

# Automates d'arbres

[http://list.mpri.master.univ-paris7.fr/wws/info/  
cours-1-18](http://list.mpri.master.univ-paris7.fr/wws/info/cours-1-18)  
[cours-1-18@mpri.master.univ-paris7.fr](mailto:cours-1-18@mpri.master.univ-paris7.fr)

Cours: Florent Jacquemard  
TD: Ștefan Ciobâcă

INRIA Saclay & LSV (CNRS-ENS Cachan)

[florent.jacquemard@inria.fr](mailto:florent.jacquemard@inria.fr)  
[ciobaca@lsv.ens-cachan.fr](mailto:ciobaca@lsv.ens-cachan.fr)

15 janvier 2010

Arbres finis orientés **non**-ordonnés étiquetés  
par des symboles de fonction sans arité

Unranked unordered labeled trees

Presburger Automata (PA)

- ▶ previous lecture : unranked ordered trees
  - ▶ XML documents
  - ▶ hedge automata (HA),  $\text{MSO}(\rightarrow, \downarrow)$ .
  - ▶ cf. TATA chap. 8.
- ▶ this lecture : unranked **unordered** trees
  - ▶ web data
  - ▶ Presburger automata (PA), PMSO.
  - ▶ cf. article "Numerical Document Queries",  
Helmut Seidl, Thomas Schwentick, Anca Muscholl, 2003.

# Unranked Unordered Trees

- ▶  $\Sigma$  is a finite alphabet.

$$\begin{aligned}\text{tree} &:= a(\text{multiset}) \quad (a \in \Sigma) \\ \text{multiset} &:= \{\text{tree}, \dots, \text{tree}\}\end{aligned}$$

- ▶  $a(\{t_1, \dots, t_n\})$  is denoted  $a(t_1, \dots, t_n)$ .
- ▶  $\text{rem}$  : the multiset can be empty.  $a(\emptyset)$  is denoted  $a$ .
- ▶ The set of unranked unordered trees over  $\Sigma$  is denoted  $\mathcal{U}_2(\Sigma)$ .

## Exemples de langages de $\mathcal{U}_2(\Sigma)$

- ▶  $\Sigma = \{a, b\}$ .
- ▶ termes de  $\mathcal{U}_2(\Sigma)$ 
  - ▶ de hauteur 1,
  - ▶ avec un  $b$  à la racine,
  - ▶ des feuilles qui sont  $a$  ou  $b$  :
    - i.* avec un nombre pair de  $a$  (HA),
    - ii.* avec le même nombre pair de  $a$  que de  $b$  ( $\neg$  HA).

# Arithmétique de Presburger

Formules de Presburger :

$$\begin{array}{l} \text{term} ::= \\ \quad \left| \begin{array}{l} x \text{ (variable du premier ordre)} \\ n \text{ (entier naturel)} \\ \text{term} + \text{term} \end{array} \right. \\ \\ \text{form} ::= \\ \quad \left| \begin{array}{l} \text{term} = \text{term} \\ \neg \text{form} \mid \text{form} \vee \text{form} \mid \text{form} \wedge \text{form} \\ \forall x \text{ form} \mid \exists x \text{ form} \end{array} \right. \end{array}$$

Interprétation dans le domaine des entiers naturels.

$(n_1, \dots, n_p) \models \phi(x_1, \dots, x_p)$  ( $x_1, \dots, x_p$  variables libres)

ssi  $\phi(n_1, \dots, n_p)$  s'évalue à *vrai*.

# Arithmétique de Presburger

- ▶ notation : termes  $nx$  pour  $\underbrace{x + \dots + x}_n$ ,
- ▶ les entiers peuvent être limités à 0 et 1,
- ▶ les atomes peuvent être limités à  $x = n$  et  $x = y + z$ .

Exemples :

- ▶  $x \leq y \equiv \exists x' y = x + x'$ .
- ▶  $odd(x) \equiv \exists y x = y + y + 1$ .

# Arithmétique de Presburger

## Theorem : Arithmétique de Presburger

L'arithmétique de Presburger est décidable en espace doublement exponentiel.

- ▶ Borne inférieure 2-EXPTIME, sup. 3-EXPTIME.
- ▶ NP-complet pour le fragment existentiel.

# Arithmétique de Presburger


Décidabilité de l'arithmétique de Presburger.

