

Dualité et théorie équationnelle des langages

Mai Gehrke¹ Serge Grigorieff² Jean-Éric Pin²

¹Radboud Universiteit

²LIAFA, CNRS et Université Paris Diderot

Octobre 2008, PPS




Sommaire


- (1) Langages
- (2) Dualité
- (3) Le monde profini
- (4) Théories équationnelles des langages



Un cercle vertueux



Un autre cercle vertueux



Première partie I

Treillis de langages



Parties reconnaissables

Un langage L de A^* est reconnu par un monoïde M s'il existe un morphisme surjectif de monoïdes $\varphi : A^* \rightarrow M$ qui **sature** L : si $u \in L$ et $\varphi(u) = \varphi(v)$, alors $v \in L$ [ou encore $L = \varphi^{-1}\varphi(L)$].

Un langage est **reconnaisable** s'il est reconnu par un monoïde fini. Un langage est reconnaissable ssi il est **rationnel** (Kleene).

Le **monoïde syntactique** d'un langage rationnel L de A^* est le **plus petit** monoïde qui le reconnaît. Sa taille sert de mesure de complexité pour L .

Treillis de langages

On fixe un alphabet fini A . Un **treillis de langages** est un ensemble de langages reconnaissables de A^* contenant \emptyset et A^* et fermé par **union finie** et **intersection finie**.

Définition

Soient u et v des mots de A^* . Un langage L de A^* **satisfait l'équation** $u \rightarrow v$ si la condition $u \in L$ entraîne $v \in L$.

Treillis finis de langages

Soit E un ensemble d'équations de la forme $u \rightarrow v$. Alors l'ensemble $\mathcal{L}(E)$ des langages de A^* vérifiant les équations de E est un treillis de langages.

Proposition

Soient L, L_1, \dots, L_n des langages. Si L satisfait toutes les équations satisfaites par L_1, \dots, L_n , alors L appartient au *treillis de langages* engendré par L_1, \dots, L_n .

Corollaire

Un ensemble fini de langages de A^ est un treillis de langages ssi il peut être défini par un ensemble d'équations de la forme $u \rightarrow v$ avec $u, v \in A^*$.*

Il y a donc une théorie équationnelle pour les treillis finis de langages. Que peut-on dire des treillis infinis ?

Corollaire

Un ensemble fini de langages de A^ est un **treillis de langages** ssi il peut être défini par un ensemble d'équations de la forme $u \rightarrow v$ avec $u, v \in A^*$.*

Il y a donc une théorie équationnelle pour les **treillis finis** de langages. Que peut-on dire des treillis infinis ?

Il faut se plonger dans le monde profini...

Deuxième partie II

Le monde profini

Citation (M. Stone)

*A cardinal principle of modern mathematical research may be stated as a maxim : **One must always topologize.***



Séparer deux mots

Un monoïde M sépare deux mots u et v de A^* s'il existe un morphisme de monoïde $\varphi : A^* \rightarrow M$ tel que $\varphi(u) \neq \varphi(v)$.

Par exemple, le morphisme qui envoie chaque mot sur sa longueur modulo 2 est un morphisme de $\{a, b\}^*$ sur $\mathbb{Z}/2\mathbb{Z}$ qui sépare $abaaba$ et $abaabab$.

Soit $M = \left\{ \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}, \begin{pmatrix} 1 & 0 \\ 1 & 0 \end{pmatrix}, \begin{pmatrix} 0 & 1 \\ 0 & 1 \end{pmatrix} \right\}$ et soit $\varphi : \{a, b\}^* \rightarrow M$ défini par $\varphi(a) = \begin{pmatrix} 1 & 0 \\ 1 & 0 \end{pmatrix}$ and $\varphi(b) = \begin{pmatrix} 0 & 1 \\ 0 & 1 \end{pmatrix}$. Alors, pour chaque mot u , φ sépare ua et ub car $\varphi(ua) = \varphi(a)$ et $\varphi(ub) = \varphi(b)$.

La distance profinie

Soient u et v deux mots. Posons

$$r(u, v) = \min\{|M| \mid M \text{ est un monoïde fini qui sépare } u \text{ et } v\}$$

$$d(u, v) = 2^{-r(u, v)}$$

Dans ce cas, d est une distance **ultramétrique**. Pour tout $x, y, z \in A^*$,

- (1) $d(x, x) = 0$,
- (2) $d(x, y) = d(y, x)$,
- (3) $d(x, z) \leq \max\{d(x, y), d(y, z)\}$

Propriétés de d

Intuitivement, deux mots sont proches pour d s'il faut un monoïde **de grande taille** pour les séparer.

