


# Énumération asymptotique d'automates finis

Frédérique Bassino

Laboratoire d'Informatique de Paris Nord



Issu de travaux en collaboration avec  
*J. David, C. Nicaud et A. Sportiello*

Séminaire Philippe Flajolet, Mai 2012

# Pourquoi vouloir énumérer les automates finis ?

- ▶ Étudier de manière quantitative les propriétés des langages réguliers.
- ▶ Utiliser la représentation (**canonique**) des langages réguliers par des automates (**minimaux**).
- ▶ Enumérer, simuler ces structures.
- ▶ Analyser en moyenne des algorithmes manipulant ces structures  
(par exemple des algorithmes de minimisation)

# Pourquoi vouloir énumérer les automates finis ?


- ▶ Étudier de manière quantitative les propriétés des langages réguliers.
- ▶ Utiliser la représentation (**canonique**) des langages réguliers par des automates (**minimaux**).
- ▶ Enumérer, simuler ces structures.
- ▶ Analyser en moyenne des algorithmes manipulant ces structures  
(par exemple des algorithmes de minimisation)

# Langages réguliers

- ▶  $\Sigma$  un alphabet fini:  $\Sigma = \{a, b, c\}$
- ▶  $\Sigma^*$  l'ensemble des mots sur  $\Sigma$ :  $\Sigma^* = \{\epsilon, a, b, c, aa, ab, \dots\}$
- ▶ Un langage régulier : langage obtenu à partir de sous-ensembles finis de  $\Sigma^*$  et d'un nombre fini d'opérations rationnelles (union  $\cup$ , concaténation  $\cdot$  et étoile  $*$ ) où

$$X^* = \{x_1x_2 \cdots x_n \mid n \geq 0, x_i \in X\}$$

Exemple : les *mots de Fibonacci*,  
c'est à dire, les mots sur  $\Sigma = \{a, b\}$  sans  $bb$



Automate


$$(a + ba)^*(\epsilon + b)$$

Expression régulière

- ▶  $\Sigma$  un alphabet fini:  $\Sigma = \{a, b, c\}$
- ▶  $\Sigma^*$  l'ensemble des mots sur  $\Sigma$ :  $\Sigma^* = \{\epsilon, a, b, c, aa, ab, \dots\}$
- ▶ Un langage régulier : langage obtenu à partir de sous-ensembles finis de  $\Sigma^*$  et d'un nombre fini d'opérations rationnelles (union  $\cup$ , concaténation  $\cdot$  et étoile  $*$ ) où

$$X^* = \{x_1x_2 \cdots x_n \mid n \geq 0, x_i \in X\}$$

Exemple : les *mots de Fibonacci*,  
c'est à dire, les mots sur  $\Sigma = \{a, b\}$  sans  $bb$



Automate


$$(a + ba)^*(\epsilon + b)$$

Expression régulière

- ▶  $\Sigma$  un alphabet fini:  $\Sigma = \{a, b, c\}$
- ▶  $\Sigma^*$  l'ensemble des mots sur  $\Sigma$ :  $\Sigma^* = \{\epsilon, a, b, c, aa, ab, \dots\}$
- ▶ Un langage régulier : langage obtenu à partir de sous-ensembles finis de  $\Sigma^*$  et d'un nombre fini d'opérations rationnelles (union  $\cup$ , concaténation  $\cdot$  et étoile  $*$ ) où

$$X^* = \{x_1x_2 \cdots x_n \mid n \geq 0, x_i \in X\}$$

Exemple : les *mots de Fibonacci*,  
c'est à dire, les mots sur  $\Sigma = \{a, b\}$  sans  $bb$



Automate

$$(a + ba)^*(\epsilon + b)$$

Expression régulière

# Expressions rationnelles

Les langages finis peuvent être représentés par des expressions rationnelles écrites sur

- ▶ un alphabet fini  $\Sigma \cup \{\epsilon\}$
- ▶ avec les opérateurs binaires : union  $+$  et concaténation  $\cdot$
- ▶ et l'opérateur unaire  $*$ .


Expression rationnelle :  $(a + ba)^*(\epsilon + b)$

- ▶ Cette représentation des langages n'a pas de forme canonique
- ▶ Tester si une expression représente  $\Sigma^*$  est PSPACE-complet.

# Automates déterministes

Un automate  $A$  est **déterministe et complet** s'il n'a qu'un seul état initial et que pour tout état  $q$  et pour toute lettre  $\ell$ , il existe exactement une transition d'étiquette  $\ell$  partant de  $q$ .

$A$  est alors identifié à un quintuplet



► *Notations.*

Taille de l'alphabet :  $|\Sigma| = k$ . Nombre d'états :  $|Q| = n$ .


- On fait un choix canonique,  $\Sigma \equiv [k]$ ,  $Q \equiv [n]$  et  $q_0 = 1$ .
- Avec un ordre total sur  $Q$ , le couple  $(\delta, \mathcal{T})$  permet de reconstruire l'automate  $A$ .



# Automates déterministes

Un automate  $A$  est **déterministe et complet** s'il n'a qu'un seul état initial et que pour tout état  $q$  et pour toute lettre  $\ell$ , il existe exactement une transition d'étiquette  $\ell$  partant de  $q$ .

$A$  est alors identifié à un quintuplet




► *Notations.*

Taille de l'alphabet :  $|\Sigma| = k$ . Nombre d'états :  $|Q| = n$ .


- On fait un choix canonique,  $\Sigma \equiv [k]$ ,  $Q \equiv [n]$  et  $q_0 = 1$ .
- Avec un ordre total sur  $Q$ , le couple  $(\delta, \mathcal{T})$  permet de reconstruire l'automate  $A$ .

# Automates déterministes




- ▶ Les états sont représentés par des cercles.
- ▶ Un état est final (dans  $\mathcal{T}$ ) s'il est doublement cerclé.
- ▶ Pour chaque état  $i \in Q$  et chaque lettre  $\alpha \in \Sigma$ , une transition sort de l'état  $i$ , vers l'état  $\delta(i, \alpha)$ .
- ▶ Pour chaque mot  $w \in \Sigma^*$ ,  $\delta(i, w)$  est l'état d'arrivée du chemin, partant de  $i$ , correspondant à la concaténation des transitions.
- ▶ Le mot  $w$  est reconnu par l'automate ssi  $\delta(1, w) \in \mathcal{T}$ .

