AKADEMIA GÓRNICZO-HUTNICZA
IM. STANISŁAWA STASZICA W KRAKOWIE

Analiza leksykalna – 1

Teoria kompilacji

Dr inż. Janusz Majewski
Katedra Informatyki

Zadanie analizy leksykalnej

Przykład:

We: COST := (PRICE + TAX) * 0.98

Wy: id_1 := (id_2 + id_3) * num_4

Tablica symboli:

Adres	Nazwa/wartość	Charakter	Dodatkowa informacja
1	COST	zmienna	….
2	PRICE	zmienna	….
3	TAX	zmienna	….
4	0.98	stała	….

Zadanie analizy leksykalnej

Przykład:

We: COST:= (PRICE + TAX) * 0.98

Wy: id_1 := (id_2 + id_3) * num_4

Wyjście skanera:	<=	**Wejście skanera:**
(id, 1)		COST
(equ,)		:=
(left-par,)		(
(id, 2)		PRICE
(plus,)		+
(id, 3)		TAX
(right-par,)		)
(mult,)		*
(num, 4)		0.98

Współpraca z parserem

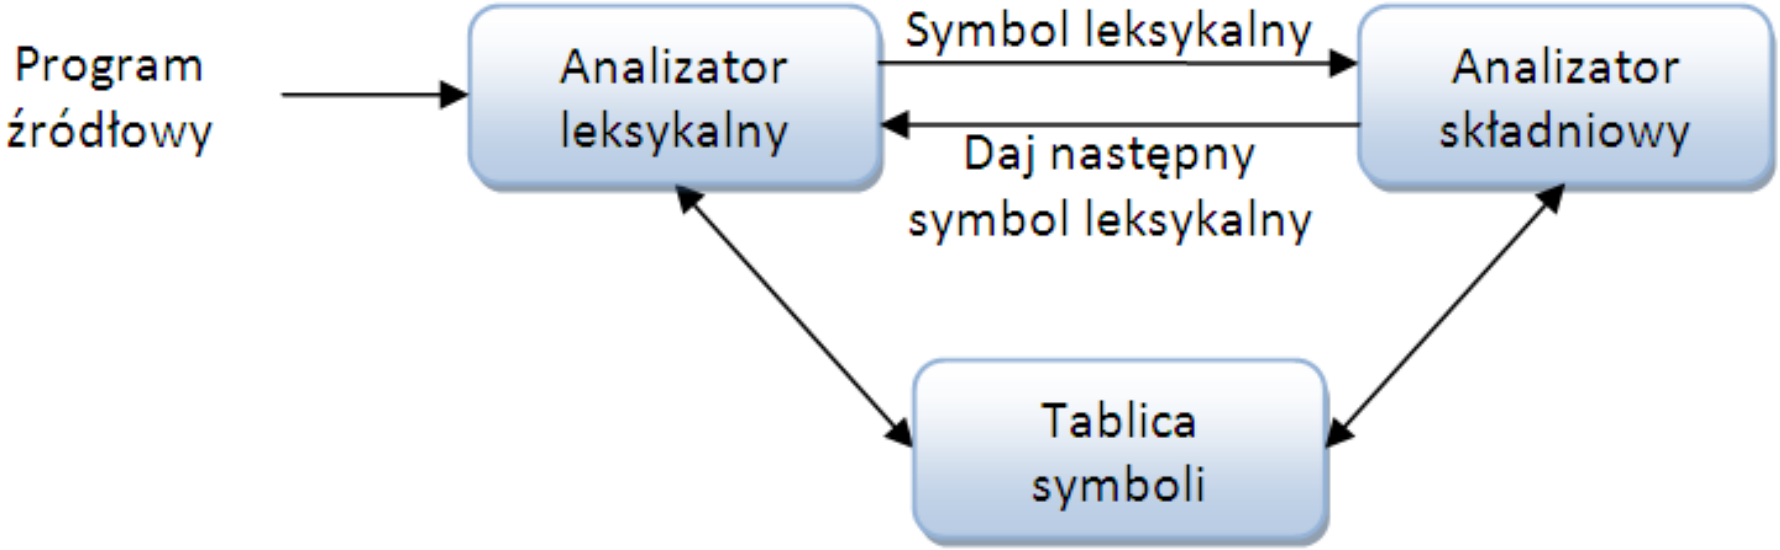

Architektura kompilatora (1)

