

Génération Aléatoire et Modèle de Boltzmann

Expressivité et Effectivité

Michèle Soria
LIP6 – UPMC


Journées ALEA 2011

CIRM, Marseille, 7 Mars 2011



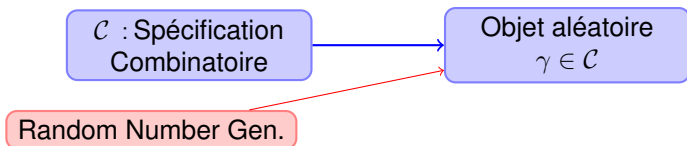
Génération Aléatoire

- **Expérimenter** → **Analyser et Conjecturer**
Test de conjectures, estimation d'ordres de grandeur
visualisation de formes et propriétés limites.
- **Validation de modèles**
Test de modèles (graphes de terrain), signification de
phénomènes observés (séquences biologiques).
- **Tests logiciels**
correction, benchmark, robustesse
couverture typique, génération intensive et automatique
- **Passage à l'échelle** → **Efficacité**
structures de grande taille : 10^6 – 10^9
mots, arbres, graphes, pavages...



Méthodes génériques et automatiques

Classe combinatoire \mathcal{C}



- **Généricité** : Classes Combinatoires \rightarrow Spécifications, Spécifications \rightarrow Équations fonctionnelles de SG,
- **Effectivité** : Générateur compilé à partir des spécifications, algorithmes probabilistes simples

Méthode récursive

Flajolet, Van Cutsem, Zimmerman

- Taille fixée, Génération uniforme
- $\Gamma_{\mathcal{C}}(n)$; $\mathbb{P}(\gamma_n) = 1/c_n$
- Calcul et stockage des coef.
- Complexité de génération : $O(n \log n)$

Méthode de Boltzmann

Duchon, Flajolet, Louchard, Schaeffer

- Taille = v.a. ; mais unif. vs taille
- $\Gamma_{\mathcal{C}}(x)$; $\mathbb{P}(\gamma) \propto e^{|\gamma|} / C(x)$
- Calcul de valeurs de SG $C(x)$
- Complexité linéaire pour génération en taille approchée

Classe combinatoire \mathcal{C} , objets étiquetés

Série génératrice exponentielle $C(z) = \sum_{\gamma \in \mathcal{C}} \frac{z^{|\gamma|}}{|\gamma|!} = \sum_{n \geq 0} \frac{c_n z^n}{n!}$

SPÉCIFICATION DE \mathcal{C} \rightsquigarrow EQUATION FONCTIONNELLE S.G. $C(z)$

Construction	Notation	SG. exponentielle
ε	1	1
atome	\mathcal{Z}	z
Union	$\mathcal{C} = \mathcal{A} \cup \mathcal{B}$	$C(z) = A(z) + B(z)$
Produit	$\mathcal{C} = \mathcal{A} \times \mathcal{B}$	$C(z) = A(z) \times B(z)$
Séquence	$\mathcal{C} = \text{SEQ}(\mathcal{A})$	$C(z) = (1 - A(z))^{-1}$
Ensemble	$\mathcal{C} = \text{SET}(\mathcal{A})$	$C(z) = \exp(A(z))$
Cycle	$\mathcal{C} = \text{CYC}(\mathcal{A})$	$C(x) = -\text{Log}(1 - A(z))$

Analogue pour classes non étiquetées, avec séries génératrices ordinaires.

