

# Alcune proprietà dei linguaggi context-free

## 1 Pumping lemma per i linguaggi context-free

Come per i linguaggi regolari, anche per quelli context-free esiste un **pumping lemma**, il quale può essere usato per dimostrare che determinati linguaggi non sono context-free.

*Teorema:* Sia  $L$  un linguaggio context-free. Esiste una costante  $n$  tale che, per ogni stringa  $z \in L$  con  $|z| \geq n$ , esiste una scomposizione  $z = uVwXy$  che soddisfa le seguenti proprietà:

1.  $|VwX| \leq n$ ;
2.  $VX \neq \epsilon$ , cioè almeno una tra le stringhe  $V$  e  $X$  deve contenere almeno un simbolo;
3. per ogni  $i \geq 0$ ,  $uV^i w X^i y \in L$ .

Siccome la scelta di  $n$  per un determinato linguaggio  $L$  non è univoca, per semplificare il discorso si chiamerà **costante di pumping**  $N$  o  $N_L$  la più piccola  $n$  per cui vale il lemma.

### 1.1 Esempio di applicazione

Dato il linguaggio

$$L = \{0^n 1^n 2^n \mid n \geq 1\} = \{012, 001122, 000111222, \dots\}$$

si dimostra che esso non è context-free usando il pumping lemma, seguendo lo stesso schema applicato nel caso dei linguaggi regolari.

Si suppone per assurdo che  $L$  sia context-free, e che  $N$  sia la relativa costante di pumping. Allora, si considera la stringa

$$z = 0^N 1^N 2^N = 0_1 \dots 0_N 1_1 \dots 1_N 2_1 \dots 2_N \in L$$

(qui le  $N$  occorrenze di ciascun simbolo  $a \in \{0, 1, 2\}$  sono state indiciate da  $a_1$  a  $a_N$ ). Siccome  $|z| = 3N > N$ , per il pumping lemma esiste una scomposizione  $z = uVwXy$  che dovrebbe verificare le proprietà (1)–(3) del lemma, ma assumendo le prime due si dimostra che la terza non può essere verificata.

Per la (1),  $|VwX| \leq N$ , la stringa  $VwX$  o non contiene 2

$$0_1 \dots \dots \overbrace{0_N 1_1 \dots \dots 1_N}^{VwX} 2_1 \dots \dots 2_N$$

oppure non contiene 0:

$$0_1 \dots \dots 0_N 1_1 \dots \dots \overbrace{1_N 2_1 \dots \dots 2_N}^{VwX}$$

Ora, per la (3) nel caso in cui  $i = 0$ , dovrebbe essere  $uV^0wX^0y = uv y \in L$ , ma:

- se  $VwX$  non contiene 2, allora per la proprietà (2),  $VX \neq \epsilon$ , in  $V$  o  $X$  deve essere presente almeno uno 0 oppure un 1, che in  $uV^0wX^0y$  viene eliminato, lasciando complessivamente almeno uno 0 o un 1 in meno rispetto al numero di 2, che rimane invariato;
- analogamente, se  $VwX$  non contiene 0, per la (2)  $VX$  deve contenere almeno un 1 o un 2, quindi  $uV^0wX^0y$  ha come minimo un 1 o un 2 in meno rispetto al numero di 0.

In entrambi i casi,  $uV^0wX^0y \notin L$ : questo contraddice il pumping lemma, portando a dedurre che  $L$  non è un linguaggio context-free.

## 1.2 Esempio di applicazione: numeri primi

Si consideri il linguaggio dei numeri primi in rappresentazione unaria,

$$L_{pr} = \{w \in \{1\}^* \mid |w| \text{ è un numero primo}\} = \{1^p \mid p \text{ è un numero primo}\}$$

che si è già dimostrato essere non regolare. Adesso, si vuole dimostrare che esso non è nemmeno context-free.

Per iniziare, si suppone per assurdo che  $L_{pr}$  sia context-free, e che  $N$  sia la relativa costante di pumping. Si sceglie poi un numero primo  $p \geq N + 2$  (che esiste sicuramente perché i numeri primi sono infiniti), e si considera la stringa  $z = 1^p \in L_{pr}$ . Siccome  $|z| = p > N$ , per il pumping lemma esiste una scomposizione  $z = uVwXy$  che dovrebbe soddisfare le proprietà (1)–(3), ma invece, assumendo la (1) e la (2), si dimostra che la (3) non può essere verificata.

