

Initiation à la combinatoire des mots - GMIN314

Pascal Ochem, Gwenaël Richomme, Patrice Séebold

gwenael.richomme@lirmm.fr

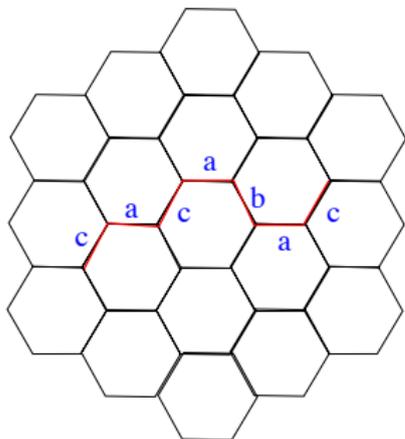
Cours 1

Les transparents de la réunion de rentrée

Contexte ?

Mot = un objet de base en modélisation utile dans de nombreux domaines :

- langages formels, automates,
- compilateurs,
- compression,
- algo du texte et du génôme,
- gestion de file d'attente,
- placement de robots,
- théorie des nombres,
- ...



Chemin dans un graphe

L'étude des mots peut permettre :

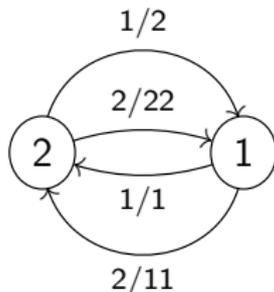
- une meilleure compréhension des objets modélisés,
- une aide à l'analyse d'algorithmes,
- principe pour de nouveaux algorithmes,
- ...

Texte	a n e a n a n u a n a n a n a s a n e
Motif	a n a n a s
	o o x

Contexte ? (fin)

Questions nous intéressant plus particulièrement :

- études de familles de mots aux propriétés extrêmes,
- mécanismes pour engendrer des mots
et étude des mots obtenus,
- existence de mots avec des propriétés particulières
notamment évitant des motifs,
- résolution de problèmes ouverts,
- ...

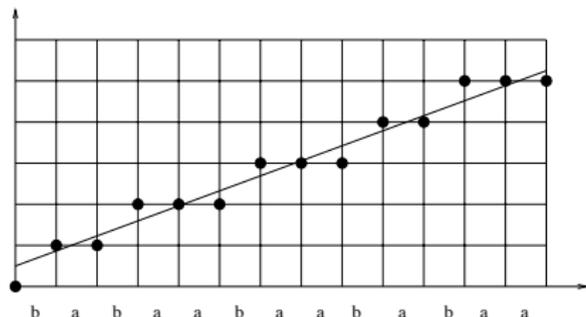


Kolakoski 221121221...

n'a pas livré tous ses secrets

- 1 Exemples de liaisons avec d'autres domaines
- 2 Résultats de base sur les mots finis
- 3 Mots infinis
 - mécanismes pour les engendrer : morphismes, transducteurs, ...
 - classification par le nombre de facteurs

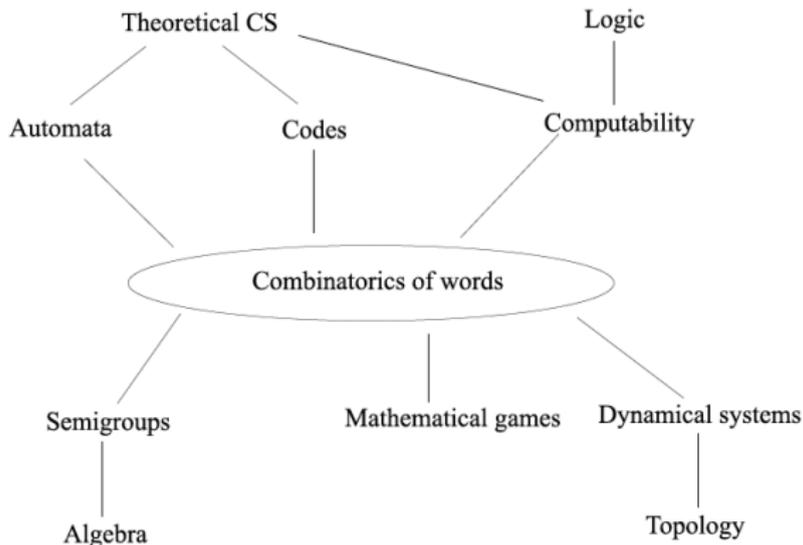
- mots sturmiens



- 4 Mots et évitabilité de motifs

- Équipe pédagogique : P. Ochem, G. Richomme, P. Séébold
- Chaque séance : cours + exos
- MCC : examen (14 points) + devoirs (6 points)

