

# Arbres et discontinuité

## 1 Introduction

## 2 Les arbres

### 2.1 Définition à base de graphes

#### 2.1.1 Graphes

Un graphe est donné par un couple  $\langle X, \Gamma \rangle$  où  $X$  est un ensemble et  $\Gamma$  une application de  $X$  dans  $\mathcal{P}(X)$ .

Tout élément  $x$  de  $X$  est un *sommet* du graphe (ou *noeud*).

$\Gamma(x)$  est l'ensemble des *successeurs* ou des *fil*s ou des *descendants immédiats* de  $x$ .

Deux sommets  $x$  et  $y$  qui sont tels que  $y$  appartient à  $\Gamma(x)$  forment un *arc*;  $x$  est l'*origine* de l'arc,  $y$  en est l'*extrémité*.

$\Gamma^*(x)$  est l'ensemble des *descendants* de  $x$  : il comprend  $x$ , les fils de  $x$ , les fils des fils de  $x$ , etc. :

(i)  $x \in \Gamma^*(x)$

(ii)  $y \in \Gamma(x)$  et  $z \in \Gamma^*(y) \Rightarrow z \in \Gamma^*(x)$

### 2.1.2 Chaînes, cycles

Une *chaîne* est constituée par une suite  $\langle x_1, x_2, \dots, x_q, x_{q+1} \rangle$  de sommets du graphe vérifiant:

$$\forall i \leq q \quad x_i \in \Gamma(x_{i+1}) \text{ ou } x_{i+1} \in \Gamma(x_i)$$

$x_1$  et  $x_{q+1}$  sont alors les deux extrémités de la chaîne.

Un *cycle* est constitué par une chaîne dont les deux extrémités coïncident.

Un graphe est *connexe* si et seulement si pour tout  $x$  et pour tout  $y$  de  $X$  ( $x$  et  $y$  étant distincts) il existe une chaîne admettant pour extrémités  $x$  et  $y$ .

### 2.1.3 Graphes étiquetés

Dans un graphe, tous les sommets sont différents. On peut affecter des *étiquettes*, prises dans un ensemble  $E$ , aux sommets.

Un graphe est à ce moment-là défini par  $\langle X, \Gamma, L \rangle$  où  $L$  est une application de  $X$  dans l'ensemble  $E$ .

Les arcs peuvent aussi être étiquetés.

#### 2.1.4 Première définition des arbres

Un arbre est un graphe connexe et sans cycles.

Attention, cette définition n'est pas celle que l'on prend en général en linguistique (ou en informatique): elle ne suppose pas l'existence d'une racine unique.

#### 2.1.5 Deuxième définition

Une *arborescence* est un arbre  $A = \langle X, \Gamma \rangle$  qui comporte un sommet  $a$  tel que tout sommet  $x \in X$  est un descendant de  $a$ .

Ce sont les arborescences que l'on appelle généralement arbres.

### 2.1.6 Définitions et propriétés

Etant donné un arbre  $A = \langle X, \Gamma \rangle$ ,  $\Gamma(x)$  est l'ensemble des *filles* du sommet  $x$ .

Un sommet est le successeur (ou le fils) au maximum d'un autre sommet.

Il n'y a qu'un sommet qui n'est fils d'aucun autre sommet: la *racine* de l'arbre.

Une *feuille* est un sommet qui n'a aucun fils.

Si  $y \in \Gamma^*(x)$ , on dit que  $x$  *domine*  $y$ .

### 2.1.7 Arbres ordonnés

$A = \langle X, \delta \rangle$  est un *arbre ordonné* à condition que  $\delta$  soit une application de  $X$  dans  $X^*$  telle que, pour tout  $x$ , si  $\delta(x) = x_1x_2 \dots x_p$ , tous les  $x_i$  sont différents et si  $\Delta(x)$  est l'ensemble composé de tous les  $x_i$ , alors  $\langle X, \Delta \rangle$  vérifie les propriétés des arborescences.

On peut définir sur un arbre ordonné  $A = \langle X, \delta \rangle$  un *ordre de précedence* (ordre strict partiel), de la manière suivante:

- (i) si  $\delta(x) = x_1x_2 \dots x_p$  et  $i < j$  alors  $x_i$  précède  $x_j$
- (ii) si  $u$  précède  $v$ ,  $u$  domine  $x$  et  $v$  domine  $y$ , alors  $x$  précède  $y$

