

Classes d'équivalences d'arbres booléens

Application à un problème de satisfaisabilité.

Aléa 2014

Cécile Mailler
Prob-L@B – University of Bath

LATIN'14 – en collaboration avec Antoine Genitrini (LIP6)

20 mars 2014

Qu'est ce qu'un problème SAT ?

$$\mathcal{E}(x_1, x_2, x_3) = [(x_1 \wedge \bar{x}_2) \vee x_1 \vee x_2] \wedge x_3$$

Cette expression booléenne est-est **satisfaisable** ?

i.e. existe-t-il $(\alpha_1, \alpha_2, \alpha_3) \in \{0, 1\}^3$ tel que $\mathcal{E}(\alpha_1, \alpha_2, \alpha_3) = 1$?

Qu'est ce qu'un problème SAT ?

$$\mathcal{E}(x_1, x_2, x_3) = [(x_1 \wedge \bar{x}_2) \vee x_1 \vee x_2] \wedge x_3$$

Cette expression booléenne est-elle **satisfaisable** ?

i.e. existe-t-il $(\alpha_1, \alpha_2, \alpha_3) \in \{0, 1\}^3$ tel que $\mathcal{E}(\alpha_1, \alpha_2, \alpha_3) = 1$?

Oui, il suffit de prendre
 $\alpha_2 = 1$ et $\alpha_3 = 1$.

Problème NP-complet

Qu'est ce qu'un problème SAT ?


$$\mathcal{E}(x_1, x_2, x_3) = [(x_1 \wedge \bar{x}_2) \vee x_1 \vee x_2] \wedge x_3$$

Cette expression booléenne est-elle **satisfaisable** ?

i.e. existe-t-il $(\alpha_1, \alpha_2, \alpha_3) \in \{0, 1\}^3$ tel que $\mathcal{E}(\alpha_1, \alpha_2, \alpha_3) = 1$?


Oui, il suffit de prendre
 $\alpha_2 = 1$ et $\alpha_3 = 1$.

Problème NP-complet



Problème 3-SAT

Dans le cadre 3-SAT, on se restreint aux expressions de la forme



où $l_{ij} \in \{x_1, \bar{x}_1, \dots, x_k, \bar{x}_k\}$.

Problème NP-complet

Cadre probabiliste

Tirons uniformément au hasard une expression de type 3–SAT à n clauses et k variables :


quelle est la probabilité qu'elle soit satisfaisable ?

Cadre probabiliste

Tirons uniformément au hasard une expression de type 3-SAT à n clauses et k variables :

quelle est la probabilité qu'elle soit satisfaisable ?

Conjecture



Asymptotiquement
quand n tend
vers $+\infty$.

Catalan–SAT


Notre idée : enlever la contrainte structurelle des formules 3–SAT.

Tirons uniformément au hasard un arbre (binaire) booléen à n feuilles.

$$l_1, \dots, l_n \in \{x_1, \bar{x}_1, \dots, x_k, \bar{x}_k\}.$$

On prend $k = k_n$, fonction croissante de n telle que $k_n \rightarrow +\infty$.

$$\mathbb{P}_n(\text{SAT}) = ?$$



Catalan–SAT


Notre idée : enlever la contrainte structurelle des formules 3–SAT.

Tirons uniformément au hasard un arbre (binaire) booléen à n feuilles.

$$l_1, \dots, l_n \in \{x_1, \bar{x}_1, \dots, x_k, \bar{x}_k\}.$$

On prend $k = k_n$, fonction croissante de n telle que $k_n \rightarrow +\infty$.

$$\mathbb{P}_n(\text{SAT}) = ?$$



Modèle (\mathbb{F})

Pour toute $f : \{0, 1\}^{k_n} \rightarrow \{0, 1\}$,

$$\mathbb{P}_n(f) = \frac{\# \text{ arbres à } n \text{ feuilles et } k_n \text{ variables calculant } f}{\# \text{ arbres à } n \text{ feuilles et } k_n \text{ variables}} = ?$$

Seconde introduction

Si k est fixé, alors, pour toute $f : \{0, 1\}^{k_0} \rightarrow \{0, 1\}$,

$$\mathbb{P}_{n,k}(f) \xrightarrow{n \rightarrow +\infty} \mathbb{P}_k(f) = \Theta_{k \rightarrow +\infty} \left(\frac{1}{k^{L(f)+1}} \right),$$

où $L(f)$ est la complexité d'une fonction booléenne, i.e. la taille des plus petits arbres la représentant. [LEFMANN-SAVICKÝ '97, KOZIK '09]