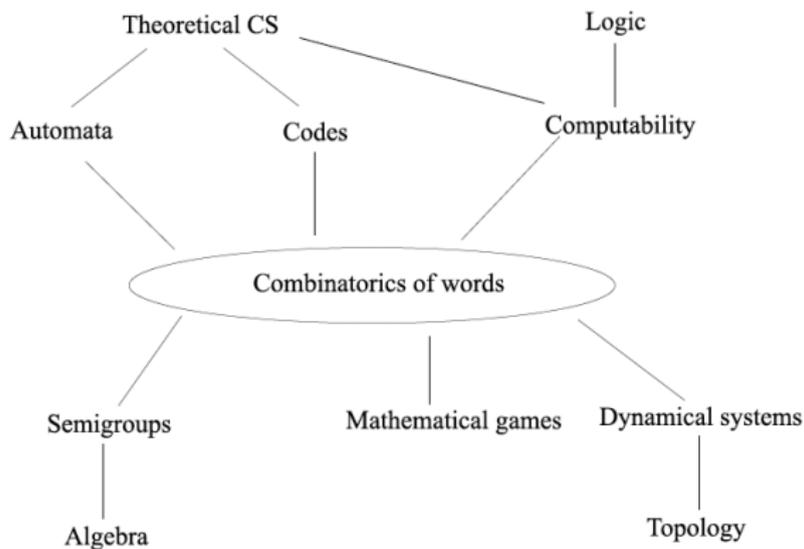
Quelques liens avec d'autres domaines



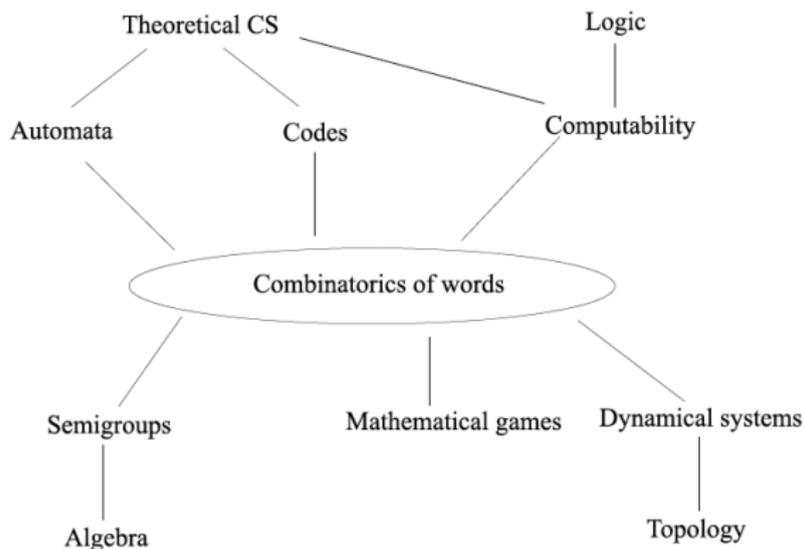
J. Karhumäki, Combinatorics of words

notes de cours, vue sur le web le 16/09/2014

<http://www.utu.fi/en/units/sci/units/math/staff/Pages/karhumak.aspx>

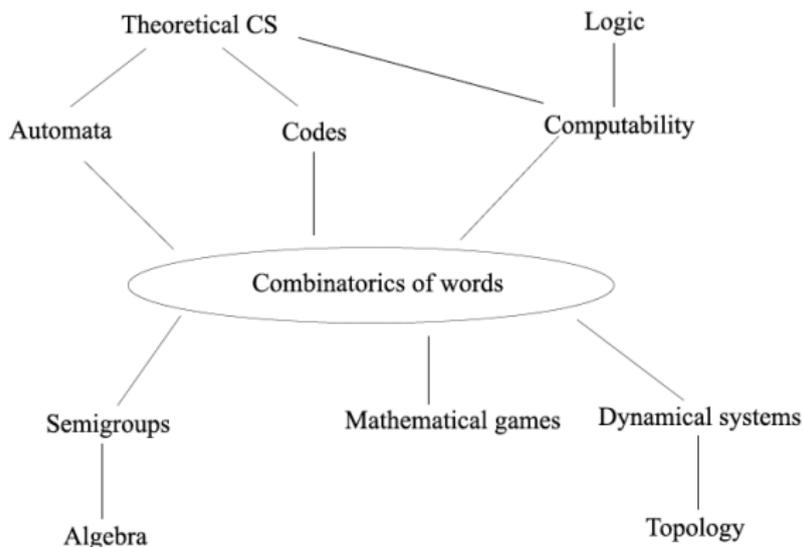


"Automata" : plus généralement théorie des langages formels et ses applications (compilateurs)