Générateurs de Boltzmann (DuFLoSc04)

Générateur d'objets étiquetés : $\mathbb{P}_x(\gamma) = \frac{x^{|\gamma|}}{|\gamma|!C(x)}$, avec $C(x) = \sum \frac{x^{|\gamma|}}{|\gamma|!}$ ($x < \rho$)

SPÉCIFICATION DE \mathcal{C} \rightsquigarrow ALGORITHME DE GÉNÉRATION $\Gamma\mathcal{C}(x)$

Construction	Algorithme de génération
$\mathcal{C} = \emptyset$ or \mathcal{Z}	$\Gamma\mathcal{C}(x) := \varepsilon$ or atom
$\mathcal{C} = \mathcal{A} \cup \mathcal{B}$	$\Gamma\mathcal{C}(x) :=$ Bernouilli $\left(\frac{A(x)}{A(x)+B(x)}\right)$; return $\Gamma\mathcal{A}(x)$ or $\Gamma\mathcal{B}(x)$
$\mathcal{C} = \mathcal{A} \times \mathcal{B}$	$\Gamma\mathcal{C}(x) :=$ return $\langle \Gamma\mathcal{A}(x); \Gamma\mathcal{B}(x) \rangle_{\text{etiq}}$ <i>appels indépendants</i>
$\mathcal{C} = \text{SEQ}(\mathcal{A})$	$\Gamma\mathcal{C}(x) := k \leftarrow$ Geometric($A(x)$); return $\langle \underbrace{\Gamma\mathcal{A}(x), \dots, \Gamma\mathcal{A}(x)}_{k \text{ fois}} \rangle_{\text{etiq}}$
$\mathcal{C} = \text{SET}(\mathcal{A})$	$\Gamma\mathcal{C}(x) := k \leftarrow$ Poisson($A(x)$); return $\langle \underbrace{\Gamma\mathcal{A}(x), \dots, \Gamma\mathcal{A}(x)}_{k \text{ fois}} \rangle_{\text{etiq}}$
$\mathcal{C} = \text{CYCLE}(\mathcal{A})$	$\Gamma\mathcal{C}(x) := k \leftarrow$ Logarithmic($A(x)$); return $\langle \underbrace{\Gamma\mathcal{A}(x), \dots, \Gamma\mathcal{A}(x)}_{k \text{ fois}} \rangle_{\text{etiq}}$

$$\alpha \in \mathcal{A} \cup \mathcal{B} \rightarrow \mathbb{P}_x(\alpha) = \frac{A(x)}{A(x)+B(x)} \frac{x^{|\alpha|}}{|\alpha|!A(x)} = \frac{x^{|\alpha|}}{|\alpha|!A(x)}$$

$$\gamma \in \mathcal{C} = \mathcal{A} \times \mathcal{B} \rightarrow \mathbb{P}_x(\gamma) = \frac{x^{|\alpha|}}{|\alpha|!A(x)} \cdot \frac{x^{|\beta|}}{|\beta|!B(x)} \cdot (\alpha + \beta)! = \frac{x^{|\alpha|+|\beta|}}{(|\alpha|+|\beta|)!A(x)B(x)} = \frac{x^{|\gamma|}}{|\gamma|!C(x)}$$

$$\gamma = (\alpha_1, \dots, \alpha_k) \in \text{SEQ}(\mathcal{A}) \rightarrow \mathbb{P}_x(\gamma) = A(x)^k(1-A(x)) \cdot \frac{x^{|\alpha_1|}}{|\alpha_1|!A(x)} \cdots \frac{x^{|\alpha_k|}}{|\alpha_k|!A(x)} \cdot (\alpha_1 + \dots + \alpha_k)! = \frac{x^{|\gamma|}}{|\gamma|!C(x)}$$

Générateurs de Boltzmann (DuFLoSc04)


- Génération libre, paramètre x
- Algorithmes probabilistes : *choix aléatoire selon lois de paramètre $A(x)$*
- Évaluation numérique des séries génératrices : *calcul de l'oracle*
- Générateur aléatoire uniforme $[0,1]$ + manipulation de réels

Théorème (Complexité de la génération libre – DuFLoSc04)

Le générateur de Boltzmann $\Gamma C(x)$ d'une classe C , spécifiée récursivement sur les opérateurs $\varepsilon, Z, U, \times, \text{Seq}, \text{Set}, \text{Cycle}$, a une **complexité arithmétique linéaire en la taille du résultat** (sous hypothèse oracle en $O(1)$).

