

JIP

Analiza składni, gramatyki

Książka o różnych językach i paradygmatach

2

Polecam jako obowiązkową lekturę do przeczytania dla wszystkich prawdziwych programistów!

Baza programisty

Pragmatic Bookshelf

Siedem języków w siedem tygodni

Praktyczny przewodnik nauki **języków programowania**

Siedmiotygodniowa podróż po czterech odmiennych **paradygmatach programowania**, siedmiu różnych **stylach składni** i czterech dekadach **rozwoju języków!**

- Porównaj najważniejsze modele programowania i techniki obsługi współbieżności
- Opisz i zbuduj system prototypów i dynamicznych typów
- Zostan wszechstronnym programistą, gotowym zmierzyć się z każdym projektem!



Bruce A. Tate

Podsumowanie wykładu 2

3

- Analiza leksykalna
- Automaty skończone AS
- Wyrażenia regularne RE
- Języki AS i RE – równoważność
- Reguły Thompsona
- Narzędzie flex

- Fortran

Plan wykładu 3

4

- Analiza syntaktyczna
- Gramatyki (G)
- Podstawowe pojęcia
- Niejednoznaczność G
- Drzewa parsowania/składni

Gramatyki formalne

5

- Gramatyka
 - ▣ narzędzie do opisu i analizy języka
 - ▣ zbiór reguł, według których buduje się poprawne zdania języka
- Przykład: gramatyki języków naturalnych; polski,...

zdanie -> <podmiot><orzeczenie><dopełnienie>

podmiot -> <osoba> | rzecz | zwierzę

orzeczenie -> idzie | stoi | leci | mówi | jedzie

dopełnienie -> do kina | szybko | na zajęcia | ładnie

osoba -> Jan | ...; rzecz -> samolot | auto ...; zwierzę -> koza | kot | ...;

Wg tych reguł można skonstruować (prawie) poprawne zdania języka polskiego, np.

Jan idzie do kina.

Samolot leci ładnie.

Auto mówi szybko.

itd.

Gramatyki formalne

6

- Jedne z tych zdań są sensowne, a inne nie są
- W procesie analizy syntaktycznej interesuje nas tylko składnia (zgodność z gramatyką), a nie znaczenie zdań
- Zdania te można otrzymać w procesie zwanym wyprowadzeniem lewo- lub prawostronnym
- Przykład wyprowadzenia lewostronnego:
zdanie -> <podmiot><orzeczenie><dopełnienie>
-> Jan <orzeczenie><dopełnienie>
-> Jan idzie <dopełnienie>
-> Jan idzie do kina

Gramatyki formalne

7

- Znaczeniem zdań języka zajmuje się semantyka
- Analiza składni nosi nazwę analizy syntaktycznej

- Gramatyka $G =$
 - (Zbiór symboli nieterminalnych = N ,
 - Zbiór terminali = T ,
 - Produkcje = P ,
 - Symbol początkowy = S)

Gramatyki formalne

8

- Gramatyka $G = (V, T, P, S)$
- Produkcje – reguły zastępowania symboli, wyprowadzania zdań, np. $X \rightarrow Y_1 Y_2 Y_3 \dots Y_n$
- głowa produkcji – lewa strona reguły
- symbol produkcji - $\rightarrow$
- terminal, symbol końcowy, słowo
- symbol nieterminalny, symbol
- symbol startowy, początkowy
- Zdanie – ciąg symboli terminalnych otrzymany w procesie wyprowadzenia lewo- | prawostronnego
- Zapis BNF (Backus-Naur Form)

Gramatyki formalne


9

- Wyprowadzaniu zdań towarzyszy proces wybierania reguł i ich kolejność – historia wyprowadzeń
- Inną metodą wyprowadzania zdań są drzewa wyprowadzeń, drzewa syntaktyczne

Gramatyki formalne

10

□ Przykład



Przykład

11

`<program> => begin <stmt_list> end`

`<stmt_list> => <stmt> | <stmt> : <stmt_list>`

`<stmt> => <var> = <expr>`

`<var> => A | B | C`

`<expr> => <var> + <var>`

`| <var> - <var>`

`| <var>`

Przykład

12

A = B + C

$\langle \text{stmt_lists} \rangle \Rightarrow \langle \text{stmt} \rangle$

$\Rightarrow \langle \text{var} \rangle = \langle \text{expr} \rangle$

$\Rightarrow A = \langle \text{expr} \rangle$

$\Rightarrow A = \langle \text{term} \rangle + \langle \text{term} \rangle$

$\Rightarrow A = \langle \text{var} \rangle + \langle \text{term} \rangle$


$\Rightarrow A = B + \langle \text{term} \rangle$

$\Rightarrow A = B + C$

Przykład

13

□ Drzewo wyprowadzenia



Przykład (Sebesta)

