

Automates et logiques pour les mots sur un alphabet infini

Alexis Bès

LACL, Université Paris 12

Plan

- ▶ Mots sur un alphabet infini
- ▶ Etat de l'art
- ▶ \mathfrak{M} -automates
- ▶ Propriétés des langages \mathfrak{M} -reconnaissables
- ▶ Caractérisations logiques
- ▶ Lien avec la notion de produit de structures
- ▶ Extension du modèle

Motivations

- ▶ Modélisation/vérification

- ▶ Système temporisé :

$$(s_0, t_0)(s_1, t_1) \dots (s_n, t_n) \dots$$

$s_i \in \Sigma$ (ensemble fini des états)

$t_i \in \mathbb{R}^+$: durée

Evolution du système : mot sur l'alphabet infini $(\Sigma \times \mathbb{R}^+)$

- ▶ Gestion de processus

$$(a_0, p_0)(a_1, p_1) \dots (a_n, p_n) \dots$$

$a_i \in \Sigma$ (ensemble fini des actions)

$p_i \in \mathbb{N}$ (numéro du processus)

- ▶ listes d'entiers, suite des valeurs d'une variable entière...

- ▶ Représentation de données semi-structurées (XML) : arbres étiquetés par des mots sur un alphabet fini

Quels modèles de calcul ?

- ▶ Candidat raisonnable : automate fini
- ▶ Ambitions :
 - ▶ expressivité
 - ▶ propriétés de clôture
 - ▶ effectivité (et complexité raisonnable)
 - ▶ caractérisations : expressions régulières, algèbre, logique

Quelques résultats

- ▶ 1969 : Eilenberg-Elgot-Shepherdson
- ▶ 1980 : Autebert-Beauquier-Boasson
- ▶ 1994 : Kaminski-Francez : automates à registre
- ▶ 2003 : Bouyer-Petit-Thérien
- ▶ 2004 : Neven-Schwentick-Vianu : pebble automata
- ▶ 2005 : Bojanczyk-David-Muscholl-Schwentick-Segoufin : logique FO^2 et *data automata*
- ▶ 2005 : Choffrut-Grigorieff
- ▶ 2005 : Demri-Lazic-Nowak : variante de LTL

Automates à registres (Kaminski-Francez)

Automates finis non-déterministes munis d'un nombre fini (fixé) de registres qui permettent de stocker des symboles et d'effectuer des comparaisons avec le symbole courant.

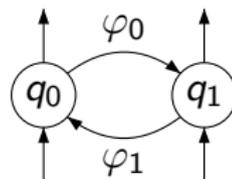
- ▶ Clos par $\cup, \cap, \cdot, *$
- ▶ Le problème du vide est décidable
- ▶ Pas clos par complémentation
 - ▶ $L = \{s_1 \dots s_n : \exists i \neq j s_i = s_j\}$ est reconnaissable
 - ▶ $\bar{L} = \{s_1 \dots s_n : \forall i \neq j s_i \neq s_j\}$ ne l'est pas
- ▶ Pas clos par opération miroir :
 - ▶ $L = \{s_1 \dots s_n : \forall i > 1 s_i \neq s_1\}$ est reconnaissable
 - ▶ $\tilde{L} = \{s_1 \dots s_n : \forall i < n s_i \neq s_n\}$ ne l'est pas
- ▶ le problème de l'universalité est indécidable (Neven & al)
- ▶ Les modèles déterministe et non-déterministe ne sont pas équivalents

\mathfrak{M} -automates

- ▶ Σ un alphabet (fini ou non)
- ▶ $\mathfrak{M} = (\Sigma; R_1, \dots, R_n, =)$ une structure relationnelle
- ▶ \mathfrak{M} -automate : automate fini non-déterministe dont les transitions sont des formules du 1er ordre écrites dans le langage de \mathfrak{M}
- ▶ L'automate suit la transition étiquetée par $\varphi(x)$ si le symbole courant s vérifie $\mathfrak{M} \models \varphi(s)$
- ▶ Langages \mathfrak{M} -reconnaissables : langages $L \subseteq \Sigma^*$ reconnaissables par un \mathfrak{M} -automate