Algorithm : Geom-Poisson-Loga(x)


```
 $U \leftarrow \text{uniform}(); S \leftarrow 0; k \leftarrow 0;$   
while  $U < S$  do  
   $S \leftarrow S + p_k; k \leftarrow k + 1;$  od  
Return  $k;$   $O(k+1)$ 
```




Générateurs de Boltzmann non étiqueté (FIFuPi07)

Théorème (FIFuPi07)


Pour une classe C **non étiquetée**, spécifiée récursivement par des opérateurs $\varepsilon, Z, U, \times, \text{Seq}, \text{Set}, \text{Cycle}$, le générateur de Boltzmann $\Gamma C(x)$ a une **complexité arithmétique linéaire en la taille du résultat**.




Partition plane




Composition circulaire




Graphe fonctionnel



Arbre non planaire



Alcool acyclique



Circuit série-parallèle


Distribution de la taille

- Générateur libre \rightarrow taille objet engendré = **v. aléatoire N**


$$\mathbb{P}_x(N = n) = \frac{c_n x^n}{n! C(x)} \quad \text{et} \quad \mathbb{E}_x(N) = x \frac{C'(x)}{C(x)}$$

mais **uniformité** à taille donnée : $\mathbb{P}_x(\gamma_n) = \frac{x^n}{n! C(x)}$


- Distribution taille dépend de **x**, $0 < x < \rho$
et du **type de singularité SG**



$$C(x) = e^{(e^x - 1)}$$



$$C(x) = \frac{1}{2 - e^x}$$



$$C(x) = \frac{1 - \sqrt{1 - 4x}}{2}$$

Contrôle de la taille

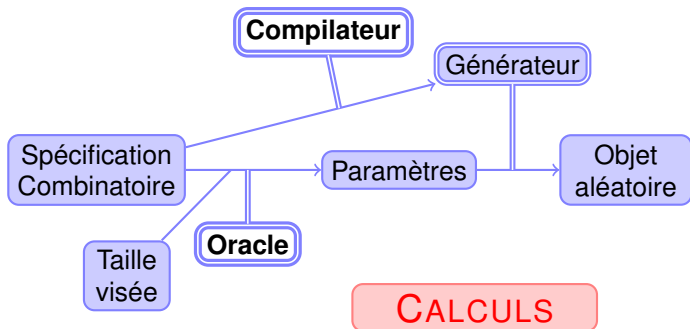
- **Contrôle de la taille** : générer objets de taille exacte n , ou de de taille approchée $[n(1 - \varepsilon), n(1 + \varepsilon)]$,
- **Rejet** : si la taille ne convient pas, rejeter et lancer une autre génération
- **Taille approchée** : complexité moyenne (essentiellement) linéaire

Complexité de la génération contrôlée (DuFILoSc04, FIFuPi07)

Soit \mathcal{C} une classe combinatoire, spécifiée récursivement à l'aide des opérateurs ε , \mathbb{Z} , \cup , \times , Seq , Set , Cyc . Le générateur avec rejet $\Gamma \mathcal{C}(x, n, \varepsilon)$ a une complexité moyenne en $\mathcal{O}(n)$:


- Distributions en cloche : 1 essai en moyenne pour engendrer un objet de taille $\in [n(1 - \varepsilon), n(1 + \varepsilon)]$
 - Distributions plates : $\mathcal{O}(1)$ essais en moyenne pour engendrer un objet de taille $\in [n(1 - \varepsilon), n(1 + \varepsilon)]$
 - Distributions piquées : $\mathcal{O}(n)$ essais mais pointage pour se ramener à distribution plate
- Mais $\mathcal{O}(n^2)$ pour taille exacte ($\mathcal{O}(n)$ pour distributions en cloche).

