

# Quelques modèles d'attachement préférentiel

Alain Jean-Marie<sup>1</sup>

<sup>1</sup>INRIA  
LIRMM CNRS/Univ. Montpellier 2

Journée ARC POPEYE  
Avignon, le 9 avril 2009

# Plan de l'exposé

- 1 Introduction
  - Attachement préférentiel : pourquoi, quoi, comment ?
  - L'attachement sans préférence
- 2 Le modèle d'Eggenberger-Pólya
- 3 Le modèle de Simon
- 4 Le modèle de Hoppe
- 5 Un autre point de vue

# Situation

- 1 Introduction
  - Attachement préférentiel : pourquoi, quoi, comment ?
  - L'attachement sans préférence
- 2 Le modèle d'EGgenberger-Pólya
- 3 Le modèle de Simon
- 4 Le modèle de Hoppe
- 5 Un autre point de vue

# Motivations

Modèles d'évolution de populations.

## Attachement

Un processus dynamique au cours duquel des individus arrivent l'un après l'autre et doivent choisir de rejoindre une "classe".

On cherche à expliquer les disparités de population observées :  
"lois d'échelle", "lois de puissance" ?

Exemples de Simon (1951) et + modernes

- villes
- mots dans un texte
- publications scientifiques, nombre de liens dans une page web
- revenus
- nombre d'espèces biologiques, allèles d'un gène
- ...

On cherche une explication **endogène**. Une piste :

### Attachement préférentiel

La classe n'est pas choisie "au hasard" (i.e. uniformément parmi les classes) mais en fonction de la population présente

⇒ les modèles d'urnes sont adaptés : contenu des urnes  $\equiv$  population de la classe.

Également, modèles de graphes : individus et classes sont confondus, et ils s'attachent les uns aux autres

Statistiques recherchées : distribution des populations, valeurs limites quand beaucoup d'individus, ratio des populations dans les classes

# Le modèle d'urne standard

Point de départ : un modèle d'attachement sans préférence particulière.

$N$  urnes.

## Règle

Les boules arrivent une après l'autre. Chaque boule jetée "au hasard" ( $\equiv$  uniformément) dans une urne.

$\implies$  pas de préférence entre les urnes (ou préférences constantes au cours du temps)

Évolution du nombre de boules dans les  $N$  urnes : chaîne de Markov homogène  $X_n = (X_{1,n}, \dots, X_{N,n})$

$$X_{n+1} = X_n + (0, \dots, 0, 1, 0, \dots, 0) \quad \text{avec proba } \frac{1}{K} .$$

↑  $i$ ème coordonnée

# Comportement asymptotique

## Théorème (Loi des grands nombres !)

Presque sûrement, et pour toute condition initiale,

$$\frac{1}{n}X_n \rightarrow \left(\frac{1}{N}, \dots, \frac{1}{N}\right).$$

En particulier, les ratios

$$\frac{X_{i,n}}{X_{j,n}}$$

convergent p.s. vers des valeurs constantes, prévisibles.

# Situation

- 1 Introduction
  - Attachement préférentiel : pourquoi, quoi, comment ?
  - L'attachement sans préférence
- 2 Le modèle d'EGgenberger-Pólya
- 3 Le modèle de Simon
- 4 Le modèle de Hoppe
- 5 Un autre point de vue

# Le modèle d' Eggenberger-Pólya

Une urne, contenant initialement des boules de couleur.

## Règle de l'urne de Pólya-Eggenberger

Une boule est prise au hasard dans l'urne.

Elle est remise dans l'urne avec  $s$  boules de la même couleur.

$\implies$  préférence proportionnelle à la population présente.

Cas de deux couleurs (Rouge, Bleu).

Évolution du nombre de boules dans l'urne : chaîne de Markov homogène  $Z_n = (R_n, B_n)$

$$Z_{n+1} = \begin{cases} (R_n + s, B_n) & \text{avec proba } \frac{R_n}{R_n + B_n} \\ (R_n, B_n + s) & \text{avec proba } \frac{B_n}{R_n + B_n} . \end{cases}$$

## Propriétés

$s$  objets de plus à chaque étape :  $S_n \equiv R_n + B_n = R_0 + B_0 + ns$ .

