4 – Grammaires régulières

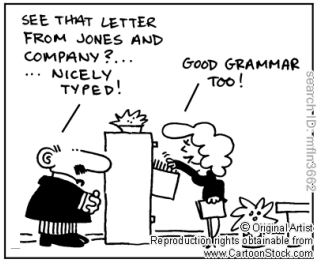

Origine

- 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 !

Exemple

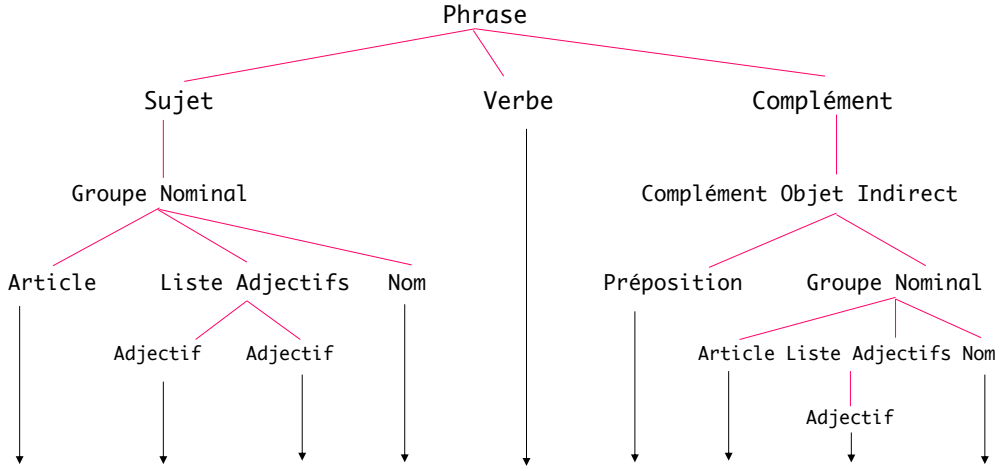

Réécriture

- 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 : $\{\varphi\ ,\ A \Rightarrow^* \varphi\}$