# Automates déterministes




- ▶ Les états sont représentés par des cercles.
- ▶ Un état est final (dans  $\mathcal{T}$ ) s'il est doublement cerclé.
- ▶ Pour chaque état  $i \in Q$  et chaque lettre  $\alpha \in \Sigma$ , une transition sort de l'état  $i$ , vers l'état  $\delta(i, \alpha)$ .
- ▶ Pour chaque mot  $w \in \Sigma^*$ ,  $\delta(i, w)$  est l'état d'arrivée du chemin, partant de  $i$ , correspondant à la concaténation des transitions.
- ▶ Le mot  $w$  est reconnu par l'automate ssi  $\delta(1, w) \in \mathcal{T}$ .

# Automates déterministes




- ▶ Les états sont représentés par des cercles.
- ▶ Un état est final (dans  $\mathcal{T}$ ) s'il est doublement cerclé.
- ▶ Pour chaque état  $i \in Q$  et chaque lettre  $\alpha \in \Sigma$ , une transition sort de l'état  $i$ , vers l'état  $\delta(i, \alpha)$ .
- ▶ Pour chaque mot  $w \in \Sigma^*$ ,  $\delta(i, w)$  est l'état d'arrivée du chemin, partant de  $i$ , correspondant à la concaténation des transitions.
- ▶ Le mot  $w$  est **reconnu** par l'automate ssi  $\delta(1, w) \in \mathcal{T}$ .

# Automates déterministes



- ▶ Les états sont représentés par des cercles.
- ▶ Un état est final (dans  $\mathcal{T}$ ) s'il est doublement cerclé.
- ▶ Pour chaque état  $i \in Q$  et chaque lettre  $\alpha \in \Sigma$ , une transition sort de l'état  $i$ , vers l'état  $\delta(i, \alpha)$ .
- ▶ Pour chaque mot  $w \in \Sigma^*$ ,  $\delta(i, w)$  est l'état d'arrivée du chemin, partant de  $i$ , correspondant à la concaténation des transitions.
- ▶ Le mot  $w$  est reconnu par l'automate ssi  $\delta(1, w) \in \mathcal{T}$ .


# Automates déterministes



$w = (abbc b)$  est reconnu;  
 $\delta(i, w) = 3$ .

- ▶ Les états sont représentés par des cercles.
- ▶ Un état est final (dans  $\mathcal{T}$ ) s'il est doublement cerclé.
- ▶ Pour chaque état  $i \in Q$  et chaque lettre  $\alpha \in \Sigma$ , une transition sort de l'état  $i$ , vers l'état  $\delta(i, \alpha)$ .
- ▶ Pour chaque mot  $w \in \Sigma^*$ ,  $\delta(i, w)$  est l'état d'arrivée du chemin, partant de  $i$ , correspondant à la concaténation des transitions.
- ▶ Le mot  $w$  est **reconnu** par l'automate ssi  $\delta(1, w) \in \mathcal{T}$ .

# Automates déterministes



$w = (abcbb)$  n'est pas reconnu;  
 $\delta(i, w) = 6$ .

- ▶ Les états sont représentés par des cercles.
- ▶ Un état est final (dans  $\mathcal{T}$ ) s'il est doublement cerclé.
- ▶ Pour chaque état  $i \in Q$  et chaque lettre  $\alpha \in \Sigma$ , une transition sort de l'état  $i$ , vers l'état  $\delta(i, \alpha)$ .
- ▶ Pour chaque mot  $w \in \Sigma^*$ ,  $\delta(i, w)$  est l'état d'arrivée du chemin, partant de  $i$ , correspondant à la concaténation des transitions.
- ▶ Le mot  $w$  est **reconnu** par l'automate ssi  $\delta(1, w) \in \mathcal{T}$ .

# Langages réguliers et automates minimaux

## Théorème de Kleene

Les langages reconnus par automates finis sont les langages réguliers.

- ▶ Pour chaque langage régulier  $\mathcal{L}$ , il existe un **unique** automate déterministe complet de taille minimale qui le reconnaît : son **automate minimal**.

*Dans la suite, on va :*

- ▶ Compter (asymptotiquement pour  $n$  grand) les automates minimaux de taille  $n$ .
- ▶ Caractériser l'ensemble des automates minimaux, parmi tous les automates déterministes finis.  
*(propriétés statistiques, probabilités d'occurrence de motifs).*

*Conséquences :*

- ▶ Génération aléatoire des automates minimaux,
- ▶ Analyse en moyenne d'algorithmes sur les langages réguliers.



# Langages réguliers et automates minimaux

## Théorème de Kleene

Les langages reconnus par automates finis sont les langages réguliers.

- ▶ Pour chaque langage régulier  $\mathcal{L}$ , il existe un **unique** automate déterministe complet de taille minimale qui le reconnaît : son **automate minimal**.

*Dans la suite, on va :*

- ▶ Compter (asymptotiquement pour  $n$  grand) les automates minimaux de taille  $n$ .
- ▶ Caractériser l'ensemble des automates minimaux, parmi tous les automates déterministes finis.  
*(propriétés statistiques, probabilités d'occurrence de motifs).*

*Conséquences :*

- ▶ Génération aléatoire des automates minimaux,
- ▶ Analyse en moyenne d'algorithmes sur les langages réguliers.

## Théorème de Kleene

Les langages reconnus par automates finis sont les langages réguliers.

- ▶ Pour chaque langage régulier  $\mathcal{L}$ , il existe un **unique** automate déterministe complet de taille minimale qui le reconnaît : son **automate minimal**.

*Dans la suite, on va :*

- ▶ Compter (asymptotiquement pour  $n$  grand) les automates minimaux de taille  $n$ .
- ▶ Caractériser l'ensemble des automates minimaux, parmi tous les automates déterministes finis.  
*(propriétés statistiques, probabilités d'occurrence de motifs).*

*Conséquences :*

- ▶ Génération aléatoire des automates minimaux,
- ▶ Analyse en moyenne d'algorithmes sur les langages réguliers.

