

METODY TRANSLACJI 2004

Folie z wykładu

notatka nr 3

Parsery bottom-up

- LR(0)
- LR(1)
- LR(k)
- sprytne uproszczenia

Parsery LR(0)

Notacja: LR(0)

- input czytany z lewej na prawą,
- prawostronne wyprowadzenie jest rekonstruowane,
- czytamy, **0** znaków inputu przed podjęciem decyzji

Tylko gramatyki prefixowe

$$w \in L_G \Leftrightarrow \text{żaden prefix } w \text{ należy do } L_G$$

(przy braku tej własności – po rozpoznaniu prefixu parser nie wiedziałby czy zaprzestać, bo nie wie, czy jest na końcu inputu)

nie jest to istotne ograniczenie:

L język bezkontekstowy \Rightarrow

$L' = \{w\$ \mid w \in L\}$ jest bezkontekstowy z własnością prefixów

Handle

- $S \xrightarrow{*}_r SyAx \rightarrow y\alpha x$ jest wyprowadzeniem prawostronnym, to α jest handle

Poszukiwanie handle

sytuacja: α na stosie, x po prawej stronie głowicy. tj. $S \xrightarrow{*}_r \alpha x$.

Kroki parsera:

- Redukcja, jeśli handle na szczycie stosu
- Shift w przeciwnym wypadku

Handle z αx to:


- suffix α , albo
- ciąg składający się częściowo z α i częściowo z x ,
- podciąg x .

textbfLemat Handle nie leży w środku stosu.

Miejsca handle

Dowód t pierwszy moment gdy handle leży w środku stosu. rozważamy krok $t - 1$:


Przypadek 1:



znak A musi jako nieterminal należeć do handle! (gdyby, nie, to symbol A przeszedłby niezmiennie do chwili $t + 1$, a to znaczyłoby że krok wyprowadzenia prawostronnego z chwili $t + 1$ do chwili t zignorowałby A)

Miejsca handle

Przypadek 2:



Element

Jeśli $A \rightarrow \alpha\beta$ jest produkcją,
to $A \rightarrow \alpha \cdot \beta$ jest **elementem** (α, β mogą być puste)

Intuicje:

x to nieprzeczytana część inputu, α to zawartość stosu

$$S \xRightarrow{*}_r \alpha x$$


Handle β znajduje się częściowo w α i częściowo w x .
kropka odziela części i odpowiada kropce w $A \rightarrow \alpha \cdot \beta$

Żywy prefix

niech $S \xRightarrow{*}_r \alpha x$,

β - handle dla αx .

Wtedy prefix y ciągu αx jest **żywy**, jeśli nie sięga za β .



Ważne elementy

Element $A \rightarrow \alpha \cdot \beta$ jest *ważny* dla żywego prefixu γ , jeśli istnieje wyprowadzenie prawostronne typu

$$S \xRightarrow{*}_r \delta A w \Rightarrow_r \delta \alpha \beta w$$

gdzie $\gamma = \delta \alpha$ ($\alpha \beta$ to handle dla $\delta \alpha \beta w$).

Zastosowania ważnych elementów

Dla handle (i tylko dla handle) mamy element z punktem **na pierwszej z prawej pozycji** (tj. rightmost)!

Takie elementy nazywają się **zupelne**.

Rozpoznawanie handle = znalezienie ważnych elementów dla każdego żywego prefixa.

Automat skończony dla obliczania ważnych elementów

Stany: elementy i stan początkowy q_0 ,
automat niedeterministyczny

Funkcja przejścia:

- $\delta(q_0, \varepsilon) = \{S \rightarrow \cdot \alpha \mid S \rightarrow \alpha \text{ jest produkcją}\}$
- $\delta(A \rightarrow \alpha \cdot X \beta, X)$ zawiera $A \rightarrow \alpha X \cdot \beta$
 dla każdego X (terminal lub nieterminal)

Uzasadnienie:

niech $A \rightarrow \alpha \cdot X \beta$ będzie ważny dla γ .

Tzn., istnieje $S \xRightarrow{*}_r \delta A w \Rightarrow_r \underbrace{\delta \alpha \cdot X \beta}_\gamma w$

Wtedy:

$S \xRightarrow{*}_r \delta A w \Rightarrow_r \underbrace{\delta \alpha X \cdot \beta}_{\gamma X} w$

i element $A \rightarrow \alpha X \cdot \beta$ jest ważny dla γX .

Automat skończony dla obliczania ważnych elementów

Funkcja przejścia, cd:

- $\delta(A \rightarrow \alpha \cdot B \beta, \varepsilon)$ zawiera $B \rightarrow \cdot \eta \mid B \rightarrow \eta$ produkcja

Uzasadnienie:

niech $A \rightarrow \alpha \cdot B \beta$ ważny element dla γ ,

tj.