a) Realizacja szeregowa

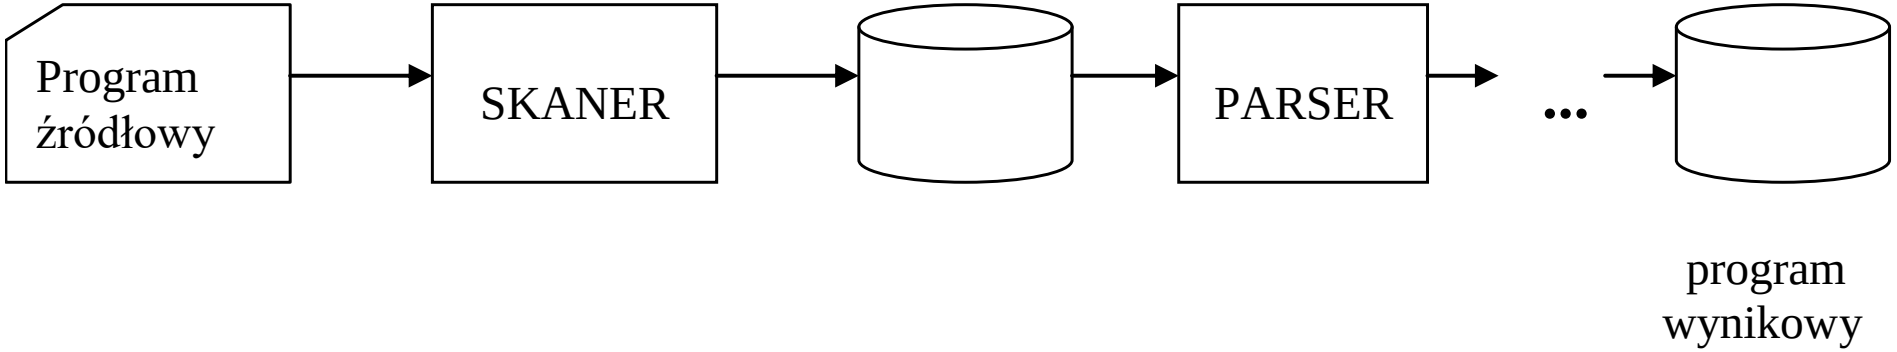

- translator wieloprzebiegowy
- translator nakładkowy
- mniejsza zajętość PaO
- dłuższy czas kompilacji

Architektura kompilatora (2)

