

# Grammatiche

- Grammatiche libere da contesto
- Grammatiche regolari
- Potenza delle grammatiche libere e regolari
- Struttura di frase: Alberi di derivazione

# Esempio dei numeri interi

- Si consideri il linguaggio per dei numeri interi, costituito cioè da tutte le sequenze di simboli che rappresentano numeri interi:

– es:       +38

             -567

             +456

             0

# Esempio di Grammatica

- Vediamo come può essere definita una grammatica per i numeri:

<{0,1,2,3,4,5,6,7,8,9,+,-},

{cifra, nat, int} ,

int,

{cifra ::= 0|1|2|3|4|5|6|7|8|9,

nat ::= cifra cifra\*,

int ::= (+|-) nat | nat}

>

Attenzione alla notazione

# Definizione di Grammatica

- Una grammatica è una quadrupla  $\langle \Lambda, V, s \in V, P \rangle$  dove:
  - $\Lambda$  = insieme finito di **terminali** (alfabeto)
  - $V$  = insieme finito di **non terminali** (categorie sintattiche o grammaticali)
  - $s$  = simbolo **iniziale** (categoria sintattica del linguaggio)
  - $P = \{i ::= e \mid i \in V, e \in E_{\Lambda \cup V}\}$  insieme finito di **produzioni**.  
Le produzioni hanno una parte sinistra ( $i$ ) e una parte destra separate da una freccia ( $\rightarrow$  oppure  $::=$ )
- Le grammatiche regolari hanno produzioni in cui a sinistra del  $::=$  c'è un simbolo non terminale a destra un'**espressione regolare** su  $\Lambda \cup V$ .

# Espressioni regolari

Espressioni regolari su un alfabeto  $A$ :  $E_A$

- $\varepsilon \in E_A$  ( $\varepsilon$  è un'espressione regolare)
- $\forall a \in A, a \in E_A$  ( $a$  è un'espressione regolare)
- $\forall e, e' \in E_A, ee' \in E_A$  (giustapposizione)
- $\forall e, e' \in E_A, e \mid e' \in E_A$  (alternativa)
- $\forall e \in E_A, [e] \in E_A$  (opzione)
- $\forall e \in E_A, e^* \in E_A$  (chiusura)



# Significato delle produzioni di una grammatica -continua

- Le produzioni di una grammatica permettono di derivare insiemi di sequenze di simboli terminali, definite dall'espressione a destra  $A=AUUV$ :

–  $\forall e \in E_A, [e] \in E_A \quad \mathbf{S}([e]) = \{\mathbf{S}(e)\} \cup \{\varepsilon\}$

–  $\forall e \in E_A, e^* \in E_A \quad \mathbf{S}(e^*) = \{\mathbf{S}(e)\}^* = \bigcup_{n \geq 0} \mathbf{S}(e)^n$

$$\mathbf{S}(e)^0 = \{\varepsilon\}, \mathbf{S}(e)^1 = \mathbf{S}(e),$$

$$\mathbf{S}(e)^2 = \mathbf{S}(ee)$$

$$\mathbf{S}(e)^n = \mathbf{S}(\underbrace{e \dots e}_{n \text{ volte}})$$

# Linguaggio di una grammatica

- Le sequenze che possono essere derivate da  $s$  (simbolo iniziale) costituiscono il linguaggio definito dalla grammatica.  $L(G) = \mathbf{S}(s)$
  - Esempio:
    - $G = \langle \{a,b\}, \{A,B,S\}, S, \{A ::= a|aa, B ::= bb, S ::= AB | BA$
- $L(G) = ?$

# L'operatore \*

- L'operatore interessante è \* (stella):
  - permette di derivare tutte le sequenze comunque lunghe di simboli della base
  - introduce insiemi infiniti
- $G = \langle \{a, b\}, \{A, S\}, S, \{A ::= aa^*, S ::= Ab \mid b^*\} \rangle$   
 $L(G) = ?$

# Osservazioni

- La semantica (S) definisce un metodo effettivo di calcolo del linguaggio.
  - generazione dell'insieme anche infinito
  - appartenenza di una sequenza?
    - quando termino? se termino
- Esercizi:
  - lettura di una grammatica
  - definizione di grammatiche.
  - sottolinguaggi (sottoinsiemi)

