

Quelques utilisations des arbres en combinatoire

Yann Verhoeven

L.R.I.

Université Paris-Sud XI

Plan
Arbres de ...
2-SAT ...
Connexité ...
Conclusion



Plan

- Présentation des arbres de Galton-Watson
 - Définition
 - Propriété
- Le seuil de satisfaisabilité de 2-SAT aléatoire
 - Présentation
 - Résultats généraux concernant le seuil
 - L'utilisation des arbres aléatoires
- La forte connexité dans le graphe aléatoire dirigé
 - Un résultat de seuil
 - Les arbres aléatoires et la forte connexité
- Conclusion

Plan

Arbres de ...
2-SAT ...
Connexité ...
Conclusion



Arbres de Galton-Watson

Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion

Nous utilisons les arbres de Galton-Watson.

- aléatoires ;
- même distribution D à chaque génération.

On les construit de la manière suivante (en notant Z_i le nombre d'enfants du $i^{\text{ème}}$ enfant),


- une racine a Z_1 enfants (Z_1 distribué selon D) ;
 - chacun des Z_1 enfants a un nombre aléatoire d'enfants (distribué selon D) ;
 - ...



Exemple de réalisation

On considère l'arbre :

- $Z_1 = 2$
- $Z_2 = 3, Z_3 = 1$
- $Z_4 = 0, Z_5 = 1, Z_6 = 2, Z_7 = 3$
- ...



Propriété fondamentale

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

Soit un arbre dont la loi de reproduction est D .

On note m l'espérance de la distribution D ,

on considère la fonction génératrice f de D

$$f(s) = \sum_{k=0}^{\infty} p_k s^k, s \in [0, 1].$$

- si $m \leq 1$, l'arbre s'éteint presque sûrement ;
- si $m > 1$, il existe un unique $q \in [0, 1[$ tel que $f(q) = q$ et l'arbre survit avec probabilité $1 - q$.



2-SAT aléatoire

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

On considère des formules **booléennes**.

- Variables booléennes ;
- opérateurs booléens : **négation** (\neg), **et** (\wedge) et **ou** (\vee).

Les formules **2-CNF** : conjonctions de clauses de taille 2.

Un exemple :

on prend les variables u_1 , u_2 et u_3 ,

$$\phi = (u_1 \vee u_2) \wedge (u_1 \vee \neg u_2) \wedge (u_2 \vee u_3) \wedge (\neg u_1 \vee \neg u_3).$$



Le problème 2-SAT

entrée : une formule sous forme 2-CNF

sortie : existe-t-il une valuation satisfaisant cette formule ?

Plan

Arbres de ...

2-SAT ...

Connexité ...


Conclusion

Pourquoi étudier ce problème qui est dans P ?

- Appartient à la famille de problèmes **k-SAT** qui est importante en informatique et dont la version probabiliste présente un phénomène de seuil pour $k \geq 2$;
- **k-SAT** apparaît en physique statistique.



Le phénomène de seuil



Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion



Les formules aléatoires

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

Deux façons de tirer des formules aléatoirement, pour n variables,

- on considère toutes les clauses possibles et chacune est choisie avec probabilité p . Ce modèle est noté $\mathcal{F}_{n,p}$;
- on choisit de manière uniforme une formule parmi celles contenant m clauses. Ce modèle est noté $\mathcal{F}_{n,m}$.

Nous exprimons nos résultats dans le modèle $\mathcal{F}_{n,p}$, la traduction dans le modèle $\mathcal{F}_{n,m}$ est facile.



Le seuil de transition

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

Théorème [Goerdts 92, Chvátal et Reed 92]

Soit $F = \mathcal{F}_{n,m}$ avec $m = m(n)$.

