

Paradygmaty i języki programowania

Analiza leksykalna


Skaner, RE, DAS, NAS, ϵ -NAS

Etapy pracy kompilatora

- Character stream
- [Lexical Analyzer]
 - token stream
- [Syntax Analyzer]
 - syntax tree
- [Semantic Analyzer]
 - syntax tree
- [Intermediate Code Generator]
 - intermediate representation
- [Machine-Independent Code Optimizer]
 - intermediate representation
- [Code Generator]
 - target-machine code
- [Machine-Dependent Code Optimizer]
 - target-machine code

1	position	...
2	initial	...
3	rate	...

SYMBOL TABLE




Analizator leksykalny (AL), skaner

- Skaner – pierwsza składowa kompilatora, która sprawdza czy można podzielić ciąg symboli wejściowych (program źródłowy) na jednostki leksykalne danego języka programowania, a więc na tzw. tokeny.
- Skaner nie zwraca uwagi na ‘śmieci’, typy, kolejność tokenów, niezadeklarowane nazwy, itd. Te zadania należą do analizatora składni
- Skaner nie ma pojęcia o grupowaniu i organizacji tokenów ...

AL

- **Tokeny** są to klasy leksemów, a więc podstawowych elementów języka programowania. Np.
 - stałe (int, double, char, string, itd)
 - operatory (arytmetyczne, logiczne, relacyjne)
 - znaki przestankowe
 - słowa kluczowe języka

Schemat skanera



Analizator rozpoznaje poszczególne elementy tokenów:

7 lub 2345 – stałe całkowite
„jan” lub „lubliN” -- łańcuchy
siedem lub abc – zmienne


Elementy te noszą nazwę leksemów i należą do różnych klas tokenów (znaczników).

Budowa skanera

- Dwie metody realizacji
 - wprost (skaner *ad hoc*)
 - wykorzystanie wyrażeń regularnych i automatów skończonych
- Ad hoc: program oparty na pętli (*loop*) i przełącznikach (*switch*) – *loop&switch*
 - należy podać definicje tokenów
 - czytać wejście z lewa na prawo
 - analizować i jeśli OK wówczas
 - wykonać odpowiedni skok w programie
 - Metoda uciążliwa!


Deterministyczny Automat Skończony

- Przykład: przełącznik; dwa stany:
- początkowy, końcowy; funkcja
- przejścia.
- Zastosowania DAS:
 - Analiza obwodów cyfrowych
 - Analizator leksykograficzny (rozbija tekst na jednostki leksykograficzne)
 - Skanowanie tekstu w celu wyszukiwania konkretnych słów (wyszukiwarki sieciowe)
 - Weryfikacja systemów o skończonej liczbie stanów (transakcje elektroniczne w internecie)



DAS

- Przykład: Wyszukiwanie, modelowanie łańcucha (słowa) **else**



- Ważną rolę w teorii automatów skończonych grają
 - Gramatyki (parser, przetwarzanie wyrażeń, $E \rightarrow E + E$ stwierdza, że wyrażenie można otrzymać z dwu wyrażeń połączonych znakiem plus; gramatyki bezkontekstowe)
 - Wyrażenia regularne (wzorce danych tekstowych, reprezentujące łańcuchy; UNIX: $[A-Z][a-z]^*[][A-Z][a-z]^*$)

Podstawowe pojęcia

- Alfabet: Σ – skończony, niepusty zbiór symboli
 - $\Sigma = \{0, 1\}$ – alfabet binarny;
 - $\Sigma = \{a, b, \dots, z\}$ – zbiór małych liter
- Łańcuch, słowo – skończony ciąg symboli wziętych z jakiegoś alfabetu
- Łańcuch pusty – ε – słowo o zerowej długości (można wybrać z każdego alfabetu)
- Długość słowa – liczba symboli niepustych
- Potęgi alfabetu – Σ^k -- zbiór słów o długości k nad alfabetem Σ
- $\Sigma^0 = \{\varepsilon\}$, $\Sigma^1 = \{0, 1\}$, $\Sigma^2 = \{0, 1, 00, 01, 10, 11\}$, ...

