



# ANNALES

DE

# L'INSTITUT FOURIER

Julien CASSAIGNE & Nataliya CHEKHOVA

**Fonctions de récurrence des suites d'Arnoux-Rauzy et réponse à une question de Morse et Hedlund**

Tome 56, n° 7 (2006), p. 2249-2270.

[http://aif.cedram.org/item?id=AIF\\_2006\\_\\_56\\_7\\_2249\\_0](http://aif.cedram.org/item?id=AIF_2006__56_7_2249_0)

© Association des Annales de l'institut Fourier, 2006, tous droits réservés.

L'accès aux articles de la revue « Annales de l'institut Fourier » (<http://aif.cedram.org/>), implique l'accord avec les conditions générales d'utilisation (<http://aif.cedram.org/legal/>). Toute reproduction en tout ou partie cet article sous quelque forme que ce soit pour tout usage autre que l'utilisation à fin strictement personnelle du copiste est constitutive d'une infraction pénale. Toute copie ou impression de ce fichier doit contenir la présente mention de copyright.

cedram

*Article mis en ligne dans le cadre du  
Centre de diffusion des revues académiques de mathématiques  
<http://www.cedram.org/>*

## FONCTIONS DE RÉCURRENCE DES SUITES D'ARNOUX-RAUZY ET RÉPONSE À UNE QUESTION DE MORSE ET HEDLUND

par Julien CASSAIGNE & Nataliya CHEKHOVA

---

RÉSUMÉ. — La fonction de récurrence  $R(n)$  d'une suite symbolique compte au bout de combien de temps on voit tous les mots de longueur  $n$ . Nous la calculons explicitement pour les suites d'Arnoux-Rauzy, définies par des conditions combinatoires qui en font une généralisation naturelle des suites sturmiennes. Puis nous répondons à une question de Morse et Hedlund (1940) en montrant que  $\frac{R(n)}{n}$  ne peut avoir une limite finie pour aucune suite non ultimement périodique.

ABSTRACT. — The recurrence function  $R(n)$  of a symbolic sequence counts how long one has to wait to see every word of length  $n$ . We compute it explicitly for the Arnoux-Rauzy sequences, which are defined by combinatorial conditions making them a natural generalization of the Sturmian sequences. We then answer a question of Morse and Hedlund (1940) by showing that  $\frac{R(n)}{n}$  cannot have a finite limit for any non-eventually periodic sequence.

Étant donnée une suite symbolique sur un alphabet fini, la *fonction de récurrence* compte la longueur minimale  $R(n)$  telle que tout facteur de longueur  $R(n)$  de la suite contienne tout facteur de longueur  $n$ . Cette fonction, qui est finie pour les suites *uniformément récurrentes*, est un des éléments qui mesurent le désordre, ou le caractère aléatoire (ou non) d'une suite. Elle a été introduite en 1940 par Morse et Hedlund [8], qui la calculent pour des suites particulières, les *suites sturmiennes*, codages naturels des rotations du tore  $\mathbb{T}^1$  ; le calcul de la fonction de récurrence d'une suite sturmiennne fait intervenir le développement en fraction continue de l'angle de la rotation associée. À la fin de leur article, Hedlund et Morse posent la question du calcul de  $R(n)$  pour d'autres suites, et demandent s'il existe

---

*Mots-clés* : dynamique symbolique, combinatoire des mots, mot infini, fonction de récurrence, suite d'Arnoux-Rauzy, graphe de Rauzy, facteur bispécial, mot singulier, mot de retour.

*Classification math.* : 37B20, 37B10, 68R15.

une suite symbolique, non ultimement périodique, pour laquelle  $\frac{R(n)}{n}$  a une limite finie.

La fonction de récurrence a fait l'objet d'études récentes par Cassaigne [5] et Durand, Host et Skau [7], montrant en particulier l'intérêt, sur le plan de la dynamique symbolique, des suites pour lesquelles  $R(n)$  est à croissance linéaire. Toutefois, il semble difficile de calculer explicitement  $R(n)$  pour une suite donnée.

Dans cet article, nous calculons explicitement la fonction de récurrence pour des généralisations naturelles des suites sturmiennes, les suites introduites dans [2] et dites depuis *suites d'Arnoux-Rauzy*. Celles-ci sont définies par certaines conditions combinatoires, et sont naturellement associées à des couples d'irrationnels pour lesquels elles fournissent un algorithme d'approximation simultanée; nous déterminons ainsi lesquelles sont à récurrence linéaire, ce qui en fait l'analogue des suites sturmiennes associées aux irrationnels à quotients partiels bornés.

En utilisant des techniques développées par Alessandri [1] et Cassaigne [3, 4], nous montrons ensuite que pour aucune suite non ultimement périodique  $\frac{R(n)}{n}$  n'a de limite finie (ou bien cette limite est infinie, ou bien cette quantité n'a pas de limite), répondant négativement à la question de Morse et Hedlund.

## 1. Préliminaires

### 1.1. Dynamique symbolique et langages formels

Soit  $\Lambda$  un alphabet fini; on considère les suites unilatérales  $u = (u_n)_{n \in \mathbb{N}}$  à valeurs dans  $\Lambda$ .

Un *mot* de longueur  $|w| = h$  est une suite finie  $w = w_1 \dots w_h$  d'éléments de  $\Lambda$ . La concaténation de deux mots  $v$  et  $w$  se note  $vw$ . Les notions de *préfixe* et *suffixe* sont définies naturellement. Le mot  $w = w_1 \dots w_h$  apparaît au rang  $i$  dans la suite  $u = (u_n)$  ou le mot  $u = u_0 \dots u_s$  si  $u_i = w_1, \dots, u_{i+h-1} = w_h$ . Le mot  $w$  est *facteur* de  $u$  s'il apparaît dans  $u$  à au moins un rang.

Si  $w$  apparaît dans un mot ou une suite aux rangs  $i$  et  $j > i$ , la *distance* entre ces deux apparitions est le nombre  $j - i$ . Si ces deux apparitions sont *consécutives*, c'est-à-dire si  $w$  n'apparaît pas aux rangs  $i + 1, \dots, j - 1$ , cette distance est appelée *lacune* ou *temps de retour* de  $w$  dans  $u$ .

Une suite  $u$  est dite *récurrente* si chacun de ses facteurs  $y$  apparaît à une infinité de rangs. Si de plus chaque facteur de  $u$   $y$  apparaît avec des lacunes bornées, la suite  $u$  est dite *minimale* ou *uniformément récurrente*.

Le langage  $F_n(u)$  est l'ensemble des facteurs de longueur  $n$  de  $u$ ; le langage  $F(u)$  est l'ensemble des facteurs de  $u$ .

La complexité d'une suite  $u$  est la fonction qui à tout entier  $n \geq 0$  associe le nombre  $p(n) = \#F_n(u)$  de facteurs de longueur  $n$ . On a toujours  $p(0) = 1$ .

Nous rappelons qu'une suite sturmienne est une suite vérifiant  $p(n) = n + 1$  pour tout  $n \geq 0$ .

DÉFINITION 1.1. — Une suite  $u = (u_n)_{n \in \mathbb{N}}$  sur l'alphabet  $\Lambda = \{0, 1, 2\}$  est une suite d'Arnoux-Rauzy si elle a les quatre propriétés suivantes :

- elle est minimale;
- elle vérifie  $p(n) = 2n + 1$  pour tout  $n \geq 0$ ;
- chaque mot de  $F_n(u)$  est préfixe d'un seul mot de  $F_{n+1}(u)$ , sauf un qui est préfixe de trois mots;
- chaque mot de  $F_n(u)$  est suffixe d'un seul mot de  $F_{n+1}(u)$ , sauf un qui est suffixe de trois mots.

### 1.2. Description du graphe de Rauzy

DÉFINITION 1.2. — Pour une suite  $u$  et un entier  $h$ , on définit le graphe de Rauzy d'ordre  $h$  de  $u$  (ou graphe des mots de longueur  $h$  de  $u$ ),  $\Gamma_h$ , de la manière suivante : les sommets sont les éléments de  $F_h(u)$ , et il y a une arête de  $w$  vers  $w'$  si  $w$  et  $w'$  apparaissent successivement dans  $u$ , c'est-à-dire si  $w = av$  et  $w' = vb$  avec  $avb$  facteur de  $u$ , pour des lettres  $a$  et  $b$  et un mot  $v$  de  $F_{h-1}(u)$ ; on étiquette cette arête par  $avb \in F_{h+1}(u)$ , et l'ensemble des arêtes est identifié à  $F_{h+1}(u)$ .

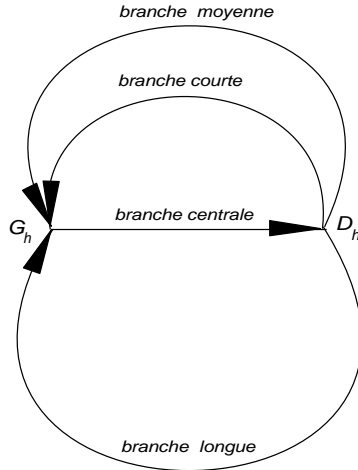
Considérons maintenant une suite d'Arnoux-Rauzy  $u$ ; ses graphes de Rauzy sont décrits dans [2]. Le graphe  $\Gamma_h$  comporte un unique sommet  $D_h$  triprolongeable à droite (trois arêtes  $D_h0$ ,  $D_h1$  et  $D_h2$  le quittent) et un unique sommet  $G_h$  triprolongeable à gauche (trois arêtes  $0G_h$ ,  $1G_h$  et  $2G_h$  y arrivent);  $D_h$  et  $G_h$  peuvent être confondus. Pour tout autre point, il y a une seule arête entrante et une seule arête sortante.

