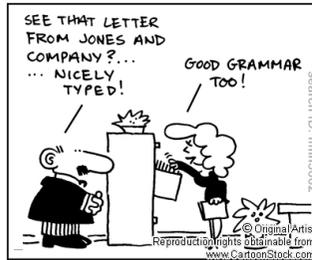


4 – Grammaires régulières



1

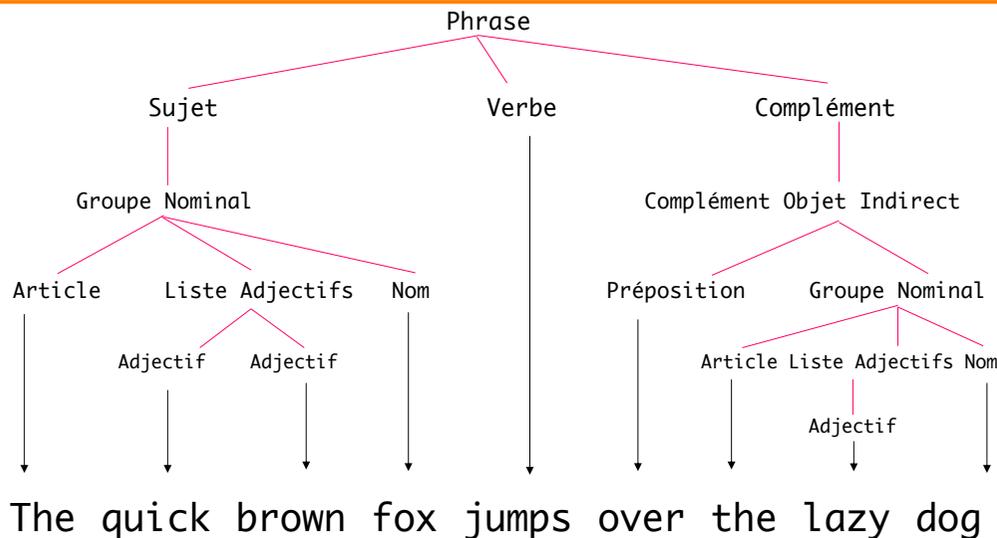
Origine

- dans les années 50 : tentatives de formalisation des langues naturelles
- but : décrire précisément les règles permettant de construire des phrases syntaxiquement correctes d'une langue
- semi-échec de la linguistique mais réussite totale pour des langues bien plus simples :

les langages informatiques !

2

Exemple



3

Réécriture

- mécanisme qui permet d'engendrer des familles d'objets (figures géométriques, étiquettes de graphes, polyominos, mots, fractales ...)
- on dispose d'un objet initial : l'axiome A
- ainsi que de règles de réécriture i.e. un ensemble d'éléments du type $\alpha \rightarrow \beta$ (lire : l'objet α se réécrit en celui β)
- elle s'appuie sur une relation de dérivation binaire transitive notée \Rightarrow^* et définie par :
 - si $\alpha \rightarrow \beta$ alors $\alpha \Rightarrow \beta$
 - si $\alpha \rightarrow \beta$ et si en remplaçant dans γ l'objet α par celui β on obtient δ alors $\gamma \Rightarrow \delta$
 - \Rightarrow^* est la fermeture transitive de \Rightarrow
- l'ensemble engendré est : $\{\varphi, A \Rightarrow^* \varphi\}$

4

Application : image de synthèse



5

Exemple

Une seule règle de réécriture :
(F signifie « flèche »)

$F \rightarrow F + F - F - FF + F + F - F$

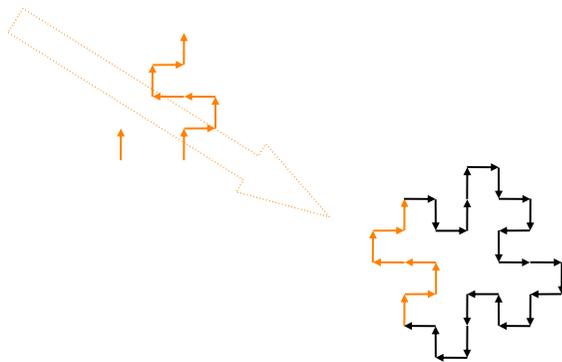
(+ signifie que l'on tourne à droite
- signifie que l'on tourne à gauche)



