*(α).

Množina *FOLLOW*(A) pro nonterminál A definuje jako množinu všech terminálních symbolů a , které se mohou vyskytovat bezprostředně vpravo od A v nějaké větné formě, tj. množina takových terminálních symbolů, pro něž existuje derivace ve tvaru $S \xrightarrow{*} aAz$ pro nějaké a a z . Povšimněte si, že během derivace mohou mezi A a a být nějaké symboly. Pokud je tomu tak, pak tyto symboly derivují prázdný řetězec ϵ a vymizí. Může-li být A nejpravějším symbolem v nějaké větné formě, je ve *FOLLOW*(A) rovněž symbol $\$$, který představuje konec vstupního řetězce.

Množina *FIRST*(X) pro všechny symboly X gramatiky vypočteme aplikací následujících pravidel opakován tak dlouho, až nelze do žádné množiny *FIRST* přidat další terminální symbol nebo ϵ .

1. Je-li X terminální symbol, potom *FIRST*(X) je rovno $\{X\}$.

2. Je-li $X \rightarrow \epsilon$ pravidlo, potom přidáme do *FIRST*(X) symbol ϵ .

3. Je-li X nonterminál a $X \rightarrow Y_1 Y_2 \dots Y_k$ pravidlo, potom přidáme do *FIRST*(X) symbol a , jestliže pro nějaké i je $a \in FIRST(Y_i)$ a ϵ je ve všech množinách *FIRST*(Y_1), \dots , *FIRST*(Y_{i-1}), tj. jestliže $Y_1 \dots Y_{i-1} \xrightarrow{*} \epsilon$. Je-li ϵ ve *FIRST*(Y_i) pro všechna $j = 1, 2, \dots, k$, potom přidáme ϵ do *FIRST*(X). Například všechny terminální symboly z *FIRST*(Y_1) jsou určiti ve *FIRST*(X). Pokud Y_1 nedriveruje ϵ , nepřidáme do *FIRST*(X) již nic dalšího, ale jestliže $Y_1 \xrightarrow{*} \epsilon$, přidáme *FIRST*(Y_2) atd.

Nyní můžeme vypočítat *FIRST*(X) pro libovolný řetězec $X_1 X_2 \dots X_n$ následujícím postupem. Přidáme do *FIRST*($X_1 X_2 \dots X_n$) všechny symboly z *FIRST*(X_1) různé od ϵ . Pokud je ϵ ve *FIRST*(X_1), přidáme rovněž symboly z *FIRST*(X_2), je-li ϵ ve *FIRST*(X_1) i *FIRST*(X_2), přidáme symboly z *FIRST*(X_3) atd. Konečně přidáme do *FIRST*($X_1 X_2 \dots X_n$) symbol ϵ , pokud všechny množiny *FIRST*(X_i) obsahují ϵ .

Výpočet množiny *FOLLOW*(A) pro všechny nonterminály A provedeme aplikací následujících pravidel opakován tak dlouho, až nelze do žádné množiny *FOLLOW* přidat další symbol.

1. Do *FOLLOW*(S), kde S je startovací symbol gramatiky, vložíme symbol $\$$ označující konec vstupního řetězce.

2. Máme-li pravidlo $A \rightarrow \alpha B \beta$, potom vše z množiny $FIRST(\beta)$ kromě ϵ se umístí do $FOLLOW(B)$.
3. Máme-li pravidlo $A \rightarrow \alpha B$ nebo $A \rightarrow \alpha B \beta$ kde $FIRST(\beta) \setminus \{\epsilon\}$ obsahuje ϵ (tj. $\beta \Rightarrow \epsilon$), potom prvky z množiny $FOLLOW(A)$ jsou obsaženy zároveň v množině $FOLLOW(B)$.

Příklad 3.1. Uvažujme gramatiku

$$\begin{array}{l} (1) \quad E \rightarrow TE' \\ (2) \quad E' \rightarrow +TE' \\ (3) \quad | \quad \epsilon \\ (4) \quad T \rightarrow FT' \\ (5) \quad T' \rightarrow *FT' \\ (6) \quad | \quad \epsilon \\ (7) \quad F \rightarrow (E) \\ (8) \quad | \quad \text{id} \end{array}$$

Potom

$$\begin{aligned} FIRST(E) &= FIRST(T) = FIRST(F) = \{(, \text{id}\} \\ FIRST(E') &= \{+, \epsilon\} \\ FIRST(T') &= \{* , \epsilon\} \\ FOLLOW(E) &= FOLLOW(E') = \{, \$\} \\ FOLLOW(F) &= \{+, *\}, \$\} \end{aligned}$$

Například id a levá závorka se přidají do $FIRST(F)$ na základě pravidla (3) z definice $FIRST$ v obou případech s $i = 1$, neboť $FIRST(\text{id}) = \{\text{id}\}$ a $FIRST(') = \{\}\}$ podle pravidla (1). Potom podle pravidla (3) s $i = 1$ z pravidla $T \rightarrow FT'$ plyne, že id a levá závorka jsou rovněž v $FIRST(T)$. Dále je například pro pravidlo (2) symbol $*$ prvkem $FIRST(E')$.

Výpočet množin $FOLLOW$ zahájíme vložením $\$$ do $FOLLOW(E)$ podle pravidla (1). Podle (2) s pravidlem $F \rightarrow (E)$ je ve $FOLLOW(E)$ také pravá závorka. Aplikace (3) na pravidlo $E \rightarrow TE'$ vede k tomu, že $\$$ a pravá závorka jsou ve $FOLLOW(E')$. Vzhledem k tomu, že $E' \Rightarrow \epsilon$, jsou také ve $FOLLOW(T)$. Jako poslední příklad aplikace pravidel pro $FOLLOW$ uvažujeme případ $T \rightarrow TE'$ v pravidle (2), podle něhož všechno z $FIRST(E')$ s výjimkou ϵ se musí umístit do $FOLLOW(T)$. To, že $\$$ je ve $FOLLOW(T)$, jsme již zjistili. ■

3.2.2 Konstrukce rozkladových tabulek

Syntaktický analyzátor pracující metodou shora dolů může použít jako zásobníkový automat tvořený vstupní páskou, vstupní páskou a rozkladovou tabulkou. Automat čte symboly ze vstupní pásky a na vstupní pásku zapisuje čísla aplikovaných pravidel gramatiky – *levý rozklad* vstupní věty. Konfigurace tohoto automatu je dána trojicí

$$(x, X\alpha, \pi).$$

kde x je nepřečtená část vstupního řetězce, $X\alpha$ obsahuje zásobníku (se symbolem X na vrcholu) a π je obsah výstupní pásky. Automat začíná pracovat v počáteční konfiguraci

$$(w, S\#, \epsilon).$$

kde w je vstupní řetězec, S startovací nonterminál a $\#$ speciální zásobníkový symbol označující duo zásobníku. Pokud automat přijme vstupní řetězec w , dostane se do koncové konfigurace

$$(\epsilon, \#, \pi),$$

kde π je levý rozklad.

Rozkladová tabulka reprezentuje zobrazení

$$M : (\Sigma \cup N \cup \{\#\} \times (\Sigma \cup \$)) \rightarrow \{\text{expand } 1, \text{expand } 2, \dots, \text{expand } n, \text{pop}, \text{accept}, \text{error}\}$$

kde význam jednotlivých akcí je následující:

- **expand i** Je-li $p_i : A \rightarrow \alpha$ i -té pravidlo gramatiky, na vrcholu zásobníku je nonterminál A , na vstupu symbol a a $M[A, a] = \text{expand } i$, provede automat přechod

$$(ax, A\beta, \pi) \vdash (ax, \alpha\beta, \pi i)$$

tj. nonterminál A se na vrcholu zásobníku nahradí pravou stranou α pravidla p_i a na výstup se dá číslo použitého pravidla i .

- **pop** Je-li na vstupu i na vrcholu zásobníku týž terminální symbol a , provede automat přechod

$$(ax, a\beta, \pi) \vdash (x, \beta, \pi)$$

tj. symbol a se odstraní z vrcholu zásobníku i ze vstupu.

- **accept** Akce **accept** představuje přijetí vstupního řetězce v koncové konfiguraci automatu, přičemž výstupní řetězec obsahuje úplný levý rozklad vstupní věty.

- **error** Akce **error** nastane tehdy, jestliže vstupní řetězec není prvkem jazyka, takže automat nemůže dále pokračovat v činnosti.

Příklad 3.2. Rozkladová tabulka deterministického zásobníkového automatu pro gramatiku

$$\begin{array}{l} (1) \quad S \rightarrow aAS \\ (2) \quad S \rightarrow b \\ (3) \quad A \rightarrow a \\ (4) \quad A \rightarrow bSA \end{array}$$

bude mít následující tvar (akce **expand** i je zapsána jako e_i , akce **accept** jako **acc** a prázdná polička představuje akci **error**):

ZÁSOBNÍK	VSTUPNÍ SYMBOL		
	a	b	\$
S	e_1	e_2	
A	e_3	e_4	
a	pop		
b		pop	
$\#$			acc

Pro vstupní řetězec $abbaab$ potom můžeme vytvořit následující posloupnost přechodů automatu:

$$\begin{aligned} (abbab\$, S\#, \epsilon) &\stackrel{1}{\vdash} (abbab\$, aAS\#, 1) \stackrel{\text{pop}}{\vdash} (bbab\$, AS\#, 1) \stackrel{4}{\vdash} (bbab\$, bSAS\#, 14) \stackrel{\text{pop}}{\vdash} \\ (bab, SAS\#, 14) &\stackrel{2}{\vdash} (bab\$, bAS\#, 14) \stackrel{\text{pop}}{\vdash} (ab\$, AS\#, 142) \stackrel{3}{\vdash} (ab\$, aS\#, 1423) \stackrel{\text{pop}}{\vdash} \\ (b\$, S\#, 1423) &\stackrel{2}{\vdash} (b\$, b\#, 14232) \vdash (\$, \#, 14232), \end{aligned}$$

která nám dá rozklad výtvry $abbaab$ ve tvaru 14232. ■

Pro konstrukci rozkladové tabulky deterministického zásobníkového automatu ke gramatice G můžeme využít algoritmu 3.1. Je založen na následující myšlence. Předpokládejme, že $A \rightarrow \alpha$ je pravidlo a že α je ve $FIRST(\alpha)$. Potom, je-li současným vstupním symbolem a , provede analyzátor expand i na A , jedná komplikaci nastane, pokud $\alpha = a$ nebo $\alpha \Rightarrow \epsilon$. V tom případě musíme opět expandovat A na a , je-li současný vstupní symbol ve $FOLLOW(A)$ nebo byl-li dosažen konec vstupního řetězce (symbol $\$$) a $\$$ je ve $FOLLOW(A)$. Akce **pop** se bude provádět tehdy, je-li na vrcholu zásobníku i na vstupu týž terminální symbol a akce **accept** nastane v situaci, kdy bude vstupní řetězec vycerpán (na vstupu bude ukončovací symbol $\$$) a zásobník vyprázdněn (na vrcholu bude symbol $\#$).

Algoritmus 3.1. (Konstrukce rozkladové tabulky prediktivního analyzátoru)

Vstup. Gramatika G .

Výstup. Rozkladová tabulka M .

Metoda.

1. Pro všechna pravidla p_i tvaru $A \rightarrow \alpha$ proved kroky 2 a 3.
2. Pro všechny terminální symboly a ve $FIRST(\alpha)$ přidej **expand** i do $M[A, a]$.
3. Je-li ϵ ve $FIRST(\alpha)$, přidej **expand** i do $M[A, \#]$ pro všechny terminální symboly b z množiny $FOLLOW(A)$. Pokud ϵ je ve $FIRST(\alpha)$ a $\$$ ve $FOLLOW(A)$, přidej **expand** i do $M[A, \$]$.
4. Pro všechny terminální symboly a přidej **pop** do $M[a, a]$.
5. Nastav $M[\#, \$]$ na **pop**.
6. Všechny nedefinované položky v M nastav na **error**.

Příklad 3.3. Použijme algoritmus 3.1 na gramatiku z příkladu 3.1. Vzhledem k tomu, že $FIRST(TE') = FIRST(T) = \{., \text{id}\}$, budou položky $M[E, .]$ a $M[E, \text{id}]$ obsahovat expand 1.

Pravidlo $E' \rightarrow +TE'$ vede k tomu, že $M[E', +]$ bude obsahovat **expand** 2. Pravidlo $E' \rightarrow \epsilon$ vede dále k tomu, že $M[E', \#]$ a $M[E', \$]$ budou obsahovat **expand** 3, neboť $FOLLOW(E') = \{., \$\}$.

Celá rozkladová tabulka vytvořená algoritmem 3.1 je na obr. 3.1.

3.2.3 LL(1) gramatiky

Algoritmus 3.1 lze aplikovat na libovolnou gramatiku G a získat tak rozkladovou tabulku M . Pro některé gramatiky se však může stát, že v některých položkách rozkladové tabulky budeme mít více konfliktních akcí. Například je-li gramatika G zleva rekurzivní nebo nejednoznačná, bude tabulka M obsahovat alespoň jednu násobně definovanou položku.

ZÁSOBNÍK	VSTUPNÍ SYMBOL				
	id	+	*	()
E	e_1			e_1	
E'		e_2			e_3 e_3
T	e_4			e_4	
T'		e_5		e_6	e_6
F	e_7			e_7	
id		pop			
$+$		pop			
$*$			pop		
$($				pop	pop
$)$					
$\$$					acc

Obrázek 3.1: Rozkladová tabulka prediktivního analyzátoru

Gramatika, jejíž rozkladová tabulka neobsahuje násobně definované položky, se nazývá **LL(1) gramatikou**. První "L" v názvu znamená, že se vstupní text prolíží zleva doprava, druhé "L" představuje vytváření levého rozkladu a "1" vyjadřuje počet symbolů ve vstupním textu, které potřebujeme znát při rozhodování o příslušnosti vstupního řetězce. Lze ukázat, že algoritmus 3.1 pro všechny LL(1) gramatiky G vede k rozkladové tabulce deterministického zásobníkového automatu, který přijímá právě jazyk $L(G)$.

Z definice LL(1) gramatiky (viz [12]) vyplývá několik vlastností, které umožňují rozhodnout, zda daná gramatika je či není typu LL(1). Následující dvě vlastnosti musí každá LL(1) gramatika nutně splňovat:

Nechť $A \rightarrow \alpha_1|\alpha_2|\dots|\alpha_n$ jsou všechna A -pravidla gramatiky G . Potom:

- **Vlastnost FF.** Množiny $FIRST$ všech pravých stran musejí být po dvojicích disjunktní, tj.

$$FIRST(\alpha_i) \cap FIRST(\alpha_j) = \emptyset \text{ pro } i \neq j$$

- **Vlastnost FFL.** Je-li dále pro nějaké i $\alpha_i \Rightarrow \epsilon$, musí být $FOLLOW(A)$ po dvojicích disjunktní s množinami $FIRST$ zblížujícími pravých stran.

$$FIRST(\alpha_i) \cap FOLLOW(A) = \emptyset \text{ pro } i \neq j$$

Z uvedených pravidel například vyplývá, že LL(1) gramatika nemůže obsahovat levu rekurzi, neboť by pro některý nonterminál A takový, že $A \stackrel{*}{\Rightarrow} A\alpha$, $\alpha \in (\Sigma \cup \{\#\})^*$, byla porušena podmínka FF. Například je-li v gramatice přímo pravidlo $A \rightarrow A\alpha|\beta$, potom $FIRST(\beta) \subseteq FIRST(A\alpha)$.

3.2.4 Transformace na LL(1) gramatiku

V mnoha případech neují výchozí gramatika, pro kterou chceme vyrobit syntaktický analyzátor, typu LL(1). To znamená, že v ní existují pravidla, která poruší některou z podmínek FF nebo FFL. Transformaci takové gramatiky na typ LL(1) nám mohou umožnit následující postupy (podrobnější popis uveden v [12]):

- **Odstanění levé rekurze**: Jak již bylo uvedeno výše, gramatika, která obsahuje levou rekurzi, nemůže být typu LL(1). Obecně můžeme zleva rekuzivní pravidlo zapsat jako

$$A \rightarrow A\alpha_1 | A\alpha_2 | \dots | A\alpha_n | \beta_1 | \dots | \beta_m$$

kde řetězce β_i nezačínají nonterminálem A . Takové pravidlo můžeme přepsat zavedením nového nonterminálu A' jako

$$A \rightarrow \beta_1 A' | \beta_2 A' | \dots | \beta_m A'$$

$$A' \rightarrow \alpha_1 A' | \alpha_2 A' | \dots | \alpha_n A' | \epsilon$$

- **Faktorizace pravidel**: Začíná-li několik pravých stran A -pravidla týmž řetězem terminálních symbolů, tj. má-li pravidlo tvary

$$A \rightarrow \beta\alpha_1 | \beta\alpha_2 | \dots | \beta\alpha_n,$$

můžeme provést jejich "vytknutí" opět zavedením nového nonterminálu A' s pravidly

$$A \rightarrow \beta A'$$

$$A' \rightarrow \alpha_1 | \alpha_2 | \dots | \alpha_n$$

Tato úprava, stejně jako předchozí, však nemusí zaručit, že nepřinese další konflikty. Budou-li například některé z řetězců α_i neprázdný průnik množin $FIRST$, dojde opět k porušení podmínky FF v nonterminálu A' .

- **Eliminace pravidel**: Některým konfliktům se můžeme vyhnout tak, že za některé nonterminály dosadíme jejich pravé strany a tím odstraníme z gramatiky pravidla, která způsobovala konflikt.

- **Reducce množiny FOLLOW**: Je-li pro některý nonterminál porušena podmínka FFL, můžeme přidat nový nonterminál, který vede ke změnění počtu prvků konfliktní množiny FOLLOW a případně i k disjunktnosti této množiny FOLLOW s množinami FIRST zbývajících pravých stran pravidel konfliktního nonterminálu (příklad viz [12], str. 103).

Uvedené transformace nemusí obecně vést k cíli, a to i v případě, že k transformované gramatice LL(1) gramatiku existuje.

3.2.5 Analýza rekuzivním sestupem

Jednou z implementací syntaktické analýzy shora dolů je analýza rekuzivním sestupem. Tato metoda spočívá v zápisu samostatných procedur pro analýzu každého nonterminálního symbolu gramatiky. Překlad programu se pak spustí voláním procedury odpovídající startovacímu nonterminálu.

Máme-li pro nonterminál A jediné pravidlo ve tvare $A \rightarrow X_1 X_2 \dots X_n$, bude tělo příslušné procedury obsahovat posloupnost akcí provádějících postupné analýzu symbolů X_1 až X_n . Je-li symbol X_i nonterminálním symbolem gramatiky, bude odpovídající akci volání podprogramu pro analýzu symbolu X_i , je-li X_i terminální symbol, zavoláme podprogram $expect(X_i)$. Tento podprogram zjistí, zda je na vstupu požadovaný symbol a v případě, že

```
procedure expect(s: symbol);
begin
  if sym = s then
    lex
  else
    error
end;
```

Obrázek 3.2: Implementace procedury **expect**

ano, přeče další vstupní symbol; v opačném případě nahlásí syntaktickou chybu. Příklad implementace procedury **expect** v jazyce Pascal je na obr. 3.2. Předpokládáme, že lexiční analyzátor je reprezentován procedurou **lex**, která při každém zavolení napiší globální proměnnou **sym** typu **symbol** následující vstupním symbolem.

Například pro analýzu nonterminálu A s jediným pravidlem $A \rightarrow xBy$ bude implementace procedury následující (předpokládáme, že terminálním symbolům x a y odpovídají konstanty **SYM.X** a **SYM.Y**):

```
procedure A;
begin
  expect(SYM.X);
  B;
  expect(SYM.Y)
end;
```

V případě, že nonterminál A je definován více A -pravidly gramatiky, např. pokud gramatika obsahuje A -pravidla $A \rightarrow \alpha_1 | \alpha_2 | \dots | \alpha_k$, musíme nejprve na základě následujícího vstupního symbolu vybrat vhodnou pravou stranu. Pro každou variantu α_i budeme mít úsek ve tvaru

```
if sym in Φ(A, αi) then begin
  /* implementace analýzy řetězce αi */
end
```

kde funkce $\Phi(A, \alpha_i)$ je definována jako

$$\Phi(A, \alpha_i) = \begin{cases} FIRST(\alpha_i), & \epsilon \notin FIRST(\alpha_i) \\ FOLLOW(A) \cup (FIRST(\alpha_i) \setminus \{\epsilon\}), & \epsilon \in FIRST(\alpha_i) \end{cases}$$

Tato funkce definuje množinu symbolů, které se mohou vyskytovat na vstupu v okamžiku expenze nonterminálu A na řetězec α_i . Pokud tento řetězec vzdále obsahuje alespoň jeden symbol, je touto množinou $FIRST(\alpha_i)$. Může-li však expandovaný řetězec být prázdný, je třeba očekávat na vstupu i ty symboly, které jsou součástí množiny $FOLLOW(A)$ nonterminálu na levé straně pravidla. Je-li na vstupu symbol, který nepatří do žádné z množin $\Phi(A, \alpha_i)$, jede o syntaktickou chybou.

Vzhledem k tomu, že výběr pravé strany musí být u analyzátoru bez návratů jednoznačný, musí být množiny symbolů definovány funkci $\Phi(A, \alpha_i)$ pro jednotlivé pravé strany α_i , disjunktivně. Toto tvrzení ale není nic jiného, než vyjádření podmínek FF a FFL pro LL(1) gramatiku.

Příklad 3.4. Máme dánu gramatiku pro aritmetický výraz s operátory + a *, závorkami a celočíselnými konstantami:

$$\begin{aligned} E &\rightarrow T \ E1 \\ E1 &\rightarrow + \ T \ E1 \mid \epsilon \\ T &\rightarrow F \ T1 \\ T1 &\rightarrow * \ F \ T1 \mid \epsilon \\ F &\rightarrow (\ E) \mid \text{id} \end{aligned}$$

Pro nonterminál $E1$ můžeme vypočítat následující množiny:

$$\begin{aligned} FIRST(+ \ T \ E1) &= \{+\}, \\ FIRST(\epsilon) &= \{\epsilon\}, \\ FOLLOW(E1) &= \{.\$, \}, \\ \Phi(E1, + \ T \ E1) &= \{+\}, \\ \Phi(E1, \epsilon) &= \{.\$, \} \end{aligned}$$

takže jej můžeme implementovat procedurou

```
procedure E1;
begin
  if sym in [ADDSYM] then begin
    expect(ADDSYM);
    T;
    E1
  end
  else if sym in [RPRSYM, EOFSYM] then begin
    /* prázdná pravá strana */
  end
  else
    error
end;
```

Typ **symbol** je v tomto případě reprezentován výštem konstant **ADDSYM** (operátor +), **MULSYM** (operátor *), **LPRSYM** (levá závorka), **RPRSYM** (pravá závorka), **IDSYM** (identifikátor) a **EOFSYM** (konec vstupního textu \\$).

Je zřejmé, že uvedené řešení lze implementovat mnohem efektivněji, pokud provedeme následující optimalizace:

- Test, zda je symbol obsažen v jednoprvkové množině. Ize nahradit přímo testem na rovnost.
- V případě, že pravá strana pravidla začíná terminálním symbolem, nemůže být volat proceduru **expect**, neboť máme již při výběru pravé strany zaručen kladný výsledek testu na obr. 3.2. Můžeme tedy rovnou volat lexiční analyzátor.
- Je-li pravá strana pravidla prázdná (tj. je-li tvorena pouze symbolem ϵ), je možné ji implementovat vždy jako poslední a obrátit příslušný test.

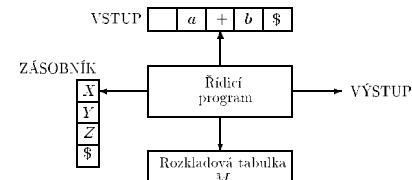
Po naznačených optimalizačních dostaneme konečnou verzi procedury analyzující nonterminál $E1$:

```
procedure E1;
begin
  if sym = ADDSYM then begin
    lex;
    T;
    E1
  end
  else if not (sym in [RPRSYM, EOFSYM]) then
    error;
end;
```

Podobným způsobem můžeme implementovat i zbývající nonterminály gramatiky. ■

3.2.6 Nerekurzivní prediktivní analýza

Implementace syntaktického analyzátoru z předešlého článku využívala pro uchování informací o rozpracované části věty implicitního zásobníku, který používá hostitelský překladač (tj. v našem případě překladač Pascal) pro realizaci volání rekuzivních podprogramů. Je však také možné vytvořit prediktivní syntaktický analyzátor, který používá svůj vlastní zásobník. Struktura takového analyzátoru je na obr. 3.3.



Obrázek 3.3: Model nerekurzivního prediktivního syntaktického analyzátoru

Tento typ analyzátoru, nazývaný **syntaktický analyzátor řízený tabulkou**, je tvořen vstupní pamětí, zásobníkem, rozkladovou tabulkou a výstupem. Vstupní paměť obsahuje analyzovaný řetězec zakončený speciálním symbolem \\$, který označuje konec vstupního řetězce. Zásobník obsahuje posloupnosti symbolů gramatiky: dva zásobníky je indikováno opět speciálním symbolem #. Rozkladová tabulka je dvojrozměrné pole $M[A, a]$, kde A je nonterminál a a je terminální symbol nebo symbol \\$.

Samostatnou částí analyzátoru je řídící program, který opakově prohledá symbol X na vrcholu zásobníku a současný vstupní symbol a , na základě nichž se rozhoduje o své další činnosti. Algoritmus rozhodování je následující:

- Je-li $X = \#$ a $a = \$$, vyčerpali jsme vstupní řetězec z zásobníku; analyzátor se zastaví a ohlásí úspěšné ukončení.

- Je-li $X = a \neq \$$, odstraníme symbol X z vrcholu zásobníku a přesuneme se na následující vstupní symbol.
- Je-li X nonterminální symbol, provedeme jeho expanzi na některou z odpovídajících pravých stran pravidel gramatiky. Pokud položka rozkladové tabulky $M[X, a]$ obsahuje X -pravidlo gramatiky, nahradíme symbol X na vrcholu zásobníku pravou stranou tohoto pravidla a na výstup předáme číslo použitého pravidla. Pokud je však $M[X, a] = \text{error}$, jde o syntaktickou chybu, kterou musí analyzátor nahlásit a provést zotavení.
- V ostatních případech jde opět o syntaktickou chybu.

Tento algoritmus můžeme vyjádřit programem na obr. 3.4. Proměnná top obsahuje index vrcholu zásobníku symbolů $stack$, funkce $pop()$ odstraní vrchol zásobníku a funkce $push()$ uloží na zásobník ijetec symbol. Funkce $error()$ provádí hlášení syntaktických chyb a případné zotavení. funkce $lex()$ představuje lexikální analyzátor, který při každém zavolání vrátí jeden symbol ze vstupu.

```
top := 0;
push(#$);
a := lex();
repeat
    X := stack[top];
    if X je terminální symbol nebo $ then
        if X = a then begin
            pop();
            a := lex();
        end
        else error()
    else /* X je nonterminál */
        if M[X, a] = X → Y1Y2...Yk then begin
            pop();
            push(Y1Y2...Yk);
            vypíš číslo použitého pravidla
        end
        else error()
    until X = # /* zásobník je prázdný */
```

Obrázek 3.4: Řídící program prediktivního analyzátoru

3.2.7 Zotavení po chybě při analýze shora dolů

K důležitým úkolům syntaktického analyzátoru patří také diagnostická činnost. Aby v rámci jednoho průchodu zdrojovým programem kompliátor odhalil co nejvíce chyb, je třeba implementovat prostředky, které dovolí, aby syntaktický analyzátor pokračoval v kontrole správnosti programu i po výskytu syntaktické chyby. Problem zotavení ze syntaktické chyby není obecně jednoduchý. Brěžně používané metody vycházejí z následujícího obecného postupu:

1. Po odhalení syntaktické chyby se ve vstupním ijeteci hledá místo (*body zotavení*, od kterého může analýza pokračovat v činnosti, přičemž se vynohlá určitá část textu. Bod zotavení je obvykle dán nalezením symbolu z množiny tzv. *klíčů*.