b) Realizacja równoległa

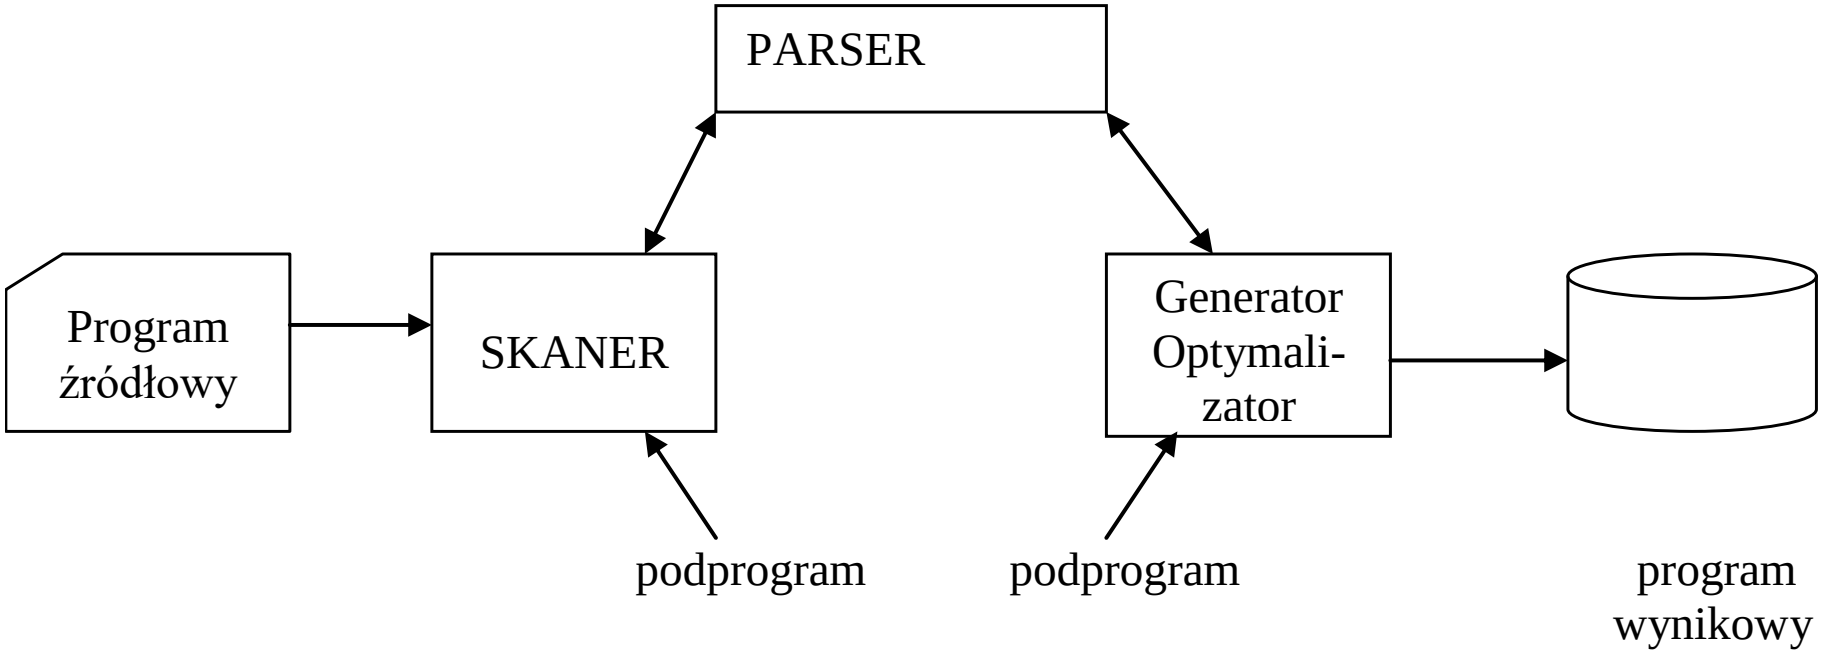

- translator jednoprzebiegowy
- większa zajętość PaO
- krótszy czas kompilacji

Zadania analizatora leksykalnego

Zadania analizatora leksykalnego:

- wyodrębnianie symboli leksykalnych (tokenów)
- ignorowanie komentarzy
- ignorowanie białych znaków (spacji, tabulacji, znaków nowej linii…)
- korelowanie błędów zgłaszanych przez kompilator z numerami linii
- tworzenie kopii zbioru wejściowego (źródłowego) łącznie z komunikatami o błędach
- czasami realizacja funkcji preprocessingu, rozwijanie makrodefinicji

Rozdzielenie etapu analizy na dwie odrębne funkcje: analizę leksykalną i analizę syntaktyczną sprawia, że jedna i druga mogą być wykonywane przy użyciu bardziej efektywnych algorytmów, gdyż algorytmy te istotnie się różnią, wykorzystując inne pryncypia formalne i realizacyjne.

Podstawowe pojęcia: token, leksem, wzorzec

Przykład:

const pi2=6.2832;

token	leksem	wzorzec (pattern)
const (słowo kluczowe)	const	const
ws	□	*biały_znak*$^+$
id	pi2	*litera* (*litera* | *cyfra*)*
relop	=	< | > | <= | >= | = | <>
num	6.2832	*cyfra*$^+$(. *cyfra*$^+$)? ((E|e) (+|–)? *cyfra*$^+$)?

źródło: `const pi2=6.2832`

leksemy: const □ pi2 = 6.2832

tokeny: const ws id relop num

Podział gramatyki G opisującej dany język programowania

Gramatyka G języka źródłowego (najczęściej bezkontekstowa):

$$G = \langle V, \Sigma, P, S \rangle$$

gdzie na ogół:

$$\Sigma = \{A, B, ..., Z, a, b, ..., z, 0, 1, ..., 9, +, -, *, /, ., (,), ...\}$$

Przebudowujemy gramatykę G na rodzinę gramatyk:

$G_S = \langle V_S, \Sigma_S, P_S, S_S \rangle$ - gramatyka syntaktyczna

$\Sigma_S = \{\Sigma_{S_i} \mid \Sigma_{S_i} \text{ jest\_tokenem}\}$ - tokeny są terminalami w gramatyce syntaktycznej

$G_i = \langle V_i, \Sigma_i, P_i, S_i \rangle$ - gramatyki leksykalne, jedna dla każdego tokenu

$S_i = \Sigma_{S_i}$

$\Sigma_{S_i} \in V_i$, $\Sigma_i \subset \Sigma$

i-ty token Σ_{S_i} jest symbolem początkowym (nieterminalem) i-tej gramatyki leksykalnej.

Podział gramatyki G opisującej dany język programowania

Podział gramatyki języka źródłowego $G = \langle V, \Sigma, P, S \rangle$

- Gramatyka syntaktyczna: $G_S = \langle V_S, \Sigma_S, P_S, S_S \rangle$
- Rodzina gramatyk leksykalnych $G_i = \langle V_i, \Sigma_i, P_i, S_i \rangle$ po jednej dla każdego tokenu

$$V = V_S \cup \bigcup_{i=1}^{n} V_i$$

$$\Sigma = \bigcup_{i=1}^{n} \Sigma_i$$

$$P = P_S \cup \bigcup_{i=1}^{n} P_i$$

$$S = S_S$$

Gramatyka języka źródłowego G jest więc efektem „podstawienia” gramatyk leksykalnych G_i do gramatyki syntaktycznej G_S.

Podział gramatyki G opisującej dany język programowania

token	leksem	wzorzec (pattern)
const (słowo kluczowe)	const	const
ws	□	*biały_znak*$^+$
id	pi2	*litera* (*litera* | *cyfra*)*
relop	=	< | > | <= | >= | = | <>
num	6.2832	*cyfra*$^+$(. *cyfra*$^+$)? ((E|e) (+|–)? *cyfra*$^+$)?