On partitionne les sommets et les arêtes de  $\Gamma_h$  en quatre branches; une branche est un ensemble de sommets et d'arêtes, et sa longueur est le nombre d'arêtes qu'elle contient.

- La branche centrale comprend le sommet  $G_h$ , l'unique arête sortant de  $G_h$ , le sommet vers lequel va cette arête, l'unique arête sortant de ce sommet, et ainsi de suite jusqu'au sommet  $D_h$  inclus; si  $D_h = G_h$ , la branche centrale est réduite au sommet  $D_h = G_h$ .

- Pour  $i = 0, 1, 2$ , la branche  $i$  comprend l'arête  $D_h i$ , le sommet vers lequel va cette arête, l'unique arête sortant de ce sommet, et ainsi de suite jusqu'au sommet  $G_h$  exclu ; si l'arête  $D_h i$  va vers  $G_h$ , la branche  $i$  est réduite à l'arête  $D_h i$ .

Nous verrons que, sauf pour les premières valeurs de  $h$ , les longueurs des trois branches 0, 1, 2 sont toujours différentes, et nous les appellerons respectivement *branche courte*, *branche moyenne* et *branche longue* (voir figure) (pour les premières valeurs de  $h$ , on choisira arbitrairement les appellations si des branches sont de même longueur). Le *circuit court*  $C_h$  (resp. *moyen*  $M_h$  et *long*  $L_h$ ) part de  $G_h$  et est composé de la branche centrale puis de la branche courte (resp. moyenne et longue). Pour éviter toute confusion avec la longueur des mots, nous noterons  $\|C_h\|$ ,  $\|M_h\|$  et  $\|L_h\|$  la longueur de ces circuits.



L'évolution des graphes  $\Gamma_h$  quand  $h$  varie est décrite dans [2]. Les sommets de  $\Gamma_{h+1}$  sont les arêtes de  $\Gamma_h$  ; si  $D_h \neq G_h$ , les sommets d'une branche de  $\Gamma_{h+1}$  sont les arêtes de la même branche de  $\Gamma_h$  (il y a *fente* d'une arête). De ce fait, la longueur de la branche centrale diminue de 1 quand on passe de  $h$  à  $h + 1$ .

Donc, pour une infinité de  $h$ , la branche centrale de  $\Gamma_h$  est de longueur 0, c'est-à-dire réduite à un sommet ; on a donc  $G_h = D_h$ , et on dit qu'il y a *éclatement*.

Les différents types d'éclatement sont décrits dans [2], voir en particulier la figure 4, mais nous introduisons ici une nouvelle terminologie ; nous disons qu'il y a un éclatement *renversant* (noté  $E_L$ ) si les sommets de la

branche centrale de  $\Gamma_{h+1}$  sont les arêtes de la branche longue de  $\Gamma_h$  ; il y a un éclatement *moyen* ( $E_M$ ) si les sommets de la branche centrale de  $\Gamma_{h+1}$  sont les arêtes de la branche moyenne de  $\Gamma_h$  ; il y a un éclatement *court* ( $E_C$ ) si les sommets de la branche centrale de  $\Gamma_{h+1}$  sont les arêtes de la branche courte de  $\Gamma_h$  ; dans les trois cas, la branche courte de  $\Gamma_{h+1}$  est réduite à une arête.

Si l'on énumère successivement les mots de longueur  $h$  apparaissant dans la suite  $u$  au rang  $i$  pour  $i = 0, \dots, n, \dots$ , on obtient un chemin infini  $\gamma_h$  dans le graphe  $\Gamma_h$ , composé d'une succession de circuits courts, moyens et longs (le premier étant éventuellement tronqué). Aussi  $\gamma_h$  peut être vu comme une suite à valeurs dans l'alphabet  $\Lambda_h = \{C_h, M_h, L_h\}$ . Si en  $h$  il y a fente,  $\gamma_h$  se déduit de  $\gamma_{h+1}$  en remplaçant  $C_{h+1}$  par  $C_h$ ,  $M_{h+1}$  par  $M_h$  et  $L_{h+1}$  par  $L_h$  ; s'il y a éclatement court,  $\gamma_h$  se déduit de  $\gamma_{h+1}$  en remplaçant  $C_{h+1}$  par  $C_h$ ,  $M_{h+1}$  par  $C_h M_h$  et  $L_{h+1}$  par  $C_h L_h$  (et en effaçant éventuellement le  $C_h$  initial) ; s'il y a éclatement moyen,  $\gamma_h$  se déduit de  $\gamma_{h+1}$  en remplaçant  $C_{h+1}$  par  $M_h$ ,  $M_{h+1}$  par  $M_h C_h$  et  $L_{h+1}$  par  $M_h L_h$  (et en effaçant éventuellement le  $M_h$  initial) ; s'il y a éclatement renversant,  $\gamma_h$  se déduit de  $\gamma_{h+1}$  en remplaçant  $C_{h+1}$  par  $L_h$ ,  $M_{h+1}$  par  $L_h C_h$  et  $L_{h+1}$  par  $L_h M_h$  (et en effaçant éventuellement le  $L_h$  initial).

Dans toute la suite, si, par abus de langage, nous parlons d'un *mot* de la branche centrale (resp. courte, moyenne, longue), il s'agira toujours d'un *sommet* de cette branche.

On note  $e_p$  l'ordre du graphe où se produit le  $p$ -ième éclatement, avec par convention  $e_0 = 0$  et  $e_1 = 1$ . On note  $c_p, m_p, \ell_p$  la longueur des circuits court, moyen et long (respectivement) *après* le  $p$ -ième éclatement, c'est-à-dire

$$\begin{aligned} c_p &= \|C_{e_p+1}\| = \|C_{e_{p+1}}\|, \\ m_p &= \|M_{e_p+1}\| = \|M_{e_{p+1}}\| \end{aligned}$$

et

$$\ell_p = \|L_{e_p+1}\| = \|L_{e_{p+1}}\|.$$

On a alors  $e_{p+1} = e_p + c_p$ . On note  $\lambda_i$  le numéro du  $i$ -ème éclatement renversant, avec par convention  $\lambda_0 = 0$ . Le premier éclatement non court est toujours considéré comme renversant (ce qui est cohérent d'après le lemme 1.4 ci-dessous) et il s'agit donc du  $\lambda_1$ -ième éclatement.

La suite des éclatements (renversants, courts ou moyens) détermine explicitement, à une permutation des lettres près, le langage de la suite

d'Arnoux-Rauzy concernée, et détermine, au moyen d'un algorithme d'approximation simultanée, un couple d'irrationnels  $(\alpha, \beta)$ ; voir [2] pour plus de détails.

Une suite d'Arnoux-Rauzy particulière est la *suite de Tribonacci*, voir par exemple [10] et [6], définie comme le *point fixe* de la substitution  $0 \rightarrow 01$ ,  $1 \rightarrow 02$ ,  $2 \rightarrow 0$ . Dans ce cas particulier, tous les éclatements sont des éclatements renversants  $E_L$ .

### 1.3. Longueurs des circuits

LEMME 1.3. — Dans  $\Gamma_1$ , les longueurs des circuits sont  $c_0 = 1$ ,  $m_0 = 2$  et  $\ell_0 = 2$ . Ensuite; les longueurs des circuits court, moyen et long sont inchangées entre  $\Gamma_h$  et  $\Gamma_{h+1}$  si en  $h$  il y a fente. Si en  $h = e_p$  il y a éclatement :

– si l'éclatement est un  $E_L$ , on a :

$$c_p = \ell_{p-1}, \quad m_p = \ell_{p-1} + c_{p-1} \quad \text{et} \quad \ell_p = \ell_{p-1} + m_{p-1},$$

– si l'éclatement est un  $E_M$ , on a :

$$c_p = m_{p-1}, \quad m_p = m_{p-1} + c_{p-1} \quad \text{et} \quad \ell_p = \ell_{p-1} + m_{p-1},$$

– si l'éclatement est un  $E_C$ , on a :

$$c_p = c_{p-1}, \quad m_p = m_{p-1} + c_{p-1} \quad \text{et} \quad \ell_p = \ell_{p-1} + c_{p-1}.$$

*Démonstration.* — Immédiate d'après la description précédente.  $\square$

LEMME 1.4. — Pour les suites d'Arnoux-Rauzy,

- les trois circuits de  $\Gamma_h$  ont des longueurs différentes sauf pour les premières valeurs de  $h$ ,  $h \leq \lambda_1$ ,
- il y a une infinité d'éclatements renversants.

*Démonstration.* — Tant que les éclatements sont des  $E_C$ , les deux circuits les plus longs ont même longueur : pour  $0 \leq p < \lambda_1$ , on a  $e_p = p$ ,  $c_p = 1$  et  $m_p = \ell_p = p + 2$ . Dès qu'il y a un éclatement autre que  $E_C$ , ces longueurs deviennent différentes :  $e_{\lambda_1} = \lambda_1$ ,  $c_{\lambda_1} = \lambda_1 + 1$ ,  $m_{\lambda_1} = \lambda_1 + 2$ ,  $\ell_{\lambda_1} = 2\lambda_1 + 2$ . Et en vertu des formules du lemme 1.3, dès que les longueurs des trois circuits deviennent différentes, elles le resteront après tous les éclatements ultérieurs. Notons qu'il n'est pas possible que tous les éclatements soient des  $E_C$ , car si c'était le cas la suite serait en fait triviale, 0000..., 1111... ou 2222..., et ce ne sont pas des suites d'Arnoux-Rauzy.