2. Syntaktický analyzátor provede synchronizaci podle pozice nalezeného klíče v gramatici a pokračuje dále v činnosti.

Množina klíčů musí být definována tak, aby obsahovala pokud možno pouze ty symboly, jejichž výskyt v gramatici je jednoznačný. Tím lze zařídit vysokou spolehlivost synchronizace analyzátoru při zotavování. Například v gramatici jazyka Pascal je klíčové slovo *else* použito jednoznačně, na rozdíl od identifikátoru nebo klíčového slova *end* (konec složeného příkazu, příkazu *case*, resp. závazku). Je-li však množina klíčů příliš omezená, roste délka neanalyzovaného textu, který se vynohlá při vyhledávání klíče ve vstupním větě.

Pro zotavení na základě množiny klíčů se používají například tyto metody:

• *Nerekurzivní metoda s pomocí množinou klíčů*. Tato metoda vychází z předem vypočtené množiny klíčů. Ke každému klíči je k dispozici informace o tom, kterou syntaktickou konstrukcí ukončuje. Například klíč '?' může ukončovat výrazu a klíč ';' příkazy. Výskytne-li se pak chybou analýzy výrazu a při zotavování se najde prává závorka, odstraní se ze zásobníku všechno, co souviselo s rozpracovaným výrazem a pokračuje se v analýze tak, jako by byl výraz analyzován správně.

• *Rekurzivní metoda s pomocí množinou klíčů*. Předchozí metoda se dá vylepšit ještě tím, že se užírá rovněž množiny klíčů, kterým začínají jisté syntaktické konstrukce. Je-li během vyhledávání bodu zotavení nalezený některý z těchto klíčů, spustí se analýza vnořené konstrukce a po jejím ukončení se pokračuje v zotavování. Tím je možné omezit rozsah neanalyzovaného textu a mohou být tedy odhaleny další chyby v zanořených konstrukcích.

• *Metoda s dynamicky budovanou množinou klíčů*. Při této metodě se množina klíčů vytváří na základě okamžitého kontextu; například při analýze příkazů v rámci pascalského cyklu *repeat* bude klíčem symbol *until*, zatímco při analýze výrazu v indexu bude klíčem prává závorka. Jednou z metod této skupiny je Hartmannova metoda, která jako množina klíčů využívá sjednocení množin *FOLLOW* rozpracovaných nonterminálů. Její implementaci se budeme dále zabývat podrobnejší.

Hartmannovo schéma zotavení

Každému syntaktickému správně vytvořenému programu analyzovanému syntaktickým analyzátorem přísluší derivační strom. Při analýze metodou rekurzivního sestupu je derivační strom budován postupným vytvářením procedur odpovídajících jednotlivým nonterminálům gramatiky a jejich prováděním. Výskyt syntaktické chyby je zastavován z hlediska syntaktického analyzátoru situací, kdy v jistém stadiu rozpracování derivačního stromu není možné v budování tohoto stromu pokračovat. Začlenění prostředků pro zotavení po chybě Hartmannovou metodou předpokládá, že analyzátor při výskytu chyby

- ukončí vytváření derivačního podstromu obsahujícího chybu (neuváděme zatím, kterého podstromu; v nejhorším případě dojde k ukončení vytváření celého stromu a tím i analýzy) s tím, že tento podstrom je nadále uvažován jako správně vytvořený

- přeskocí všechny symboly na vstupu mezi chybou a koncem fráze odpovídající uzavřenému derivačnímu podstromu.

Snahou dobrého zotavování je uzavřít po chybě co nejtěsnější podstrom obklopující chybu (podstrom, jehož kořen je co nejvíce vzdálen od vrcholu derivačního stromu). Čím těsněji podstrom je uzavřen, tím méně symbolů je třeba přeskocit. Přeskakování symboly nejsou analyzovány; mohou být zdrojem dalších syntaktických chyb a pokud je symboly přeskovenou příliš mnoho, nelze v jedné analýze odhalit všechny chyby.

V každém okamžiku analýzy je vytvářen derivační podstrom pro jistý počet nonterminálů, přičemž tyto podstromy jsou do sebe vnořeny. Přidáme každému rozpracovanému derivačnímu podstromu množinu symbolů nazvanou *CONTEXT(A)*, která je sjednocením množin *FOLLOW(A)* všech nonterminálů, jež mají v okamžiku expenze nonterminálem A rozpracovaný derivační podstrom, včetně množiny *FOLLOW(A)*. Vznikne-li v průběhu vytváření derivačního podstromu pro nonterminál A chyba, musí proběhnout zotavení.

Množina *CONTEXT(A)* je dynamicky budovanou množinou klíčů, které využíváme při hledání bodu zotavení. Přeskovení symbolů na vstupu mezi chybou a koncem fráze odpovídající jistému podstromu je realizováno přeskovením všech symbolů na vstupu, které nejsou v množině *CONTEXT(A)*. Protože všechny symboly z množiny *CONTEXT(A)* jsou zároveň prvky jedné nebo více množin *FOLLOW* pro jednotlivé vnořené derivační podstromy, je zajistěno, že bude přeskoven nejméně množin počet symbolů ze vstupu a nalezen nejbližší možný bod zotavení v daném kontextu. Zároveň je třeba postupně uzavřít analýzu všech nonterminálů počínaje od nejvnořenějšího, v jejichž množinách *FOLLOW* není obsažen nastavený vstupní symbol. Posledním nonterminálem, jehož analýza se uzavře, je nonterminál, v jehož množině *FOLLOW* bod zotavení je.

Během analýzy metodou rekurzivního sestupu může dojít k detekci syntaktické chyby ve dvou situacích:

- je-li na vstupu jiný terminální symbol než se očekává, nebo
- nelze-li při expazi nonterminálu vybrat na základě současného vstupního symbolu žádoucí pravou stranu pravidla (vstupní symbol není prvek $\Phi(A, \alpha_i)$ pro žádoucí i).

První případ odpovídá situaci, kdy se chyba hlásí z procedury *expect*, druhý případ nastává bezprostředně při vstupu do procedury analyzující konkrétní nonterminál. Je-li k dispozici množina klíč *CONTEXT* (budeme ji nazývat také *kontextovou množinou*, neboť definuje kontext, v němž analýza probíhá), můžeme upravit proceduru *expect* tak, aby při chybě provedala zároveň i synchronizaci, jak ukazuje obr. 3.5.

Test na začátku analýzy nonterminálu zároveň se zotavením může provést procedura *check(s, context)*, která jako první parametr obdrží sjednocení množin $\Phi(A, \alpha_i)$ pro všechny pravé strany α_i nonterminálu A. Není-li současný vstupní symbol v této množině, nahlásí se chyba a provede se zotavení pomocí kontextové množiny. Při hledání bodu zotavení se ještě připoští, aby se na vstupu ještě objevil symbol z množiny očekávaných symbolů s, což umožňuje efektivní zotavení v situaci, kdy je na vstupu nějaký symbol navíc.

Vlastní postup při začlenění zotavení do analýzy rekurzivním sestupem je pak následující:

- procedury pro analýzu nonterminálů budou jako vstupní parametr předávány hodnotou dostávají aktuální kontextovou množinu, tj. deklarace procedur budou mít tvar

```
procedure A(context: symbols);
```

```
type symbols = set of symbol;

procedure expect(s:symbol; context: symbols);
begin
    if sym = s then
        lex
    else begin
        error;
        while not (sym in context) do lex
    end
end;

procedure check(s, c: symbols);
begin
    if not (sym in s) then begin
        error;
        while not (sym in c+s) do lex
    end
end;
```

Obrázek 3.5: Implementace pomocných procedur pro zotavení

- při volání procedury pro analýzu nonterminálu nebo procedury *expect* se vždy vypočte nová kontextová množina
- před volbou varianty v nonterminálu se zavolá procedura *check($\bigcup \Phi(A, \alpha_i)$, context)*, která zjistí, zda současný vstupní symbol odpovídá některé z pravých stran pro nonterminál A.

Výpočet kontextové množiny symbolu X, na pravé straně pravidla $A \rightarrow X_1X_2\dots X_iX_{i+1}\dots X_k$ spočívá v rozšíření současné kontextové množiny *CONTEXT(A)* o symboly, které se stanou klíči pro analyzovaný terminální a nebo nonterminální symbol. Možné jsou například tyto příspůvky:

1. Kontextovou množinu nonterminálu X, vždy rozšíříme o prvky množiny *FOLLOW(X_i)*, tj.

$$\text{CONTEXT}(X_i) = \text{CONTEXT}(A) \cup \text{FOLLOW}(X_i), X_i \in \Sigma$$

zatímco kontextovou množinu terminálních symbolů (tj. argument procedury *expect*) ponecháme původní.

$$\text{CONTEXT}(X_i) = \text{CONTEXT}(A), X_i \in \Sigma$$

2. Kontextovou množinu symbolu X, (terminálního i nonterminálního) vždy rozšíříme o symboly, jimiž může začínat zbyvající část feřece na pravé straně pravidla, tj.

$$\text{CONTEXT}(X_i) = \text{CONTEXT}(A) \cup (\text{FIRST}(X_{i+1}\dots X_k) \setminus \{\epsilon\})$$

3. Kontextovou množinu symbolu X , rozšíříme o symboly ležící ve $FIRST$ všech následujících symbolů v pravidle, tj.

$$CONTEXT(X_i) = CONTEXT(A) \cup \left(\bigcup_{j=i+1}^k FIRST(X_j) \setminus \{ \epsilon \} \right)$$

První varianta je nejjednodušší, ovšem vyžaduje výpočet množin $FOLLOW$ a vede obecně k přeskoupení zbytku rozpracovaného pravidla při chybě uvnitř některého ze symbolů na pravé straně. Další dvě varianty se liší možností kontextové množiny, přičemž nejvhodnější řešení je zdejně kombinací všech tří přístupů, kdy do kontextové množiny nebudeme přidávat ty symboly, které jsou nejednoznačné (tj. takové, které se ve zdrojovém textu mohou vyskytovat v různých významech). Na výběru kontextových množin podstatné závisí kvalita zotavení, která se projevuje nejen počtem odhalených skutečných chyb, ale (v opačném smyslu) i počtem kláštených zdalečených chyb.

Příklad 3.5. Uvažujme následující gramatiku pro deklarace proměnných s inicializací:

$$\begin{aligned} S &\rightarrow \text{var } \text{id } L = \text{num} \\ L &\rightarrow . \text{ id } L \mid \epsilon \end{aligned}$$

Použijeme-li posledního přístupu k výpočtu kontextových množin, můžeme syntaktickou analýzu se zotavením implementovat následujícimi procedurami (symboly **var**, **id**, **num**, čárka, rovník a $\$$ jsou pojmenovány po řádku **VARSYM**, **IDSYM**, **NUMSYM**, **COMSYM**, **EQSYM** a **EOFSYM**):

```
procedure S(c: symbols);
begin
    expect(VARSYM, c + [IDSYM, COMSYM, EQSYM, NUMSYM]);
    expect(IDSYM, c + [COMSYM, EQSYM, NUMSYM]);
    L(c + [EQSYM, NUMSYM]);
    expect(EQSYM, c + [NUMSYM]);
    expect(NUMSYM, c);
end;
procedure L(c: symbols);
begin
    check([COMSYM, EQSYM], c);
    if sym = COMSYM then begin
        lex;
        expect(IDSYM, c + [COMSYM]);
        L(c)
    end
end;
```

Poznamenajme, že v situaci, kdy některý nonterminál A může generovat prázdny řetězec, je podle definice funkce Φ součástí prvního parametru funkce $check$ také množina $FOLLOW(A)$. Vzhledem k tomu, jak se vytváří kontextová množina, můžeme množinu $FOLLOW(A)$ nahradit obecnější množinou $CONTEXT(A)$, která v dané situaci lépe reprezentuje množinu přípustných symbolů, které mohou v konkrétní situaci za nonterminálem A následovat. Například při analýze výrazu reprezentovaných nonterminálem E je v množině $FOLLOW(E)$ vždy obsažena pravá závorka jako důsledek pravidla $E \rightarrow (E)$. Pokud však

uebyla ještě otevřená žádná levá závorka, neúpravná závorka vlastně platným klíčem a nemůže být ani součástí kontextové množiny. Například v proceduře pro nonterminál L se může funkce **check** volat jako

check(c + [COMSYM], c)

Kapitola 4

Syntaxí řízený překlad

4.1 Základní pojmy teorie překladu

V tomto odstavci zavedeme některé základní pojmy teorie překladu, na které dále navážeme definicemi pojmu, které se přímo využívají při implementaci překladače.

Definice 4.1. Nechť Σ a Δ jsou abecedy. Abecedu Σ nazíváme *vstupní abecedou*, Δ *výstupní abecedou*. Překladem jazyka $L_1 \subset \Sigma^*$ do jazyka $L_2 \subset \Delta^*$ nazíváme relaci $TRAN : L_1 \rightarrow L_2$, Je-li $[x, y] \in TRAN$, pak řetězec y nazýváme *výstupem* pro řetězec x .

Typickým příkladem překladu je překlad infixového zápisu aritmetického výrazu na postfixový. Tento překlad je nekonečný (relace $TRAN$ obsahuje nekonečně mnoho dvojic řetězců) a relace, jež ho definuje, je ve skutečnosti funkce, neboť ke každému infixovému zápisu výrazu existuje právě jeden zápis postfixový. Problém koncretní specifikace nekonečného překladu je analogický specifikaci nekonečného jazyka. Stejně jako tomu bylo u syntaktické analýzy, jsou i zde dva možné přístupy — prostrednictvím generativního systému (gramatiky) nebo prostrednictvím automatu.

Generativní systém, nazývaný *překladovou párovou gramatikou*, je založený na dvou vzájemně spojených bezkontextových gramaticích. První z nich, tzv. *vstupní gramatiku*, popisuje jazyk tvorěný všemi větami zdrojového jazyka L_1 ; druhá, *výstupní gramatika*, popisuje jazyk $L_2 = \{g | [x, g] \in TRAN\}$ tvorěný všemi výstupy pro řetězec jazyka L_1 . Mechanismus zobecněné derivace umožňuje paralelní derivaci řetězce x ve vstupní gramatice a řetězce y ve výstupní gramatice.

Druhý přístup ke specifikaci překladu využívá pojmu *překladový automat*, který je ziskán rozšířením konečného nebo zásobníkového automatu o výstupní pásku a výstupní funkci, která předpisuje výstup automatu. Překlad definovaným překladovým automatem je množina dvojic řetězců $[x, y]$ takových, že automat přijme řetězec x a na výstup vyslechne řetězec y . Teorií překladových automatů se tento učební text nebude zabývat, případně zájemce odkazujeme na [2].

Definice 4.2. *Překladová párová gramatika* je pěticou

$$V = (N, \Sigma, \Delta, P, S)$$

kde N je konečná množina *nonterminálních symbolů*, Σ konečná *vstupní abecedou*, Δ konečná *výstupní abecedou*, P množina *přepisovacích pravidel* a $S \in N$ *startovací (nonterminální) symbol*.

Definice 4.3. Nechť $V = (N, \Sigma, \Delta, P, S)$ je překladová párová gramatika, přičemž $N \cap \Delta = \emptyset$ a množina P obsahuje pouze pravidla tvaru

$$A \rightarrow x_0 B_1 x_1 B_2 \dots B_k x_k \quad (4.1)$$

pro $x_i \in \Sigma^*$, $y_i \in \Delta^*$, $0 \leq i \leq k$. Pak *překladová gramatika* G_V příslušející gramatice V je pětice $G_V = (N, \Sigma, \Delta, P', S)$, kde množina P' obsahuje pouze pravidla ve tvaru

$$A \rightarrow x_0 y_1 B_1 x_1 y_2 B_2 \dots B_k x_k y_k$$

odvozenou z původních pravidel ve tvaru (4.1).

Příklad 4.1. Uvažujme překladovou párovou gramatiku

$$V = (\{E, T, F\}, \{\cdot, +, *, i, (\cdot), \cdot, +, *, i\}, \{P, E\})$$

s pravidly

$$\begin{aligned} E &\rightarrow E + T, E T + \\ E &\rightarrow T, T \\ T &\rightarrow T * F, T F * \\ T &\rightarrow F, F \\ F &\rightarrow (E), E \\ F &\rightarrow i, i \end{aligned}$$

Tato párová gramatika generuje překlad infixového aritmetického výrazu do postfixového výrazu, např.

$$\begin{aligned} [E, E] &\Rightarrow [E + T, ET+] \Rightarrow [T + T, TT+] \Rightarrow [F + T, FT+] \Rightarrow \\ &\Rightarrow [i + i, iT+] \Rightarrow [i + T * F, iTF * +] \Rightarrow [i + F * F, iFF * =] \Rightarrow \\ &\Rightarrow [i + i * F, iiF * +] \Rightarrow [i + i * i, iii * +] \end{aligned}$$

Příklad 4.2. Pravidla gramatiky z předchozího příkladu zachovávají pořadí odpovídajících si nonterminálů na pravých stranách. Po přejmenování symbolů výstupní abecedy tedy můžeme odvodit následující překladovou gramatiku:

$$G_V = (\{E, T, F\}, \{\cdot, +, *, i, (\cdot)\}, \{\text{ADD}, \text{MUL}, \text{ID}\}, P', E)$$

s pravidly

$$\begin{array}{l} E \rightarrow E + T \text{ ADD} \\ E \rightarrow T \\ T \rightarrow T * F \text{ MUL} \\ T \rightarrow F \\ F \rightarrow (E) \\ F \rightarrow i \text{ ID} \end{array}$$

Tato gramatika umožňuje provést např. následující derivaci:

$$\begin{aligned} E &\Rightarrow E + T \text{ ADD} \Rightarrow F + T \text{ ADD} \Rightarrow i \text{ ID} + T \text{ ADD} \Rightarrow \\ &\Rightarrow i \text{ ID} + T * F \text{ MUL ADD} \Rightarrow i \text{ ID} + F * F \text{ MUL ADD} \Rightarrow \\ &\Rightarrow i \text{ ID} + i \text{ ID} * F \text{ MUL ADD} \Rightarrow i \text{ ID} + i \text{ ID} * i \text{ ID MUL ADD} \end{aligned}$$

Vidíme, že ve větě "i ID + i ID * i ID MUL ADD" tvoří symboly vstupní abecedy jak jde po sobě vstup a výstupní symboly odpovídají výstupu překladu, tj. dvojice (i+i*, ID ID ID MUL ADD) je pravé překlad.

Z hlediska implementace mohou být symboly výstupní abecedy reprezentovány jako skutečné výstupní symboly (symboly ID, ADD a MUL z předešlých příkladů by např. mohly představovat instrukce zašluhovkového mechanizmu pro vyhodnocení aritmetického výrazu) nebo jako akce, např. pro symbol ADD volání procedury pro vygenerování instrukce sčítání nebo dokonce pro provedení součtu v případě interpretačního překladače. V dalších odstavcích se budeme zabývat rozšířením pojmu překladové gramatiky o atributy symbolů, přičemž konkrétní reprezentaci jednotlivých symbolů nebude v definicích uvažovat.

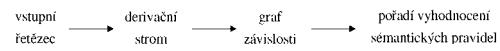
4.2 Atributovaný překlad

Prozatím jsme se zabývali pouze kontrolou, zda je věta, kterou překládáme, pravém překládáním jazyka. V této kapitole přidáme k syntaktickým konstrukcím další informace atributy, které se vyhodnocují na základě sémantických pravidel.

Pro připojení sémantických pravidel k pravidlům gramatiky existují dvě notace, syntaxi řízené definice a překladová schemata. Syntaxi řízené definice jsou specifikací překladu na vysoké úrovni abstrakce. Uklívají mnoha implementačních detailů a osvobožují uživatele od nutnosti specifikovat explicitně pořadí, v jakém se bude překlad provádět. Překladová schemata určují pořad využití vyhodnocování sémantických pravidel, takže umožňují ukázat i některé implementační detaily.

Obecně jak při překladu pomocí syntaxi řízených definic, tak i při použití překladových schematic rozkládáme vstupní posloupnost symbolů, budujeme derivační strom a potom procházíme stromem tak, abychom vyhodnotili sémantická pravidla v uzel derivačního stromu (viz obr. 4.1). Vyhodnocení sémantických pravidel může být generování kódu, ukládání informací do tabulek symbolů, vydávání zpráv o chybách nebo provádění nějakých jiných činností. Výsledkem vyhodnocení sémantických pravidel je překlad posloupnosti vstupních symbolů.

Implementace nemusí být doslova shodná se schematicemi na obr. 4.1. Speciální případy syntaxi řízeného překladu lze implementovat v jednom případu s vyhodnocením sémantických



Obrázek 4.1: Celkový pohled na syntaxi řízený překlad

pravidel během analýzy, bez explicitní konstrukce derivačního stromu nebo grafu ukazujícího závislosti mezi atributy. Vzhledem k tomu, že jednopřáhlová implementace je důležitá pro efektivitu překladače, je velká část této kapitoly věnována studiu takových případů. Jedna důležitá podřízená, zvaná *L-atributové definice*, zahrnuje téměř všechny překlady, které lze provádět bez explicitní konstrukce derivačního stromu.

4.2.1 Atributové překladové gramatiky

Definice 4.4. *Atributová překladová gramatika (APG)* je trojice

$$G_{AP} = (G_P, A, F)$$

kde $G_P = (N, \Sigma, \Delta, R, S)$ je překladová gramatika, A množina *atributů* a F množina *sémantických pravidel*. V případě, že je množina výstupních symbolů Δ prázdna, hovoříme pouze o *atributové gramatice*.

Pro každý symbol $X \in N \cup \Sigma \cup \Delta$ jsou dány dvě (případně prázdňou) disjunktivní množiny množina $I(X)$ *dědičných atributů* a množina $S(X)$ *syntetizovaných atributů*, přičemž pro $a \in I(S)$ jsou zadány počáteční hodnoty (dědičné atributy startovacího nonterminálu) a pro terminální symboly $X \in \Sigma$ je $I(X) = \emptyset$ (terminální symboly nemají dědičné atributy) a jejich syntetizované atributy jsou zadány.

Nechť r -té pravidlo gramatiky má tvar $iX_0 \rightarrow X_1X_2 \dots X_n$, kde $X_0 \in N$, $X_i \in N \cup \Sigma \cup \Delta$ pro $1 \leq i \leq n$. Pak

a) pro každý symbol X_k , $1 \leq k \leq n$ na pravé straně pravidla r a jeho dědičný atribut $d \in I(X_k)$ je dáno sémantické pravidlo

$$d = f_r^{d,k}(a_1, a_2, \dots, a_n)$$

kde a_i , $1 \leq i \leq n$ jsou atributy symbolů v témtěž pravidle r ,

b) pro každý syntetizovaný atribut s symbolu X_0 na levé straně pravidla r je dáno sémantické pravidlo

$$s = f_r^{s,0}(a_1, a_2, \dots, a_n)$$

kde a_i , $1 \leq i \leq n$ jsou pouze dědičné atributy symbolu $X_k \in \Delta$.

PRÁVIDLA	SEMANTICKÁ PRÁVIDLA
$E_0 \rightarrow E_1 + T$	$E_0.val = E_1.val + T.val$
$E \rightarrow T$	$E.val = T.val$
$T_0 \rightarrow T_1 * F$	$T_0.val = T_1.val * F.val$
$T \rightarrow F$	$T.val = F.val$
$F \rightarrow (E)$	$F.val = E.val$
$F \rightarrow \text{num}$	$F.val = \text{num}.ival$

Obrázek 4.2: Atributová gramatika pro aritmetický výraz

Sémantická pravidla realizujeme obvykle příkazy (funkce) vhodného vyššího programovacího jazyka (např. C nebo Pascal). Atributy pak chápeme jako proměnné či parametry jistého datového typu.

V dalším textu budeme atributy symbolů pojmenovávat kvalifikovaným jménem ve tvaru $X.a$, kde X je jméno symbolu a a jméno atributu. Sémantické funkce budeme psát vždy za pravidlem gramatiky, k němuž se vztahují. V případě, že se v jednom pravidle bude vyskytovat určitý symbol vícekrát, rozlišíme jednotlivé výskytu pomocí indexu.

Příklad 4.3. Atributová gramatika na obr. 4.2 popisuje aritmetický výraz tvorený celočíselnými konstantami, operátory +, * a závorkami. Nonterminály E , T a F mají celočíselný syntetizovaný atribut val , který udává hodnotu příslušného podvýrazu, syntetizovaný atribut $ival$ terminálního symbolu num udává hodnotu celočíselné konstanty získanou z lexikální analýzy. Jednotlivá sémantická pravidla počítají hodnotu atributu val nonterminálu na levé straně z hodnot val symbolů na pravé straně pravidel gramatiky.

Vyhodnocení sémantických pravidel definuje hodnoty atributů užlů derivačního stromu pro vstupní řetězec. Derivační strom s hodnotami atributů v každém uzel nazýváme ohodnocený derivační strom. Proces výpočtu hodnot atributů v uzel nazýváme ohodnocením derivačního stromu.

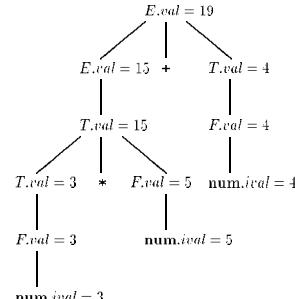
Příklad 4.4. Atributová gramatika z příkladu 4.3 vypočte hodnotu aritmetického výrazu s desetičinnými čísly, závorkami a operátory + a *. Například pro výraz $3 * 5 + 4$ vypočte hodnotu 19 jako hodnotu atributu $E.val$ startovacího nonterminálu E . Obr. 4.3 obsahuje ohodnocený derivační strom pro vstup $3 * 5 + 4$.

Abychom ukázali, jak se atributy vyhodnocují, uvažujeme levý dolní vnitřní uzel, odpovídající použitému pravidlu $F \rightarrow \text{num}$. Odpočívající sémantické pravidlo $F.val := \text{num}.ival$ přidělí atributu $F.val$ v tomto uzel hodnotu 3, neboť hodnota $\text{num}.ival$ následujícího uzel je 3. Podobně v předešlém tohoto F-užlu má atribut $T.val$ hodnotu 5. Nyní uvažujeme uzel pro pravidlo $T \rightarrow T * F$. Hodnota atributu $T.val$ v tomto uzel je definována jako

PRÁVIDLO	SÉMANTICKÉ PRÁVIDLO
$T_0 \rightarrow T_1 * F$	$T_0.val := T_1.val * F.val$

Pokud aplikujeme na tento uzel uvedené sémantické pravidlo, bude mít $T_1.val$ hodnotu 3 levého následníka a $F.val$ hodnotu 5 pravého následníka. $T_0.val$ tedy dostane v tomto uzel hodnotu 15. Konečně pro startovací nonterminál E se podobným způsobem vypočte hodnota 19.

Sémantické funkce z definice atributové gramatiky nám z matematického hlediska umožňují pouze vyhodnocovat atributy a předávat je mezi jednotlivými symboly gramatiky



Obrázek 4.3: Ohodnocený derivační strom pro $3 * 5 + 4$

bez možnosti využití vedlejších efektů (např. výstupní operace, práce s globálními proměnnými apod.). Pokud připustíme, aby sémantické funkce měly vedlejší efekty, hovoříme o *syntaxi řízené definici* (SDD).