Application : image de synthèse

Exemple

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

F → F + F - F - FF + F + F - F

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

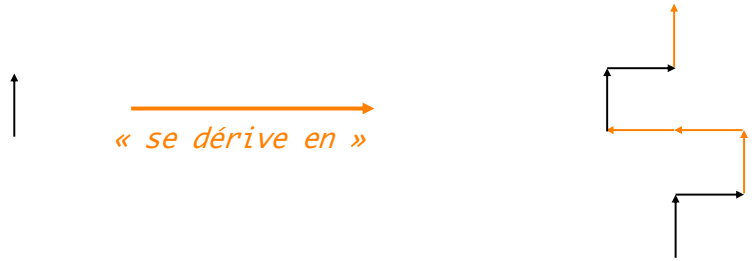

Une étape de réécriture

F + F + F + F

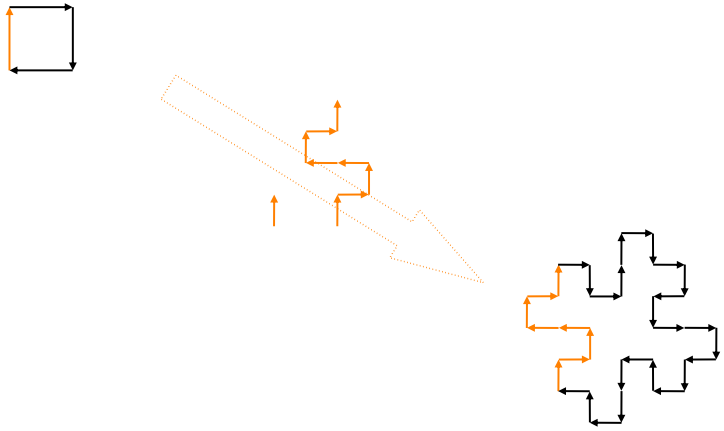

Début de l'étape 2

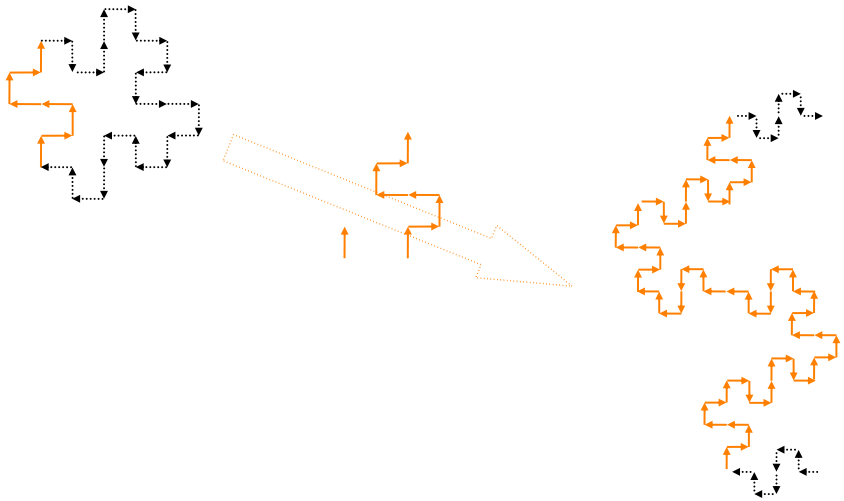

2e étape entière

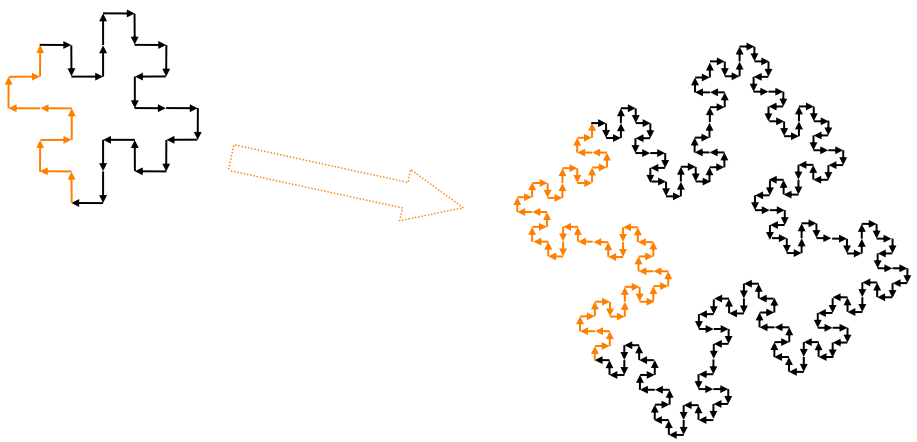

Avec la tortue de Python

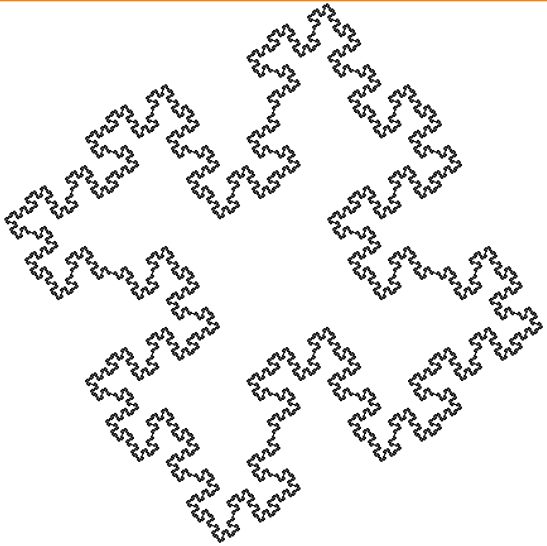

Génération de langages

- 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 ...

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 $V = N \cup T$
  - $N \cap T = \varnothing$
  - (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

Exemples

- G = (N,T,P,A) avec :
  - N = {A, B} ensemble des non-terminaux
  - T = {a, b} ensemble des terminaux
  - P = { A → a A
    A → b B
    B → b B
    B → ε }
  - 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' = { A → 0 A 1
    A → ε }

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

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

Arbre de dérivation

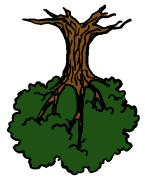

Soit G = (N,T,P,A) une grammaire avec des productions avec *un seul non-terminal par partie gauche.*

- 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 $\alpha_1, \alpha_2, \ldots \alpha_n$, s'il existe dans P une production :
    $B \rightarrow \alpha_1 \alpha_2 \ldots \alpha_n$
  - w est formé de la concaténation des feuilles lues dans un parcours en profondeur de l'arbre.