Soient les ratios :

$$\rho_n = \frac{R_n}{R_n + B_n} \quad \beta_n = \frac{B_n}{R_n + B_n} .$$

### Théorème

Les suites de variables aléatoires  $\{\rho_n\}$  et  $\{\beta_n\}$  sont des martingales par rapport à la filtration engendrée par les  $\{Z_n\}$ .

### Preuve

$$\begin{aligned} \mathbb{E}(\rho_{n+1} | (R_n, B_n)) &= \frac{R_n + s}{S_n + s} \frac{R_n}{S_n} + \frac{R_n}{S_n + s} \frac{B_n}{S_n} \\ &= \frac{R_n(S_n + s)}{(S_n + s)(S_n)} = \rho_n . \end{aligned}$$

## Loi limite

## Théorème (Pólya, 1931)

Presque sûrement,

$$\frac{1}{n} (R_n, B_n) \rightarrow (U, 1 - U)$$

où  $U$  a une distribution  $\text{Beta}(R_0, B_0)$ .Pour mémoire : la densité de la loi  $\text{Beta}(\alpha, \beta)$  est

$$f_{\alpha, \beta}(x) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} x^{\alpha-1} (1-x)^{\beta-1} .$$

En particulier, si  $R_0 = B_0 = 1$ , la distribution est uniforme.

## Les problèmes avec ce résultat

Comme observé par Gaujal, Thierry (2007), ce résultat pose des problèmes potentiels pour les applications :

- la limite n'est pas déterministe
- elle dépend fortement de la condition initiale
- le ratio

$$\tau_n = \frac{\max\{B_n, R_n\}}{\min\{B_n, R_n\}} \sim \frac{\max\{U, 1 - U\}}{\min\{U, 1 - U\}}$$

ne converge que vers une v.a.

⇒ valeur prédictive/explicative du modèle sur un petit nombre d'observations ?

Par contre, des limites p.s. peuvent apparaître pour des généralisations.

# Situation

- 1 Introduction
  - Attachement préférentiel : pourquoi, quoi, comment ?
  - L'attachement sans préférence
- 2 Le modèle d'EGgenberger-Pólya
- 3 **Le modèle de Simon**
- 4 Le modèle de Hoppe
- 5 Un autre point de vue

## Le modèle de Simon

Une suite d'objets de différents "types" arrive. On suppose que :

- la proba que l'objet soit d'un type pas encore apparu est  $\alpha$
- sinon, la proba que l'objet soit d'un type  $k$  déjà apparu est proportionnel à la fréquence empirique de ce type.

Dans le langage des urnes, on obtient ce résultat avec :

### Règles de l'urne de Simon

Une boule est prise au hasard dans l'urne.

Elle est remise dans l'urne avec une seconde boule :

- d'une nouvelle couleur avec proba  $\alpha$
- de la même couleur avec proba  $1 - \alpha$

Se réduit au modèle d'Éggenberger-Pólya si  $\alpha = 0$ . Facilement analysable aussi si  $\alpha = 1$ ...

# L'analyse de Simon

Soit  $f(k, K)$  le nombre **moyen** d'urnes avec  $k$  boules à l'étape  $K$ .

$$f(k, K+1) = f(k, K) + \frac{1-\alpha}{K} ((k-1)f(k-1, K) - kf(k, K)) .$$

De cette récurrence on "dédit" que

$$\frac{1}{K} f(k, K) = \frac{\alpha}{2-\alpha} \frac{\Gamma(k)\Gamma(2+1/\bar{\alpha})}{\Gamma(k+1+1/\bar{\alpha})} \sim k^{-1-1/\bar{\alpha}} .$$

Mais on a le problème qu'il ne s'agit que d'une moyenne.

## Solution exacte

Kullmann et Kertész (2008) ont trouvé la distribution.