6

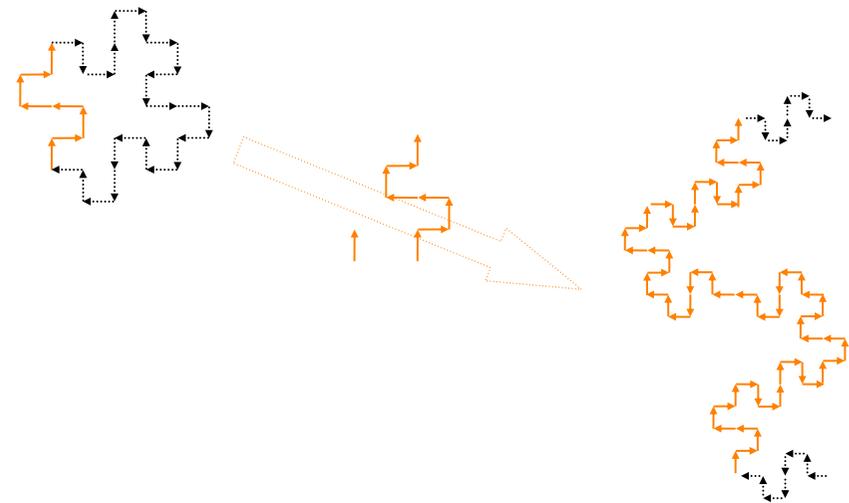
Une étape de réécriture

$F + F + F + F$



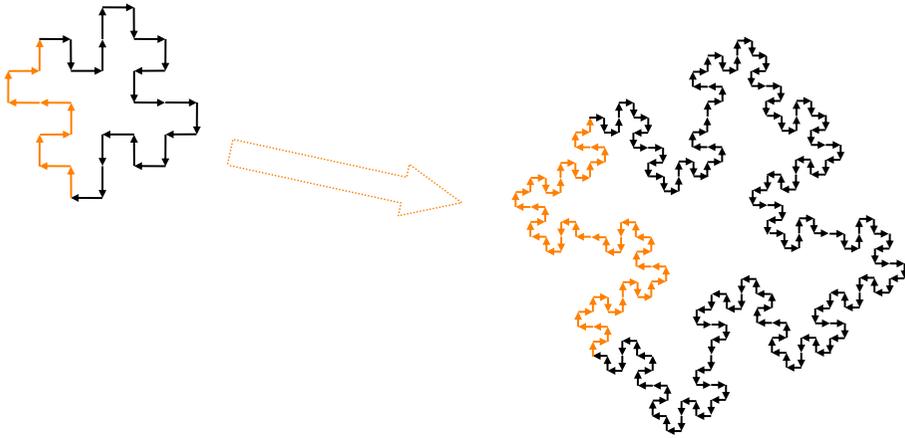
7

Début de l'étape 2



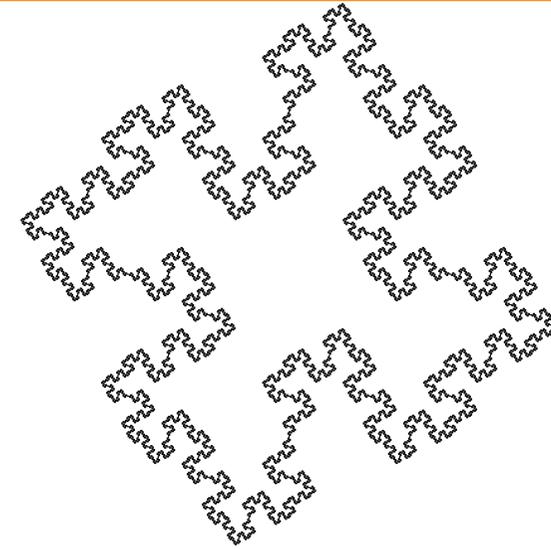
8

2^e étape entière



9

Avec la tortue de Python



10

Génération de langages

- un **automate fini accepte** les mots d'un langage rationnel
on dit que le langage rationnel est **reconnu** par cet automate
un automate est donc un **système de reconnaissance**
- une **expression régulière décrit** un langage rationnel,
c'est un formalisme pour leur éviter la notation ensembliste
- mais comment **énumérer** les mots d'un langage rationnel ?
dès lors qu'il est infini, *a priori* c'est impossible ...

Problème comment **engendrer** de façon automatique
tous les mots d'un langage rationnel* donné ?

- si le langage est fini, on les énumère tous
- s'il est infini, on veut énumérer des mots de longueur arbitrairement grande

*rationnel, juste pour commencer ...

11

Grammaire

- Une **grammaire G** est un quadruplet (N, T, P, A) où :
 - N est un ensemble fini de symboles **non-terminaux**
 - T est l'alphabet de symboles **terminaux**
 - P est un ensemble fini de **productions** (ou de règles)
 $\{ \varphi \rightarrow \psi, \varphi \in (N \cup T)^+, \psi \in (N \cup T)^* \}$
 - A est l'**axiome**
- **Propriétés**
 - le vocabulaire est $V = N \cup T$
 - $N \cap T = \emptyset$
 - (P, A) est un système de réécriture.
- Le **langage engendré** par la grammaire G est
 - $L(G) = \{ \varphi \in T^*, A \Rightarrow^* \varphi \}$
 - $L(G)$: ensemble des mots sur T **dérivant** de l'axiome A.