On peut associer à une formule  $\phi(x_1, \dots, x_p)$  un automate fini sur l'alphabet  $\{0, 1\}^p$  reconnaissant l'ensemble des  $\langle b_{1,1}, \dots, b_{p,1} \rangle \dots \langle b_{1,k}, \dots, b_{p,k} \rangle$  tels que  $b_{1,1} \dots b_{1,k}, \dots, b_{p,1} \dots b_{p,k}$  sont les représentations en binaire d'entiers  $n_1, \dots, n_p$  satisfaisant  $\phi$ .

Donc on peut décider si il existe  $n_1, \dots, n_p$  tels que  $(n_1, \dots, n_p) \models \phi(x_1, \dots, x_p)$ .

# Arithmétique de Presburger et automates

automate fini pour  $x_1 + x_2 = x_3$



# Ensemble semi-linéaires

## Definition :

- ▶ Un ensemble *linéaire* est un sous ensemble de  $\mathbb{N}^p$  de la forme  $\{\overline{v}_0 + \overline{v}_1 + \dots + \overline{v}_m \mid m \geq 0, \overline{v}_1, \dots, \overline{v}_m \in B\}$ , pour  $\overline{v}_0 \in \mathbb{N}^p$  et  $B \subset \mathbb{N}^p$  fini donnés.
- ▶ Un ensemble *semi-linéaire* est une union finie d'ensembles linéaires.

modèles de formules Presburger  $\equiv$  semi-linéaires.

## Projection et théorème de Parikh

$$\Sigma = \{a_1, \dots, a_p\}.$$

### Definition : Projection de Parikh

La projection de Parikh d'un mot  $w \in \Sigma^*$  est le tuple  $\#(w) := (m_1, \dots, m_p)$  où  $m_i$  ( $i \leq p$ ) est le nombre d'occurrences de  $a_i$  dans  $w$ .

Pour un ensemble  $L \subseteq \Sigma^*$ , on note  $\#(L) := \{\#(w) \mid w \in L\}$ .

### Theorem :

Pour tout langage  $L \subseteq \Sigma^*$  context-free, il existe une formule de Presburger  $\phi(x_1, \dots, x_p)$  telle que  $\#(L) := \{(n_1, \dots, n_p) \models \phi(x_1, \dots, x_p)\}$ .

Quand  $L$  est régulier, la formule de Presburger est calculée en temps linéaire (dans la taille du NFA définissant  $L$ ).

Inversement, étant donnée une formule de Presburger  $\phi(x_1, \dots, x_p)$ , on peut construire un NFA  $\mathcal{A}$  tel que  $\#(L(\mathcal{A})) = \{(n_1, \dots, n_k) \models \phi(x_1, \dots, x_k)\}$ .

# Automates de Presburger (PA)

## Definition : Automates de Presburger

Un *automate de Presburger* (PA) sur un alphabet  $\Sigma$  est un tuple  $\mathcal{A} = (\Sigma, Q, Q^f, \Delta)$  où  $Q = \{q_1, \dots, q_p\}$  est un ensemble fini d'états,  $Q^f \subseteq Q$  est le sous-ensemble des états finaux et  $\Delta$  est un ensemble de règles de transition de la forme :  $a(\phi) \rightarrow q$  avec  $a \in \Sigma$ ,  $q \in Q$ , et  $\phi = \phi(x_1, \dots, x_p)$  est une formule de Presburger avec une variable libre pour chaque état.

Le langage du  $\mathcal{A}$  dans l'état  $q \in Q$ , noté  $L(\mathcal{A}, q)$ , est le plus petit sous-ensemble de  $\mathcal{U}_2(\Sigma)$  de termes  $a(t_1, \dots, t_n) \in \mathcal{U}_2(\Sigma)$  tels que

- ▶ il existe  $i_1, \dots, i_n \leq p$  tels que pour tout  $j \leq n$ ,  
 $t_j \in L(\mathcal{A}, q_{i_j})$ ,
- ▶ il existe une transition  $a(\phi) \rightarrow q \in \Delta$  telle que  
 $\#(q_{i_1}, \dots, q_{i_n}) \models \phi(x_1, \dots, x_p)$ .

Le langage de  $\mathcal{A}$  est  $L(\mathcal{A}) = \bigcup_{q \in Q^f} L(\mathcal{A}, q)$ .