$S \xRightarrow{*}_r \delta A w \Rightarrow_r \underbrace{\delta \alpha \cdot B \beta}_\gamma w$.

wtedy też

$S \xRightarrow{*}_r \delta A w \Rightarrow_r \delta \alpha B \beta w \xRightarrow{*}_r \delta \alpha B \beta' w \Rightarrow_r \underbrace{\delta \alpha \cdot \eta \beta' w}_\gamma$.

Tzn. $B \rightarrow \cdot \eta$ jest ważny dla γ .

Zamiana na automat deterministyczny

Konstrukcja potęgowa - ale "leniwa", konstruujemy tylko te zbiory, które potrzebujemy

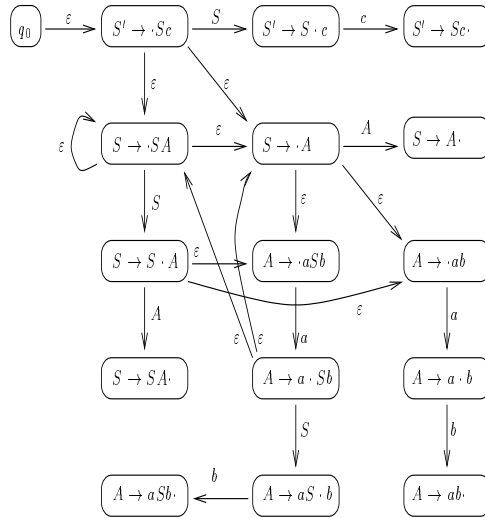
przykład: Gramatyka:

$S' \rightarrow Sc$

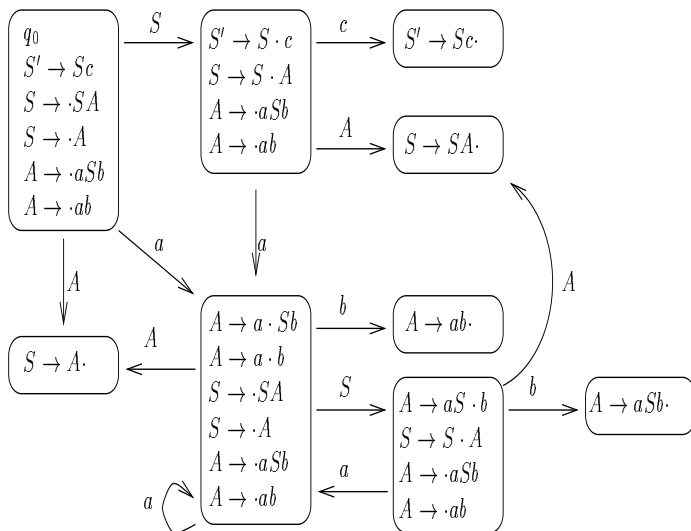
$S \rightarrow SA \mid A$

$A \rightarrow aSb \mid ab$

Automat niedeterministyczny



Automat deterministyczny



Twierdzenie

$\delta(q_0, \gamma)$ (stan po wczytaniu γ) zawiera

$$A \rightarrow \alpha \cdot \beta$$

wtedy i tylko wtedy gdy

$$A \rightarrow \alpha \cdot \beta$$

jest ważny dla γ .

(\Rightarrow) oczywiste (na podstawie definicji).

(\Leftarrow)

Trzeba pokazać, że ważny element jest osiągalny.

Niech $A \rightarrow \alpha \cdot \beta$ będzie ważny dla γ , tj.

$$S \xRightarrow{*}_r \gamma_1 A w \xRightarrow{r} \underbrace{\gamma_1 \alpha \beta}_\gamma w$$

Pokazujemy, że $\delta(q_0, \gamma_1)$ zawiera $A \rightarrow \alpha \cdot \beta$.

Wtedy kilka kroków (przesunięcie kropki) pokazuje, że $\delta(q_0, \gamma)$ zawiera element $A \rightarrow \alpha \cdot \beta$.

Indukcja po długości wyprowadzenia.

Wyprowadzenie $S \xRightarrow{*}_r \gamma_1 A w$ przedstawiamy jako

$$S \xRightarrow{*}_r \gamma_2 B x \Rightarrow_r \gamma_2 \gamma_3 A \gamma_4 x \xRightarrow{*}_r \underbrace{\gamma_2 \gamma_3}_\gamma A \underbrace{yx}_w$$

Z powodu wyprowadzenia

$S \xRightarrow{*}_r \gamma_2 B x \Rightarrow_r \gamma_2 \gamma_3 A \gamma_4 x$ element $[B \rightarrow \cdot \gamma_3 A \gamma_4]$ jest ważny dla γ_2 .