"Codes" : codes à longueurs variables

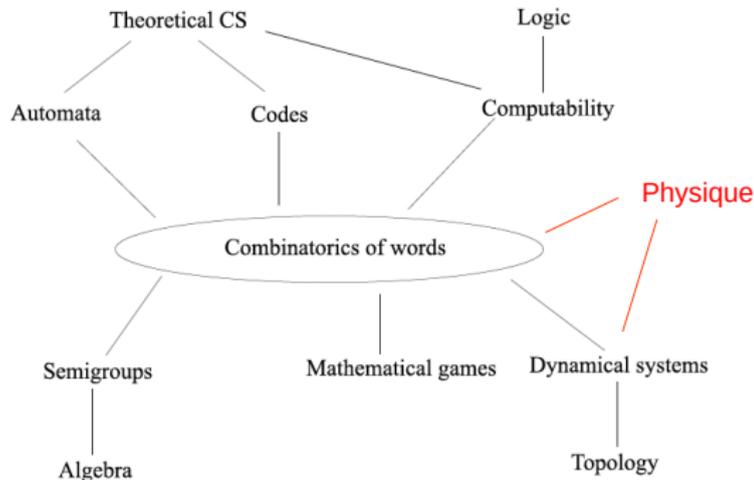
Morphismes injectifs = actions de codage



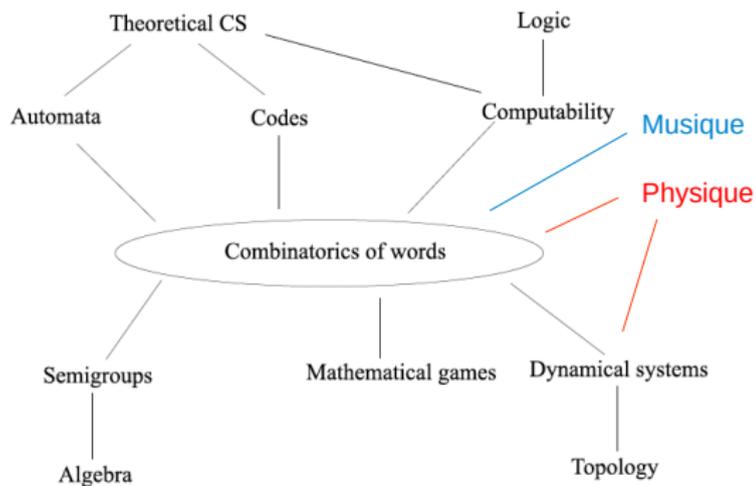
Algebra : exemple célèbre "Problème de Burnside"

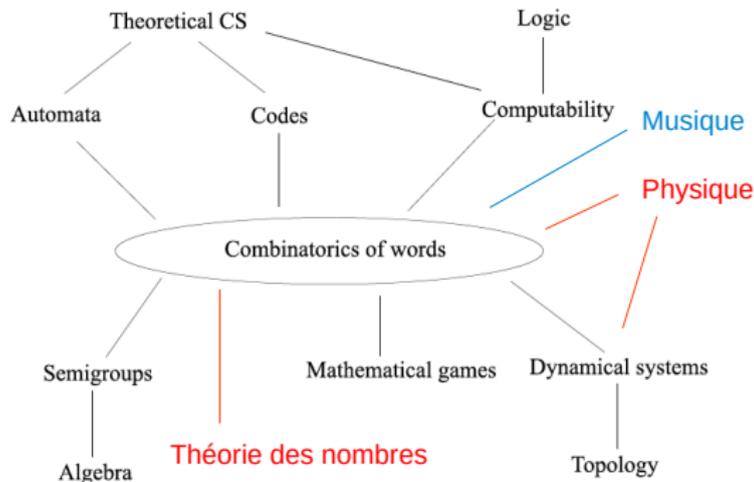
If S is a finitely generated semigroup and if each of its elements generate a finite semigroup, is G itself finite ?

Non ! Preuve utilise mots sans carré.