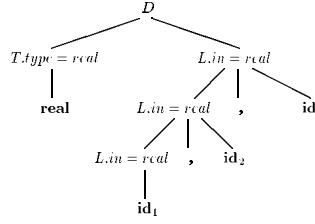
Příklad 4.5. Deklarace generování nonterminálu D v syntaxi řízené definici na obr. 4.4 se skládá z klíčového slova $real$ nebo $read$ následovaného sezonem identifikátorů. Nonterminál L má syntetizovaný atribut $type$, jehož hodnota je určena klíčovým slovem v deklaraci. Sémantické pravidlo $L.in := T.type$, svázané s pravidlem $D \rightarrow T L$, nastavuje dědičný atribut $L.in$ na hodnotu typu v deklaraci. Pravidla přenášejí tento typ dohoda derivačního stromu pomocí dědičného atributu $L.in$. Pravidla spojená s pravidlem gramatiky pro L volají proceduru $addtype$, která připojí typ k položce tabulky symbolů pro každý identifikátor (na položku ukazuje atribut $entry$).

Obr. 4.5 ukazuje ohodnocený derivační strom pro větu $real id_1.id_2.id_3$. Hodnota $L.in$ ve třech L -uzlech má typ identifikátorů id_1 , id_2 a id_3 . Tyto hodnoty se určí výpočtem hodnoty atributu $L.type$ levého následníka kořene a pak výpočtem $L.in$ shora dolů ve třech L -uzlech pravého podstromu kořene. V každém L -uzlu také voláme proceduru $addtype$, která

PRÁVIDLO	SEMANTICKÉ PRÁVIDLO
$D \rightarrow T L$	$L.in := T.type$
$T \rightarrow \text{int}$	$T.type := \text{integer}$
$T \rightarrow \text{real}$	$T.type := \text{real}$
$L \rightarrow L_1.id$	$L_1.in := L.in$
$L \rightarrow \text{id}$	$addtype(id.entry, L.in)$ $addtype(id.entry, L.in)$

Obrázek 4.4: Syntaxi řízená definice s dědičným atributem $L.in$

uloží do tabulky symbolů informaci o tom, že identifikátor v pravém podstromu uzlu má typ *real*. ■

Obrázek 4.5: Derivační strom s dědičnými atributy v uzlech *L*

4.2.2 Graf závislostí

Sémantická pravidla udávají závislosti mezi atributy. Tyto závislosti reprezentujeme *grafem závislosti* (dependency graph), ze kterého pak můžeme odvodit pořadí vyhodnocení sémantických pravidel. Závislý atribut *b* u uzlu derivačního stromu na atributu *c*, pak musí být sémantické pravidlo pro *b* vyhodnoceno po sémantickém pravidlu definujícím *c*.

Jestě před tím, než začneme konstruovat graf závislostí k danému derivačnímu stromu, převedeme všechna sémantická pravidla do tvary $b := f(c_1, c_2, \dots, c_k)$ závěrem prázdného syntetizovaného atributu *b* pro všechna sémantická pravidla tvořená voláním procedury. Graf obsahuje ke každému atributu jeden uzel a hranu vedoucí z uzlu *b* do uzlu *c*, pokud atribut *b* závisí na atributu *c*. Graf závislostí lze konkrétně vytvořit následujícím způsobem:

```

for každý uzel n derivačního stromu do
  for každý atribut a symbolu gramatiky v n do
    vytvořit uzel grafu závislosti pro a;
  for každý uzel n derivačního stromu do
    for každé sémantické pravidlo b :=  $f(c_1, c_2, \dots, c_k)$ 
      spojené s pravidlem použitým v n do
        for i := 1 to k do
          vytvořit hranu z uzlu pro ci do uzlu pro b;
  
```

Předpokládejme například, že $A.a := f(X.x, Y.y)$ je sémantické pravidlo k pravidlu gramatiky $A \rightarrow X.Y$. Toto pravidlo definuje syntetizovaný atribut *A.a*, jež závisí na atributech $X.x$ a $Y.y$. Je-li takový pravidlo použito v derivačním stromu, budeme mít v grafu závislosti tři uzly *A.a*, $X.x$ a $Y.y$ a hranou vedoucí z *A.a* do $X.x$ (*A.a* závisí na $X.x$) a hranou z *A.a* do $Y.y$ (*A.a* závisí také na $Y.y$).

Je-li s pravidlem $A \rightarrow X.Y$ spojeno sémantické pravidlo $X.i := g(A.a, Y.y)$, bude graf závislosti obsahovat hranu do *A.a* z $X.x$ a také do *A.a* z $Y.y$, neboť $X.i$ závisí jak na *A.a*, tak na $Y.y$.

4.3. VYHODNOCENÍ S-ATRIBUTOVÝCH DEFINIC ZDOLA NAHORU

podle jejich čísel. Na základě topologického sortu pak můžeme zapsat následující program. (Pro atribut svázaný s uzlem *n* grafu závislosti budeme používat označení a_n .)

```

a1 := real;
a2 := a1;
addtype(id3, entry, a5);
a3 := a5;
addtype(id2, entry, a7);
a4 := a7;
addtype(id1, entry, a9);
  
```

Vyhodnocením téhoto sémantických pravidel vložíme do tabulky symbolů pro všechny deklarované identifikátory typ *real*. ■

Pro vyhodnocování sémantických pravidel bylo navrženo několik metod.

- Metody derivačního stromu.** Tyto metody získávají pořadí vyhodnocení sémantických pravidel v čase překladu k topologickému sortu grafu závislosti, vytvoreného z derivačního stromu po každý vstupní text. Pořadí vyhodnocení tyto metody najdoušou pouze v případě, že graf závislosti pro uvažovaný derivační strom obsahuje cyklus.
- Metody založené na pravidlech.** V době vytváření překladače se analyzují sémantická pravidla spojená s pravidly gramaticky ručně nebo speciálně upravenými prostředky. Pro každé pravidlo gramatiky je pořadí, ve kterém se budou vyhodnocovat příslušné atributy, pevně určeno již při návrhu překladače.
- Nezávislé metody.** Pořadí vyhodnocení se vybere bez ohledu na sémantická pravidla. Například probíhá překlad během syntaktické analýzy, je pořadí vyhodnocení dáné použitím metodu překladu, nezávislé na sémantických pravidlech. Nezávislé pořadí vyhodnocování omezuje třídu syntaxí fixených definic, jež mohou být implementovány.

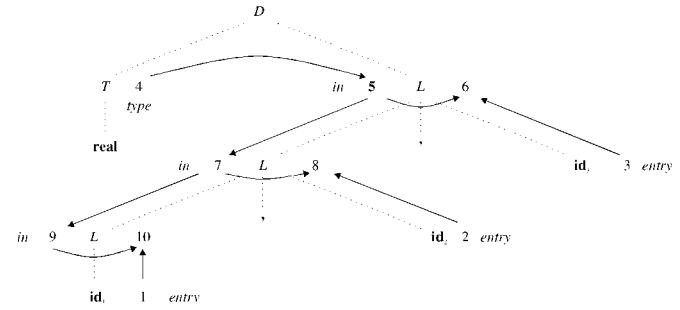
Metody založené na pravidlech a nezávislé metody nemusí explicitně konstruovat během překladu graf závislostí, takže mohou být efektivněji s ohledem na dobu překladu i velikost požadované paměti.

4.3 Vyhodnocení S-atributových definic zdola nahoru

Vytvoření překladače pro obecnou syntaxí řízenou definicí může být značně obtížným problémem. Existují však dosti rozsáhlé třídy se speciálními vlastnostmi, pro které lze překladač implementovat jednoduše. Jedenou z nich jsou S-atributové definice, tj. takové definice, které pracují pouze se syntetizovanými atributy.

Syntetizované atributy můžeme vyhodnocovat současně s analýzou zdrojového textu zdola nahoru. Atributy mohou být uloženy společně s ostatními informacemi, které používá analyzátor, na zásobníku. Při každé redukci podle nějakého pravidla se vypočítají atributy nontermínálního symbolu na levé straně pravidla a ty se uloží do zásobníku. Atributy symbolů na pravé straně jsou v okamžiku redukce umístěny na vrcholu zásobníku, takže jsou pro výpočet vždy k dispozici. Při vhodném návrhu překladového schématu je možné pracovat v omezené míře i s dědičnými atributy, jak dále ukážeme.

Syntaktický analyzátor pracující metodou zdola nahoru používá pro uchovávání informací o průběhu analýzy zásobník. Položky zásobníku můžeme rozšířit vždy o hodnotu atributu.



Obrázek 4.6: Graf závislostí

Příklad 4.6. Obr. 4.6 ukazuje graf závislosti pro derivační strom na obr. 4.5. Užly v grafu závislosti jsou označeny čísly; tato čísla budeme používat dále. Pro *L.in* zde máme hrany vedoucí do uzlu 5 z uzlu 4 pro *T.type*, neboť dědičný atribut *L.in* závisí na atributu *T.type* na základě sémantického pravidla $L.in := T.type$ pro pravidlo gramatiky $D \rightarrow T.L$. Dvě hrany vedoucí do uzlu 7 a 9 vyplývají ze závislosti $L.in$ na *L.in* podle sémantického pravidla $L.in := L.in$ pro pravidlo gramatiky $L \rightarrow L_1.id$. Sémantické pravidlo *addtype(id.entry, L.in)* spojené s *L*-pravidly vede k vytvoření prázdného atributu. Uzly 6, 8 a 10 byly vytvořeny právě pro tyto prázdné atributy. ■

4.2.3 Pořadí vyhodnocení pravidel

Definice 4.5. *Topologický sort* orientovaného acyklického grafu je libovolné uspořádání m_1, m_2, \dots, m_k uzlů grafu takové, že hranu vedou z uzlu uvedených dříve do uzlu uvedených později; to znamená, že je-li $m_i \rightarrow m_j$ hrana z m_i do m_j , potom se m_i vyskytuje v tomto uspořádání před m_j . ■

Libovolný topologický sort grafu závislosti je použitelný jako pořadí, v němž se můží vyhodnocovat sémantická pravidla spojená s uzly derivačního stromu. V topologickém sortu jsou závislé atributy c_1, c_2, \dots, c_k v sémantickém pravidle $b := f(c_1, c_2, \dots, c_k)$ k dispozici ještě před vyhodnocením f .

Překlad specifikovaný syntaxí řízenou definicí můžeme provést následujícím způsobem. Pro vytvoření derivačního stromu k zadávanému vstupu použijeme východisko gramatiky. Podle předchozího algoritmu vytvoříme graf závislosti. Z topologického sortu grafu závislosti získáme pořadí vyhodnocení sémantických pravidel a vyhodnocení sémantických pravidel v tomto pořadí získáme překlad vstupního řetězce.

Příklad 4.7. Hranu v grafu závislosti na obr. 4.6 vycházejí vždy z uzlu s nižším číslem do uzlu s vyšším číslem. Topologický sort grafu závislosti tedy získáme zapsáním uzlů v pořadí

state	val
...	...
X	X.e
Y	Y.y
Z	Z.z
...	...

Obrázek 4.7: Rozšířený zásobník syntaktického analyzátoru

jak ukazuje obr. 4.7. Každá položka odpovídá vždy jednomu symbolu v jíž zpracované části vstupní formy; tento symbol je uveden ve sloupci *state*. Ve sloupci *val* je pak uvedena hodnota atributu odpovídajícímu symbolu z pravidla sloupcem *state*. Jinou možnou implementací je použít dvou paralelních zásobníků, jednoho pro uchovávání informací o analýze a druhého pro atributy. Pokud může mít jeden symbol více atributů, můžeme je všechny umístit do jednoho zásobníku a tento nový datový typ pak používat jako jediný (struktuřovaný) atribut. Rovněž můží různé symboly různé typy atributů, můžeme všechny tyto typy sloučit do jediného pomocí základního s variantařní složkou, můžeme nebo podobně konstrukce, kterou pro to poskytuje implementační jazyk.

Současný vrchol zásobníku je označen ukazatelem *top*. Předpokládáme, že se syntetizovaný atribut vyhodnocuje právě před provedenou redukcí. Máme-li například s pravidlem $A \rightarrow XYZ$ svažitelné sémantické pravidlo $A.a := f(X.e, Y.y, Z.z)$, je před redukcí atribut $Z.z$ uložen ve *val[top]*, atribut $y.y$ ve *val[top - 1]* a atribut $X.e$ ve *val[top - 2]*. Pokud symbol nemá atribut, není odpovídající hodnota pole *val* definována. Po redukcí se hodnota *top* sníží o 2, stav odpovídající *A* se uloží do *val[top]* (tj. místo X) a vypočtená hodnota syntetizovaného atributu *A.a* se uloží do *val[top]*.

Příklad 4.8. Uvažujeme gramatiku z obr. 4.2 po výpočtu hodnoty aritmetického výrazu. Tato gramatika pracuje pouze se syntetizovanými atributy a může být tedy implementována přímo při překladu zdola nahoru. Opráť předpokládáme, že lexikální analyzátor dodá hodnotu atributu *num.val*: tuto hodnotu uložíme do zásobníku při provádění akce přesun. Obr. 4.8 uvádí možnou implementaci sémantických akcí s atributovým zásobníkem v poli *val*.

PRAVIDLA	SEMANTICKÁ AKCE
$E \rightarrow E_1 + T$	$val[ntop] := val[top - 2] + val[top]$
$E \rightarrow T$	
$T \rightarrow T_1 * F$	$val[ntop] := val[top - 2] * val[top]$
$T \rightarrow F$	
$F \rightarrow (E)$	$val[ntop] := val[top - 1]$
$F \rightarrow num$	

Obrázek 4.8: Implementace aritmetického výrazu pomocí atributového zásobníku

Uvedený úsek kódů pro sémantické akce nefiguruje nastavování proměnných *top* a *ntop*. Provádí-li se redukce podle pravidla s *r* hodnotami na pravé straně, nastaví se *ntop* na

$top - r + 1$ a po provedení akce se top nastaví na $utop$. Ještě vhodnejší řešení je použít pro syntetizovaný atribut levé strany pravidla zvláštní proměnnou, která se pak přesune do zásobníku až po dokončení výpočtu. Obr. 4.9 ukazuje posloupnost akcí překladače při vstupu $2+3*5$.

STUP	STATE	VAL	POUŽITE PRAVIDLO
2+3*5	- -	- -	
+3*5	2	2	
+3*5	F	2	$F \rightarrow \text{num}$
+3*5	T	2	$T \rightarrow F$
+3*5	E	2	$E \rightarrow T$
3*5	E *	3 -	
*5	E + 3	2 - 3	
*5	E * F	2 - 3	$F \rightarrow \text{num}$
*5	E + T	2 - 3	$T \rightarrow F$
5	E + T *	2 - 3 -	
	E + T * 5	2 - 3 - 5	
	E + T * F	2 - 3 - 5	$F \rightarrow \text{num}$
	E + T	2 - 15	$T \rightarrow T + F$
	E	17	$E \rightarrow E + T$

Obrázek 4.9: Analýza a vyhodnocení výrazu $2+3*5$

Po implementaci S-attributových definic je možné použít generátora yacc. Implicitně yacc predpokládá, že všechny symboly jazyka mají jeden atribut typu `int`. Syntetizované atributy symbolů na pravé straně pravidla jsou dostupné pod symbolickým jménem $\$i$, kde i je pořadové číslo symbolu počínaje 1. Atribut levostranného nonterminálu se ukládá do proměnné se symbolickým jménem $\$S$. Nemá-li některé pravidlo uvedeno sémantickou akci, provede se implicitně akce $\{ \$S = \$1; \}$, která předá atribut prvního symbolu v pravidle jako atribut levé strany. Na obr. 4.10 je uvedeno totéž překladové schéma jako na obr. 4.8 zapsané pro generátory yacc.

```
%term NUM
%%
E : E '+' T { $$ = $1 + $3; }
| T ;
T : T '*' F { $$ = $1 * $3; }
| F ;
F : '(' E ')' { $$ = $2; }
| NUM ;
;
```

Obrázek 4.10: Specifikace překladu se syntetizovanými atributy pro yacc

Pokud potřebujeme jako atribut použít jiného datového typu, například v případě našeho aritmetického výrazu typ `double`, stačí do úvodní části specifikace doplnit text

4.4 L-attributové definice

Mnohem širší řídík syntaxí řízených definic jsou L-attributové definice, jejichž atributy se mohou vždy vypočítat během jediného průchodu analyzátoru zdrojovým textem. Tato řídík zahrnuje všechny syntaxí řízené definice založené na LL(1) gramatickách; po určitých úpravách je lze použít i při překladu zdola nahoru. Následující definice specifikuje vlastnosti L-attributových definic.

Definice 4.6. Syntaxí řízená definice je *L-attributová*, jestliže všechny dědičné atributy symbolů X_1, \dots, X_n na pravé straně pravidla $A \rightarrow A_1X_1 \dots X_n$ závisí pouze na

- atributech symbolů X_1, X_2, \dots, X_{j-1} vlevo od X_j v téžemž pravidle a
- dědičných atributech symbolu A na levé straně pravidla.

Poznamenajme, že každá S-attributová definice je zároveň L-attributová, neboť uvedená omezení se vztahuji pouze na dědičné atributy.

Pro zápis L-attributových definic zavedeme pojmenování *překladové schéma* jako syntaxí řízenou definici, která umožňuje zápis sémantických akcí kolikrát uvnitř pravé strany pravidla. Tuto sémantickou akce budeme uvažovat do složených závorek a budeme předpokládat, že se provodou vždy před analýzou symbolů, které za nimi následují. Překladová schéma nám umožní definovat explicitně pořadí vyhodnocení sémantických akcí.

Příklad 4.10. Překlad výrazu s operátorem sčítání a celočíselnými konstantami můžeme popsat pomocí následujícího překladového schématu:

```
E → T R
R → + T {print('+'')} R1 | ε
T → num {print(num.cal)}
```

Při návrhu překladových schémat musíme dbát na to, aby hodnota každého atributu byla dostupná v okamžiku, kdy se na ní odkazujeme. Obecně pokud máme dědičné i syntetizované atributy, je třeba dodržovat následující pravidla:

- Dědičný atribut symbolu na pravé straně pravidla se musí vypočítat akcí umístěnou před tímto symbolem.
- Akce se nesmí odkazovat na syntetizovaný atribut symbolu vpravo od ní.
- Syntetizovaný atribut symbolu na levé straně pravidla se může vypočítat až tehdy, jakmile ji disponuje hodnoty všech atributů, které používá. Výpočet tohoto atributu se obvykle umisťuje na konec pravé strany pravidla.

Následující překladové schéma nedodržuje první z uvedených tří podmínek:

```
S → A1 A2 {A1.in := 1; A2.in := 2}
A → a {print(A.in)}
```

Dědičný atribut $A.i$ ve druhém pravidle totiž není v okamžiku pokusu o jeho tisk při analýze řetězce aa definován, pokud procházíme derivačním stromem do hloubky. Příchod začne

```
%{
#define YYSTYPE double
%}
```

V praktických situacích však obvykle nevystačíme s jediným typem atributu pro všechny symboly. Jak již bylo uvedeno dříve, můžeme typ atributu definovat jako union několika různých typů. K tomu nabízí yacc své vlastní prostředky, které mnohem zjednoduší zápis sémantických akcí. V definici části specifikace můžeme uvést deklaraci všech složek unie, například

```
%union
{ int ival;
  double rval;
}
```

kterou definuje celočíselný atribut $ival$ a reálný atribut $rval$. Dále musíme uvést pro každý terminální a nonterminální symbol s atributem jméno jeho atributu (jméno odpovídající složky unie). Toto jméno pak bude yacc vždy automaticky přidávat ke všem odkazům na atributy příslušných symbolů a zároveň bude kontrolovat, zda jsou definovány typy atributů, na které se v sémantických pravidlech odkazujeme. Definice typu atributu pro terminální symboly se uvádí v lomených závorkách bezprostředně za klíčovým slovem `%term` a platí pro všechny terminální symboly definované za tímto klíčovým slovem. Pro nonterminální symboly se používá obdobná syntaxe s klíčovým slovem `%type`.

Příklad 4.9. Rozšíříme gramaturu z příkladu 4.8 o reálné konstanty s tím, že výpočet hodnoty výrazu se bude zvlášť provádět v polyfylivé čárci. K tomu budeme potřebovat atribut $ival$ typu `int` pro celočíselné konstanty (symbol `INUM`) a atribut $rval$ typu `double` pro reálné konstanty a nonterminální. Výsledná specifikace pro yacc je uvedena na obr. 4.11. ■

```
%union { int ival; double rval; }
%term <ival> INUM
%term <rval> RNUM
%type <rval> E T F
%%
E : E '+' T { $$ = $1 + $3; }
| T ;
T : T '*' F { $$ = $1 * $3; }
| F ;
F : '(' E ')' { $$ = $2; }
| INUM ;
;
```

Obrázek 4.11: Specifikace překladu s atributy různých typů

uzlen S a dále pokračuje v uzlech A_1 a A_2 ještě před tím, než se nastaví hodnoty $A_1.in$ a $A_2.in$. Umístění akci definující hodnoty $A_1.in$ a $A_2.in$ mezi symboly A na pravé straně pravidla $A \rightarrow A_1A_2$, bude $A.in$ již v okamžiku tisku definováno.

V případě, že máme L-attributovou syntaxí řízenou definici, lze z ní vždy vytvořit překladové schéma, jež splňuje uvedené tři požadavky.

4.5 Překlad shora dolů

V této části si ukážeme, jak lze implementovat L-attributové definice během prediktivní analýzy. Budeme pracovat spíše s překladovými schématy než se syntaxí řízenými definicemi, neboť se nám umožní využít explicitně pořadí akcí a výpočtu atributů. Ukážeme si také, jak se dá odstranit levá rekurence z překladového schématu se syntetizovanými atributy.

4.5.1 Odstranění levé rekurencie z překladového schématu

Mnoho aritmetických operátorů je asociativních zleva, takže je přirozené pro jejich syntaxi použít zleva rekurevní gramaturu. Následující postup umožňuje odstranit levou rekurenci z překladového schématu se syntetizovanými atributy. Předpokládejme, že máme následující překladové schéma:

```
A → A1 Y {A.a := g(A1.a, Y.y)}
A → X {A.a := f(X.x)}
```

Všechny symboly mají syntetizované atributy pojmenované odpovídajícím písmenem malé abecedy, f a g jsou libovolnou funkce.

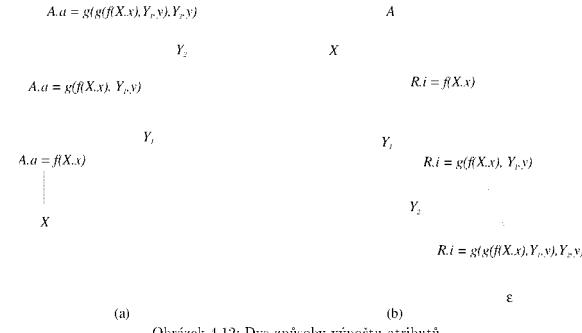
Algoritmem pro odstranění levé rekurenci býchom z (4.2) dostali následující gramaturu:

```
A → X R
R → Y R | ε
```

Uvažujeme-li sémantické akce, získáme transformované schéma:

```
A → X {R.i := f(X.x)}
R → Y {R.i := g(R.s, Y.y)}
R → ε {R.s := R.i}
```

Transformované schéma používá pro R atributy i a s . Aby bylo zřejmé, že výsledky (4.2) a (4.4) jsou shodné, uvažujeme dva ohodnocené derivační stromy z obr. 4.12. Hodnota $A.a$ se na obr. 4.12(a) počítá podle (4.2). Obr. 4.12(b) obsahuje výpočet $R.i$ podle (4.4) při příchodu stromem směrem dolů. Hodnota $R.i$ se potom předává nahoru bezeměny jako $R.s$ a nakonec se stane hodnotou atributu $A.a$ v kořeni ($R.s$ není na obr. 4.12(b) zakreslen).



Obrázek 4.12: Dva způsoby výpočtu atributů

4.5.2 Implementace prediktivního syntaxí řízeného překladače

L-attributové definice, jak již bylo uvedeno, umožňují vyhodnocení atributů v jediném průchodu již během syntaktické analýzy. Pro jejich implementaci můžeme použít metodu rekurezního sestupu, která byla popsána v předešlém kapitole: rozšíříme ji pouze o sémantické akce a atributy. Atributový zásobník bude v tomto případě implementován podobně jako syntaktický zásobník pomocí implicitního zásobníku implementačního jazyka.

Atributy nonterminálních symbolů můžeme při rekurezném sestupu reprezentovat jako parametry příslušných procedur. Dědičné atributy při tomto přístupu budou představovat vstupní parametry procedury (i_j), parametry předávané hodnotou, syntetizované atributy naopak budou výstupními parametry (t_j , budou předávány odkazem). V některých speciálních případech můžeme též parametry předávaného odkazem použít zároveň pro dva atributy jeden dědičný a jeden syntetizovaný.

Atributy terminálních symbolů se vytvářejí v lexikálním analyzátoru a předávají se obvykle v globálních proměnných. Obsah příslušné globální proměnné můžeme podle potřeby uchovávat pro pozdější použití do lokální proměnné definované uvnitř procedury.

Sémantické akce můžeme zapsat přímo na odpovídající místa v procedury. Je však třeba dát na to, aby se definovaly hodnoty všech syntetizovaných atributů levostranného nonterminálu (i_j , hodnoty všech parametrů předávaných odkazem) i v případě, že dojde k syntaktické chybě, ze které se překladač zotaví. Pro tyto účely lze často použít speciálních hodnot atributů, které mohou být dále identifikovány a se kterými lze dále pracovat jako s neznámou informací.

Příklad 4.11. Uvažujme následující překladové schéma pro vyhodnocení výrazů s aditivními operátory a celocíselními konstantami.

$$E \rightarrow T \{ R.i := T.val \} R \{ E.val := R.s \}$$

4.6. VYHODNOCENÍ DĚDIČNÝCH ATRIBUTŮ ZDOLA NAHORU

```
procedure E(var val: integer);
var val1: integer;
begin
    T(val1);
    R(val1, val)
end;
procedure R(i: integer; var s: integer);
var op: char;
    val: integer;
begin
    if sym in ['+', '-'] then begin
        op := lexop;
        T(val1);
        if op = '+' then
            R(i + val1, s)
        else
            R(i - val1, s)
    end
    else
        s := i
end;
procedure T(var val: integer);
begin
    if sym = NUM then begin
        val := lexical;
        sym := lex
    end
    else
        error;
end;
```

Obrázek 4.13: Implementace překladového schématu rekurezním sestupem

Pokud pracujeme s dědičnými atributy, můžeme využít toho, že během analýzy nonterminálu Y v pravidle $A \rightarrow XY$ jsou na zásobníku stále k dispozici atributy symbolu X . Pokud je například dědičný atribut $Y.i$ symbolu i definován pravidlem $Y.i := X.s$, kde $X.s$ je atribut symbolu X , můžeme místo hodnoty $Y.i$ vůbec použít $X.s$. Důležité je, aby tento atribut byl v zásobníku vždy na stejném místě.

Příklad 4.13. Uvažujme následující překladové schéma pro deklarace proměnných typu *integer* a *real*.

$$\begin{aligned} R &\rightarrow \text{addop } T \{ \\ &\quad \text{if addop.op} = \text{add then} \\ &\quad \quad R_1.i := R.i + T.val \\ &\quad \text{else} \\ &\quad \quad R_1.i := R.i - T.val \} \\ &\quad R_1 \{ R.s := R_1.s \} \\ &\quad | \quad \epsilon \{ R.s := R.i \} \\ T &\rightarrow \text{num } \{ T.val := \text{num}.val \} \end{aligned}$$

Symbol **addop** má atribut *op* s hodnotou '+' nebo '-'; jeho hodnota bude uložena v globální proměnné *leop*. Termínální symbol **num** představující celočíselnou konstantu má atribut *ival*, jehož hodnota lexikální analýzátorem uloží do globální proměnné *leical*. Implementace tohoto překladového schématu je na obr. 4.13.

