


COEFFICIENTS BINOMIAUX DE MOTS

Michel Rigo

<http://www.discmath.ulg.ac.be/>
16 septembre 2012

<http://orbi.ulg.ac.be/handle/2268/201779>



La notion de coefficient binomial de mots est classique en COW.
Voir, par exemple, Sakarovitch & Simon, Lothaire.

$\binom{w}{x}$ nombre de fois où x apparaît comme sous-mot de w


i.e., x apparaît comme sous-suite de w

On compte les applications

$\varphi : \{1, \dots, |x|\} \rightarrow \{1, \dots, |w|\}$ telles que

$$\varphi(1) < \dots < \varphi(|x|)$$

$$w_{\varphi(1)} \cdots w_{\varphi(|x|)} = x$$



$$\binom{aabbab}{ab} = 7$$

Généralise la notion usuelle de coefficient binomial d'entiers

$$\binom{a^m}{a^n} = \binom{m}{n}, \quad m, n \in \mathbb{N}$$

$$\text{On a } \binom{w}{a} = |w|_a, \quad a \in A$$

Ces coefficients se calculent aisément :

$$\binom{w}{\varepsilon} = 1, \quad \binom{w}{x} = 0, \quad \text{if } |w| < |x|$$


$$u, v \in A^*, a, b \in A, \quad \binom{ua}{vb} = \binom{u}{vb} + \delta_{a,b} \binom{u}{v}$$

```
coeff[u_, v_] := coeff[u, v] =  
  If[Length[v] == 0, 1,  
    If[Length[u] < Length[v], 0,  
      coeff[Drop[u, -1], v]  
      + ((Last[u] == Last[v]) /. {True -> 1, False -> 0})  
      coeff[Drop[u, -1], Drop[v, -1]]  
    ]  
  ]
```


| | ε | 1 | 10 | 11 | 100 | 101 | 110 | 111 | 1000 | \vdots | 1100 |
|---------------|---------------|---|----|----|-----|-----|-----|-----|------|----------|------|
| ε | | | | | | | | | | | |
| 1 | | | | | | | | | | | |
| 10 | | | | | | | | | | | |
| 11 | | | | | | | | | | | |
| 100 | | | | | | | | | | | |
| 101 | | | | | | | | | | | |
| 110 | | | | 1 | | | 1 | | | | |
| 111 | | | | | | | | | | | |
| 1000 | | | | | | | | | | | |
| \vdots | | | | | | | | | | | |
| 1100 | | | | | | | | 2 | | | |
| \vdots | | | | | | | | | | | |

$$\begin{pmatrix} ua \\ vb \end{pmatrix} = \begin{pmatrix} u \\ vb \end{pmatrix} + \delta_{a,b} \begin{pmatrix} u \\ v \end{pmatrix}$$


| | ε | 1 | 10 | 11 | 100 | 101 | 110 | 111 |
|---------------|---------------|----------|----|----------|-----|-----|-----|----------|
| ε | 1 | 0 | 0 | 0 | 0 | 0 | 0 | 0 |
| 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| 10 | 1 | 1 | 1 | 0 | 0 | 0 | 0 | 0 |
| 11 | 1 | 2 | 0 | 1 | 0 | 0 | 0 | 0 |
| 100 | 1 | 1 | 2 | 0 | 1 | 0 | 0 | 0 |
| 101 | 1 | 2 | 1 | 1 | 0 | 1 | 0 | 0 |
| 110 | 1 | 2 | 2 | 1 | 0 | 0 | 1 | 0 |
| 111 | 1 | 3 | 0 | 3 | 0 | 0 | 0 | 1 |



Triangle de Pascal (modulo 2) généralisé à $1\{0,1\}^*$



J. Leroy, M. R., M. Stipulanti, Generalized Pascal triangle for binomial coefficients of words, *Adv. in Appl. Math.* **80** (2016), 24—47.



c homothétie de centre $(0, 0)$ et rapport $1/2$; $h : (x, y) \mapsto (x, 2y)$.

DEFINITION

Soit $k \geq 1$. Deux mots u, v sont k -binomialement équivalents $u \equiv_k v$ si et seulement si

$$\binom{u}{x} = \binom{v}{x} \quad \forall x \in A^{\leq k}.$$

Remarque : équivalence 1-binomiale = *équivalence abélienne*.

On trouve aussi la notion de k -spectre d'un mot u .
C'est un polynôme (formel) de $\mathbb{N}\langle A^* \rangle$ de degré k

$$\text{Spec}_{u,k} = \sum_{x \in A^{\leq k}} \binom{u}{x} x.$$

Deux mots u, v sont k -binomialement équivalents SSI ils ont le même k -spectre. \rightsquigarrow **information complète**.