## PA : exemple 1

$$\Sigma = \{a, b, f\}.$$

Ensemble des arbres de  $\mathcal{U}_2(\Sigma)$  où tous les  $a$  et  $b$  étiquettent des feuilles :

$$\mathcal{A} = (\{q\}, \{q\}, \{a(x_q = 0) \rightarrow q, b(x_q = 0) \rightarrow q, f(true) \rightarrow q\})$$

## PA : exemple 2

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

Ensemble des arbres de  $\mathcal{U}_2(\Sigma)$  avec le même nombre de  $a$  et de  $b$  sous chaque noeud.

$$\mathcal{A} = (\{q_a, q_b, q\}, \{q_a, q_b, q\}, \{a(\phi) \rightarrow q_a, b(\phi) \rightarrow q_b, c(\phi) \rightarrow q\})$$

avec  $\phi \equiv x_{q_a} = x_{q_b}$ .

## PA : exemple 3

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

Ensemble des arbres de  $\mathcal{U}_2(\Sigma)$  dont tout noeud interne est étiqueté par  $a$  et tout noeud étiqueté par  $a$  a au moins autant de fils sans  $b$  que de fils contenant  $b$ .

$$Q = Q_f = \{q_a, q_b\}.$$

L'état  $q_b$  accepte les arbres contenant un  $b$  et  $q_a$  les autres.

$$\Delta = \left\{ \begin{array}{ll} a(x_{q_a} \geq x_{q_b} = 0) \rightarrow q_a & a(x_{q_a} \geq x_{q_b} > 0) \rightarrow q_b \\ b(x_{q_a} = x_{q_b} = 0) \rightarrow q_b & \end{array} \right\}$$

# Automates de Presburger normalisés

## Definition :

Un PA  $\mathcal{A} = (\Sigma, Q, Q^f, \Delta)$  sur  $\Sigma$  est dit *normalisé* si pour tous  $a \in \Sigma$  et  $q \in Q$ , il y a au plus une transition de la forme  $a(\phi) \rightarrow q$  dans  $\Delta$ .

Quand  $\mathcal{A}$  est normalisé, on note  $a(\phi_{a,q}) \rightarrow q$  l'unique transition avec  $a$  et  $q$ .

## Proposition :

Pour tout PA  $\mathcal{A}$ , il existe un PA normalisé  $\mathcal{A}_n$  reconnaissant le même langage.

La taille de  $\mathcal{A}_n$  est linéaire dans la taille de  $\mathcal{A}$ .

# Automates de Presburger complets et déterministes

## Definition : PA déterministes

Un PA  $\mathcal{A} = (\Sigma, Q, Q^f, \Delta)$  sur  $\Sigma$  est *déterministe* si pour tout  $a \in \Sigma$  et tous  $q_{i_1}, \dots, q_{i_n} \in Q^*$ , si  $a(\phi) \rightarrow q \in \Delta$  et  $a(\phi') \rightarrow q' \in \Delta$  sont telles que  $\#(q_{i_1}, \dots, q_{i_n}) \models \phi$  et  $\#(q_{i_1}, \dots, q_{i_n}) \models \phi'$ , alors  $q = q'$ .

## Lemma :

Le déterminisme de PA est décidable.

## Definition : PA complets

Un PA  $\mathcal{A} = (\Sigma, Q, Q^f, \Delta)$  sur  $\Sigma$  est *complet* si pour tout  $a \in \Sigma$  et tous  $q_{i_1}, \dots, q_{i_n} \in Q^*$  il existe au moins une transition  $a(\phi) \rightarrow q \in \Delta$  telle que  $\#(q_{i_1}, \dots, q_{i_n}) \models \phi$ .

# Complétion de PA

## Proposition : Complétion

Pour tout PA  $\mathcal{A}$ , il existe un PA complet  $\mathcal{A}_c$  reconnaissant le même langage.

La taille de  $\mathcal{A}_c$  est linéaire dans la taille de  $\mathcal{A}$ .