Z indukcji $\delta(q_0, \gamma_2)$ zawiera także $[B \rightarrow \cdot \gamma_3 A \gamma_4]$.

Wtedy: $\delta(q_0, \gamma_2 \gamma_3)$ zawiera $B \rightarrow \gamma_3 \cdot A \gamma_4$.

Po jednym kroku: $\delta(q_0, \gamma_2 \gamma_3) = \delta(q_0, \gamma_1)$ zawiera $A \rightarrow \cdot \alpha \beta$.

Gramatyki LR(0)

Gramatyka bezkontekstowa nazywa się LR(0), jeśli:

- 1) Symbol początkowy S nie występuje po prawej stronie produkcji.
- 2) Dla każdego żywego prefixu γ mamy: jeśli $A \rightarrow \alpha \cdot$ jest ważny dla γ , wtedy
 - żaden inny element $C \rightarrow \delta \cdot$ nie jest ważny dla γ .
 - żaden inny element z symbolem terminalnym po prawej stronie kropki nie jest ważny dla γ .

(pomijamy zagadnienia, jakie występują gdy $\alpha = \epsilon$)

Uwagi do definicji

definicja dopasowana do budowy parsera:

warunek 1) łatwy do osiągnięcia:

nowy symbol startowy: S' , jedyna produkcja dla S' to $S' \rightarrow S$.

warunek 2.1) służy do unikania konfliktów przy parsingu. np. dwa ważne elementy $A \rightarrow \alpha \cdot$, $C \rightarrow \delta \cdot$ dla jednego γ wskazywałyby na dwie różne redukcje.

warunek 2.2) podobnie: $A \rightarrow \alpha \cdot$ i $B \rightarrow \beta \cdot c\delta$ dawałyby konflikt typu Shift-Reduce.

Testowanie na własność LR(0)

- konstruuje deterministyczny automat skończony, który oblicza ważne elementy,
- sprawdź czy żaden stan nie przeczy własnościom LR(0).

Konstrukcja parsera LR(0)

Niech G będzie gramatyką LR(0).

Twierdzenie Można skonstruować automat deterministyczny ze stosem rozpoznający L_G .


(ten automat nazywamy **LR(0)-parserem**.)

Konstrukcja parsera LR(0)

akceptowanie parser akceptuje z pustym stosem.

zawartość stosu: $X_1 s_1 X_2 s_2 \dots X_k s_k$, gdzie

- $X_1 X_2 \dots X_k$ + nieprzeczytana część inputu = "Rechtssatzform"
- $X_1 \dots X_k$ tworzy żywotny prefix,
- s_i jest stanem automatu, który oblicza ważne elementy, po przeczytaniu $X_1 \dots X_i$.



Konstrukcja parsera LR(0)

Krok parsera:

Przypadek 1: Redukcja – s_k zawiera pełny element ($A \rightarrow X_{k-i} \dots X_k$)

W stosie znajduje się handle $X_{k-i} \dots X_k$

- usuń $X_{k-i} s_{k-i} \dots X_k s_k$ ze stosu
- przeczytaj s_{k-i-1}
- wpisz A na stos
- wpisz na stos stan $\delta(s_{k-i-1}, A)$ automatu dla $X_1 \dots X_{k-i-1} A$.

Przypadek 2: Shift – s_k nie zawiera pełnego elementu. Brak handle na stosie.

Dalej wypełniamy:

- przeczytaj następny znak inputu i wpisz na stos jako X_{k+1} ,
- oblicz $s_{k+1} = \delta(s_k, X_{k+1})$ i wpisz na stos.

Poprawność parsera

Twierdzenie LR(0)-parser prawidłowo pracuje dla gramatyk LR(0).

- jeśli istnieje wyprowadzenie prawostronne, to jest ono rekonstruowane krok po kroku (brak niedeterminizmu!)
Istotnie, jeśli $A \rightarrow \alpha \cdot$ i $B \rightarrow \gamma \cdot \rho$ jest ważny dla prefixu ω , wtedy pierwszy znak ρ to nieterminal. Wtedy element $B \rightarrow \gamma \cdot \rho$ nie może być użyty do Shift-u. Więc parser **musi** robić co trzeba.

Moc LR(0)

Twierdzenie

Jeśli L jest językiem bezkontekstowym, dla którego istnieje automat deterministyczny ze stosem, który akceptuje z pustym stosem, to

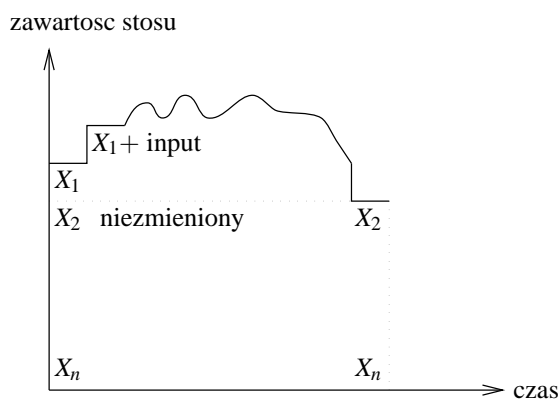
L ma gramatykę LR(0).