14

Prosta gramatyka instrukcji przypisania

$\langle \text{assign} \rangle \rightarrow \langle \text{id} \rangle = \langle \text{expr} \rangle$

$\langle \text{id} \rangle \rightarrow A \mid B \mid C$

$\langle \text{expr} \rangle \rightarrow \langle \text{id} \rangle + \langle \text{expr} \rangle$

$\mid \langle \text{id} \rangle * \langle \text{expr} \rangle$

$\mid (\langle \text{expr} \rangle)$

$\mid \langle \text{id} \rangle$

Wyprowadzenie $A = B*(A+C)$

$\langle \text{assign} \rangle \Rightarrow \langle \text{id} \rangle = \langle \text{expr} \rangle$

$\Rightarrow A = \langle \text{expr} \rangle$

$\Rightarrow A = \langle \text{id} \rangle * \langle \text{expr} \rangle$

$\Rightarrow A = B * \langle \text{expr} \rangle$


$\Rightarrow A = B * (\langle \text{expr} \rangle)$

$\Rightarrow A = B * (\langle \text{id} \rangle + \langle \text{expr} \rangle)$

$\Rightarrow A = B * (A + \langle \text{expr} \rangle)$

$\Rightarrow A = B * (A + \langle \text{id} \rangle)$

$\Rightarrow A = B * (A + C)$



Więcej definicji

15

- Rozpatrzmy gramatykę z produkcjami
$$S \rightarrow A \mid B$$
$$A \rightarrow Ax \mid y$$
$$B \rightarrow z$$
- symbole: $\{S, A, B, x, y, z\}$
- symbole nieterminalne: $N = \{S, A, B\}$
- symbole terminalne: $T = \{x, y, z\}$
- V i T są rozłączne

Więcej definicji

16

- Umowa
 - ▣ Duże litery – symbole nieterminalne
 - ▣ małe litery łac. – terminale
 - ▣ małe litery gr. – dowolne, tzn terminale $\vee$ nieterminale
- Dla zdefiniowania języka potrzebujemy zbioru produkcji postaci $\alpha \rightarrow \beta$
- W gramatykach bezkontekstowych α jest pojedynczym symbolem nieterminalnym, a β jest dowolnym łańcuchem terminali i symboli nieterminalnych.

Więcej definicji

17

- Forma zdaniowa = ciąg symboli wyprowadzonych z symbolu startowego S , zawierający ew. symbole nieterminalne

- Oznaczenia
 - ▣ $\alpha \rightarrow \beta$ wyprowadzenie β z α
 - ▣ $\alpha \rightarrow^* \beta$ wyprowadzenie β z α przy zastosowaniu zera lub więcej produkcji, reguł
 - ▣ $\alpha \rightarrow^+ \beta$ wyprowadzenie β z α przy zastosowaniu przynajmniej jednej produkcji

Równoważność gramatyk

18

- Językiem $L(G)$ zdefiniowanym przez gramatykę G nazywamy zbiór zdań wyprowadzonych z G
- Dwie gramatyki G i G' są równoważne jeśli języki $L(G)$ i $L(G')$ są takie same.

Hierarchia gramatyk wg Chomsky'ego

19

- Noam Chomsky
 - ▣ 4 typy gramatyk
- typ 0 – gramatyki ogólne: produkcje $\alpha \rightarrow \beta$, α, β są z V i α jest niepusty
- typ 1 – gramatyki kontekstowe: produkcje są postaci $\alpha X \gamma \rightarrow \alpha \beta \gamma$; α, β, γ są z V , α, γ stanowią kontekst symbolu X
- typ 2 – gramatyki bezkontekstowe: $X \rightarrow \alpha$, α jest z V , X jest pojedynczą kategorią syntaktyczną; Każde X można zastąpić przez α niezależnie od kontekstu
- typ 3 – gramatyki regularne: $X \rightarrow a$, $X \rightarrow aY$, $X \rightarrow \varepsilon$, gdzie a jest symbolem terminalnym

Hierarchia gramatyk wg Chomsky'ego

20

- Najbardziej restrykcyjną jest gramatyka typu 3, a najogólniejszą jest gramatyka typu 0
- Gramatyka typu 3 jest gramatyką typu 2, a gramatyka typu 2 jest typu 1, a ta jest typu 0.
- Gramatyka typu 3, bezkontekstowa, okazuje się najdogodniejszą w projektowaniu języków programowania

Przykłady

21

- Gramatyka palindromów, terminale: 0, 1

$P \rightarrow \varepsilon \mid 0 \mid 1 \mid 0P0 \mid 1P1$

0

0101010

111

00110101100

Przykłady

22

- Gramatyka prostych wyrażeń arytmetycznych

$E \rightarrow E \text{ op } E \mid (E) \mid \text{int}$

$\text{op} \rightarrow + \mid - \mid * \mid /$

$2+3*4, \quad 7+(8+5)*4/3, \quad (6*7+2)/2+8+5$

- Wyprowadzenia, zadanie.