Wzorce są opisami sposobu wyodrębniania tokenów.
Wzorce pełnią rolę produkcji w gramatykach leksykalnych.
Tokeny są symbolami nieterminalnymi w gramatykach leksykalnych.
Tokeny są terminalami w gramatyce syntaktycznej.

Trudności w budowaniu analizatora leksykalnego

Przykład:

W niektórych językach programowania słowa kluczowe nie są zastrzeżone (FORTRAN, PL/I). W języku PL/I poprawny jest zapis:

IF THEN **THEN** THEN = ELSE ; **ELSE** ELSE = THEN;

Trudności w budowaniu analizatora leksykalnego

Przykład:

W języku FORTRAN spacje (z wyjątkiem spacji wewnątrz łańcuchów) są zawsze ignorowane. Nazwy zmiennych nie wymagają deklaracji. Typ zmiennej ustalany jest na podstawie pierwszej litery nazwy.

Porównujemy:

1) DO 5 I = 1 **.** 25 równoznaczne DO5I = 1.25
(instrukcja przypisania, DO5I – zmienna rzeczywista)

2) DO 5 I = 1**,** 25 instrukcja pętli wyliczanej typu "for", odpowiednik:

```
for I := 1 to 25 do
  begin
        ...
        ...
etykieta ...
        ...
5: end;
```

Trudności w budowaniu analizatora leksykalnego

Przykład c.d.:

1)

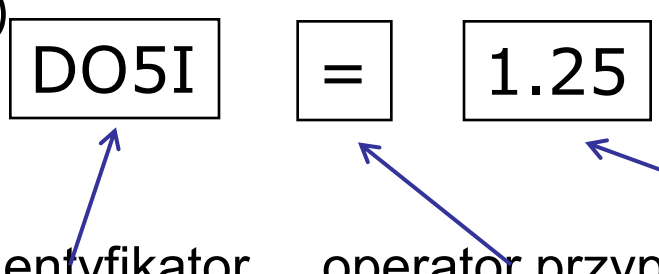

2)

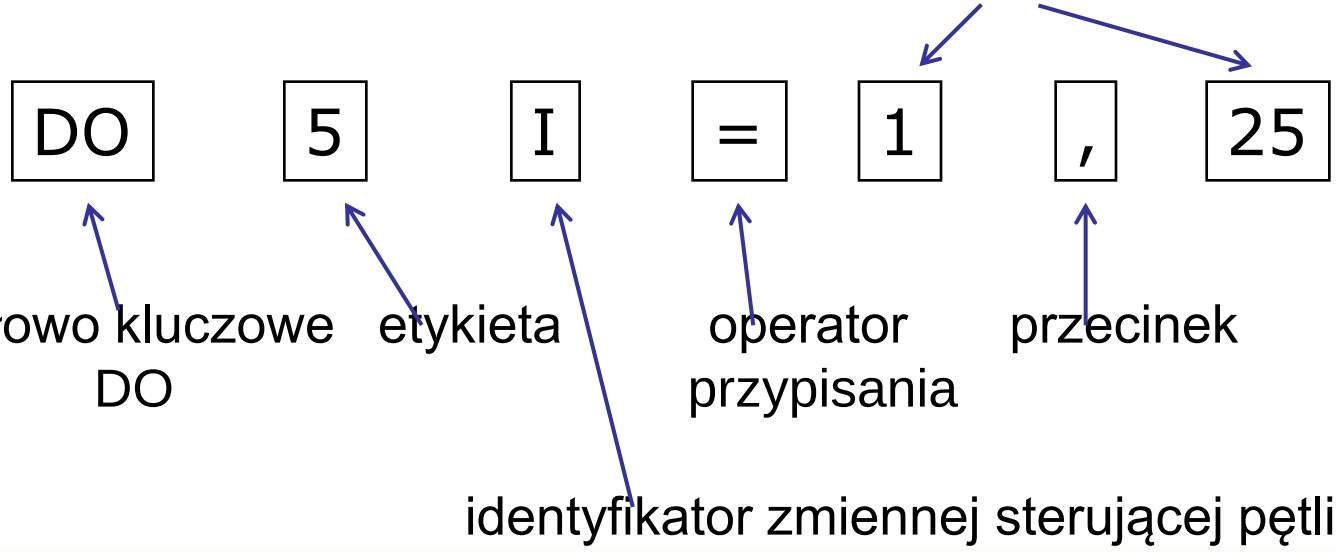

Trudności w budowaniu analizatora leksykalnego

Przykład c.d.:

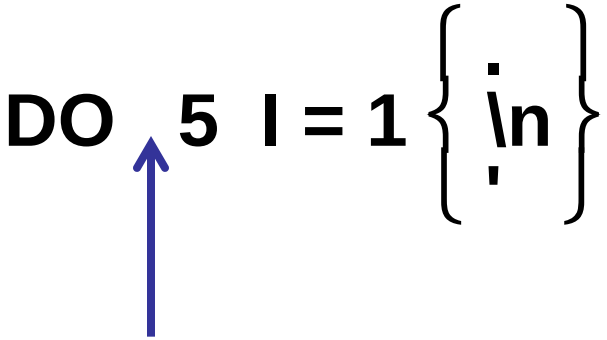

Po przeczytaniu znaków DO nie można dokonać uzgodnienia tokenu "Słowo kluczowe DO" dopóki nie zbada się prawego kontekstu i nie znajdzie się przecinka (wtedy rzeczywiście uzgadnia się "DO") lub kropki bądź znaku nowej linii (wtedy mamy instrukcje podstawienia).