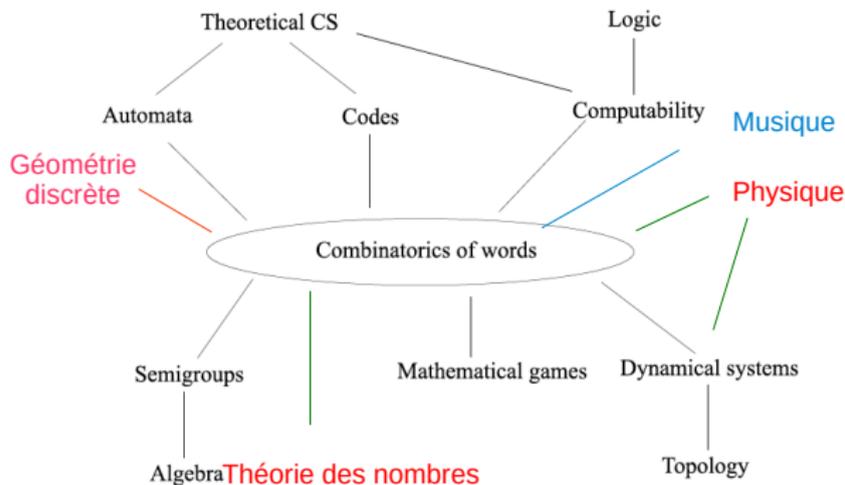
Physique : liens entre quasi-cristaux et mots sturmiens





Théorie des nombres, systèmes de numération

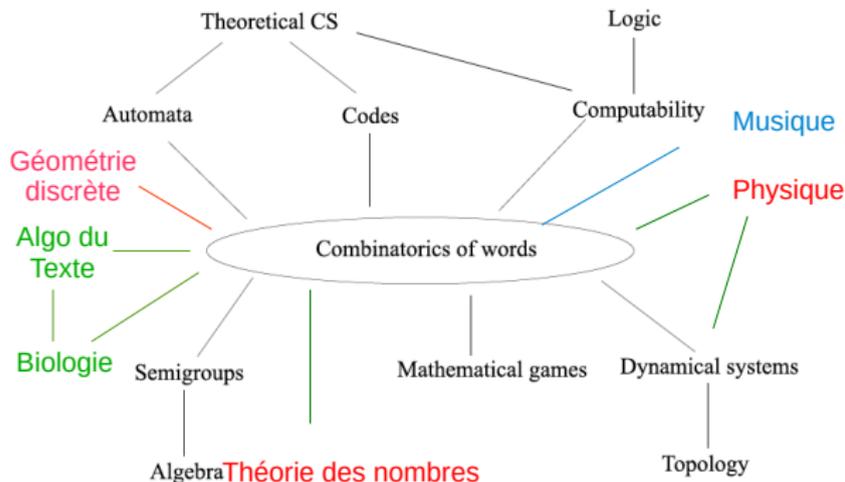
Nombres rationnels = mots dont le développement décimal est
ultimement périodique



Géométrie discrète

Exemple historique : codage de segments = mots équilibrés ;
codage de droite = mots sturmiens

Autres approches récentes : codage de plan, mots tangents, ...



Biologie :

- génôme,
- modélisation croissance plantes (L-systèmes),
- ... ,

J. Berstel, école jeunes chercheurs Marne la Vallée 2004 :
« l'algorithmique du texte est le premier étage d'une fusée
qui en comporte 3, le deuxième étant l'algorithmique du texte,
le troisième étant constitué par les applications (biologie,
traitement de texte (XML, grep, ...)) »

J. Berstel, école jeunes chercheurs Marne la Vallée 2004 :
« l'algorithmique du texte est le premier étage d'une fusée qui en comporte 3, le deuxième étant l'algorithmique du texte, le troisième étant constitué par les applications (biologie, traitement de texte (XML, grep, ...)) »

- principes d'algorithmes
Exemple : bords disjoints dans Knuth, Morris, Pratt
- analyse d'algorithmes
Exemple : les mots de Fibonacci permettent d'obtenir le délai maximal entre deux décalages de fenêtre dans KMP

Quelques exemples survolés

Mot de Thue-Morse et carrés magiques (1/2)

Mot de Thue-Morse : point fixe de

$$\mu : \begin{cases} 0 \rightarrow 01 \\ 1 \rightarrow 10 \end{cases}$$

01101001100101101001011001101001 ...