12

Exemples

• $G = (N, T, P, A)$ avec :

- $N = \{A, B\}$ ensemble des non-terminaux
- $T = \{a, b\}$ ensemble des terminaux
- $P = \{ \begin{array}{l} A \rightarrow a A \\ A \rightarrow b B \\ B \rightarrow b B \\ B \rightarrow \varepsilon \end{array} \}$
- A est l'axiome

☞ $L(G)$ est décrit par a^*b^+

• $G' = (N', T', P', A)$ avec :

- $N' = \{A\}$, axiome A
- $T' = \{0, 1\}$
- $P' = \{ \begin{array}{l} A \rightarrow 0 A 1 \\ A \rightarrow \varepsilon \end{array} \}$

☞ $L(G') = \{0^n 1^n, n \geq 0\}$ (non-rationnel)

ATTENTION
à ne pas inventer une
expression régulière
pour un langage
non rationnel ...

13

Arbre de dérivation

Soit $G = (N, T, P, A)$ une grammaire avec des productions avec *un seul non-terminal par partie gauche*.



- un **arbre de dérivation** pour un mot w engendré par G est un arbre dont :

- la **racine** est étiquetée par l'**axiome** A
- les **feuilles** sont étiquetées par des éléments de $T \cup \{\varepsilon\}$

- les **nœuds internes** le sont par des éléments de N
- un nœud interne étiqueté B a des fils étiquetés de gauche à droite $\alpha_1, \alpha_2, \dots, \alpha_n$, s'il existe dans P une production :

$$B \rightarrow \alpha_1 \alpha_2 \dots \alpha_n$$

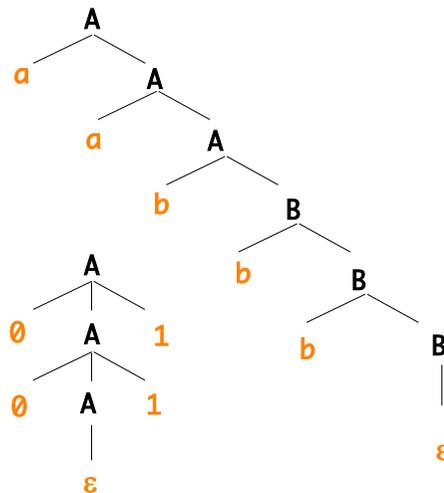
- w est formé de la concaténation des feuilles lues dans un **parcours en profondeur** de l'arbre.

14

Exemples

• $G = (N, T, P, A)$ avec :

- $N = \{A, B\}$
- $T = \{a, b\}$
- $P = \{ \begin{array}{l} A \rightarrow a A \mid b B \\ B \rightarrow b B \mid \varepsilon \end{array} \}$



• $G' = (N', T', P', A)$ avec :

- $N' = \{A\}$
- $T' = \{0, 1\}$
- $P' = \{A \rightarrow 0 A 1 \mid A \rightarrow \varepsilon\}$

Le symbole $|$ permet juste de regrouper les parties droites d'une même partie gauche.

15

Grammaires régulières*

- Une grammaire (N, T, P, A) est **régulière à droite** si les productions de P sont de la forme

$$\begin{array}{l} B \rightarrow a C \\ \text{ou} \quad B \rightarrow a \\ \text{ou} \quad B \rightarrow \varepsilon \end{array}$$

avec $B \in N, C \in N$ et $a \in T$

- Une grammaire (N, T, P, A) est **régulière à gauche** si les productions de P sont de la forme :

$$\begin{array}{l} B \rightarrow C a \\ \text{ou} \quad B \rightarrow a \\ \text{ou} \quad B \rightarrow \varepsilon \end{array}$$

avec $B \in N, C \in N$ et $a \in T$

il existe un algorithme
pour passer d'une grammaire
régulière à gauche à une
grammaire régulière à droite
engendrant le même langage
(cf. TD 4)

Théorème un langage L est **rationnel** si et seulement si il existe une **grammaire régulière** qui engendre les mots de L .

* aussi dites grammaires **linéaires**.