EXEMPLE

Le 2-spectre du mot $u = abbab$ est

$$\text{Spec}_{u,2} = 1\varepsilon + 2a + 3b + aa + 4ab + 2ba + 3bb.$$

Le 3-spectre de ce mot est

$$\text{Spec}_{u,3} = \text{Spec}_{u,2} + aab + 2aba + 3abb + 2bab + bba + bbb.$$

Notez que le k -spectre contient

$$\frac{(\#A)^{k+1} - 1}{(\#A) - 1} \text{ coefficients (éventuellement nuls).}$$

\rightsquigarrow croissance **exponentielle** en k .

$$2 + 3 = \binom{5}{1}, \quad 1 + 4 + 2 + 3 = \binom{5}{2}, \quad 1 + 2 + 3 + 2 + 1 + 1 = \binom{5}{3}$$

ababbba, *abbabab*, *baabbab*, *babaabb* sont 2-binomialement équivalents

$$|w|_a = 3, \quad |w|_b = 4, \quad \binom{w}{aa} = \binom{3}{2} = 3, \quad \binom{w}{bb} = \binom{4}{2} = 6$$


$$\binom{w}{ab} = 7, \quad \binom{w}{ba} = 5$$

mais pas 3-binomialement équivalents

$$\binom{ababbba}{aab} = 3, \quad \binom{abbabab}{aab} = 4.$$

Si $|u| \geq k \geq |x|$, alors on a

$$\binom{|u| - |x|}{k - |x|} \binom{u}{x} = \sum_{t \in A^k} \binom{u}{t} \binom{t}{x}.$$



$u \equiv_k v$ si et seulement si

$$\begin{pmatrix} u \\ x \end{pmatrix} = \begin{pmatrix} v \\ x \end{pmatrix} \quad \forall x \in A^{\leq k}.$$

COROLLAIRE

Soient $u, v \in A^{\geq k}$. On a $u \equiv_k v$ SSI $\begin{pmatrix} u \\ t \end{pmatrix} = \begin{pmatrix} v \\ t \end{pmatrix}$ pour tout mot t de longueur k .

En COW, il existe un zoologie de relations d'équivalence :

- ▶ équivalence abélienne (depuis Erdős en 1961)

$$abbacba \sim_{ab} cababba$$

- ▶ équivalence k -abélienne (Karhumäki, Saarela, Zamboni 2013)

$$|u|_x = |v|_x \quad \forall x \in A^{\leq k}$$

- ▶ équivalence cyclique ou en termes de sous-groupes de permutations (Cassaigne 2014, Charlier, Puzynina, Zamboni 2015)
- ▶ équivalence k -binomiale
- ▶ (Parikh) matrix equivalence (Salomaa *et al.* 2000)
- ▶ congruence de Simon (1975, Karandikar, Schnoebelen 2015)

$$Supp(\text{Spec}_{u,k}) = Supp(\text{Spec}_{v,k})$$

applications aux “piecewise testable languages”

Liens avec les matrices de Parikh.

$A = \{a_1, \dots, a_k\}$. Le “Parikh matrix mapping”

$$\psi_k : A^* \rightarrow \mathbb{N}^{(k+1) \times (k+1)}$$

est le morphisme défini par la condition :

si $\psi_k(a_q) = (m_{i,j})_{1 \leq i, j \leq k+1}$, alors pour tout $i \in \{1, \dots, k+1\}$,

$$m_{i,i} = 1, \quad m_{q,q+1} = 1,$$

tous les autres éléments de la matrice $\psi_k(a_q)$ étant 0.

DÉFINITION

Deux mots sont M -équivalents, ou *matrice-équivalents*, s'ils possèdent la même matrice de Parikh.

EXEMPLE, $\#A = 2$

Considérons $A = \{a, b\}$. On a

$$\psi_2(a) = \begin{pmatrix} 1 & 1 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}, \quad \psi_2(b) = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 1 \\ 0 & 0 & 1 \end{pmatrix}$$

et

$$\psi_2(abbab) = \psi_2(a)\psi_2(b)\psi_2(b)\psi_2(a)\psi_2(b) = \begin{pmatrix} 1 & 2 & 4 \\ 0 & 1 & 3 \\ 0 & 0 & 1 \end{pmatrix}.$$

Les matrices de Parikh, pour un alphabet de taille k , encodent

$$k(k+1)/2$$

coefficients binomiaux d'un mot w pour les sous-mots de longueur $\leq k$.