Complexité

- fonctions constantes Vrai et Faux : $L(\text{Vrai}) = L(\text{Faux}) = 0$
- fonction XOR : $L(\text{XOR}) = 4$ ($x_1 \text{ XOR } x_2 = (x_1 \wedge \bar{x}_2) \vee (\bar{x}_1 \wedge x_2)$)

Seconde introduction

Si k est fixé, alors, pour toute $f : \{0, 1\}^{k_0} \rightarrow \{0, 1\}$,

$$\mathbb{P}_{n,k}(f) \xrightarrow{n \rightarrow +\infty} \mathbb{P}_k(f) = \Theta_{k \rightarrow +\infty} \left(\frac{1}{k^{L(f)+1}} \right),$$

où $L(f)$ est la complexité d'une fonction booléenne, i.e. la taille des plus petits arbres la représentant. [LEFMANN-SAVICKÝ '97, KOZIK '09]

Complexité

- fonctions constantes Vrai et Faux : $L(\text{Vrai}) = L(\text{Faux}) = 0$
- fonction XOR : $L(\text{XOR}) = 4$ ($x_1 \text{ XOR } x_2 = (x_1 \wedge \bar{x}_2) \vee (\bar{x}_1 \wedge x_2)$)


Faisons tendre n et k vers l'infini simultanément !

Modèle (\mathbb{F})

$$\mathbb{P}_n(f) = \frac{\# \text{ arbres à } n \text{ feuilles et } k_n \text{ variables calculant } f}{\# \text{ arbres à } n \text{ feuilles et } k_n \text{ variables}} \underset{n \rightarrow +\infty}{\sim} ?$$

Classes d'équivalence

Exemples



Même relation d'équivalence pour les fonctions :

$\langle f \rangle$ = classe d'équivalence de f .

de classes d'équivalence d'arbres de taille n à k_n variables
calculant une fonction de $\langle f \rangle$

$$\mathbb{P}_n \langle f \rangle = \frac{\text{\# de classes d'équivalence d'arbres de taille } n \text{ à } k_n \text{ variables calculant une fonction de } \langle f \rangle}{\text{\# de classes d'équivalence d'arbres de taille } n \text{ à } k_n \text{ variables}}$$

Nos deux modèles

Modèle (E)

$$\mathbb{P}_n\langle f \rangle \underset{n \rightarrow +\infty}{\sim} ?$$

Modèle (F)

$$\mathbb{P}_n(f) = \frac{\# \text{ arbres à } n \text{ feuilles et } k_n \text{ variables calculant } f}{\# \text{ arbres à } n \text{ feuilles et } k_n \text{ variables}} \underset{n \rightarrow +\infty}{\sim} ?$$

Définitions

Quelques définitions avant le résultat :

- Une variable x_i est **essentielle** pour f si $f|_{x_i=1} \neq f|_{x_i=0}$.
 $\mathbf{Ess}(f) = \#$ variables essentielles de f .
- **multiplicité** de $f = \#$ répétitions dans un arbre minimal de f ,

$$\mathbf{R}(f) = L(f) - \mathbf{Ess}(f).$$

Exemples

- $R(\text{Vrai}) = R(\text{Faux}) = L(\text{Vrai}) - \mathbf{Ess}(\text{Vrai}) = 0 - 0 = 0$
- $R(x_1 \vee x_2) = 2 - 2 = 0$
- $R(x_1 \text{ XOR } x_2) = 4 - 2 = 2$

Résultat

Modèle (F)

Pour toute fonction $f : \{0, 1\}^{k_0} \rightarrow \{0, 1\}$,

$$\mathbb{P}_n(f) = \Theta \left(\left(\frac{1}{k_n} \right)^{L(f)+1} \right).$$

Modèle (E)

Pour toute fonction $f : \{0, 1\}^{k_0} \rightarrow \{0, 1\}$,


- Si $k_n \leq \frac{n}{\ln n}$, alors $\mathbb{P}_n(f) = \Theta \left(\left(\frac{1}{k_n} \right)^{R(f)+1} \right)$;
- Si $k_n \geq \frac{n}{\ln n}$, alors $\mathbb{P}_n(f) = \Theta \left(\left(\frac{\ln n}{n} \right)^{R(f)+1} \right)$.