Si, pour  $h > h_0$ , on n'a plus que des éclatements  $E_M$  ou  $E_C$ , on vérifie que les mots de la branche longue de  $\Gamma_{h_0}$  n'apparaissent plus ultérieurement que dans les circuits longs, donc apparaissent dans  $u$  avec des lacunes supérieures à la longueur des autres circuits, ce qui contredit la minimalité. □

## 2. Fonction de récurrence

**DÉFINITION 2.1.** — *La fonction de récurrence d'une suite  $u$  est la fonction, notée  $R(n)$ , qui à un entier  $n \geq 1$  associe le plus petit entier  $r$  (ou  $+\infty$ , si un tel  $r$  n'existe pas) tel que tout mot de  $F_n(u)$  apparaisse dans tout mot de  $F_r(u)$ .*

Un nombre  $t$  est un *temps de retour* d'un mot  $w$  dans  $u$  si  $t$  est la distance entre deux apparitions consécutives de  $w$  dans  $u$ . On appelle *temps de retour maximal*, noté  $t(w)$ , d'un mot  $w$  dans  $u$ , la distance maximale entre deux apparitions consécutives de  $w$  dans  $u$  ( $t(w) = +\infty$  si cette distance est non bornée), et on note  $r(n)$  le maximum des  $t(w)$  pour tous les mots  $w \in F_n(u)$ . Si  $u$  est minimale,  $r(n)$  et  $t(w)$  sont toujours finis.

On appelle *mot singulier* tout facteur  $w = xvy$  de  $u$ , tel que  $x$  et  $y$  soient des lettres et qu'il existe  $x' \neq x, y' \neq y$  telles que  $x'vy$  et  $xvy'$  apparaissent dans  $u$ . Par convention, tout mot de longueur 1 est aussi singulier.

L'article [5] précise une méthode générale, essentiellement due à Morse et Hedlund [8], pour calculer la fonction de récurrence d'une suite. La première partie du lemme suivant figure déjà dans la thèse de Mouline [9]; la démonstration que nous donnons provient de [5], propositions 2 et 3.

**LEMME 2.2.** — *Les fonctions  $R$  et  $r$  sont liées, pour tout  $n \geq 1$ , par*

$$R(n) = r(n) + n - 1.$$

Pour  $n \geq 1$ ,

$$r(n) = \max_{w \in S_n(u)} t(w),$$

où  $S_n(u)$  est l'ensemble des mots singuliers de  $u$  de longueur inférieure ou égale à  $n$ .

*Démonstration* [5]. — Soit  $w$  un facteur de longueur  $n$  de  $u$  tel que  $t(w) = r(n)$ . Si  $m \geq r(n) + n - 1$ , tout mot de  $F_m(u)$  doit contenir tout mot de  $F_n(u)$ ; et, si  $m < r(n) + n - 1$ , on trouve un mot de  $F_m(u)$  qui ne contient pas  $w$ , d'où le premier résultat.



On pose  $r_0(n) = \max_{w \in S_n(u)} t(w)$ ; comme le temps de retour maximal d'un mot est au moins égal à celui de ses préfixes,  $r_0(n) \leq r(n)$ . Si

$$r(n) > r(n-1),$$

soit  $w = xvy$  de longueur  $n$  tel que  $r(n) = t(w)$ . Comme

$$t(xv) \leq r(n-1) < r(n) = t(w),$$

il existe des apparitions de  $xv$  suivies d'une autre lettre que  $y$ , et de même il existe des apparitions de  $vy$  précédées d'une autre lettre que  $x$ ;  $w$  est donc un mot singulier et donc  $r(n) \leq r_0(n)$ . Il en est de même si  $n = 1$ . Enfin, si  $r(n) = r(n-1)$ , on choisit le plus petit  $n' \geq 1$  tel que

$$r(n) = r(n'),$$

et

$$r(n) = r(n') = r_0(n') \leq r_0(n),$$

d'où le deuxième résultat.  $\square$

LEMME 2.3. — *Soit  $u$  une suite d'Arnoux-Rauzy. Alors tout mot singulier de  $u$  autre que les lettres est de longueur  $e_{p-1} + 2$  pour un certain  $p \geq 1$ , et son temps de retour maximal  $r_p$  est :*

- si le  $p$ -ième éclatement est un  $E_C$ ,  $r_p = \ell_p$ ,
- si le  $p$ -ième éclatement est un  $E_L$  ou un  $E_M$  et si le  $a(p)$ -ième éclatement, défini comme le premier éclatement  $E_L$  ou  $E_M$  après le  $p$ -ième éclatement, est un  $E_M$ ,  $r_p = \ell_{a(p)}$ ,
- si le  $p$ -ième éclatement est un  $E_L$  ou un  $E_M$  et si le  $a(p)$ -ième éclatement est un  $E_L$ ,  $r_p = \ell_{b(p)}$ , où le  $b(p)$ -ième éclatement est le premier éclatement  $E_L$  après le  $a(p)$ -ième éclatement.

Les mots singuliers de longueur 1, c'est-à-dire les lettres de l'alphabet, ont pour temps de retour maximal 2,  $\ell_{\lambda_1}$  et  $r_0 = \ell_{\lambda_2}$ .

*Démonstration.* — Par définition,  $w$  est un mot singulier de longueur  $n \geq 2$  si et seulement s'il est l'unique arête d'une branche (autre que la branche centrale) de  $\Gamma_{n-1}$ , ce qui ne peut se produire que juste après un éclatement : il existe  $p \geq 1$  tel que  $n-1 = e_{p-1} + 1$ . Comme seule la branche courte de  $\Gamma_{e_{p-1}+1}$  est de longueur 1, il n'y a qu'un seul mot singulier de longueur  $n$ .

Dans  $\Gamma_{n-1}$ , le mot singulier  $w$  est une arête du circuit court  $C = C_{n-1}$ , et n'est une arête d'aucun des autres circuits,  $M = M_{n-1}$  et  $L = L_{n-1}$ .

La suite  $u$  correspond à un chemin infini  $\gamma = \gamma_{n-1}$  dans le graphe  $\Gamma_{n-1}$ ; ce chemin est une suite de circuits  $C$ ,  $L$  et  $M$ , et on peut donc le considérer comme une suite infinie à valeurs dans l'alphabet  $\Lambda' = \{C, L, M\}$ ; deux

apparitions consécutives de  $w$  dans  $u$  correspondent à deux apparitions consécutives de  $C$  dans  $\gamma$ . Nous allons donc étudier ces apparitions dans la suite  $\gamma$ .

Si l'éclatement suivant, l'éclatement  $p$ , est un  $E_C$ , alors le chemin  $\gamma$  est une concaténation de mots (sur  $\Lambda'$ )  $C, CM, CL$ ; on trouve  $C$  dans tous ces mots, et on voit toujours  $C$  après  $CM$  ou  $CL$ ; le plus long temps de retour possible pour le mot  $w$  est donc la longueur du circuit  $CL$ , soit

$$t(w) = \|CL\| = c_{p-1} + \ell_{p-1} = \ell_p.$$

Si l'éclatement  $p$  est un  $E_L$  ou  $E_M$ ,  $\gamma$  est une concaténation respectivement de  $C' = L, M' = LC, L' = LM$  ou de  $C' = M, M' = MC, L' = ML$ . Dans les deux cas, deux apparitions consécutives de  $w$  dans  $u$  correspondent à deux apparitions consécutives de  $C$  dans  $\gamma$ , donc de  $M'$ .

Le prochain éclatement  $E_L$  ou  $E_M$  est le  $a(p)$ -ième éclatement; soit  $h = e_{a(p)}$ . La suite  $u$  correspond à un chemin infini  $\gamma_h$  dans  $\Gamma_h$ . Comme tous les éclatements entre le  $p$ -ième et le  $a(p)$ -ième sont des  $E_C$ ,  $\gamma$  se déduit de  $\gamma_h$  en remplaçant  $C_h$  par  $C', M_h$  par  $C'^{a(p)-p-1}M'$  et  $L_h$  par  $C'^{a(p)-p-1}L'$ , le premier mot pouvant être tronqué à gauche. Deux apparitions consécutives de  $w$  dans  $u$  correspondent à deux apparitions consécutives de  $M'$  dans  $\gamma$ , donc à deux apparitions consécutives de  $M_h$  dans  $\gamma_h$ .

Si l'éclatement  $a(p)$  est un  $E_M$ ,  $\gamma_h$  est une concaténation de mots  $M_h, M_hC_h, M_hL_h$ ; on trouve  $M_h$  dans tous ces mots, et on voit toujours  $M_h$  après  $M_hC_h$  ou  $M_hL_h$ ; le plus long temps de retour possible pour le mot  $w$  est donc la longueur du circuit  $M_hL_h$ , soit  $t(w) = \|M_hL_h\| = \ell_{a(p)}$ .