- wszystko co można zrobić, można zrobić za pomocą LR(0)
- nikt nie mówi, że łatwo skonstruować gramatykę,
nikt nie mówi, że automat ma mało stanów

Przypomnienie - równoważność automatów ze stosem i CFL

Najważniejszy trick przy budowie gramatyki: stany postaci $[qXp]$.

Znaczenie: „wpisujemy X na stos w stanie q , usuwamy X przy stanie p “.



Przypomnienie - równoważność automatów ze stosem i CFL

Dla przejścia $(q, X) \rightarrow (q_1, X_1 X_2 \dots X_n)$ automatu ze stosem mamy produkcję:

$$[q, X, q'] \rightarrow [q_1 X_1 q_2][q_2 X_2 q_3] \dots [q_n X_n q']$$

(q_1, q_2, \dots, q_{n-1} są dowolne).

Konstrukcja gramatyki

niech Q zbiór stanów automatu M ,

δ - funkcja przejścia M .

Stany nieterminalne:

- $[qXp]$ $p, q \in Q$, gdzie X symbol ze stosu
- A_{qaY} $q \in Q$, a to symbol inputu, Y symbol ze stosu


A_{qaY} gwarantować mają, że G_M jest LR(0).

Produkcje:

- (1) $S \rightarrow [q_0 Z_0 p]$ dla każdego $p \in Q$

- (2) $[qYp] \rightarrow A_{qaY}$,
jeśli $\delta(q, a, Y) = (p, \epsilon)$
- (3) $[qYq_{k+1}] \rightarrow A_{qaY}[q_1X_1q_2][q_2X_2q_3] \cdots [q_kX_kq_{k+1}]$,
jeśli $\delta(q, a, Y) = (q_1, X_1 \dots X_k) \forall q_2, \dots, q_k \in Q$
- (4) $A_{qaY} \rightarrow a \quad \forall q, a, Y$

Szkic dowodu



Podstawowa własność

Ciąg kroków M , w trakcie których M czyta input, odpowiada
ciągowi prawostronnych wyprowadzeń przy pomocy produkcji typu $A_{qaY} \rightarrow a$
(w odbiciu zwierciadlanym)

$$\text{Powód: } [qYp] \rightarrow \underbrace{A_{qaY}}_{\text{później}} \underbrace{[qX_1p_1] \cdots [p_kX_kp]}_{\substack{\text{zostaje wcześniej} \\ \text{zastąpione przez terminale}}}$$

- Zakładamy, że gramatyka nie ma zbędnych symboli.
- Dla $[qXp]$ niech w_{qXp} będzie ciąg terminali t.ż.: $[qXp] \xRightarrow{*}_r w_{qXp}$

- $h(\alpha)$ to ciąg jaki można wyprowadzić z α :

$$h(A_{qaY}) = a$$

$$h([qXp]) = w_{qXp}$$

$$h(XY) = h(X)h(Y)$$

- Funkcja N : $N(\gamma)$ jest liczbą kroków automatu, które odpowiadają wyprowadzeniu $\gamma \xRightarrow{*}_r h(\gamma)$. Tj.

$$N(A_{qaY}) = 1$$

$$N([qXp]) = \text{liczba kroków dla } w_{qXp}$$

- Funkcja m (śląd wyprowadzenia):

$$m(A_{qaY}) = (qaY)$$

$$m([qXp]) = (\text{ciąg indeksów } A \text{ dla wyprowadzenia z } w_{qXp})^R$$

$$m(XY) = m(X)m(Y)$$

Podstawowa własność zdefiniowanej gramatyki

Jeśli $X \rightarrow \beta$ i $Y \rightarrow \delta$ są produkcjami postaci (2) oraz (3), wtedy δ nie jest **właściwym** podciągiem β .

Wynika to z tego, że A_{qaY} (pierwszy znak w β) koduje długość β .

Kierunek dowodu

Aby wykazać własność LR(0) musimy pokazać że jeśli $B \rightarrow \beta \cdot$ jest ważny dla żywotnego prefixu γ , to:

- żaden element $A_{qaX} \rightarrow \cdot a$ nie jest ważny dla γ ,
- żaden element $C \rightarrow \alpha \cdot$ nie jest ważny dla γ .