Exemple de langage \mathfrak{M} -reconnaisable

- ▶ $\mathfrak{M} = (\mathbb{N}; +, =)$
- ▶ L : ensemble des mots sur \mathbb{N} dont les symboles sont alternativement pairs et impairs
- ▶ Un \mathfrak{M} -automate pour L :



avec

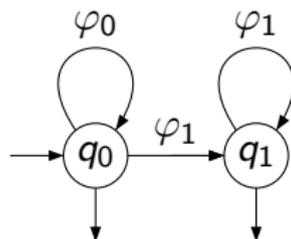
- ▶ $\varphi_0(x) : \exists y(x = y + y)$
- ▶ $\varphi_1(x) : \neg\varphi_0(x)$

Version multi-têtes

- ▶ \mathfrak{M} -automate à n têtes (synchrone) : reconnaît des relations $R \subseteq \Sigma^* \times \dots \times \Sigma^*$
- ▶ Etant donnés n mots w_1, \dots, w_n sur Σ , on complète avec des $\#$ de sorte à former un mot de $(\Sigma^n)^*$. On travaille avec une structure $\mathfrak{M}_\# = (\Sigma \cup \{\#\}; \dots)$ définie à partir de \mathfrak{M} .

Exemple avec $\mathfrak{M} = (\mathbb{N}; +, =)$:

- ▶ $R = \{(u, v) \mid |u| \leq |v| \text{ et } u[i] < v[i] \text{ pour tout } i < |u|\}$
- ▶ Un \mathfrak{M} -automate pour R :



avec

- ▶ $\varphi_0(x_1, x_2) : \exists y(x_2 = x_1 + y \wedge y + y \neq y)$
- ▶ $\varphi_1(x_1, x_2) : (x_1 = \# \wedge x_2 \neq \#)$

Quelques propriétés

Proposition

- ▶ Si $\mathfrak{M} = (\Sigma; (P_a)_{a \in \Sigma})$ avec Σ fini, et $P_a(x)$ ssi x porte un a , alors les relations \mathfrak{M} -reconnaissables sont les relations synchrones.
- ▶ Si $\mathfrak{M} = (\Sigma; \dots)$ avec Σ infini alors le langage $\{aa \mid a \in \Sigma\}$ n'est pas \mathfrak{M} -reconnaissable.

Proposition

La classe des langages \mathfrak{M} -reconnaissables est close par

- ▶ opérations booléennes
- ▶ projection

Proposition

La décidabilité du problème " $L(\mathcal{A}) = \emptyset$?" est équivalente à celle de $FO(\mathfrak{M})$.

Logique et automates

Trois formalismes classiques :

- ▶ Büchi-Elgot-Trakhtenbrot : logique du second-ordre monadique $(\mathbb{N}, <)$
- ▶ Eilenberg-Elgot-Shepherdson : logique du 1er ordre de $\mathcal{S} = (\Sigma^*; EqLength, \preceq, \{L_a\}_{a \in \Sigma})$ où
 - ▶ $EqLength(x, y)$ ssi $|x| = |y|$
 - ▶ $x \preceq y$ ssi x préfixe de y
 - ▶ $L_a(x)$ ssi a est la dernière lettre de x .
- ▶ Arithmétique de Büchi de base k : théorie du 1er ordre de $(\mathbb{N}; +, V_k)$ où $V_k(x) =$ plus grande puissance de k qui divise x .

Logique du second-ordre monadique (MSO)

- ▶ Extension de la logique du premier ordre
- ▶ variables du premier ordre x, y, z, \dots : (indices des) positions
- ▶ variables du second ordre X, Y, Z, \dots : ensembles de positions
- ▶ $x \in X$
- ▶ $x < y, Q_a(x)$: la position x porte un a

Exemple avec $\Sigma = \{a, b\}$:

$$\exists x \exists y (x < y \wedge \neg \exists z (x < z < y) \wedge Q_a(x) \wedge Q_a(y))$$

définit le langage $\Sigma^* aa \Sigma^*$;

Théorème (Büchi-Elgot-Trakhtenbrot) :

Les langages définissables dans MSO sont les langages rationnels ;

Généralisation de MSO

$MSO(\mathfrak{M})$: on remplace les prédicats $Q_a(x)$ par des prédicats $\alpha_F(x)$ interprétés par “le symbole s en x -ème position vérifie $\mathfrak{M} \models F(s)$ ”