Pour  $X_0 = (1)$  et avec  $\bar{\alpha} = 1 - \alpha$ ,

$$\mathbb{P}(X_{i,K} = k) = \alpha^{i-1} \sum_{\ell=1}^k (-1)^{\ell-1} \binom{k-1}{\ell-1} \frac{\Gamma(K - \ell\bar{\alpha})}{\Gamma(k)\Gamma(1 - \ell\bar{\alpha})} \left[ \sum_{b=i}^K \frac{\Gamma(b)\Gamma(1 - \ell\bar{\alpha})}{\Gamma(b - \ell\bar{\alpha})} \binom{b-2}{i-2} \bar{\alpha}^{b-i} \right].$$

Par exemple, la “distribution moyenne de la taille”

$$\lim_{K \rightarrow \infty} \frac{1}{K} \sum_{i=1}^K \mathbb{P}(X_{i,K} = k) = \frac{\Gamma(k)\Gamma(2 + 1/\bar{\alpha})}{\Gamma(k + 1 + 1/\bar{\alpha})} \frac{\alpha}{1 + \bar{\alpha}} \sim k^{-1-1/\bar{\alpha}}.$$

# Situation

- 1 Introduction
  - Attachement préférentiel : pourquoi, quoi, comment ?
  - L'attachement sans préférence
- 2 Le modèle d'Eggenberger-Pólya
- 3 Le modèle de Simon
- 4 Le modèle de Hoppe
- 5 Un autre point de vue

# L'urne de Hoppe

Une seule urne, une couleur spéciale (Noir) et une infinité de couleurs non-noires. Initialement,  $\beta$  boules noires.

## Règle de l'Urne de Hoppe

On tire une boule au hasard dans l'urne. On la remet avec une seconde boule :

- d'une nouvelle couleur si la boule tirée est noire
- de la même couleur sinon.

On crée donc une nouvelle couleur avec probabilité

$$\frac{\beta}{\beta + \sum_i n_i} .$$

Modèle introduit dans Hoppe (1984), analysé dans Hoppe (1987).

Si  $\beta = 0$ , c'est le modèle de Eggenberger-Pólya.

Si  $\beta = 1$ , c'est le modèle du Restaurant Chinois.

## Nouvelles couleurs

Distribution du nombre  $N_K$  de nouvelles couleurs

Fonction génératrice, moyenne... (Ewens 1972)

$$\begin{aligned}\mathbb{E}\left(u^{N_K}\right) &= \prod_{\ell=0}^{K-1} \frac{\ell + \beta u}{\ell + \beta} \\ \mathbb{E}N_K &= \sum_{\ell=0}^{K-1} \frac{\beta}{\ell + \beta} \sim \beta \log K \\ \mathbb{V}N_K &\sim \beta \log K .\end{aligned}$$

Comportement asymptotique :

Théorème (Mahmoud)

$$\frac{N_K - \beta \log K}{\sqrt{\log K}} \rightarrow_{\mathcal{L}} \mathcal{N}(0, \beta) .$$

# Distribution d'occupation

Soit  $A_\ell$  le nombre d'urnes dont la population est  $\ell$ .

## Loi d'occupation (Ewens, Karlin & McGregor, Hoppe)

Pour toute partition  $\mathbf{a} = (a_1, \dots, a_K)$  du nombre  $K$  ( $K = \sum ia_i$ ), on a :

$$\mathbb{P}(\mathbf{A} = \mathbf{a}) = K! \prod_{\ell=1}^K \frac{\beta^{a_\ell}}{a_\ell! \ell^{a_\ell} (\beta + \ell - 1)},$$

dite "Ewens' sampling formula".

# Situation

- 1 Introduction
  - Attachement préférentiel : pourquoi, quoi, comment ?
  - L'attachement sans préférence
- 2 Le modèle d'EGgenberger-Pólya
- 3 Le modèle de Simon
- 4 Le modèle de Hoppe
- 5 **Un autre point de vue**

# Une approche différente

Introduction d'un nouveau modèle.

Raisons :

- pour pouvoir calculer la distribution des populations,
- pour avoir une croissance moins que linéaire du nombre de couleurs

# Une approche différente

Introduction d'un nouveau modèle.

Raisons :

- pour pouvoir calculer la distribution des populations, ne sachant pas que c'est possible pour le modèle de Simon
- pour avoir une croissance moins que linéaire du nombre de couleurs, ne connaissant pas le modèle de Hoppe.

# Une approche différente

Introduction d'un nouveau modèle.