Lemat Niech J = zbiór ważnych elementów dla żywotnego prefixu γ .
Jeśli $B \rightarrow \beta \cdot$ jest w J , to żaden $A_{qaY} \rightarrow \cdot a$ nie należy do J .

Dowód Lematu

Przypadek 1: $B \rightarrow \beta \cdot$ jest postaci $S \rightarrow [q_0 Z_0 p] \cdot$.

Wtedy $\gamma = [q_0 Z_0 p]$.

Jeśli $A_{qaY} \rightarrow \cdot a$ jest w J , to

$S \xRightarrow{*}_r \gamma A_{qaY}$.

Ale γ istnieje tylko po pierwszym kroku wyprowadzenia.

Dowód Lematu

Przypadek 2: $B \rightarrow \beta \cdot$ jest postaci $[qY p] \rightarrow A_{qaY} [] [] \cdots [] \cdot$,

Wtedy $\gamma = \gamma' \beta$.

Założmy, że mamy wyprowadzenia:

$S \xRightarrow{*}_r \gamma' \beta y$

$S \xRightarrow{*}_r \gamma' \beta A_{qaY} y'$.

β może tylko być otrzymane z produkcji $B \rightarrow \beta$.

W momencie powstania β nie może A_{qaY} stać po prawej stronie B (prawostronne wyprowadzenie!).

Ale wtedy w następnym kroku używany ostatni nieterminal z β !

Dowód Lematu

Przypadek 3: $B \rightarrow \beta \cdot$ jest postaci $A_{pbZ} \rightarrow b \cdot$

- γA_{qaY} jest żywotnym prefixem, bo $A_{qaY} \rightarrow \cdot a$ jest ważny dla γ
- z drugiej strony $\gamma = \gamma' b$, gdyż $A_{pbZ} \rightarrow b \cdot$ jest ważny dla γ . Więc $\gamma A_{qaY} = \gamma' b A_{qaY}$ to żywotny prefix.

Dowód Lematu

- jeśli $b \neq \epsilon$, to mielibyśmy terminal na lewo od nieterminala. Dla tej gramatyki to niemożliwe. Więc: $b = \epsilon$.

- Rozważamy żywotne prefixy γA_{qaY} , $\gamma A_{p\epsilon Z}$.

Pokażemy, że automat nie będzie deterministyczny. Rozpatrujemy:

$h(\gamma A_{qaY}) = h(\gamma) a$ i $h(\gamma A_{p\epsilon Z}) = h(\gamma)$

Rozważamy $N(\gamma) + 1$ kroków M na $h(\gamma) a$:

- pierwsze $N(\gamma) + 1$ kroków M na $h(\gamma)a = h(\gamma A_{p\epsilon Z})a$ to $m(\gamma)m(A_{p\epsilon Z}) = m(\gamma)(p, \epsilon, Z)$.
- Z drugiej strony ponieważ $h(\gamma)a = h(\gamma A_{qaY})$, jest $N(\gamma) + 1$ kroków w $m(\gamma A_{qaY}) = m(\gamma)m(A_{qaY}) = m(\gamma)(q, a, Y)$

Część 2 dowodu własności LR(0)

Lemat

Niech J będzie zbiorem ważnych elementów dla γ .

Jeśli $B \rightarrow \beta \cdot \in J$, to żaden inny element $C \rightarrow \alpha \cdot$ nie jest w J .

Dowód

Przypadek 1: $B \rightarrow \beta \cdot, C \rightarrow \alpha \cdot$ nie są elementami typu $A_{qaY} \rightarrow a \cdot$

- $\beta = A \dots [] \dots []$ – wtedy $A \dots$ wyznacza β
- $B \rightarrow \beta$ ma formę $S \rightarrow [q_0 Z_0 p]$ - łatwe ...jak poprzednio

Dowód

Przypadek 2: $B \rightarrow \beta \cdot, C \rightarrow \alpha \cdot$ są postaci $A_{qaY} \rightarrow a \cdot$.

Podprzypadki:

a) $\alpha = \beta$:

rozważamy $N(\gamma) + 1$ kroków na $h(\gamma)a$

Wtedy $h(\gamma A_{q\alpha Y}) = h(\gamma)\alpha$ i $h(\gamma A_{q'\beta Y'}) = h(\gamma)\beta = h(\gamma)\alpha$

1. na $h(\gamma A_{q\alpha Y})$ pierwsze $N(\gamma) + 1$ kroków to:
 $m(\gamma)m(A_{q\alpha Y}) = m(\gamma)(q\alpha Y)$
2. dla $h(\gamma A_{q'\beta Y'})$ pierwszych $N(\gamma) + 1$ kroków to:
 $m(\gamma)m(A_{q'\beta Y'}) = m(\gamma)(q'\beta Y')$

niedeterminizm!