Si l'éclatement  $a(p)$  est un  $E_L$ ,  $\gamma_h$  est une concaténation de  $C'' = L_h, M'' = L_hC_h, L'' = L_hM_h$ , et deux apparitions consécutives de  $w$  dans  $u$  correspondent à deux apparitions consécutives de  $M_h$  dans  $\gamma_h$ , donc de  $L''$ . On regarde alors l'éclatement  $b(p)$ , le premier éclatement renversant après le  $a(p)$ -ième éclatement (cet éclatement existe grâce au lemme 1.4), et le chemin  $\gamma_k$  avec  $k = e_{b(p)}$ . Les éclatements précédents étant des  $E_C$  ou  $E_M$ ,  $\gamma_h$  se déduit de  $\gamma_k$  en remplaçant  $C_k, M_k$  et  $L_k$  par des mots  $C''', M'''$  et  $L'''$  respectivement (le premier mot pouvant être tronqué à gauche), où la seule occurrence de  $L''$  et donc de  $M_h$  est dans  $L'''$ . Deux apparitions consécutives de  $w$  dans  $u$  correspondent donc à deux apparitions consécutives de  $L_k$  dans  $\gamma_k$ . Puisque l'éclatement  $b(p)$  est renversant,  $\gamma_k$  est une concaténation de  $L_k, L_kC_k, L_kM_k$ , et on trouve toujours  $L_k$  après  $L_kC_k$  ou  $L_kM_k$ ; le plus long temps de retour possible pour le mot  $w$  est donc  $t(w) = \|L_kM_k\| = \ell_{b(p)}$ .

Parmi les lettres de l'alphabet, l'une est triprolongeable à gauche et à droite : par exemple  $0 = G_1 = D_1$ . La suite  $u$  se factorise alors sur

$\{0, 01, 02\}$ , et on a donc  $t(0) = 2$ . Après un certain nombre d'éclatements courts, on arrive à  $\Gamma_{\lambda_1}$  dont les circuits sont étiquetés par  $0, 0^{\lambda_1}1, 0^{\lambda_1}2$ ; l'éclatement suivant est renversant, et donne (en prenant  $0^{\lambda_1}1$  comme circuit long) les circuits  $0^{\lambda_1}1, 0^{\lambda_1}10, 0^{\lambda_1}10^{\lambda_1}2$ , donc  $t(1) = 2\lambda_1 + 2 = \ell_{\lambda_1}$ . Enfin, pour que 2 apparaisse dans tous les circuits, il faut attendre l'éclatement renversant suivant, et  $t(2) = \ell_{\lambda_2}$ .  $\square$

PROPOSITION 2.4. — Soient  $u$  une suite d'Arnoux-Rauzy et  $R(n)$  sa fonction de récurrence. On note  $e_p$  la longueur des mots au moment du  $p$ -ième éclatement,  $\ell_p$  la longueur du circuit long après cet éclatement,  $\lambda_i$  le numéro du  $i$ -ième éclatement renversant, et  $\mu_i$  le numéro du dernier éclatement moyen ou renversant précédant l'éclatement  $\lambda_i$  (avec par convention  $e_{-1} = -1, e_0 = 0$  et  $\lambda_0 = \mu_1 = 0$ ). Alors, pour tout  $i \geq 1$ , et pour tout  $n$  compris entre  $e_{\mu_i-1} + 2$  et  $e_{\mu_{i+1}-1} + 1$ , on a  $R(n) = n - 1 + \ell_{\lambda_{i+1}}$ .

Démonstration. — Montrons pour commencer que seuls les mots singuliers correspondant au troisième cas du lemme 2.3, et ceux de longueur 1, ont une influence sur la fonction de récurrence; ces mots singuliers sont précisément ceux dont la longueur est de la forme  $e_{\mu_i-1} + 2$  (ce qui inclut les lettres, pour  $i = 1$ ).

Soient  $w$  un mot singulier qui n'est pas de ce type, et  $p \geq 1$  tel que  $|w| = e_{p-1} + 2$ . Le temps de retour de  $w$  est, d'après le lemme 2.3, soit  $\ell_p$ , soit  $\ell_{a(p)}$ , donc  $t(w) \leq \ell_{a(p)}$  puisque la suite  $(\ell_i)$  des longueurs des circuits longs est strictement croissante. Si  $p < \lambda_1$ , alors  $w$  est dans le premier cas du lemme 2.3 et  $t(w) = \ell_p < \ell_{\lambda_2} = t(w')$ , où  $w'$  est la lettre qui maximise le temps de retour.

Si  $p \geq \lambda_1$ , soit  $p' \leq p$  maximal tel que le  $p'$ -ième éclatement soit renversant (éventuellement  $p' = p$ , et en tout cas  $p' \geq \lambda_1$ ). Si  $p' = \lambda_1$ , alors  $a(p) < \lambda_2$  et on a  $t(w) \leq \ell_{a(p)} < \ell_{\lambda_2} = t(w')$ , où  $w'$  est la lettre qui maximise le temps de retour, comme ci-dessus. Si  $p' > \lambda_1$ , soit  $q$  le numéro du dernier éclatement  $E_M$  ou  $E_L$  précédant le  $p'$ -ième éclatement, et  $w'$  le mot singulier de longueur  $e_{q-1} + 2$ : ce mot singulier  $w'$  est dans le troisième cas du lemme 2.3, et  $b(q) \geq a(p)$ , donc  $t(w) \leq \ell_{a(p)} \leq \ell_{b(q)} = t(w')$ .

On a donc, pour tout  $n \geq 1$ ,

$$r(n) = \max_{w \in S'_n} t(w),$$

où  $S'_n$  est l'ensemble des mots singuliers de longueur au plus  $n$  qui sont soit des lettres, soit dans le troisième cas du lemme 2.3.

Si  $e_{\mu_i-1} + 2 \leq n \leq e_{\mu_{i+1}-1} + 1$ , on a  $\max_{w \in S'_n} t(w) = \ell_{b(\mu_i)} = \ell_{\lambda_{i+1}}$ , d'où le résultat.  $\square$

Ces formules permettent de calculer explicitement la fonction  $R(n)$  pour une suite d'Arnoux-Rauzy définie par sa suite d'éclatements ; par exemple, on retrouve immédiatement le cas particulier de Tribonacci [6].

La proposition précédente implique :

COROLLAIRE 2.5. — Pour une suite d'Arnoux-Rauzy,

$$\limsup_{n \rightarrow +\infty} \frac{R(n)}{n} < +\infty$$

si et seulement si le nombre d'éclatements entre deux  $E_L$  consécutifs,  $\lambda_{i+1} - \lambda_i$ , est borné.

Démonstration. — Supposons d'abord que  $\lambda_{i+1} - \lambda_i \leq A$  pour tout  $i \geq 0$ . On a alors  $\lambda_{i+1} - \mu_i \leq 2A$ . Pour tout  $p$ ,  $e_{p+1} = e_p + c_p$  avec  $c_p \leq \ell p - 1 = \|L_{e_p}\| \leq 2e_p$  (la somme des longueurs des branches de  $\Gamma_{e_p}$  est  $2e_p + 2$ , puisque  $u$  est de complexité  $2n + 1$ , donc la branche longue est au plus de longueur  $2e_p$ ), donc  $e_{p+1} \leq 3e_p$ , et  $e_{\lambda_{i+1}+1}/e_{\mu_i-1} \leq 3^{2A+2}$ . Si  $e_{\mu_i-1} + 2 \leq n \leq e_{\mu_{i+1}-1} + 1$ ,  $R(n) = n - 1 + \ell\lambda_{i+1}$  par la proposition 2.4, donc  $R(n)/n \leq 1 + \ell\lambda_{i+1}/e_{\mu_i-1} \leq 1 + 2e_{\lambda_{i+1}+1}/e_{\mu_i-1} \leq 1 + 2 \cdot 3^{2A+2}$ .

Dans le cas contraire, pour tout  $A$  fixé, il existe  $i$  tel que  $\lambda_{i+1} - \lambda_i > A$  : le  $\lambda_i$ -ème éclatement, renversant, est suivi de  $A$  éclatements non renversants. Soit  $n = e_{\mu_i-1} + 2$  : par la proposition 2.4,  $R(n) = n - 1 + \ell\lambda_{i+1}$ . Comme l'éclatement  $\lambda_i$  est renversant, on a, par le lemme 1.3,  $c_{\lambda_i} = \ell\lambda_i - 1 = \|L_{e_{\lambda_i}}\| \geq (2e_{\lambda_i} + 4)/3$  (la somme des longueurs des branches de  $\Gamma_{e_{\lambda_i}}$  est  $2e_{\lambda_i} + 2$ , et la branche centrale est de longueur 0 tandis que la branche longue est strictement plus longue que les deux autres). Après les  $A$  éclatements suivants, on a  $\ell\lambda_i + A \geq \ell\lambda_i + Ac_{\lambda_i}$  (avec égalité si tous ces éclatements sont courts), donc  $\ell\lambda_i + A \geq (2e_{\lambda_i} + 4)A/3$ . Ainsi

$$\frac{R(n)}{n} \geq \frac{\ell\lambda_{i+1}}{e_{\mu_i-1} + 2} \geq \frac{\ell\lambda_i + A}{e_{\lambda_i} + 2} \geq \frac{2A}{3} :$$

$R(n)/n$  n'est pas borné. □

En adoptant la terminologie de [7], conçue par analogie avec le cas des suites sturmiennes, on pourra appeler *suite d'Arnoux-Rauzy à quotients partiels bornés* toute suite d'Arnoux-Rauzy telle que le nombre d'éclatements entre deux  $E_L$  consécutifs est borné.