Podstawowe pojęcia

- Konwencja
 - Małe litery z początku alfabetu łac.: a, b, c ... - symbole
 - Małe litery z końca alfabetu: w, x, y, z – słowa, łańcuchy
- Zbiór wszystkich łańcuchów nad Σ oznaczamy przez Σ^* (* - operator Kleene'go)
 - $\Sigma^* = \Sigma^0 \mathbf{U} \Sigma^1 \mathbf{U} \Sigma^2 \mathbf{U} \dots$

Język

- Językiem nazywamy zbiór łańcuchów (słów) wybranych z pewnego alfabetu Σ (inaczej: jeśli Σ jest alfabetem i $L \subseteq \Sigma^*$ to L nazywamy językiem nad Σ)
- Przykłady
 - język polski, angielski, C, C++, ...
 - Języki abstrakcyjne
 - Język ze słów złożonych z n zer i n jedynek $\{\epsilon, 01, 0011, 000111, \dots\}$
 - Język ze słów złożonych z 0 i 1 zawierających tyle samo zer i jedynek $\{\epsilon, 01, 0101, 1010, 0110, \dots\}$
 - Zbiór liczb pierwszych zapisanych w postaci binarnej $\{\epsilon, 10, 11, 101, 111, 1011, \dots\}$
 - Σ^*
 - $\emptyset$ - zbiór pusty
 - $\{\epsilon\}$; zauważmy, że $\epsilon \neq \emptyset$

Problem

- Dla danego $w \in \Sigma^*$ rozstrzygnąć czy $w \in L(\Sigma)$

Przykład. Rozstrzygnięcie czy napis należy do języka liczb pierwszych L_p jest w ogólności trudnym problemem obliczeniowym


Praca parsera!

Definicja DAS

- $A = (Q, \Sigma, \delta, q_0, F)$
 - A = nazwa DAS
 - Q = skończony zbiór stanów
 - Σ = zbiór symboli wejściowych
 - δ = funkcja przejścia (ze stanu do stanu)
 - q_0 = stan początkowy
 - F = zbiór stanów końcowych

Definicja DAS


- Notacja wygodniejsza
 - Diagram przejść
 - Tablica przejść
- Przykład: DAS akceptujący łańcuchy zawierające podłańcuch 01



DAS, funkcja przejścia


- Funkcja przejścia dla DAS z poprzedniego przykładu; $\delta(stan, symbol_wejściowy) \rightarrow stan$;

	0	1
$\rightarrow q_0$	q_2	q_0
$*q_1$	q_1	q_1
q_2	q_2	q_1




(gwiazdka oznacza stany akceptujące)

DAS i $\delta(\text{stan}, \text{symbol})$




		a	b
(start)	x:	y	z
	y:	x	z
(final)	z:	z	z

Prosty automat




Prosty automat




"AUTOMAT"

A. złożony, NAS




(Przykład pożyczony z kursu cs143, Stanford)

A. złożony, NAS



0 1 1 1 0 1


A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1




A. złożony, NAS



0 1 1 1 0 1



A. złożony, NAS



Ponieważ automat znalazł się w jednym ze stanów końcowych, więc słowo zostało zaakceptowane

0 1 1 1 0 1


Rozszerzenie δ

- **Podstawa.** $\delta(q, \varepsilon) = q$
- **Krok indukcyjny.** Jeśli $w=xa$, to $\delta(q, w) = \delta(\delta(q, x), a)$

Aby obliczyć $\delta(q, w)$ obliczamy najpierw $\delta(q, x)$ – czyli stan, w którym znajdzie się automat po przetworzeniu wszystkich symboli w poza ostatnim. Przypuśćmy, że stanem tym jest p . Wtedy dokonując przejścia ze stanu p na wejściu a , a więc ostatnim symbolu w , otrzymamy $\delta(q, w)$, a zatem $\delta(q, w) = \delta(p, a)$

Przykład DAS

- $L = \{w \mid w \text{ ma parzystą liczbę zer i parzystą liczbę jedynek}\}$
- Zadaniem DAS jest więc liczenie zer i jedynek modulo 2



	0	1
$\rightarrow^* q_0$	q_2	q_1
q_1	q_3	q_0
q_2	q_0	q_3
q_3	q_1	q_2

Język DAS

- Język DAS $A=(Q, \Sigma, \delta, q_0, F)$ oznaczamy przez $L(A)$ i definiujemy następująco:

$$L(A) = \{w \mid \delta(q_0, w) \in F\}$$

- Język DAS $A, L(A)$, to zbiór słów w przeprowadzających stan początkowy automatu q_0 w jeden ze stanów akceptujących (końcowych) F .
- Jeśli $L=L(A)$ dla pewnego A to L nazywamy językiem regularnym.

Wyrażenia regularne (RE)

- Definicja: RE = wyrażenie regularne (*regular expression, regex*)
 - RE są to reguły definiujące słowa lub zbiory słów (łańcuchów) należących do języka formalnego Σ^* .
- Reguły składania dla x i y należących do reg:
 - konkatencja (złożenie): xy
 - alternatywa: $x|y$ lub $x+y$; czytaj x lub y
 - powtarzanie: x^* , x powtórzone zero lub więcej razy
- RE
 - każdy symbol alfabetu Σ
 - ε , pusty łańcuch
 - jeśli r i p są RE to również (r) , rp , $r|p$, r^* są RE
 - nic poza tym nie jest RE

Priorytet operatorów RE

- Priorytet = kolejność

(R)