Une suite de mots u_n est une **suite de Cauchy** ssi, pour tout morphisme φ de A^* vers un monoïde fini, la suite $\varphi(u_n)$ est ultimement constante.

Une suite de mots u_n **converge** vers un mot u ssi, pour tout morphisme φ de A^* sur un monoïde fini, la suite $\varphi(u_n)$ est ultimement égale à $\varphi(u)$.

Le monoïde profini libre

La complétion de l'espace métrique (A^*, d) est le **monoïde profini libre** sur A , noté $\widehat{A^*}$. Ses éléments sont appelés des **mots profinis**.

Le produit est uniformément continu sur A^* et s'étend donc par continuité à $\widehat{A^*}$. Si A est **fini**, $\widehat{A^*}$ est **compact**.

Tout morphisme $\varphi : A^* \rightarrow M$, où M est fini (discret) est uniformément continu. Puisque A^* est dense dans $\widehat{A^*}$, φ s'étend de façon unique en un morphisme uniformément continu $\widehat{\varphi} : \widehat{A^*} \rightarrow M$.

Le monoïde profini libre comme limite projective


Le monoïde profini peut être défini comme la **limite projective** du **système dirigé** formé par les morphismes surjectifs entre monoïdes finis.

En particulier, un mot profini u est complètement déterminé par ses images $\hat{\varphi}(u)$, où φ décrit la classe des morphismes de A^* sur un monoïde fini.

$$\text{Mot profini} = \{\hat{\varphi}(u)\}_{\varphi:A^* \rightarrow M}$$

Un mot profini non fini

Pour chaque $u \in \widehat{A}^*$, la suite $u^{n!}$ est une suite de Cauchy et donc converge dans \widehat{A}^* vers une limite, notée u^ω . Si φ est un morphisme de A^* sur un monoïde fini M , $\hat{\varphi}(u^\omega)$ est l'unique idempotent du sous-semigroupe de M engendré par $x = \varphi(u)$.



Troisième partie III

Théorie équationnelle des langages



Soit L un langage reconnaissable de A^* et soit $\eta : A^* \rightarrow M$ son morphisme syntactique. On sait que η se prolonge en un morphisme uniformément continu de \hat{A}^* vers M . On note \overline{L} la fermeture topologique de L pour la distance profinie.

Définition

Soient u et v des mots profinis de \hat{A}^* . Alors L satisfait l'équation $u \rightarrow v$ si la condition $u \in \overline{L}$ entraîne $v \in \overline{L}$.

Une définition équivalente

Soit L un langage reconnaissable de A^* et soit $\eta : A^* \rightarrow M$ son monoïde syntactique.

Définition

Soient u et v des mots profinis de \hat{A}^* . Alors L satisfait l'équation $u \rightarrow v$ si la condition $\hat{\eta}(u) \in \eta(L)$ entraîne $\hat{\eta}(v) \in \eta(L)$.

Caractérisation équationnelle des treillis

Soit E un ensemble d'équations de la forme $u \rightarrow v$.
Le sous-ensemble de $\text{Rec}(A^*)$ défini par E est
l'ensemble de tous les langages reconnaissables de
 A^* satisfaisant toutes les équations de E .

Théorème

Un ensemble de langages reconnaissables de A^ est un treillis de langages ssi il peut être défini par un ensemble d'équations de la forme $u \rightarrow v$, où $u, v \in \hat{A}^*$.*

Quatrième partie IV

Dualité



Petit résumé sur la dualité

L'**espace dual** d'un treillis distributif est l'ensemble de ses **filtres premiers**.

Éléments \leftrightarrow Filtres premiers

Algèbres de Boole \leftrightarrow Espaces topologiques

Treillis distributifs \leftrightarrow Espaces topologiques ordonnés

Sous-treillis \leftrightarrow Espaces quotients

Opérations n -aires \leftrightarrow Relations $(n + 1)$ -aires

Filtres premiers et valuation

Soit D un treillis distributif borné (avec 0 et 1).

Un **filtre premier** est une partie F de D telle que

- (1) $1 \in F$, $0 \notin F$,
- (2) si $x \in F$ et $x \leq y$, alors $y \in F$ (axiome d'extension),
- (3) si $x, y \in F$, alors $x \wedge y \in F$,
- (4) si $x \vee y \in F$, alors $x \in F$ ou $y \in F$.