THÉORÈME (A. MATEESCU, A. SALOMAA, K. SALOMAA, S. YU 2001)

Soit $A = \{a_1, \dots, a_k\}$ un alphabet ordonné.

Soient w un mot fini et $\psi_k(w) = (m_{i,j})_{1 \leq i, j \leq k+1}$.

Alors

$$m_{i,j+1} = \binom{w}{a_i \cdots a_j}$$

pour tous i, j tels que $1 \leq i \leq j \leq k$.

\rightsquigarrow **information partielle** : $\mathcal{O}(k^2)$ vs. $\Omega((\#A)^k)$

Exemple sur $A = \{a, b, c\}$

$$\psi_3(w) = \begin{pmatrix} 1 & \binom{w}{a} & \binom{w}{ab} & \binom{w}{abc} \\ 0 & 1 & \binom{w}{b} & \binom{w}{bc} \\ 0 & 0 & 1 & \binom{w}{c} \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

$$\psi_3(wb) = \begin{pmatrix} 1 & \binom{w}{a} & \binom{w}{ab} & \binom{w}{abc} \\ 0 & 1 & \binom{w}{b} & \binom{w}{bc} \\ 0 & 0 & 1 & \binom{w}{c} \\ 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

Par exemple,

$$\binom{wb}{ab} = \binom{w}{a} + \binom{w}{ab}$$

Aussi, les *matrices de Parikh généralisées* ψ_u à tout mot $u \in A^*$,

Soit $u = u_1 \cdots u_\ell$.

Si $\psi_u(a) = (m_{i,j})_{1 \leq i,j \leq \ell+1}$,

alors pour tout $i \in \{1, \dots, \ell+1\}$, $m_{i,i} = 1$,

et pour tout $i \in \{1, \dots, \ell\}$,

$$m_{i,i+1} = \delta_{a, u_i},$$

les autres éléments de la matrice $\psi_u(a)$ étant nuls.

REMARQUE

On retrouve les matrices de Parikh 'classiques' avec

$$u = a_1 a_2 \cdots a_k$$

si $A = \{a_1, \dots, a_k\}$.

Il vient

$$\psi_{a b b a}(a) = \begin{pmatrix} 1 & \mathbf{1} & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & \mathbf{1} \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}, \quad \psi_{a b b a}(b) = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & \mathbf{1} & 0 & 0 \\ 0 & 0 & 1 & \mathbf{1} & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}.$$

Généralisation naturelle du théorème de Mateescu et al.

THÉORÈME (ȘERBĂNUTĂ 2004)

Soient $u = u_1 \cdots u_\ell$ et w un mot. Soit $\psi_u(w) = (m_{i,j})_{1 \leq i, j \leq \ell+1}$.
Alors, pour tout $1 \leq i \leq j \leq \ell$,

$$m_{i,j+1} = \binom{w}{u_i \cdots u_j}.$$

En particulier, la **première ligne de $\psi_u(w)$** contient les coefficients correspondant aux préfixes de u :

$$\binom{w}{\varepsilon}, \binom{w}{u_1}, \binom{w}{u_1 u_2}, \dots, \binom{w}{u_1 \cdots u_{\ell-1}}, \binom{w}{u}.$$

De même, la **dernière colonne de $\psi_u(w)$** contient les coefficients correspondant aux suffixes de u :

$$\binom{w}{u}, \binom{w}{u_2 \cdots u_\ell}, \dots, \binom{w}{u_1}, \binom{w}{\varepsilon}.$$

Exemple

$$\psi_{abba}(w) = \begin{pmatrix} 1 & \binom{w}{a} & \binom{w}{ab} & \binom{w}{abb} & \binom{w}{abba} \\ 0 & 1 & \binom{w}{b} & \binom{w}{bb} & \binom{w}{bba} \\ 0 & 0 & 1 & \binom{w}{b} & \binom{w}{ba} \\ 0 & 0 & 0 & 1 & \binom{w}{a} \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix}$$

PROPOSITION

Pour un alphabet **binaire**, deux mots sont 2-binomialement équivalents SSI ils ont la même matrice de Parikh.

$$\psi_2(w) = \begin{pmatrix} 1 & \binom{w}{a} & \binom{w}{ab} \\ 0 & 1 & \binom{w}{b} \\ 0 & 0 & 1 \end{pmatrix}$$

\Rightarrow clair !