**pr.:** Soit  $\mathcal{A} = (Q, Q_f, \Delta)$  un PA supposé normalisé.

On ajoute l'état  $q_\perp$  :  $\mathcal{A}_c = (Q \cup \{q_\perp\}, Q_f, \Delta_c)$  avec

$$\begin{aligned} \Delta_c &:= a(\phi_{a,q} \wedge x_{q_\perp} = 0) \rightarrow q \text{ t.q. } a(\phi_{a,q}) \rightarrow q \in \Delta \\ &\cup a\left(\bigwedge_{q \in Q} \neg \phi_{a,q} \vee x_{q_\perp} > 0\right) \rightarrow q_\perp \end{aligned}$$

# Détermination de PA

## Proposition : Détermination

Pour tout PA  $\mathcal{A}$ , il existe un PA déterministe  $\mathcal{A}_d$  reconnaissant le même langage.

La taille de  $\mathcal{A}_d$  est exponentielle dans la taille de  $\mathcal{A}$  (borne inférieure).

**pr.:** Soit  $\mathcal{A} = (Q, Q_f, \Delta)$ , normalisé avec  $Q = \{q_1, \dots, q_b\}$ .

$$\mathcal{A}_d = (2^Q, \{S \subseteq Q \mid S \cap Q_f \neq \emptyset\}, \Delta_d)$$

Formules de Presburger dans  $\Delta_d$  : une variable libre  $x_S$  pour chaque  $S \subseteq Q$ .

## $\varepsilon$ -transitions et élimination

Remark :

PA avec transitions  $q \rightarrow q' \equiv$  PA.

# PA : opérations Booléennes

## Proposition :

La classe des langages de PA est fermée par union, intersection et complément.

- ∪ union disjointe (linéaire) ou produit (quadratique, préserve déterminisme).
- ∩ loi de De Morgan ou produit (quadratique).
- ¬ complète, détermine, inverse états finaux (exponentiel).

# PA : décision de l'appartenance

Proposition :  $\in$

Le problème de l'appartenance est décidable pour les PA.

- ▶ en temps polynomial pour les DPA,
- ▶ NP-complet pour les NPA.

## PA : décision du vide

Proposition :  $\emptyset$

Le problème du vide est décidable en temps polynomial pour les PA.

pr.: marquage d'états, construction de  $M_i \subseteq Q$ .

▶ initialement,  $M_0 = \emptyset$ .

▶ à chaque étape, si pour  $q \in Q \setminus M_i$ ,  $\bigwedge_{p \in Q \setminus M_i} x_p = 0 \wedge \bigvee_{a \in \Sigma} \phi_{a,q}$

est satisfiable, alors  $M_{i+1} := M_i \cup \{q\}$ .

## PA : décision de l'inclusion, équivalence

Proposition :  $\subseteq, \equiv$

Les problèmes de l'inclusion et équivalence sont décidables pour les PA.

**pr.:**  $L(\mathcal{A}_1) \subseteq L(\mathcal{A}_2)$  ssi  $L(\mathcal{A}_1) \cap (\mathcal{U}_2(\Sigma) \setminus L(\mathcal{A}_2)) = \emptyset$ .

## Correspondance entre PA, HA et AC-TA

Il y a correspondance entre :

- ▶ les langages de PA
- ▶ les langages de CF-HA dont les langages (CF) de transitions sont clos par permutation
- ▶ la classe des clôtures de langages d'arbres réguliers modulo AC

## Rappel : CF-HA

### Definition : CF-HA

CF-HA : tuple  $(\Sigma, Q, Q_f, \Delta)$  comme un HA dont les transitions sont de la forme  $a(L) \rightarrow q$  avec  $a \in \Sigma$ ,  $q \in Q$ , et  $L \subseteq Q^*$  est hors contexte (*context-free*).

## Langages réguliers modulo AC (AC-TA)

Signature  $\Sigma = \Sigma_{\emptyset} \uplus \{a\}$ .

Le symbole  $a$  est binaires et suit les axiomes d'associativité et commutativité :

$$a(x_1, a(x_2, x_3)) = a(a(x_1, x_2), x_3) \quad (\text{A})$$

$$a(x_1, x_2) = a(x_2, x_1) \quad (\text{C})$$

Pour un TA  $\mathcal{B}$  sur  $\Sigma$ , on note

$\text{AC}(L(\mathcal{B})) := \{t \in \mathcal{T}(\Sigma) \mid t =_{\text{AC}} s \in L(\mathcal{B})\}$  (langage d'AC-TA)

Proposition :

- ▶ la classe des langages d'arbres réguliers est strictement incluse dans la classe des langages d'AC-TA.
- ▶ La classe des langages d'AC-TA est close par opérations Booléennes.