Nonterminál R má dědičný atribut i , jehož hodnotu je vždy levý operand součtu nebo rozdílu, a syntetizovaný atribut s představující mezičíslodelek výpočtu hodnoty celého výrazu. Tyto dva atributy bychom mohli sloužit do jediného parametru procedury R a tím celou implementaci zjednodušit. Povídáme si, že některé sémantické akce, spočívající pouze v přiřazení hodnoty atributu, nejsou zapsány explicitně jako přířazovací příkazy – například akce $\{R.i := T.val\}$ v pravidle pro nonterminál E se realizuje předáním hodnoty proměnné *val* jako argumentu procedury R . ■

4.6 Vyhodnocení dědičných atributů zdola nahoru

Pokud chceme implementovat L-attributovou definici během překladu zdola nahoru, narazíme na jeden zásadní rozdíl od přípravy shora dolů. Během analýzy zdola nahoru je pravidlo, podle kterého se bude redukovat, známo až v okamžiku redukce, tj. při dosažení jejího konce. To znamená, že všechny sémantické akce můžeme provádět až na konci pravidla. Přesto pomocí určitých transformací můžeme převést všechny L-attributovou definice založenou na LL(1) gramatickách do tvary, který lze metodou zdola nahoru implementovat. Tyto transformace lze rovněž použít i na některé (ovšem ne všechny) definice založené na LR(1) gramatickách.

První užitečnou transformací je odstranění sémantických akcí, které jsou uvnitř pravidla. Tato transformace vkládá do původní gramaticky tzv. *marker*, nonterminální symbol generující prázdný tetézec ϵ . Každou sémantickou akci, která je uvnitř pravé strany pravidla, nahradíme novým markerem M a původní sémantickou akci přidáme na konec pravidla $M \rightarrow \epsilon$.

Příklad 4.12. Překladové schéma z příkladu 4.10 můžeme převést do tvary

$$\begin{aligned} E &\rightarrow T \ R \\ R &\rightarrow + M \ R_1 \ | \ \epsilon \\ T &\rightarrow \text{num } \{ \text{print}(\text{num}.val) \} \\ M &\rightarrow \epsilon \{ \text{print}('+) \} \end{aligned}$$

který je ekvivalentní původnímu, tj. obě gramaticky přijímají stejný jazyk a pro všechny vstupní řetězce se sémantické akce provedou vždy ve stejném pořadí. Sémantické akce jsou nyní na koncích pravidel, takže je můžeme provést bezprostředně před redukcí. ■

$$\begin{aligned} D &\rightarrow T \quad \{ L.in := T.type \} \\ L &\\ T &\rightarrow \text{int} \quad \{ T.type := \text{integer} \} \\ T &\rightarrow \text{real} \quad \{ T.type := \text{real} \} \\ L &\rightarrow \{ L.in := L.in \} \\ L_1 &, id \quad \{ addtype(id, entry, L.in) \} \\ L &\rightarrow id \quad \{ addtype(id, entry, L.in) \} \end{aligned}$$

V okamžiku redukce libovolný pravý strany nonterminálu L je na zásobníku symbol T bezprostředně před touto pravou stranou. Místo atributu *L.in*, který je definován kopirováním pravidlem $L.in := T.type$, tedy můžeme použít přímo atributu *T.type*. Uvedená schéma můžeme implementovat pomocí atributového zásobníku *val* tak, jak ukazuje obr. 4.14. Stejně jako na obr. 4.8 pronášená *top* obsahuje současný index vrcholu zásobníku a *nstop* index vrcholu zásobníku po provedení redukce. ■

PRÁVIDLO	SEMANTICKÁ AKCE
$D \rightarrow T \ L$	$\{ L.in := T.type \}$
$T \rightarrow \text{int}$	$\{ T.type := \text{integer} \}$
$T \rightarrow \text{real}$	$\{ T.type := \text{real} \}$
$L \rightarrow L_1, id$	$\{ L_1.in := L.in \}$
$L \rightarrow id$	$\{ addtype(id, entry, L.in) \}$

Obrázek 4.14: Implementace dědičných atributů při analýze zdola nahoru

Používáme-li pro generování syntaktického analyzátoru programu yacc, můžeme k atributům symbolů, které leží na zásobníku před pravou stranou, přistupovat stejně jako k atributům symbolů redukovaného pravidla pomocí zápisu $\$i$, kde i je index symbolu. Tento index je roven nule pro první symbol před redukovanou pravou stranou, -1 pro předcházející atd. Schéma z příkladu 4.13 tedy můžeme pro yacc zapsat tak, jak ukazuje obr. 4.15.

Z	term INT REAL ID
D :	$T \ L$;
T :	$\text{INT } \{ \$\$ = \text{integer}; \}$
L :	$\text{REAL } \{ \$\$ = \text{real}; \}$
	$ \text{ ID } \{ addtype(\$3, \$0); \}$
	$ \text{ ID } \{ addtype(\$1, \$0); \} ;$

Obrázek 4.15: Použití dědičných atributů v zápisu pro yacc

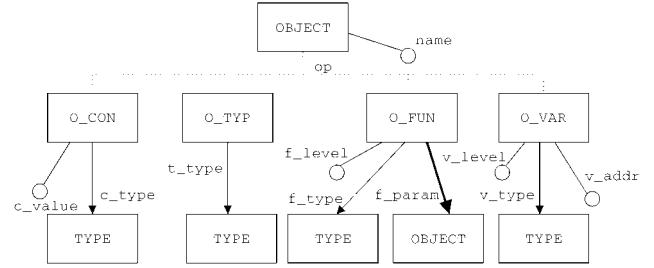
V případě, že používáme atributy různých typů, nedovede yacc odvodit sám typ atributu, který nepatří symbolu v pravidle, a je tedy třeba tento typ uvést explicitně zápisem $\$typ$. Yacc také umožňuje zápis sémantických akcí na libovolné místo pravé strany pravidla; případnou transformaci nahrazením sémantické akce markerem provede automaticky. Opět pokud má taková vnitřní akce syntetizovaný atribut a používáme-li typovaných atributů, je třeba uvést typ při všech odkazech na tento atribut.

programu, kterým můžeme reprezentovat jak deklarace, tak i příkazy nebo výrazy v programu (viz článek 8.1.1).

E-R graf je tvořen dvěma množinami uzlů. Jedna množina uzlů představuje základní sémantické entity (pojmenované objekty, typy, příkazy, výrazy atd.) a druhá množina uzlů představuje atributy entit. Hranou spojující jednotlivé entity vyjadruje relace mezi entitami. Relace mohou být typu 1:1 (např. relace "typ proměnné" přiřazuje entitu "proměnná" její právě jeden typ) nebo typu 1:N (např. relace "parametr procedury" přiřazuje entitu "procedura" uspořádanou množinou objektů, reprezentujících její parametry). Atributy jsou spojeny hranami s uzly, k nimž patří (např. entita "proměnná" může mít jako atribut svou relativní adresu).

Graficky budeme entity znázorňovat obdélníky, relace 1:1 slabšími, relace 1:N silnějšími šipkami a atributy malými kroužky spojenými s entitami hranou. Jeden atribut může obsluhovat různé varianty jedné entity (např. "objekt" může být "proměnná", "procedura", "návštěv" atd.), v tom případě tyto varianty nakreslíme jako samostatné entity spojené se společnou částí točkoványmi čarami.

Příklad 5.1. Obr. 5.1 představuje část E-R grafu pro pojmenované objekty v jazyce Pascal. Tabulka symbolů bude v tomto případě uchovávat informace o entitách OBJECT, jejichž atribut name bude představovat výhledovací klíč. Objekty mohou být konstanty, typy, funkce nebo proměnné. Příčemž atribut name představuje jiného pojmenovaného objektu a atribut op rozlišuje druh objektu. Všechny uvedené objekty mají relaci 1:1 definován typ funkce má navíc seznam parametrů reprezentovaný relací f_param typu 1:N.



Obrázek 5.1: E-R graf pro objekty jazyka Pascal

Další entitu, která se na obr. 5.1 používá, je TYPE, reprezentující datový typ. Pro tuento entitu můžeme vytvořit stejným postupem graf, jehož část je na obr. 5.2.

Implementace E-R grafu pomocí dynamických datových struktur je již jednoduchá. Každou entitu budeme reprezentovat jediným záznamem, který bude obsahovat společné atributy a relace a případně seznam jednotlivých variant této entity. Vazby typu 1:1 můžeme definovat

Kapitola 5

Tabulka symbolů

V tabulce symbolů se uchovávají informace o pojmenovaných objektech, deklarovaných explicitně (uživatelské typy, proměnné, procedury, návštěvi atd.) nebo implicitně (standardní typy, procedury a funkce, pomocnou proměnnou vytvořenou překladačem atd.). Tyto informace se využívají zejména k následujícím účelům:

- řešení kontextových vazeb v programu (vztah mezi deklarací a použitím objektu), kterou nelze popsat bezkontextovou gramatickou.
- provádění typové kontroly a
- generování intermediařního a cílového kódu.

Jednotlivé atributy objektů v tabulce symbolů jsou clány bud zdrojovým jazykem (např. jméno, druh, typ, počet parametrů procedury) nebo cílovým jazykem (např. velikost, adresu).

Tabulka symbolů se může vytvářet buď během sémantické analýzy a generování mezikódů — v tom případě předává lexikální analýzatorem všechna jména jako řetězec znaků, — nebo se může vytvářet již během lexikální analýzy, kdy jsou jména objektů reprezentována v příběhu celého překladu pouze jako ukazatele do tabulky. Samozřejmě ve druhém případě musí sémantická analýza doplnit do tabulky zhýrající údaje, které nemohou být po lexikální analýze ještě známy. Při jednodušším překladu může lexikální analýzator přímo vydělávat nalezené identifikátory v tabulce a umožnit syntaktické analýzy využívat pro rozhodování některých kontextově závislých informací, např. místo symbolu pro identifikátor vrátit speciální symbol pro identifikátor proměnné nebo procedury. Taková interakce lexikálního analyzátoru s tabulkou symbolů může vést ke zjednodušení gramatiky a zlepšení detekce a zotavení po kontextově závislých chybách, na druhé straně se ale súžuje modularita překladače.

5.1 Informace v tabulce symbolů

Kromě jména objektů obsahuje tabulka symbolů — jak již bylo uvedeno na začátku této kapitoly — další informace potřebné pro činnost překladače. Strukturu této informaci můžeme vyjádřit speciálním grafem, převzatým z teorie databázových systémů, tzv. E-R grafem (Entity Relationship Graph, viz [6]). Tento graf vyjadřuje sémantické vztahy mezi jednotlivými objekty a dá se v překladače písmeně implementovat pomocí dynamických datových struktur, jak si dalej ukážeme. E-R graf má při překladu mnohem širší použití než jen pro popis informací v tabulce symbolů, ve skutečnosti umožňuje definovat úplný sémantický model

stromová. Například samotná reprezentace datového typu ObjList vede k cyklu v grafu (obsahuje ukazatel sama na sebe). Pro příchod sémantickým grafem se proto musí využívat poněkud upravené algoritmy pro zpracování stromů.

5.2 Organizace tabulky symbolů

5.2.1 Operace nad tabulkou symbolů

Dvě nejdůležitější prováděcí operace nad tabulkou symbolů jsou operace *vkládání* (insertion) a *vyhledávání* (lookup, retrieval).

Operace vkládání do tabulky obecně nejprve zjistí, zda ukládaná hodnota klíče (v tomto případě objekt se stejným jménem) již v tabulce není. Pokud ne, vytvoří se nový záznam a zařadí se do tabulky. V opačném případě se může našelit chyba, např. "vícenásobné deklarován identifikátor." U některých jazyků však nalezené jména v tabulce nemusí znamenat chybou stav, např. v následujících případech:

- deklarace procedury v Pascalu, jejíž záhlaví už bylo uvedeno dříve s direktivou forward,
- deklarace objektu, který byl už v programu použit, a kterému byly přiděleny implicitní atributy (např. funkce nebo návštěvi příkaz v jazyce C).

Operace vkládání v tabulce obvykle vrátí informaci o tom, zda se objekt s požadovaným jménem v tabulce nachází, a v případě, že ano, vrátí rovněž nalezený objekt. Pokud objekt v tabulce není a zdrojový jazyk umožňuje implicitní deklarace, vytvoří se nový objekt s implicitními atributy, zařadí se do tabulky a vrátí se stejně, jako by v tabulce již byl.

V následujících odstavcích provedeme pouze přehled nejpoužívanějších metod. Implementace konkrétních algoritmů byla náplní kurzu Programovací techniky (viz [5]).

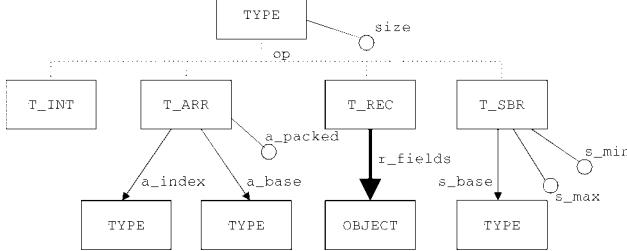
5.2.2 Implementace tabulek pro jazyky bez blokové struktury

Pro jazyky bez blokové struktury vystačíme s jediným adresovým prostorem pro všechny položky. Některé z dale uvedených metod se rovněž používají pro vyhledávání v tabulce. Základní implementační metody jsou:

- *Nesířené tabulky*. Nesířené tabulky (pole, seznamy) jsou z hlediska implementace nejednodušší. Položky do nich vkládáme v tom pořadí, jak jsou deklarovány. Ukládání i vyhledávání má však časovou náročnost $\mathcal{O}(n)$, kde n je počet položek v tabulce. Tato organizace se dá použít pouze tehdy, očekáváme-li malý počet položek.
- *Sířené tabulky s binárním vyhledáváním*. Používajeme-li pro tabulku symbolů seřazené pole, můžeme súžit časovou náročnost vyhledávání na $\mathcal{O}(\log_2 n)$, ovšem neznamí se časová náročnost vkládání, neboť musíme stále zajímat seřazenou tabulkou. Binární vyhledávání v seřazeném poli je výhodné právě pro tabulky klíčových slov, které jsou statické.
- *Stromové strukturované tabulky*. Stromové uspořádání tabulky symbolů redukuje dobu vkládání na $\mathcal{O}(\log_2 n)$. Doba vyhledávání se polýbuje mezi $\mathcal{O}(n)$ a $\mathcal{O}(\log_2 n)$, v závislosti na struktuře stromu. Tato doba je konstantní pro optimálně vyvážené stromy, které však vyžadují značně složité algoritmy vkládání. Proto se velmi často používají různá suboptimální řešení, nejčastěji AVL stromy.

5.1. INFORMACE V TABULCE SYMBOLŮ

Obrázek 5.2: E-R graf pro datové typy jazyka Pascal



jako ukazatele na příslušné typy entit, vazby 1:N jako ukazatele na první položku seznamu entit.

Příklad 5.2. Entitu OBJECT z příkladu 5.1 můžeme v Pascalu reprezentovat následujícimi datovými typy:

```

type
  Objects = ( O_CON, O_TYP, O_FUN, O_VAR );
  ObjList = record
    ent: ^ObjEnt;
    next: ^ObjList;
  end;
  ObjEnt = record
    name: String;
    case op: Objects of
      O_CON: ( c_value: Value;
                c_type: ^TypeEnt );
      O_TYP: ( t_type: ^TypeEnt );
      O_FUN: ( f_level: Integer;
                f_type: ^TypeEnt;
                f_param: ^ObjList );
      O_VAR: ( v_level: Integer;
                v_addr: Integer;
                v_type: ^TypeEnt );
    end;
  TypeEnt = ...
  
```

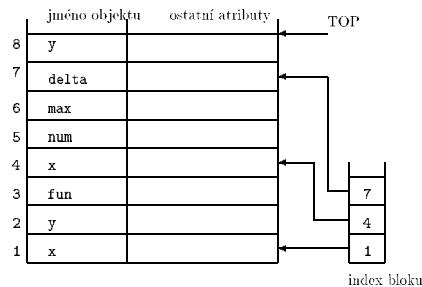
Při dalším zpracování takto reprezentovaného modelu deklaračí je třeba mít stále na paměti, že výsledná datová struktura — když se to tak jeví z uvedených příkladů — nemusí být

- Tabulky s rozptýlenými položkami.* Z hlediska doby vyhledávání jsou nejvýhodnějším řešením tabulky s rozptýlenými položkami, u nichž doba vyhledávání je do značné míry nezávislá na počtu záznamů v tabulce (závislost se projevuje až při vysokém zaplnění, kterému se dá předejít vhodnou volbou velikosti tabulky). Nevýhody této organizace jsou především v problematickém ošetření přeplnění tabulky, velkých množicích na paměť a v tom, že tabulka neumožňuje systematický průchod položkami v abecedním pořadí.

5.2.3 Implementace blokově strukturované tabulky symbolů

Po jazyky s blokovou strukturou jako Pascal, C nebo Modula-2 musí být k dispozici ještě další dvě operace, které označíme jako **tabopen** a **tabclose**. Operace **tabopen** se volá vždy na začátku nového bloku deklarací a operace **tabclose** na konci bloku. Tyto operace zajistí rozdělování jednotlivých úrovní deklarací a umožní uchovávat v tabulce několik různých objektů označených stejnými jmény za předpokladu, že byly deklarovány na různých úrovních. Operace vkládání a vyhledávání musí proto splňovat ještě tyto dodatečné podmínky:

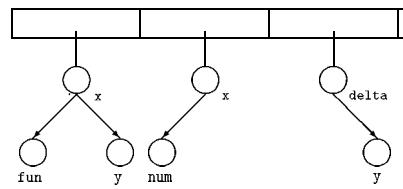
- při vkládání se pracuje pouze s naposledy otevřenou úrovní tabulky, případně další výskytů téhož jména na některé nižší úrovni se neberou v úvahu;
- při vyhledávání se prohledávají postupně všechny úrovně tabulky od nejvyšší úrovně k nejnižší a vrátí se objekt odpovídající prvnímu nalezenému výskytu hledaného jména;



Obrázek 5.3: Příklad zásobníkové organizace tabulky symbolů s blokovou strukturou

Implementace blokově strukturované tabulky symbolů je obvykle založena na některé z metod, které byly uvedeny v předchozím odstavci. Vzhledem k tomu, že každá úroveň tabulky symbolů se uzavírá až teď, jsou-li uvažovány všechny vnořené úrovně, je přirozenou reprezentací blokově strukturované tabulky zásobník. V praxi se nejčastěji užívají tyto kombinace:

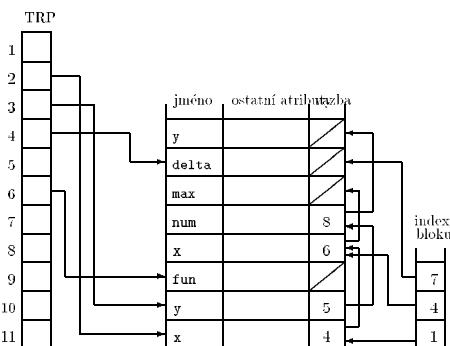
- Zásobníková tabulka symbolů.* Jde o nejjednodušší organizaci tabulky, kdy jsou záznamy jednoduše umisťovány na vrcholu zásobníku tak, jak přicházejí jednotlivé deklarace symbolů. Kromě zásobníku položek se ještě udržuje zásobník indexů úrovní, který ukazuje odkaz vždy na první položku dané úrovně (viz obr. 5.3). Operace **tabopen** pouze ukládá na jeho vrchol současný index vrcholu zásobníku položek a operace **tabclose** vrátí index zásobníku položek na hodnotu, která leží na vrcholu zásobníku indexů. Při vyhledávání se prochází zásobník od vrcholu směrem zpět, při ukládání se hledají případné předchozí výskyny jména pouze na vrcholu zásobníku, až po naposledy uložený index. Tato organizace je velmi podobná nesdílené tabulce symbolů včetně jejich nevhodných časových charakteristik, proto se dá použít pouze tam, kde se neorečkává velký počet ukládaných položek.



Obrázek 5.4: Příklad stromové organizace tabulky symbolů s blokovou strukturou

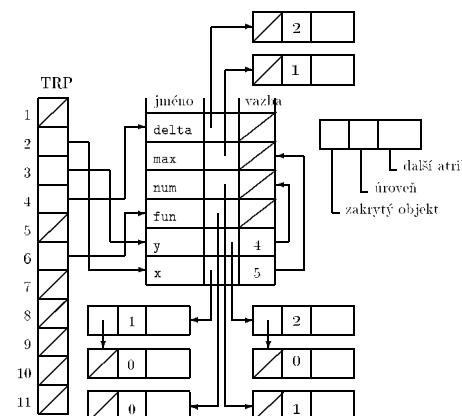
- Kombinace zásobníku a stromu.* Při této organizaci udržujeme podobně jako v předchozím případě zásobník otevřených úrovní tabulky symbolů, ovšem tento zásobník nyní bude obsahovat odkazy na kořenové uzly stromů pro jednotlivé úrovně (viz obr. 5.4). Každý otevřený úrovní nyní přísluší samostatné tabulce symbolů, organizované jako strom. Při vkládání se pracuje se stromem, na který ukazuje položka na vrcholu zásobníku úrovně, při vyhledávání se postupně prochází jednotlivé úrovně počínaje naposledy otevřenou úrovní. Tato metoda je zvláště vhodná pro velký počet položek v tabulce, pokud jsme omezování velikosti paměti.

- Kombinace zásobníku a tabulky s rozptýlenými položkami.* Použití tabulky s rozptýlenými položkami pro blokově strukturované jazyky není příliš zřejmé, tento typ tabulky nezachovává pořadí položek a nemůže samostatně zajistit určitý způsob procházení tabulkou. Je však možné použít oddělený prostor pro položky a vlastní tabulku organizovat pouze jako tabulku ukazatelů na položky (viz obr. 5.5). V tom případě můžeme podobně jako v první uvedené metodě ukládat do zásobníku index první přidělené položky každé otevřené úrovně. Tím máme k dispozici informaci o příslušnosti položek tabulky do jednotlivých bloků, kterou můžeme využít při vyhledávání a vkládání. Operace **tabclose** kromě toho, že obnoví index vrcholu zásobníku položek, musí rovněž odstranit všechny příslušné odkazy a nahradit je příznaky neplatné položky (trüsenim položek v tabulce s rozptýlenými položkami se zabývá některý text [5]). Tato metoda výzaduje při vkládání a vyhledávání projít celým řetězem synonym a vyhledat v něm všechny výskyny téhož jména.



Obrázek 5.5: Příklad blokově strukturované tabulky s rozptýlenými položkami

- Jednoúrovňová blokově strukturovaná tabulka symbolů.* Pravděpodobně nejefektivnější variantou blokově strukturované tabulky symbolů s rozptýlenými položkami využívá zásobníku pro ukládání všech existujících deklarací konkrétního identifikátora (viz 5.6), zatímco hlavní vyhledávací mechanismus je implementován jedinou společnou vyhledávací tabulkou pro všechny úrovně. Je-li při operaci vkládání v tabulce nalezena položka se shodným jménem, avšak deklarována v nadřazené úrovni, přidá se do tabulky nová položka, na kterou se přesuní původní odkaz, a do nové položky se uschová adresa zakryté položky. Tím se při vyhledávání zajistí, že budou přístupná pouze ta jména, která jsou zároveň dostupná na současné úrovni deklarací v programu. Operace **tabclose** musí v tabulce vyhledat všechny položky patřící do právě uvažované úrovně, obnovit odkazy na zakrytá jména, případně zrušit v tabulce odstranit odkazy na jména, která nebyla deklarována v žádém nadřazeném bloku. Podobná organizace se dá využít i pro implementaci tabulky pomocí binárních vyhledávacích stromů. Její hlavní výhoda je v tom, že doba vyhledávání není závislá na deklaraci úrovně hledaného jména (vyhledávání probíhá paralelně na všech úrovních).



Obrázek 5.6: Příklad jednoúrovňového blokově strukturované tabulky symbolů

```
(1) program table(input,output);
(2) var max : integer;

(3) function fib(n: integer): integer;
(4) begin
(5)   if n < 2 then
(6)     fib := 1
(7)   else
(8)     fib := fib(n-2) + fib(n-1)
(9)   end;

(10) procedure printtab(n: integer);
(11) var i : integer;
(12) begin
(13)   for i := 1 to n do
(14)     writeln( i:3, fib(i):6 );
(15)   end;

(16) begin
(17)   read(max);
(18)   printtab(max);
(19) end.
```

Obrázek 6.1: Program v Pascalu pro tisk tabulky Fibonacciho čísel

Vyskytuje-li se jméno podprogramu uvnitř proveditelného příkazu, říkáme, že se podprogram v tomto bode volá. Volání podprogramu provede jeho tělo. Hlavní program na řádech 16–19 v obr. 6.1 volá na řádku 18 proceduru `printtab`. Volání procedur má obvykle charakter příkazu, zatímco volání funkci se vyskytuje jako součást výrazu.

Některé identifikátory v definici podprogramu jsou speciální a nazývají se *formální parametry* podprogramu. Identifikátor *n* je formálním parametrem procedury `fib`. Volánímu podprogramu můžeme předat argumenty, nazývané také *skutečné parametry*, tyto argumenty nahrazují formální parametry podprogramu v jeho těle. Vztahem mezi skutečnými a formálními argumenty se budeme zabývat v článku 6.5. Na řádku 14 v obr. 6.1 je volání `fib` se skutečným parametrem *i*.

Každé provedení těla podprogramu nazýváme aktivaci podprogramu. *Doba života* aktivace podprogramu je posloupnost kroků mezi prvním a posledním krokem provádění těla podprogramu, včetně času stráveného prováděním podprogramů volaných z p. jinu volaných podprogramů atd.

Jsou-li *a* a *b* aktivačí podprogramů, potom jejich doby života se budou nepřekrývají, nebo jsou do sebe zanovené. To znamená, že zacne-li *b* ještě před ukončením *a*, musí řízení opustit *b* dříve než *a*. Tato vlastnost se dá využít při přidělování prostoru pro lokální proměnné podprogramů na zásobníku. Podprogram je *rekurzivní*, jestliže jeho nová aktivace může začít ještě předtím, než se ukončí jeho dřívější aktivace.

Podprogramy představují prostředek pro strukturalizaci programu. Na tu strukturalizaci můžeme použít ze dvou stran: jako na statické členění textu programu do samostatných jednotek, nebo jako na hierarchii aktivních podprogramů v době běhu programu.

6.2. ORGANIZACE PAMĚTI

83

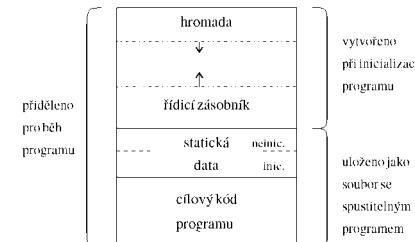
KAPITOLA 6. STRUKTURA PROGRAMU V DOBĚ BĚHU

- vygenerovaný cílový kód,
- statická data,
- řídicí zásobník,
- hromada.

Velikost vygenerovaného kódu je známa již v době překladu, takže jej může překládač umístit do staticky definované oblasti, obvykle na začátek přiděleného paměťového prostoru. Rovněž velikost statických datových objektů může být známa již v době překladu a překládač je může umístit k programu nebo uložit dokonce jako součást programu. Například v jazyce Fortran lze všem pronámyňovým vyhradit prostor ve statické oblasti paměti, neboť neumožňuje rekurzivní volání podprogramů a pracuje pouze s daty, jejichž umístění lze definovat staticky v době překladu.

Jazyky umožňující rekurzivní volání procedur (C, Pascal) využívají pro aktivace podprogramů řídicího zásobníku, do kterého se ukládají jednotlivé aktivační záznamy. Strukturu aktivačního záznamu se budeme zabývat později.

Při řešení dynamického přidělování paměti (C, Pascal) využívají pro aktivační paměť funkci `new` nebo `allocate` při přidělování paměti například pro pole s dynamicky rozráženými) a používají zvláštní část paměti zvané *hromada*. Vzhledem k tomu, že se velikost použité části paměti pro zásobník a hromadu v průběhu činnosti programu mohou značně měnit, je výhodné pro obě části využít opačné konce společné části paměti – viz obr. 6.3. Nedostatek paměti se rozpozná tehdy, jestliže ukazatel konče některé oblasti překročí hodnotu ukazatele konce druhé oblasti.