\Leftarrow

$$\begin{aligned} \binom{w}{aa} &= \binom{|w|_a}{2} \\ \binom{w}{aa} + \binom{w}{ab} + \binom{w}{ba} + \binom{w}{bb} &= \binom{|w|}{2} \end{aligned}$$

Malheureusement, on n'a pas mieux.

Deux mots sur $\{a, b, c\}$,

$$u = abcbabcabcbab \text{ and } v = bacabbcabbcbbba$$

- ▶ non 3-binomialement équivalents : $\binom{u}{abb} = 34$ et $\binom{v}{abb} = 36$,
- ▶ MAIS même matrice de Parikh $\psi_3(u) = \psi_3(v)$.

Note : ils n'ont pas la même matrice de Parikh *généralisée*

$$\psi_{abb}(u) \neq \psi_{abb}(v).$$

En effaçant les c 's, on obtient deux mots sur $\{a, b\}$

$$u' = abbabbabbab \text{ et } v' = baabbabbbba$$

- ▶ non 3-binomialement équivalents : $\binom{u'}{abb} = 34$, $\binom{v'}{abb} = 36$
- ▶ MAIS même matrice de Parikh

$$\begin{pmatrix} 1 & 4 & 16 \\ 0 & 1 & 7 \\ 0 & 0 & 1 \end{pmatrix}$$

En effet, l'équivalence 3-binomiale est un **refinement** de l'équivalence 2-binomiale.

Enfin, deux mots sur $\{a, b, c\}$

$$u = bccaa \text{ et } v = cacab$$

- ▶ non 2-binomialement équivalents : $\binom{u}{ca} = 4$ et $\binom{v}{ca} = 3$,
- ▶ MAIS avec la même matrice de Parikh $\psi_3(u) = \psi_3(v)$.

$$\begin{pmatrix} 1 & 2 & 0 & 0 \\ 0 & 1 & 1 & 2 \\ 0 & 0 & 1 & 2 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

THÉORÈME (A. SALOMAA 2010)

Sur un alphabet **binaire** A , deux mots ont la même matrice de Parikh SSI l'un s'obtient à partir de l'autre par une suite finie de transformations de la forme

$$xabybaz \rightarrow xbayabz$$

où $a, b \in A$ et $x, y, z \in A^*$.

Valide aussi pour l'équivalence 2-binomiale.

$$1011001001011 \equiv_2 1101001000111 \equiv_2 1100110000111$$

$$\#[0 \cdots 01 \cdots 1]_{\equiv_2} = 1$$

$$\#(\{a, b\}^n / \equiv_2) = \frac{n^3 + 5n + 6}{6}$$

REMARQUE

Si $x \equiv_{k-1} y$, alors

$$pxqyr \equiv_k pyqxr$$

Cependant, il n'est pas clair que le résultat précédent puisse être généralisé

Sur 3 lettres :

$$2100221 \equiv_2 0221102$$

mais 2100221 ne peut pas être factorisé en $pxqyr$ avec $x \equiv_{ab} y$.

QUESTIONS

La notion d'évitement est classique en COW (Thue début XX^e).

- ▶ $\#A = 2$, tout mot de longueur ≥ 4 contient un **carré** uu
- ▶ $\#A = 2$, les **cubes** (et les chevauchements) peuvent être évités

abbabaabbaababbabaababbaabbabaab ...

- ▶ $\#A = 3$, les carrés peuvent être évités

(abb)(ab)(a)(abb)(a)(ab)(abb)(ab)(a)(ab)(abb)(a)(abb)(ab) ...

$0 \mapsto 012, 1 \mapsto 02, 2 \mapsto 1$

- ▶ $\#A = 3$, les **carrés abéliens** sont inévitables
- ▶ $\#A = 4$, les carrés abéliens peuvent être évités (V. Keränen)
- ▶ $\#A = 3$, les **cubes abéliens** peuvent être évités (F. M. Dekking)

QUESTIONS

On définit un carré 2-binomial uv où $u \equiv_2 v$

“carré abélien \prec carré 2-binomial $\prec \dots \prec$ carré”

- ▶ les carrés sont évitables sur 3 lettres
- ▶ les carrés abéliens sont évitables sur 4 lettres

\rightsquigarrow les carrés 2-binomiaux sont-ils évitables sur 3 lettres ?

$$0 \mapsto 012, 1 \mapsto 02, 2 \mapsto 1$$

Remarque : les carrés k -binomiaux sont évitables sur 3 lettres, $\forall k \geq 2$.