Une **valuation** est un morphisme de treillis v de D dans le **treillis booléen** $\{0, 1\}$.

- (1) $v(0) = 0$ $v(1) = 1$
- (2) $v(x \vee y) = v(x) + v(y)$ $v(x \wedge y) = v(x)v(y)$



Espace dual

Si $v : D \rightarrow \{0, 1\}$ est une **valuation**, l'ensemble $v^{-1}(1)$ est un **filtre premier**.

Si p est un **filtre premier**, l'application définie par

$$v(x) = \begin{cases} 1 & \text{si } x \in p \\ 0 & \text{sinon} \end{cases}$$

est une **valuation**.

L'**espace dual** d'un treillis distributif est l'ensemble de ses **filtres premiers**, ou, de façon équivalente, l'ensemble de ses **valuations**.



Dualité de Stone-Priestley

Soit X_D l'ensemble des **filtres premiers** de D (dual de D). L'application $e : D \rightarrow \mathcal{P}(X_D)$ donnée par


$$e(d) = \{ \text{filtres premiers contenant } d \}$$

définit un morphisme de treillis injectif (mais pas surjectif en général).


On munit X_D d'une topologie dont les ensembles de la forme $e(d)$ ($d \in D$) et leur complément forment une **base d'ouverts** (et donc de **clopen**). L'espace X_D est un espace topologique ordonné **compact** (pas nécessairement séparé).



Dual d'un treillis distributif fini



Treillis



Filtres premiers

L'espace dual de $\text{Rec}(A^*)$

Almeida (1989, implicitement) and Pippenger (1997, explicitement) ont prouvé :

Théorème

L'espace dual du treillis des langages rationnels est l'espace des mots profinis. Le plongement canonique est donné par la clôture topologique : $e(L) = \overline{L}$.

En effet, **filtres premiers** de $\text{Rec}(A^*)$, **valuations** et **mot profinis** peuvent être identifiés !

L'espace dual de $\text{Rec}(A^*)$ (suite)

- Si p est un **filtre premier**, il existe un unique **mot profini** u tel que, pour tout $\varphi : A^* \rightarrow M$, $\hat{\varphi}(u)$ soit l'unique élément $m \in M$ tel que $\varphi^{-1}(m) \in p$.

- Si u est un **mot profini**, l'ensemble

$$p_u = \{ L \in \text{Rec}(A^*) \mid \hat{\varphi}(u) \in \varphi(L) \text{ pour un morphisme } \varphi \text{ de } A^* \text{ sur un monoïde fini} \}$$

est un **filtre premier**.

- Si v est une **valuation**, on peut définir un **mot profini** u par la condition $\hat{\varphi}(u) = m$ ssi, pour chaque $\varphi : A^* \rightarrow M$, la valuation du langage $\varphi^{-1}(m)$ vaut 1.

Dualité de Priestley

Donc X_A est l'ensemble des mot profinis. D'après le théorème de dualité de Priestley, on a un morphisme injectif de treillis distributif de $\text{Rec}(A^*)$ dans $\mathcal{P}(X_A)$:

$$\begin{aligned} L &\rightarrow \{\text{filtres premiers contenant } L\} \\ &\rightarrow \{\text{valuations telles que } v(L) = 1\} \\ &\rightarrow \{\text{mot profinis } u \text{ tels que } \hat{\eta}(u) \in \eta(L)\} \end{aligned}$$

Ces ensembles sont des **ouverts et fermés** de X_A .
De plus, comme chaque singleton $\{u\}$ est un langage reconnaissable, A^* se plonge dans $\mathcal{P}(X_A)$.

Quelques formules

Les applications $L \mapsto \overline{L}$ et $K \mapsto K \cap A^*$ définissent des isomorphismes réciproques entre les algèbres de Boole $\text{Rec}(A^*)$ et $\text{Clopen}(\widehat{A^*})$. Pour tout $L, L_1, L_2 \in \text{Rec}(A^*)$:

- (1) $\overline{L^c} = (\overline{L})^c$,
- (2) $\overline{L_1 \cup L_2} = \overline{L_1} \cup \overline{L_2}$, $\overline{L_1 \cap L_2} = \overline{L_1} \cap \overline{L_2}$,
- (3) Si $x, y \in A^*$, on a $\overline{x^{-1}Ly^{-1}} = x^{-1}\overline{L}y^{-1}$.
- (4) Si $\varphi : A^* \rightarrow B^*$ est un morphisme et $L \in \text{Rec}(B^*)$, alors $\hat{\varphi}^{-1}(\overline{L}) = \overline{\varphi^{-1}(L)}$.