Alors, on a

i. si $\frac{m}{n} \leq c$, pour $c < 1$ fixé, alors

$$\lim_{n \rightarrow \infty} \Pr[F \text{ est satisfaisable}] = 1 ;$$

ii. si $\frac{m}{n} \geq c$, pour $c > 1$ fixé, alors

$$\lim_{n \rightarrow \infty} \Pr[F \text{ est insatisfaisable}] = 1.$$



Au dela du seuil

Les fonctions $\rho_S = \rho_S(n)$ et $\rho_I = \rho_I(n)$ sont dites admissibles si l'on a

$$\frac{m}{n} \leq \rho_S \Rightarrow \Pr[F \text{ est satisfaisable}] = 1 - o(1),$$

$$\frac{m}{n} \geq \rho_I \Rightarrow \Pr[F \text{ est satisfaisable}] = o(1).$$

Alors, sont admissibles,

$$\rho_S = 1 - \varepsilon$$

$$\rho_I = 1 + \varepsilon$$

[Goerdt 92, Chvátal et Reed 92]

$$\rho_S = 1 - 1/\sqrt{\ln n}$$

[Goerdt 99]

$$\rho_I = 1 + \omega(n)n^{-1/4}$$

[Verhoeven 99]

$$\rho_S = 1 - \omega(n)n^{-1/8}$$

[de la Vega 00]

$$\rho_S = 1 - \omega(n)n^{-1/3} \quad \rho_I = 1 + \omega(n)n^{-1/3}$$

[Bollobás, Borgs, Chayes, Kim, Wilson 01]

$$\rho_S = 1 - \omega(n)n^{-1/3}$$

[de la Vega et Verhoeven 01]

Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion



Le graphe associé

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

On transforme une formule 2-CNF F en un graphe dirigé $G(F)$ [Aspvall, Plass, Tarjan].

Pour chacune des n variables u_i on introduit dans le graphe les sommets u_i et $\neg u_i$.

Pour chaque clause $u \vee v$ de F on introduit les arcs :

$$\neg u \rightarrow v \text{ et } \neg v \rightarrow u.$$

$$(\neg\neg v = v)$$

Théorème [Aspvall, Plass et Tarjan 79]

Une formule 2-CNF F est insatisfaisable si et seulement s'il existe dans $G(F)$ un circuit contenant un littéral et son complément.




Un exemple :

On considère à nouveau

$$\phi = (u_1 \vee u_2) \wedge (u_1 \vee \neg u_2) \wedge (u_2 \vee u_3) \wedge (\neg u_1 \vee \neg u_3).$$

Le graphe qui lui est associé est



Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion



Une borne supérieure du seuil

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

Théorème [Verhoeven 99]

Soit $F = \mathcal{F}_{n,p}$ avec $p \geq (1 + n^{-1/4})/2n$. Alors

$$\lim_{n \rightarrow \infty} \Pr[F_{n,p} \text{ est insatisfaisable}] = 1.$$



Schéma de démonstration

On prend $p \geq (1 + n^{-1/4})/2n$.

Pour montrer l'insatisfaisabilité d'une formule, on cherche s'il existe une variable u tel qu'on ait dans le graphe associé :

- un chemin de u vers $\neg u$;
- un chemin de $\neg u$ vers u .

Un algorithme qui trouve de tels chemins avec probabilité $1 - o(1)$ permet de conclure en vertu du théorème de [Aspvall, Plass et Tarjan].

Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion



L'algorithme

Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion


Schéma de l'algorithme :

- soit u un sommet de $G(F)$;
- on construit pas à pas l'arbre des sommets atteignables à partir de u (dont la frontière est notée $X_t(u)$) et l'arbre des sommets qui peuvent atteindre $\neg u$ (dont la frontière est notée $Y_t(\neg u)$),
 - si l'un des deux arbres meurt on choisit un sommet v parmi ceux non encore touchés et on recommence ;
 - dès que les frontières $X_t(u)$ et $Y_t(\neg u)$ atteignent la taille $\omega(n)\sqrt{2n}$ pour un certain t l'algorithme s'arrête avec succès car deux ensembles de taille $\omega(n)\sqrt{2n}$ sont reliés par un arc dans les deux sens avec probabilité $1 - o(1)$.




Illustration de l'algorithme

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion





Développement d'un arbre

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion




Utilisation des arbres de Galton-Watson

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion





Utilisation des arbres de Galton-Watson (2)

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion



Utilisation des arbres de Galton-Watson (3)

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion



Lemmes intermédiaires, la taille de l'arbre

Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion

On suppose $X(u) = X_\infty(u)$.

On pose $p \geq (1 + n^{-1/4})/2n$.