QUESTIONS

On définit un carré 2-binomial uv où $u \equiv_2 v$

“carré abélien \prec carré 2-binomial $\prec \dots \prec$ carré”

- ▶ les carrés sont évitables sur 3 lettres
- ▶ les carrés abéliens sont évitables sur 4 lettres

\rightsquigarrow les carrés 2-binomiaux sont-ils évitables sur 3 lettres ?

$$0 \mapsto 012, 1 \mapsto 02, 2 \mapsto 1$$

Remarque : les carrés k -binomiaux sont évitables sur 3 lettres, $\forall k \geq 2$.

QUESTIONS

On définit un cube 2-binomial uvw où $u \equiv_2 v$, $v \equiv_2 w$

abbabaabbaab

“cube abélien \prec cube 2-binomial $\prec \dots \prec$ cube”

- ▶ les cubes sont évitables sur 2 lettres
- ▶ les cubes abéliens sont évitables sur 3 lettres

\rightsquigarrow les cubes 2-binomiaux sont-ils évitables sur 2 lettres ?

$0 \mapsto 001, 1 \mapsto 011$

M. Rao, M. R., P. Salimov, Avoiding 2-binomial squares and cubes, *Theoret. Comput. Sci.* **572** (2015), 83–91.

On définit un cube 2-binomial uvw où $u \equiv_2 v$, $v \equiv_2 w$

abbabaabbaab

“cube abélien \prec cube 2-binomial $\prec \dots \prec$ cube”

- ▶ les cubes sont évitables sur 2 lettres
- ▶ les cubes abéliens sont évitables sur 3 lettres

\rightsquigarrow les cubes 2-binomiaux sont-ils évitables sur 2 lettres ?

$0 \mapsto 001, 1 \mapsto 011$

M. Rao, M. R., P. Salimov, Avoiding 2-binomial squares and cubes, *Theoret. Comput. Sci.* **572** (2015), 83–91.

QUESTIONS

Sakarovitch et Simon demandaient déjà d'avoir une meilleure connaissance de $\#(A^n / \sim_k)$ où \sim_k est la congruence de Simon.

- ▶ Etant donnés $k \geq 1$ et deux mots u, v de longueur n
decider, en temps polynomial en n, k , si $u \equiv_k v$.
- ▶ Etant donnés $k \geq 1$ et deux mots w, x
trouver, en temps polynomial, toutes les occurrences des facteurs de w qui sont k -binomialement équivalents à x .
- ▶ Etant donnés deux mots u, v de longueur n ,
trouver le plus grand k tel que $u \equiv_k v$.


cf. aussi *k-abelian pattern matching*, T. Ehlers, F. Manea, R. Mercas, D. Nowotka, DLT 2014. (en temps linéaire)

Idées principales du papier
'Testing k -binomial equivalence'
arXiv:1509.00622
D. Freydenberger *et al.*

On considérera uniquement la première question.


Première réponse, étant donné un mot w de longueur n et un entier k

\rightsquigarrow construire un AFND $\mathcal{A}_{w,k}$ ayant $nk + 1$ états



- ▶ tous les états sont finals,
- ▶ accepte exactement les sous-mots de w de longueur $\leq k$
- ▶ un sous-mot x est accepté $\binom{n}{x}$ fois!

$$w = abbab, k = 3$$



$$\binom{w}{abb} = 3, \quad \binom{w}{ba} = 2$$

Deux automates sont **équivalents** s'ils acceptent le *même langage avec les mêmes multiplicités*.

Etant donnés deux mots u, v

- ▶ construire $\mathcal{A}_{u,k}$ et $\mathcal{A}_{v,k}$
- ▶ $u \equiv_k v$ se réduit à ' $\mathcal{A}_{u,k}$ et $\mathcal{A}_{v,k}$ sont-ils équivalents?'

W. Tzeng, SIAM J. Computing 1992

\rightsquigarrow algorithme polynomial, au moins en $n^3 \dots$

Du résumé du papier de Tzeng :

Two probabilistic automata are equivalent if for any string x , the two automata accept x with equal probability. This paper presents an $\mathcal{O}((n_1 + n_2)^4)$ algorithm for determining whether two probabilistic automata U_1 and U_2 are equivalent, where n_1 and n_2 are the number of states in U_1 and U_2 , respectively.