### 3. Réponse à une question de Morse et Hedlund

Le résultat suivant ne concerne pas particulièrement les suites d'Arnoux-Rauzy, mais répond à une question datant de 1940 [8] : existe-t-il des suites

non triviales pour lesquelles  $\frac{R(n)}{n}$  a une limite finie? Pour cela, nous supposons d'abord que l'alphabet  $\Lambda$  a deux lettres (qu'on notera 0 et 1), et montrons une série de lemmes, dont nous déduirons le résultat pour les suites sur deux lettres. Nous l'étendrons ensuite à  $k$  lettres par un procédé de codage.

Un facteur  $v$  de  $u$  est dit *spécial* à droite (resp. à gauche) s'il existe des lettres  $x$  et  $y$  ( $x \neq y$ ) telles que les mots  $vx$  et  $vy$  (resp.  $xv$  et  $yv$ ) sont aussi facteurs de  $u$ .

Pour tout  $n$ , on note  $s(n)$  le nombre de facteurs spéciaux à droite de  $u$  de longueur  $n$ , qui est aussi le nombre de facteurs spéciaux à gauche de longueur  $n$  si la suite  $u$  est récurrente (ce qui est toujours vrai des suites qui nous intéressent ici). On a alors  $s(n) = p(n+1) - p(n)$ , voir [4].

LEMME 3.1. — Si  $\limsup \frac{R(n)}{n} < +\infty$ , pour tout  $n$  la suite  $u$  a un nombre borné par une constante  $k$  de facteurs spéciaux à droite de longueur  $n$ .

*Démonstration.* — Si l'hypothèse est vérifiée, alors il existe  $a$  tel que  $R(n) \leq an$ ; comme tous les  $p(n)$  facteurs de longueur  $n$  de  $u$  apparaissent dans un même mot de longueur  $R(n)$ , on a  $p(n) \leq R(n) - n + 1 \leq an$ ; en vertu d'un résultat de Cassaigne [3], la quantité  $s(n) = p(n+1) - p(n)$  est donc bornée par une constante  $k$ ; or  $s(n)$  n'est autre que le nombre de facteurs spéciaux à droite de longueur  $n$ .  $\square$

DÉFINITION 3.2. —

- On appelle mots de retour d'un facteur  $w$  de  $u$  les mots  $u_{s+q} \dots u_{t+q-1}$ , où  $u_s \dots u_{s+q-1}$  et  $u_t \dots u_{t+q-1}$  sont deux apparitions consécutives de  $w$ .
- On appelle chemin élémentaire d'ordre  $n$  un mot  $c' = u_{s+n} \dots u_{t+n-1}$ , où  $u_s \dots u_{s+n-1} = d'$  est spécial à droite,  $u_t \dots u_{t+n-1} = d''$  est spécial à droite, et il n'y a pas d'apparition de facteur spécial à droite de longueur  $n$  entre  $s+1$  et  $t-1$ .

On peut aussi voir un chemin élémentaire comme mot de retour de l'ensemble des facteurs spéciaux à droite.

LEMME 3.3. — Le nombre de chemins élémentaires est exactement  $2s(n)$ .

*Démonstration.* — On sait qu'il y a exactement  $s(n)$  facteurs spéciaux à droite, et de chacun partent exactement deux chemins élémentaires.  $\square$

Les lemmes 3.4 et 3.5 sont démontrés indépendamment (avec des meilleures constantes) dans [7].

LEMME 3.4. — Si  $\limsup \frac{R(n)}{n} < +\infty$  et si la suite  $u$  n'est pas ultimement périodique, il existe  $0 < b < a$  tels que, si  $w$  est un facteur de longueur  $n$ , tous ses temps de retour sont compris entre  $bn$  et  $an$ .

Démonstration. — On sait déjà que  $R(n) \leq an$  pour tout  $n \geq 1$  et donc  $r(n) \leq an$ , où  $a = \sup_n \frac{R(n)}{n}$ . Il nous reste à minorer le plus petit temps de retour. Comme  $u$  est non ultimement périodique,  $p(n) \geq n + 1$  pour tout  $n$ , d'après [8]. Soit  $m = \lfloor \frac{n}{a} \rfloor$ .

Il y a au moins  $m + 1$  facteurs de longueur  $m$ , dont au plus  $k$  sont spéciaux à droite. D'après le lemme 3.3, il y a donc au plus  $2k$  chemins élémentaires. Soit  $(w_0, \dots, w_\ell)$  le plus long de ces chemins.  $w_1, \dots, w_\ell$  sont alors  $\ell$  facteurs différents de longueur  $m$  tels que

- $\ell \geq \frac{m+1}{2k}$ ,
- la  $j$ -ème lettre de  $w_{i+1}$  est la  $(j + 1)$ -ième lettre de  $w_i$ , pour  $1 \leq j \leq m - 1, 1 \leq i \leq \ell - 1$ ,
- les  $w_i$  ne sont pas spéciaux à droite pour  $1 \leq i \leq \ell - 1$ , tandis que  $w_\ell$  est spécial à droite.

Par conséquent, toute apparition de  $w_1$  est suivie d'apparitions de  $w_2, \dots, w_\ell$ , et tout temps de retour de  $w_1$  est au moins  $\ell$ .

Mais tout mot de longueur  $n$  contient  $w_1$ , car  $R(\lfloor \frac{n}{a} \rfloor) \leq a \lfloor \frac{n}{a} \rfloor \leq n$ ; donc tout mot de longueur  $n$  a tous ses temps de retour supérieurs à  $\ell \geq \frac{m+1}{2k}$ . Comme  $m = \lfloor \frac{n}{a} \rfloor > \frac{n}{a} - 1$ , on a  $\ell > \frac{n}{2ka}$ ; on peut donc prendre  $b = \frac{1}{2ka}$ .  $\square$

LEMME 3.5. — On suppose que  $\limsup \frac{R(n)}{n} < +\infty$  et que la suite  $u$  n'est pas ultimement périodique. Alors le nombre de mots de retour différents de tout facteur spécial à droite est borné par une constante  $B$ .

Démonstration. — Soient  $d$  un facteur spécial à droite de longueur  $n$  et  $c$  un mot de retour de  $d$ . On coupe  $c$  en chemins élémentaires. On a vu dans le lemme 3.3 qu'il y a exactement  $2s(n)$  chemins élémentaires et par le lemme 3.1, on a  $2s(n) \leq 2k$ . Nous qualifions de *longs* ceux dont la longueur est au moins  $\frac{bn}{k}$ , de *courts* les autres. Le chemin  $c$  est une concaténation de chemins élémentaires  $c'_1 \dots c'_\ell$ , comprenant  $\ell 1$  chemins longs et au plus  $\ell 1 + 1$  plages de chemins courts consécutifs. On a  $\ell 1 \leq \frac{ak}{b}$ , sinon  $c$  aurait une longueur supérieure à  $an$ ; chaque plage de chemins courts comprend au plus  $k$  chemins, sinon deux de ces chemins partiraient du même facteur spécial à droite, qui aurait de ce fait un temps de retour inférieur à  $bn$ . Donc  $c$  est une concaténation d'au plus  $A = \frac{ak}{b} + (\frac{ak}{b} + 1)k$  chemins élémentaires, et on ne peut construire ainsi qu'au plus  $B = (2k + 1)^A$  tels mots.  $\square$

Les deux lemmes suivants (lemmes 3.6 et 3.7) concernent toutes les suites symboliques récurrentes sur deux lettres, sans condition sur  $R(n)$ . Le premier se trouve dans [4], et sa démonstration est immédiate ; le second se trouve dans [3] et [1], et nous reproduisons intégralement sa démonstration. Nous rappelons que  $v$  est un *facteur bispécial* (c'est-à-dire spécial dans les deux directions à la fois) s'il existe des lettres  $x \neq x'$  et  $y \neq y'$  telles que  $vy, vy', xv$  et  $x'v$  sont facteurs de  $u$ . Le mot  $v$  est un *facteur bispécial strict* si  $xvy, x'vy, xvy', x'vy'$  sont facteurs, *ordinaire* si  $xvy, xvy'$  et  $x'vy'$  sont facteurs, *faible* si seuls  $xvy$  et  $x'vy'$  sont facteurs. L'ensemble des facteurs spéciaux à gauche forme un arbre infini, avec une arête de  $v$  à  $vx$  si  $x$  est une lettre et  $vx$  est spécial à gauche. Dans cet arbre, les facteurs bispéciaux stricts indiquent les embranchements et les facteurs bispéciaux faibles les extrémités des branches.

Pour tout  $n$ , on note  $bs(n)$  le nombre de facteurs bispéciaux stricts de longueur  $n$ , et  $bf(n)$  le nombre de facteurs bispéciaux faibles de longueur  $n$ .