Exemples avec $\mathfrak{M} = (\mathbb{N}; +)$

- ▶ l'ensemble $L_1 \subseteq \mathbb{N}^*$ des mots ne contenant que des symboles pairs est $MSO(\mathfrak{M})$ -définissable par $\forall y \alpha_F(y)$, où $F(x) : \exists z(z + z = x)$
- ▶ l'ensemble $L_2 \subseteq \mathbb{N}^*$ des mots dont les symboles sont alternativement pairs et impairs est $MSO(\mathfrak{M})$ -définissable par

$$\forall x \forall y ((x < y \wedge \neg \exists z x < z < y) \rightarrow ((\alpha_F(x) \leftrightarrow \alpha_{\neg F}(y))))$$

Théorème

Un langage $L \subseteq \Sigma^*$ est \mathfrak{M} -reconnaisable ssi il est $MSO(\mathfrak{M})$ -définissable.

Structures automatiques (Hodgson, Khoussainov-Nerode)

→ Structures représentables (et décidables) par automate

Définition

$\mathfrak{N} = (N; R_1, \dots, R_k)$ est *automatique* s'il existe Σ fini et une injection $\mu : N \rightarrow \Sigma^*$ tels que les images de N, R_1, \dots, R_k par μ sont des relations synchrones.

Exemple

$(\mathbb{N}; +)$ est automatique.

Théorème (Hodgson)

Si \mathfrak{N} est automatique alors :

1. Toute relation définissable dans \mathfrak{N} est synchrone ;
2. $FO(\mathfrak{N})$ est décidable.

Structures \mathfrak{M} –automatiques

Définition

Soit $\mathfrak{M} = (\Sigma; \dots)$. La structure $\mathfrak{N} = (N; R_1, \dots, R_k)$ est \mathfrak{M} –automatique s'il existe une injection $\mu : N \rightarrow \Sigma^*$ telle que les images de N, R_1, \dots, R_k par μ sont des relations \mathfrak{M} –reconnaissables

Exemple

$(\mathbb{N} \setminus \{0\}; \times)$ est $(\mathbb{N}; +)$ –automatique : considérer μ qui à tout $n = p_0^{n_0} p_1^{n_1} \dots p_k^{n_k}$ associe $\mu(n) = n_0 n_1 \dots n_k$.

Théorème

Si \mathfrak{N} est \mathfrak{M} –automatique alors :

1. Toute relation définissable dans \mathfrak{N} est \mathfrak{M} –reconnaissable ;
2. $FO(\mathfrak{N})$ se réduit à $FO(\mathfrak{M})$.

Eilenberg-Elgot-Shepherdson

Soit $\mathcal{S} = (\Sigma^*; EqLength, \preceq, \{L_a\}_{a \in \Sigma})$ où

- ▶ $EqLength(x, y)$ ssi $|x| = |y|$;
- ▶ $x \preceq y$ ssi x préfixe de y ;
- ▶ $L_a(x)$ ssi a est la dernière lettre de x .

Théorème (EES)

1. Pour Σ fini et $|\Sigma| \geq 2$, les relations $R \subseteq \Sigma^n$ définissables dans \mathcal{S} sont les relations synchrones.
2. $FO(\mathcal{S})$ est décidable.

Et pour un alphabet Σ infini ?

- ▶ *Dans le cas où Σ est infini, à quel type d'automate correspondent les relations définissables dans $\mathcal{S} = (\Sigma^*; EqLength, \preceq, \{L_a\}_{a \in \Sigma})$?*
- ▶ Choffrut-Grigorieff : automates avec des contraintes qui sont des combinaisons booléennes de formules de la forme $x = y$ et $x = a$
- ▶ correspondent aux \mathfrak{M} -automates avec $\mathfrak{M} = (\Sigma; \{P_a\}_{a \in \Sigma})$.