Obrázek 6.3: Organizace paměti při běhu programu

6.3 Strategie přidělování paměti

Pro datové oblasti, jimž jsme se zabývali v předešlém článku, se používají následující hlavní metody přidělování paměti:

Kapitolu 6

Struktura programu v době běhu

Ještě než začneme uvažovat generování kódu, musíme definovat vztah mezi statickým zdrojovým textem programu a akcemi, které se musejí provést v době běhu programu. Během zpracování může totéž jméno ve zdrojovém textu označovat různé objekty na cílovém počítači. Tato kapitola se bude zabývat vztahem mezi jmény a datovými objekty.

Přidělování a uvoľňování paměti pro datové objekty má na starost systém *řízení programu v době běhu* (run-time system), tvořený podprogramy zaváděními společně s cílovým programem. Návrh řídicího systému je silně ovlivňován semantikou procedur. V této kapitole se budeme zabývat technikami, které jsou využitelné pro jazyky jako je C, Pascal nebo Modula-2.

Každý provedení procedury nazýváme její *aktivaci*. Je-li procedura rekurzivní, může v jednom okamžiku existovat zároveň několik jejích aktivací. Každé volání procedury v Pascalu vede k aktivaci, která může manipulovat s datovými objekty přidělenými speciálně pro její potřebu.

Reprezentace datových objektů v době běhu je dáná jejich typem. Často lze elementární datové typy jako jsou znaky, celá a reálná čísla reprezentovat na cílovém počítači ekvivalentní datovými objekty. Složené datové typy jako jsou pole, řetězce a struktury, se obvykle reprezentují jako kolekce primitivních objektů.

6.1 Podprogramy

Většina současných procedurálních programovacích jazyků umožňuje vytváření strukturovaných programů, ve kterých je základním pojmem *podprogram* jako samostatná programová jednotka, představující abstrakci nějaké akce. Abychom byli konkrétní, budeme předpokládat, že zdrojový program je tvořen procedurami a funkcemi jako v Pascalu.

6.1.1 Statická a dynamická struktura podprogramů

Definice podprogramu je deklarace, která ve své nejjednodušší formě váže identifikátor s příkazem. Tento identifikátor je *jmenem podprogramu* a příkaz je *tělem podprogramu*. Například úsek programu v Pascalu na obr. 6.1 obsahuje na řádcích 3–9 definici podprogramu se jménem `fib`: tělo podprogramu je na řádcích 5–8. Podprogramy, které vracejí hodnotu, se nazývají *funkce*, ostatní podprogramy se nazývají *procedury*. Celý program lze rovněž chápát jako podprogram volaný programu operačního systému počítače.

81

Obrázek 6.2: Aktivační strom

Při běhu programu má každá aktivace podprogramu obvykle k dispozici vlastní oblast paměti pro lokální proměnné a další pomocné údaje (obsah registrů v okamžiku volání, návratová adresa z podprogramu apod.). Tato oblast paměti se nazývá *aktivační záznam podprogramu*. Aktivační záznamy mohou mít v případě, že zdrojový jazyk neumožňuje rekurzivní volání, přidělenou statickou oblast paměti nebo se mohou uchovávat v zásobníku. Při volání podprogramu se na vrchol řídicího zásobníku uloží nový aktivační záznam, který se odstraní při návratu zpět. Je-li na vrcholu řídicího zásobníku aktivační záznam pro uzlu *a* aktivačního stromu, potom zbytek zásobníku obsahuje aktivační záznamy všech nadřazených uzlů v cestě od kořene k uzlu *a*. Blíže se budeme organizací paměti v době běhu zabývat v dalším článku.

6.2 Organizace paměti

Předložený program dostane od operačního systému počítače k dispozici blok paměti, který obecně může být rozdělen na následující části:

- statické přidělení paměti v době překladu,
- přidělování paměti na zásobníku a
- přidělování paměti z hromady.

V dalších odstavcích se zaměříme na přidělování paměti pro aktivační záznamy podprogramů.

6.3.1 Statické přidělování

Při statickém přidělování paměti jsou všem objektům v programu přiděleny adresy již v době překladu. Při kterémkoliv volání podprogramu jsou jeho lokální proměnné vždy na stejném místě, což umožňuje zachovávat hodnoty lokálních proměnných mezi různými aktivacemi podprogramu. Statická alokace proměnných však klade na zdrojový jazyk určitá omezení. Údaje o velikosti a počtu všech datových objektů musí být známy již v době překladu, rekurzivní podprogramy mají vždy omezenou možnost, neboť všechny aktivační podprogramy sdílejí tytéž proměnné, a konečně nelze vytvářet dynamické datové struktury.

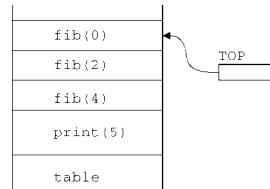
Jedním z jazyků, které používají statické přidělování paměti, je Fortran. Program ve Fortranu se skládá z hlavního programu, podprogramů a funkcí. Aktivační záznamy podprogramů mohou být umístěny dokonce přímo v kódu, což se používalo běžně u starších počítačů.

6.3.2 Přidělování na zásobníku

Přidělování paměti pro aktivační záznamy na zásobníku se používá běžně u jazyků, které umožňují rekurzivní volání podprogramů nebo které používají staticky do sebe zanořené podprogramy. Paměť pro lokální proměnné je přidělena při aktivaci podprogramu vždy na vrcholek zásobníku a při návratu je opět uvolněna. To ale zároveň znamená, že hodnoty lokálních proměnných se mezi dvěma aktivačními podprogramy nezachovávají.

Při implementaci přidělování paměti na zásobníku bývá jeden registr vyhrazen jako ukazatel na začátek aktivačního záznamu na vrcholeku zásobníku. Vzhledem k tomuto registru se pak počítají všechny adresy datových objektů, které jsou umístěny v aktivačním záznamu. Například u přidělení nového aktivačního záznamu je součástí *volací posloupnosti*, obnovení stavu před voláním se provádí během *návratové posloupnosti*. Volací (a návratové) posloupnosti se od sebe v různých implementacích liší. Jejich činnost bývá rozdělena mezi volající i volaný program: obvykle volající program určí adresu začátku nového aktivačního záznamu (k tomu potřebuje znát velikost záznamu vlastního), přesune do něj předávané argumenty a spustí volaný podprogram zároveň s uloženou návratovou adresou do určitého registru nebo na známé místo v paměti. Volaný podprogram nejdříve uschová do svého aktivačního záznamu stavovou informaci (obsahy registrů, stavový slovo procesoru, návratovou adresu), inicializuje svá lokální data a pokračuje zpracováním svého těla. Při návratu opět volaný podprogram uloží hodnotu výsledku do registru nebo do paměti, obnoví uschovanou stavovou informaci a provede návrat do volajícího programu. Ten si převezme návratovou hodnotu a tím je volání podprogramu ukončeno. Na obr. 6.4 je uveden stav řídícího zásobníku při vydihování nejvýše koncového uzlu aktivačního stromu z obr. 6.2.

umožňuje zdrojový jazyk předávat podprogramům datové struktury, jejichž velikost není známa v době překladu (např. pole, jehož počet prvků je dáno hodnotou jiného parametru), je třeba uvedenou strategii poněkud modifikovat. V části aktivačního záznamu, kde



Obrázek 6.4: Řídící zásobník

jsou umístěny parametry, se vyhrazuje pouze místo pro deskriptory objektu s ukazatelem na jeho skutečnou hodnotu a případně ještě dalšími informacemi, a pro vlastní objekt se vyhrazí místo samostatné až za všechny položky s pevnou délou. K hodnotě objektu se pak přistupuje nepřímo přes deskriptor.

6.3.3 Přidělování z hromady

Strategie přidělování na zásobníku je nepoužitelná, pokud mohou hodnoty lokálních proměnných přetrvávat i po ukončení aktivačce, případně pokud aktivace volaného podprogramu může převést aktivači volajícího. V těchto případech přidělování a uvolňování aktivačních záznamů se mohou překrývat, takže nemůžeme paměť organizovat jako zásobník.

Aktivační záznamy se mohou v těchto nejobecnějších situacích přidělovat z volné oblasti paměti (hromady), která se jinak používá pro dynamické datové struktury vytvářené uživateli. Přidělené aktivační záznamy se uvolníjí až tehdy, pokud se ukončí aktivačce příslušného podprogramu nebo pokud už nejsou lokální data potřebná.

Při použití této strategie se pro vlastní přidělování a uvolňování paměti používají stejně techniky jako pro dynamické proměnné.

6.4 METODY PŘÍSTUPU K NELOKÁLNÍM OBJEKTŮM

V předchozích odstavcích jsme se zabývali různými metodami přidělování paměti pro lokální data podprogramů. Nebrali jsme však do úvahy existenci globálních dat – globálních datových objektů přístupných v rámci celého programu, případně lokálních proměnných ve statickým nadřazených podprogramech.

Data, která jsou globální v celém programu, mají charakter statických dat a může být pro ně použita technika statického přidělování paměti. Adresy těchto objektů jsou známy již v době překladu. Například v jazyce C existují pouze globální data a lokální data jednotlivých funkcí, které do sebe nemohou být staticky zanořeny.

Pro podprogramy, které jsou staticky zanořené do jiných podprogramů, musíme zajistit možnost přístupu k lokálním proměnným nadřazeným blokům, tj. k jejich aktivačním záznamům. Nejdodruhousí řešením je rozšíření aktivačního záznamu o ukazatel na aktivační záznam bezprostředního statického nadřazeného podprogramu (*přístupový ukazatel*). Odkazuje-li

duši přístup k lokálním proměnným, zvláště má-li cílový počítač instrukce s adresou danou součtem obsahu registru a nějaké konstanty. Překladač může na základě analýzy programu zjistit nejvyšší statickou úroveň zanoření, a tím i početovaný počet registrů pro display, takže zbyvající registry se mohou použít pro výpočty.

6.5 Předávání parametrů do podprogramu

Parametry podprogramu mají obvykle přidělen prostor v aktivačním záznamu. Do tohoto prostoru se při volání podprogramu umístit skutečné parametry – hodnoty, případně jiné datové struktury zpřístupňující předávaný parametr. To, co se konkrétně předává, závisí na typu a pozádovaném způsobu předávání.

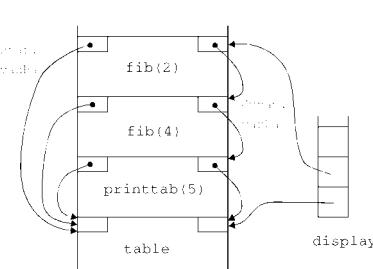
V této části se budeme zabývat několika technikami předávání parametrů. Na základě způsobu implementace můžeme tyto techniky rozdělit do tří skupin:

- **předávání hodnotou (kopírováním), výsledkem a hodnotou-výsledkem**
Hodnota skutečného parametru se kopíruje do formálního parametru nebo se výsledná hodnota formálního parametru kopíruje zpět do skutečného parametru.
- **předávání odkazem (var)**
Parametry předávané odkazem se reprezentují jako adresa skutečného parametru. Změna takového formálního parametru vede k bezprostřední změně skutečného parametru.
- **předávání jménem**
Parametry předávané jménem se podle potřeby využívají při všech odkazech. Jejich zpracování je blízké zpracování makrodefinice.
- **předávání procedur a funkcí**
Parametry, které představují procedury nebo funkce, se předávají jako deskriptory podprogramů; tyto deskriptory obsahují kromě adresy vstupního bodu podprogramu též vazbu reprezentující prostředí, v němž se má podprogram provádět.

6.5.1 Předávání parametrů hodnotou a výsledkem

Při předávání hodnotou se do aktivačního záznamu podprogramu zkopíruje hodnota skutečného parametru a veškeré výpočty uvnitř podprogramu se provádějí s touto kopírou. To znamená, že hodnota skutečného parametru se při tomto způsobu předávání nezmění. Parametry předávané hodnotou můžeme používat za vstupní parametry podprogramu. Podobně při předávání výsledkem se v podprogramu pracuje stále s lokální hodnotou formálního parametru, která se při návratu z podprogramu okopíruje do skutečného parametru (skutečným parametrem tedy musí být L-hodnota, tj. taková hodnota, která může stat na levé straně přířazení). Parametry předávané výsledkem mohou být pouze výstupními parametry. Kombinaci obou metod získáme zároveň vstupní i výstupní parametry.

Tento způsob předávání parametrů můžeme implementovat jednoduše v místě volání, kdy přesuneme hodnotu parametru do nebo z aktivačního záznamu volaného podprogramu. Uvnitř podprogramu s takovým parametrem zacházíme stejně jako s kteroukoliv jinou lokální proměnnou. Poněkud odlišný přístup je třeba volit při předávání polí nebo řetezů. Zde se často využívá nepřímo přístupu přes přistupový vektor (deskriptor), který obsahuje adresu



Obrázek 6.5: Přistupové ukazatele a display

Display může být implementován různými způsoby. Pokud má cílový počítač dostatečný počet registrů, může být display tvoren posloupností vybraných registrů; tím se značně zjedno-

začátku pole nebo řetězce a případně i další údaje, jako počet prvků pole, délku řetězce nebo rozsahy indexů. Takto je možné implementovat i předávání polí a řetězců proměnné délky. Velikost přistupového vektoru je známa v době překladu a je tedy možné pro něj vyhradit pevné místo v aktivačním záznamu. Skutečná hodnota pak může být uložena na jiném místě, např. v oblasti pro dynamické proměnné. Při předávání záznamu můžeme přesunout přímo hodnotu záznamu nebo předat jen jeho adresu a nechat vlastní přesun na volání podprogramu.

6.5.2 Předávání parametrů odkazem

Při této metodě předávání parametrů umístí volající do aktivačního záznamu volaného podprogramu pouze adresu předávané hodnoty. Uvnitř podprogramu se pak všechny odkazy na takový formální parametr zpracovávají jako nepřímé. Pro pole můžeme předat přímo adresu začátku pole nebo adresu přistupového vektoru. Předávání parametrů odkazem se dá jednoduše nahradit předáváním adresy hodnotou, například jako je to definováno v jazyce C. Pokud však takový jazyk nemá dostatečně silnou typovou kontrolu, může velmi často docházet k chybám, například pokud programátor předá místo ukazatele přímo hodnotu nebo naopak pokud místo hodnoty formálního parametru pracuje s jeho adresou.

Příklad 6.2. Následující podprogram v jazyce C provádí zámenu hodnot dvou proměnných, jejichž adresy jsou předávány hodnotou. Všechny výskytty parametrů v výrazech musí explicitně obsahovat dereferenci ukazatele.

```
void swap(int *x, int *y)
{
    int temp;
    temp = *x; *x = *y; *y = temp;
}
```

6.5.3 Předávání parametrů jménem

Metoda předávání parametrů jménem byla použita například v jazyce Algol 60. Je-li jako skutečný parametr předán výraz, např. odkaz na prvek pole $a[i]$, závisí v každém okamžiku jeho hodnota nejen na obsahu pole a , ale i na hodnotě proměnné i . Každý výskyt formálního parametru předávaného hodnotou v textu podprogramu se vlastně nahradí textové hodnotou skutečného parametru, jakoby šlo o makrodefinici.

Příklad 6.3. Volání $swap(i, a[i])$ podprogramu z příkladu 6.2 by se provedlo tak, jako bychom zapsali

```
temp := i; i := a[i]; a[i] := temp
```

To znamená, že při volání jménem se sice i nastaví na $a[i]$ tak, jak očekáváme, avšak potéčerní hodnotu I_0 proměnné i uloží do $a[a[I_0]]$ a ne do $a[I_0]$. Lze ukázat, že pokud se používá předávání jménem, nelze správně pracující verzi procedury $swap$ vůbec napsat. ■

Implementace předávání parametrů jménem je značně obtížná. Pro každý takový parametr musíme vygenerovat podprogram pro jeho výhodnocení. Další komplikací je, že výhodnocení parametru musí probíhat v prostředí volajícího podprogramu (například pro odkazy na proměnné se musí použít tabulka symbolů platná v místě volání). Podprogramu se tedy předává

dvojice hodnot – adresa podprogramu pro vyhodnocení parametru a adresa definující prostředí v místě volání. Vzhledem k problematické implementaci se dnes metoda předávání parametrů jménem nepoužívá, je však zajímavá z hlediska vývoje jazyků a implementačních technik. Tato metoda je také velice blízká technice tzv. *otevřených (inline) podprogramů*, tj. podprogramů, jejichž tělo se vždy rozvíje v místě volání.

6.5.4 Předávání procedur a funkcí

Při předávání podprogramu jako parametru musíme v jazycích, které umožňují zanořování podprogramů, řešit obdobný problém jako při předávání parametrů jménem. Nestáčí pouze předat adresu začátku podprogramu – předávaný podprogram musí mít v okamžiku volání připraveno torž prostředí, jako by byl volaný v místě předávání. Jedná se především o vazby zajišťující přístup ke statickým nadřazeným lokálním proměnným.

```
procedure A;
var m: real;

procedure B(procedure P);
begin
    P
end;

procedure C;
var x: real;
procedure D;
begin
    x := 3.25;
end;
procedure E;
begin
    B(D)
end;
begin
    E
end;
begin
    C
end;
```

Obrázek 6.6: Předávání procedury D jako parametru

Například v programu na obr. 6.6 procedura E volá proceduru B a předává ji jako parametr proceduru D. Procedura D musí mít přístupnou proměnnou m a x , avšak v místě jejího volání (v těle procedury B) je přístupná pouze proměnná m . Proto musí překladač zajistit kromě předání adresy D také předání ukazatele na aktivační záznam procedury C a při volání formální procedury zajistit potřebné vazby.

ukazatel, že indexování se provádí pouze pro pole, že uživateli definovaná funkce se aplikuje na správný počet a typ argumentů atd.

Informace o typech, získaná během typové kontroly, může být požadována při generování kódu. Například aritmetické operátory jako je $*$ se obvykle aplikují buď na celá nebo na reálná čísla, a musíme tedy na základě kontextu rozhodnout, o který význam operátoru $*$ se jedná. Symbol reprezentující v různých kontextech různé operace se nazývá *přiřazení*. Přetěžování může být doprovázeno implicitní konverzí typů, kdy překladač doplňuje operátor pro konverzi operandu na typ očekávaný podle kontextu.

Odlíšným pojmem od přetěžování je *polymorfismus*. Polymorfické funkce a procedury mohou při každém volání pracovat s argumenty jiných typů. Např. v jazyce Pascal můžeme proceduru *writeln* používat za polymorfickou, neboť jejími argumenty mohou být celočíselné, reálné, booleovské výrazy, znaky nebo řetězce. V závislosti na typu skutečného argumentu se tepře vybírá konkrétní algoritmus pro zobrazení hodnoty.

7.1 Typové systémy

Návrh podsystému typové kontroly jazyka je založen na informacích o syntaktických konstrukcích jazyka a pravidlích pro příznačnost typů jazykových konstrukcí. Tato pravidla mohou mít například následující formu:

- „Jsem-li oba operandy aritmetických operací sčítání, odčítání a násobení typu integer, je výsledek typu integer.“
- „Výsledek množného operátoru & je ukazatel na objekt, ke kterému se vztahuje operand. Je-li typ operandu ‘...’, je typ výsledku ‘ukazatel na ...’.“

V uvedených úsečích se implicitně předpokládá, že s každým výrazem je svázán jeho typ. Typy navíc mohou mít určitou strukturu: typ ‘‘ukazatel na ...’’ je vytvořen z typu ‘‘...’’, na který se odkazuje.

V běžných programovacích jazycích jsou k dispozici obvykle dvě skupiny datových typů: základní nebo složené. Základní typy jsou atomické typy, z hlediska programátora bez další vnitřní struktury. V Pascalu jsou například základními typy *boolean*, *char*, *integer* a *real*. Intervaly jako 1..10 a výčetový typy jako

violet, *indigo*, *blue*, *green*, *yellow*, *orange*, *red*

lze používat za základní výraz. Pascal programátorovi dovoluje vytvářet podle potřeby další typy ze základních a dříve definovaných složených typů: příkladem jsou pole, záznamy a množiny. Jako složené typy lze navíc chápát i ukazatele a funkce.

7.1.1 Typové výrazy

Typ jazykové konstrukce lze popsat *typovým výrazem*. Neformálně je typový výraz buď základní typ nebo je vytvořen aplikací operátoru zvaného konstruktorem typu na jiné typové výrazy. Soubor základních typů a konstrukturů je dán definicí jazyka.

V této kapitole budeme používat následující definice typového výrazu:

1. Základní typ je typový výraz. Mezi základními typy jsou *boolean*, *char*, *integer* a *real*. Speciální základní typ *type_error* signalizuje chybu během typové kontroly. Konkrétně

základní typ *void* označuje "nepřítomnost hodnoty" a dovoluje přidat datový typ i procedurální a příkazům.

2. Vzhledem k tomu, že typové výrazy mohou být pojmenované, je jméno typu typovým výrazem. Příklad použití jmén typů je dále v 3(c).

3. Typový konstruktor aplikovaný na typový výraz je typovým výrazem. Mezi konstruktory patří:

- a) *Konstruktor pole*. Je-li T typový výraz, pak $\text{array}(I, T)$ je typovým výrazem, jenž označuje pole prvků typu T s indexovou množinou I . Typ I je často intervalem celých čísel. Například deklarace v Pascalu

```
var A: array [1..10] of integer;
```

spojuje se jménem A typový výraz $\text{array}(1..10, \text{integer})$.

- b) *Součin typů*. Jsou-li T_1 a T_2 typové výrazy, potom jejich kartézský součin $T_1 \times T_2$ je typovým výrazem. Předpokládáme, že \times je zde asociativní.

- c) *Záružný*. Rozdíl mezi záznamem a součinem je ten, že složky záružnemu jsou pojmenované. Typový konstruktor *record* bude aplikován na n -tici tvořenou jmény složek a typy složek. Například úsek programu v Pascalu:

```
type row = record
  address: integer;
  lexeme: array [1..15] of char
end;
```

```
var table: array [1..101] of row;
```

deklaruje jméno typu row představujícího typový výraz

```
record((address  $\times$  integer)  $\times$  (lexeme  $\times$  array(1..15, char)))
```

a proměnnou table jako položku záznamu tohoto typu.

- d) *Ukazatele*. Je-li T typový výraz, potom $\text{pointer}(T)$ je typový výraz označující typ "ukazatel na objekt typu T ". Například opět v Pascalu deklarace

```
var p: row;
```

deklaruje proměnnou p s typem $\text{pointer}(\text{row})$.

- e) *Funkce*. Z matematického hlediska funkce zobrazují prvky jedné množiny, definovaného oboru, do jiné množiny, oboru hodnot. Funkce v programovacích jazycích můžeme chápat jako zobrazení zdrojového typu D (domain) do cílového typu R (range). Typ takové funkce lze užívat typovým výrazem $D \rightarrow R$. Například standardní funkce *mod* jazyka Pascal má zdrojový typ $\text{int} \times \text{int}$, tj. dvojici celých čísel, a cílový typ int . Za předpokladu, že x má vyšší prioritu než \rightarrow a že \rightarrow je asociativní zprava, tedy má *mod* typ

$\text{int} \times \text{int} \rightarrow \text{int}$

Jako další příklad vezmeme deklaraci z Pascalu

`function f(a, b: char): integer; ...`

která říká, že zdrojovým typem funkce f je $\text{char} \times \text{char}$ a cílovým typem je $\text{pointer}(\text{integer})$. Typ f je tedy označen typovým výrazem

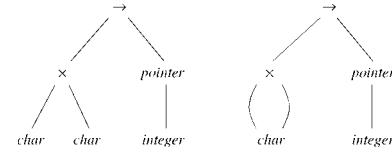
$\text{char} \times \text{char} \rightarrow \text{pointer}(\text{integer})$

Z implementačních důvodů jsou často kladena omezení na typ, jež může funkce vrátit; např. v jazyce C nelze vracet pole nebo funkce. Existují však jazyky, z nichž Lisp je nejvýraznějším příkladem, které dovolují, aby funkce vrátily objekty libovolných typů, takže můžeme např. definovat funkci g typu

$(\text{integer} \rightarrow \text{integer}) \rightarrow (\text{integer} \rightarrow \text{integer})$

Funkce g tedy má jako argument funkci zobrazující cele číslo na celé číslo, a tato funkce produkuje jako výsledek jinou funkci stejného typu. Zpracování takového funkci (viz. funkci vyššího řádu) je typické pro funkcionální jazyky.

Výhodnou metodou reprezentace typových výrazů je použití grafu. Během překladu definice typu můžeme pro typový výraz sestrojit strom nebo DAG, jehož vnitřními uzly budou konstruktory typu a listy budou základní typy, jméný typů a typových proměnných (viz obr. 7.1). Obdobnou reprezentaci je grafový model, uvedený na obr. 5.2.



Obrázek 7.1: Strom a DAG pro výraz $\text{char} \times \text{char} \rightarrow \text{pointer}(\text{integer})$

Typový systém je soubor pravidel pro přiřazování typových výrazů různým částem programu; v této kapitole jej budeme implementovat pomocí syntaxi řízeného překladu. Různými překladači téhož jazyka mohou být implementovány různé typové systémy. Například v systému Unix jsou pro původní verzi jazyka C k dispozici dva programy s odlišnými typovými systémy. Program *lint* provádí pouze statickou kontrolu programu bez jeho překladu, ovšem na základě mnohem přísnějšího typového systému než překladač *cc*, a tím umožňuje odhalení programátorských chyb, které samy o sobě nejsou v rozporu s definicí jazyka C.

Příklad 7.1. Jako příklad implementace typové kontroly použijeme jednoduchý jazyk, ve kterém musí být typ každého identifikátoru deklarován před jeho použitím. Jazyk má následující gramatiku:

```
P → D ; E
D → D : D | id : T
```

7.1.2 Statická a dynamická kontrola typů

Kontrole prováděná překladačem říkáme statická, zatímco kontroly prováděné při běhu programu se nazývají dynamické. V principu je možné všechny kontroly provádět až dynamicky, pokud cílový kód posene s hodnotou první zároveň i jeho typ. Z hlediska efektivity spoleklosti programu je však vhodnejší provádět v dobu překladu co nejvíce počet kontrol.

Spolehlivý typový systém (sound type system) vylučuje potřebu dynamické kontroly typových chyb, neboť dovoluje starécky zajistit, že takové chyby nemohou za běhu cílového programu nastat. To znamená, že pokud nějaký spolehlivý typový systém přifádí části programu jiný typ než *type_error*, potom při běhu cílového kódu vygenerovaného z této části programu nemůže nastat typová chyba. Jazyk je *prísně typovaný* (strongly typed), pokud jeho překladač může zaručit, že program, který přijme, se bude provádět bez typových chyb.

V praxi se však mohou některé kontroly provádět výlučně dynamicky. Například pokud nejdříve deklarujeme

```
table: array [0..255] of char;
i: integer;
```

a potom počítáme $\text{table}[i]$, nemůže překladač obecně zaručit, že při provádění programu bude hodnota i ležet v intervalu 0 až 255. Pouze v některých programech lze pomocí technik analýzy toku dat zda je i v určitých mezích. Zádná technika to však nemůže provést správně ve všech případech.

7.1.3 Zotavení po chybě při typové kontrole

Vzhledem k tomu, že typová kontrola má schopnost zachytovat chyby v programech, je pro podsvětlem typové kontroly důležité, aby při výskytu chyby provedl něco rozumného. Nejdříve ze všeho musí překladač ohlásit podstavu a pozici chyby. Při typové kontrole vyžadujeme, aby došlo k zotavení a mohl se kontrolovat i zbytek programu. Zotavení musí být zabudováno již od počátku do typového systému.

