

Stefan Sokołowski

# JĘZYKI FORMALNE I METODY KOMPILACJI

wykład 1

Inst. Informatyki Stosowanej, ANS  
Elbląg, 2024/2025

Wykład 1, str. 1

Języki formalne

JĘZYK ŹRÓDŁOWY  
(wysokiego poziomu)

KOMPILATOR

JĘZYK DOCEŁOWY  
(wewnętrzny)

Kompilator musi „znać” oba języki...


Jak program komputerowy nauczyć języka?  
Najpierw trzeba ten język ściśle **zdefiniować**.

*Języki formalne* mają u podstaw sposoby ścisłego definiowania języków.

## Języki formalne




### PRZYKŁAD:



## Języki formalne

### PRZYKŁADY:



litery:

```
class Test {
    public static void main
        ( String [ ] args ) {
        System . out . println
            ( "To tylko test." ) ;
    }
}
```

## Proste języki formalne (przykłady)

$\{a, \text{aback}, \text{abandon}, \text{abase}, \dots, \text{zoom}\}$

— język (*skończony*) składający się ze słów języka angielskiego

$\{0, 1, 10, 11, 100, 101, \dots\}$

— język (*nieskończony*) składający się z liczb binarnych

$\{a^n b^n \mid n \geq 0\} = \{\lambda, ab, aabb, aaabbb, \dots\}$

puste (to nie jest litera!)

— język (*nieskończony*) składający się z takich słów, w których

- występują tylko litery  $a$  i  $b$ ,
- liczba liter  $a$  jest równa liczbie liter  $b$ ,
- wszystkie litery  $a$  poprzedzają wszystkie litery  $b$ .

## Języki formalne

### DEFINICJE:

$\Sigma$  — skończony niepusty *alfabet*, czyli zbiór tzw. *liter*

*słowo* — dowolny ciąg skończonej długości o elementach z  $\Sigma$

$\Sigma^*$  — zbiór **wszystkich** słów

*język* — dowolny zbiór słów  $L \subseteq \Sigma^*$

### PRZYKŁAD: nie mylić! —

$\lambda$  — słowo *puste* (ciąg liter o długości 0)

**Uwaga:** to nie jest litera!

$\emptyset \stackrel{\text{def}}{=} \{\}$  — język pusty (nie zawierający żadnego słowa)

$\Lambda \stackrel{\text{def}}{=} \{\lambda\}$  — język zawierający wyłącznie słowo puste

### PRZYKŁAD:

$1(*2-1)(1-(2-*1))()$  — słowo nad alfabetem  $\Sigma \stackrel{\text{def}}{=} \{ (, ), -, *, 1, 2 \}$

$\{\lambda, a, b, ab, ba\}$  — język nad alfabetem  $\Sigma \stackrel{\text{def}}{=} \{a, b\}$  zawierający pięć słów

$\{a^n \mid n \geq 0\} = \{\lambda, a, aa, aaa, \dots\}$  — jęz. nieskończ. nad alf.  $\Sigma \stackrel{\text{def}}{=} \{a\}$

## Jak **porządnie** opisać język nieskończony?

- $\{\lambda, ab, aabb, aaabbb, \dots\}$  — co oznaczają kropeczki?
- $\{a^n b^n \mid n \geq 0\}$  — lepiej, ale są niepożądane elementy obce (liczby, zmienne, relacje, ...)

Język definiujemy na dwa sposoby. Przez

- **generator** — cokolwiek **wyprodukuje**, uważamy za należące do języka
- **akceptor** — cokolwiek **zatwierdza**, uważamy za należące do języka

Opis języka programowania przeznaczony dla programisty powinien być **generatorem** — ma wyjaśniać, jak pisać poprawne programy.

Kompilator języka programowania powinien zawierać **akceptor** — sprawdzający, czy program na jego wejściu należy do języka.

## Generatory: gramatyki bezkontekstowe

**DEFINICJA:** Gramatyka bezkontekstowa  $G$  — czwórka  $\langle \Sigma, N, P, S \rangle$

- alfabet *terminalny*  $\Sigma$ ;
- alfabet *nieterminalny* lub *pomocniczy*  $N$  (rozłączny z  $\Sigma$ );
- skończony zbiór  $P$  *produkcji* postaci  $A \rightarrow w$ , gdzie  
 $A \in N$  (czyli jest pojedynczym nieterminaliem),  
 $w \in (N \cup \Sigma)^*$  (czyli jest słowem z terminali i nieterminali);
- wybrany nieterminal  $S \in N$  nazywany *nieterminaliem początkowym* albo *aksjomatem* gramatyki.