Problemy

23

- Parseery = analizatory składni mogą mieć problemy w przypadku gdy gramatyka jest niejednoznaczna lub gdy występuje tzw. rekurencja lewostronna, lub faktoryzacja

Krótko o powyższym.

Niejednoznaczność G

24

- Niejednoznaczność objawia się w przypadku gdy istnieje więcej niż jedno drzewo wyprowadzeń
- Przykład. Gramatyka prostych wyrażeń arytmetycznych z przykładu powyżej.


$E \rightarrow E \text{ op } E \mid (E) \mid \text{int}$
 $\text{op} \rightarrow + \mid - \mid * \mid /$

- Zajmijmy się wyprowadzeniem wyrażenia $10-2*5$
 - $E \rightarrow E \text{ op } E \rightarrow 10 \text{ op } E \rightarrow 10 + E \rightarrow 10 - E \text{ op } E \rightarrow 10 - 2 \text{ op } E \rightarrow 10 - 2 * E \rightarrow 10 - 2 * 5$
 - $E \rightarrow E \text{ op } E \rightarrow E \text{ op } E \text{ op } E \rightarrow 10 \text{ op } E \text{ op } E \rightarrow 10 - 2 \text{ op } E \rightarrow 10 - 2 * E \rightarrow 10 - 2 * 5$


Niejednoznaczność G

25

- Lepiej widać to na drzewach wyprowadzeń. Mamy dwa drzewa – niejednoznaczna G



plon $\sim (10 - 2) * 5$



plon $\sim 10 - (2 * 5)$

Niejednoznaczność G

26

- Lewe drzewo: najpierw op zamieniany jest na $*$, a następny na $-$
- Prawe drzewo: odwrotnie
- Sugeruje to, że plon lewego drzewa można złożyć do wyrażenia $(10-2)*5$, a prawego do $10-(2*5)$
- Oba drzewa są legalne dla podanej gramatyki
- Prawidłowe powinno być drzewo prawe gdyż prawidłowo interpretuje kolejność działań $(*, -)$

Przykład, ten sam



27

- Produkcje $E \rightarrow E + E \mid E * E$ pozwalają generować wyrażenia w dowolnej kolejności. Np. forma zdaniowa $E + E * E$ może powstać w wyprowadzeniach:

- ▣ 1. $E \rightarrow E + E \rightarrow E + E * E$

- ▣ 2. $E \rightarrow E * E \rightarrow E + E * E$

- Drzewa



Niejednoznaczność

28

- Nie ma ogólnej metody, która pozwala przewidzieć niejednoznaczność gramatyk
- Znane niejednoznaczności można zakodować budując w odpowiedni sposób analizator, np. tak, by wybierał prawe drzewo składni w podanym przykładzie
- Inna metoda usuwania niejednoznaczności polega na redefinicji gramatyki na gramatykę równoważną bez niejednoznaczności

Niejednoznaczność

29

- W przypadku powyższej gramatyki wyrażeń arytmetycznych

$$E \rightarrow E \text{ op } E \mid (E) \mid \text{int}$$
$$\text{op} \rightarrow + \mid - \mid * \mid /$$

możemy dokonać podziału wyrażeń na składniki (terms, T) i czynniki (factors, F) i wymusić ich rozwinięcia w określonym porządku:

$$E \rightarrow E \text{ top } E \mid T$$
$$\text{top} \rightarrow + \mid -$$
$$T \rightarrow T \text{ fop } T \mid F$$
$$\text{fop} \rightarrow * \mid /$$
$$F \rightarrow (E) \mid \text{int}$$

- Jest tylko jedno drzewo składni dla $10-2*5$. Sprawdź!

Niejednoznaczność G

30

- ... ale co z 10-3-2?
Powinno być (10-3)-2 czy 10-(3-2)?
Łączność lewostronna!
- Prawidłowa G, równoważna, po zmianach:
 $E \rightarrow E \text{ top } T \mid T$
 $\text{top} \rightarrow + \mid -$
 $T \rightarrow T \text{ fop } F \mid F$
 $\text{fop} \rightarrow * \mid /$
 $F \rightarrow (E) \mid \text{int}$
- Nie ma reguł ogólnych. Jednak w przypadku języków programowania jest niewiele takich przypadków, które wymagają takich zmian gramatyki.

Produkcje rekurencyjne

31

- Przykład.