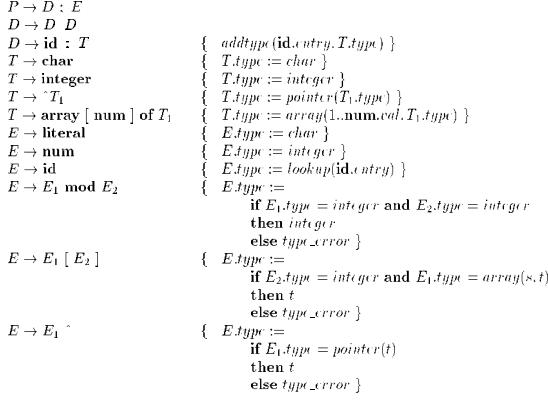
Zavedení zpracování chyb může vést k typovým systémům, který jde mnohem dalej než systém nutný pouze k specifikaci správných programů. Například nastala-li již chyba, nemůžeme znát typy nesprávně vyváženého úseku programu. Zacházení s neúplnými informacemi vyžaduje techniky podobné metodám potřebným v jazycích, které nevyžadují deklaraci identifikátorů před jejich použitím. K zajištění konzistentního použití nedeklarovaných nebo zjevně nesprávně deklaroványch identifikátorů lze použít typových proměnných, představujících neznačené datové typy.

7.2 Ekvivalence typových výrazů

Během typové kontroly často vyžadujeme, aby dva datové typy byly ekvivalentní. Pojem ekvivalence datových typů však prozatím nebyl přesně definován; není například zřejmé, zda dva různě pojmenované typy se shodou vnitřní strukturou, jsou či nejsou ekvivalentní. V programovacích jazycích se setkáváme v podstatě se dvěma základními přístupy. *Ekvivalence podle jména* povážuje každý pojmenovaný typ za jedinečný, odlišný od všech ostatních pojmenovaných či nepojmenovaných typů; dva typové výrazy jsou ekvivalentní podle jiného právě této, jsou-li identické. Při zjištování *ekvivalence podle struktury* nejprve nahradíme všechna jména odpovídajícími typovými výrazy; dva typové výrazy považujeme za ekvivalentní, jestliže po tomto nahrazení mají oba výrazy stejnou vnitřní strukturu.

```
T → char | integer | array [ num ] of T | ↑ T
E → literal | num | id | E mod E | E [ E ] | E'
```

Základní typy jazyka jsou *char* a *integer*, typ *type_error* se používá pouze pro signifikantní typové chyby. Pro jednoduchost předpokládáme, že index pole začíná vždy od hodnoty 1. Překladové schéma na obr. 7.2 popisuje budování typových výrazů, deklaraci proměnných a typovou kontrolu výrazů. Po vhodné modifikaci gramatiky můžeme toto schéma použít jak pro překlad shora dolů, tak i pro překlad zdoňa nahoru.



Obrázek 7.2: Překladové schéma pro typovou kontrolu deklarací a výrazů

V uvedeném překladovém schématu akce *addtype(id.entry, T.type)* do položky tabulky symbolů specifikované syntetizovaným atributem *entry* uloží typ identifikátoru *id* z deklarace. Syntetizovaný atribut *type* nonterminálu *E* udává typ odpovídajícího výrazu. Pro zjištění typu, který je svázán s polohou tabulkou symbolů *t*, používáme funkce *lookup(t)*.

Při kontrole operátora *mod* ve výrazu požadujeme, aby oba operandy měly typ *integer*. V odkazu na prvek pole $E_1[E_2]$ musí mít indexový výraz E_2 typ *integer*; typ výsledku t je potom dán typem prvého pole, který ziskáme z konstruktuoru *array(s,t)*. Pro výraz E požadujeme, aby jeho operandum byl ukazatel; typ t celého výrazu opět získáme z konstruktuoru *pointer(t)*. Toto překladové schéma můžeme podobným způsobem rozšířit o další typy a operátory.

Příklad 7.2. Uvažujme následující úsek deklarací v jazyce Pascal:

```
type link = ^ cell;
var next : link;
    last : link;
    p   : ^ cell;
    q, r : ^ cell;
```

Identifikátor **link** je zde jmenem typu **cell**. Zajímá nás, zda typy proměnných **next**, **last**, **p**, **q** a **r** jsou či identické. Proměnný **next** a **last** je příznačný typový výraz **link**, ostatní proměnný výraz **pointer(cell)**. Je-li implementována ekvivalence podle jmen, mají proměnné **next** a **last** stejný typ, neboť jiný odpovídající typové výrazy jsou identické. Podobně proměnné **p**, **q** a **r** mají stejný typ, ovšem odlišný od typu proměnné **next**. Uvažujeme-li však strukturální ekvivalence, jsou typy všech proměnných stejný, neboť po nahrazení jmena typu **link** odpovídajícímu typovým výrazem **pointer(cell)** z jeho definice dostaneme pro všechny proměnné výrazy se stejnou vnitřní strukturu.

V některých implementacích se k ekvivalence podle jmen přistupuje poněkud odlišným způsobem. Každému výskytu nepojmenovaného typu se připřadi implicitní jmeno, které tento výskyt odliší od všech ostatních výskytů téhož nepojmenovaného typu. V našem případě by tedy proměnná **p** mohla mít jiný typ než proměnné **q** a **r**. Tento přístup podstatně zjednoduší implementaci ekvivalence typů, neboť pokud například reprezentujeme typy proměnných pomocí ukazatele na datové struktury popisující konkrétní výskyt typu, můžeme za ekvivalentní datové typy považovat ty, které jsou reprezentovány stejnými ukazateli.

Pro testování strukturální ekvivalence můžeme použít algoritmu obdobnému tomu, který je uveden na obr. 7.3. Funkce **sequiv(s,t)** vrátí hodnotu true, pokud jsou typové výrazy **s** a **t** strukturálně ekvivalentní, a hodnotu false v opačném případě.

```
function equiv(s,t): boolean;
begin
  if s a t jsou stejně základní typy then
    return true
  else if s = array(s1,s2) and t = array(t1,t2) then
    return equiv(s1,t1) and equiv(s2,t2)
  else if s = s1 × s2 and t = t1 × t2 then
    return equiv(s1,t1) and equiv(s2,t2)
  else if s = pointer(s1) and t = pointer(t1) then
    return equiv(s1,t1)
  else if s = s1 → s2 and t = t1 → t2 then
    return equiv(s1,t1) and equiv(s2,t2)
  else
    return false
end
```

Obrázek 7.3: Testování strukturální ekvivalence typových výrazů

V některých implementacích překladačů se pro kódování typových výrazů používají i jiné datové struktury než graf. Datorový typ může být zakódován jako posloupnost bitů tvořená

kódem základního datového typu, ke kterému se přidávají kódy typových konstruktorů v pořadí jejich aplikace. Výhodou tohoto přístupu je išporána reprezentace a jednodušší testování strukturální ekvivalence, neboť dva strukturně odlišné datové typy nemohou mít stejnou binárnou reprezentaci. Naopak nevýhodou je omezený přípustně složitost datových typů, které může programátor používat, obvykle délku slova procesoru.

Při implementaci ekvivalence podle struktury musíme uvažovat i možnost rekursivní definice typu — např. datový typ záznam může v sobě obsahovat ukazatel na jiný záznam téhož typu. Je-li datový typ v překladači reprezentován grafem, obdržíme po nahrazení jmen typů odpovídajícími grafy cyklický graf, a musíme tedy zajistit, aby se algoritmus zjišťující strukturální ekvivalence typů choval korektně i v tomto případě.

7.3 Typové konverze

Uvažujme výraz **x+i**, kde **x** je typu real a **i** typu integer. Vzhledem k tomu, že reprezentace obou typů počítáři je odlišná a že počítář pro operace nad celými a reálnými čísly používá jiné instrukce, musí překladač nejdříve zajistit konverzi jednoho z operandů na společný datový typ. To, zda tato konverze je implicitní nebo musí být explicitně zapsána programátorem, závisí na definici jazyka. Podobně musí být definována pravidla pro přípravování hodnot do proměnných různých typů. Například v jazyce Pascal se při přifázefaci celočíselné hodnoty do reálné proměnné provede implicitní konverze přípravování hodnoty na typ real, ovšem při přifázefaci reálného výrazu do celočíselné proměnné musí programátor explicitně definovat používanou konverzi voláním funkce **true** nebo **round**.

Implicitní konverze jednoho datového typu na druhý (často také zvaný *cast*) provádí překladač automaticky. Obvykle jsou tyto konverze omezeny na případy, kdy není třeba dát ke ztrátě informace, např. konverze celého čísla na reálné. *Explicitní konverze* datových typů požaduje programátor obvykle ve formě volání určitých standardních funkcí nebo pomocí operátorů konverze. Například v jazyce Pascal funkce **ord** převádí znaky na celá čísla a funkce **chr** naopak celá čísla na znaky, zatímco v jazyce C se tato konverze provádí implicitně. V jazyce Ada jsou všechny konverze explicitní, činí se zajistit skutečně dílčedlná typová kontrola a dodatečná případných chyb v důsledku nesprávně zapsaných výrazů.

7.4 Přetěžování funkcí a operátorů

Přetěžení symbolu je takový, který má různý význam v závislosti na kontextu, ve kterém je použit. Ve významech je například přetěžení symbol +, protože ve výrazu A + B může mít různý význam v závislosti na typech operandů A a B. V jazyce Ada jsou přetěžené závorky (): výraz A(C) může být odkaz na 1-tý prvek pole A, volání funkce A s parametrem I nebo explicitní konverze výrazu I na typ A.

Přetěžení se nazývá *výrobené*, pokud se nám podaří nalézt jednoznačný význam pro určitý výskyt přetěženého symbolu. U běžných programovacích jazyků, kde přetěžení nastává pouze u standardních operátorů, není obvykle nalezení jednoznačného významu obtížné. V jazyčích jako je Ada nebo C++ však může docházet k velmi komplikovaným situacím, když podvýraz nějakého výrazu může mít množinu možných typů a když pro vyřešení přetěžení potřebujeme znát širší kontext.

Příklad 7.3. V jazyce Ada je jednou ze standardních interpretací operátoru * násobení dvou celých čísel. Tento operátor můžeme přetěžit deklaracemi jeho dalších významů, např.

```
function "*" ( i, j : integer ) return complex;
function "*" ( x, y : complex ) return complex;
```

Po uvedených deklaracích množina možných typů operátoru * zahrnuje

```
integer × integer → integer
integer × integer → complex
complex × complex → complex
```

Za předpokladu, že konstanty 2, 3 a 5 jsou pouze typu integer, může mít podvýraz **3*5** typ **integer** nebo **complex**, v závislosti na kontextu. Je-li úplný výraz **2*(3*5)**, musí být **3*5** typu **integer**, neboť operátor * může mít oba operaandy typu **integer** nebo oba operaandy typu **complex**. V jazyce C++ může být tato situace ještě komplikovaná tím, že programátor může definovat funkce pro implicitní konverzi typu **integer** na **complex**; teďby se po implicitní konverzi hodnoty 4 na typ **complex** mohl celý výraz vylučovat jako výraz typu **complex** a výsledný typ by byl opět nejednoznačný. Zpracování přetěžených symbolů je obecně známé složitý problém; některé algoritmy, které se pro řešení přetěžení používají, je možno nalézt v [2].

7.5 Polymorfické procedury a funkce

Obyčejné procedury a funkce umožňují provedení svého těla pouze s parametry pevných typů, které jsou uvedeny v deklaraci podprogramu nebo jsou dány implicitními konvenčemi. Typy parametrů polymorfických procedur a funkcí naopak mohou být při každém volání podprogramu odlišné. V běžných programovacích jazycích se s polymorfismem setkáváme například u standardních operátorů pro indexování polí, volání funkcí a manipulaci s ukazateli. Například v jazyce C je-li výraz **xx** operand x typu "...", je výsledek typu "ukazatel na ...". Za symbol "...", můžeme dosadit libovolný typ, takže operátor & je v jazyce C polymorfický.

Polymorfické procedury a funkce jsou z hlediska programátorského velmi efektivními prostředkem pro vyjadřování obecných algoritmů. Například potřebujeme-li v Pascalu funkci pro zjištění délky seznamu celých nebo reálných čísel, musíme stejný algoritmus zapsat dvakrát, případně lít si budou pouze deklarace typu parametru funkce. Výhodnější by bylo použít polymorfické funkce, která by umožňovala výpočet délky seznamu příkazem libovolného typu (který ve vlastním výpočtu nehráje žádnou roli).

Abychom mohli specifikovat typy polymorfických funkcí, musíme v typových významech použít *typové proměnné*. Typové proměnné budeme označovat písmeny řecké abecedy α , β , ..., a budou reprezentovat vždy konkrétní neznámý typ. Například operátor **&** z jazyka C bude mít typ

$$\alpha \rightarrow \text{pointer}(\alpha)$$

V programovacích jazycích, které nevyžadují explicitní definice typů proměnných a funkcí (například ve funkcionálních jazycích jako je jazyk ML), musíme typy jednotlivých jazykových konstrukcí určovat na základě kontextu. Tento proces se nazývá *inference typů*. Například ve funkci

```
fun length(lptr) =
  if null(lptr) then 0
  else length(tl(lptr)) + 1;
```

se na druhém řádku volá standardní funkce **null**, která je typu **list(a) → boolean**, kde **list** je konstruktér seznamu. Odtud je zřejmé, že **lptr** může být typu **list(a)**, kde **a** je nějaký (libovolný) typ. Jako výsledek se vráci celočíselná konstanta 0, protože je výsledek funkce **length** typu **integer**. Funkce **length** má tedy typ **list(a) → integer**. Na třetím řádku můžeme už jenom provést na základě znalosti typu funkce **tl** a **length** kontrolu, zda je uvedený výraz typově správný.

Inference typu lze využít i v překladačích klasických jazyků pro doplnování chybějících informací v době překladače. Například v jazyce C můžeme z volání funkce odvodit typy jejich operandů a výsledku a později, v okamžiku její definice, zkонтrolovat, zda je toto definice konzistentní s předchozími voláními.

7.5.1 Unifikace typových výrazů

Při inferenci typů je základním problémem nalezení společné instance dvou typových významů s typovými proměnnými — jejich *unifikace*. Unifikaci můžeme definovat pomocí funkce **S** zvané *substituce*, která proměnné přířazuje výrazy. Zápis **S(c)** predstavuje výraz získávaný tak, že všechny proměnné α obsažené v c nahradíme hodnotou **S(α)**. Potom **S** je unifikátor pro c a f , právě když $S(c) = S(f)$.

Máme-li dva typové výrazy c a f , hledáme takovou nejúčinnější substituci proměnných v nich obsažených, aby po této substituci oba výrazy byly ekvivalentní. Výsledkem unifikace může být buď tato substituce, nebo zjistíme, že společná instance výrazů neexistuje. Speciálně případem unifikace je testování ekvivalence dvou typových výrazů; pokud výrazy c a f neobsahují proměnné, je možné je unifikovat právě tedy, jestliže jsou ekvivalentní.

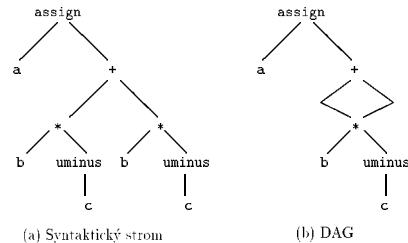
Příklad 7.4. Uvažujme následující dva typové výrazy:

$$\begin{aligned} ((\alpha_1 \rightarrow \alpha_2) \times \text{list}(\alpha_3)) &\rightarrow \text{list}(\alpha_2) \\ ((\alpha_3 \rightarrow \alpha_4) \times \text{list}(\alpha_3)) &\rightarrow \alpha_5 \end{aligned}$$

Pro tyto výrazy můžeme najít substituci **S** takovou, že $S(\alpha_1) = S(\alpha_3) = \alpha_3$, $S(\alpha_2) = S(\alpha_4)$, $S(\alpha_5) = \text{list}(\alpha_2)$, která zobrazuje c a f na výraz

$$S(c) = S(f) = ((\alpha_3 \rightarrow \alpha_4) \times \text{list}(\alpha_3)) \rightarrow \text{list}(\alpha_2)$$

Jeden z možných unifikátorů algoritmů je uveden v [2]; podobný algoritmus se používá při vyhodnocování programů v logických programovacích jazykách (např. Prolog) nebo obecně při řešení problémů z oblasti umělé inteligence.

Obrázek 8.1: Grafická reprezentace výrazu $a := b * -c + b * -c$

se kód pro výhodnější výrazu $p=p->next$ může vygenerovat až za konec těla cyklu a je tedy nutné nějakým způsobem uchovat výraz až do okamžiku, kdy bude tělo cyklu zpracováno. Překlad výrazu může probíhat dvoufázově: nejdříve se vytvoří jeho grafová reprezentace, a pak se tento graf ve vhodném okamžiku převede například do tříadresového kódu.

V analytiko-syntetickém modelu překladu převádí přední část překladače zdrojový program do intermediární reprezentace, ze které dálé zadní část překladače generuje cílový kód. Je samozřejmě možné — a také se tak často postupuje — přeložit zdrojový program přímo do cílového jazyka. Překlad využívající nějakého strojového nezávislého mezikódu má však své výhody:

1. Zjednodušuje se přepracování překladače pro jiný cílový jazyk (retargeting). Stačí vytvořit pouze novou koncovou část.
2. Mezikód lze optimalizovat s využitím metod strojové nezávislé optimalizace.

V této kapitole si ukážeme použití metod syntaktického překladu pro překlad základních programových konstrukcí jako jsou deklarace, přířazení a řídící příkazy do intermediárního kódu. Většina uvedených metod se dá použít během překladu zdola nahoru nebo shora dolů, takže generování intermediárního kódu se dá podle potřeby začlenit do syntaktické analýzy.

8.1 Intermediární jazyky

Jako intermediární reprezentace programu se používají nejčastěji stromy (případně obecné grafy) a zásobníkový nebo tříadresový kód. Výběr mezikódu je často dán požadavky na efektivitu jeho dalšího zpracování. Například pro rozsáhlou optimalizaci je výhodnější použít tříadresový kód místo zásobníkového. Naopak zásobníkový kód může být výhodnější v překladačích generujících kód pro počítače se zásobníkovou architekturou.

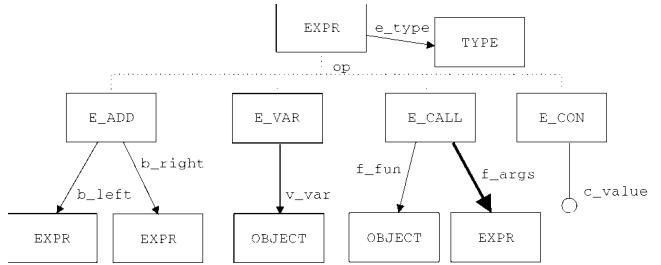
8.1.1 Grafová reprezentace

Za přirozenou grafovou reprezentaci programu můžeme považovat přímo syntaktický strom nebo DAG. Na obr. 8.2 je znázorněn strom a DAG pro přířazovací příkaz $a := b * -c + b$.

Pomocí grafu se často v překladači reprezentují deklarace, které se neobjevují přímo v mezikódu (viz odstavec 5.1), a výrazy, jejichž kód se někdy může v mezikódu vyskytovat na jiném místě, než kde byl výraz uveden ve zdrojovém programu. Například pro příkaz cyklu `for` jazyka C

```
for(p=first; p; p=p->next) print(p);
```

101



Obrázek 8.2: E-R model výrazu

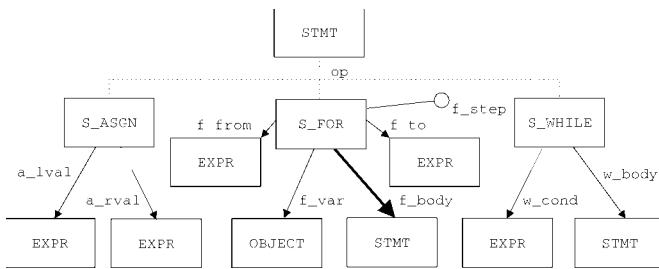
Pro obecnou reprezentaci jak výrazů, tak i příkazů programu můžeme rovněž použít E-R modelu z článku 5.1. Část semantického grafu pro typické výrazy je uvedena na obr. 8.2, na obr. 8.3 je znázorněna struktura některých příkazů jazyka Pascal.

8.1.2 Zásobníkový kód

Postfixová notace, ze které vychází zásobníkový kód, představuje linearizovaný zápis syntak-

8.1. INTERMEDIÁRNÍ JAZYKY

103



Obrázek 8.3: E-R model příkazu

```

VAR b      ; ... (b)
VAR c      ; ... (b) (c)
INV       ; ... (b) (-c)
MUL      ; ... (b * -c)
VAR b      ; ... (b * -c) (b)
VAR c      ; ... (b * -c) (b) (c)
INV       ; ... (b * -c) (b) (-c)
MUL      ; ... (b * -c) (b * -c)
ADD      ; ... (b * -c + b * -c)
ASG a    ; ...
  
```

Obrázek 8.4: Zásobníkový kód pro výraz $a := b * -c + b * -c$

tikého stromu; je to seznam uzlů, ve kterém je uzel stromu uveden vždy bezprostředně za svými přímými následníky. Postfixový zápis syntaktického stromu z obr. 8.2(a) je

```
a b c uminus * b c uminus * + assign
```

Postfixová notace neobsahuje explicitně hrany syntaktického stromu. Ty se dají zpětně odvodit z polohy uzlů a z pořadí jejich operandů.

Zásobníkový kód je tvořen posloupností příkazů, které obecně definují posloupnost akcí nad zásobníkem. Každá z těchto akcí představuje buď vložení hodnoty proměnné nebo konstanty na vrchol zásobníku, provedení určité operace nebo uložení hodnoty z zásobníku do proměnné. Operandy a výsledky operací jsou obvykle uloženy na zásobníku. Příkaz $a := b * -c + b * -c$ může v zásobníkovém kódě zapsat například tak, jak ukazuje obr. 8.4. V poznámce je u každé instrukce zásobníkového kódu uveden obsah zásobníku po jejím provedení. Pořadí operandů a operátorů je stejně jako v postfixové notaci, ovšem postfixová notace operandy od operátorů formálně nerozlišuje.

104

KAPITOLA 8. GENEROVÁNÍ INTERMEDIÁRNÍHO KÓDU

8.1.3 Tříadresový kód

Tříadresový kód je posloupnost příkazů, které mají obecně tvar

 $x := y \ op \ z$

kde x , y a z jsou jména, konstanty nebo překládačem vytvořené dočasné objekty; op představuje libovolný operátor, např. některý z aritmetických nebo logických operátorů. V operande nemohou být žádné další výrazy, příkaz obsahuje vždy jen jeden operátor. Proto musí být složitější výraz rozložen na své nejjednodušší složky s použitím dočasných proměnných vytvořených překládačem. Zde je vidět zásadní rozdíl mezi zásobníkovým a tříadresovým kódem. Zásobníkový kód se odkazuje na operandy implicitně, na základě jejich pozice, zatímco tříadresový kód všechny operandy pojmenovává. Tím se značně zjednoduší optimalizace tříadresového mezikódu, při nichž se mohou jednotlivé příkazy navzájem libovolně přesouvat.

Pojmenování kódu vychází z toho, že každý příkaz obvykle obsahuje tři adresy, dvě pro operandy a jednu pro výsledek. Při implementaci mohou tyto adresy znamenat například ukazatele do tabulky symbolů na příslušné objekty.

Tříadresový kód je linearizovanou reprezentací syntaktického stromu nebo DAG, ve kterém jiná generovaná překládačem odpovídají vnitřním uzlům grafu. Syntaktický strom a DAG z obr. 8.1 jsou na obr. 8.5 zapsány v tříadresovém kódě. Jména proměnných se mohou v zápisu používat přímo, protože nejsou žádné příkazy, které by reprezentovaly listy původního grafu.

t1 := -c t2 := b * t1 t3 := -c t4 := b * t3 t5 := t2 + t4 a := t5	t1 := c t2 := b * t1 t5 := t2 + t2 a := t5
--	---

(a) Kód pro syntaktický strom

(b) Kód pro DAG

Obrázek 8.5: Tříadresový kód pro strom a DAG z obr. 8.1

Typy příkazů tříadresového kódu

Příkazy tříadresového kódu jsou podobné příkazům jazyka assembleru. Mohou být označeny symbolickým návěstím, které se využívá v příkazech pro změnu toku řízení. Transformace symbolického jména na index příkazu v jeho vnitřní reprezentaci se provádí buď v samostatném průchodu, nebo metodou backpatching, kterou se budeme zabývat v odstavci 8.7.

V dalším textu budeme používat následující nejčastější tříadresové příkazy:

- Přiřazovací příkazy ve tvaru $x := y \ op \ z$, kde op je binární aritmetický nebo logický operátor.
- Přiřazovací příkazy ve tvaru $x := op \ y$, kde op je unární operátor (unární minus, logická negace, operátory pro konverzi datových typů apod.).
- Kopírovací příkazy ve tvaru $x := y$.

- Nepodmíněný skok `goto L`.
- Podmíněný skoky ve tvaru `if x relop y goto L`, které se provedou tehdy, je-li splněna relace `op` mezi hodnotami `x` a `y`.
- Příkazy `param x a call p,n` pro volání procedury a `return y` s volitelnou hodnotou `y` reprezentující návratovou hodnotu. Typická posloupnost těchto příkazů pro volání procedury `p(x1, x2, ..., xn)` je:

```
param x1
param x2
...
param xn
call p,n
```

kde `n` je počet skutečných parametrů předávaných proceduře.

- Přířazení s indexováním ve tvaru `x:=y[1]` nebo `x[1]:=y`.
- Přířazení adres a neprázdný přístup přes ukazatel ve tvaru `x:=&y`, `x==&y` a `*x==y`. První z těchto příkazů uloží do `x` adresu objektu `y`, další uloží do `x` hodnotu, jejíž adresa je v promené `y` a poslední uloží na adresu, která je v promené `x` hodnotu `y`.

Výběr operátorů je velmi důležitou součástí návrhu intermediárního kódu. Soubor operátorů musí být dostatečně bohatý, aby se jím daly vyjádřit všechny operace zdrojového jazyka. Menší počet operátorů zjednoduší implementaci generátoru kódů, avšak vede k podstatnému delšímu úsekůmu, který se dále musí optimalizovat.

Implementace tříadresových příkazů

Tříadresové příkazy jsou abstraktní formou intermediárního kódů. V překladači se tyto příkazy mohou implementovat jako záznamy s položkami pro operátor a operandy. Obvykle se pro ně používá jedna z následujících reprezentací:

- Ctverce (quadruples).** Ctverce je struktura se čtyřimi položkami, které označíme `op`, `arg1`, `arg2` a `result`. Položka `op` obsahuje kód operátoru, `arg1` a `arg2` operandy a `result` výsledek. Některé příkazy nemusí využívat všechny položky, např. unární operátory nevyužívají `arg2`.
- Trojice (triples).** V této reprezentaci datová struktura reprezentující příkaz neobsahuje položku pro výsledek. Výsledek je v operaudech dalších příkazů reprezentován číslem příslušné trojice.
- Neprázdné trojice (indirect triples).** Nevhodnou předchozí reprezentaci je, že se jednotlivé trojice nemohou jednoznačně přesouvat nebo rušit, například během optimalizace kódů. Proto se může využít ještě dalšího pomocného pole, které obsahuje pouze ukazatele na jednotlivé trojice a které definuje jejich skutečné polohy.

8.2. DEKLARACE

```
P →
  D
D → D : D
D → id: T
T → integer
T → real
T → array [ num ] of T
T → ↑ Ti
{ offset := 0 }

{ enter(id.name, T.type, offset);
  offset := offset + T.width }

{ T.type := integer;
  T.width := 4 }

{ T.type := real;
  T.width := 8 }

{ T.type := array(num.val, Ti.type);
  T.width := num.val * Ti.width }

{ T.type := pointer(Ti.type);
  T.width := 4 }
```

Obrázek 8.8: Výpočet typů a relativních adres v deklaracích

Pomocí nonterminálů generujících prázdný řetězec (markerů) můžeme taková pravidla přepsat do tvaru, kdy jsou všechny akce na konci pravidel. Např. s využitím nonterminálu `M` přepsíme (8.1) na

```
P → M D
M → ε {offset := 0}
```

Přesun akcí na konec pravidel umožňuje provádět překlad zdola nahoru, kdy se sémantické akce provádějí během redukce pravé strany pravidla.