R^*

R_1R_2

$R_1|R_2$ lub $R_1 + R_2$

- Przykład: $\mathbf{ab^*c|d}$ należy interpretować jako $((\mathbf{a(b^*)})\mathbf{c})|\mathbf{d}$

Przykłady prostych RE

- $\Sigma=\{0,1\}$ – alfabet
- łańcuch, który zawiera 00 jako podłańcuch

$$(0 \mid 1)^*00(0 \mid 1)^*$$

Przykłady prostych RE

- $\Sigma=\{0,1\}$ – alfabet
- łańcuch, który zawiera 00 jako podłańcuch

$$(0 \mid 1)^*00(0 \mid 1)^*$$

110011

0000

01111011100111

Przykłady prostych RE

- $\Sigma=\{0,1\}$ – alfabet
- łańcuch, który zawiera tylko trzy symbole

$(0|1)(0|1)(0|1)$

011

110

111

Przykłady prostych RE

- $\Sigma=\{0,1\}$ – alfabet
- łańcuch, który zawiera tylko trzy symbole

$(0|1)\{3\}$

011

110

111

Przykłady prostych RE

- $\Sigma=\{0,1\}$ – alfabet
- łańcuch, który zawiera przynajmniej jedno 0

$1^*00^*1^*$

0111

11011

111011

Przykłady prostych RE

- $\Sigma=\{0,1\}$ – alfabet
- łańcuch, który zawiera jedno 0

$1^*0?1^*$

0111

11011

111011

Zastosowania RE

- $\Sigma = \{a, @, .\}$, gdzie a = dowolna litera
- Adresy e-mail

$aa^* (.aa^*)^* @ aa^* .aa^* (.aa^*)^*$

Zastosowania RE

- $\Sigma = \{a, @, .\}$, gdzie a = dowolna litera
- Adresy e-mail

$aa^* (.aa^*)^* @ aa^* .aa^* (.aa^*)^*$

piotr@gmail.com

piotr.kowalski@umcs.lublin.pl

Zastosowania RE

- $\Sigma = \{a, @, .\}$, gdzie a = dowolna litera
- Adresy e-mail

$aa^* (.aa^*)^* @ aa^* .aa^* (.aa^*)^*$

piotr@gmail.com

piotr.kowalski@umcs.lublin.pl

Zastosowania RE

- $\Sigma = \{a, @, .\}$, gdzie a = dowolna litera
- Adresy e-mail

$a+ (.a+)^* @ a+.a+ (.a+)^*$

piotr@gmail.com

piotr.kowalski@umcs.lublin.pl

Zastosowania RE

- $\Sigma = \{a, @, .\}$, gdzie a = dowolna litera
- Adresy e-mail

$a+ (.a+)^* @ a+ (.a+)^+$

piotr@gmail.com

piotr.kowalski@umcs.lublin.pl

Zastosowania RE

- $\Sigma = \{+, -, 0, \dots, 9\}$
- Liczby nieparzyste ze znakiem

$(+|-)?(0|1|2|3|4|5|6|7|8|9)^*(1|3|5|7|9)$

-121

1157

+111115

Zastosowania RE

- $\Sigma = \{+, -, 0, \dots, 9\}$
- Liczby nieparzyste ze znakiem

$(+|-)?[0123456789]^*[13579]$

-121

1157

+111115

Zastosowania RE

- $\Sigma = \{+, -, 0, \dots, 9\}$
- Liczby nieparzyste ze znakiem

$(+|-)?[0-9]^*[13579]$


-121

1157

+111115


Zastosowania RE

- Przykład. $\Sigma = \{a, b\}$ – alfabet
 - łańcuchy zawierające tylko nieparzystą liczbę a: $a(aa)^*$
 - łańcuchy zawierające aa: $b^*(aa)^*b^*$
- RE $[0-9]^*$ realizuje następujący DAS skończony pokazany poniżej



Zastosowania RE


- Zadanie: Podać RE, które realizuje automat skończony pokazany poniżej



Inne automaty skończone


- **NAS** = niedeterministyczny automat skończony; może znaleźć się jednocześnie w wielu stanach wyjściowych
- **ϵ -NAS** = NAS reagujący na słowa puste
 - Przykład. ϵ -NAS akceptujący liczby dziesiętne postaci:

- opcjonalny znak + lub -
- ciąg cyfr
- kropka
- ciąg cyfr




- NAS ze stosem
- inne

Równoważność NAS i RE



NAS akceptujący język RE
 $(0|1)^*(000|111)(01)^*$


Równoważność automatów i RE




(Hopcroft i in.)