# Esempio dei numeri

- Si consideri il linguaggio per i numeri, costituito cioè da tutte le sequenze di simboli che rappresentano numeri, sia interi che frazionari, rappresentati in virgola fissa e anche in virgola mobile:

– es:        +38  
              -567  
              +456.34  
              -1239.02  
              +0.289E2

# Esempio di Grammatica

- Vediamo come può essere definita una grammatica per i numeri:

$\langle \{0,1,2,3,4,5,6,7,8,9,+,-,E,.\},$   
 $\{cifra, nat, int, fract, exp, num\},$   
 $num,$   
 $\{cifra ::= 0|1|2|3|4|5|6|7|8|9,$   
 $nat ::= cifra\ cifra^*,$   
 $int ::= ([+|-])\ nat,$   
 $fract ::= int.nat,$   
 $exp ::= fract\ E\ int,$   
 $num ::= nat\ | \ fract\ | \ exp \rangle$

# Esempio delle espressioni aritmetiche

- Ci sono molte grammatiche equivalenti per uno stesso linguaggio, ad esempio:

$\langle \{0,1,2,3,4,5,6,7,8,9,+,-,E,.. \},$

$\{\text{nat}, \text{int}, \text{fract}, \text{exp}, \text{num}\}$

$\text{num},$

$\{\text{nat} ::= (0|1|2|3|4|5|6|7|8|9) (0|1|2|3|4|5|6|7|8|9)^*,$

$\text{int} ::= (+|-) \text{nat}$

$\text{fract} ::= \text{int}.\text{nat},$

$\text{exp} ::= \text{fract } E \text{ int},$

$\text{num} ::= \text{nat} \mid \text{fract} \mid \text{exp} \rangle$

È stato eliminato il non terminale cifra con un peggioramento della leggibilità della grammatica

# Osservazioni

- Le grammatiche regolari possono sempre essere riscritte con un unico non terminale.
  - Definizione di S
  - Peggioramento della leggibilità della grammatica

# Grammatiche regolari

- Lo studio dei linguaggi e delle grammatiche è argomento di corsi più avanzati noi vediamo solo:
  - le grammatiche **Libere da Contesto** (LC) che ci permettono di definire la sintassi dei linguaggi di programmazione e
  - le **grammatiche regolari** incluse in quelle LC.
- Nelle grammatiche libere da contesto le produzioni possono avere a **sinistra della freccia solo un simbolo non terminale**. (Gli esempi visti rientrano tutti in questo caso).
- Le grammatiche regolari (GR) sono LC ed inoltre esiste un **ordinamento totale** sui non terminali tale che  $j > i$  se  $j$  compare a destra nella produzione di  $i$  cioè 
$$i ::= e \in P \Rightarrow e \in E_{\{j \in V \mid j > i\} \cup \Lambda}$$

# Potenza delle grammatiche

- Si consideri l'insieme di sequenze su  $\{a,b,c\}$  costituite da  $n$  occorrenze di 'a' seguite da altrettante occorrenze di 'b', cioè:

$$\{a^n c b^n \mid n \geq 0\}$$

- Si definisca una grammatica  $G$  tale che  $L(G) = \{a^n c b^n \mid n \geq 0\}$

# Grammatiche libere da contesto

- Le produzioni delle grammatiche LC sono così definite  $P = \{i ::= \alpha \mid i \in V, \alpha \in (\Lambda \cup V)^+\}$  senza nessuna restrizione sui non terminali a destra, come invece avveniva per le GR (ordinamento).
- L'alternatore ( $|$ ), la  $\square$  e l'operatore  $*$  non sono ammessi nelle produzioni. A destra c'è una concatenazione di simboli (terminali e non).
- Le produzioni possono essere ricorsive: Non è possibile definire un ordinamento su  $V$ .
- Si dimostra (non in questo corso) che le grammatiche LC includono le GR.

# Caratteristiche delle grammatiche LC

- La produzione

$$S := a S b \mid c$$

è una produzione corretta ma...

- Cosa significa?
  - Quale linguaggio denota  $L(S)$ ?
- Il significato delle produzioni e quindi il linguaggio definito dalla grammatica possono essere ottenuti con la relazione  $\rightarrow^*$ .