## Correspondences $\mathcal{T}(\Sigma) \leftrightarrow \mathcal{U}_2(\Sigma)$

On suppose  $\Sigma_{AC} = \{a\}$ .

$$\text{flat} : \mathcal{T}(\Sigma) \rightarrow \mathcal{U}_2(\Sigma)$$

$$\text{hflat} : \mathcal{T}(\Sigma)^* \rightarrow \mathcal{H}(\Sigma)$$

$$\text{flat}^{-1} : \mathcal{U}_2(\Sigma) \rightarrow \mathcal{T}(\Sigma)$$

Définitions ( $g \in \Sigma_n \setminus \{a\}$ ) :

$$\text{flat}(g(t_1, \dots, t_n)) = g(\text{flat}(t_1) \dots \text{flat}(t_n))$$

$$\text{flat}(a(t_1, t_2)) = a(\text{hflat}(t_1 t_2))$$

$$\text{hflat}(g(s_1, \dots, s_n) t_2 \dots t_m) = \text{flat}(g(s_1, \dots, s_n)) \text{hflat}(t_2 \dots t_m)$$

$$\text{hflat}(a(s_1, s_2) t_2 \dots t_m) = \text{hflat}(s_1 s_2 t_2 \dots t_m)$$

$$\text{flat}^{-1}(g(t_1 \dots t_n)) = g(\text{flat}^{-1}(t_1), \dots, \text{flat}^{-1}(t_n))$$

$$\text{flat}^{-1}(a(t_1 \dots t_m)) = a(t_1, a(t_2, \dots, a(t_{m-1}, t_m)))$$

$$(m \geq 2)$$

**Logique monadique faible du second ordre**

**PMSO**

# Logique monadique du second ordre de Presburger

Syntaxe des formules de PMSO.

- ▶ variables du premier ordre  $x \dots$
- ▶ variables du second ordre  $X \dots$
- ▶

$$\begin{array}{l} \text{form} ::= \\ \text{pres} ::= \\ \text{term} ::= \end{array} \left| \begin{array}{l} x = y \mid x \downarrow y \mid a(x) \mid x \in X \mid x/\text{pres} \quad (a \in \Sigma) \\ \text{form} \wedge \text{form} \mid \text{form} \vee \text{form} \mid \neg \text{form} \\ \exists x \text{ form} \mid \exists X \text{ form} \mid \forall x \text{ form} \mid \forall X \text{ form} \\ \text{term} = \text{term} \\ \neg \text{pres} \mid \text{pres} \vee \text{pres} \mid \text{pres} \wedge \text{pres} \\ \forall z \text{ pres} \mid \exists z \text{ pres} \\ z \quad (\text{variable enti\`ere du premier ordre}) \\ n \quad (\text{entier naturel}) \\ [X] \quad (X \text{ var. du second ordre}) \\ \text{term} + \text{term} \end{array} \right.$$

formules pres telles que les variables  $z$  sont li es.

rem. pas d'atomes  $x \rightarrow y$  comme pour les arbres ordonn es.

# Logique monadique du second ordre de Presburger

## Sémantique de PMSO.

- ▶ domaine : ensemble  $\|t\|$  des sommets d'un arbre  $t \in \mathcal{U}_2(\Sigma)$ ,
- ▶  $\sigma$  : variables du premier ordre  $\rightarrow \|t\|$ ,
- ▶  $\rho$  : variables du second ordre  $\rightarrow 2^{\|t\|}$ ,
- ▶  $t, \sigma, \rho \models x = y$  ssi  $\sigma(x)$  identique à  $\sigma(y)$ ,
- ▶  $t, \sigma, \rho \models x \downarrow y$  ssi  $\sigma(x)$  est le père de  $\sigma(y)$  dans  $t$ ,
- ▶  $t, \sigma, \rho \models a(x)$  ssi  $\sigma(x)$  étiqueté par  $a$  dans  $t$ ,
- ▶  $t, \sigma, \rho \models x \in X$  ssi  $\sigma(x) \in \rho(X)$ ,
- ▶  $t, \sigma, \rho \models x/\phi$  ssi  $(n_1, \dots, n_p) \models \phi$  où  $n_i$  est le nombre de fils (dans  $t$ ) de  $\sigma(x)$  dans  $\rho(X_i)$  (avec  $\text{dom}(\rho) = \{X_1, \dots, X_p\}$ ),
- ▶  $t, \sigma, \rho \models \psi_1 \vee \psi_2$  ssi  $t, \sigma, \rho \models \psi_1$  ou  $t, \sigma, \rho \models \psi_2$ ,
- ▶  $t, \sigma, \rho \models \psi_1 \wedge \psi_2$  ssi  $t, \sigma, \rho \models \psi_1$  et  $t, \sigma, \rho \models \psi_2$ ,
- ▶  $t, \sigma, \rho \models \neg\psi$  ssi  $t, \sigma \not\models \psi$ ,
- ▶  $t, \sigma, \rho \models \exists x \psi$  ssi il existe  $p \in \|t\|$  t.q.  $t, \sigma \cup \{p \rightarrow x\}, \rho \models \psi$ ,
- ▶  $t, \sigma, \rho \models \exists X \psi$  ssi il existe  $P \subseteq \|t\|$  t.q.  
 $t, \sigma, \rho \cup \{P \rightarrow X\} \models \psi$ ,