LEMME 3.6. — *Pour tout  $n$ ,  $s(n+1) - s(n) = bs(n) - bf(n)$ .*

*Démonstration.* —  $s(n)$  augmente de un quand il y a un embranchement dans l'arbre des facteurs spéciaux à droite, et diminue de un quand il y a une extrémité.  $\square$

LEMME 3.7. — *Soient  $n_1 < n_2$  deux entiers. Le nombre de facteurs bispéciaux stricts dont la longueur est comprise entre  $n_1$  et  $n_2 - 1$  est majoré par*

$$\sum_{n=n_1}^{n_2-1} bs(n) \leq s(n_1) \left( s(n_1) + s(n_2) + 2(p(n_2+1) - p(n_1+1)) \frac{s(n_1)}{n_1} \right).$$

*Démonstration* [3, 1]. — L'ensemble des facteurs spéciaux à gauche dont la longueur est comprise entre  $n_1$  et  $n_2$  est une forêt de  $s(n_1)$  arbres binaires finis dont les branches ont une longueur inférieure ou égale à  $n_2 - n_1$  (on met une arête de  $w$  vers  $w'$  si  $w' = wa$  où  $a$  est une lettre). Cette forêt contient

$$\sum_{n=n_1}^{n_2} s(n) = p(n_2+1) - p(n_1)$$

nœuds et

$$\sum_{n=n_1+1}^{n_2} s(n) = p(n_2+1) - p(n_1+1)$$

arêtes. Elle comporte  $d = \sum_{n=n_1}^{n_2-1} bs(n)$  embranchements; il y a  $s(n_2)$  branches de longueur  $n_2 - n_1$  et  $h = \sum_{n=n_1}^{n_2-1} bf(n)$  branches qui se terminent avant d'atteindre cette longueur. De plus, d'après le lemme 3.6, on a  $s(n_2) - s(n_1) = d - h$ .

Nous allons construire une projection  $\varphi$  de cette forêt sur le graphe  $\Gamma_{n_1}$  comme suit : on envoie tout facteur spécial à gauche de longueur comprise entre  $n_1$  et  $n_2$  sur son suffixe de longueur  $n_1$ , et si une arête va de  $m$  à  $ma$ , on la projette sur l'arête de  $\Gamma_{n_1}$  qui va de  $\varphi(m)$  à  $\varphi(ma)$ .

Pour tout sommet  $v$  (resp. toute arête  $e$ ) de  $\Gamma_{n_1}$ , on note  $\pi(v)$  (resp.  $\pi(e)$ ) le nombre de nœuds (resp. d'arêtes) qui se projettent sur  $v$  (resp.  $e$ ); cette quantité est appelée *poïds* de  $v$  (resp. de  $e$ ). La somme des poids des arêtes entrantes (resp. sortantes) de  $v$  sera notée  $\pi_e(v)$  (resp.  $\pi_s(v)$ ).

Pour tout sommet  $v$  de  $\Gamma_{n_1}$ , on note de plus :

- $c(v) = 1$  si  $v$  est facteur spécial à gauche et  $c(v) = 0$  sinon,
- $t(v)$  le nombre de facteurs spéciaux à gauche de longueur  $n_2$  qui ont  $v$  pour suffixe (c'est-à-dire le nombre des branches de la forêt de longueur  $n_2 - n_1$  dont la projection se termine en  $v$ ),
- $d(v)$  le nombre de facteurs bispéciaux stricts de longueur comprise entre  $n_1$  et  $n_2 - 1$  qui se projettent en  $v$ ,
- $h(v)$  le nombre de facteurs bispéciaux faibles de longueur comprise entre  $n_1$  et  $n_2 - 1$  qui se projettent en  $v$ .

Remarquons que  $h(v)$  et  $d(v)$  ne sont non nuls que si  $v$  est spécial à droite, et alors  $h(v) \leq d(v) + 1$  puisque l'ensemble des facteurs spéciaux à droite de longueur comprise entre  $n_1$  et  $n_2$  qui ont  $v$  pour suffixe forme un arbre binaire comportant  $d(v)$  embranchements et au moins  $h(v)$  feuilles.

Pour tout sommet  $v$  de  $\Gamma_{n_1}$ , on a :

$$(3.1) \quad \pi_s(v) - \pi_e(v) = c(v) + d(v) - h(v) - t(v).$$

En effet, les seuls facteurs spéciaux à gauche qui se projettent en  $v$  et qui ne sont pas assortis d'exactlyement une arête entrante et une arête sortante sont :

- $v$  lui-même s'il est facteur spécial à gauche puisque le nœud correspondant n'a pas d'arête entrante,
- ceux qui sont facteurs bispéciaux stricts puisqu'ils ont deux arêtes sortantes,
- ceux qui sont facteurs bispéciaux faibles et ceux qui sont de longueur maximale qui n'ont pas d'arêtes sortantes.

La combinaison de ces effets donne (3.1).

Soit maintenant  $S$  un sous-graphe de  $\Gamma_{n_1}$ , c'est-à-dire un graphe constitué de certains sommets de  $\Gamma_{n_1}$  et de certaines arêtes reliant ces sommets.



Une arête qui n'est pas dans  $S$  mais dont l'origine (resp. l'arrivée) est un sommet de  $S$  sera dite sortante de  $S$  (resp. entrante dans  $S$ ). Notons alors :

- $\pi_e(S)$  le poids total des arêtes entrantes dans  $S$ ,
- $\pi_s(S)$  le poids total des arêtes sortantes de  $S$ ,
- $c(S)$  le nombre de facteurs spéciaux à gauche contenus dans  $S$ ,
- $d(S)$  le nombre de facteurs bispéciaux stricts qui se projettent sur un sommet de  $S$ ,
- $h(S)$  le nombre de facteurs bispéciaux faibles qui se projettent sur un sommet de  $S$ ,
- $t(S)$  le nombre de branches dont la projection se termine dans  $S$ .

En sommant l'égalité précédente sur tous les sommets de  $S$ , on obtient :

$$\pi_s(S) - \pi_e(S) = c(S) + d(S) - h(S) - t(S).$$

Mais comme  $h(S) \leq d(S) + s(n_1)$  (il y a au plus  $s(n_1)$  facteurs spéciaux à droite dans  $S$ ), que  $t(S) \leq s(n_2)$  (il n'y a que  $s(n_2)$  branches de longueur maximale), et que  $c(S) \geq 0$ , il vient que :

$$(3.2) \quad \pi_e(S) - \pi_s(S) \leq s(n_1) + s(n_2).$$

Les  $d$  facteurs bispéciaux stricts se projettent sur les  $s(n_1)$  facteurs spéciaux à droite de longueur  $n_1$ . Il y a donc au moins un facteur spécial à droite  $v$  de longueur  $n_1$  sur lequel se projettent au moins  $\frac{d}{s(n_1)}$  facteurs bispéciaux stricts. Notons  $e_1$  et  $e_2$  les deux arêtes sortantes de  $v$  dans  $\Gamma_{n_1}$ . Leurs poids sont au moins égaux à  $\frac{d}{s(n_1)}$ .

Soit

$$f = \frac{1}{s(n_1)} \left( \frac{d}{s(n_1)} - s(n_1) - s(n_2) \right).$$

Pour  $i = 1, 2$ , considérons le sous-graphe  $S_i$  constitué de tous les sommets qui peuvent être atteints à partir de  $v$  en empruntant d'abord  $e_i$ , puis des arêtes de poids au moins  $f$ , qui seront les arêtes de  $S_i$ .

Supposons que  $v$  n'est pas dans  $S_i$  (ce qui implique  $f > 0$ ). Notons  $q$  le nombre de sommets de degré sortant 2 contenus dans  $S_i$ ; comme  $v$  n'est pas dans  $S_i$ , on a  $q < s(n_1)$ . Puisque  $S_i$  est connexe par construction, le nombre d'arêtes sortantes de  $S_i$  est au plus  $q + 1$ . Et ces arêtes sont de poids strictement inférieurs à  $f$  puisqu'elles ne sont pas dans  $S_i$ . Le poids total des arêtes sortantes vérifie donc  $\pi_s(S_i) < (q + 1)f \leq s(n_1)f$ . Mais si  $v$  n'est pas dans  $S_i$ ,  $e_i$  est une arête entrante dans  $S_i$  et donc  $\pi_e(S_i) \geq \frac{d}{s(n_1)}$ . Il vient alors que :

$$\pi_e(S_i) - \pi_s(S_i) > \frac{d}{s(n_1)} - s(n_1)f = s(n_1) + s(n_2)$$

ce qui est exclu par (3.2).