Definicje regularne

Do opisu wzorców dla skanera stosujemy definicje regularne:

$d_1 \rightarrow r_1$

$d_2 \rightarrow r_2$

.....

$d_n \rightarrow r_n$

gdzie:

d_i - unikalna nazwa

r_i - wyrażenie regularne nad symbolami alfabetu $\Sigma \cup \{d_1, d_2, ..., d_{i-1}\}$

Przykład definicji regularnych (1)

Stałe bez znaku w Pascal'u:

cyfra → *0* | *1* | *2* | *3* | *4* | *5* | *6* | *7* | *8* | *9*

cyfry → *cyfra* *cyfra* *

część-ułamkowa → . *cyfry* | ε

wykładnik → (*E* | *e*) (+ | – | ε) *cyfry* | ε

num → *cyfry* *część-ułamkowa* *wykładnik*

Rozszerzenie zbioru operatorów

Dla ułatwienia wprowadza się nowe operatory w wyrażeniach regularnych, np.:

w^+ - oznacza jedno lub więcej wystąpień wzorca w

$$w^+ = w\, w^*$$

$w?$ - oznacza zero lub jedno wystąpienie wzorca w

$$w? = w \mid \varepsilon$$

Przykład definicji regularnych (2)

Stałe bez znaku w Pascal'u zapisane po rozszerzeniu zbioru operatorów w wyrażeniach regularnych:

cyfra → *0* | *1* | *2* | *3* | *4* | *5* | *6* | *7* | *8* | *9*

cyfry → *cyfra* $^{+}$

część-ułamkowa → (**.** *cyfry*) ?

wykładnik → ((*E* | *e*) (+ | –) ? *cyfry*) ?

num → *cyfry* *część-ułamkowa* *wykładnik*

Rozpoznawanie tokenów

Przykładowa gramatyka syntaktyczna:

$stmt \rightarrow \underline{if}\ expr\ \underline{then}\ stmt \mid \underline{if}\ expr\ \underline{then}\ stmt\ \underline{else}\ stmt \mid \varepsilon$
$expr \rightarrow term\ \underline{relop}\ term \mid term$
$term \rightarrow \underline{id} \mid \underline{num}$

Definicje regularne:

$\underline{delim} \rightarrow \square \mid \backslash t \mid \backslash n$
$\underline{ws} \rightarrow \underline{delim}^{+}$
$\underline{letter} \rightarrow a \mid b \mid \ldots \mid z \mid A \mid B \mid \ldots \mid Z$
$\underline{digit} \rightarrow 0 \mid 1 \mid \ldots \mid 9$
$\underline{if} \rightarrow if$
$\underline{then} \rightarrow then$
$\underline{else} \rightarrow else$
$\underline{relop} \rightarrow < \mid <= \mid <> \mid > \mid >= \mid =$
$\underline{id} \rightarrow \underline{letter}\ (\ \underline{letter} \mid \underline{digit}\ )^{*}$
$\underline{num} \rightarrow \underline{digit}^{+}\ (\ .\ \underline{digit}^{+}\ )\ ?\ (\ E\ (\ + \mid -\ )\ ?\ \underline{digit}^{+}\ )\ ?$

Skaner ma rozpoznawać…

	token	**atrybut tokenu**
ws	-	-
if	if	-
then	then	-
else	else	-
id	id	wskaźnik do tablicy symboli
num	num	wskaźnik do tablicy symboli
<	relop	LT
<=	relop	LE
<>	relop	NE
=	relop	EQ
>	relop	GT
>=	relop	GE

Diagramy przejść (1)

*Liczba bez znaku w Pascalu – token **num***

cyfra$^+$ (. cyfra$^+$)? ((e|E) (+|–)? cyfra$^+$)?