## PMSO : exemples

- ▶ racine :

$$x = \varepsilon \equiv \neg \exists y y \downarrow x$$

- ▶ feuille :

$$\text{leaf}(x) \equiv \neg \exists y x \downarrow y$$

- ▶  $x \downarrow y \equiv \exists Y Y = \{y\} \wedge x/[Y]=1$

- ▶ ordre préfixe = clôture transitive de  $\downarrow$  :

$$x \downarrow^* y \equiv \forall X (x \in X \wedge \forall z \forall z' (z \in X \wedge z \downarrow z' \Rightarrow z' \in X)) \Rightarrow y \in X$$

# langages de PMSO

## Definition : langage

Le langage défini formule close  $\psi$  de PMSO sur  $\Sigma$  est l'ensemble des termes  $t \in \mathcal{U}_2(\Sigma)$  t.q.  $t \models \psi$ .

## langage de PMSO : exemple 1

L'ensemble des arbres de la forme  $f(a, \dots, a, b, \dots, b)$  avec le même nombre de  $a$  que de  $b$ .

$$\begin{aligned} \exists X_a \exists X_b f(\varepsilon) \quad & \wedge \forall y (y \in X_a \Leftrightarrow a(y)) \wedge (y \in X_b \Leftrightarrow b(y)) \\ & \wedge \forall y \varepsilon \downarrow y \Rightarrow (\text{leaf}(y) \wedge (y \in X_a \vee y \in X_b)) \\ & \wedge \varepsilon / [X_a]=[X_b] \end{aligned}$$

## PMSO : PA exemple 2

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

Ensemble des arbres de  $\mathcal{U}_2(\Sigma)$  dont tout noeud interne est étiqueté par  $a$  et tout noeud étiqueté par  $a$  a au moins autant de fils sans  $b$  que de fils contenant  $b$ .

$$\begin{aligned} \exists X_a \exists X_b \forall x & \quad (b(x) \Rightarrow \text{leaf}(x)) \\ & \wedge (a(x) \wedge x/[X_a] \geq [X_b] > 0 \Rightarrow x \in X_b) \\ & \wedge (a(x) \wedge x/[X_a] \geq [X_b] = 0 \Rightarrow x \in X_a) \\ & \wedge (b(x) \wedge x/[X_a] = [X_b] = 0 \Rightarrow x \in X_b) \end{aligned}$$

$$Q = Q_f = \{q_a, q_b\}.$$

L'état  $q_b$  accepte les arbres contenant un  $b$  et  $q_a$  les autres.

$$\Delta = \left\{ \begin{array}{ll} a(x_{q_a} \geq x_{q_b} = 0) \rightarrow q_a & a(x_{q_a} \geq x_{q_b} > 0) \rightarrow q_b \\ & b(x_{q_a} = x_{q_b} = 0) \rightarrow q_b \end{array} \right\}$$

## PMSO : exemples de requetes

Base de clients d'un vendeur de musique en ligne, stockée dans un arbre d'arité variable non-ordonné.

Un client est un sous-arbre :

- ▶ racine étiquetée par `client`
- ▶ informations dans les fils (achats, étiquetés en tête par le genre).