# Esempi di derivazioni

produzione

$S ::= aSb$

derivazioni

$S \rightarrow aSb$

$aSb \rightarrow aaSbb$

$aaSbb \rightarrow aaaSbbb$

e ancora...

produzione

$S ::= c$

derivazioni

$S \rightarrow c$

$aSb \rightarrow acb$

$aaSbb \rightarrow aacbb$

continua1

# Esempi di $\rightarrow^*$

$S ::= a S b$

$S ::= c$

$S \rightarrow^* S$

$S \rightarrow^* aSb$

$aSb \rightarrow^* aaaSbbb$

$S \rightarrow^* c$

$S \rightarrow^* acb$

$S \rightarrow^* aacbb$

$S \rightarrow^* aaacbbb$

Ottenuto per induzione sui passi di  $\rightarrow^*$

# Linguaggio definito da una grammatica G

Sia  $G = \langle \Lambda, V, S, P \rangle$ ,  $A \in V$

Definiamo linguaggio  $L(A)$  denotato in G da A:

$$L(A) = \{ \alpha \in \Lambda^* \mid A \rightarrow^* \alpha \}$$

Sia  $G = \langle \Lambda, V, S, P \rangle$ ,

Definiamo linguaggio  $L(G)$  denotato dalla grammatica

$$L(G) = L(s) = \{ \alpha \in \Lambda^* \mid s \rightarrow^* \alpha \}$$

**Esempio:**  $G = \langle \{a,b\}, \{S\}, S, \{S ::= a S b, S ::= \varepsilon\} \rangle$

allora  $L(G) = L(S) = \{a^n b^n \mid n \geq 0\}$

# Esempio delle espressioni aritmetiche

La seguente grammatica definisce il linguaggio delle espressioni aritmetiche:

$\langle \{0,1,2,3,4,5,6,7,8,9,*,+,-,/,(,)\}, \{Int,Op,Exp\}, Exp,$

$\{Int ::= 0|1|2|3|4|5|6|7|8|9,$

$Op ::= (+|-|*|/),$

$Exp ::= Int, Exp ::= Exp Op Exp, Exp ::= (Exp)\}, \rangle$

# Struttura delle frasi

- Ad esempio  $L(G)$  contiene:  $\{3+4*6, 78-34, \dots$   
ecc.}
- Le sequenze di simboli non rappresentano la **struttura della frase** che è invece espressa nella grammatica. Non c'è traccia in una sequenza di simboli di come sia stata derivata.
- Quali sono i modi per derivare una sequenza?
- Vediamo alcuni esempi di derivazioni diverse.

# Struttura delle frasi

- Ad esempio  $3+4*6$  potrebbe essere stata derivata:

$\text{Exp} \rightarrow \text{Exp Op Exp} \rightarrow \text{Int Op Exp} \rightarrow \text{Int Op Exp Op Exp} \rightarrow$   
 $3 \text{ Op Exp Op Exp} \rightarrow 3 + \text{Exp Op Exp} \rightarrow 3 + \text{Int Op Exp} \rightarrow$   
 $3 + 4 \text{ Op Exp} \rightarrow 3 + 4 * \text{Exp} \rightarrow 3 + 4 * \text{Int} \rightarrow 3 + 4 * 6$

oppure

$\text{Exp} \rightarrow \text{Exp Op Exp} \rightarrow \text{Exp Op Int} \rightarrow \text{Exp Op Exp Op Int} \rightarrow$   
 $\text{Int Op Exp Op Int} \rightarrow \text{Int Op Int Op Int} \rightarrow 3 \text{ Op Int Op Int} \rightarrow 3$   
 $+ \text{Int Op Int} \rightarrow 3 + 4 \text{ Op Int} \rightarrow 3 + 4 * \text{Int} \rightarrow 3 + 4 * 6$

# Definizione di grafo


- Un **grafo** è una coppia di insiemi  $\langle N_L, E \rangle$  dove  $N_L$  sono i nodi e  $E$  gli archi.
- I **nodi** hanno associata un'etichetta -  $L: N_L \rightarrow L(N_L)$  ( *$L$  è una funzione che dato un nodo mi calcola la sua etichetta*).
- Gli **archi** sono coppie  $\langle s, t \rangle$  o triple  $\langle s, t, c \rangle$  dove  $s$  e  $t$  sono nodi (di partenza e di arrivo se il grafo è orientato) mentre  $c$  è l'eventuale etichetta.