Raisons :

- pour pouvoir calculer la distribution des populations, ne sachant pas que c'est possible pour le modèle de Simon
- pour avoir une croissance moins que linéaire du nombre de couleurs, ne connaissant pas le modèle de Hoppe.

Constatation :

- le modèle de Pólya-Eggenberger est relativement facile à analyser grâce au fait que les ajouts de boules "commutent en probabilité".
- dans le modèle de Simon qui le généralise, on a perdu cette commutation.

⇒ rétablir la situation !

# Commutativité

Deux événements quand la population est  $n = |\mathbf{n}|$  :

- arrivée dans la couleur  $i$  :  $A_i(\cdot)$ , proba  $(1 - \alpha(n))n_i/n$
- nouvelle couleur :  $N(\cdot)$ , proba  $\alpha(n)$

Probabilité de  $A_i(N(\cdot))$  :

$$\alpha(n) (1 - \alpha(n+1)) \frac{n_i}{n+1} .$$

Probabilité de  $N(A_i(\cdot))$  :

$$(1 - \alpha(n)) \frac{n_i}{n} \alpha(n+1) .$$

Égalité si :

$$\alpha(n) = \frac{\beta}{n + \beta} \quad \beta \equiv \frac{\alpha_1}{1 - \alpha_1} .$$

# Règles de l'urne

## Règle de l'urne " commutative "

On tire une boule au hasard dans l'urne. On la remet avec :

- une boule d'une nouvelle couleur avec probabilité  $\alpha(n)$
- une boule de la même couleur avec probabilité  $(1 - \alpha(n))$

où

$$\alpha(n) = \frac{\beta}{n + \beta} .$$

Et c'est l'Urne de Hoppe avec  $\beta$  boules noires !!

Comme dans ce modèle, toutes les évolutions ont la même proba.  
Il suffit de dénombrer les chemins d'un état à un autre.

# Loi de transition

Soient  $\mathbf{n}$  et  $\mathbf{m}$  deux vecteurs :

- $\mathbf{n} \in \mathbb{S}_d \equiv \{(n_1, \dots, n_d), n_i \in \mathbb{N}^*, 1 \leq i \leq d\}$ ,
- $\mathbf{m} \in \mathbb{S}_{d,d'}^+ \equiv \{(n_1, \dots, n_{d'}), n_i \in \mathbb{N}, 1 \leq i \leq d, n_i \in \mathbb{N}^*, d+1 \leq i \leq d'\}$ .

Alors :

## Probas de transition

$\mathbb{P}(\mathbf{n} \rightarrow \mathbf{n} + \mathbf{m})$

$$= \frac{\beta^{d'-d}}{\prod_{j=|\mathbf{n}|}^{|\mathbf{n}|+|\mathbf{m}|-1} j + \beta} \frac{|\mathbf{m}|!}{(d'-d)!} \prod_{i=1}^d \binom{n_i + m_i - 1}{n_i - 1} \prod_{j=d+1}^{d'} \frac{1}{m_j} .$$

## Quelques identités

Identité plutôt connue :

$$\sum_{\substack{\mathbf{m} \in \mathbb{N}^d \\ |\mathbf{m}|=K}} \prod_{i=1}^d \binom{n_i + m_i - 1}{m_i} = [z^K] \frac{1}{(1-z)^{|\mathbf{n}|}} = \binom{|\mathbf{n}| + K - 1}{K}.$$

Identité moins connue (?) :

$$\sum_{\mathbf{m} \in (\mathbb{N}^*)^d, |\mathbf{m}|=K} \prod_{i=1}^d \frac{1}{m_i} = [z^K] \left( \log \frac{1}{1-z} \right)^d = ?$$

# Fonctions génératrices

Un vecteur  $\mathbf{n} \in \mathbb{S}_d$  étant donné :

La FG maîtresse

$$\begin{aligned}
 & \sum_{k=0}^{\infty} u^k \sum_{\mathbf{m} \in \mathbb{S}_{d,d+k}^+, |\mathbf{m}|=K} \prod_{i=1}^{d+k} z_i^{m_i} \mathbb{P}(\mathbf{n} \rightarrow \mathbf{n} + \mathbf{m}) \\
 &= \frac{\Gamma(|\mathbf{n}| + \beta) K!}{\Gamma(|\mathbf{n}| + \beta + K)} [z^K] \prod_{i=1}^d \frac{1}{(1 - zz_i)^{n_i}} \\
 & \quad \sum_{k=0}^{\infty} \frac{(\beta u)^k}{k!} \prod_{j=d+1}^{d+k} \log \frac{1}{(1 - zz_j)}.
 \end{aligned}$$