Dowód

b) $\alpha = \epsilon$:

Rozważmy $N(\gamma) + 1$ kroków na $h(\gamma)\beta$.

Rozważamy inputy:

$h(\gamma A_{q\epsilon Y}) = h(\gamma)$ i $h(\gamma A_{q'\beta Y'}) = h(\gamma)\beta$

Dla $h(\gamma)\beta$:


z powodu $\gamma A_{q\epsilon Y}$ obliczenie to $m(\gamma)(q\epsilon Y)$.

z powodu $\gamma A_{q'\beta Y'}$ obliczenie to $m(\gamma)(q'\beta Y')$.

Dla tego samego inputu dwa różne obliczenia.

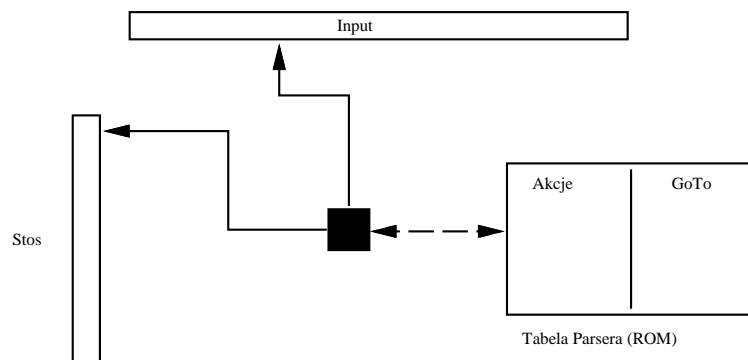
c) $\alpha = \beta = \epsilon \dots$

Przypadek 3: $B \rightarrow \beta$ ma formę $A_{qaY} \rightarrow a$, ale $C \rightarrow \alpha$ nie.



Mielibyśmy terminale w α , co nie może się zdarzyć.

Inne parsery



Inne parsery

- Na stosie: $s_0X_1s_1X_2s_2\cdots X_ms_m$
- Konfiguracja: $(\underbrace{s_0X_1s_1X_2s_2\cdots X_ms_m}_{\text{stos}}, \underbrace{a_ia_{i+1}\cdots a_n\$}_{\text{nie przeczytana część inputu}})$

- Operacje

ACTION(s_m, a), poprzez Look-up w tabeli parsera:

1. shift s : wpisz a na stos, dodatkowo s
2. redukuj: przez $A \rightarrow \beta$
3. akceptuj
4. error

Nowa konfiguracja:

dla 1.) $(s_0X_1s_1X_2s_2\cdots X_ms_m a_i s, a_{i+1}\cdots a_n\$)$

$s = \text{GOTO}(s_m, a_i)$,

dla 2.) $(s_0X_1s_1X_2s_2\cdots X_{m-r}s_{m-r} A s, a_i\cdots a_n\$)$

$s = \text{GOTO}(s_{m-r}, A)$, gdzie $r = \text{długość } \beta$

Simple-LR-Parsing Table (SLR)

Jeśli LR(0) dla danej gramatyki nie funkcjonuje, SLR pomaga uniknąć konfliktów

Idea: użyć następnego symbol inputu do decyzji.

Przykład: mamy handle β , oraz γ ,

nie wiadomo czy użyć $A \rightarrow \beta$ czy $B \rightarrow \gamma$

Czytamy następnym znak c .

Jeśli np. $c \in \text{FOLLOW}(A)$ i $c \notin \text{FOLLOW}(B)$, to tylko $A \rightarrow \beta$ wchodzi w grę.

Definicja parsera SLR

Jak LR(0), ale używamy informacji:

- Jeśli $A \rightarrow \alpha \cdot$ należy do s_m , wtedy
 $\text{ACTION}(s_m, a) = \text{zredukuj przy pomocy } A \rightarrow \alpha$, jeśli $a \in \text{FOLLOW}(A)$.
- Jeśli $A \rightarrow \alpha \cdot a\beta$ jest w s_m , wtedy $\text{ACTION}(s_m, a) = \text{shift}$

Nie chodzi tylko o wczesne wykrywanie błędów!
 Tabela SLR nie może zawierać żadnych konfliktów.
 $\text{ACTION}(s_m, a)$ musi być jednoznacznie zdefiniowana.

Przykład

$E' \rightarrow E, \quad E \rightarrow E + T \mid T, \quad T \rightarrow T * F \mid F, \quad F \rightarrow (E) \mid id$

- nie jest LR(0):
 rozważ $E' \Rightarrow E$ oraz $E' \Rightarrow E \rightarrow E + T$.
 Dla prefixa E następujące elementy są ważne:
 $E' \rightarrow E \cdot, E \rightarrow E \cdot + T$.
 Konflikt typu shift-reduce.
- dla SLR: jak wygląda ACTION dla stanu
 $I = \{E' \rightarrow E \cdot, E \rightarrow E \cdot + T\}$?
 $\text{ACTION}(I_1, \$) = \text{akceptuj}$
 $\text{ACTION}(I_1, +) = \text{shift}$
 Unikamy konfliktu, bo $\text{FOLLOW}(E')$ nie zawiera "+".