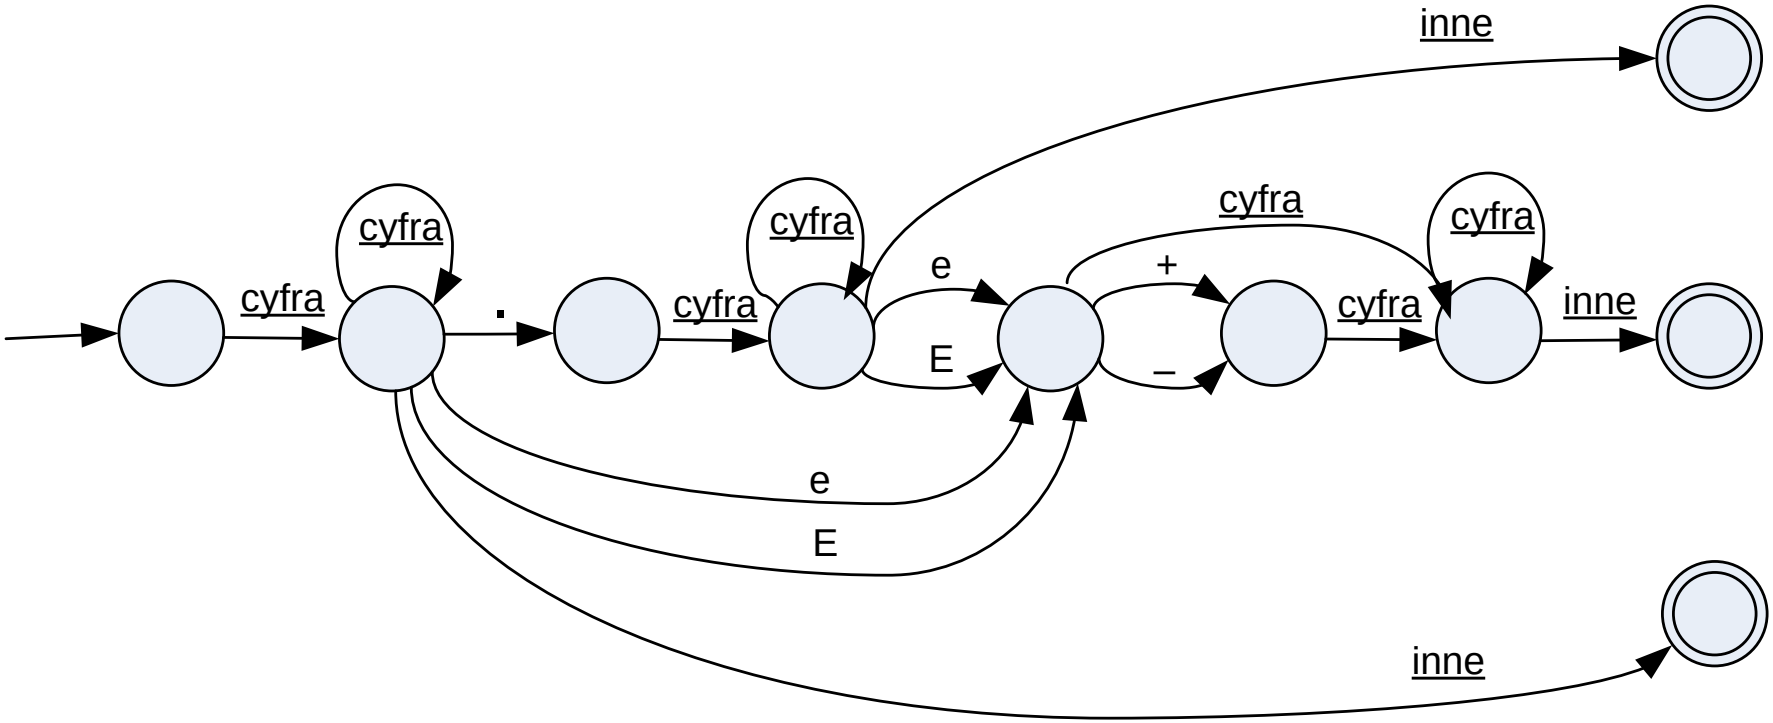

Diagramy przejść (2)