- S. Kiefer, A. S. Murawski, et al. *On the complexity of the equivalence problem for probabilistic automata*, LNCS **7213** (2012), 467–481.
- M.-P. Schützenberger, *On the definition of a family of automata*, Inf. and Control, 245–270, 1961. (minimisation d'automates pondérés)

Seconde réponse, un algorithme probabiliste

DÉFINITION

Soient un mot $w \in \{0, 1\}^*$ de longueur n et un entier k ,

$$Q_{w,k}(X) := \sum_{v \in A^{\leq k}} \binom{w}{v} X^{val_2(1v)}$$

$$Q_{0010,2}(X) = X + 3X^2 + X^3 + 3X^4 + X^5 + X^6$$

Comme le k -spectre, contient **l'information complète**.

EXEMPLE

Le 2-spectre du mot *abbab* est

$$1 \underbrace{\varepsilon}_1 + 2 \underbrace{a}_{10} + 3 \underbrace{b}_{11} + \underbrace{aa}_{100} + 4 \underbrace{ab}_{101} + 2 \underbrace{ba}_{110} + 3 \underbrace{bb}_{111}.$$

$$Q_{01101,2}(X) = X + 2X^2 + 3X^3 + X^4 + 4X^5 + 2X^6 + 3X^7.$$

REMARQUE

$Q_{w,k}$ est de degré

$$\text{val}(\underbrace{11 \cdots 1}_{k \text{ fois}}) = 2^{k+1} - 1$$

\rightsquigarrow croît **exponentiellement** avec k .

REMARQUE

Deux mots u, v sont k -binomialement équivalents SSI

$$Q_{u,k}(X) = Q_{v,k}(X).$$

A première vue, il est nécessaire de calculer tous les coefficients !
(au moins la moitié d'entre eux)

Soit p un grand nombre premier (bien choisi),
 $Q_{u,k}(X)$ et $Q_{v,k}(X)$ sont vus comme des polynômes de $\mathbb{F}_p[X]$.

Si $u \not\equiv_k v$, alors $Q_{u,k}(X) - Q_{v,k}(X)$ est un polynôme non nul de degré d ayant au plus d zéros. Si on choisit $\alpha \in \mathbb{F}_p$ aléatoirement,

$$\mathbb{P}((Q_{u,k} - Q_{v,k})(\alpha) = 0) \leq d/p.$$

Si $u \equiv_k v$, alors $Q_{u,k}(X) - Q_{v,k}(X) = 0$.

Pour tout $\alpha \in \mathbb{F}_p$, $Q_{u,k} - Q_{v,k}(\alpha) = 0$

REMARQUE

Deux mots u, v sont k -binomialement équivalents SSI

$$Q_{u,k}(X) = Q_{v,k}(X).$$

A première vue, il est nécessaire de calculer tous les coefficients !
(au moins la moitié d'entre eux)

Soit p un grand nombre premier (bien choisi),
 $Q_{u,k}(X)$ et $Q_{v,k}(X)$ sont vus comme des polynômes de $\mathbb{F}_p[X]$.

Si $u \not\equiv_k v$, alors $Q_{u,k}(X) - Q_{v,k}(X)$ est un polynôme non nul de degré d ayant au plus d zéros. Si on choisit $\alpha \in \mathbb{F}_p$ aléatoirement,

$$\mathbb{P}((Q_{u,k} - Q_{v,k})(\alpha) = 0) \leq d/p.$$

Si $u \equiv_k v$, alors $Q_{u,k}(X) - Q_{v,k}(X) = 0$.

Pour tout $\alpha \in \mathbb{F}_p$, $Q_{u,k} - Q_{v,k}(\alpha) = 0$

UN ALGORITHME PROBABILISTE

En *supposant* que d/p est 'petit', on choisit aléatoirement $\alpha \in \mathbb{F}_p[X]$.

En *supposant* que l'on calcule 'facilement' $Q_{u,k}(\alpha)$ et $Q_{v,k}(\alpha)$.

- ▶ Si $Q_{u,k}(\alpha) \neq Q_{v,k}(\alpha)$, alors $u \not\equiv_k v$.
 \rightsquigarrow L'algorithme renvoie $u \not\equiv_k v$.
- ▶ Si $Q_{u,k}(\alpha) = Q_{v,k}(\alpha)$, alors *presque sûrement* $u \equiv_k v$.
 \rightsquigarrow L'algorithme renvoie $u \equiv_k v$.

On a $Q_{u,k}(\alpha) = Q_{v,k}(\alpha)$ **et** $u \not\equiv_k v$, uniquement si on a tiré un zéro du polynôme non nul $(Q_{u,k} - Q_{v,k})(X)$.

\rightsquigarrow On obtient une conclusion erronée $u \equiv_k v$ alors que $u \not\equiv_k v$, avec une probabilité d'au plus d/p .