Généralisation

Pour $\mathfrak{M} = (\Sigma; R_1, \dots, R_k)$, on définit

$$S_{\mathfrak{M}} = (\Sigma^*; EqLength, \preceq, A_{R_1}, \dots, A_{R_k}, A_=)$$

où pour tout i , $A_{R_i}(x_1, \dots, x_n)$ ssi il existe $w_1, \dots, w_n \in \Sigma^*$ et $a_1, \dots, a_n \in \Sigma$ tels que :

- ▶ $x_i = w_i a_i$ pour tout i ;
- ▶ tous les w_i ont la même longueur
- ▶ $(a_1, \dots, a_n) \in R_i^{\mathfrak{M}}$.

Théorème

- ▶ Pour toute relation $R \subseteq \Sigma^n$, R est \mathfrak{M} -reconnaisable ssi R est définissable dans $S_{\mathfrak{M}}$;
- ▶ $FO(S_{\mathfrak{M}})$ se réduit à $FO(\mathfrak{M})$.

Un peu mieux

Pour $\mathfrak{M} = (\Sigma^*; \preceq, \dots)$, $MSO^{ch}(\mathfrak{M})$: restriction de $MSO(\mathfrak{M})$ où les variables du second ordre sont interprétées comme des chaînes pour \preceq .

Théorème (Kuske-Lohrey 2006)

Soient

$$\mathfrak{M} = (\Sigma; R_1, \dots, R_k)$$

et

$$\mathfrak{M}^* = (\Sigma^*; \preceq, A'_{R_1}, \dots, A'_{R_k}, A'_{=})$$

où $A'_{R_i} = \{(ua_1, \dots, ua_n) \mid (a_1, \dots, a_n) \in R_i\}$.

Alors $MSO^{ch}(\mathfrak{M}^*)$ se réduit à $FO(\mathfrak{M})$.

Théorème (Thomas-Bès)

$MSO^{ch}(\Sigma^*; EqLength, \preceq, A_{R_1}, \dots, A_{R_k}, A_{=})$ se réduit à $FO(\mathfrak{M})$.

\mathfrak{M} —automates et produits de structures

Produits de structures en logique (Mostowski, Feferman-Vaught, Shelah...)

- ▶ I un ensemble, $(\mathfrak{M}_i)_{i \in I}$ une famille de structures sur le même langage \rightarrow définitions diverses de $\prod_{i \in I} \mathfrak{M}_i$
- ▶ Théorèmes de (dé)composition : la théorie du 1er ordre du produit se réduit à celle des facteurs et à celle d'une structure *Ind* liée à l'ensemble des parties de I

Cas particulier intéressant de produit $\prod_{i \in I} \mathfrak{M}_i$

- ▶ Tous les \mathfrak{M}_i sont égaux à $\mathfrak{M}_\# = (\Sigma \cup \{\#\}; \dots)$
- ▶ $I = \mathbb{N}$, et $Ind = (PartiesFinies(\mathbb{N}); \subseteq, \ll)$ où $X \ll Y$ ssi $X = \{x\}$, $Y = \{y\}$ avec $x < y$ (variante de $WMSO(\mathbb{N}; <)$).
- ▶ Une *puissance faible généralisée* (Feferman-Vaught) de $\mathfrak{M}_\#$ relativement à Ind est (presque) par définition une structure dont le domaine et les relations de base sont $MSO(\mathfrak{M})$ -définissables, i.e. une structure \mathfrak{M} -automatique.

Relecture des résultats précédents

- ▶ clôture des relations \mathfrak{M} -reconnaissables \leftrightarrow clôture par définissabilité
- ▶ Si \mathfrak{N} est \mathfrak{M} -automatique alors $FO(\mathfrak{N})$ se réduit à $FO(\mathfrak{M}) \leftrightarrow FO(\mathfrak{N})$ se réduit à $FO(Ind)$ et $FO(\mathfrak{M})$

Une extension du formalisme logique

- ▶ Le modèle manque d'expressivité : si $\mathfrak{M} = (\Sigma; \dots)$ avec Σ infini alors $\{aa \mid a \in \Sigma\}$ n'est pas \mathfrak{M} -reconnaisable
- ▶ Idée : ajouter à $MSO(\mathfrak{M})$ des prédicats $\alpha_F(x_1, \dots, x_n)$ qui expriment des relations entre les symboles associés aux positions x_1, \dots, x_n (exemple : égalité)
- ▶ Notation : $MSO^+(\mathcal{L})$
- ▶ Problème : trop expressif \rightarrow indécidabilité (même avec FO et $\mathfrak{M} = (\mathbb{N}; =)$)