Donc  $v$  appartient à  $S_1$  et à  $S_2$ . Il existe donc deux boucles allant de  $v$  à lui-même qui n'empruntent que des arêtes de poids au moins  $f$  ; une commençant par  $e_1$  et l'autre par  $e_2$ . Soient  $\ell_1$  et  $\ell_2$  les longueurs de ces boucles. Les deux boucles correspondent à deux mots  $w_1$  et  $w_2$  de longueurs respectives  $\ell_1$  et  $\ell_2$  tels que  $vw_1$  et  $vw_2$  ont tous les deux  $v$  comme suffixe. De plus,  $w_1$  et  $w_2$  ne commencent pas par la même lettre (puisque une boucle commence par  $e_1$  et l'autre par  $e_2$ ). Les mots  $vw_1w_2$  et  $vw_2w_1$  ont pour suffixe  $v$ , et comme  $|w_1w_2| = |w_2w_1|$  et  $w_1w_2 \neq w_2w_1$ , il vient que  $|w_1w_2| > |v|$ , c'est-à-dire que  $\ell_1 + \ell_2 > n_1$ . La réunion des deux boucles contient au moins  $\max(\ell_1, \ell_2)$  arêtes, donc au moins  $\frac{n_1}{2}$  arêtes. Il y a donc dans  $\Gamma_{n_1}$  au moins  $\frac{n_1}{2}$  arêtes de poids au moins  $f$ . Le poids total du graphe étant  $p(n_2+1) - p(n_1+1)$  (c'est le nombre d'arêtes de la forêt qu'on projette sur  $\Gamma_{n_1}$ ), il vient donc :

$$p(n_2 + 1) - p(n_1 + 1) \geq \frac{n_1}{2} f,$$

c'est-à-dire :

$$p(n_2 + 1) - p(n_1 + 1) \geq \frac{n_1}{2s(n_1)} \left( \frac{d}{s(n_1)} - s(n_1) - s(n_2) \right)$$

d'où le résultat. □

LEMME 3.8. — *On suppose que  $\limsup \frac{R(n)}{n} < +\infty$  et que la suite  $u$  n'est pas ultimement périodique. Soit  $k$  défini dans le lemme 3.1. Alors, pour tout  $n$ , et tout  $x \geq 1$ , le nombre de facteurs bispéciaux stricts de longueur comprise entre  $n$  et  $xn$  est au plus  $2xk^3$  et le nombre de facteurs bispéciaux faibles de longueur comprise entre  $n$  et  $xn$  est au plus  $2xk^3 + k$ .*

*Démonstration.* — Le résultat est trivial si  $k = 1$  ou  $n = 1$ . On suppose donc que  $k \geq 2$  et  $n \geq 2$ . Pour les bispéciaux stricts, on applique le lemme 3.7 avec  $n_1 = n$  et  $n_2 = \lfloor xn \rfloor + 1$ , sachant que  $s(n) \leq k$  pour tout  $n$  et donc  $p(n_2 + 1) - p(n_1 + 1) \leq k(n_2 - n_1)$  :

$$\begin{aligned} \sum_{i=n_1}^{n_2-1} bs(i) &\leq k \left( 2k + 2k(n_2 - n_1) \frac{k}{n_1} \right) \\ &\leq 2k^2 \left( 1 + k(x - 1 + \frac{1}{n}) \right) \leq 2k^3 x. \end{aligned}$$

On applique ensuite le lemme 3.6 pour les bispéciaux faibles. □

LEMME 3.9. — *Soient  $e$  un facteur bispécial ordinaire de longueur  $n$  et  $x \in \Lambda$  tel que  $xe$  est encore spécial à droite. Soient  $c_1, \dots, c_r$  les mots de retour de  $e$ ,  $r$  étant majoré par la constante  $B$  du lemme 3.5,  $C_1, \dots, C_r$*

les mots de retour de  $xe$ , avec  $r' \leq B$ , et  $a$  et  $b$  les constantes du lemme 3.4.

Alors :

– ou bien

$$\sum_{k=1}^{r'} |C_k| \geq \sum_{i=1}^r |c_i| + bn,$$

– ou bien

$$\sum_{k=1}^{r'} |C_k| = \sum_{i=1}^r |c_i|$$

et il existe un bispécial faible  $g$ , de longueur inférieure à  $(a+1)n$ , et qui contient  $e$  comme préfixe.

*Démonstration.* — Soit  $e$  un facteur bispécial ordinaire, alors  $e$  est précédé de  $x$  ou  $x'$ , suivi de  $y$  ou  $y'$ , mais seuls  $xy$ ,  $x'ey$  et  $xy'$  sont facteurs de  $u$ . Les mots de retour de  $xe$  sont des concaténations de mots de retour de  $e$ , et chaque mot de retour de  $e$  apparaît dans au moins un mot de retour de  $xe$ .

Si un mot de retour de  $e$  apparaît deux fois dans les mots de retour de  $xe$ , comme les autres mots de retour de  $e$  apparaissent au moins une fois, on a

$$\sum_{k=1}^{r'} |C_k| \geq \sum_{i=1}^r |c_i| + bn$$

puisque  $|c_i| \geq bn$  par le lemme 3.4.

Supposons que chaque mot de retour de  $e$  n'apparaît qu'une fois dans les mots de retour de  $xe$  de sorte que  $\sum_{k=1}^{r'} |C_k| = \sum_{i=1}^r |c_i|$ . Soit  $c$  un mot de retour de  $e$ ; si  $xec$  est facteur de  $u$ ,  $c$  apparaît au début d'un mot de retour de  $xe$ ; si  $x'ec$  est facteur,  $c$  apparaît dans un mot de retour de  $xe$ , mais précédé d'au moins un autre mot de retour de  $e$ . Comme  $c$  n'apparaît qu'une fois dans les mots de retour de  $xe$ , les mots  $xec$  et  $x'ec$  ne peuvent être tous les deux facteurs, donc  $ec$  n'est pas spécial à gauche. Soit  $d$  de longueur maximale tel que  $ed$  soit spécial à gauche : un tel  $d$  existe puisque  $e$  est spécial à gauche, et  $d$  ne peut avoir aucun mot de retour  $c$  de  $e$  comme préfixe, donc  $d$  est un préfixe propre d'un tel mot de retour et  $|d| < an$ . Le mot  $ed$  est alors bispécial faible. □

LEMME 3.10. — Si  $\limsup \frac{R(n)}{n} < +\infty$ , il existe des constantes  $Q$  et  $Q'$  telles que pour tout  $n \geq 1$  il existe deux entiers  $n \leq m < m' \leq 2n$  vérifiant

–  $m' - m \geq \frac{n}{Q'}$ ,

– le nombre de mots singuliers de longueur strictement comprise entre  $m$  et  $m'$  est au plus  $Q$ .

*Démonstration.* — Si  $u$  est ultimement périodique,  $u$  a un nombre fini de mots singuliers et le résultat est donc trivial. On suppose donc que  $u$  n'est pas ultimement périodique. Par définition, si  $w$  est un mot singulier,  $w = xvy$ , où  $v$  est un facteur bispécial strict ou ordinaire.

Par le lemme 3.8, le nombre  $N_1$  de facteurs bispéciaux stricts dont la longueur est comprise entre  $n - 1$  et  $2n - 2$  est borné par  $4k^3$ , où  $k$  est la constante définie dans le lemme 3.1, et le nombre  $N_2$  de facteurs bispéciaux faibles dont la longueur est comprise entre  $n - 1$  et  $2n - 2$  par  $4k^3 + k$  et donc  $N_2 + N_1 \leq 8k^3 + k$ . En posant  $Q' = 8k^3 + k + 1$ , on peut donc trouver  $m$  et  $m'$  tels que  $n \leq m < m' \leq 2n$ ,  $m' - m \geq \frac{n}{Q'}$  et tels qu'il n'y ait aucun facteur bispécial faible ou strict de longueur strictement comprise entre  $m - 2$  et  $m' - 2$  (notons que si  $n \leq Q'$ , c'est trivialement vrai).

Soit  $P$  le nombre de facteurs bispéciaux ordinaires dont la longueur est strictement comprise entre  $m - 2$  et  $m' - 2$ ; on va majorer  $P$ .

Soient  $d_1, \dots, d_{k'}$  les facteurs spéciaux à droite de longueur  $m' - 2$ , on a  $k' \leq k$ . Pour tout  $p \in [m - 1, m' - 3]$ , les facteurs spéciaux à droite de longueur  $p$  sont les suffixes de longueur  $p$  de  $d_1, \dots, d_{k'}$ . En effet, sinon il existe  $p \in [m - 1, m' - 3]$  et un mot  $w$  de longueur  $p$  tel que  $w$  est spécial à droite, mais ni  $0w$  ni  $1w$  ne sont spéciaux à droite, et  $0w$  et  $1w$  ne peuvent donc apparaître que suivis respectivement de  $x$  et  $x'$  avec  $x \neq x'$ ; donc  $0wx$  et  $1wx'$  sont facteurs, mais pas  $1wx$  ni  $0wx'$ , et  $w$  est bispécial faible, ce qui contredit le choix de  $m$  et  $m'$ . Les facteurs bispéciaux étant spéciaux à droite, il existe donc au moins  $\frac{P}{k}$  facteurs bispéciaux ordinaires qui sont des suffixes d'un même  $d_{i_0}$ . Soit  $e_j$  le suffixe de longueur  $m - 2 + j$ ,  $1 \leq j \leq m' - m$ , de ce  $d_{i_0}$ .

Soient  $c_1, \dots, c_r$  les mots de retour de  $e_j$ . Si  $e_j$  n'est pas bispécial,  $e_j$  est toujours précédé d'une même lettre  $x$ , et les mots de retour de  $xe_j$  sont encore  $c_1, \dots, c_r$ . Si  $e_j$  est bispécial, il ne peut être qu'ordinaire par construction de  $m$  et  $m'$ , donc on est dans un des deux cas du lemme 3.9.

Si on est dans le deuxième cas, c'est-à-dire si la somme des temps de retour de  $e_j$  est égale à celle des temps de retour de  $xe_j$ , son extension spéciale à droite, alors il existe un bispécial faible  $g_j$  dont la longueur est inférieure à  $(a + 1)(2n - 2)$  et qui contient  $e_j$  comme préfixe. Pour un  $g$  donné, soient  $j_1, j_2, \dots, j_h$  ( $j_1 < j_2 < \dots < j_h$ ) les  $j$  pour lesquels  $g_j$  existe et  $g_j = g$ . On a donc  $g_{j_1} = g_{j_2} = \dots = g_{j_h} = g$ . On a une occurrence de  $e_{j_1}$  comme suffixe de chaque  $e_{j_i}$ , qui est préfixe de  $g$ , et donc  $h$  occurrences distinctes de  $e_{j_1}$  à l'intérieur de  $g$ . Mais les mots de retour de  $e_{j_1}$  ont une longueur supérieure ou égale à  $b(n - 1)$ , donc la longueur de  $g$  est comprise entre  $(n - 1) + (h - 1)b(n - 1)$  et  $(a + 1)(2n - 2)$ , d'où  $h \leq 1 + \frac{2a+1}{b}$ .