Requete pour clients  $x$  qui ont acheté plus de jazz que de blues :

$$\begin{aligned} query_1(x) \equiv & (\exists X_{\text{jazz}} \forall y y \in X_{\text{jazz}} \Leftrightarrow \text{jazz}(y)) \\ & \wedge (\exists X_{\text{blues}} \forall y y \in X_{\text{blues}} \Leftrightarrow \text{blues}(y)) \\ & \wedge \text{client}(x) \wedge x/[X_{\text{jazz}}] > [X_{\text{blues}}] \end{aligned}$$

Requete pour clients  $x$  ayant acheté plus de jazz que n'importe quel autre genre :

$$\begin{aligned} query_1(x) \equiv & (\exists X_{\text{jazz}} \forall y y \in X_{\text{jazz}} \Leftrightarrow \text{jazz}(y)) \\ & \wedge (\exists X_{\text{other}} \forall y y \in X_{\text{other}} \Leftrightarrow \neg \text{jazz}(y)) \\ & \wedge \text{client}(x) \wedge x/[X_{\text{jazz}}] > [X_{\text{other}}] \end{aligned}$$

## Theorem

$L \subseteq \mathcal{U}(\Sigma)$  est définissable en PMSO ssi  $L$  est un langage de PA.

Contraintes de Presburger et  
arbres finis orientés **ordonnés** étiquetés par  
des symboles de fonction sans arité

Presburger Hedge Automata (PHA)

# Automates d'Hedges et Presburger (PHA)

## Definition : Automates d'Hedges et Presburger

Un *automate d'Hedges et Presburger* (PHA) sur un alphabet  $\Sigma$  est un tuple  $\mathcal{A} = (\Sigma, Q, Q^f, \Delta)$  où  $Q = \{q_1, \dots, q_p\}$  est un ensemble fini d'états,  $Q^f \subseteq Q$  est le sous-ensemble des états finaux et  $\Delta$  est un ensemble de règles de transition de la forme :  $a(\bigvee_i (L_i \wedge \phi_i)) \rightarrow q$  avec  $a \in \Sigma$ ,  $q \in Q$ ,  $L_i \subseteq Q^*$  langage régulier et  $\phi_i = \phi(x_1, \dots, x_p)$  est une formule de Presburger avec une variable libre p. ch. état.

Pour  $w \in Q^*$  on définit  $w \models L_i \wedge \phi_i$  par  $w \in L_i$  et  $\#(w) \models \phi_i$ .

## PHA : langages

Le langage  $L(\mathcal{A}, q)$  de  $\mathcal{A}$  dans l'état  $q \in Q$ , est le plus petit ensemble d'arbres d'arité variable **ordonnés**  $a(t_1, \dots, t_n) \in \mathcal{U}(\Sigma)$  t.q.

- ▶ il existe  $i_1, \dots, i_n \leq p$  tels que pour tout  $j \leq n$ ,  
 $t_j \in L(\mathcal{A}, q_{i_j})$ ,
- ▶ il existe une transition  $a(\bigvee_i (L_i \wedge \phi_i)) \rightarrow q \in \Delta$  telle que  
 $q_{i_1} \dots q_{i_n} \models \bigvee_i (L_i \wedge \phi_i)$ , i.e. il existe  $i$  t.q.
  - ▶  $q_{i_1} \dots q_{i_n} \in L_i$ ,
  - ▶  $\#(q_{i_1} \dots q_{i_n}) \models \phi_i(x_1, \dots, x_p)$ .

Le langage de  $\mathcal{A}$  est  $L(\mathcal{A}) = \bigcup_{q \in Q_f} L(\mathcal{A}, q)$ .

# PHA : propriétés

## Proposition :

- ▶ La classe des langages de PHA est fermée par union et intersection,
- ▶ La classe des langages de PHA n'est pas fermée par complémentaire.
  
- ▶  $\cup, \cap$  : produit
- ▶ csq problème de l'universalité.

## Proposition :

$DPHA \neq NPHA$ .

# PHA : problèmes de décision

Proposition :  $\in$

L'appartenance est décidable en PTIME pour PHA.

Lemma :

Étant donné  $Q$ ,  $p = |Q|$ ,  $M \subseteq Q$ , et une contrainte  $L \wedge \phi$  où  $L \subseteq Q^*$  est régulier et  $\phi = \phi(x_1, \dots, x_p)$  est une formule de Presburger, il est décidable si il existe  $w \in M^* \cap L$  tel que  $\#(w) \models \phi$ .