# Nouvelles couleurs

Distribution du nombre  $N_K$  de nouvelles couleurs

## Nouvelles couleurs

$$\mathbb{E} \left( u^{N_K} \right) = \prod_{\ell=0}^{K-1} \frac{|\mathbf{n}| + \ell + \beta u}{|\mathbf{n}| + \ell + \beta}$$

$$\mathbb{E} N_K = \sum_{\ell=0}^{K-1} \frac{\beta}{|\mathbf{n}| + \ell + \beta} \sim \beta \log K$$

$$\mathbb{V} N_K = \sum_{\ell=0}^{K-1} \frac{\beta}{|\mathbf{n}| + \ell + \beta} \frac{|\mathbf{n}| + \ell}{|\mathbf{n}| + \ell + \beta} \sim \beta \log K .$$

Ce sont les résultats de Ewens/Hoppe modifiés. Voir Pitman.

# Répartition dans les couleurs

FG des populations des “vieilles couleurs” et de la population émigrante  $E_K$  :

FG nouveau monde/ ancien monde

$$\mathbb{E} \left( \prod_{i=1}^d z_i^{X_{i,K}} z_0^{E_K} \right)$$

$$= \frac{\Gamma(|\mathbf{n}| + \beta) K!}{\Gamma(|\mathbf{n}| + \beta + K)} [z^K] \prod_{i=1}^d \frac{1}{(1 - z z_i)^{n_i}} \frac{1}{(1 - z z_0)^\beta} .$$

## Valeurs

Nombres moyens dans les anciennes couleurs  $i$

$$\mathbb{E}X_{i,K} = \frac{Kn_i}{|\mathbf{n}| + \beta} \quad \mathbb{E}E_K = \frac{K\beta}{|\mathbf{n}| + \beta} .$$

Variances...

Pour la répartition dans les nouvelles couleurs...

Nombre moyen dans la nouvelle couleur  $j$

$$\begin{aligned} \mathbb{E}X_{j,K} \\ = \frac{\Gamma(|\mathbf{n}| + \beta)K!}{\Gamma(|\mathbf{n}| + \beta + K)} [z^K] \frac{z}{(1-z)^{|\mathbf{n}|+1}} \sum_{k=j}^{\infty} \frac{\beta^k}{k!} \left( \log \frac{1}{1-z} \right)^{k-1} . \end{aligned}$$

## Propriétés asymptotiques

Lois limites dans les anciennes couleurs : voir Eggenberger-Pólya.

Nombre de nouvelles couleurs : voir Hoppe.

$$\frac{1}{\log K} N_K \rightarrow_{\mathcal{L}} \beta .$$

Population des nouvelles couleurs : pour tout  $j = O(1)$ ,

$$\mathbb{E}X_{j,K} \sim \frac{1}{|\mathbf{n}| + \beta} \frac{\log K}{K} .$$

Convergence pas bien claire pour  $K = O(100)$ ...

## Fréquences et occupations limites

### Proportions limites (Pitman)

Le vecteur de fréquences de population  $(X_{j,K}/K; j = 1, \dots)$  converge vers le vecteur aléatoire

$$(W_1, (1 - W_1)W_2, (1 - W_1)(1 - W_2)W_3, \dots)$$

où les  $W_i$  sont indépendantes et  $\sim \text{Beta}(1, \beta)$ .