Multiplés propriétés :

- pas de chevauchement
- nème terme = parité du nombre de 1 dans écriture binaire de n

Mot de Thue-Morse et carrés magiques (2/2)

0	1	1	0	1	0	0	1	1	0	0	1	0	1	1	0
1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16

Mot de Thue-Morse et carrés magiques (2/2)

0 1 1 0 1 0 0 1 1 0 0 1 0 1 1 0
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16

	2	3	
5			8
9			12
	14	15	

Mot de Thue-Morse et carrés magiques (2/2)

0 1 1 0 1 0 0 1 1 0 0 1 0 1 1 0
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16

	2	3	
5			8
9			12
	14	15	

16	2	3	13
5	11	10	8
9	7	6	12
4	14	15	1

Mot de Thue-Morse et carrés magiques (2/2)

0 1 1 0 1 0 0 1 1 0 0 1 0 1 1 0
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16

	2	3	
5			8
9			12
	14	15	

16	2	3	13
5	11	10	8
9	7	6	12
4	14	15	1

Fonctionne pour les carrés magiques $2^n \times 2^n$ avec $n \geq 2$

Mot de Thue-Morse et carrés magiques (2/2)

0 1 1 0 1 0 0 1 1 0 0 1 0 1 1 0
1 2 3 4 5 6 7 8 9 10 11 12 13 14 15 16

	2	3	
5			8
9			12
	14	15	

16	2	3	13
5	11	10	8
9	7	6	12
4	14	15	1

Fonctionne pour les carrés magiques $2^n \times 2^n$ avec $n \geq 2$

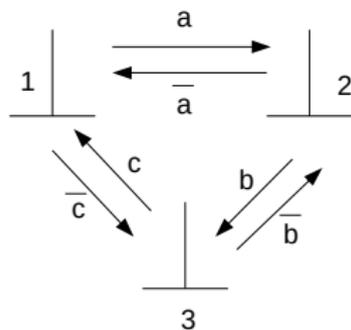


A. Adler and S.-Y. R. Li, [Magic cubes and Prouhet sequences](#)
Amer. Math. Monthly 84 (8), p618-627 (1977)



J. Berstel, A. Lauve, C. Reutenauer, F. V. Saliola
[Combinatorics on Words](#), CRM Monograph Series 27, 2009

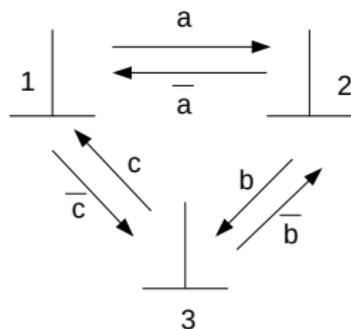
Tours de Hanoï (1/6)



Exemple : déplacement de 3 disques de 1 vers 2 va être codé par

$$a\bar{c}bac\bar{b}a$$

Tours de Hanoï (1/6)

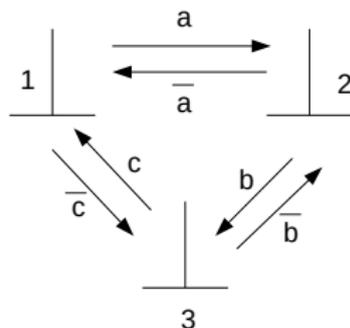


Exemple : déplacement de 3 disques de 1 vers 2 va être codé par

$$a\bar{c}bac\bar{b}a$$

Connu : déplacement optimal en $2^n - 1$ déplacement pour n disques

Tours de Hanoï (2/6)



H_n = suite de déplacements optimal pour n disques à partir de 1
(vers 2 si n pair, vers 3 si n impair)

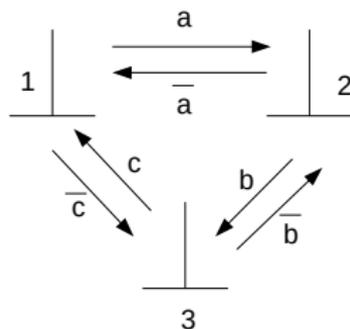
$H_0 = \varepsilon$ (mot vide)

$H_1 = a\bar{c}b$

$H_2 = a\bar{c}b a \bar{c} \bar{b} a$

$H_3 = a\bar{c}b a \bar{c} \bar{b} a \bar{c} \bar{b} a \bar{c} b a \bar{c} b$

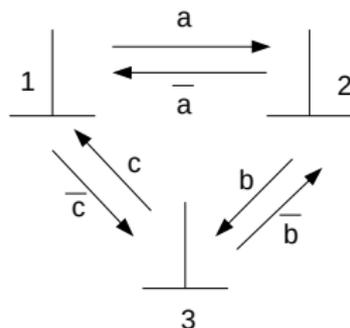
Tours de Hanoï (3/6)