Résultat

Modèle (F)

Pour toute fonction $f : \{0, 1\}^{k_0} \rightarrow \{0, 1\}$,

$$\mathbb{P}_n(f) = \Theta \left(\left(\frac{1}{k_n} \right)^{L(f)+1} \right).$$



Modèle (E)


Pour toute fonction $f : \{0, 1\}^{k_0} \rightarrow \{0, 1\}$,

- Si $k_n \leq \frac{n}{\ln n}$, alors $\mathbb{P}_n(f) = \Theta \left(\left(\frac{1}{k_n} \right)^{R(f)+1} \right)$;
- Si $k_n \geq \frac{n}{\ln n}$, alors $\mathbb{P}_n(f) = \Theta \left(\left(\frac{\ln n}{n} \right)^{R(f)+1} \right)$.

Idées de la preuve : Modèle (E).

$A_n = \#$ classes d'équivalence d'arbres à n feuilles et k_n variables


$$A_n = 2^{n-1} C_{n-1} B_{n,k_n}$$



Idées de la preuve : Modèle (E).

$A_n = \#$ classes d'équivalence d'arbres à n feuilles et k_n variables

$$A_n = 2^{n-1} C_{n-1} B_{n,k_n}$$




étiquetage : $B_{n,k_n} = \sum_{p=1}^{k_n} \binom{n}{p} 2^{n-p}$

- p est le nombre de parts de la partition

Idées de la preuve : Modèle (E).

$A_n = \#$ classes d'équivalence d'arbres à n feuilles et k_n variables

$$A_n = 2^{n-1} C_{n-1} B_{n,k_n}$$



étiquetage : $B_{n,k_n} = \sum_{p=1}^{k_n} \binom{n}{p} 2^{n-p}$

- p est le nombre de parts de la partition
- ensuite, chaque part est partitionnée en deux parts (dont une peut être vide)

Idées de la preuve : Modèle (E).

Donc $A_n = 2^{2n-1} C_{n-1} B_{n,k_n}$, où

$$B_{n,k_n} = \sum_{p=1}^{k_n} \left\{ \begin{matrix} n \\ p \end{matrix} \right\} 2^{n-p}.$$

Lemme technique

- Si $k_n \leq \frac{n}{\ln n}$, $\frac{B_{n-1,k_n}}{B_{n,k_n}} = \Theta\left(\frac{1}{k_n}\right)$;
- Si $k_n \geq \frac{n}{\ln n}$, $\frac{B_{n-1,k_n}}{B_{n,k_n}} = \Theta\left(\frac{\ln n}{n}\right)$.

intuition au tableau

Idées de la preuve : Modèle (E).

Donc $A_n = 2^{2n-1} C_{n-1} B_{n,k_n}$, où

$$B_{n,k_n} = \sum_{p=1}^{k_n} \left\{ \begin{matrix} n \\ p \end{matrix} \right\} 2^{n-p}.$$

Lemme technique

- Si $k_n \leq \frac{n}{\ln n}$, $\frac{B_{n-1,k_n}}{B_{n,k_n}} = \Theta\left(\frac{1}{k_n}\right)$;
- Si $k_n \geq \frac{n}{\ln n}$, $\frac{B_{n-1,k_n}}{B_{n,k_n}} = \Theta\left(\frac{\ln n}{n}\right)$.

intuition au tableau

N.B. Dans le modèle (F),

$$\begin{aligned} A_n &= 2^{n-1} C_{n-1} (2k_n)^n \\ &= 2^{n-1} C_{n-1} B_{n,k_n} \end{aligned}$$

avec $B_{n,k_n} = (2k_n)^n$, et

$$\frac{B_{n-1,k_n}}{B_{n,k_n}} = \frac{1}{2k_n}.$$

Reformulation du résultat

Théorème – Modèle (E) :

Pour toute fonction $f : \{0, 1\}^{k_0} \rightarrow \{0, 1\}$,

$$\mathbb{P}_n \langle f \rangle = \Theta \left(\left(\frac{B_{n-1, k_n}}{B_{n, k_n}} \right)^{R(f)+1} \right).$$

Théorème – Modèle (F) :

Pour toute fonction $f : \{0, 1\}^{k_0} \rightarrow \{0, 1\}$,

$$\mathbb{P}_n(f) = \Theta \left(\left(\frac{B_{n-1, k_n}}{B_{n, k_n}} \right)^{L(f)+1} \right).$$

Tautologies

Comprendre comment le lemme technique implique le résultat

On va regarder le cas particulier $f \equiv \text{Vrai}$:

Lemme :

Asymptotiquement quand n tend vers $+\infty$, $\mathbb{P}_n\langle \text{Vrai} \rangle = \Theta\left(\frac{B_{n-1, k_n}}{B_{n, k_n}}\right)$.