Le nombre de  $e_j$  pour lesquels on se trouve dans le deuxième cas du lemme 3.9 est donc égal au plus à  $\frac{2a+b+1}{b}M$ , où  $M$  est le nombre de bispéciaux faibles de longueur comprise entre  $(n - 1)$  et  $(a + 1)(2n - 2)$ ; par le lemme 3.8,  $M \leq 2(2a + 2)k^3 + k$ , donc le nombre de tels  $e_j$  est au plus

$$K = \frac{2a + b + 1}{b} ((4a + 4)k^3 + k),$$

indépendamment de  $n$ .

Mais, chaque fois qu'on est dans le premier cas, la somme des longueurs des mots de retour augmente d'au moins  $b(n - 1)$ . Si on part des mots de retour de  $e_1$ , qui sont de longueur au moins  $b(n - 1)$ , on applique le processus ci-dessus pour arriver aux mots de retour de  $e_{m'-m} = d_{i_0}$ , après être passé par au moins  $\frac{P}{k}$  facteurs bispéciaux ordinaires.

La somme des longueurs des mots de retour de  $d_{i_0}$  est alors au moins  $(\frac{P}{k} - K)b(n - 1)$  et l'un d'eux a donc une longueur d'au moins  $(\frac{P}{k} - K)\frac{b(n-1)}{B}$ , et d'au plus  $a(2n - 2)$ ; on a donc  $P \leq Q = \frac{2aBk}{b} + kK$ .

À chaque facteur bispécial ordinaire de longueur strictement comprise entre  $m - 2$  et  $m' - 2$  correspond exactement un mot singulier de longueur strictement comprise entre  $m$  et  $m'$ ; comme il n'y a pas de facteurs bispéciaux stricts de longueur strictement comprise entre  $m - 2$  et  $m' - 2$ , on obtient ainsi tous les mots singuliers, et leur nombre est donc majoré par  $Q$ . □

**THÉORÈME 3.11.** — *Si  $u$  est non ultimement périodique,  $\frac{R(n)}{n}$  ne peut avoir une limite finie.*

*Démonstration.* —

*Cas des alphabets à deux lettres.*

Supposons que  $\frac{R(n)}{n}$  a une limite finie. Si  $u$  est non ultimement périodique, il y a une infinité de mots singuliers, car il y a une infinité de facteurs bispéciaux stricts ou ordinaires.

Soient  $h_p$  les longueurs successives des mots singuliers de  $u$ , et  $r_p$  le plus grand temps de retour de tous les mots singuliers de longueur inférieure ou égale à  $h_p$ . D'après le lemme 2.2,  $r(h_p) = r(h_{p+1} - 1) = r_p$ . Donc  $\frac{R(n)}{n} = \frac{r_p + h_p - 1}{h_p}$  pour  $n = h_p$ ,  $\frac{R(n)}{n} = \frac{r_p + h_{p+1} - 2}{h_{p+1} - 1}$  pour  $n = h_{p+1} - 1$ ;  $\frac{r_p}{h_p}$  et  $\frac{r_p}{h_{p+1}}$  ont donc même limite, finie et non nulle par le lemme 3.4. Donc  $\frac{h_{p+1}}{h_p} \rightarrow 1$  quand  $p \rightarrow +\infty$ .

Mais le lemme 3.10 permet, pour tout  $n$  fixé, de trouver

$$n \leq m < m' \leq 2n, \quad m' - m \geq \frac{n}{Q'},$$

tels qu'il y ait au plus  $Q$  mots singuliers de longueur strictement comprise entre  $m$  et  $m'$  ; il existe donc (parmi ces mots singuliers, plus le mot singulier précédent et le mot singulier suivant) deux mots singuliers consécutifs dont les longueurs diffèrent d'au moins  $\frac{n}{(Q+1)Q'}$  ; on a donc trouvé un  $p$  tel que  $h_p \leq 2n$  et  $h_{p+1} - h_p \geq \frac{n}{(Q+1)Q'}$ , donc  $\frac{h_{p+1}}{h_p} \geq 1 + \frac{1}{2(Q+1)Q'}$  ; comme  $h_{p+1} \geq n$ , cette situation se produit pour une infinité de  $p$ , ce qui contredit le paragraphe précédent.

*Cas des alphabets plus grands.*

Nous allons utiliser les techniques développées dans [3].

Soient maintenant  $\Lambda$  un alphabet de taille quelconque  $s$  et  $u$  une suite sur  $\Lambda$ . On va coder  $u$  de la manière suivante.

Supposons que les éléments de  $\Lambda$  sont numérotés de  $c_0$  à  $c_{s-1}$  et soit  $\varphi$  le morphisme de  $\Lambda^*$  dans  $\Lambda'^*$  avec  $\Lambda' = \{a, b\}$ , où  $\Lambda^*$  est l'ensemble des mot finis sur l'alphabet  $\Lambda$ , défini par  $\varphi(c_i) = a^{i+1}b^{s-i}$  pour tout  $i$  compris entre 0 et  $s - 1$ .

Pour  $n \geq s + 1$ , on a

$$(s + 1)R_u \left( \left\lfloor \frac{n}{s + 1} \right\rfloor \right) - s \leq R_{\varphi(u)}(n) \leq (s + 1)R_u \left( \left\lceil \frac{n + s}{s + 1} \right\rceil \right) + s .$$

En effet, tout facteur de longueur  $n$  de  $\varphi(u)$  est facteur d'un mot de la forme  $\varphi(v)$ , où  $v$  est un facteur de longueur  $\lceil \frac{n+s}{s+1} \rceil$  de  $u$ , qui apparaît donc dans tout facteur de longueur  $R_u(\lceil \frac{n+s}{s+1} \rceil)$  de  $u$ , d'où la majoration. Inversement, soient  $v$  un facteur de  $u$  de longueur  $\lfloor \frac{n}{s+1} \rfloor$  et  $w$  un facteur de  $u$  de longueur  $R_u(\lfloor \frac{n}{s+1} \rfloor) - 1$  tel que  $w$  ne contient pas  $v$  : alors  $\varphi(w)$  est un facteur de  $\varphi(u)$  de longueur  $(s+1)R_u(\lfloor \frac{n}{s+1} \rfloor) - s - 1$  qui ne contient pas  $\varphi(v)$ , car, par construction de  $\varphi$ ,  $\varphi(v)$  n'apparaît dans  $\varphi(u)$  qu'à des positions multiples de  $s + 1$ , d'où la minoration.

D'après cet encadrement,  $\frac{R_u(n)}{n}$  a une limite finie si et seulement si  $\frac{R_{\varphi(u)}(n)}{n}$  a une limite finie (et ces limites sont alors égales). On a ainsi ramené le cas général à celui de l'alphabet binaire. □

BIBLIOGRAPHIE

[1] P. ALESSANDRI, « Codages de rotations et basses complexités », Thèse, Université Aix-Marseille II, 1996.  
 [2] P. ARNOUX & G. RAUZY, « Représentation géométrique de suites de complexité  $2n + 1$  », *Bull. Soc. Math. France* **119** (1991), p. 199-215.  
 [3] J. CASSAIGNE, « Special factors of sequences with linear subword complexity », *Developments in Language Theory (Magdeburg, 1995)* (1996), p. 25-34, World Scientific.

- [4] ———, « Complexité et facteurs spéciaux », *Bull. Belg. Math. Soc.* **4** (1997), p. 67-88.
- [5] ———, « Limit values of the recurrence quotient of Sturmian sequences », *Theoret. Comp. Sci.* **218** (1999), p. 3-12.
- [6] N. CHEKHOVA, P. HUBERT & A. MESSAOUDI, « Propriétés combinatoires, ergodiques et arithmétiques de la substitution de Tribonacci », *J. Théorie Nombres Bordeaux* **13** (2001), p. 371-394.
- [7] F. DURAND, B. HOST & C. SKAU, « Substitutional dynamical Bratteli diagrams and dimension groups », *Ergodic Theory Dynam. Systems* **19** (1999), p. 953-993.
- [8] M. MORSE & G. A. HEDLUND, « Symbolic dynamics II. Sturmian trajectories », *Amer. J. Math.* **62** (1940), p. 1-42.
- [9] J. MOULINE, « Contribution à l'étude de la complexité des suites substitutives », Thèse, Université de Provence, 1989.
- [10] G. RAUZY, « Nombres algébriques et substitutions », *Bull. Soc. Math. France* **110** (1982), p. 147-178.

Julien CASSAIGNE  
Institut de mathématiques de Luminy  
163 avenue de Luminy  
Case 907  
13288 Marseille Cedex 9 (France)  
cassaigne@iml.univ-mrs.fr

Nataliya CHEKHOVA  
Université de Tours  
Faculté des sciences et techniques  
Laboratoire de mathématiques et physique théorique  
Parc de Grandmont  
37200 Tours (France)  
natalya@univ-tours.fr