16

Exemple & contre-exemple

- $G = (N, T, P, A)$ est régulière à droite :

$$P = \left\{ \begin{array}{l} A \rightarrow a A \mid b B \\ B \rightarrow b B \mid \varepsilon \end{array} \right\}$$

- $L(G)$ est décrit par l'expression régulière : a^*b^+

- $G' = (N', T', P', A)$ n'est pas une grammaire régulière :

$$P' = \left\{ \begin{array}{l} A \rightarrow \emptyset B \mid \varepsilon \\ B \rightarrow A 1 \end{array} \right\}$$

$$L(G') = \{ \emptyset^n 1^n, n \geq 0 \}$$

Un langage non-rationnel ne peut pas être engendré par une grammaire régulière.

Ainsi, une grammaire obtenue en panachant les productions d'une grammaire régulière à gauche et celle d'une grammaire régulière à droite n'est généralement pas une grammaire régulière.

17

A.F.D. → grammaire régulière *

Le théorème précédent se prouve à l'aide d'une double construction.

Premier sens :

- soit un automate fini déterministe donné :

$$A = (\Sigma, Q, \delta, q_0, F)$$

- construisons $G = (N, T, P, A)$ une grammaire régulière pour $L(A)$:
 - l'ensemble des non-terminaux N est celui des états Q de A **
 - l'ensemble des terminaux T égale Σ
 - l'axiome A de G correspond à l'état q_0
 - pour tout (q, σ, q') de δ il crée la production $q \rightarrow \sigma q'$ dans P **
 - pour tout f de F , il crée la production $f \rightarrow \varepsilon$ dans P **

* on pourrait aussi partir d'un A.F.N.

** à un renommage près.

18

Exemple

$$A = (\Sigma, Q, \delta, A, F)$$

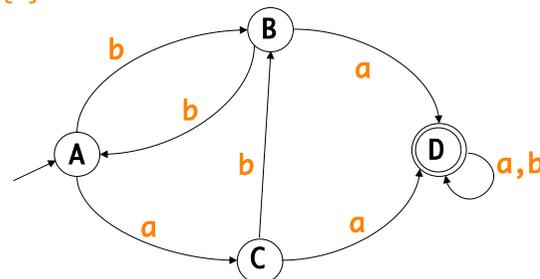
$$\Sigma = \{a, b\}, Q = \{A, B, C, D\}, F = \{D\}$$

$$G = (N, T, P, A)$$

$$N = \{A, B, C, D\}$$

$$T = \{a, b\}$$

$$P = \left\{ \begin{array}{l} A \rightarrow a C \\ A \rightarrow b B \\ B \rightarrow a D \\ B \rightarrow b A \\ C \rightarrow a D \\ C \rightarrow b B \\ D \rightarrow a D \\ D \rightarrow b D \\ D \rightarrow \varepsilon \end{array} \right\}$$



$$L(G) = L(A)$$

19

Grammaire régulière → A.F.N.

Construction réciproque :

- soit $G = (N, T, P, A)$ une grammaire régulière à droite construisons un automate fini A qui accepte $L(G)$:

$$A = (\Sigma, Q, \delta, q_0, F)$$

- on ajoute un nouveau non-terminal X pour les productions $B \rightarrow \alpha$ et on les remplace par $B \rightarrow \alpha X$ et $X \rightarrow \varepsilon$
- les états de Q correspondent aux non-terminaux $N \cup \{X\}$ *
- l'alphabet Σ coïncide avec l'ensemble T des terminaux
- l'état q_0 correspond à l'axiome A de la grammaire
- pour toute production $B \rightarrow \alpha C$ de P , on crée (B, α, C) * dans δ
- pour toute production $B \rightarrow \varepsilon$, l'état correspondant à B est final dans A .

* à un renommage près.

20

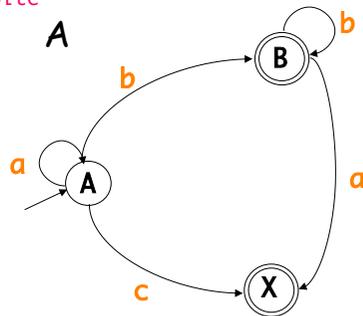
Exemple

$G = (N, T, P, A)$ une grammaire régulière à droite

$N = \{A, B\}$

$T = \{a, b, c\}$

$P = \left\{ \begin{array}{l} A \rightarrow a A \\ A \rightarrow b B \\ A \rightarrow c \quad (\text{devient } A \rightarrow c X \text{ et } X \rightarrow \varepsilon) \\ B \rightarrow b B \\ B \rightarrow a \quad (\text{devient } B \rightarrow a X) \\ B \rightarrow \varepsilon \end{array} \right\}$



$A = (\Sigma, Q, \delta, A, F)$

$\Sigma = \{a, b, c\}$

$Q = \{A, B, X\}$

$F = \{B, X\}$

$L(G) = L(A)$

$E : a^* b^+ (\varepsilon + a) + a^* c$