Preuve en deux étapes :

- asymptotiquement quand n tend vers l'infini, presque toute tautologie est *simple*
- la proportion des tautologies simples à n feuilles et k_n variables se comporte en $\Theta\left(\frac{B_{n-1, k_n}}{B_{n, k_n}}\right)$

Tautologies

Comprendre comment le lemme technique implique le résultat

On va regarder le cas particulier $f \equiv \text{Vrai}$:

Lemme :


Asymptotiquement quand n tend vers $+\infty$, $\mathbb{P}_n\langle \text{Vrai} \rangle = \Theta\left(\frac{B_{n-1, k_n}}{B_{n, k_n}}\right)$.

Preuve en deux étapes :

- asymptotiquement quand n tend vers l'infini, presque toute tautologie est *simple* **[admis pour l'exposé]**
- la proportion des tautologies simples à n feuilles et k_n variables se comporte en $\Theta\left(\frac{B_{n-1, k_n}}{B_{n, k_n}}\right)$ **[on va montrer ça]**

Tautologies

Comptons les tautologies simples :



Tautologies simples

Comptons les tautologies simples :

$$S(z) = z^2 K''(A(z))$$

et


$$TS_n = B_{n-1, k_n} [z^n] S(z),$$

où

$$K(z) = \frac{1 - \sqrt{1 - 4z}}{2} - z,$$

et

$$A(z) = \frac{1 - \sqrt{1 - 8z}}{4} + \frac{z}{2}.$$



Tautologies simples

Donc,

$$\frac{TS_n}{A_n} = \frac{B_{n-1,k_n} [z^n] z^2 K''(A(z))}{B_{n,k_n} [z^n] 2A(z)},$$

car

$$A_n = 2^{n-1} C_{n-1} B_{n,k_n} = B_{n,k_n} [z^n] 2A(z).$$

Donc, quand $n \rightarrow +\infty$,

$$\mathbb{P}_n(\text{Vrai}) \sim \frac{TS_n}{A_n} = \frac{B_{n-1,k_n}}{B_{n,k_n}} \Theta(1).$$

Tautologies simples

Donc,

$$\frac{TS_n}{A_n} = \frac{B_{n-1,k_n} [z^n] z^2 K''(A(z))}{B_{n,k_n} [z^n] 2A(z)},$$

car


$$A_n = 2^{n-1} C_{n-1} B_{n,k_n} = B_{n,k_n} [z^n] 2A(z).$$

Donc, quand $n \rightarrow +\infty$,

$$\mathbb{P}_n\langle \text{Vrai} \rangle \sim \frac{TS_n}{A_n} = \frac{B_{n-1,k_n}}{B_{n,k_n}} \Theta(1).$$

en vrai, on a multi-compté, mais on peut montrer que l'erreur est négligeable...

Cas général



On suit la stratégie de [KOZIK '09] :

- quand n tend vers l'infini, presque tout arbre calculant f est *simple*
- la proportion de *simple*- f est donnée par

$$\Theta \left(\left(\frac{B_{n-1, k_n}}{B_{n, k_n}} \right)^{R(f)+1} \right),$$

dans le modèle (E).

Conclusion

On a réussi à comprendre :

- comment faire tendre n et k vers l'infini simultanément –
Modèle (\mathbb{F})

→ *pas de changement par rapport au modèle classique*

- comment le modèle change quand on introduit des classes
d'équivalence – Modèle (\mathbb{E})

→ *phénomène de saturation en $k_n = \frac{n}{\ln n}$*

Conclusion

On a réussi à comprendre :


- comment faire tendre n et k vers l'infini simultanément –
Modèle (\mathbb{F})

→ *pas de changement par rapport au modèle classique*


- comment le modèle change quand on introduit des classes
d'équivalence – Modèle (\mathbb{E})

→ *phénomène de saturation en $k_n = \frac{n}{\ln n}$*

Concernant le problème SAT :



Ouvertures




Changer la distribution sur les arbres : ABR aléatoire, ou arbres triangulaires (déterministes).

On conjecture une transition de phase dans ce modèle.

On sait que à k fixé, les modèles d'arbres *saturés* vérifient

$$\mathbb{P}_{n,k}(\text{SAT}) \xrightarrow{n \rightarrow \infty} \frac{1}{2}.$$

On espère



Merci de votre attention !