Sia  $m = |VX|$ . Dalla (2),  $VX \neq \epsilon$ , si ha che  $m \geq 1$ , mentre dalla scelta di  $p \geq N + 2$  e dalla (1),  $|VwX| \geq N$ , si deduce che  $m \leq N \leq p - 2$ ; complessivamente:

$$1 \leq m \leq N \leq p - 2$$

Sapendo la lunghezza di  $VX$ , si ricava quella delle altre parti della stringa  $z = uVwXy$ ,

$$|uvw| = |uVwXy| - |VX| = |z| - |VX| = p - m$$

e da  $m \leq p - 2$  segue che

$$|uwy| = p - m \geq 2$$

Per la (3) del pumping lemma, con  $i = p - m$ , dovrebbe essere  $uV^{p-m}wX^{p-m}y \in L_{pr}$ . La lunghezza di questa stringa è

$$\begin{aligned} |uV^{p-m}wX^{p-m}y| &= |uvw| + |V^{p-m}X^{p-m}| \\ &= |uvw| + |(VX)^{p-m}| \\ &= |uvw| + |VX|(p - m) \\ &= (p - m) + m(p - m) \\ &= (p - m)(m + 1) \end{aligned}$$

cioè un numero che è il prodotto di due fattori interi, entrambi maggiori di 1:

- si è visto prima che  $p - m \geq 2 > 1$ ;
- si ha  $m + 1 > 1$  perché  $m \geq 1$ .

Allora,  $|uV^{p-m}wX^{p-m}y|$  è un numero composto, non primo, quindi per definizione  $uV^{p-m}wX^{p-m}y \notin L_{pr}$ , contrariamente al pumping lemma. Ciò è assurdo, dunque deve essere falsa l'assunzione iniziale che  $L_{pr}$  fosse un linguaggio context-free.

## 2 Proprietà di chiusura dei linguaggi context-free

*Teorema:* La classe dei linguaggi liberi dal contesto è chiusa rispetto alle seguenti operazioni:

- unione (se  $L_1$  e  $L_2$  sono CFL, anche  $L_1 \cup L_2$  è un CFL);
- concatenazione ( $L_1L_2$ );
- chiusura di Kleene ( $L^*$ ) e chiusura positiva ( $L^+$ );
- inversione ( $L^R = \{w^R \mid w \in L\}$ ).

Invece, a differenza dei linguaggi regolari, i linguaggi context-free *non* sono chiusi rispetto all'operazione di intersezione: se  $L_1$  e  $L_2$  sono CFL, non è garantito che anche  $L_1 \cap L_2$  sia un CFL. Ad esempio:

- Il linguaggio  $L_1 = \{0^n1^n2^i \mid n \geq 1, i \geq 1\}$  comprende le stringhe formate da un certo numero di 0, seguiti dallo stesso numero di 1 e poi da un numero qualsiasi di 2. Esso è un CFL in quanto si può dimostrare che è generato da una grammatica con le regole di produzione

$$\begin{aligned} S &\rightarrow AB \\ A &\rightarrow 0A1 \mid 01 \\ B &\rightarrow 2B \mid 2 \end{aligned}$$

dove  $S$  è il simbolo iniziale.

- Il linguaggio  $L_2 = \{0^i 1^n 2^n \mid n \geq 1, i \geq 1\}$  comprende le stringhe formate da un numero qualsiasi di 0, seguiti da un determinato numero di 1 e dallo stesso numero di 2. In pratica, questo linguaggio è ottenuto da  $L_1$  scambiando i ruoli di 0 e 2. Anch'esso è un CFL, in quanto generato dalla seguente grammatica:

$$\begin{aligned} S &\rightarrow AB \\ A &\rightarrow 0A \mid 0 \\ B &\rightarrow 1B2 \mid 12 \end{aligned}$$

L'intersezione di questi due linguaggi contiene le stringhe che hanno lo stesso numero di 0, 1 e 2,

$$L_1 \cap L_2 = \{0^n 1^n 2^n \mid n \geq 1\}$$

ma si è dimostrato prima che tale linguaggio non è context-free.