L'ensemble des feuilles d'un arbre ordonné est totalement ordonné par la relation de précedence. On peut par conséquent écrire:

$$\text{feuilles}(A) = z_1z_2 \dots z_n$$

## 2.2 Définition alternative des arbres ordonnés étiquetés (Wall, 1972)

Un arbre est un quadruplet  $A = \langle X, L, D, P \rangle$  où  $X$  est un ensemble,  $L$  une application de  $X$  dans un ensemble  $Cat$ ,  $D$  est une relation d'ordre partiel sur  $X$  (relation de domination) et  $P$  est une relation d'ordre strict partiel sur  $X$  (relation de précédence). Il faut que les trois conditions suivantes (racine unique, exclusivité et non-croisement) soient vérifiées :

$$(i) \exists x \in X \forall y \in X \langle x, y \rangle \in D$$

$$(ii) \forall x, y \in X \langle x, y \rangle \in P \text{ ou } \langle y, x \rangle \in P \Leftrightarrow \langle x, y \rangle \notin D \text{ et } \langle y, x \rangle \notin D$$

$$(iii) \forall w, x, y, z \in X$$

$$\langle w, x \rangle \in P \text{ et } \langle w, y \rangle \in D \text{ et } \langle x, z \rangle \in D \Rightarrow \langle y, z \rangle \in P$$

### 2.2.1 Représentation d'un énoncé par un arbre

On considère un ensemble  $W$ , l'ensemble des formes lexicales, et on suppose qu'il existe une application:

$$cat : W \rightarrow \mathcal{P}(Cat)$$

où  $Cat$  est un ensemble de catégories.

Soit  $A$  un arbre tel que  $feuilles(A) = z_1 z_2 \dots z_n$  et soit  $w_1 w_2 \dots w_n \in W^*$  un énoncé. Cet énoncé sera représenté par l'arbre  $A$  si et seulement si:

$$\forall i \in \{1, \dots, n\} \quad L(z_i) \in cat(w_i)$$

## 2.3 Arbres et grammaires

### 2.3.1 Définition des grammaires indépendantes du contexte

Une grammaire *indépendante du contexte* (ou “context free”, ou CF) est décrite par un 4-uple  $G = \langle V_T, V_N, S, \mathcal{R} \rangle$  où  $V_T$  est un vocabulaire *terminal* (ou alphabet),  $V_N$  est un vocabulaire auxiliaire (ou vocabulaire *non terminal*) disjoint de  $V_T$ ,  $S$  est un élément particulier de  $V_N$ , appelé *axiome* de la grammaire, et  $\mathcal{R}$  est un ensemble de *règles* (de réécriture) qui ont la forme suivante:

$$A \rightarrow \beta$$

$A$  étant un élément de  $V_N$  et  $\beta$  étant un élément de  $(V_N \cup V_T)^*$ .

Dans une règle telle que  $A \rightarrow \beta$ ,  $A$  est la *partie gauche* et  $\beta$  est la *partie droite*.

### 2.3.2 Décomposition d'un arbre en arbres élémentaires

Etant donné un arbre ordonné étiqueté  $\langle X, \delta, L \rangle$ , pour chaque sommet  $x \in X$  qui n'est pas une feuille, on définit l'*arbre élémentaire* de racine  $x$   $A[x] = \{X_x, \delta_x, L_x\}$  où :

$$X_x = \{x\} \cup \Delta(x)$$

$$\delta_x(x) = \delta(x)$$

$$\forall y \in \Delta(x) \quad \delta_x(y) = \varepsilon$$

$$\forall y \in X_x \quad L_x(y) = L(y)$$

### 2.3.3 Arbres élémentaires et règles de grammaires

On considère à présent des arbres dont les sommets sont étiquetés par des valeurs prises dans  $V_N \cup V_T$ .

Etant donnée une grammaire CF  $G = \langle V_T, V_N, S, \mathcal{R} \rangle$ , on dira qu'un arbre élémentaire  $A[x] = \{X_x, \delta_x, L_x\}$  tel que  $\delta(x) = x_1 \dots x_n$  est compatible avec la grammaire si et seulement si

$$L(x) \rightarrow L(x_1) \dots L(x_n)$$

est une règle de la grammaire.

On dira qu'un arbre  $A$  est compatible avec la grammaire, ou qu'il est *admissible* relativement à la grammaire, si et seulement si, pour tous les sommets  $x$  qui ne sont pas des feuilles,  $A[x]$  est compatible avec la grammaire.

## **2.4 Les représentations en machine des arbres**

### **2.4.1 Représentation par des tableaux à deux dimensions**

1°/ Le tableau des fils de chaque sommet.

2°/ Les relations de dominance et de précédence.

### **2.4.2 Représentation par le tableau des fils aînés et le tableau des frères cadets**

### **2.4.3 Représentation dans des tableaux aux dimensions variables**

### **2.4.4 Représentations dans les langages de manipulation de symboles**

## **2.5 Arbres et structures parenthésées**