Choix de p ?

Les coefficients in $Q_{w,k} \in \mathbb{F}_p[X]$ sont inférieurs à n^k , en effet

$$\binom{a^n}{a^k} = \binom{n}{k} = \frac{n(n-1)\cdots(n-k+1)}{k!} < n^k$$

Choisir un nombre premier
 $p \in [n^k, 2n^k]$

Ce n'est pas un problème pour obtenir un algorithme polynomial :

- ▶ AKS est polynomial en $\log(n)$
- ▶ test probabiliste de Miller–Rabin, déterministe si hypothèse de Riemann OK.

$Q_{w,k}(X)$ est de degré $2^{k+1} - 1$ et $p \geq n^k$

$$\text{probabilité d'erreur : } \frac{d}{p} \leq \frac{2^{k+1} - 1}{n^k} \xrightarrow{n \rightarrow +\infty} 0$$

Pour des mots suffisamment longs u, v , on croira volontiers l'algorithme quand il renvoie ' $u \equiv_k v$ '.

RÉSULTAT PRINCIPAL

Soit w un mot de longueur n . Soit $\alpha \in \mathbb{F}_p$.

La valeur $Q_{w,k}(\alpha)$ peut être calculée en $\mathcal{O}(k^2 n)$ opérations.

$$Q_{w,k}(X) = \sum_{|v| \leq k} \binom{w}{v} X^{\text{val}_2(1v)} = \sum_{\ell=1}^k X^{2^\ell} \left(\underbrace{\sum_{|v|=\ell} \binom{w}{v} X^{\text{val}_2(v)}}_{=: R_{w,\ell}(X)} \right)$$

\rightsquigarrow Il faut déterminer $R_{w,\ell}(\alpha)$ pour tout $\ell \in \{1, \dots, k\}$

$$w = w_1 \cdots w_n \quad w[i, n] = w_i \cdots w_n$$

On utilise la programmation dynamique pour la table $k \times n$ et les valeurs

$$R_{w[i,n],t}(\alpha), \quad i \in \{1, \dots, n\}, t \in \{1, \dots, k\}$$

| | | | | | | |
|-------------|------------------|------------------|-----|----------------|--------------------|---|
| $R_{w,k}$ | $R_{w[2,n],k}$ | $R_{w[3,n],k}$ | ... | ... | $R_{w[n,n],k}$ | 0 |
| $R_{w,k-1}$ | $R_{w[2,n],k-1}$ | $R_{w[3,n],k-1}$ | ... | ... | $R_{w[n,n],k-1}$ | 0 |
| $R_{w,k-2}$ | $R_{w[2,n],k-2}$ | $R_{w[3,n],k-2}$ | ... | ... | $R_{w[n,n],k-2}$ | 0 |
| ⋮ | ⋮ | ⋮ | | | ⋮ | ⋮ |
| ⋮ | ⋮ | ⋮ | | | ⋮ | ⋮ |
| | | | | $R_{w[i,n],t}$ | $R_{w[i+1,n],t}$ | |
| | | | | | $R_{w[i+1,n],t-1}$ | |
| ⋮ | ⋮ | ⋮ | | | ⋮ | ⋮ |
| ⋮ | ⋮ | ⋮ | | | ⋮ | ⋮ |
| $R_{w,1}$ | $R_{w[2,n],1}$ | $R_{w[3,n],1}$ | ... | ... | $R_{w[n,n],1}$ | 0 |
| 1 | 1 | 1 | ... | ... | 1 | 1 |

$$\underbrace{R_{w[n+1,n],t}}_{=\varepsilon} = 0 \text{ si } t > 0; R_{w[i,n],0} = 1 \text{ pour tout } 1 \leq i \leq n+1$$

$R_{w[i,n],t}$, $i \leq n$, $t \geq 1$,
 dépend uniquement de $R_{w[i+1,n],t}$ and $R_{w[i+1,n],t-1}$

Soient $i \leq n$, $t \geq 1$, on a

$$R_{w[i,n],t}(X) = R_{w[i+1,n],t}(X) + R_{w[i+1,n],t-1}(X), \text{ si } w_i = 0$$

$$R_{w[i,n],t}(X) = R_{w[i+1,n],t}(X) + X^{2^t} R_{w[i+1,n],t-1}(X), \text{ si } w_i = 1$$