EXPRESSIVITÉ



- Extensions à d'autres opérateurs combinatoires
 - Cycle pointé non-étiqueté (*BoFuKaVi07, PaSt07*)
 - Langages Réguliers avec Shuffle (*DaPaRoSo10*)
 - Produit Boite (*RoSo09*)
 - Opérateurs différentiels (Roussel, *BoSoRo11*)
 - Produit d'Hadamard $O(n\sqrt{n})$ (*BoGaRo10*)
 - ...
- Extensions à d'autres univers combinatoires
 - Semi-étiquetés et colorés (*BoJa09*)
 - Classes multiplicatives Boltzmann-Dirichlet (*BoBa11*)
 - ...
- Génération Biaisée
 - Boltzmann multicritère (*BoPo10*)
 - Boltzmann "uniforme biaisé"
 - ...

- Calculs de séries
 - Oracle pour systèmes combinatoires récurrents et différentiels (Salvy, *PiSaSo11*)
 - Rayon de convergence ?
 - Paramètre en fonction de la taille visée ?
 - Systèmes combinatoires multivariés ?
 - ...
- Certification
 - arithmétique réelle : impact des erreurs (Duchon)
 - arithmétique discrète : générateurs de Boltzman binaires (*FIPeSo11*)
 - ...
- Implantation
 - Générateurs automatiques
 - Bibliothèques dédiées
bio, tests, automates, arbres, réseaux
 - ...



- **Généricité** et **Effectivité**
- Complexité moyenne **booléenne** en $O(|\gamma|)$
- Simulateur parfait de v.a. discrètes
 - X : Géométrique, Poisson, Logarithmique
 - $\mathbb{P}(X = k)$ nécessite $O(k)$ bits en moyenne

Algorithm : Bernoulli(p)

```
 $i \leftarrow 1 + \text{Geom}(1/2);$   
Return  $\text{Bit}_i(p)$ ;
```

$\mathbb{P}(\#bits = i) = 2^{-(i+1)}, \mu = 2$

bits indépendant de p

$\text{Bit}_i(p)$: accès avec proba $\frac{1}{2^{(i+1)}}$

Algorithm : Géométrie(p)

```
 $k \leftarrow 0;$   
do  $i \leftarrow 1 + \text{Geom}(1/2);$   
if  $\text{Bit}_i(p) = 1$  then Return  $k$ ;  
          else  $k \leftarrow k + 1$ ;  
fi;od;
```

$O(k+1)$ bits pour $\text{Geom}(p) = k$

$$\text{SGE } (\mathcal{P}) : P(x) = \sum P_n \frac{x^n}{n!}$$

Algorithm : Schema Von Neuman (x, \mathcal{P})

do

$N \leftarrow \text{Geom}(x)$;

Tirer U_1, \dots, U_N v.a. indep. unif. $[0, 1]$;

if $\sigma(U_1, \dots, U_N) \in \mathcal{P}$ **then** Return N ;

od;

$$\mathbb{P}(VN(x, \mathcal{P}) = n) = \frac{1}{P(x)} \frac{P_n x^n}{n!} \text{ Boltz}$$

- $U_1 < \dots < U_n$
 $P_n = 1 \rightarrow P(x) = e^x$
 \Rightarrow **Poisson**
- $U_1 < \{U_2, \dots, U_n\}$
 $P_n = (n-1)! \rightarrow P(x) = \log \frac{1}{1-x}$
 \Rightarrow **Logarithmique**

Générateur discret (FIPeSo11) : $U_i = \sum_{j>0} b_j 2^{-j}$, $b_j \in \{0, 1\}$

- Générer (U_1, \dots, U_N) avec le minimum de bits pour les différencier
- Construction d'un trie :
 - LC = nombre de bits consommés
 - 1 seul registre

Théorème (FIPeSo11)

– \mathcal{P} classe de permutations et x paramètre, Schéma von Neumann \rightarrow

exactement v.a. discrete $\mathbb{P}(N = n) = \frac{1}{P(\lambda)} \frac{P_n \lambda^n}{n!}$.

– **Nombre moyen d'itérations** $\frac{1}{s}$, $s = (1 - x)P(x)$, et distrib. $1 + \text{Geom}(s)$.