# Alberi

- Un albero è un grafo orientato in cui ogni nodo ha al più un arco entrante e non ci sono cicli.
- Esiste un unico nodo detto **radice** che non ha archi entranti.
- I nodi che non hanno archi uscenti sono detti **foglie**.
- I nodi  $B_1, B_2, \dots, B_k$  raggiunti da un arco uscente dal nodo A sono detti **figli** di A mentre A è detto **padre** di  $B_1, B_2, \dots, B_k$
- Si possono definire:
  - la **profondità** di un albero data dal cammino più lungo dalla radice ad una foglia.
  - **l'ampiezza** data dal massimo numero di archi uscenti da un nodo (ovvero dal numero massimo di figli per ogni nodo)

# Esempio

Gli alberi sono utilissimi per strutturare le informazioni. Nella sintassi servono per rappresentare la struttura della frase, che altrimenti si perde nella sequenza di simboli.



# Visita e frontiera di un albero

- La **visita** di un albero è un'operazione in cui si esaminano tutti i nodi dell'albero:
  - l'accesso è dalla radice scendendo sui figli
  - esistono vari tipi di visite (non le trattiamo) a seconda dell'ordine con cui si esaminano i nodi.
- La **frontiera** di un albero è costituita dai nodi foglia dell'albero.

# Alberi di derivazione sintattica parse tree

- Le produzioni di una grammatica possono essere utilizzate per costruire un albero, detto **albero di derivazione sintattica** (ADS), per rappresentare ogni frase del linguaggio.
- Sia  $G = \langle \Lambda, V, s, P \rangle$  e sia  $A = \langle N, E \rangle$  un ADS derivante da  $G$ . Valgono le seguenti proprietà:
  - $L(N) \subseteq \Lambda \cup V$  in particolare:
    - la radice ha etichetta  $s$
    - le foglie sono etichettate su  $\Lambda$
    - i nodi intermedi su  $V$
- Per ogni nodo non foglia  $n$  con etichetta  $a$ , lo indicheremo  $n_a$ , compresa la radice, se esiste un arco  $\langle n_a, n_b \rangle \Rightarrow$  esiste  $a ::= \gamma b \beta \in P$

# Costruzione degli ADS a partire da una grammatica $G$





- Sia  $G = \langle \Lambda, V, s, P \rangle$  una grammatica,
  1. si inizia costruendo un albero che ha un solo nodo etichettato con  $s$  cioè  $A = \langle N, E \rangle$  tali che  $N = \{n_s\}, E = \{\}$
  2. Finchè la frontiera di  $A$  contiene un simbolo non terminale  $a$  si sceglie una produzione  $a ::= x_1 \dots x_k \in P$ , (si noti che  $x_i \in \Lambda \cup V$ ) e si costruisce  $A' = \langle N', E' \rangle$  trasformando (**riscrivendo**)  $A$  nel seguente modo:
    - $N' = N \cup \{n_{x_i} \mid i \in [1, \dots, k]\}$
    - $E' = E \cup \{\langle n_a, n_{x_i} \rangle \mid i \in [1, \dots, k]\}$ .il nodo  $n_a$  che era una foglia in  $A$ , diviene in  $A'$  un nodo intermedio con  $k$  nodi figli,  $n_{x_i}$

# Produzioni come riscritture di alberi

- In sostanza si parte costruendo la radice e si espande l'albero sostituendo le foglie etichettate con simboli non terminali, con sottoalberi corrispondenti ad una produzione che abbia il simbolo non terminale a sinistra.
- Gli alberi che rappresentano frasi del linguaggio sono quelli che hanno sulla **frontiera solo simboli terminali**.
- La frase del linguaggio rappresentata da un albero si ottiene concatenando etichette della sua frontiera.

# Esempio


Exp



# Grammatiche ambigue

Una grammatica è ambigua se esiste più di un albero di derivazione sintattica con una stessa frontiera. Es: la grammatica delle espressioni aritmetiche definita precedentemente.

$3+4*6$  l'albero rappresenta  $3+(4*6)$



$3+4*6$ , l'albero rappresenta  $(3+4)*6$