*Operatory relacyjne w Pascalu – token **relop***

< | <= | <> | = | >= | >

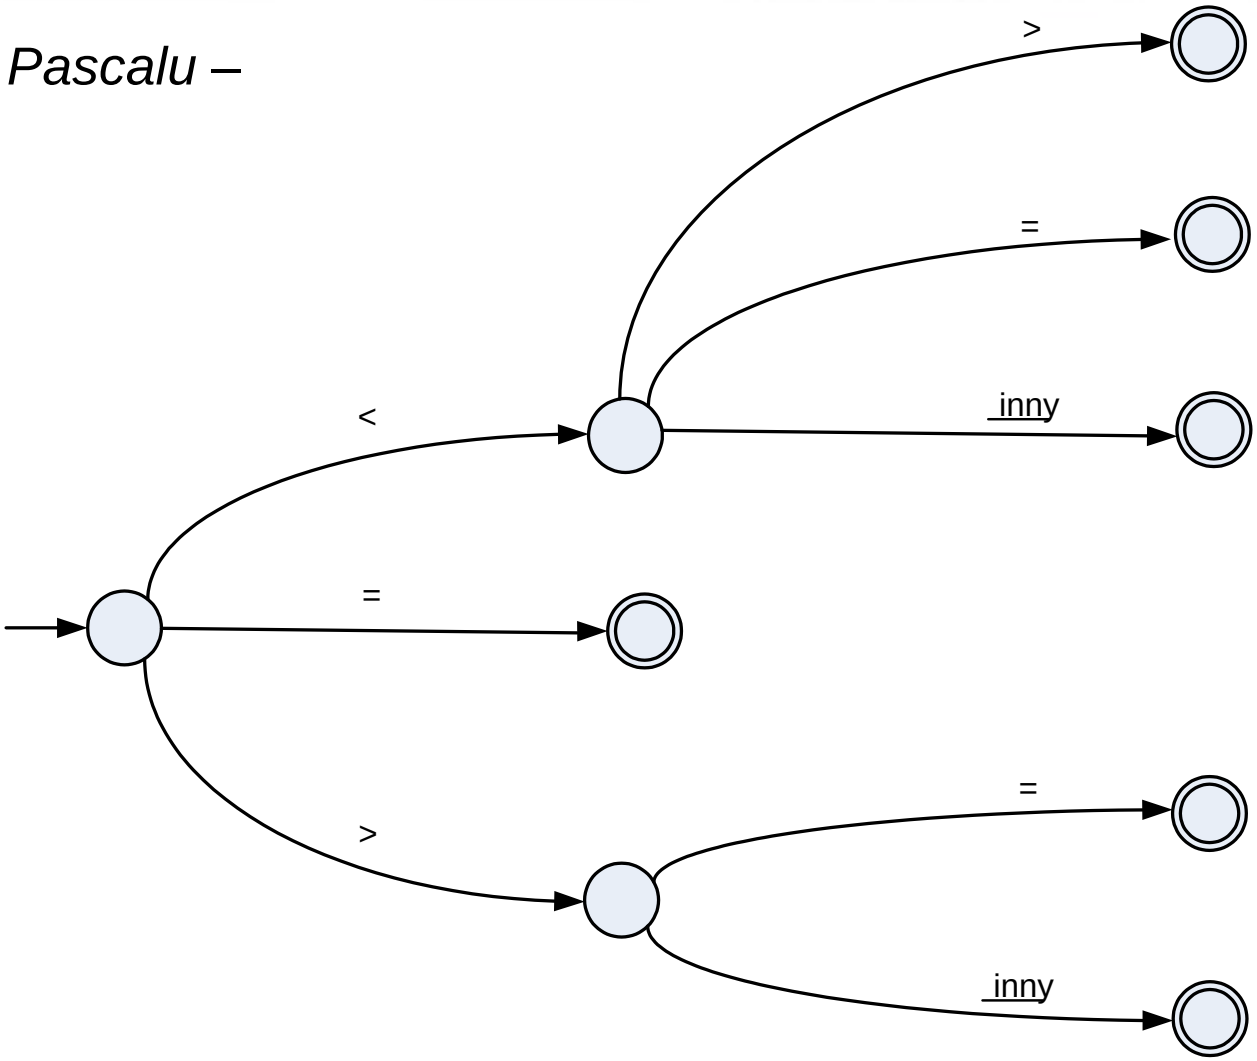

Diagramy przejść (3)

*Identyfikator – token **id***

litera (litera | cyfra)*

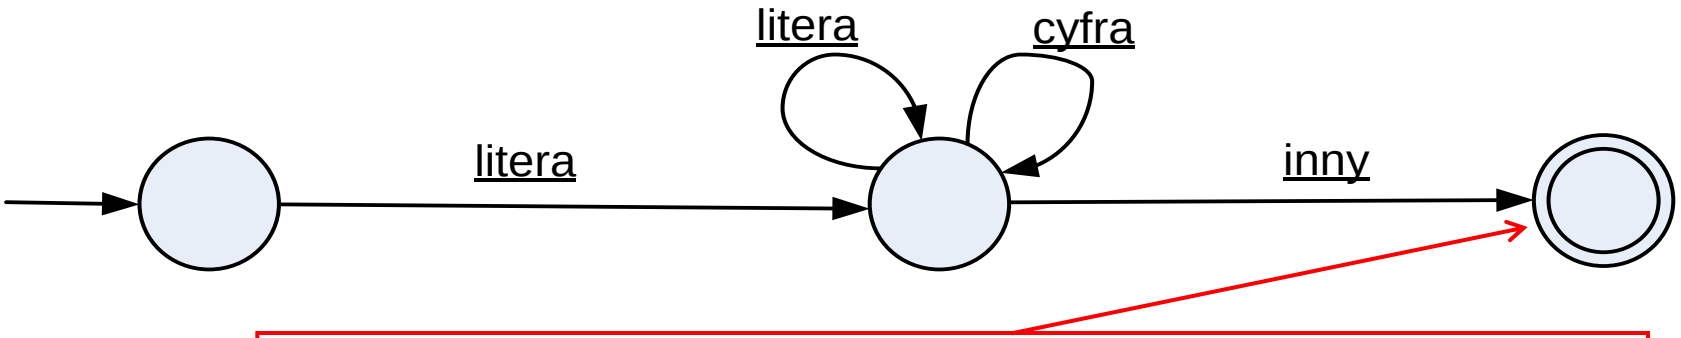

„oddaj” ostatni przeczytany symbol na wejście;
sprawdź, czy leksem to słowo kluczowe;
jeśli tak – zwróć odpowiednie słowo kluczowe;
jeśli nie – sprawdź, czy identyfikator jest już w tablicy symboli;
jeśli jest – zwróć adres jego pozycji;
jeśli nie ma – utwórz nową pozycję, wpisz identyfikator do tablicy symboli i zwróć wskaźnik.