## Théorème de Kleene

Les langages reconnus par automates finis sont les langages réguliers.

- ▶ Pour chaque langage régulier  $\mathcal{L}$ , il existe un **unique** automate déterministe complet de taille minimale qui le reconnaît : son **automate minimal**.


*Dans la suite, on va :*

- ▶ Compter (asymptotiquement pour  $n$  grand) les automates minimaux de taille  $n$ .
- ▶ Caractériser l'ensemble des automates minimaux, parmi tous les automates déterministes finis.  
*(propriétés statistiques, probabilités d'occurrence de motifs).*

*Conséquences :*

- ▶ Génération aléatoire des automates minimaux,
- ▶ Analyse en moyenne d'algorithmes sur les langages réguliers.

# Les automates : accessibilité




Un automate est **accessible** si, pour tout état  $i$ , il existe un mot  $w$  tel que  $\delta(1, w) = i$ .

Dans ce cas, un ordre canonique sur  $Q$  est donné par le parcours en largeur (selon l'ordre de  $\Sigma$ ) de l'automate à partir de l'état initial 1.

L'arbre de recherche associé couvre alors tous les états de l'automate

# Les automates : accessibilité



Un automate est **accessible** si, pour tout état  $i$ , il existe un mot  $w$  tel que  $\delta(1, w) = i$ .


Dans ce cas, un ordre canonique sur  $Q$  est donné par le parcours en largeur (selon l'ordre de  $\Sigma$ ) de l'automate à partir de l'état initial 1.

L'arbre de recherche associé couvre alors tous les états de l'automate

# Les automates : Minimalité

Deux états  $i$  et  $j$  sont les **équivalents** - au sens de Myhill–Nerode - ssi, pour tout mot  $w$ , ou bien  $\delta(i, w), \delta(j, w) \in \mathcal{T}$  ou bien  $\delta(i, w), \delta(j, w) \notin \mathcal{T}$ .

On peut vérifier cette propriété par un parcours en largeur simultané à partir des deux états.

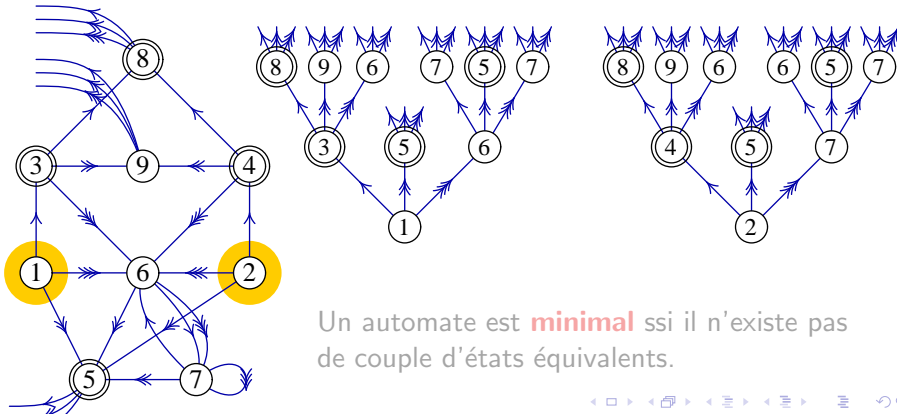


Un automate est **minimal** ssi il n'existe pas de couple d'états équivalents.

# Les automates : Minimalité

Deux états  $i$  et  $j$  sont les **équivalents** - au sens de Myhill–Nerode - ssi, pour tout mot  $w$ , ou bien  $\delta(i, w), \delta(j, w) \in \mathcal{T}$  ou bien  $\delta(i, w), \delta(j, w) \notin \mathcal{T}$ .

On peut vérifier cette propriété par un parcours en largeur simultané à partir des deux états.

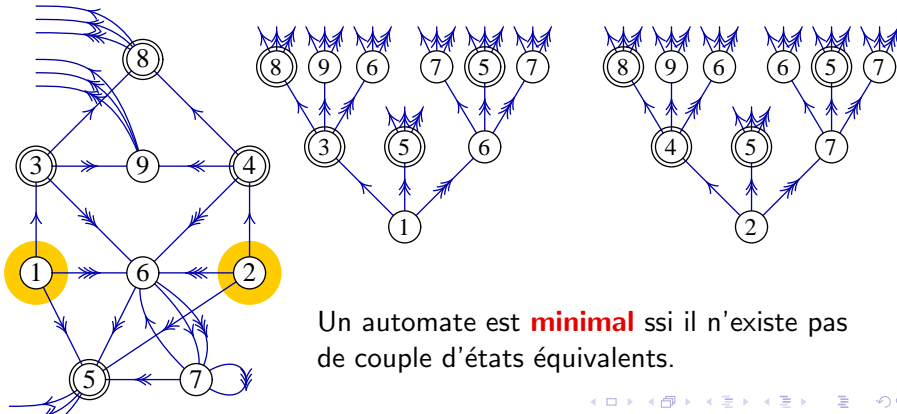


Un automate est **minimal** ssi il n'existe pas de couple d'états équivalents.

# Les automates : Minimalité

Deux états  $i$  et  $j$  sont les **équivalents** - au sens de Myhill–Nerode - ssi, pour tout mot  $w$ , ou bien  $\delta(i, w), \delta(j, w) \in \mathcal{T}$  ou bien  $\delta(i, w), \delta(j, w) \notin \mathcal{T}$ .

On peut vérifier cette propriété par un parcours en largeur simultané à partir des deux états.




Un automate est **minimal** ssi il n'existe pas de couple d'états équivalents.




# Les automates : accessibilité et minimalité

Un automate est...

**accessible**, ssi les arbres de recherche issu de l'état initial couvre tous les états de l'automate



**minimal**, ssi il n'existe pas couple d'arbres de recherche certifiant que deux états sont équivalents




Il s'agit de contraintes **non-locales** et difficiles à exprimer d'un point de vue combinatoire.


# Les automates : accessibilité et minimalité

Un automate est...