SLR nie zawsze wystarcza

Gramatyka:

$S \rightarrow L = R \mid R$

$L \rightarrow *R \mid id$

$R \rightarrow L$

Jest jednoznaczna!

Stan $I_2 = \{S \rightarrow L \cdot = R, R \rightarrow L \cdot\}$ opisuje ważne elementy dla prefixu L .

- zauważmy, że „=” $\in \text{FOLLOW}(R)$
 (bo $S \Rightarrow_r L = R \Rightarrow_r *R = R$)

- $\text{ACTION}(I_2, =) = \text{shift}$, z powodu elementu $S \rightarrow L \cdot = R$
 $\text{ACTION}(I_2, =) = \text{reduce}$, ponieważ $=$ należy do $\text{FOLLOW}(R)$

Konflikt! SLR-parser nie działa.

Kanoniczne tabele LR

Intensywniej używamy następnego znaku.

LR(1)–element jest postaci [LR(0)–element, symbol inputu].

Element $[A, \rightarrow \alpha \cdot \beta, a]$ nazywa się *ważny* dla prefixu γ , jeśli istnieje wyprowadzenie prawostronne takie że:

$$S \xRightarrow{*} \delta A w \Rightarrow_r \delta \alpha \beta w$$

gdzie $\gamma = \delta \alpha$ i a jest pierwszym terminalem w (lub $w = \epsilon$ oraz $a = \$$).
 Więc $a \in \text{FOLLOW}(A)$.

Uwaga: a nie musi być następnym znakiem inputu!

Przykład

Gramatyka: $S \rightarrow BB, B \rightarrow aB \mid b$, tak więc $L = a^* b a^* b$

- $S \Rightarrow_r BB \Rightarrow_r BaB \Rightarrow_r aBab \Rightarrow_r aaBab \Rightarrow_r \underbrace{aaa} Bab$,
 więc $[B \rightarrow a \cdot B, a]$ jest ważny dla aaa .

- $S \Rightarrow_r BB \Rightarrow_r BaB \Rightarrow_r \underbrace{Baa} B$,
 więc $[B \rightarrow a \cdot B, \$]$ jest ważny dla Baa .

- Czy $[B \rightarrow a \cdot B, a]$ jest ważny dla Baa ? Jeśli tak, to

$$S \xRightarrow{*} BaBa \dots \Rightarrow_r Baa Ba \dots \xRightarrow{*} a \dots aba \dots aba \dots$$

Ale dla słów z L może drugie b stać tylko na końcu. Więc $[B \rightarrow a \cdot B, a]$ nie jest ważny dla Baa .

Idea obliczenia ważnych LR(1)–elementów

- niech $[A \rightarrow \alpha \cdot B, a]$ ważny LR(1)–element dla $\delta\alpha$, oraz

$$S \xRightarrow{*}_r \delta Aax \Rightarrow_r \delta\alpha Bax \xRightarrow{B \rightarrow \eta}_r \delta\alpha\eta ax$$

Wtedy $[B \rightarrow \cdot \eta, a]$ jest ważny dla $\delta\alpha$.

Idea obliczenia ważnych LR(1)–elementów

- Ogólnie:
niech $[A \rightarrow \alpha \cdot B\beta, a]$ ważny LR(1)–element dla γ ,

$$S \xRightarrow{*}_r \delta Aax \Rightarrow_r \delta\alpha B\beta ax \xRightarrow{*}_r \delta\alpha B\beta' ax \Rightarrow_r \underbrace{\delta\alpha}_{\gamma} \eta\beta' ax,$$

wtedy $[B \rightarrow \cdot \eta, y]$ jest ważny dla γ , gdzie y to pierwszy symbol $\beta'ax$. (β' zawiera tylko symbole terminalne.)

Co z y ?

Przypadek 1: $\beta' = \epsilon$, wtedy $y = a$

Przypadek 2: $\beta' \neq \epsilon$, wtedy

$$y \in \text{FIRST}(\beta'ax) = \text{FIRST}(\beta'a) \in \underbrace{\text{FIRST}(\beta a)}_{\text{już znane}}$$

Idea obliczenia ważnych LR(1)–elementów

- niech $[A \rightarrow \alpha \cdot X\beta, a]$ ważny dla γ .

ponieważ $S \xRightarrow{*}_r \delta Aax \Rightarrow_r \underbrace{\delta\alpha X}_{\gamma} \beta ax$

jest $[A \rightarrow \alpha \cdot X\beta, a]$ ważny dla γ .