On se souvient que

$$R_{w[i,n],t}(X) = \sum_{|v|=t} \binom{w_i \cdots w_n}{v} X^{val_2(v)}$$

$$\underbrace{R_{w[i,n],t}(X)}_{\downarrow} = R_{w[i+1,n],t}(X) + R_{w[i+1,n],t-1}(X), \text{ si } w_i = 0$$

$$\begin{aligned} & \sum_{|v|=t} \binom{0w_{i+1}\cdots w_n}{v} X^{val_2(v)} \quad v \text{ débute avec 0 ou 1} \\ &= \sum_{|u|=t-1} \binom{0w_{i+1}\cdots w_n}{0u} X^{val_2(0u)} + \sum_{|u|=t-1} \binom{0w_{i+1}\cdots w_n}{1u} X^{val_2(1u)} \\ &= \sum_{|u|=t-1} \binom{w_{i+1}\cdots w_n}{u} X^{val_2(u)} + \sum_{|u|=t-1} \binom{w_{i+1}\cdots w_n}{0u} X^{val_2(0u)} \\ &+ \sum_{|u|=t-1} \binom{w_{i+1}\cdots w_n}{1u} X^{val_2(1u)} \\ &= \overbrace{\sum_{|u|=t-1} \binom{w_{i+1}\cdots w_n}{u} X^{val_2(u)}}^{R_{w[i+1,n],t-1}(X)} \\ &+ \underbrace{\sum_{|u|=t-1} \binom{w_{i+1}\cdots w_n}{0u} X^{val_2(0u)} + \sum_{|u|=t-1} \binom{w_{i+1}\cdots w_n}{1u} X^{val_2(1u)}}_{R_{w[i+1,n],t}(X)} \end{aligned}$$

En résumé,

- ▶ Calculer un élément $R_{w[i,n],t}(\alpha)$ de la table est *une addition* dans \mathbb{F}_p et $p \sim n^k$.
Cela nécessite $\mathcal{O}(\log p) = \mathcal{O}(k \log n)$ — arithmétique des corps finis
- ▶ On doit calculer $k \times n$ éléments de ce type
 $\rightsquigarrow \mathcal{O}(k^2 n \log n)$
- ▶ Enfin, on calcule

$$Q_{w,k}(\alpha) = \sum_{\ell=1}^k \alpha^{2^\ell} R_{w,\ell}(\alpha)$$

k produits, chacun nécessitant $\mathcal{O}(\log^2 p) = \mathcal{O}(k^2 \log^2 n)$
 $\rightsquigarrow \mathcal{O}(k^3 \log^2 n)$

REFERENCES

- ▶ P. Karandikar, M. Kufleitner, Ph. Schnoebelen. On the index of **Simon's congruence** for piecewise testability, *Information Processing Letters* **15** (2015), 515–519.
- ▶ J. Mañuch, Characterization of a word by its subwords, in : G. Rozenberg, W. Thomas (Eds.), *Developments in Language Theory*, World Scientific Publ. Co., Singapore, 2000, pp. 210–219.
- ▶ A. Mateescu, A. Salomaa, K. Salomaa, Yu Sheng, A Sharpening of the Parikh Mapping, *RAIRO-Theoretical Informatics and Applications* **35** (2001), 551–564.
- ▶ M. Rigo, P. Salimov, Another generalization of abelian equivalence : Binomial complexity of infinite words, *Theoret. Comput. Sci.* **601** (2015), 47—57.

REFERENCES

- ▶ M. Rigo, Relations on words, Arxiv/1602.03364
- ▶ J. Sakarovitch, I. Simon, Subwords, in : M. Lothaire (Ed.), *Combinatorics on Words*, Addison-Wesley, Reading, MA, 1983, pp. 105–142.
- ▶ A. Salomaa, Counting (scattered) subwords, *EATCS Bull.* **81** (2003) 165–179.
- ▶ A. Salomaa, Connections between subwords and certain matrix mappings, *Theoret. Comput. Sci.* **340** (2005) 188–203.
- ▶ A. Salomaa, Criteria for the **matrix equivalence of words**, *Theoret. Comput. Sci.* **411** (2010) 1818–1827.
- ▶ T.-F. Şerbănuţă, Extending Parikh matrices, *Theoret. Comput. Sci.* **310** (2004), 23–246.

4th CANT School & Conference — CIRM, Marseille

Combinatorics, Automata and Number Theory

November 28th – December 2nd, 2016

<http://www.cant.ulg.ac.be/cant2016/>

<http://scientific-events.weebly.com/1502.html>

21th international conference DLT

Developments in Language Theory

7 – 11 August 2017

<http://www.cant.ulg.ac.be/dlt/>