Diagramy przejść (4)

Identyfikatory

litera (litera | cyfra)*

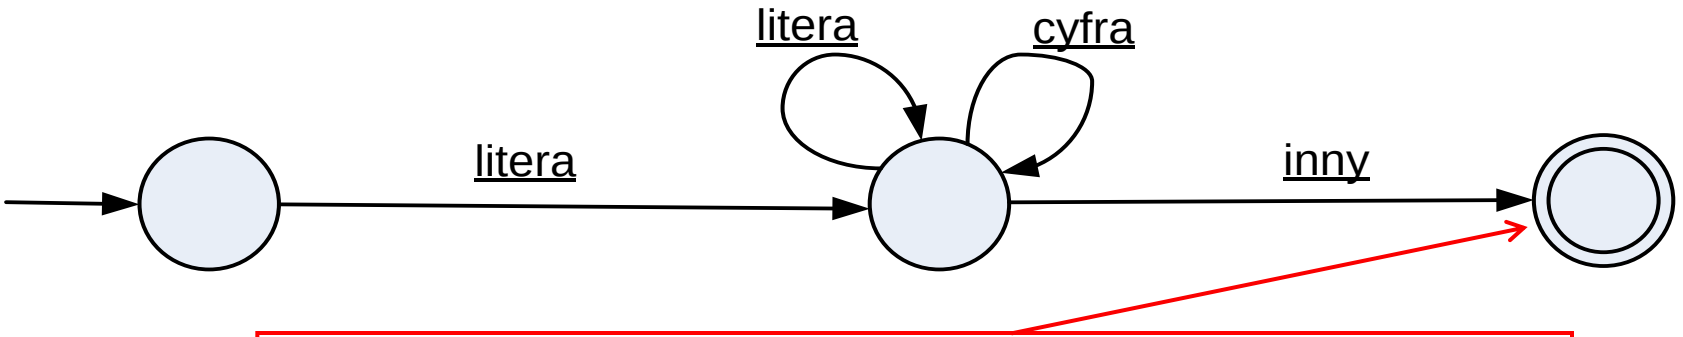

„oddaj” ostatni przeczytany symbol na wejście; sprawdź, czy leksem to słowo kluczowe...

Nie zawsze stosuje się metodę umieszczania słów kluczowych w tablicy i sprawdzania każdego identyfikatora, czy nie jest on słowem kluczowym. Można budować dla słów kluczowych odrębne wzorce i konstruować automaty rozpoznające. Wówczas jednak liczba stanów analizatora gwałtownie rośnie.

Diagramy przejść – ignorowanie białych znaków

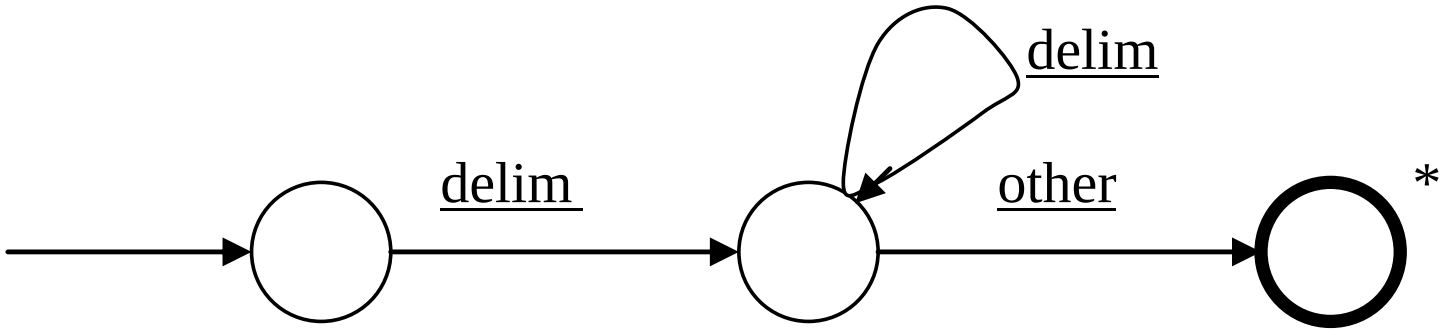

cofnij ostatni przeczytany znak na wejście;
żadna inna akcja analizatora nie jest podejmowana