Lemme

Soit $F = \mathcal{F}_{n,p}$ et u un littéral de F . Alors

$$\Pr \left[|X(u)| \geq \omega(n)\sqrt{2n} \right] \geq 12n^{-1/4}.$$

Et par ailleurs,

$$E[|X(u)| \mid |X(u)| < \omega(n)\sqrt{2n}] \leq 2n^{1/4}.$$

Ce lemme est obtenu à l'aide d'arbres de Galton-Watson.



Lemmes intermédiaires, l'algorithme réussit

- On développe deux arbres de façon indépendante ;
- chacun est suffisamment grand avec une probabilité supérieure à $12n^{-1/4}$.

Lemme

L'algorithme présenté permet de trouver deux sous-ensembles de $G(F)$ dont les tailles des frontières sont au moins $\omega(n)\sqrt{2n}$ après au plus $\omega(n)n^{1/2}/3$ essais avec probabilité $1 - o(1)$.

Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion



Lemmes intermédiaires, nombre de sommets utilisés

- L'algorithme comporte au plus $\omega(n)n^{1/2}/3$ étapes ;
- chaque étape qui échoue “consomme” $2n^{1/4}$ sommets.

Lemme

L'algorithme présenté n'utilise pas plus de $\omega(n)n^{3/4}$ sommets, avec probabilité $1 - o(1)$, avant de trouver deux sous-ensembles de $G(F)$ dont la frontière est de taille $\omega(n)\sqrt{2n}$.

Il suffit donc de prévoir initialement $H = \omega(n)n^{3/4}$ sommets de réserve.

Plan

Arbres de ...

2-SAT ...

Connexité ...

Conclusion



Connexité forte

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

On considère le graphe aléatoire dirigé $D_{n,p}$ à n sommets où chaque arc est présent avec la probabilité p .

Deux sommets x et y appartiennent à la même **composante fortement connexe** si et seulement si

- il existe un chemin de x à y ;
- et il existe un chemin de y à x .

Motivations de ce problème,

- il est relié au problème **2-SAT** ;
- il est lié à un phénomène de seuil ;
- peut être un outil de l'étude du World Wide Web.



Le seuil et l'existence de la composante géante

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

Comme dans le cas non orienté [Erdős-Rényi], on assiste à un phénomène de seuil pour la taille de la composante fortement connexe dans $D_{n,p}$ [Karp].

Le phénomène est le suivant,

- si $p = (1 - \varepsilon)/n$ pour $\varepsilon > 0$ fixé, les composantes connexes sont “petites” ;
- si $p = (1 + \varepsilon)/n$ pour ε fixé, il apparaît une composante fortement connexe “géante”.



La composante géante

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

Théorème [Karp 91]

Soit $\omega(n)$ une fonction croissante non bornée, c une constante strictement supérieure à 1 et Θ la racine de $1 - x - e^{-cx} = 0$ dans $]0, 1[$.

Il existe une constante M telle que, avec probabilité $1 - o(1)$,

- un graphe aléatoire orienté $D_{n,c/n}$ a exactement une composante fortement connexe contenant plus de $M \log n$ sommets ;
- la taille de cette composante est comprise dans l'intervalle

$$[\Theta^2 n - \omega(n) \sqrt{n \log n}, \Theta^2 n + \omega(n) \sqrt{n \log n}].$$



Une taille plus précise

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

Théorème [Verhoeven 01]

Soit $\omega(n)$ une fonction croissante non bornée, c une constante strictement supérieure à 1 et Θ la racine de $1 - x - e^{-cx} = 0$ dans $]0, 1[$.

Alors,

- la taille de la composante géante de $D_{n,c/n}$ est comprise dans l'intervalle

$$[\Theta^2 n - \omega(n)\sqrt{n}, \Theta^2 n + \omega(n)\sqrt{n}].$$

Ce résultat est obtenu à l'aide d'arbres de Galton-Watson.



Conclusion

- Plan
- Arbres de ...
- 2-SAT ...
- Connexité ...
- Conclusion

Utilisation des arbres de Galton-Watson dans l'analyse d'algorithmes de recherche :

- recherche en largeur [Verhoeven]
 - une borne supérieure du seuil de 2-SAT aléatoire ;
 - une estimation des fluctuations de la taille de la composante fortement connexe géante.
- recherche en profondeur [Ajtai, Komlós et Szemerédi] ;