Pour déplacement à partir de 2 (vers 3 ou 1 selon parité) : $\sigma(H_n)$

$$\text{où } \sigma \begin{cases} \sigma(a) = b & \sigma(\bar{a}) = \bar{b} \\ \sigma(b) = c & \sigma(\bar{b}) = \bar{c} \\ \sigma(c) = a & \sigma(\bar{c}) = \bar{a} \end{cases}$$

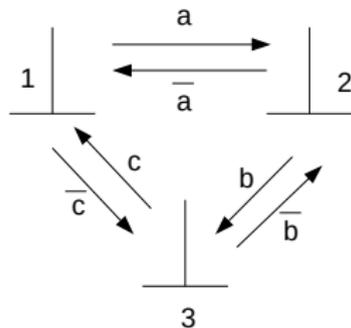
Tours de Hanoï (3/6)



Pour déplacement à partir de 2 (vers 3 ou 1 selon parité) : $\sigma(H_n)$

$$\text{où } \sigma \begin{cases} \sigma(a) = b & \sigma(\bar{a}) = \bar{b} \\ \sigma(b) = c & \sigma(\bar{b}) = \bar{c} \\ \sigma(c) = a & \sigma(\bar{c}) = \bar{a} \end{cases}$$

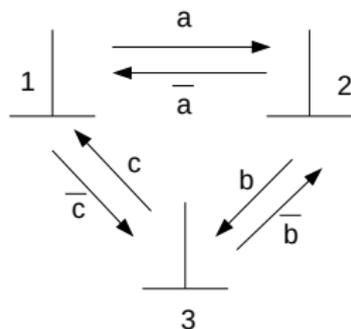
Pour déplacement de 3 vers 1 : $\sigma^2(H_n)$



Observation :

- $H_0 = \varepsilon$ (mot vide)
- $H_{2n+1} = H_{2n}a\sigma^{-1}(H_{2n})$ for $n \geq 0$
- $H_{2n} = H_{2n-1}\bar{c}\sigma(H_{2n-1})$ for $n \geq 1$

Tours de Hanoi (5/6)

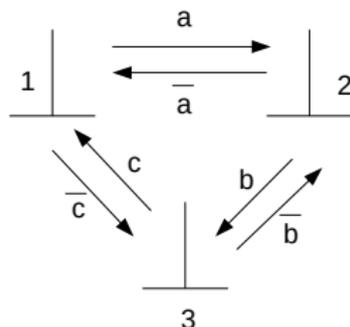


Résultat : for all $n \geq 0$:

- $\varphi(H_{2n})a = H_{2n+1}$
- $\varphi(H_{2n+1})b = H_{2n+2}$

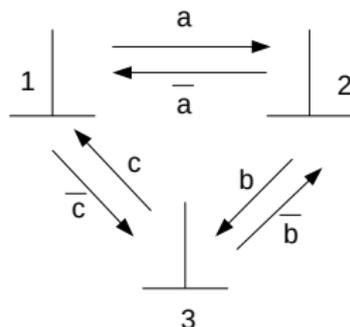
où

$$\varphi \begin{cases} a \rightarrow a\bar{c} & \bar{a} \rightarrow ac \\ b \rightarrow c\bar{b} & \bar{b} \rightarrow cb \\ c \rightarrow b\bar{a} & \bar{c} \rightarrow ba \end{cases}$$



Conclusions :

- H_n préfixe de longueur $2^n - 1$ du point fixe de φ en a
- Analyse de ce point fixe : pas de carré



Conclusions :

- H_n préfixe de longueur $2^n - 1$ du point fixe de φ en a
- Analyse de ce point fixe : pas de carré



J.P. Allouche, D. Astorian, J. Randall, J. Shallit

Morphisms and Squarefree Strings, and the Tower of Hanoi Puzzle
Amer. Math. Monthly 101 (7), 1994.

Mots et circularité (1/2)



B. Smyth

Computing Patterns in Strings, 2003

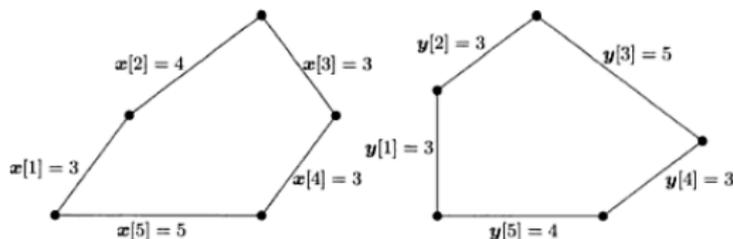


Figure 1.1. Two congruent polygons

En "computer graphics" et "computational geometry"