8.2.2 Deklarace v jazyčích s blokovou strukturou

V jazyčích jako je Pascal nebo C mohou být jednotlivé bloky deklarácií do sebe zanořené. Na začátku zanořeného bloku deklarácií se dočasně potlačí zpracování deklarácií nadřazeného bloku, ve kterém se pokrajuje až po uzavření zanořeného bloku. V kapitole 5 jsme pro tento účel zavedli operace `tabopen` a `tabclose`, které otevíráy a zavírají jednu úroveň blokově strukturované tabulky symbolů. Následující příklad ukazuje, jak se bloková struktura jazyka odrazí ve zpracování deklarácií.

Příklad 8.2. Jazyk deklarácií z příkladu 8.1 rozšíříme o pravidlo

```
D → proc id : D : S
```

umožňující deklarovat proceduru s lokálními deklaráciemi. Na začátku vnořeného bloku deklaráci musíme nejdříve uschovat současnou hodnotu čítače `offset` (použijeme k tomu atributu markeru `M`), nastavit tento čítač na nulu a otevřít novou úroveň tabulky symbolů. Po ukončení této bloku naopak uzavřeme současnou úroveň a obnovíme původní hodnotu čítače viz obr. 8.9.

Jazyk C sice neumožňuje do sebe vkládat deklaráci funkci, avšak dovoluje do sebe zařeňovat bloky deklarácií proměnných. Všechny proměnné v zanořených blocích spolu sdílejí společnou oblast paměti; jejich relativní adresy se počítají od začátku oblasti lokálních proměnných funkce, v níž jsou deklarovány. To znamená, že při vstupu do bloku musíme nechat

	op	arg1	arg2	result		op	arg1	arg2
(0)	uminus	c		t1	(0)	uminus	c	
(1)	*	b	t1	t2	(1)	*	b	(0)
(2)	uminus	c		t3	(2)	uminus	c	
(3)	*	b	t3	t4	(3)	*	b	(2)
(4)	+	t2	t4	t5	(4)	+	(0)	(3)
(5)	assign	t5		a	(5)	assign	a	(4)

(a) Čtvrtice

(b) Trojice

Obrázek 8.6: Reprezentace tříadresových příkazů trojicemi a čtvrticemi

	prička		op	arg1	arg2
(0)	(14)		(14)	uminus	c
(1)	(15)		(15)	*	b
(2)	(16)		(16)	uminus	c
(3)	(17)		(17)	*	b
(4)	(18)		(18)	+	(15)
(5)	(19)		(19)	assign	a

Obrázek 8.7: Reprezentace tříadresových příkazů nepřímými trojicemi

8.2 Deklarace

8.2.1 Deklarace proměnných

Při zpracování deklarácií je základním úkolem překládače vytváření tabulky symbolů. S tím ovšem souvisí i shromažďování informací o datových typech a velikostech jejich reprezentace a přidělování adres proměnným a složkám záznamů, což již není nezávislé na generování cílového kódů. Překládač musí uvažovat nejen konkrétní velikosti objektů různých typů, ale také další požadavky definující architekturu cílového počítače, například zarovnávání. Při vytváření přemístitelného kódu je adresa objektu definována vždy dvěma údaji: příslušnosti do určité samostatné adresované skupiny objektů (např. globální a lokální proměnné nebo procedury, konstanty, externí proměnné) a relativní adresu vzhledem k začátku této skupiny. Pro každou takovou skupinu můžeme udílovat samostatný čítač adres, který se při deklaráci objektu patřícího k příslušné skupině vždy zvýší o velikost datového typu objektu.

Příklad 8.1. Překládací schéma na obr. 8.8 popisuje překlad posloupnosti deklarácií ve tvaru `id: T`. Současná relativní adresa pro deklarování proměnné je uložena v promené `offset`, a je na začátku nastavena na nulu. Procedura `enter(name, type, offset)` vytvoří novou položku tabulky symbolů pro proměnnou `name` typu `type`, které bude přidělena relativní adresa `offset`. Syntetizované atributy `type` a `width` nonterminálu `T` představují typ a jeho velikost. Typ je reprezentován grafem, jehož údaje se vytvářejí ze základních typů `integer` a `real` funkemi `array` a `pointer`. Předpokládáme, že hodnoty typu `integer` a ukazatele vyzadují 4 slabiky a hodnoty typu `real` 8 slabik paměti.

Inicializace proměnné `offset` ve schématu na obr. 8.8 má tvar

$$P \rightarrow \{offset := 0\}D \quad (8.1)$$

```
D → proc id : M : S { tabclose();
  offset := M.offset }
M →
{ M.offset = offset;
  offset = 0;
  tabopen() }
```

Obrázek 8.9: Zpracování zanořených deklarácií

hodnotu `offset` bez změny. Při výstupu z bloku můžeme obnovit původní hodnotu a případně tak využít uvolněné paměti pro další proměnné.

Podobným způsobem jako lokální proměnné se zpracovávají také deklaráce položek záznamů. Na začátku deklarácie záznamu se rovněž otevře nová úroveň tabulky symbolů a vymuší se čítač adres, při ukončení záznamu se však musí deklaráce položek, které se při zpracování těla záznamu doložily do tabulky, uchovat jako atribut datového typu záznamu. Tyto deklaráce se totiž budou dle použití při odkazech na složky záznamu výrazech. Nejdříve musíme implementovat úlohy položek záznamu, jež při použití tabulky symbolů strukturované jako zásobník stromů – uschová se ukazatel na kořen stromu pro poslední otevřenou úroveň tabulky. Deklarace položek záznamu s variantami (v jazyce Pascal) probíhá obdobně, pouze se po deklaráci nové úrovně nezvysňuje čítač adres a tím se všem odpovídajícím položkám přidělí totožné místo. Pouze je třeba sledovat délku největší položky, která se stane délkou celého datového typu.

S deklarácemi položek záznamů také souvisí zpracování příkazu `with` jazyka Pascal. Tento příkaz zpřístupní současně všechny složky určitého záznamu. Příkaz `with` se dříve implementoval tak, že znovu otevřene novou úrovně deklaráci a vložíme do ní část tabulky symbolů, kterou jsme uschovali při dokončení deklaráce záznamu. Po ukončení platnosti příkazu `with` opět všechny zrušíme.

8.3 Přiřazovací příkazy a výrazy

Pro překlad celočíselných aritmetických výrazů a přířazení do jednoduchých proměnných můžeme použít schématu z obr. 8.10. V tomto schématu se používá funkce `lookup` pro vyhledání proměnné v tabulce symbolů na základě jejího jména; pokud se jméno v tabulce neobjeví, funkce vrátí hodnotu `nil`. Funkce `newtype` vrátí ukazatel na nově vytvořenou dočasnou proměnnou. Dočasné proměnné mohou být obecně uloženy rovněž v tabulce symbolů, pokud jiné funkce nejsou v tabulce symbolů uloženy.

Sémantické akce na obr. 8.10 používají pro výstup tříadresových příkazů procedury `emit`, jejichž parametry uvádějí zdrojového bloku, dočasného bloku a výsledek. Příkaz `emit` je implementován funkcií `lookup`, která vrací hodnotu, kterou můžeme použít programátorem pro proměnné v programu.

Sémantické akce na obr. 8.10 používají pro výstup tříadresových příkazů procedury `emit`, jejichž parametry uvádějí zdrojového bloku a výsledek. Příkaz `emit` je implementován funkcií `lookup`, která vrací hodnotu, kterou můžeme použít programátorem pro proměnné v programu.

Uvedené překládací schéma se dá použít i v případě, že pracujeme s jazykem, který má blokovou strukturu, neboť jedná zámeňa nastane v implementaci funkce `lookup` (viz kapitola 5). Dočasné proměnné se považují vždy za lokální proměnné podprogramu, ve kterém jsou použity.

```

 $S \rightarrow id := E$  {  $p := lookup(id.name);$ 
     $\text{if } p \neq \text{nil} \text{ then}$ 
         $\text{emit}(p' := E.place)$ 
     $\text{else error}$  }

 $E \rightarrow E_1 + E_2$  {  $E.place := newtemp;$ 
     $\text{emit}(E.place' := E_1.place' +' E_2.place)$  }

 $E \rightarrow E_1 * E_2$  {  $E.place := newtemp;$ 
     $\text{emit}(E.place' := E_1.place' *' E_2.place)$  }

 $E \rightarrow - E_1$  {  $E.place := newtemp;$ 
     $\text{emit}(E.place' := 'uminus' E_1.place)$  }

 $E \rightarrow ( E_1 )$  {  $E.place := E_1.place$  }

 $E \rightarrow id$  {  $p := lookup(id.name);$ 
     $\text{if } p \neq \text{nil} \text{ then}$ 
         $E.place := p$ 
     $\text{else error}$  }

```

Obrázek 8.10: Překladové schéma pro překlad aritmetických výrazů a přiřazení

8.3.1 Přidělování dočasných proměnných

Při přidělování dočasných proměnných se dají použít dvě odlišné strategie. Pro optimalizující překladače je výhodné, pokud každé volání *newtemp* vrátí nové jméno, odlišné od všech předchozích. To však může mít za následek přeflovnání tabulky symbolů (nebo obecně pravou paměti) informacemi, které se používají jen velmi krátce.

Další možností, která se využívá zejména v jednopřichodových překladačích, je vícenásobné využívání dočasných proměnných. Ze schématu na obr. 8.10 je zřejmé, že např. překladem výrazu $E_1 + E_2$ vznikne kód ve tvaru

```

vypočti  $E_1$  do proměnné  $t_1$ 
vypočti  $E_2$  do proměnné  $t_2$ 
 $t := t_1 + t_2$ 

```

po jehož vypočtení již nejsou proměnné t_1 a t_2 dále potřebné. Doba života všech dočasných proměnných použitých pro vypočtení E_1 je vlastně zanořena do doby života proměnné t , takže je možné upravit funkci *newtemp* tak, že pro přidělování dočasných proměnných využívá zásobníku. Rovněž je možné do schématu zahrát explicitní volání procedury pro uvoľnení dočasné proměnné: tato proměnná se zařadí do seznamu volných dočasných proměnných, odkud se pak může znova použít při dalším volání *newtemp*.

Přidělování dočasných proměnných je poněkud komplikovanější, pokud jin může být přidělena hodnota více než jedenkrát, např. v podmínečném výrazu $a > b ? a : b$ v jazyce C se musí hodnota oboru větví dostat do téže proměnné. Podobný problém nastává tehdy, pokud prováděme optimalizaci spojčených podvýrazů: tehdy se může hodnota jedné dočasné proměnné použít na více místech.

8.3.2 Adresování prvků polí

Pole obsahuje vždy prvky stejného typu, které se mohou umístit bezprostředně jeden za druhým do společného bloku paměti. Je-li velikost každého prvku w , je i -tý prvek pole A uložen

na adresu

$$\text{base} + (i - low) \times w \quad (8.2)$$

kde low je dolní mez indexů pole a $base$ je relativní adresa přidělené oblasti paměti (neboli relativní adresa prvku $A[low]$). Výraz (8.2) můžeme přepsat do tvaru, který umožňuje jeho částečné vypočtu již v době překladu:

$$i \times w + (\text{base} - low) \times w$$

Podvýraz $c = base - low \times w$ se dá vypočítat v okamžiku deklarace pole a uložit do tabulky symbolů pro A. Při generování kódu pro přístup k prvku $A[i]$ získáme jeho relativní adresu jednoduše přičtením $i \times w$ k c.

Stejnou úvahu můžeme provést pro vícerozměrné pole. Dvojrozměrná pole se obvykle ukládají v paměti po řádcích, kdy můžeme pro výpočet relativní adresy prvku $A[i_1, i_2]$ použít výrazu

$$\text{base} + ((i_1 - low_1) \times n_2 + i_2 - low_2) \times w$$

kde low_1 a low_2 jsou dolní meze indexů i_1 a i_2 a n_2 je počet sloupců pole, tj. $n_2 = high_2 - low_2 + 1$, kde $high_2$ je horní mez indexu i_2 . Uvedený výraz můžeme opět přepsat do tvaru, ve kterém je oddělena konstantní a proměnná část adresy, jako

$$((i_1 \times n_2) + i_2) \times w + (\text{base} - ((low_1 \times n_2) + low_2) \times w) \quad (8.3)$$

Druhý operand tohoto součtu může být vypočten již v době překladu.

Zobecněním výrazu 8.3 pro k-rozměrné pole uložené tak, že se poslední index mění nejrychleji, dostaneme pro relativní adresu prvku $A[i_1, i_2, \dots, i_k]$ následující výraz (*mapovací funkci*):

$$((\dots((i_1 \times n_2) + i_2) \times n_3 + i_3) \dots) \times n_k + i_k) \times w \\ + \text{base} - ((\dots((low_1 \times n_2) + low_2) \times n_3 + low_3) \dots) \times n_k + low_k) \times w \quad (8.4)$$

Vzhledem k tomu, že pro j -tý index předpokládáme pevnou hodnotu $n_j = high_j - low_j + 1$, můžeme výraz na druhém řádku v (8.4) vypočítat v době překladu a uložit do položky tabulky symbolů pro A. V jazyce C je celý výpočet jednodušší, neboť dolní mez všech indexů je vždy nulová, takže konstantní část výrazu (8.4) je vždy rovna pouze *base*.

Překladové schéma na obr. 8.11 popisuje překladovacích příkazů s aritmetickými výrazy a indexy. Toto schéma přímo implementuje výpočet podle vzorce (8.4). Oproti schématu z obr. 8.10 je operandem, resp. levou stranou přiřazení místo symbolu *id* nonterminál *L* představující *l*-hodnotu (tj. hodnotu, která může stat na levé straně přiřazení). Pro tento nonterminál můžeme zavést následující pravidla:

$$L \rightarrow id [Elist] | id \\ Elist \rightarrow Elist . E | E$$

Pro vlastní výpočet je však výhodnejší tato pravidla přepsat do tvaru, kdy máme během zpracování indexů již k dispozici ukazatele na položku tabulky symbolů pro indexované pole:

$$L \rightarrow Elist | id \\ Elist \rightarrow Elist . E | id [E$$

Ve schématu na obr. 8.11 se tento ukazatel předává jako atribut *Elist.array*. Dále se pro počet dimenzí (indexových výrazů) používá atribut *Elist.ndim*. Funkce *limit(array, j)* vrátí hodnotu n_j , počet prvků v j -té dimenzi pole, na jehož záznam v tabulce symbolů ukazuje *array*. Funkce *c(array)* vrátí konstantní část výrazu (8.4) pro pole *array*. Atribut *Elist.place* obsahuje jenom dočasné proměnné, do které byla uložena hodnota vypočtená z indexových výrazů v *Elist*.

```

(1)  $S \rightarrow L := E$  {  $\text{if } L.offset = \text{null} \text{ then /* } L \text{ je jednoduchá proměnná */}$ 
     $\text{emit}(L.place' := E.place);$ 
     $\text{else}$ 
         $\text{emit}(L.place' [ L.offset ]' := E.place) \}$ 

(2)  $E \rightarrow E_1 + E_2$  {  $E.place := newtemp;$ 
     $\text{emit}(E.place' := E_1.place' +' E_2.place) \}$ 

(3)  $E \rightarrow ( E_1 )$  {  $E.place := E_1.place \}$ 

(4)  $E \rightarrow L$  {  $\text{if } L.offset = \text{null} \text{ then /* } L \text{ je jednoduchá proměnná */}$ 
     $E.place := L.place$ 
     $\text{else begin}$ 
         $E.place := newtemp;$ 
         $\text{emit}(E.place' := L.place' [ L.offset ]) \}$ 
     $\text{end} \}$ 

(5)  $L \rightarrow Elist$  [ {  $L.place := newtemp;$ 
     $L.offset := newtemp;$ 
     $\text{emit}(L.place' := c(Elist.array));$ 
     $\text{emit}(L.offset' := Elist.place' *' width(Elist.array)) \}$ 

(6)  $L \rightarrow id$  {  $L.place := id.place;$ 
     $L.offset := \text{null} \}$ 

(7)  $Elist \rightarrow Elist . E$  {  $t := newtemp;$ 
     $m := Elist.ndim + 1;$ 
     $\text{emit}(t' := Elist.place' *' limit(Elist.array, m));$ 
     $\text{emit}(t' := t' +' E.place);$ 
     $Elist.array := Elist.array;$ 
     $Elist.place := t;$ 
     $Elist.ndim := m \}$ 

(8)  $Elist \rightarrow id [ E$  {  $Elist.array := id.place;$ 
     $Elist.place := E.place;$ 
     $Elist.ndim := 1 \}$ 

```

Obrázek 8.11: Překladové schéma pro výrazy s indexy

Nonterminál *L*, reprezentující *l*-hodnotu, má dva atributy, *L.place* a *L.offset*. Je-li *L* jednoduchá proměnná, obsahuje *L.place* ukazatel na příslušnou položku tabulky symbolů a *L.offset* je null. V opačném případě ukazuje *L.place* na položku tabulky symbolů pro pole a *L.offset* na položku pro dočasnou proměnnou, do které byla uložena vypočtená relativní adresa prvku pole.

Příklad 8.3. Nechť *A* je pole 10×20 s dolnímimezemi indexů $low_1 = low_2 = 1$. Počty prvků v jednotlivých dimenzích jsou tedy $n_1 = 10$ a $n_2 = 20$. Nechť velikost prvku *w* je 4. Přiřazení $x := A[ly, zj]$ se přeloží do následující posloupnosti tříadresových příkazů:

```

t1 := y * w
t1 := t1 + z /* konstanta c = base_A - 84 */
t3 := 4 * t1
t4 := t2[t3]
x := t4

```

V příkladu jsme použili místo atributu *id.place* přímo jméno proměnné.

8.3.3 Konverze typů během přiřazení

V uvedených příkladech překladových schémat jsme zatím uvažovali pouze aritmetické výrazy tvořené operandy téhož typu. V praxi se však běžně pracuje se smíšenými výrazy, u nichž musí překladač bud vygenerovat příslušnou implicitní typovou konverzitu, nebo musí nahlásit chybu.

```

E.place := newtemp;
if E1.type = integer and E2.type = integer then begin
    emit(E.place' := E1.place' int +' E2.place);
    E.type := integer
end
else if E1.type = real and E2.type = real then begin
    emit(E.place' := E1.place' real +' E2.place);
    E.type := real
end
else if E1.type = integer and E2.type = real then begin
    u := newtemp;
    emit(u' := 'inttoreal' E1.place);
    emit(E.place' := u'real +' E2.place);
    E.type := real
end
else if E1.type = real and E2.type = integer then begin
    u := newtemp;
    emit(u' := 'inttoreal' E2.place);
    emit(E.place' := E1.place'real +' u);
    E.type := real
end
else
    E.type := type_error;

```

Obrázek 8.12: Sémantická akce pro pravidlo $E \rightarrow E_1 + E_2$

Uvažujme například jednoduché rozšíření aritmetického výrazu o datové typy *real* a *integer* s možností implicitní konverze celočíselného operantu na reálný ve smíšených výzrazech. K tomu musíme zavést nový atribut *E.type*, jehož hodnota *real* nebo *integer* reprezentuje typ příslušného výrazu. Sémantická pravidla ve schématech na obr. 8.10 a 8.11 musíme rozšířit o výpočet tohoto atributu a generování odpovídajících konverzí a aritmetických operátorů. Pro převod hodnoty *y* typu *integer* na reálnou hodnotu *x* budeme generovat

na vhodných místech instrukci $x := \text{inttoreal}$ a budeme rozlišovat typ prováděné aritmetické operace. Například pro pravidlo $E \rightarrow E_1 + E_2$ můžeme použít semantickou akci z obr. 8.12.

V reálné implementaci výrazů se sumujícími operandy se nevytváří samostatné pravidlo pro každý operátor; spíše se používá společný podprogram, jehož jedním parametrem je operátor, pro který se má vygenerovat kód. Často se generování kódů pro výrazy také řeší pomocí tabulek — například můžeme použít tabulku, ze které pro zadané typy operandů získáme informaci o tom, zda je tato kombinace přípustná a zda generovat určitou typovou konverzi pro některý z operandů.

Příklad 8.4. Za předpokladu, že proměnné x a y mají typ $real$ a i a j typ $integer$, můžeme pro vstup $x := y * i * j$ vygenerovat kód

```
t1 := i int* j
t3 := inttoreal t1
t2 := y real* t3
x := t2
```

8.4 Booleovské výrazy

Booleovské výrazy se v programovacích jazycích používají ke dvěma hlavním účelům — pro výpočet logických hodnot a (především) jako podmínky v příkazech pro změnu toku řízení (jako je např. podmíněný příkaz nebo příkaz cyklu).

Booleovské výrazy jsou tvorové operátory jako **and**, **or** nebo **not** a operandy, kterými mohou být booleovské konstanty, proměnné nebo relační výrazy. V některých jazycích mohou být operandy booleovských výrazů hodnoty i jiných typů. Pro další výklad budeme vycházet z této gramatiky booleovského výrazu:

$$E \rightarrow E \text{ or } E \text{ and } E \mid (E) \text{ id } \text{rellop id} \mid \text{true} \mid \text{false}$$

Terminální symbol **rellop** bude mít atribut *op* určující jeden ze šesti relačních operátorů.

Pro reprezentaci booleovských hodnot a překlad booleovských výrazů se používají dvě základní metody. První metoda reprezentuje logické hodnoty jako čísla a vyhodnocuje booleovské výrazy stejně jako aritmetické. Pro kódování booleovských hodnot se často používá 0 jako false a 1 nebo nenulová hodnota jako true.

Druhou základní metodou je reprezentace booleovských výrazů tokem řízení, tj. pozici dosaženou v programu. Tato metoda je zvláště výhodná pro implementaci řídicích příkazů, neboť umožňuje jejich efektivnější vyhodnocování — pokud např. ve výrazu E_1 **or** E_2 zjistíme, že hodnota jednoho operantu je true, nemusíme již vyhodnocovat druhý operant.

To, zda můžeme použít první nebo druhou metodu, je dletočně implementovaného programovacího jazyka. Dovoluje-li jazyk pouchevat některou části výrazu nevhodněnou, může překladač provést optimální reprezentaci booleovského výrazu a vyhodnotit jen tu část výrazu, kterou potřebuje. Pokud však některý z operandů má vedený dřívek (např. se v něm volá funkce, která mění hodnotu nějaké globální proměnné), můžeme při zkráceném vyhodnocení výrazu dostat neocíkavé výsledky. Obecně nelze říci, která z obou metod je vyhodněnější; některé překladače umožňují pomocí parametru metodu překladu určit nebo dovedou vybrat vhodnou metodu na základě analýzy každého konkrétního výrazu.

```
100: if a < b goto 103      107: t2 := 1
101: t1 := 0                 108: if e < f goto 111
102: goto 104                109: t3 := 0
103: t1 := 1                 110: goto 112
104: if c < d goto 107      111: t3 := 1
105: t2 := 0                 112: t4 := t2 and t3
106: goto 108                113: t5 := t1 or t4
```

Obrázek 8.14: Překlad výrazu $a < b \text{ or } c < d \text{ and } e < f$

zde se dostaneme na řádek 101 nebo 103 a podle toho pokračovat ve vyhodnocování zbytku výrazu; samotná hodnota proměnné $t1$ je redundantní.

Překladové schéma na obr. 8.15 využívá pro zkrácené vyhodnocení výrazu dělících atributů $E.true$, $E.false$, které obsahují jmenovité návěsti, na které má program přejít. Jejich hodnota příslušného podvýrazu true, resp. false. Nontermínum M s atributem $M.lab$ slouží pouze pro vygenerování návěsti před vyhodnocením druhého operandu binárního operátoru. Funkce $ncwlabel$ při každém volání vrátí novou, ještě nepoužitou návěstí.

```
E → E1 or M E2 { E1.true := E2.true;           E1.false := M.lab := ncwlabel;
                      E2.false := E1.false }
E → E1 and M E2 { E1.false := E2.false := E1.false;           E1.true := M.lab := ncwlabel;
                      E2.true := E1.true }
E → not E1 { E1.true := E1.false;           E2.false := E1.true }
E → ( E1 ) { E1.true := E1.true;           E1.false := E1.false }
E → id1 rellop id2 { gen('if' id1.place rellop op id2.place 'goto' E.t);
                           gen('goto' E.false) }
E → true { gen('goto' E.true) }
E → false { gen('goto' E.false) }
M → ε { gen(M.lab := :) }
```

Obrázek 8.15: Překladové schéma pro zkrácené vyhodnocení booleovských výrazů

Pro každý relační operátor se vygeneruje podmíněný skok na návěstí $E.true$ a nepodmíněný skok na návěstí $E.false$. Všechny další operace spočívají pouze ve vhodném vytváření a kombinování návěsti pro tyto dva skoky. Například předpokládejme, že máme výraz ve tvare E_1 **and** E_2 . Má-li E_1 hodnotu false, bude mít i celý výraz E hodnotu false a můžeme tedy pro E_1 .false použít hodnotu $E.false$. Má-li E_1 hodnotu true, musíme vyhodnotit ještě E_2 , takže použijeme $E_1.true$ jako návěstí prvního příkazu pro E_2 . Podobná úvaha platí i pro operátor **or**. Pro výraz ve tvare **not** E nepotřebujeme dokonce vůbec žádají kód, pouze vyměníme úlohy atributů $E.true$ a $E.false$.

Příklad 8.6. Na základě schématu z obr. 8.15 můžeme pro booleovský výraz $a < b \text{ or } c < d \text{ and } e < f$ vygenerovat kód uvedený na obr. 8.16. ■

8.4.1 Reprezentace booleovských výrazů číselnou hodnotou

Za předpokladu, že budeme logické hodnoty reprezentovat čísky 0 a 1 a provádět úplný vyhodnocení, můžeme výraz a **or** b **and** c přeložit do tříadresového kódu jako

```
t1 := not c
t2 := b and t1
t3 := a or t2
```

Pokud výraz obsahuje relační operátor, musíme z výsledku relace nejprve odvodit příslušnou číselnou hodnotu. Například výraz $x < y$ se přeloží jako

```
100: if x < y goto 103
101: t1 := 0
102: goto 104
103: t1 := 1
```

Překladový schéma pro generování tříadresového kódu pro booleovské výrazy je na obr. 8.13. Předpokládámme, že procedura *cinit* zapisuje do vystupující soubornu tříadresové příkazy a že proměnná *nextstat* obsahuje index následujícího příkazu tříadresového kódu, zvyšovaný procedurou *cinit*.

```
E → E1 or E2 { E.place := ncwtemp;
                      cinit(E.place := :) E1.place 'or' E2.place ) }
E → E1 and E2 { E.place := ncwtemp;
                      cinit(E.place := :) E1.place 'and' E2.place ) }
E → not E1 { E.place := ncwtemp;
                      cinit(E.place := :) 'not' E1.place ) }
E → ( E1 ) { E.place := E1.place }
E → id1 rellop id2 { E.place := ncwtemp;
                      cinit('if' id1.place rellop op id2.place 'goto' nextstat + 3);
                      cinit(E.place := :) '0' );
                      cinit('goto' nextstat + 2);
                      cinit(E.place := :) '1' )
}
E → true { E.place := ncwtemp;
                      cinit(E.place := :) '1' )
}
E → false { E.place := ncwtemp;
                      cinit(E.place := :) '0' ) }
```

Obrázek 8.13: Překladové schéma pro číselnou reprezentaci booleovských výrazů

Příklad 8.5. Na základě schématu z obr. 8.13 můžeme pro booleovský výraz $a < b \text{ or } c < d \text{ and } e < f$ vygenerovat kód uvedený na obr. 8.14. ■

8.4.2 Zkrácené vyhodnocování booleovských výrazů

Metoda zkráceného vyhodnocování booleovských výrazů umožňuje zpracovat booleovské výrazy bez jejich úplného vyhodnocení. Při této metodu se logické hodnoty nereprezentují jako data; každý kombinaci logických hodnot operandů ve výrazu místo toho odpovídá určitá pozice ve vygenerovaném kódu, na kterou se program dostane pomocí podmíněných a ne-podmíněných skoků. Například na obr. 8.14 můžeme hodnotu proměnné $t1$ odvodit z toho,

```
if a < b goto Ltrue
goto L1
L1: if c < d goto L2
goto Lfalse
L2: if e < f goto Ltrue
goto Lfalse
```

Obrázek 8.16: Zkrácený překlad výrazu $a < b \text{ or } c < d \text{ and } e < f$

Kód vygenerovaný podle schématu z obr. 8.15 není optimální. Například na obr. 8.16 lze využít druhý řádek, anž se nějak ovlivní funkce programu. Vygenerovaný kód lze optimalizovat buď dodatečně, nebo je možné do překladového schématu začlenit akce, které budou určit optimální vyhodnocování kódu, na kterou se program dostane pomocí podmíněných skoků. Například na obr. 8.14 můžeme hodnotu proměnné $t1$ odvodit z toho,

L1: if c > d goto Lfalse

můžeme využít i následující skok na návěst **Lfalse**.