**accessible**, ssi les arbres de recherche issu de l'état initial couvre tous les états de l'automate



**minimal**, ssi il n'existe pas couple d'arbres de recherche certifiant que deux états sont équivalents



Il s'agit de contraintes **non-locales** et difficiles à exprimer d'un point de vue combinatoire.

# Enumérer les automates unaires ( $k = 1$ )

Les automates unaires (déterministes et complets) vérifient

$$i = 1 \cdot a^{i-1}$$

et sont donc caractérisés par le choix de l'état  $c$  tel que  $c = n \cdot a$ .

*Nicaud 1999*

- ▶ Il y a  $n2^n$  automates unaires canoniquement étiquetés
- ▶ Asymptotiquement la moitié des automates unaires (déterministes, complets) accessibles sont minimaux.

# Enumérer les automates unaires ( $k = 1$ )

Les automates unaires (déterministes et complets) vérifient



$$i = 1 \cdot a^{i-1}$$

et sont donc caractérisés par le choix de l'état  $c$  tel que  $c = n \cdot a$ .

*Nicaud 1999*



- ▶ Il y a  $n2^n$  automates unaires canoniquement étiquetés
- ▶ Asymptotiquement la moitié des automates unaires (déterministes, complets) accessibles sont minimaux.

# Automates $k$ -aires ( $k \geq 2$ ) et tableaux







# Automates $k$ -aires ( $k \geq 2$ ) et tableaux





# Automates $k$ -aires ( $k \geq 2$ ) et tableaux









# Automates $k$ -aires ( $k \geq 2$ ) et tableaux




# Automates $k$ -aires ( $k \geq 2$ ) et tableaux



# Automates $k$ -aires ( $k \geq 2$ ) et tableaux




# Automates $k$ -aires ( $k \geq 2$ ) et tableaux




● Une croix par colonne

# Automates $k$ -aires ( $k \geq 2$ ) et tableaux




- Une croix par colonne
- Au moins une croix par ligne – la plus à gauche est rouge

# Automates $k$ -aires ( $k \geq 2$ ) et tableaux



- Une croix par colonne
- Au moins une croix par ligne – la plus à gauche est rouge
- Les croix rouges (*squelette*) forment une séquence monotone

# Automates $k$ -aires ( $k \geq 2$ ) et tableaux



- Une croix par colonne
- Au moins une croix par ligne – la plus à gauche est rouge
- Les croix rouges (*squelette*) forment une séquence monotone
- Enfin, il faut que les croix rouges restent à la gauche de la diagonale (*contrainte  $k$ -Dyck*)

# Enumérer les automates accessibles

Soit  $\mathcal{D}_{n,k}$  l'ensemble des structures de transition (déterministes complètes) accessibles, sur un alphabet de taille  $|\Sigma| = k \geq 2$ , avec  $|Q| = n$  états.

*Korshunov, 1978; Bassino et Nicaud, 2007; Lebensztayn, 2010.*

$$|\mathcal{D}_{n,k}| = \omega_k \left\{ \begin{matrix} kn+1 \\ n \end{matrix} \right\} (1 + \mathcal{O}(n^{-1})) ,$$

où  $\left\{ \begin{matrix} n \\ m \end{matrix} \right\}$  est le *nombre de Stirling de seconde espèce*, et  $\omega_k$  satisfait  $-k\omega_k = \ln(1 - \omega_k)$ .

Qu'est ce qui se cache derrière ce théorème ?

- Le nombre de tableaux  $n \times m$  est exactement  $\left\{ \begin{matrix} n \\ m \end{matrix} \right\}$   
(Les *nombre de Stirling de seconde espèce* comptent le nombre de partitions  $n$ 'un ensemble à  $n$  éléments en  $m$  sous-ensembles).
- Un tableau est  $k$ -Dyck, si le squelette ne passe pas sous la diagonale : cela se produit avec une probabilité d'ordre  $\omega_k$ .



# Enumérer les automates accessibles

Soit  $\mathcal{D}_{n,k}$  l'ensemble des structures de transition (déterministes complètes) accessibles, sur un alphabet de taille  $|\Sigma| = k \geq 2$ , avec  $|Q| = n$  états.

*Korshunov, 1978; Bassino et Nicaud, 2007; Lebensztayn, 2010.*

$$|\mathcal{D}_{n,k}| = \omega_k \left\{ \begin{matrix} kn+1 \\ n \end{matrix} \right\} (1 + \mathcal{O}(n^{-1})) ,$$

où  $\left\{ \begin{matrix} n \\ m \end{matrix} \right\}$  est le *nombre de Stirling de seconde espèce*, et  $\omega_k$  satisfait  $-k\omega_k = \ln(1 - \omega_k)$ .

Qu'est ce qui se cache derrière ce théorème ?

- Le nombre de tableaux  $n \times m$  est exactement  $\left\{ \begin{matrix} n \\ m \end{matrix} \right\}$   
(Les *nombre de Stirling de seconde espèce* comptent le nombre de partitions  $n$ 'un ensemble à  $n$  éléments en  $m$  sous-ensembles).
- Un tableau est  $k$ -Dyck, si le squelette ne passe pas sous la diagonale : cela se produit avec une probabilité d'ordre  $\omega_k$ .

# Enumérer les automates accessibles

Soit  $\mathcal{D}_{n,k}$  l'ensemble des structures de transition (déterministes complètes) accessibles, sur un alphabet de taille  $|\Sigma| = k \geq 2$ , avec  $|Q| = n$  états.

*Korshunov, 1978; Bassino et Nicaud, 2007; Lebensztayn, 2010.*

$$|\mathcal{D}_{n,k}| = \omega_k \left\{ \begin{matrix} kn+1 \\ n \end{matrix} \right\} (1 + \mathcal{O}(n^{-1})) ,$$


où  $\left\{ \begin{matrix} n \\ m \end{matrix} \right\}$  est le *nombre de Stirling de seconde espèce*, et  $\omega_k$  satisfait  $-k\omega_k = \ln(1 - \omega_k)$ .

Qu'est ce qui se cache derrière ce théorème ?