– S.G. probabilités du **nombre C de flips** consommés par l'algorithme :

$$E(q^C) = \frac{qH^+(x, q)}{1 - qH^-(x, q)},$$

$$H^+(z, q) = (1 - z) \sum_{n=0}^{\infty} \frac{P_n}{n!} h_n(q) z^n, \quad H^-(z, q) = (1 - z) \sum_{n=0}^{\infty} \left(1 - \frac{P_n}{n!}\right) h_n(q) z^n.$$

– **Queues de distribution exponentielles.**

En cours :

- Extension autres lois
- Intégration dans générateur de Boltzmann


II - Boltzmann Uniforme Biisé

Générateur de Boltzmann Biisé : $\Gamma\mathcal{A}(x) \rightarrow \Gamma\mathcal{A}(ux)$

Soit $\Gamma\mathcal{A}(x)$ gen. Boltzmann engendre α avec probabilité $p_\alpha(x)$.

Soit $\delta_{A,x}(t)$ densité de probabilité sur σ .

Alors le **générateur biaisé** $\Gamma\mathcal{A}(ux)$, avec u tiré selon $\delta_{A,x}(t)$, engendre α avec probabilité $q_\alpha(x) = \int_\sigma p_\alpha(tx) \delta_{A,x}(t) dt$.



Générateur exponentiel $\widehat{\Gamma} \rightarrow$ Générateur ordinaire Γ

$$\Gamma \mathcal{A}(x) = \widehat{\Gamma} \mathcal{A}(ux)$$

- Générateur exponentiel : $\widehat{\Gamma} \mathcal{A}(x)$

$$p_\alpha(x) = \frac{x^{|\alpha|}}{|\alpha|!} \frac{1}{A_E(x)}, \quad \text{avec } A_E(x) = \sum_{\alpha \in \mathcal{A}} \frac{x^{|\alpha|}}{|\alpha|!}$$

- Générateur ordinaire : $\Gamma \mathcal{A}(x)$

$$q_\alpha(x) = \frac{x^{|\alpha|}}{A_O(x)}, \quad \text{avec } A_O(x) = \sum_{\alpha \in \mathcal{A}} x^{|\alpha|}$$

- Biais : $\delta_{A,x}(t) = \frac{A_E(xt)}{A_O(x)} e^{-t}$ sur $[0, \infty)$

$$\begin{aligned} \mathbb{P}(\Gamma \mathcal{A}(x) = \alpha/n) &= \int_0^\infty \mathbb{P}(\widehat{\Gamma} \mathcal{A}(xt) = \alpha) \cdot \delta_{A,x}(t) dt \\ &= \int_0^\infty \frac{(xt)^n}{n! A_E(xt)} \cdot \frac{A_E(xt)}{A_O(x)} e^{-t} dt \\ &= \frac{x^n}{A_O(x)} \int_0^\infty \frac{t^n}{n!} \cdot e^{-t} dt \\ &= \frac{x^n}{A_O(x)} \end{aligned}$$

$$\Gamma \mathcal{A}(x) = \dot{\Gamma} \mathcal{A}(ux)$$

- Générateur pointé $\dot{\Gamma} \mathcal{A}(x) : p_\alpha(x) = \frac{\alpha x^{|\alpha|}}{xA'(x)}$
- Générateur non pointé $\Gamma \mathcal{A}(x) : q_\alpha(x) = \frac{x^{|\alpha|}}{A(x)}$
- Biais $\delta_{A,x}(t) = \frac{x A'(xt)}{A(x) - A(0)}$ sur $[0, 1]$

$$\begin{aligned} \mathbb{P}(\Gamma \mathcal{A}(x) = \alpha / n > 0) &= \int_0^1 \frac{n(xt)^n}{xt A'(xt)} \cdot \frac{x A'(xt)}{A(x) - A(0)} dt \\ &= \frac{x^n}{A(x) - A(0)} \int_0^1 n t^{n-1} du = \frac{x^n}{A(x) - A(0)} \end{aligned}$$