Un résultat de dualité

Les **résiduels gauche** et **droit** de L par K sont :

$$K \backslash L = \{u \in A^* \mid Ku \subseteq L\}$$

$$L / K = \{u \in A^* \mid uK \subseteq L\}$$

Théorème

Le **produit** des mots profinis est le dual de l'opération de **résiduation** sur les langages rationnels.

L'identité $(H \backslash L) / K = H \backslash (L / K)$ dans $\text{Rec}(A^*)$ équivaut au fait que le produit est associatif.



Théorème

Un ensemble de langages reconnaissables de A^ est un treillis de langages ssi il peut être défini par un ensemble d'équations de la forme $u \rightarrow v$, où $u, v \in \hat{A}^*$.*

La preuve résulte de la **dualité** entre sous-treillis de $\text{Rec}(A^*)$ et préordres de l'espace dual \hat{A}^* .

Si \mathcal{L} est un treillis de langages, le préordre qui définit le **quotient** dans l'espace dual est exactement la **théorie équationnelle** de \mathcal{L} .

Structures uniformes associées à un treillis

Si \mathcal{L} est un **treillis de langages**, la structure (quasi)-uniforme **pro- \mathcal{L}** est engendrée par les ensembles $U_L = (L \times A^*) \cup (A^* \times L^c)$ où $L \in \mathcal{L}$.

Théorème

Une fonction $f : A^* \rightarrow A^*$ est **uniformément continue** pour la structure (quasi)-uniforme **pro- \mathcal{L}** ssi f^{-1} préserve les langages de \mathcal{L} .

La topologie associée définit un **espace spectral**.

Cinquième partie V

Retour sur la théorie équationnelle



Treillis de langages fermés par quotient

On dit que L satisfait l'équation $u \leq v$ si, pour tout $x, y \in \hat{A}^*$, il satisfait l'équation $xvy \rightarrow xuy$.

Proposition

Soit $L \in \text{Rec}(A^*)$, soit (M, \leq_L) son monoïde syntactique ordonné et soit $\eta : A^* \rightarrow M$ son morphisme syntactique. Alors L satisfait l'équation $u \leq v$ ssi $\hat{\eta}(u) \leq_L \hat{\eta}(v)$.

Treillis de langages fermés par quotient (2)

On dit que L satisfait l'équation $u \leq v$ si, pour tout $x, y \in \hat{A}^*$, il satisfait l'équation $xvy \rightarrow xuy$.

Théorème

Un ensemble de langages reconnaissables de A^ est un treillis de langages fermé par quotient ssi il peut être défini par un ensemble d'équations de la forme $u \leq v$, où $u, v \in \hat{A}^*$.*

Algèbres de Boole fermées par quotient

On note $u = v$ si $u \leq v$ et $v \leq u$.

Théorème

Un ensemble de langages reconnaissables de A^ est une algèbre de Boole fermée par quotient ssi il peut être défini par un ensemble d'équations de la forme $u = v$, où $u, v \in \hat{A}^*$.*

On retrouve ainsi une conséquence des théorèmes d'Eilenberg et de Reiterman.

Interprétation des équations (Notation : $P = \eta(L)$)

Fermé par		Interprétation
\cup, \cap	$u \rightarrow v$	$\hat{\eta}(u) \in P \Rightarrow \eta(v) \in P$
quotient	$u \leq v$	$xvy \rightarrow xuy$
complément (L^c)	$u \leftrightarrow v$	$u \rightarrow v$ et $v \rightarrow u$
quotient et L^c	$u = v$	$xuy \leftrightarrow xvy$
φ^{-1}		Variables = mots
φ^{-1} strict. alpha.		Variables = lettres
φ^{-1} length multiplying		Variables = mots de même longueur

Langages avec zéro

Un **langage avec zéro** est un langage dont le monoïde syntactique possède un zéro.

Proposition

*La classe des langages reconnaissables **avec zéro** est fermée pour les **opérations booléennes** et par **quotients**.*

Par conséquent, il peut être défini par un ensemble d'équations de la forme $u = v \dots$



Un mot profini

Fixons un ordre total sur l'alphabet A . Soit u_0, u_1, \dots la suite ordonnée de tous les mots de A^+ dans l'ordre des mots croisés (longueur d'abord).