- Le nombre de tableaux  $n \times m$  est exactement  $\left\{ \begin{matrix} n \\ m \end{matrix} \right\}$   
(Les *nombre de Stirling de seconde espèce* comptent le nombre de partitions  $n$ 'un ensemble à  $n$  éléments en  $m$  sous-ensembles).
- Un tableau est  $k$ -Dyck, si le squelette ne passe pas sous la diagonale : cela se produit avec une probabilité d'ordre  $\omega_k$ .

# Relations entre squelette et croix noires et contrainte $k$ -Dyck

Q: Combien de tableaux  $T$  peuvent compléter un squelette donné ?



R: Code le squelette par la séquence  $\mathbf{c} = \{c_y\}_{1 \leq y \leq n}$ . C'est


$$\mu(\mathbf{c}) = \begin{cases} \prod_{y=1}^n y^{c_y} & \sum_y c_y = (k-1)n + 1 \\ 0 & \text{autrement} \end{cases}$$

Corollaire :  $\sum_T \phi(\mathbf{c}(T)) = \sum_{\mathbf{c}} \mu(\mathbf{c}) \phi(\mathbf{c})$ .

La probabilité d'être  $k$ -Dyck est une fonction du type  $\phi(\mathbf{c}(T))$ .

# Relations entre squelette et croix noires et contrainte $k$ -Dyck

**Q:** Combien de tableaux  $T$  peuvent compléter un squelette donné ?



**R:** Code le squelette par la séquence  $\mathbf{c} = \{c_y\}_{1 \leq y \leq n}$ . C'est


$$\mu(\mathbf{c}) = \begin{cases} \prod_{y=1}^n y^{c_y} & \sum_y c_y = (k-1)n + 1 \\ 0 & \text{autrement} \end{cases}$$

**Corollaire :**  $\sum_T \phi(\mathbf{c}(T)) = \sum_{\mathbf{c}} \mu(\mathbf{c}) \phi(\mathbf{c})$ .

La probabilité d'être  $k$ -Dyck est une fonction du type  $\phi(\mathbf{c}(T))$ .

# Relations entre squelette et croix noires et contrainte $k$ -Dyck

**Q:** Combien de tableaux  $T$  peuvent compléter un squelette donné ?



**R:** Code le squelette par la séquence  $\mathbf{c} = \{c_y\}_{1 \leq y \leq n}$ . C'est


$$\mu(\mathbf{c}) = \begin{cases} \prod_{y=1}^n y^{c_y} & \sum_y c_y = (k-1)n + 1 \\ 0 & \text{autrement} \end{cases}$$

**Corollaire :**  $\sum_T \phi(\mathbf{c}(T)) = \sum_{\mathbf{c}} \mu(\mathbf{c}) \phi(\mathbf{c})$ .

La probabilité d'être  $k$ -Dyck est une fonction du type  $\phi(\mathbf{c}(T))$ .

# Relations entre squelette et croix noires et contrainte $k$ -Dyck

**Q:** Combien de tableaux  $T$  peuvent compléter un squelette donné ?



**R:** Code le squelette par la séquence  $\mathbf{c} = \{c_y\}_{1 \leq y \leq n}$ . C'est


$$\mu(\mathbf{c}) = \begin{cases} \prod_{y=1}^n y^{c_y} & \sum_y c_y = (k-1)n + 1 \\ 0 & \text{autrement} \end{cases}$$

**Corollaire :**  $\sum_T \phi(\mathbf{c}(T)) = \sum_{\mathbf{c}} \mu(\mathbf{c}) \phi(\mathbf{c})$ .

La probabilité d'être  $k$ -Dyck est une fonction du type  $\phi(\mathbf{c}(T))$ .

# Relations entre squelette et croix noires et contrainte $k$ -Dyck

**Q:** Combien de tableaux  $T$  peuvent compléter un squelette donné ?



**R:** Code le squelette par la séquence  $\mathbf{c} = \{c_y\}_{1 \leq y \leq n}$ . C'est

$$\mu(\mathbf{c}) = \begin{cases} \prod_{y=1}^n y^{c_y} & \sum_y c_y = (k-1)n + 1 \\ 0 & \text{autrement} \end{cases}$$

**Corollaire :**  $\sum_T \phi(\mathbf{c}(T)) = \sum_{\mathbf{c}} \mu(\mathbf{c}) \phi(\mathbf{c})$ .

La probabilité d'être  $k$ -Dyck est une fonction du type  $\phi(\mathbf{c}(T))$ .

# Enumérer les automates minimaux

Soit  $\mathcal{A}_{n,k}$  l'ensemble des automates accessibles, sur un alphabet de taille  $|\Sigma| = k \geq 2$ , avec  $|Q| = n$  états.

*Korshunov, 1978; Bassino et Nicaud, 2007; Lebensztayn, 2010.*

$$|\mathcal{A}_{n,k}| = 2^n \omega_k \left\{ \begin{matrix} kn+1 \\ n \end{matrix} \right\} (1 + \mathcal{O}(n^{-1})) ,$$

où  $\left\{ \begin{matrix} n \\ m \end{matrix} \right\}$  est le *nombre de Stirling de seconde espèce*, et  $\omega_k$  satisfait  $-k\omega_k = \ln(1 - \omega_k)$ .

On munit l'ensemble des automates accessibles  $A = (\delta, \mathcal{T})$  de la mesure  $\mu(\delta, \mathcal{T}) = \mu_{\text{uniforme}}(\delta) \times \mu_{\text{Bernoulli}}^{(b)}(\mathcal{T})$ .

*Bassino, David et Sportiello, 2012*

Quand  $n$  tend vers  $+\infty$ , la probabilité qu'un automate accessible  $A$  soit minimal tend vers

$$\exp\left(-\frac{1-2b(1-b)}{2} \omega_k^k n^{-k+2}\right) .$$



# Enumérer les automates minimaux

Soit  $\mathcal{A}_{n,k}$  l'ensemble des automates accessibles, sur un alphabet de taille  $|\Sigma| = k \geq 2$ , avec  $|Q| = n$  états.