- Générateur base $\Gamma \rightarrow$ Générateur intégré $\bar{\Gamma} \mathcal{A}(x) = \Gamma \mathcal{A}(ux)$
 $p_\alpha(x) = \frac{x^{|\alpha|}}{A(x)}, \quad q_\alpha(x) = \frac{x^{|\alpha|+1}}{(|\alpha|+1) \int_0^x A(v)}, \quad \delta_{A,x}(t) = \frac{x A'(xt)}{\int_0^x A(v)}$ sur $[0, 1]$

Exemple : Arbres de Cayley

- Enracinés : $\mathcal{A} = \mathcal{Z} \times \text{SET}(\mathcal{A})$ $A(z) = \sum n^{n-1} \frac{z^n}{n!}$

$\Gamma A(x) := k \leftarrow \text{Poisson}(A(x)),$
return $\mathcal{Z} \times \underbrace{\langle \Gamma A(x), \dots, \Gamma A(x) \rangle}_k$

- Non enracinés $B(z) = \sum n^{n-2} \frac{z^n}{n!} \rightarrow zB'(z) = A(z)$

$\Gamma B(x) := \text{tirer } u \text{ sur } [0, 1] \text{ selon densité } \frac{A(x)}{xB(x)} ;$
return $\Gamma A(ux)$

- Enracinés croissants $\mathcal{C} = \mathcal{Z}^\square \times \text{SET}(\mathcal{C}) \rightarrow \mathcal{C}'(z) = e^{\mathcal{C}(z)}$
 $\rightarrow \mathcal{C}(z) = -\text{Log}(1 - z)$

$\Gamma C(x) := \text{tirer } u \text{ sur } [0, 1] \text{ selon densité } \frac{x\mathcal{C}'(x)}{\mathcal{C}(x)}$
 $k \leftarrow \text{Poisson}(C(ux)),$
return $\mathcal{Z} \times \underbrace{\langle \Gamma C(ux), \dots, \Gamma C(ux) \rangle}_k$

Nouveaux opérateurs

Combinaison de GB Biaisés : $(\Gamma\mathcal{B}(ux), \Gamma\mathcal{C}(ux)) \rightarrow \Gamma\mathcal{A}(x)$

$\Gamma\mathcal{B}(x)$ et $\Gamma\mathcal{C}(x)$ générateurs de Boltzmann pour \mathcal{B} et \mathcal{C} ,

$\delta_{\mathcal{B},\mathcal{C},x}(t)$ densité de probabilité sur σ ; $\mathcal{A} = \mathcal{B} \star \mathcal{C}$

u tiré selon $\delta_{\mathcal{B},\mathcal{C},x}(t)$, $(\Gamma\mathcal{B}(ux), \Gamma\mathcal{C}(ux)) \rightarrow \Gamma\mathcal{A}(x)$.

- Produit Boîte :

$$\mathcal{A} = \mathcal{B}^{\square} \times \mathcal{C} \rightarrow A(z) = \int_0^z B'(t)C(t)dt$$

$\Gamma\mathcal{A}(x) :=$ tirer u selon $\delta(t) = \frac{x B'(tx) C(tx)}{A(x)}$, sur $[0,1]$

$\beta \leftarrow \Gamma B'(xu)$; $\gamma \leftarrow \Gamma C(xu)$

return $\alpha = \text{ProduitBoite}(\beta, \gamma)$

Généralisation :

GB pour équation
différentielle du 1er ordre

$\mathcal{T}' = \mathcal{F}(\mathcal{Z}, \mathcal{T})$ (BoRoSo11)

- Produit ordonné :

$$\mathcal{A} = \mathcal{B} \bullet \mathcal{C} \rightarrow A(z) = \int_0^z B'(z-t)C(t)dt$$

$\Gamma\mathcal{A}(x) :=$ tirer u selon $\delta(t) = \frac{B'(x-t)C(t)}{A(x)}$, sur $[0,x]$

$\beta \leftarrow \Gamma B'(x-u)$; $\gamma \leftarrow \Gamma C(u)$

return $\alpha = \text{ProduitOrdonne}(\beta, \gamma)$

Application : GB pour
langages réguliers avec
Shuffle (DaPaRoSo10)