### PRZYKŁAD:

Terminale:  $a, b$

Nieterminale:  $X$

Aksjomat:  $X$

Produkcje:  $X \rightarrow \lambda$   
 $X \rightarrow aXa$   
 $X \rightarrow bXb$

## Jak gramatyka definiuje język?

**DEFINICJA:** Wywodliwość —

$uXv \Rightarrow_G u w v$  czyli  $u w v$  jest bezpośrednio wywodliwe z  $uXv$   $\iff$  w  $P$  jest produkcja  $X \rightarrow w$

$w_1 \Rightarrow_G^* w_n$  czyli  $w_n$  jest wywodliwe z  $w_1$   $\iff$   $w_1 \Rightarrow_G w_2 \Rightarrow_G w_3 \Rightarrow_G \dots \Rightarrow_G w_{n-1} \Rightarrow_G w_n$

**DEFINICJA:** Język  $L(G)$  generowany przez gramatykę  $G$  — składa się z tych słów wywodliwych z **aksjomatu**, które już nie zawierają nieterminali:  $L(G) \stackrel{\text{def}}{=} \{w \in \Sigma^* \mid S \Rightarrow_G^* w\}$ .

**PRZYKŁAD:**

Gramatyka:

$X \rightarrow \lambda$   
 $X \rightarrow aXa$   
 $X \rightarrow bXb$

$X \Rightarrow^* bbaabb \in L(G)$

**LEMAT:**

$L(G) = \{ww^R \mid w \in \{a,b\}^*\}$

$X \Rightarrow bXb \Rightarrow bbXbb \Rightarrow bbaXabb \Rightarrow bbaabb$

## Jak gramatyka definiuje język?

### NIE MYLIĆ:

$\rightarrow$  — formalny symbol w produkcji w gramatyce

$\Rightarrow$  — relacja bezpośredniej wywodliwości:

jeśli  $X \rightarrow w$  to  $X \Rightarrow w$

ale np.  $0X1 \Rightarrow 00X11$

a **nieprawda, że**  $0X1 \rightarrow 00X11$

$\Rightarrow^*$  — relacja wywodliwości:

jeśli  $w_1 \Rightarrow w_2$  to  $w_1 \Rightarrow^* w_2$

ale np.  $X \Rightarrow^* 0011$

a **nieprawda, że**  $X \Rightarrow 0011$

$X \rightarrow \lambda$   
 $X \rightarrow 0X1$

## Jak gramatyka definiuje język?

### PRZYKŁAD:

Gramatyka  $G$ :

$$\begin{array}{lcl} E & \rightarrow & T \\ E & \rightarrow & E + T \\ T & \rightarrow & F \\ T & \rightarrow & T * F \\ F & \rightarrow & a \\ F & \rightarrow & ( E ) \end{array}$$

$$\begin{aligned} E &\Rightarrow E + T \Rightarrow T + T \Rightarrow F + T \Rightarrow a + T \\ &\Rightarrow a + T * F \Rightarrow a + F * F \Rightarrow a + a * F \\ &\Rightarrow a + a * a \in L(G) \end{aligned}$$

## Jak gramatyka definiuje język?

### PRZYKŁAD:

Gramatyka  $G$ :

$$\begin{array}{lcl} E & \rightarrow & T \\ E & \rightarrow & E + T \\ T & \rightarrow & F \\ T & \rightarrow & T * F \\ F & \rightarrow & a \\ F & \rightarrow & ( E ) \end{array}$$

$$\begin{aligned} E &\Rightarrow T \Rightarrow F \Rightarrow ( E ) \Rightarrow ( E + T ) \Rightarrow ( T + T ) \\ &\Rightarrow ( F + T ) \Rightarrow ( a + T ) \Rightarrow ( a + F ) \\ &\Rightarrow ( a + a ) \in L(G) \end{aligned}$$

$$L(G) = \text{wyrażenia arytmetyczne zbudowane z } a, +, *, (, )$$