*Korshunov, 1978; Bassino et Nicaud, 2007; Lebensztayn, 2010.*

$$|\mathcal{A}_{n,k}| = 2^n \omega_k \left\{ \begin{matrix} kn+1 \\ n \end{matrix} \right\} (1 + \mathcal{O}(n^{-1})) ,$$

où  $\left\{ \begin{matrix} n \\ m \end{matrix} \right\}$  est le *nombre de Stirling de seconde espèce*, et  $\omega_k$  satisfait  $-k\omega_k = \ln(1 - \omega_k)$ .

On munit l'ensemble des automates accessibles  $A = (\delta, \mathcal{T})$  de la mesure  $\mu(\delta, \mathcal{T}) = \mu_{\text{uniforme}}(\delta) \times \mu_{\text{Bernoulli}}^{(b)}(\mathcal{T})$ .

*Bassino, David et Sportiello, 2012*

Quand  $n$  tend vers  $+\infty$ , la probabilité qu'un automate accessible  $A$  soit minimal tend vers

$$\exp\left(-\frac{1-2b(1-b)}{2} \omega_k^k n^{-k+2}\right) .$$

$$\mathbb{P}[i \sim j] = (\mathbb{P}[i, j \in \mathcal{T}] + \mathbb{P}[i, j \notin \mathcal{T}]) \\ \times \prod_{\alpha \in \Sigma} (\mathbb{P}[\delta(i, \alpha) = \delta(j, \alpha)] + \mathbb{P}[\delta(i, \alpha) \sim \delta(j, \alpha)])$$

Si  $\mathcal{T}$  suit une distribution de Bernoulli,  $\mu_{\text{Bernoulli}}^{(b)}(\mathcal{T})$ , ( $\beta = 2b(1 - b)$ )

$$\mathbb{P}[i, j \in \mathcal{T}] + \mathbb{P}[i, j \notin \mathcal{T}] = 1 - \beta < 1.$$

D'une façon naïve,  $\mathbb{P}[\delta(i, \alpha) = \delta(j, \alpha)] = 1/n$  (c'est vrai pour les applications aléatoires). Parmi les fonctions de transition  $\delta$  accessibles, on a un **facteur de correction**  $\omega_k$ . En posant  $p_{ij} = \mathbb{P}[i \sim j]$ ,

$$p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} + p_{ij} \right)^k.$$

La seule solution  $0 < p_{ij} < 1$  est  $p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} \right)^k \left( 1 + \mathcal{O}\left(\frac{1}{n^{k-1}}\right) \right)$ .

$$\mathbb{P}[i \sim j] = (\mathbb{P}[i, j \in \mathcal{T}] + \mathbb{P}[i, j \notin \mathcal{T}]) \\ \times \prod_{\alpha \in \Sigma} (\mathbb{P}[\delta(i, \alpha) = \delta(j, \alpha)] + \mathbb{P}[\delta(i, \alpha) \sim \delta(j, \alpha)])$$

Si  $\mathcal{T}$  suit une distribution de Bernoulli,  $\mu_{\text{Bernoulli}}^{(b)}(\mathcal{T})$ , ( $\beta = 2b(1 - b)$ )

$$\mathbb{P}[i, j \in \mathcal{T}] + \mathbb{P}[i, j \notin \mathcal{T}] = 1 - \beta < 1.$$

D'une façon naïve,  $\mathbb{P}[\delta(i, \alpha) = \delta(j, \alpha)] = 1/n$  (c'est vrai pour les application aléatoires). Parmi les fonctions de transition  $\delta$  accessibles, on a un **facteur de correction**  $\omega_k$ . En posant  $p_{ij} = \mathbb{P}[i \sim j]$ ,

$$p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} + p_{ij} \right)^k.$$

La seule solution  $0 < p_{ij} < 1$  est  $p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} \right)^k \left( 1 + \mathcal{O}\left(\frac{1}{n^{k-1}}\right) \right)$ .

$$\mathbb{P}[i \sim j] = (\mathbb{P}[i, j \in \mathcal{T}] + \mathbb{P}[i, j \notin \mathcal{T}]) \\ \times \prod_{\alpha \in \Sigma} (\mathbb{P}[\delta(i, \alpha) = \delta(j, \alpha)] + \mathbb{P}[\delta(i, \alpha) \sim \delta(j, \alpha)])$$

Si  $\mathcal{T}$  suit une distribution de Bernoulli,  $\mu_{\text{Bernoulli}}^{(b)}(\mathcal{T})$ , ( $\beta = 2b(1 - b)$ )

$$\mathbb{P}[i, j \in \mathcal{T}] + \mathbb{P}[i, j \notin \mathcal{T}] = 1 - \beta < 1.$$

D'une façon naïve,  $\mathbb{P}[\delta(i, \alpha) = \delta(j, \alpha)] = 1/n$  (c'est vrai pour les applications aléatoires). Parmi les fonctions de transition  $\delta$  accessibles, on a un **facteur de correction**  $\omega_k$ . En posant  $p_{ij} = \mathbb{P}[i \sim j]$ ,

$$p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} + p_{ij} \right)^k.$$

La seule solution  $0 < p_{ij} < 1$  est  $p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} \right)^k \left( 1 + \mathcal{O}\left(\frac{1}{n^{k-1}}\right) \right)$ .

$$p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} + p_{ij} \right)^k \quad \longrightarrow \quad p_{ij} \simeq (1 - \beta) \left( \frac{\omega_k}{n} \right)^k$$

Ça veut dire que la partie dominante de la probabilité  $p_{ij}$  est donnée par des couples  $(i, j)$  tels que  $\delta(i, \alpha) = \delta(j, \alpha)$  pour toutes  $\alpha \in \Sigma$ .

Cela correspond au motif

$i \quad j$

$l_1 \quad l_2 \dots l_k$

*Conséquence importante !*

Un automate non-minimal a presque sûrement de **petits certificats** de non-minimalité.

En utilisant le **Paradigme de Poisson** - la somme de plusieurs variables indicatrices, rares et presque indépendantes suit presque une loi de Poisson -,  $\mathbb{P}[A \text{ minimal}] \simeq \exp\left(-\binom{n}{2} p_{ij}\right)$ , ce qui correspond à notre théorème.

$$p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} + p_{ij} \right)^k \quad \longrightarrow \quad p_{ij} \simeq (1 - \beta) \left( \frac{\omega_k}{n} \right)^k$$

Ça veut dire que la partie dominante de la probabilité  $p_{ij}$  est donnée par des couples  $(i, j)$  tels que  $\delta(i, \alpha) = \delta(j, \alpha)$  pour toutes  $\alpha \in \Sigma$ .