Proposition :  $\emptyset$

Le vide est décidable pour PHA.

Proposition :  $\forall$

L'universalité est indécidable pour PHA.

## PHA : logique

### Theorem :

Un ensemble d'arbres de  $\mathcal{U}(\Sigma)$  est reconnaissable par un PHA ssi il est défini par une formule de PMSO de la form  $\exists X_1 \dots \exists X_k \phi$  où  $\phi$  est du premier ordre.

### Corollary :

- ▶ EPMSO (fragment existentiel) est décidable dans  $\mathcal{U}(\Sigma)$ .
- ▶ PMSO est indécidable dans  $\mathcal{U}(\Sigma)$ .

**Arbres finis orientés mixtes**  
(ordonnés et non ordonnés)  
étiquetés par des  
symboles de fonction sans arité

# Mixed Trees

- ▶  $\Sigma = \Sigma_A \cup \Sigma_{AC}$ .

tree :=  $a(\text{hedge}) \mid c(\text{multiset})$  ( $a \in \Sigma_A, c \in \Sigma_{AC}$ )  
hedge := tree, ..., tree  
multiset := {tree, ..., tree}

- ▶  $c(\{t_1, \dots, t_n\})$  is denoted  $c(t_1, \dots, t_n)$ .
- ▶ The set of mixed unranked trees over  $\Sigma$  is denoted  $\mathcal{M}(\Sigma)$ .

# Presburger m-Tree Automata (PMA)

## Definition : Presburger m-Tree Automata

A *Presburger m-Tree Automaton* (PMA) over an alphabet  $\Sigma = \Sigma_A \cup \Sigma_{AC}$  is a tuple  $\mathcal{A} = (\Sigma, Q, Q^f, \Delta)$  where  $Q = \{q_1, \dots, q_p\}$  is a finite set of *states*,  $Q^f \subseteq Q$  is the subset of final states and  $\Delta$  is a set of transition rules of the form :

- ▶  $a(L) \rightarrow q$  with  $a \in \Sigma_A$ ,  $q \in Q$ ,  $L \subseteq Q^*$  is a regular language  
or
- ▶  $c(\phi) \rightarrow q$  with  $c \in \Sigma$ ,  $q \in Q$ ,  $\phi = \phi(x_1, \dots, x_p)$  is a Presburger formula with one free variable for each state.

## PMA : languages

The language  $L(\mathcal{A}, q)$  of the PMA  $\mathcal{A}$  in state  $q \in Q$ , is the smallest set of mixed trees

- ▶  $a(t_1, \dots, t_n)$ ,  $a \in \Sigma_A$ , such that
  - ▶ there exists  $i_1, \dots, i_n \leq p$  with  $t_j \in L(\mathcal{A}, q_{i_j})$  for all  $j \leq n$ ,
  - ▶ there exists a transition  $a(L) \rightarrow q \in \Delta$  such that  $q_{i_1} \dots q_{i_n} \in L$ ,
- ▶ or  $c(t_1, \dots, t_n)$ ,  $c \in \Sigma_{AC}$ , such that
  - ▶ there exists  $i_1, \dots, i_n \leq p$  with  $t_j \in L(\mathcal{A}, q_{i_j})$  for all  $j \leq n$ ,
  - ▶ there exists a transition  $c(\phi) \rightarrow q \in \Delta$  such that  $\#(q_{i_1} \dots q_{i_n}) \models \phi(x_1, \dots, x_p)$ .

The language of  $\mathcal{A}$  is  $L(\mathcal{A}) = \bigcup_{q \in Q_f} L(\mathcal{A}, q)$ .

## PMA : properties

Proposition :

The class of PMA languages is closed under all Boolean operations.

Proposition :

$DPMA \equiv NPMA$ .

## PMA : decision problems

Proposition :  $\in$

Membership is decidable for PMA.

Proposition :  $\emptyset$

Emptiness is decidable for PMA.

Consequences of the same results for PHA ( $\text{PMA} \subseteq \text{PHA}$ ).

## PMA : logique

Theorem :

The class of languages of  $\mathcal{M}(\Sigma)$  definable by formulae de PMSO is the class of PMA languages.

Corollary

*PMSO over  $\mathcal{M}(\Sigma)$  is decidable.*