$lista_zmiennych \rightarrow zmienna \mid lista_zmiennych, zmienna$

- Ogólniej:

$A \rightarrow \alpha \mid A \alpha$

Jeśli z prawej strony produkcji występuje z lewej strony ten sam symbol nieterminalny, który występuje po stronie lewej produkcji, to takie produkcje nazywamy lewostronnie rekurencyjnymi (tutaj A lub $lista_zmiennych$). Prowadzi to do problemów w przypadku pewnych technik używanych w analizie syntaktycznej

Rekurencja

32

- Istnieje sposób eliminowania rekurencji lewostronnej
- Przykład: $X \rightarrow Xa \mid Xb \mid AB \mid C \mid \mid DEF$
- Metoda
 - ▣ wprowadzamy nowy symbol nieterminalny X'
 - ▣ X' dodajemy po prawej stronie wszystkich produkcji nierekurencyjnych, a więc do AB, C, DEF
 - ▣ dodajemy produkcję $X' \rightarrow$ “odwrotność” lewych produkcji rekurencyjnych X , z X zastąpionym przez X' oraz produkcję $X' \rightarrow \varepsilon$.
$$X \rightarrow ABX' \mid CX' \mid DEFX'$$
$$X' \rightarrow aX' \mid bX' \mid \varepsilon$$
 - ▣ Otrzymaliśmy gramatykę z rekurencją prawostronną

Faktoryzacja

33

- Parser czyta wejście z lewej strony na prawą
- Dla każdego przeczytanego tokenu wygodnie jest zdecydować od razu, która reguła ma być użyta w procesie wyprowadzania
- W przypadku gdy z prawej strony produkcji występują wspólne symbole pojawia się problem wyboru właściwej produkcji
- Przykład
`instr -> if warunek then instr else instr |
 if warunek then instr | ...`

Faktoryzacja

34

- W przykładzie wspólnym prefiksem jest `if warunek then instr`
- Po napotkaniu `if` parser “nie wie” której reguły użyć; prowadzi to do niezrównoważonych instrukcji warunkowych `if – else`
- Technika lewostronnej faktoryzacji pozwala usunąć problem
 - ▣ Produkcje przepisujemy tak aby decyzję o wyborze reguły odsunąć w czasie, na moment gdy wczytamy odpowiednio wiele informacji
 - ▣ Część wspólną obu produkcji faktoryzujemy
 - ▣ Dodajemy nową regułę, która będzie stosowana później

Faktoryzacja

35

`instr -> if warunek then instr else instr |
if warunek then instr | ...`

zamieniamy na

`instr -> if warunek then instr Opelse | ...
Opelse -> else instrukcja | ϵ |...`

W ten sposób decyzja o wyborze części `else` lub ϵ zostaje odłożona na później.

Ukryta rekurencja

36

- Może się zdarzyć, że rekurencja jest ukryta
- Przykład.
 $S \rightarrow Ta \mid cd$
 $T \rightarrow Se \mid bbS$
- Rekurencja staje się jawna po wstawieniu za S ciągu Ta w pierwszej produkcji $T \rightarrow \dots$:
 $S \rightarrow Ta \mid cd$
 $T \rightarrow Tae \mid cde \mid bbS$
- Po eliminacji rekurencji (zgodnie z podanymi wcześniej regułami) otrzymamy równoważną gramatykę bez rekurencji lewostronnej
 $S \rightarrow Ta \mid cd$
 $T \rightarrow cdeT' \mid bbST'$
 $T \rightarrow aeT' \mid \varepsilon$

Ukryta faktoryzacja

37

- Zadanie
Pokazać, że następującą gramatykę należy sfaktoryzować
 $A \rightarrow da \mid acB$
 $B \rightarrow abB \mid daA \mid Af$
- W zadaniu pierwsza i druga produkcja B przekrywają się z trzecią. Aby to unaocznić podstawimy A do trzeciej produkcji B
 $A \rightarrow da \mid acB$
 $B \rightarrow abB \mid daA \mid daF \mid acBf$
- Po faktoryzacji (wprowadzamy wspólne faktory M, N)
 $A \rightarrow da \mid acB$
 $B \rightarrow aM \mid daN$
 $M \rightarrow bB \mid cBf$
 $N \rightarrow A \mid f$

ALGOL

38

- Algol był pierwszym językiem programowania opisanym przy użyciu gramatyki bezkontekstowej
- John Backus, Peter Naur, notacja BNF lub EBNF (extended)
- Własności Algolu
 - ▣ struktury blokowe
 - ▣ silne typowanie
 - ▣ zakresy
 - ▣ procedury
 - ▣ wywołania przez wartość i referencyjne
 - ▣ rekurencja (wymaga stosu w czasie wykonania programu; brak w językach Fortran i Cobol)

Literatura

39

- Aho, Seti, Ullman
- Hopcroft
- Scott

Co dalej?

40

- ☐ Lex/Flex
- ☐ Bison/yacc
- ☐ Semantyka