Cela correspond au motif

$i \quad j$

*Conséquence importante !*

Un automate non-minimal a presque sûrement de **petits certificats** de non-minimalité.


$l_1 \quad l_2 \dots l_k$

En utilisant le **Paradigme de Poisson** - la somme de plusieurs variables indicatrices, rares et presque indépendantes suit presque une loi de Poisson -,  $\mathbb{P}[A \text{ minimal}] \simeq \exp\left(-\binom{n}{2} p_{ij}\right)$ , ce qui correspond à notre théorème.

$$p_{ij} = (1 - \beta) \left( \frac{\omega_k}{n} + p_{ij} \right)^k \quad \longrightarrow \quad p_{ij} \simeq (1 - \beta) \left( \frac{\omega_k}{n} \right)^k$$

Ça veut dire que la partie dominante de la probabilité  $p_{ij}$  est donnée par des couples  $(i, j)$  tels que  $\delta(i, \alpha) = \delta(j, \alpha)$  pour toutes  $\alpha \in \Sigma$ .

Cela correspond au motif



*Conséquence importante !*

Un automate non-minimal a presque sûrement de **petits certificats** de non-minimalité.

En utilisant le **Paradigme de Poisson** - la somme de plusieurs variables indicatrices, rares et presque indépendantes suit presque une loi de Poisson -,  $\mathbb{P}[A \text{ minimal}] \simeq \exp\left(-\binom{n}{2} p_{ij}\right)$ , ce qui correspond à notre théorème.

# Énumération des automates minimaux

*Bassino, David et Sportiello, 2011*

Pour  $n$  grand, la probabilité que  $A$  soit minimal converge vers

$$\exp\left(-\frac{1-2b(1-b)}{2} \omega_k^k n^{-k+2}\right).$$

Certains **motifs**, dans les graphes orientés correspondant aux structures de transition, ont un rôle central dans la preuve.

$M$        $i$        $j$

$M^{(3)}$        $i$        $j$        $h$

$l_1$        $l_2 \dots l_k$

$l_1$        $l_2 \dots l_k$





# Énumération des automates minimaux

*Bassino, David et Sportiello, 2011*

Pour  $n$  grand, la probabilité que  $A$  soit minimal converge vers

$$\exp\left(-\frac{1-2b(1-b)}{2} \omega_k^k n^{-k+2}\right).$$

Certains **motifs**, dans les graphes orientés correspondant aux structures de transition, ont un rôle central dans la preuve.



# Quantités qui interviennent dans la preuve

On va définir les quantités

- ▶  $P_{\text{rare}}$  : probabilité que  $A$  ne contienne pas de motifs  $M$ , et pourtant l'automate n'est pas minimal ;
- ▶  $P_{\text{confl}}$  : probabilité que  $A$  contienne des motifs  $M^{(3)}$  ;
- ▶  $P(r)$  : probabilité que  $A$  ne contienne pas des motifs  $M^{(3)}$ , et qu'il contienne exactement  $r$  motifs  $M$ .

Pour une distribution de Bernoulli sur les états terminaux,

$$\mathbb{P}[A \text{ n'est pas minimal}] = \sum_{r \geq 1} (1 - (2b(1-b)))^r P(r) + \mathcal{O}(P_{\text{rare}}, P_{\text{confl}})$$

Si on prouve que  $P_{\text{rare}}, P_{\text{confl}} = o(1 - P(0))$

et que  $P(r) = \text{Pois}_{\rho}(r)(1 + o(1))$  un certain  $\rho$ ,

$$\mathbb{P}[A \text{ n'est pas minimal}] = (1 - \exp(-\rho(1 - 2b(1-b))))(1 + o(1)).$$

# Quantités qui interviennent dans la preuve

On va définir les quantités

- ▶  $P_{\text{rare}}$  : probabilité que  $A$  ne contienne pas de motifs  $M$ , et pourtant l'automate n'est pas minimal ;
- ▶  $P_{\text{confl}}$  : probabilité que  $A$  contienne des motifs  $M^{(3)}$  ;
- ▶  $P(r)$  : probabilité que  $A$  ne contienne pas des motifs  $M^{(3)}$ , et qu'il contienne exactement  $r$  motifs  $M$ .

Pour une distribution de Bernoulli sur les états terminaux,

$$\mathbb{P}[A \text{ n'est pas minimal}] = \sum_{r \geq 1} (1 - (2b(1-b))^r) P(r) + \mathcal{O}(P_{\text{rare}}, P_{\text{confl}})$$

Si on prouve que  $P_{\text{rare}}, P_{\text{confl}} = o(1 - P(0))$

et que  $P(r) = \text{Pois}_{\rho}(r)(1 + o(1))$  un certain  $\rho$ ,

$$\mathbb{P}[A \text{ n'est pas minimal}] = (1 - \exp(-\rho(1 - 2b(1-b))))(1 + o(1)).$$

📖 N. Alon et J. Spencer, *The probabilistic method*

Soit  $\{\mathcal{E}_j\}$  une collection d'évènements. On cherche  $p(r) = \mathbb{P}[r \text{ des } \mathcal{E}_j \text{ sont vrais}]$ . Soit

$$S^{(r)} = \sum_{(i_1, \dots, i_r)} \mathbb{P}[\mathcal{E}_{i_1} \wedge \dots \wedge \mathcal{E}_{i_r}]$$

## Crible de Brun

S'il existe  $\mu < +\infty$  tel que, pour  $n$  grand, et pour chaque  $r$ ,

$$S^{(r)} \rightarrow \frac{1}{r!} \mu^r$$

alors

$$p(r) \rightarrow \exp(-\mu) \frac{1}{r!} \mu^r .$$

En utilisant le crible de Brun, il suffit de montrer que

- ▶ **Estimation des  $M$  motifs :**

$$S^{(r)} \sim \rho^r / r!, \text{ pour } \rho = \frac{1}{2} \omega_k^k n^{-k+2},$$

- ▶ **Estimation des  $M^{(3)}$  motifs :**


$$P_{\text{confl}} \sim \frac{1}{6} \omega_k^{2k} n^{-2k+3}$$

- ▶ **Estimation de la “boîte noire” :**

$$P_{\text{rare}} = o(n^{-k+2}).$$

# Ingrédient de l'estimation de $P(r)$ et $P_{\text{confl}}$

$Q$  : Quelle est la probabilité d'avoir un motif **conditionné** à un squelette  $\mathbf{c}$ ?