Exemples

- G = (N,T,P,A) avec :
  - N = { A, B }
  - T = { a, b }
  - P ={ A → a A | b B
    B → b B | ε }

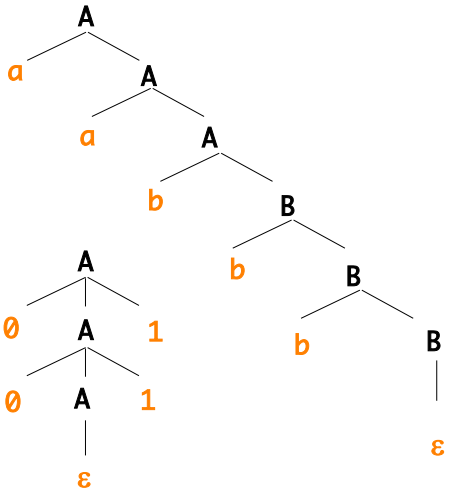

- G' = (N',T',P',A) avec :
  - N' = { A }
  - T' = { 0, 1 }
  - P' = { A → 0 A 1 | A → ε }

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

Grammaires régulières*

- Une grammaire (N,T,P,A) est régulière *à droite* si les productions de P sont de la forme
  $B \rightarrow a\ C$
  ou $B \rightarrow a$
  ou $B \rightarrow \varepsilon$
  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 :
  $B \rightarrow C\ a$
  ou $B \rightarrow a$
  ou $B \rightarrow \varepsilon$
  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.

Exemple & contre-exemple

- G = (N,T,P,A) est régulière à droite :
  - P = { A → a A | b B
    B → b B | ε }
  - L(G) est décrit par l'expression régulière : $a^* b^+$
- G' = (N',T',P',A) n'est pas une grammaire régulière :
  - P' = { A → 0 B | ε
    B → A 1 }
  - L(G') = { $0^n 1^n$, $n \geq 0$ }

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.

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 → σ q' dans P **
  - pour tout f de F, il crée la production f → ε dans P **

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

Exemple

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

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

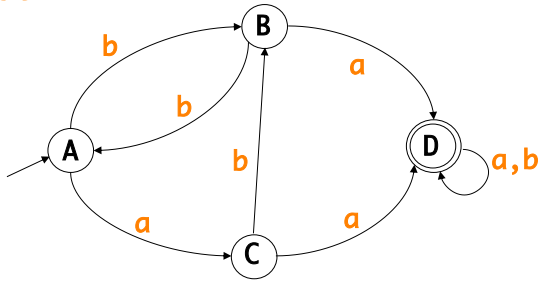

L(G) = L(A)

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 = { A → a C
A → b B
B → a D
B → b A
C → a D
C → b B
D → a D
D → b D
D → ε }

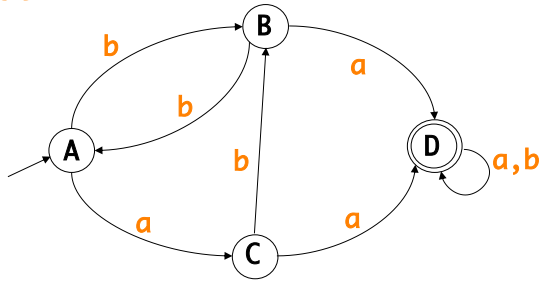

L(G) = L(A)

Grammaire régulière → A.F.N.

Construction réciproque :

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

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

- on ajoute un nouveau non-terminal X pour les productions $B \to \alpha$ et on les remplace par $B \to \alpha\ X$ et $X \to \varepsilon$
- 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 $B \to \alpha\ C$ de P, on crée (B,α,C) * dans δ
- pour toute production $B \to \varepsilon$, l'état correspondant à B est final dans $\mathcal{A}$.

* à un renommage près.

Exemple

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

$N = \{A,B\}$
$T = \{a,b,c\}$
$P = \{$ $A \to a\ A$
$A \to b\ B$
$A \to c$ (devient $A \to c\ X$ et $X \to \varepsilon$)
$B \to b\ B$
$B \to a$ (devient $B \to a\ X$)
$B \to \varepsilon$ $\}$

$\mathcal{A} = (\Sigma, Q, \delta, A, F)$

$\Sigma = \{a,b,c\}$
$Q = \{A,B,X\}$
$F = \{B,X\}$

Exemple

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

$N = \{A,B\}$
$T = \{a,b,c\}$
$P = \{$ $A \to a\ A$
$A \to b\ B$
$A \to c$ (devient $A \to c\ X$ et $X \to \varepsilon$)
$B \to b\ B$
$B \to a$ (devient $B \to a\ X$)
$B \to \varepsilon$ $\}$

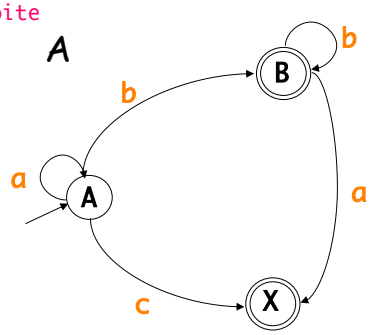

$\mathcal{A} = (\Sigma, Q, \delta, A, F)$

$\Sigma = \{a,b,c\}$
$Q = \{A,B,X\}$
$F = \{B,X\}$

$L(G) = L(\mathcal{A})$

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