Un fragment syntaxique décidable

Définition

$MSO_R^+(\mathcal{L})$: fragment de $MSO^+(\mathcal{L})$ constitué des énoncés

$$\exists x_1 \dots \exists x_m \psi$$

où ψ formule de $MSO^+(\mathcal{L})$ où les α_F sont de la forme
 $\alpha_F(x_1, \dots, x_m, y)$

Proposition

Le problème de la satisfaisabilité pour $MSO_R^+(\mathfrak{M})$ se réduit à la décidabilité de $FO(\mathfrak{M})$

Exemples avec $\mathfrak{M} = (\mathbb{N}; +)$

- ▶ L_1 : ens. mots u sur \mathbb{N} tels qu'un symbole $s \in \Sigma$ apparaît au moins deux fois dans u

$$\exists x \exists y (x < y \wedge \alpha_F(x, y))$$

où

$$F(x_1, x_2) : x_1 = x_2.$$

- ▶ L_2 : ens. mots $u = s_0 \dots s_m$ tels qu'il existe j avec $s_k \geq 2s_j$ pour tout $k > j$:

$$\exists x (\exists x' (x < x') \wedge \forall y (x < y \rightarrow \alpha_G(x, y)))$$

où

$$G(x_1, x_2) : \exists z (x_2 = x_1 + x_1 + z)$$

exprime $x_2 \geq 2x_1$.

Exemple avec $\mathfrak{M} = (\Sigma^*; EqLength, \preceq, \{L_a\}_{a \in \Sigma})$

- ▶ L : ens. des mots $w = s_0 \dots s_m$ sur $\Gamma = \Sigma^*$ tels que toutes les positions paires portent le même symbole, et toutes les positions impaires portent un symbole qui est préfixe de s_0

$\exists X [EvenPositions(X) \wedge$

$\wedge \exists x \in X \forall y \in X \alpha_{F_1}(x, y) \wedge \exists z (\forall t \neg t < z \wedge \forall y \notin X \alpha_{F_2}(y, z))]$

où $EvenPositions(X)$ exprime que X contient les positions paires et

$F_1(v_1, v_2) : v_1 = v_2 ;$

$F_2(v_1, v_2) : v_1 \preceq v_2.$

Perspectives

- ▶ Extension aux mots infinis, aux arbres
- ▶ Fragments de complexité raisonnable
- ▶ Version automates du résultat précédent
- ▶ Extensions décidables de MSO
- ▶ Nouvelles techniques de composition de structures

Annexe - Quelques détails sur les produits de structures

Produits de structures en logique

- ▶ I un ensemble, $(\mathfrak{M}_i)_{i \in I}$ une famille de structures sur le même langage \rightarrow définitions diverses de $\prod_{i \in I} \mathfrak{M}_i$
- ▶ Théorèmes de composition : la théorie du 1er ordre du produit se réduit à celle des facteurs et à celle d'une structure liée à l'ensemble des parties de I

Puissance faible d'une structure (Mostowski)

- ▶ $\mathfrak{M} = (\Sigma \cup \{\#\}; R_1, \dots, R_n)$ une structure relationnelle
- ▶ La puissance faible de \mathfrak{M} relativement à \mathbb{N} et $\#$ est la structure $\mathfrak{N} = (D; R_1^{\mathfrak{N}}, \dots, R_k^{\mathfrak{N}})$ telle que
 - ▶ D : fonctions $f : \mathbb{N} \rightarrow \Sigma \cup \{\#\}$ presque toujours égales à $\#$
 - ▶ $\mathfrak{N} \models R_i^{\mathfrak{N}}(f_1, \dots, f_k)$ ssi $\mathfrak{M} \models R_i^{\mathfrak{M}}(f_1(i), \dots, f_k(i))$ pour tout $i \in \mathbb{N}$

Un exemple de puissance faible

- ▶ $\mathfrak{M} = (\mathbb{N}; +)$ où 0 est l'élément distingué
- ▶ $\mathfrak{N} = (D; +^{\mathfrak{N}})$
 - ▶ D : fonctions $f : \mathbb{N} \rightarrow \mathbb{N}$ presque toujours nulles
 - ▶ $\mathfrak{N} \models +^{\mathfrak{N}}(f_1, f_2, f_3)$ ssi $f_1(i) + f_2(i) = f_3(i)$ pour tout i
 - ▶ \mathfrak{N} est isomorphe à $(\mathbb{N} \setminus \{0\}; \times)$