V některých jazycích, jako je např. jazyk C, se booleovské výrazy mohou libovolně kombinovat s ostatními aritmetickými výrazy. Schéma pro překlad takových kombinovaných výrazů musí zajistit přechod mezi reprezentací toku řízení a číselnou reprezentací logických hodnot. Obr. 8.17 ukazuje dvě taková pravidla pro aritmetický výraz AE a booleovský výraz BE .

```
AE → BE { BE.true := ncwlabel;
            BE.false := ncwlabel;
            templat := ncwlabel;
            AE.place := ncwtemp;
            gen(BE.true := :) );
            gen(AE.place := :) '1';
            gen('gen' templat);
            gen(BE.false := :) );
            gen(AE.place := :) '0';
            gen(templat := :) }
BE → AE { gen('if' AE.place <> '0' 'goto' BE.true);
            gen('goto' BE.false) }
```

Obrázek 8.17: Pravidla pro překlad smíšených booleovských výrazů

8.5 Příkazy pro změnu toku řízení

Nyní se pokusíme předvédat metody překladu booleovských výrazů začlenit do překladu řídicích příkazů. Budeme uvažovat příkazy generované následující gramatikou:

```
S → if E then S1
| if E then S1 else S2
| while E do S1
```

V těchto pravidlech je vždy E booleovský výraz. Při překladu s úplným vyhodnocením bude mít E syntetizovaný atribut $E.place$, jinému proměnnému obsahující hodnotu výrazu, při zkrá-

ceném překladu tokem řízení bude mít E naopak dva *dědiče* atributy obsahující návěstí pro hodnotu true ($E.true$) a false ($E.false$), stejně jako v předcházejících odstavcích.

$S \rightarrow \text{if } E \text{ then } M_1 S_1$	{ $E.true := newlabel;$ $E.false := newlabel;$ $M_1.lab := E.true;$ $gen(E.false ':')$ }
$S \rightarrow \text{if } E \text{ then } M_1 S_1 \text{ else } N M_2 S_2$	{ $E.true := newlabel;$ $E.false := newlabel;$ $M_1.lab := E.true;$ $M_2.lab := E.false;$ $N.lab := newlabel;$ $gen(N.lab ':')$ }
$S \rightarrow \text{while } M_1 E \text{ do } M_2 S_1$	{ $M_1.lab := newlabel;$ $M_2.lab := E.true;$ $gen('goto' M_1.lab);$ $gen(E.false ':')$ }
$M \rightarrow \epsilon$	{ $gen(M.lab ':')$ }
$N \rightarrow \epsilon$	{ $gen('goto' N.lab)$ }

Obrázek 8.18: Překladové schéma pro řidicí příkazy

Překladové schéma na obr. 8.18 vychází z předpokladu, že booleovské výrazy se překládají zkárečně. Pro vkládání návěsti a skoků do řidicích konstrukcí se zde používají nonterminál M a N s dědičním atributem *lab* označujícím jiného návěsti pro definici nebo skok. Nonterminál N zajišťuje v úplném příkazu *if* přeskok části *else* při splnění podmínky.

Příklad 8.7. Uvažujme příkaz

```
while a < b do
    if c < d then
        x := y + z
    else
        x := y - z
```

Na základě schémat na obr. 8.10, 8.15 a 8.18 můžeme pro tento příkaz vygenerovat následující tříadresový kód:

```
L1: if a < b goto L2
     goto Lnext
L2: if c < d goto L3
     goto L4
L3: t1 := y + z
     x := t1
     goto L1
L4: t2 := y - z
     x := t2
     goto L1
Lnext:
```

Pokud obrátíme směr relací v prvním a třetím řádku, můžeme vypustit za nimi následující nepodmíněné skoky. ■

8.7. BACKPATCHING

kód vygenerovaný pro jednotlivé varianty. Každá varianta je pak označena návěstím a končí skokem na příkaz následující za selektivním příkazem (V jazyce C se tento skok generuje pouze pro explicitně zapsaný příkaz *break*).

```
kód pro vyhodnocení  $E$  do proměnné  $t$ 
goto test
L1: kód pro  $S_1$ 
     goto next
L2: kód pro  $S_2$ 
     goto next
     ...
Ln: kód pro  $S_n$ 
     goto next
test:if t =  $V_1$  goto L1
      if t =  $V_2$  goto L2
      ...
      if t =  $V_n$  goto Ln
next:
```

Obrázek 8.20: Překlad selektivního příkazu

Cáste kód uvedená mezi návěstmi *test* a *next* odpovídá vlastnímu selektivnímu příkazu a její struktura tedy závisí na zvolené metodě překladu. Pokud nechceme tento problém řešit již při generování mezikódu, lze rozšířit mezikód o speciální příkazy reprezentující selektivní příkaz, např. takto:

```
test: select t,Def
      case  $V_1, L_1$ 
      case  $V_2, L_2$ 
      ...
      case  $V_n, L_n$ 
next:
```

Příkaz *select* má jako parametr odkaz na místo, kde je uložena hodnota vypočteného výrazu a návěsti pro implicitní variantu. Příkaz *case* definuje hodnotu konstanty a návěsti příslušného příkazu pro každou uvedenou variantu. Konec seznamu příkazu *case* je jednoduše rozpoznatelný podle návěsti, které musí vždy následovat. O skutečné metodě překladu se pak může rozhodnout až při generování kódu, kdy bude například využit některých speciálních instrukcí procesoru.

8.7 Backpatching

V předchozích odstavcích jsme si předvedly několik různých metod generování mezikódu pro řidicí příkazy. Nezábývali jsme se však vlastním přiřazením adres pro jednotlivá návěsti, občaseli jsme jej použitím symbolických jmen. Při viceprichodovém překladu se totiž přiřazení může provést v samostatném průchodu vygenerovaným kódem, kdy už jsou známy všechny vygenerované instrukce i rozmištění jednotlivých návěstí. Pokud se ale překlad provádí jednoprichodově, dostáváme se velmi často do situace, kdy neznáme v určitém bodě číselovou adresu návěsti, neboť kód, který bude tímto návěstem označen, ještě nebyl vygenerován.

8.6 Selektivní příkazy

Selektivní příkazy typu switch nebo case jsou dostupné v mnoha jazycích. Představují vlastní zobecněný příkaz i s více variantami. Obecně mají tyto příkazy strukturu obdobnou jako na obr. 8.19. Výraz E v záhlaví selektivního příkazu se využívá a v případě, že se jeho hodnota rovná některé z uvedených konstant V_i , provede se příkaz S_i , uvedený za konstantou. V opačném případě, pokud je uvedena varianta *default*, se provede implicitní příkaz S_{def} .

```
switch E
begin
  case  $V_1$  :  $S_1$ 
  case  $V_2$  :  $S_2$ 
  ...
  case  $V_n$  :  $S_n$ 
  default :  $S_{def}$ 
end
```

Obrázek 8.19: Struktura selektivního příkazu

Selektivní příkazy můžeme implementovat mnoha různými způsoby v závislosti na intervalu, ve kterém leží uvedené konstanty, velikosti mezer mezi konstantami (počtu nevyužitých hodnot uvnitř intervalu mezi největší a nejmenší konstantou) a preferovaných vlastnostech vygenerovaného kódu (optimalizace na čas nebo velikost kódu). Obecně se používají následující metody:

- *Posloupnost podmíněných skoků*. Tato nejjednodušší varianta je výhodná pouze při malém počtu položek: každý podmíněný skok testuje jednu uvedenou variantu.
- *Tabulka dvojic*. Vytvoříme vyhledávací tabulku obsahující vždy hodnotu konstanty a návěsti začátku příkazu pro tuuto variantu. V tabulce pak můžeme vyhledávat některou z běžných metod. Nemůžeme hodnotu výrazu v tabulce nalezena, proveďte se implicitní varianta. Pro velké počty návěsti se někdy používá tabulka s rozptýlenými položkami.
- *Rozskaková tabulka*. V případě, že hodnoty konstant dostatečně hustě zaplnily určitý interval hodnot, například $< i_{min}, i_{max} >$, můžeme využít pole návěsti obsahující v j -tém prvku návěsti pro hodnotu $i_{min} + j$. Při vyhodnocení selektivního příkazu se nejprve zjistí, zda hodnota výrazu t leží v intervalu $< i_{min}, i_{max} >$ a pokud ano, provede se nejprvní skok na návěsti uložené v $(t - i_{min})$ -té položce tabulky. Nevyužití pozice v tabulce se zaplní návěstím pro implicitní variantu nebo chybou.

V praxi se rovněž používají modifikace uvedených metod nebo jejich kombinace. Například můžeme kromě podmíněného skoku testujícího rovnost hodnoty výrazu s některou konstantou vygenerovat zároveň odkos, je-li hodnota menší, a dále pak testovat odděleně již menší podmínky hodnot (je vlastně o implementaci binárního vyhledávacího stromu pomocí toku řízení). Po vymezení dostatečně kompaktní podmínky hodnot pak můžeme pro konečné vyhodnocení použít rozskakovou tabulku.

Překlad selektivního příkazu do tříadresového kódu má strukturu jako na obr. 8.20. Po vyhodnocení výrazu E se provede odkos na vlastní tělo selektivního příkazu, čímž se přeskocí

Tento problém můžeme řešit tak, že necháme adresu návěsti prázdnou a udržujeme seznam adres, ze kterých se na každé takové návěsti odkazujeme. V okamžiku, kdy dosáhneme místa obsahujícího definici návěsti, zpětne jeho adresu doplníme do všech míst uvedených v seznamu. Tato metoda zpětných oprav se nazývá *backpatching*. Implementaci si ukážeme na jednopřichodovém překlade řidicích příkazů s logickými výrazy vyhodnocovanými zkráceně.

Budeleme předpokládat, že generujeme číverce uložené v poli: návěsti pak budou indexy do pole číveric. Adresa následující volné číverce bude uložena v proměnné *nextquad*. Pro manipulaci se seznamy návěsti budeme používat následující podprogramy:

1. *makelist(i)* vytvoří nový seznam obsahující ponze index i ; vrátí ukazatel na vytvořený seznam.
2. *merge(p1, p2)* spojí dva seznamy, na které ukazuje p_1 a p_2 do jediného a vrátí ukazatel na takto vytvořený nový seznam.
3. *backpatch(p, i)* vloží i jako adresu návěsti do všech příkazů obsažených v seznamu, na který ukazuje p .

8.7.1 Booleovské výrazy

Při překladu booleovských výrazů dophňme do gramatiky nonterminál (marker) M , který bude sloužit pro uschování současně hodnoty čítače číverce *nextquad*. Upravená gramatika, pro kterou budeme dle výtvářet překladové schéma, je následující:

(1)	$E \rightarrow E_1 \text{ or } M E_2$
(2)	$E_1 \text{ and } M E_2$
(3)	$\text{not } E_1$
(4)	(E_1)
(5)	$\text{id}_i \text{ relop id}_2$
(6)	true
(7)	false
(8)	$M \rightarrow \epsilon$

Nonterminál M používá syntetizované atributy *trueList* a *falseList*, obsahující seznamy nejupředušných instrukcí s odkosy při hodnotě výrazu true a false. Sémantické akce vycházejí z následující úvaly: Například je-li v pravidle $E \rightarrow E_1 \text{ and } M E_2$ hodnota E_1 false, je i hodnota E false, takže všechny příkazy v E_1 , *trueList* se stanou částí E_2 , *falseList*. Je-li však E_1 true, musíme nejdříve testovat E_2 , takže číselovou adresu pro instrukce v E_1 , *trueList* musí být adresa začátku kódu pro vyhodnocení E_2 . Tu získáme pomocí markeru M , jehož atribut *Mquad* obsahuje právě index prvního příkazu pro E_2 . S pravidlem $M \rightarrow \epsilon$ je svazána sémantická akce

{ $M.quad := nextquad$ }

Hodnota čítače *nextquad* uschovávaná tímto nonterminálem bude sloužit pro zpětné opravy adres v seznamu *EtrueList* v okamžiku, kdy dosáhneme konci pravidla pro operátor *and*. Celé překladové schéma pro booleovské výrazy je uvedeno na obr. 8.21. Sémantické akce (5) generuje dva skoky, podmíněný a nepodmíněný. Oba tyto skoky směřují na dosud nezáznamen adresu, proto se jejich adresy zařadí do seznamů *EtrueList* a *EfalseList*. V pravidlech (6) a (7) se reprezentuje konstanta *true* a *false* jako nepodmíněný skok, jehož adresa se opět zařadí do příslušného seznamu neúplných skoků: druhý seznam v tomto případě

- (1) $E \rightarrow E_1 \text{ or } M E_2$ { $\text{backpatch}(E_1, \text{falselist}, M.\text{quad})$; $E.\text{truelist} := \text{merge}(E_1.\text{truelist}, E_2.\text{truelist})$; $E.\text{falselist} := E_2.\text{falselist}$ }
- (2) $E \rightarrow E_1 \text{ and } M E_2$ { $\text{backpatch}(E_1, \text{truelist}, M.\text{quad})$; $E.\text{truelist} := E_2.\text{truelist}$; $E.\text{falselist} := \text{merge}(E_1.\text{falselist}, E_2.\text{falselist})$ }
- (3) $E \rightarrow \text{not } E_1$ { $E.\text{truelist} := E_1.\text{falselist}$; $E.\text{falselist} := E_1.\text{truelist}$ }
- (4) $E \rightarrow (E_1)$ { $E.\text{truelist} := E_1.\text{truelist}$; $E.\text{falselist} := E_1.\text{falselist}$ }
- (5) $E \rightarrow \text{id}_1 \text{ relop id}_2$ { $E.\text{truelist} := \text{makelist}(nextquad)$; $E.\text{falselist} := \text{makelist}(nextquad + 1)$; $\text{cmif('if' id_1.place relop op id_2.place 'goto _')}$; cmif('goto _') }
- (6) $E \rightarrow \text{true}$ { $E.\text{truelist} := \text{makelist}(nextquad)$; $E.\text{falselist} := \text{nil}$; cmif('goto _') }
- (7) $E \rightarrow \text{false}$ { $E.\text{falselist} := \text{makelist}(nextquad)$; $E.\text{truelist} := \text{nil}$; cmif('goto _') }
- (8) $M \rightarrow \epsilon$ { $M.\text{quad} := nextquad$ }

Obrázek 8.21: Překladové schéma pro booleovské výrazy s backpatchingem

bude prázdný. Uvedené schéma může být použito přímo při překladu zdola nahoru, neboť uvedené sémantické akce se vyskytují na konci pravidel a mohou se tedy provádět zároveň s redukcemi.

Příklad 8.8. Uvažujme opět výraz $a < b$ or $c < d$ and $e < f$ jako v příkladu 8.6. Odpovídající ohodnocený derivační strom je uveden na obr. 8.22 (názvy atributů jsou zde zkráceny). Pro podvýraz $a < b$ se na základě pravidla (5) vygeneruje dvě čtvrtice

```
100: if a < b goto -
101: goto -
```

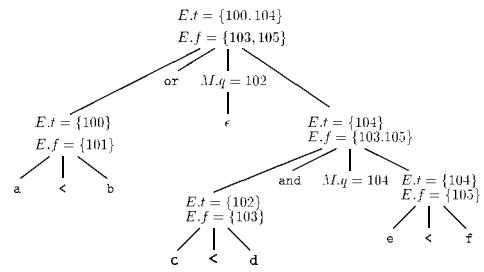
Nonterminál M v pravidle (1) zaznamená hodnotu $nextquad$, která je nyní 102. Redukce $c < d$ na E podle pravidla (5) vygeneruje čtvrtice

```
102: if c < d goto -
103: goto -
```

Nyní máme k dispozici nonterminál E_1 z pravidla (2). Následující marker M zaznamená současnou hodnotu $nextquad$, tj. 104. Redukce $e < f$ na E opět podle pravidla (5) vygeneruje

```
104: if y < f goto -
105: goto -
```

Dále nastane redukce podle pravidla $E \rightarrow E_1 \text{ and } M E_2$. Odpovídající sémantická akce volá proceduru $\text{backpatch}(\{102\}, 104)$, která doplní adresu 104 do příkazu 102. Konečně redukce podle pravidla $E \rightarrow E_1 \text{ or } M E_2$ volá $\text{backpatch}(\{101\}, 102)$, která doplní adresu 102 do příkazu 101. Tím dostaneme konečnou posloupnost příkazů ve tvaru

Obrázek 8.22: Ohodnocený derivační strom pro $a < b$ or $c < d$ and $e < f$

```
100: if a < b goto -
101: goto 102
102: if c < d goto 104
103: goto -
104: if e < f goto -
105: goto -
```

přičemž pro nonterminál E reprezentující celý výraz budeme mít atributy $E.\text{falselist} = \{103, 105\}$ a $E.\text{truelist} = \{100, 104\}$. To znamená, že celý výraz má hodnotu true, provedenou-li se skoky v příkazech 100 nebo 104, a hodnotu false, provedenou-li se skoky v příkazech 103 nebo 105. Cílové adresy tétočko skoků se doplní dále během překladu v závislosti na tom, co se má udělat při které hodnotě výrazu. ■

8.7.2 Překlad řídicích příkazů

Nyní předvedeme, jakým způsobem se dá backpatching použít při jednopřechodovém překladu řídicích příkazů. Pro překlad budeme používat následující gramatiku:

- (1) $S \rightarrow \text{if } E \text{ then } S$
- (2) | $E \text{ then } S \text{ else } S$
- (3) | $\text{while } E \text{ do } S$
- (4) | $\text{begin } L \text{ end}$
- (5) | A
- (6) $L \rightarrow L ; S$
- (7) | S

Nonterminál S označuje příkaz, L seznam příkazů. A přířazovací příkaz a E booleovský výraz. Pro booleovský výraz používáme výsledků předchozího odstavce, struktura přířazovacího příkazu, případně dalších jednočlenných příkazů naši výsledné zájmu.

Pro překlad zvolíme opět ten přístup, že budeme zpětně doplňovat adresy skoků v tom okamžiku, kdy dosáhneme jejich cílového příkazu. Kromě dvou seznamů adres pro booleovské

výrazy budeme rovněž potřebovat seznam adres skoků na kód, který následuje za příkazy generovanými nonterminály S a L ; na tento seznam bude ukazovat atribut $nextlist$.

Při překladu příkazu $S \rightarrow \text{while } E \text{ do } S_1$ budeme potřebovat dvě čtvrtice: jednu pro označení začátku celého příkazu S a jednu pro tělo cyklu S_1 . Adresy tétočko návěsti opět zaznamenáme pomocí dvou výslovných markerů M na příslušných pozicích v pravidle:

$S \rightarrow \text{while } M_1 E \text{ do } M_2 S_1$

S nonterminálem M bude opět sváženo pravidlo, které do atributu $M.\text{quad}$ uloží hodnotu čísla $nextquad$. Po zpracování těla S_1 se řízení vraci na začátek cyklu, takže při redukcii $\text{while } M_1 E \text{ do } M_2 S_1 \text{ na } S$ přepíšeme cílové adresy skoků ze seznamu $S_1.\text{nextlist}$ na $M_1.\text{quad}$. Vzhledem k tomu, že posledním příkazem S_1 nemusí být skok, musíme rovněž za tělo S_1 doplnit explicitní skok na začátek kódu pro E . Nakonec do příkazu v seznamu $E.\text{truelist}$ doplníme adresu začátku S_1 , tj. $M_2.\text{quad}$ a $E.\text{falselist}$ se stane hodnotou atributu $S.\text{nextlist}$ celého příkazu S .

Překlad příkazu $\text{if } E \text{ then } S_1 \text{ else } S_2$ je ještě poněkud složitější, neboť potřebujeme za kód vygenerovaný z S_1 vložit skok přes kód pro S_2 . K tomu využijeme dalšího markeru N s atributem $N.\text{nextlist}$, seznamem obsahující pouze adresu čtvrtice s příkazem $\text{goto } __$, který vygeneruje sémantická akce spojená s N . Úplné překladové schéma pro řídicí příkazy je uvedeno na obr. 8.23.

- (1) $S \rightarrow \text{if } E \text{ then } M_1 S_1 N \text{ else } M_2 S_2$
 - { $\text{backpatch}(E.\text{truelist}, M_1.\text{quad})$;
 - $\text{backpatch}(E.\text{falselist}, M_2.\text{quad})$;
 - $S.\text{nextlist} := \text{merge}(S_1.\text{nextlist}, \text{merge}(N.\text{nextlist}, S_2.\text{nextlist}))$ }
- (2) $N \rightarrow \epsilon$ { $N.\text{nextlist} := \text{makelist}(nextquad)$;
- (3) $M \rightarrow \epsilon$ { $M.\text{quad} := nextquad$ }
- (4) $S \rightarrow \text{if } E \text{ then } M_1 S_1$
 - { $\text{backpatch}(E.\text{truelist}, M_1.\text{quad})$;
 - $S.\text{nextlist} := \text{merge}(E.\text{falselist}, S_1.\text{nextlist})$ }
- (5) $S \rightarrow \text{while } M_1 E \text{ do } M_2 S_1$
 - { $\text{backpatch}(S_1.\text{nextlist}, M_1.\text{quad})$;
 - $\text{backpatch}(E.\text{truelist}, M_2.\text{quad})$;
 - $S.\text{nextlist} := E.\text{falselist}$;
 - $\text{cmif('goto' } M_1.\text{quad} \text{'})}$
- (6) $S \rightarrow \text{begin } L \text{ end}$ { $S.\text{nextlist} := L.\text{nextlist}$ }
- (7) $S \rightarrow A$ { $S.\text{nextlist} := \text{nil}$ }
- (8) $L \rightarrow L_1 : M S$ { $\text{backpatch}(L_1.\text{nextlist}, M.\text{quad})$;
- (9) $L \rightarrow S$ { $L.\text{nextlist} := S.\text{nextlist}$ }

Obrázek 8.23: Překladové schéma pro řídicí příkazy s backpatchingem

Při zpracování návěsti a příkazů skoku jako součásti zdrojového jazyka je třeba provádět návěst kontroly, například zda existuje právě jedna definice návěsti, nebo zda cílová adresa skoku nemůže domnívit složené konstrukce. Některé jazyky, jako např. Pascal, dále vyzadují, aby všechna návěsti byla předem deklarována.

Pokud překládá rozpozná příkaz skoku, např. $\text{goto } L$, musí zkontrolovat, zda je v rozsahu platnosti návěsti L právě jedna jeho definice. Pokud se návěsti ještě nevyskytlo, uloží se do tabulky symbolů a přířadí se mu jako atribut seznam tvorený adresou vygenerované čtvrtice s příkazem skoku. Při všech dalších výslovných návěsti v příkazu skoku ještě před jeho definicí se do tohoto seznamu pouze přidávají adresy odpovídajících skokových instrukcí. V okamžiku, kdy se vyskyne definice takto jíž použitého návěsti, zavolá se procedura backpatch , které se předá seznam nedokončených skokových instrukcí a současná hodnota $nextquad$. Hodnota $nextquad$ se rovněž uloží do tabulky symbolů jako skutečná adresa návěsti, která se pak může v následujících příkazech skoku použít přímo.

8.7.3 Volání podprogramů

Podprogramy jsou tak dílčí a často používané programové konstrukce, že je nutné, aby pro volání a návraty z podprogramů generoval překladá co nejefektivnější kód. V některých případech se mohou akce spojené s předáváním řízení mezi podprogramy provádět ve spolupráci se systémem řízení větu programu.

Jak již bylo uvedeno v kapitole 6, volání podprogramu je obvykle standardizované ve tvaru určitého významu posloupnosti. I když se volání posloupnosti od sebe liší i po jednorázovém implementaci jednoho programovacího jazyka, jsou obvykle tvorený následujícími akcemi:

Je-li zavolen podprogram, musí se přidělit prostor pro alokaci základu voláního podprogramu. Musí se vydodat potřebné argumenty a dát je k dispozici volánímu podprogramu na určitěm základu místo. Dále je třeba upravit vazební ukazatele tak, aby měl volaný podprogram zajištěn přístup ke správným datům v nadřazených blozech. Stav volajícího podprogramu musí být uložen tak, aby mohl být znova obnoven při návratu. Na základu místo se také uloží návratová adresa, místo, na které se vrátí řízení po ukončení voláního podprogramu. Návratová adresa je obvykle místo následující za příkazem volání. Nakonec se musí vygenerovat skok na začátek volaného podprogramu.

Při návratu z podprogramu se rovněž musí provést určité pevně stanovené akce. Je-li podprogram funkční, je třeba uložit na známé místo výsledek. Dále se musí obnovit aktivitařní záznam volajícího podprogramu a provést skok na návratovou adresu.

Mezi těkou volajícího a volaného podprogramu není žádoucí pěsna hranice. Často se tyto úkoly rozdělují na základě vlastností zdrojového jazyka, cílového pořítače a požadavků opečeného systému.

Literatura

- [1] Adobe Systems, Inc.: *PostScript language reference manual*. Addison-Wesley, sixteenth edition, 1990.
- [2] A. V. Aho, R. Sethi, J. D. Ullman: *Compilers. Principles, Techniques, and Tools*. Addison-Wesley, 1987.
- [3] J. P. Bennett: *Introduction to compiling techniques: a first course using ANSI C, LEX and YACC*. McGraw-Hill, 1990.
- [4] A. I. Holub: *Compiler Design in C*. Prentice Hall, 1990.
- [5] J. M. Honzík: *Programovací techniky*. Učební texty vysokých škol. Ediční středisko VUT Brno, 1985.
- [6] T. Hruška: *Modelování semantiky programovacích jazyků a využití modelů při implementaci překladačů*. Disertační práce, VUT Brno, 1983.
- [7] D. E. Knuth: *The METAFONTbook*. Addison-Wesley, 1986.
- [8] D. E. Knuth: *The TeXbook*. Addison-Wesley, 1987.
- [9] L. Lamport: *BTEx: A Document Preparation System*. Addison-Wesley, 1986.
- [10] B. Melichar: Bezkontextové, překladové a atributové gramatiky. In *Sborník konference MOP'85. 1. díl*, strany 23–116. 1985.
- [11] Jean-Paul Tremblay, P. G. Sorenson: *The Theory and Practice of Compiler Writing*. Computer Science Series. McGraw-Hill, 1985.
- [12] M. Češka a kol.: *Gramatiky a jazyky*. Skriptum VUT Brno. Ediční středisko VUT Brno, 1985.
- [13] M. Češka, T. Hruška: *Gramatiky a jazyky — cvičení*. Skriptum VUT Brno. Ediční středisko VUT Brno, 1986.
- [14] W. M. Waite, G. Goos: *Compiler construction*. Text and monographs in computer science. Springer-Verlag, 1984.