### Occupations limites (Pitman)

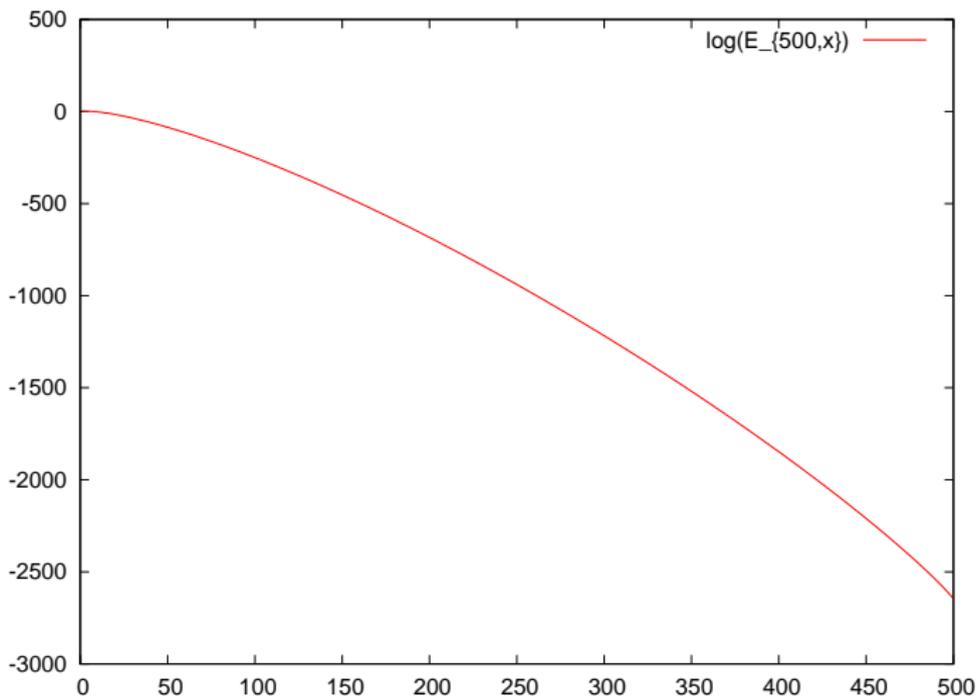
Le vecteur de fréquences d'occupation  $(\#\{j | X_{j,K} = \ell\}, \ell = 1, \dots)$  converge vers le vecteur aléatoire

$$(Z_{\beta,1}, Z_{\beta,2}, \dots)$$

où les  $Z_{\beta,i}$  sont indépendantes et  $\sim \text{Poisson}(\beta/i)$ .

# Repartition des populations

En moyenne, les nouvelles couleurs sont très inégales...



# Généralisation de Pitman

Pitman a introduit un deuxième paramètre.

## Règle de Pitman

Les boules arrivent une par une. Sachant qu'il y a  $k$  couleurs, la boule  $n$  est :

est d'une nouvelle couleur avec probabilité  $\frac{\beta + k\alpha}{n + \beta}$  ,  
 de la couleur  $i$  avec probabilité  $\frac{n_i - \alpha}{n + \beta}$  .

Ce modèle est également "commutatif".

$\implies$  certains résultats se généralisent.

Des asymptotiques en  $n^\alpha$  apparaissent pour  $0 < \alpha < 1$ .

# Perspectives

Parmi les questions en suspens :

- loi limite pour les populations moyennes ?
- loi limite pour les statistiques d'ordre ?
- extension à des urnes “multicolores” plus générales...

# Bibliographie

## Modèles d'Urnes

-  N.J. Johnson and S. Kotz, *Urn Models and Their Application*, Wiley, 1977.
-  H.M. Mahmoud, *Pólya Urn Models*, CRC Press, 2009.
-  J. Pitman, “Combinatorial Stochastic Processes”, Springer, 2006.
-  F.M. Hoppe, “Pólya-like urns and the Ewens’ sampling formula”, *J. Math. Biology*, 20, pp. 91–94, 1984.
-  F.M. Hoppe, “The sampling theory of neutral alleles and an urn model”, *J. Math. Biology*, 25, pp. 123–159, 1987.

## Bibliographie (suite)

### Attachement préférentiel

-  L. Kullmann and J. Kertész, “Preferential growth : exact solution of the time dependent distributions”,  
[arXiv :cond-mat/0012410v1](#), 2008.

### Modèles de population

-  H.A. Simon, “On a class of skew distribution functions”,  
*Biometrika*, 42, 3/4, pp. 425–440, 1951.
-  B. Gaujal, L. Gulyas, Y. Surdati Mansuri and E. Thierry,  
“Markov chain analysis of an agent growth model”, LIP  
Research Report, 2007-15, 2007.