Evaluation des formules dans \mathfrak{N} :

- ▶ On a $\mathfrak{N} \models +^{\mathfrak{N}}(f_1, f_2, f_3)$ ssi $f_1(i) + f_2(i) = f_3(i)$ pour tout $i \in \mathbb{N}$
- ▶ ou encore : $(\mathcal{P}_f(\mathbb{N}); \subseteq) \models \forall Y X \subseteq Y$ avec $X = \{i \mid \mathfrak{M} \models f_1(i) + f_2(i) \neq f_3(i)\}$
- ▶ On a ainsi trouvé des formules G et θ telles que $\mathfrak{N} \models +^{\mathfrak{N}}(f_1, f_2, f_3)$ ssi $(\mathcal{P}_f(\mathbb{N}); \subseteq) \models G(X)$ avec $X = \{i \mid \mathfrak{M} \models \theta(f_1(i), f_2(i), f_3(i))\}$
- ▶ (G, θ) : suite de réduction pour la formule $+^{\mathfrak{N}}(x, y, z)$

Théorème de composition pour les puissances faibles

Théorème (Mostowski)

- ▶ A toute formule $F(f_1, \dots, f_k)$ dans \mathfrak{N} on peut associer de manière effective une suite de réduction $(G, \theta_1, \dots, \theta_n)$
- ▶ $FO(\mathfrak{N})$ se réduit à $FO(\mathfrak{M})$ et $FO(\mathcal{P}_f(\mathbb{N}); \subseteq)$.
- ▶ $FO(\mathcal{P}_f(\mathbb{N}); \subseteq)$ est décidable

Exemple (suite)

$FO(\mathfrak{N})$ se réduit à $FO(\mathbb{N}; +)$ qui est décidable. Donc $FO(\mathfrak{N})$ (et $FO(\mathbb{N} \setminus \{0\}; \times)$) sont décidables.

Puissances faibles généralisées (Feferman-Vaught)

On part de

$$\mathfrak{M} = (\Sigma \cup \{\#\}; R_1, \dots, R_n)$$

et d'une structure

$$S = (\mathcal{P}_f(\mathbb{N}); \subseteq, S_1, \dots, S_p)$$

Puissance faible généralisée de \mathfrak{M} relativement à S : toute structure \mathfrak{N} de domaine D et dont toutes les relations de base admettent une suite de réduction relativement à M et S .

Théorème (Feferman-Vaught)

- ▶ A toute formule $F(f_1, \dots, f_k)$ dans \mathfrak{N} on peut associer de manière effective une suite de réduction $(G, \theta_1, \dots, \theta_n)$;
- ▶ $FO(\mathfrak{N})$ se réduit à $FO(\mathfrak{M})$ et $FO(S)$.

Puissances faibles généralisées et \mathfrak{M} -automates

- ▶ Cas particulier intéressant : $S = (\mathcal{P}_f(\mathbb{N}); \subseteq, \ll)$ où $X \ll Y$ ssi $X = \{x\}$, $Y = \{y\}$, avec $x < y$. $FO(S)$ est une variante de $WMSO(\mathbb{N}; <)$.
- ▶ Soient $\mathfrak{M} = (\Sigma; \dots)$, et \mathfrak{N} une puissance faible généralisée de $\mathfrak{M}_\#$ relativement à S .
- ▶ A tout mot $w \in \Sigma^*$ on fait correspondre (en complétant par des $\#$) un mot $c(w) \in (\Sigma \cup \{\#\})^\omega$, i.e un élément du domaine de \mathfrak{N} .

Proposition

- ▶ Une relation R est \mathfrak{M} -reconnaissable ssi $c(R)$ admet une suite de réduction relativement à \mathfrak{M} et S
- ▶ \mathfrak{N} est une structure \mathfrak{M} -automatique
- ▶ clôture des relations \mathfrak{M} -reconnaissables \leftrightarrow clôture par définissabilité