Procedura obliczania elementów LR(1)

PROCEDURE CLOSURE(I); (transytywne domknięcie)
 REPEAT
 \forall elementu $[A \rightarrow \alpha \cdot B\beta, a] \in I$, produkcji $B \rightarrow \gamma$,
 $b \in \text{FIRST}(\beta a)$ oraz $[B \rightarrow \cdot \gamma, b] \notin I$:
 $I := I \cup [B \rightarrow \cdot \gamma, b]$
 UNTIL nie ma zmian
 output I

Procedura obliczania elementów LR(1)

PROCEDURE GOTO(I, X); (X to symbol z inputu.)
 $I := \{[A \rightarrow \alpha X \cdot \beta, a] \mid [A \rightarrow \alpha \cdot X\beta, a] \in I\}$
 output I

MAIN PART;
 $C := \text{CLOSURE}(\{[S' \rightarrow \cdot S] \mid S' \rightarrow S \text{ w gramatyce}\})$
 REPEAT dla każdego $I \in C$, X t.ż. $\text{GOTO}(I, X) \neq \emptyset$
 $C := C \cup \{ \text{CLOSURE}(\text{GOTO}(I, X)) \}$
 UNTIL nie ma zmian w C .

Sposób działania

tabela parsingu steruje parserem. Niech a - aktualny symbol z taśmy, I - symbol na wierzchu stosu. (I to zbiór ważnych elementów LR(1)).

- Jeśli $[A \rightarrow \alpha \cdot a\beta, b] \in I$, wykonaj Shift:
 - głowica na taśmie przesuwa się na prawo,
 - dwa nowe symbole na stos:
 a oraz $\text{CLOSURE}(\text{GOTO}(I, a))$.
- Jeśli $[A \rightarrow \alpha \cdot, a] \in I$, wtedy $\text{ACTION}(I, a) = \text{reduce}$ przy pomocy $A \rightarrow \alpha$
- Jeśli $[S' \rightarrow S \cdot, \$] \in I$, wtedy $\text{ACTION}(I, S) = \text{akceptuj}$.

Gramatyki LR(1)

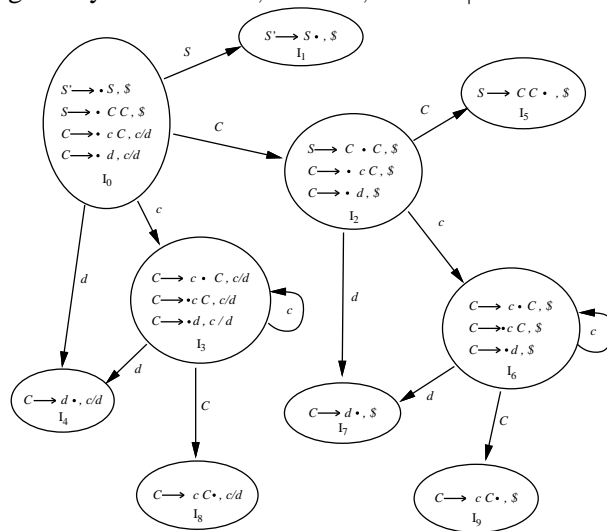
Gramatyka nazywa się LR(1), jeśli żadne konflikty nie występują w $\text{ACTION}()$.
 Typy konfliktów:

$\left. \begin{array}{l} [A \rightarrow \alpha \cdot, b] \\ [A \rightarrow \beta \cdot, b] \end{array} \right\}$ konflikt reduce–reduce

$\left. \begin{array}{l} [A \rightarrow \alpha \cdot a\beta, c] \\ [B \rightarrow \beta \cdot, a] \end{array} \right\}$ konflikt shift–reduce

Konstrukcja tabeli

gramatyka: $S' \rightarrow S, S \rightarrow CC, C \rightarrow cC \mid d$



Kanoniczna tabela parsingu

stan	ACTION			GOTO	
	c	d	\$	S	C
0	s3	s4		1	2
1			ACC		
2	s6	s7			5
3	s3	s4			8
4	r3	r3			
5			r1		
6	s6	s7			9
7			r3		
8	r2	r2			
9			r2		

- Każda gramatyka SLR jest LR(1).
(ale LR(1)- parser może okazać się większy - niepotrzebnie)
- Nie każda LR(1) jest SLR.
- Praktycznie LR(1)- parsery są często wystarczające, choć nie każda gramatyka dCFL jest LR(1).
- LR(1)-tabela jest często za duża dla praktycznych zastosowań.
⇒ Motywacja dla gramatyk i parserów pomiędzy SLR oraz LR(1).