- représentation d'un polygone convexe par 2 chaînes
 - longueur des côtés dans ordre occurrence
 - angles dans même ordre
- problème : tester congruence (mêmes longueurs et mêmes angles)
- solution naïve : comparer un représentant d'un polygone avec tous les représentants de l'autre polygone

Mots et circularité (2/2)



B. Smyth

Computing Patterns in Strings, 2003

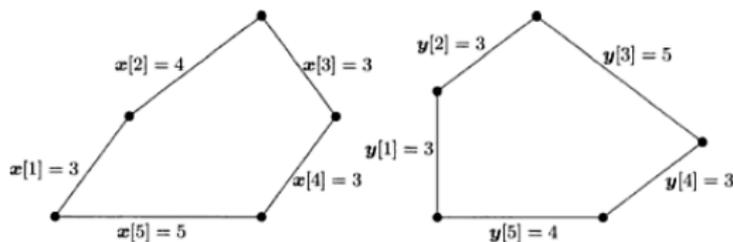


Figure 1.1. Two congruent polygons

Meilleure solution = choix d'un représentant

Mot de Lyndon = mot plus petit que ses suffixes propres dans l'ordre lexicographique.

Mots et circularité (2/2)



B. Smyth

Computing Patterns in Strings, 2003

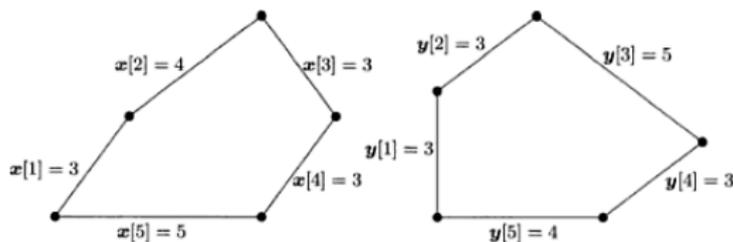


Figure 1.1. Two congruent polygons

Meilleure solution = choix d'un représentant

Mot de Lyndon = mot plus petit que ses suffixes propres dans l'ordre lexicographique.

Solution du même type optée pour un problème de placement de robots (problème d'élection de leader dans un système distribué)



Y. Dieudonné, F. Petit

Circle formation of weak robots and Lyndon words

Infor. Process. Letters 101, p156-162, 2007

Au sujet algorithmes de Burrows Wheeler (1/



S. Mantaci, A. Restivo, M. Sciortino

Burrows–Wheeler transform and Sturmian words

Infor. Process. Letters 86, p241–246, 2003

"The Burrows–Wheeler transform (BWT from now on) was introduced in 1994 by Burrows and Wheeler and it represents an extremely useful tool for textual lossless data compression.

Au sujet algorithmique de Burrows Wheeler (1/



S. Mantaci, A. Restivo, M. Sciortino

Burrows–Wheeler transform and Sturmian words

Infor. Process. Letters 86, p241–246, 2003

"The Burrows–Wheeler transform (BWT from now on) was introduced in 1994 by Burrows and Wheeler and it represents an extremely useful tool for textual lossless data compression. The idea is to apply a reversible transformation in order to produce a permutation $BWT(w)$ of an input string w , defined over an alphabet A , so that the string becomes easier to compress."



S. Mantaci, A. Restivo, M. Sciortino

Burrows–Wheeler transform and Sturmian words

Infor. Process. Letters 86, p241–246, 2003

"The Burrows–Wheeler transform (BWT from now on) was introduced in 1994 by Burrows and Wheeler and it represents an extremely useful tool for textual lossless data compression. The idea is to apply a reversible transformation in order to produce a permutation $BWT(w)$ of an input string w , defined over an alphabet A , so that the string becomes easier to compress."

Principe :

- Considérer les conjugués (permutations circulaires)
- Les trier
- $BWT(w) = \text{mot des dernières lettres}$

Au sujet algorithmes de Burrows Wheeler (2/)

Exemple : $w = abaababa$

Conjugués :

abaababa

baababaa

aababaab

ababaaba

babaabaa

abaabaab

baabaaba

aabaabab

Au sujet algorithmes de Burrows Wheeler (2/)

Exemple : $w = abaababa$

Conjugués :

abaababa

baababaa

aababaab

ababaaba

babaabaa

abaabaab

baabaaba

aabaabab

Triés :

aabaabab

aababaab

abaabaab

abaababa

ababaaba

baabaaba

baababaa

babaabaa

$$\text{BWT}(abaababa) = bbbaaaaa = b^3 a^5$$

Plus généralement : $\text{BWT}(w) = b^k a^\ell$ avec $\text{pgcd}(k, \ell) = 1 \iff w$ conjugué d'un mot standard

Approfondissons !