Reguły McNaughtona-Yamady-Thompsona


1. Ten NFA akceptuje jeden wybrany symbol alfabetu




2. Ten NFA akceptuje tylko ϵ




3. Ten ϵ -NFA akceptuje $r|s$



4. Ten ϵ -NFA akceptuje rs





5. Ten ϵ -NFA akceptuje r^*



Od RE do DAS

- Używając podanych reguł (McNaughton-Yamada-Thompson; patrz: Aho+) możemy zbudować NAS z danych RE, następnie przekształcić NFA w DAS. Alfabet jest cały czas ten sam. Języki RE i tak zbudowanego DAS są identyczne (*Jak to zrobić dokładnie? Patrz np. Aho+ lub Hopcroft+*)


Zadanie




- Pokaż, że NAS pokazany obok ($\Leftarrow$) można zastąpić przez DAS pokazany obok, poniżej.
- Zapisz RE dla otrzymanego DAS

Przykład


Zamiana wyrażenia regularnego
 $(0|1)^*1(0|1)$ na DAS z
wykorzystaniem reguł
Thompsona.



(a)



(b)



(c)

Wyrażenia regularne UNIXa

- **UNIX**

- . – dowolny znak

- * - dowolna liczba wystąpień

- ^ - początek wiersza

- \$ - koniec wiersza

- \ - znosi znaczenie specjalne; zwykły znak

- [abc] – któryś ze znaków wypisanych

- \(...\) – zapamiętywanie ciągu w buforze

- \<, \> początek, koniec słowa

- **Standard POSIX**

- klasy znaków w nawiasach [: :]

- [:alnum:], [:alpha:], [:blank:], [:cntrl:], [:digit:], [:graph:] – drukowalne

- [:lower:], [:print:], [:punct:], [:space:], [:upper:], [:xdigit:]

`lex`, `flex` – generator skanerów

- Proces przejścia od RE do automatów (pokazany krótko powyżej) jest wykorzystywany przez narzędzie `lex` lub `flex`, służące do budowania skanerów – programów do analizy leksykalnej innych programów, napisanych w jakimś języku, np. C++ lub Java.
- `flex` pobiera ciąg wyrażeń regularnych, opisujących dany język, buduje automat skończony oraz program w języku C służący jako analizator leksykalny programów ...


Przykład języka programowania

- Fortran (pierwszy, prymitywny język wyższego poziomu)
 - zmienne: dł. 5 znaków, pierwszy znak litera; duże litery. Zmienne o nazwach zaczynających się na *i, j, k, l, m, n* mają domyślnie typ całkowity, inne rzeczywisty;
 - Nie potrzeba deklarować zmiennych z wyjątkiem tablic. Tablice mogą być co najwyżej 3 wymiarowe.
 - Instrukcja podstawienia z lewej strony zawiera zmienną, z prawej wyrażenie
 - Struktury kontrolne
 - bezwzględny skok: `GOTO <numer instrukcji>`
 - skok obliczany: `GOTO (20,30,40,50) I` -- *I* może mieć wartość 1, 2, 3, 4 – skok do instrukcji o numerze 20, 30, 40 lub 50
 - `IF (A+B-C/2) 10, 12, 14` -- skok do 10, 12, 14 w zależności od wartości $w=A+B+C/2$: $w < 0 \rightarrow 10$, $w = 0 \rightarrow 12$, $w > 0 \rightarrow 14$
 - Instrukcja DO: `DO 21 K=1, N, 2` wykonuje się do instrukcji z numerem 21 łącznie; *K* zmienia się co 2 od 1 do *N*.
 - Brak podprogramów definiowanych przez użytkownika
 - Ignorowane są odstępy; np. `DIMENSIONDANE(1234)` lub `D I M E N S I O N D A N E (1234)` lub ładniej `DIMENSION DANE(1234)` -- deklaracja tablicy o długości 1234
 - Słów kluczowych można używać jako nazw np. `IF = 10` lub `DIMENSION DO(2)`
- Zadanie. NAPISZ schemat skanera☺ Pierwsze skanery to skanery ad hoc. Tutaj nawet RE, czy automaty skończone mają problem.

Literatura

- A. Aho, R. Sethi, J. Ullman, Compilers: Principles, Techniques, and Tools. Reading, MA: Addison-Wesley, 1986; jest wydanie polskie.
- J. Hopcroft, J. Ullman, Introduction to Automata Theory, Languages, and Computation, Reading MA: Addison-Wesley, 1979; jest wydanie polskie.

Co dalej?



- Character stream
- [Lexical Analyzer]
 - token stream
- [Syntax Analyzer]
 - syntax tree
- [Semantic Analyzer]
 - syntax tree
- [Intermediate Code Generator]
 - intermediate representation
- [Machine-Independent Code Optimizer]
 - intermediate representation
- [Code Generator]
 - target-machine code
- [Machine-Dependent Code Optimizer]
 - target-machine code

1	position	...
2	initial	...
3	rate	...

SYMBOL TABLE