(avec  $i < j$ ),

$R$  : **Zéro**, s'il y a des croix rouges dans les colonnes de  $j$ ,  
 $y^{-k}$  si ce n'est pas le cas.

$$\mathbb{P}(M_{ij} | \mathbf{c}) \mu(\mathbf{c}) \equiv \mu(\mathbf{c}') \quad \mathbf{c}' = \mathbf{c} \setminus \text{colonnes de } j$$


# Ingédient de l'estimation de $P(r)$ et $P_{\text{confl}}$

**Q** : Quelle est la probabilité d'avoir un motif **conditionné** à un squelette  $\mathbf{c}$ ?



(avec  $i < j$ ),

**R** : **Zéro**, s'il y a des croix rouges dans les colonnes de  $j$ ,  
 $y^{-k}$  si ce n'est pas le cas.




$$\mathbb{P}(M_{ij} | \mathbf{c}) \mu(\mathbf{c}) \equiv \mu(\mathbf{c}')$$

$$\mathbf{c}' = \mathbf{c} \setminus \text{colonnes de } j$$


# Ingédient de l'estimation de $P(r)$ et $P_{\text{confl}}$

**Q** : Quelle est la probabilité d'avoir un motif **conditionné** à un squelette  $\mathbf{c}$ ?



(avec  $i < j$ ),

**R** : **Zéro**, s'il y a des croix rouges dans les colonnes de  $j$ ,  
 $y^{-k}$  si ce n'est pas le cas.




$$\mathbb{P}(M_{ij} | \mathbf{c}) \mu(\mathbf{c}) \equiv \mu(\mathbf{c}')$$

$$\mathbf{c}' = \mathbf{c} \setminus \text{colonnes de } j$$




# Ingédient de l'estimation de $P(r)$ et $P_{\text{confl}}$

**Q** : Quelle est la probabilité d'avoir un motif **conditionné** à un squelette  $\mathbf{c}$ ?



(avec  $i < j$ ),

**R** : **Zéro**, s'il y a des croix rouges dans les colonnes de  $j$ ,  
 $y^{-k}$  si ce n'est pas le cas.




$$\mathbb{P}(M_{ij} | \mathbf{c}) \mu(\mathbf{c}) \equiv \mu(\mathbf{c}')$$

$$\mathbf{c}' = \mathbf{c} \setminus \text{colonnes de } j$$


# Ingédient de l'estimation de $P(r)$ et $P_{\text{confl}}$

**Q** : Quelle est la probabilité d'avoir un motif **conditionné** à un squelette  $\mathbf{c}$ ?



(avec  $i < j$ ),

**R** : **Zéro**, s'il y a des croix rouges dans les colonnes de  $j$ ,  $y^{-k}$  si ce n'est pas le cas.



$$\mathbb{P}(M_{ij} | \mathbf{c}) \mu(\mathbf{c}) \equiv \mu(\mathbf{c}') \quad \mathbf{c}' = \mathbf{c} \setminus \text{colonnes de } j$$

*Bassino-David-Sportiello 2012*

On peut engendrer aléatoirement des automates minimaux en temps moyen  $\mathcal{O}(n^{3/2})$ , avec un générateur de Boltzmann.

- ▶ Génération aléatoire d'automates accessibles en temps  $\mathcal{O}(n^{3/2})$  (Bassino-Nicaud 2007),  
Basée sur un générateur de Boltzmann pour engendrer des partitions d'un ensemble à  $kn$  éléments en  $n$  sous-ensemble.
- ▶ Comme il y a une proportion constante d'automates minimaux, le rejet moyen est en  $\mathcal{O}(1)$ .

# Analyse en moyenne de la minimisation (Moore)

*Bassino-David-Sportiello 2012*

La complexité moyenne de la minimisation avec l'algorithme de Moore est en  $\Theta(n \log \log n)$  pour la distribution uniforme sur les automates déterministes complets et accessibles.

- ▶ La complexité de l'algorithme de minimisation de Moore pour la distribution uniforme sur les automates déterministes à  $n$  états est  $\mathcal{O}(n \log \log n)$  (*David 2011*).
- ▶ La borne supérieure vient de la distribution de la taille de la partie accessible d'une  $k$ -application aléatoire (*Carayol-Nicaud 2012*)
- ▶ La borne inférieure de l'algorithme de Moore appliquée aux automates minimaux à  $n$  états est  $\Omega(n \log \log n)$  (*Bassino-David- Nicaud 2009*)
- ▶ La conclusion vient de la probabilité qu'un automate accessible soit minimal.

# Analyse en moyenne de la minimisation (Hopcroft)

*Bassino-David-Sportiello 2012*

Pour la distribution uniforme sur les automates déterministes complets et accessibles, il existe une famille d'implantations de l'algorithme de Hopcroft dont la complexité moyenne est  $\mathcal{O}(n \log \log n)$ .

Il existe une famille d'implantations de l'algorithme de minimisation de Hopcroft qui sont toujours plus rapides que l'algorithme de Moore. (*David 2011*).

# Que reste-t-il à faire ?

- ▶ Extension au cas des automates incomplets
- ▶ Extension au cas où  $\mathbb{E}[|\mathcal{T}|] \rightarrow 0$  (par exemple,  $\mathbb{E}[|\mathcal{T}|] \sim n^\gamma$ ,  $0 < \gamma < 1$ ).
- ▶ Calcul de propriétés statistiques plus subtiles, en particulier la distribution de la **profondeur de l'arbre de recherche** (à partir de l'état initial).