Qu'est-ce qu'un mot ?

- **Alphabet** : ensemble fini non vide de symboles
Attention ! A la non-ambigüité des symboles !
- **Lettre** : élément d'un alphabet.
- **Mot** : suite de lettres.
Notation : les lettres sont accolées.
(a, b, a, a, b) est noté $abaab$

Formellement, on note : $a_1 \dots a_n$ un mot constitué dans l'ordre des lettres a_1 puis a_2 puis $\dots a_n$.

- **Mot vide** : suite vide de lettres : ε .

Convention : $a_p \dots a_{p-1}$ désigne le mot vide.

- **Définition** : la **concaténation** de deux mots u et v est le mot obtenu en mettant bout à bout dans l'ordre les lettres de u puis les lettres de v .
- **Notation** : uv ou $u.v$
- **Exemples** :
($aabac$).(dab) vaut $aabacdab$
- Formellement, si $n \geq 0$ et $p \geq 0$ sont deux entiers, si $a_1, \dots, a_n, b_1, \dots, b_p$ sont des lettres, alors la concaténation des mots $a_1 \dots a_n$ et $b_1 \dots b_p$ est le mot $a_1 \dots a_n b_1 \dots b_p$.

- Propriétés de la concaténation :
 - $u\varepsilon = u = \varepsilon u$
 - $(uv)w = u(vw)$
- Propriété : l'ensemble des mots munis de la concaténation forme un monoïde.
- Monoïde : ensemble muni d'une opération interne associative possédant un élément neutre.
- Autres exemples de monoïdes : $(\mathbb{N}, +)$, (\mathbb{N}^+, \times)
- Notation de l'ensemble des mots définis sur un alphabet A :
 A^*

- **Propriété fondamentale :**

Tout mot se décompose de manière unique sur les lettres.

Plus formellement :

si $a_1, \dots, a_n, b_1, \dots, b_p$ sont des lettres alors

l'égalité $a_1 \dots a_n = b_1 \dots b_p$ implique $n = p$ et $a_i = b_i$ pour tout entier $i, 1 \leq i \leq n$.

- Le monoïde A^* est dit libre (de base A).

- Longueur d'un mot : nombre de lettres qui le composent.
- Notation : $|u|$ est la longueur de u .
- Exemple : $|abaab| = 5$
- Propriété :
 - $|\varepsilon| = 0$
 - $|uv| = |u| + |v|$

- $|u|_a$: nombre d'occurrences de a dans u
(a est une lettre, u un mot)
- Exemple : $|abaab|_a = 3$
- Propriété :
 - $|\varepsilon|_a = 0$
 - $|uv|_a = |u|_a + |v|_a$

- La longueur des mots sur un alphabet A est un *morphisme* de (A^*, \cdot) dans $(\mathbb{N}, +)$.
- Soient (M_1, \cdot_1) et (M_2, \cdot_2) deux monoïdes. Un morphisme f de M_1 dans M_2 est une application de M_1 dans M_2 qui :
 - préserve le produit :
pour tous x, y dans M_1 ,
$$f(x \cdot_1 y) = f(x) \cdot_2 f(y)$$
 - préserve l'élément neutre : l'image de l'élément neutre de M_1 est l'élément neutre de M_2 .

Morphisme de monoïdes libres

- Def. Morphisme entre deux monoïdes libres (on dira juste morphisme).
- Propriété : un morphisme de monoïdes libres est entièrement défini par l'image des lettres.
 - $f(\varepsilon) = \varepsilon$
 - $f(a_1 \dots a_n) = f(a_1) \dots f(a_n)$
- Exemple : morphisme de Fibonacci :

$$\varphi \begin{cases} a \mapsto ab \\ b \mapsto a \end{cases}$$

$$\varphi(aabab) = ababaaba$$

- Un morphisme f est injectif si pour tous mots u et v , $f(u) = f(v)$ implique $u = v$.
- Un ensemble de mots X est un code si et seulement si pour tous entiers $n \geq 0$ et $p \geq 0$, pour tous mots, $x_1, \dots, x_n, y_1, \dots, y_p$, l'égalité $x_1 \dots x_n = y_1 \dots y_p$ implique $n = p$ et pour tout i entre 1 et p , $x_i = y_i$.
- Propriété : un morphisme f défini sur un alphabet A est injectif si et seulement si $f(A)$ est un code.

. . . quelques utilisations

- Codage
- Construction simple de mots
- Explication de la structure de certains mots
- Formalisation de la notion d'équation