$1, a, b, aa, ab, ba, bb, aaa, aab, aba, abb, baa, bab, \dots$

Reilly et Zhang (voir aussi Almeida-Volkov) ont prouvé que la suite $(v_n)_{n \geq 0}$ définie par

$$v_0 = u_0, \quad v_{n+1} = (v_n u_{n+1} v_n)^{(n+1)!}$$

converge vers un idempotent ρ_A de l'idéal minimal du monoïde profini libre sur A .



Proposition

*Un langage reconnaissable possède un **zéro** ssi il satisfait l'équation $x\rho_A = \rho_A = \rho_A x$ pour tout $x \in A^*$.*

Langages non denses

Un langage L de A^* est **dense** si, pour tout mot $u \in A^*$, $L \cap A^*uA^* \neq \emptyset$.

Les langages **non-denses** ou **pleins** sont fermés par **union** finie, **intersection** finie et **quotients**. Ils **ne sont pas fermés** par **inverse de morphismes**, même pour les morphismes strictement alphabétiques.

Théorème

Un langage de A^ est **non-dense** ou **plein** ssi il satisfait l'équation $x \leq 0$ pour tout $x \in A^*$.*

Langages minces (slender)

Un langage L est **mince** si sa densité $d_L(n) = |L \cap A^n|$ est $O(1)$.


Théorème (Folklore)

*Un langage reconnaissable est **mince** ssi il est union finie de langages de la forme xu^*y .*

Ces langages sont fermés par **union** finie, **intersection** finie, **quotients** et **morphismes** mais **pas par inverse de morphismes**, même pour les morphismes strictement alphabétiques.

Théorème

Un langage reconnaissable est *mince* ssi son automate déterministe minimal ne contient *aucune paire connectée de cycles simples*.



Deux cycles connectés, où $x, y \in A^+$ et $u \in A^*$.

Équations définissant les langages minces

On note $i(u)$ l'initiale du mot u .

Théorème

Supposons que $|A| \geq 2$. Un langage reconnaissable de A^* est *mince ou plein* ssi il satisfait les équations $x \leq 0$ et $0 \leq x^\omega u y^\omega$ pour tout $x, y \in A^+$, $u \in A^*$ tels que $i(uy) \neq i(x)$.

Langages clairsemés (sparse)

Un langage L est **clairsemé** si sa densité est polynomiale.

Théorème (Folklore)

Un langage reconnaissable est clairsemé ssi il est union finie de langages de la forme $u_0 v_1^ u_1 \cdots v_n^* u_n$.*

Ces langages sont fermés par **union** finie, **intersection** finie, **produit de concatenation**, **quotients** et **morphismes** mais **pas par inverse de morphismes**, même pour les morphismes strictement alphabétiques.



Théorème

Supposons que $|A| \geq 2$. Un langage reconnaissable de A^* est *clairsemé ou plein* ssi il satisfait les équations $0 \leq (x^\omega y^\omega)^\omega$ pour tout $x, y \in A^+$, tels que $i(x) \neq i(y)$.

Applications

En résumé, tout **treillis de langages rationnels** a une caractérisation **équationnelle**.

En particulier, tout **fragment de logique** (du premier ordre, du second ordre monadique, temporelle ou autre) fermé par **conjonction** et **disjonction** définit une classe de langages rationnels qui peut être décrite par des **équations**.


Résumé

On a montré que tout **treillis de langages** admet une description **équationnelle**, un résultat qui étend le **théorème des variétés d'Eilenberg** et ses **extensions**.

En particulier, toute classe de langages rationnels définie par un **fragment de logique** fermé par **conjonctions** et **disjonctions** (premier ordre, second ordre monadique, logique temporelle, etc.) admet une description **équationnelle**.



Retour sur les cercles vertueux



Extensions potentielles

Notre résultat s'étend sans difficulté aux **mots infinis** (en utilisant des ω -semigroupes) et très certainement aux mots sur des **ordinaux** ou des **ordres linéaires** en utilisant les travaux de Bruyère-Carton.

D'après les spécialistes, il s'étend également aux langages d'**arbres** (finis, infinis).

Le point de vue de la dualité permet d'étudier beaucoup d'autres problèmes. . .

