



Arbres de contexte, identification et adaptivité

Application à la modélisation

Aurélien Garivier

Université Paris Sud

Orsay

Plan de l'exposé

- Notions de théorie de l'information
- Le modèle des sources à arbres de contexte
- Identification par MDL
- Prédiction et mélanges

Notations

- Soit E un alphabet fini de lettres. Les **mots** sur E sont les éléments de $E^* = \bigcup_{n=0}^{\infty} E^n$.
- Pour $x, s \in E^*$, le **nombre d'occurrences** de s dans x est
$$N_x(s) = \sum_{i=1}^{|x|-s+1} \mathbb{1}_{x_i^{i+|s|-1} = s}$$
- Pour $P \in \mathbb{P}(E)$, l'**entropie** de P est
$$H(P) = \sum_{a \in E} P(a) \log \frac{1}{P(a)}$$
- Pour $x \in E^n$, l'**entropie empirique** (coût de codage) de x est ($\log = \log_2$):

$$H(x) = nH(\hat{p}_x) = \sum_{a \in E} N_x(a) \log \frac{n}{N_x(a)}$$

Théorie de l'information - Shannon '48

- **Problème** : code $f_n : E^n \rightarrow \{0, 1\}^*$ injectif
- **Hypothèse** : x est la réalisation d'une **source** P_n
- \implies **coût moyen** : $C(f_n) = \sum_{x \in E^n} P_n(x) |f_n(x)|$
- **Théorème** (optimisation)

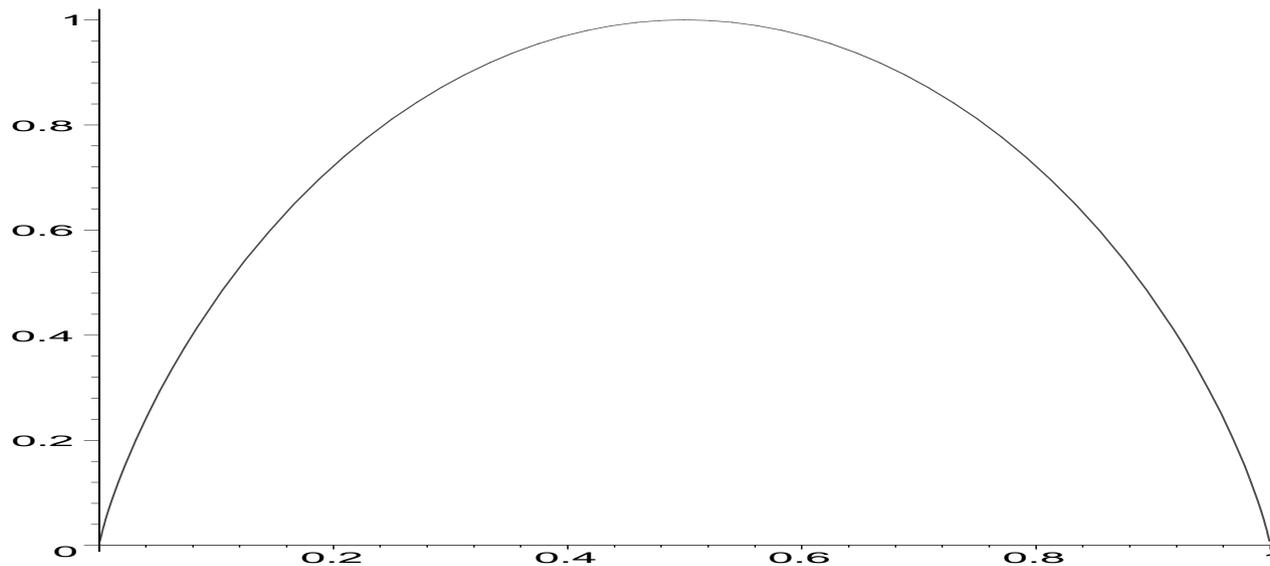
$$C(f_n) \geq \sum_{x \in E^n} P_n(x) \log \frac{1}{P_n(x)} \triangleq nH_n(P_n)$$

- Pour toutes les sources *stationnaires ergodiques*,
 $H_n(P_n) \rightarrow H(P)$ **entropie** de la source P .
- Il existe des codes s'approchant arbitrairement près du
taux de codage entropique.

Exemple

$E = \{0, 1\}$, $P =$ source sans mémoire : $X_i \stackrel{iid}{\sim} B(p)$, $0 < p < 1$.

$$H_n(P) = H_1(p) = h(p) = p \log \frac{1}{p} + (1 - p) \log \frac{1}{1 - p}$$



Le codage arithmétique

- Idée : coder en calculant des probabilités selon une **Proba de codage** Q_n
- $f_n(x) = \text{les } \lceil -\log Q_n(x) \rceil + 2 \text{ premiers bits de } Q_n(X \leq x)$.
- $$C(f_n) = \mathbb{E}_{P_n} -\log Q_n(X)_{(+2)} = nH_n(P) + nD_n(P_n|Q_n)_{(+2)}$$
- La meilleur proba de codage est le maximum de vraisemblance.
- La **redondance** (= perte par rapport au “coût idéal”) s’interprète mathématiquement comme une distance de Kullback-Leibler.

Codage universel

- **Problème** : si on ne connaît pas P ?
- Coder efficacement reste possible au prix d'un surcoût = redondance.
- Idée 1 (sources sans mémoire) :
 - on code la loi empirique $\rightarrow (|E| - 1) \log n$ bits
 - puis on code x avec cette proba de codage $\rightarrow nH$ bits
- Idée 2 (sources sans mémoire) : Proba de codage $Q = \text{mélange}$ des lois sans mémoire.

Le mélange de Krichevsky-Trofimov

- Notons $\Theta_E = \{\theta \in [0, 1]^E : \sum_{a \in E} \theta_a = 1\}$ et \mathbb{P}_θ la loi du processus iid sur $E^{\mathbb{Z}}$ défini par $\mathbb{P}_\theta(X_0 = a) = \theta_a$.
- Mélange de Krichevski-Trofimov sur E^n :

$$\mathcal{KT}(x_1^n) = \int_{\theta \in \Theta_E} P_\theta(x_1^n) \frac{\Gamma\left(\frac{|E|}{2}\right)}{\sqrt{|E|} \Gamma\left(\frac{1}{2}\right)^{|E|}} \prod_{a \in E} \theta_a^{-1/2} d\theta_a$$

- Calcul itératif : comme un MV avec $|E|$ “demi-expériences” avant de commencer :

$$\mathcal{KT}(011) = \frac{1/2}{1} \times \frac{1/2}{2} \times \frac{3/2}{3} = \frac{1}{16}.$$

Optimalité

- Utilisation en codage itératif.
- Il vérifie la propriété fondamentale suivante :
 $\forall x \in E^n,$
$$-\log \mathcal{KT}(x) \leq \inf_{\theta \in \Theta} -\log P_{\theta}(x) + \frac{1}{2} (|E| - 1) \log n + |E|/2$$
- \implies **redondance minimax** sur la classe des processus iid.

Plan de l'exposé

- Notions de théorie de l'information
- Le modèle des sources à arbres de contexte
- Identification par MDL
- Prédiction et mélanges

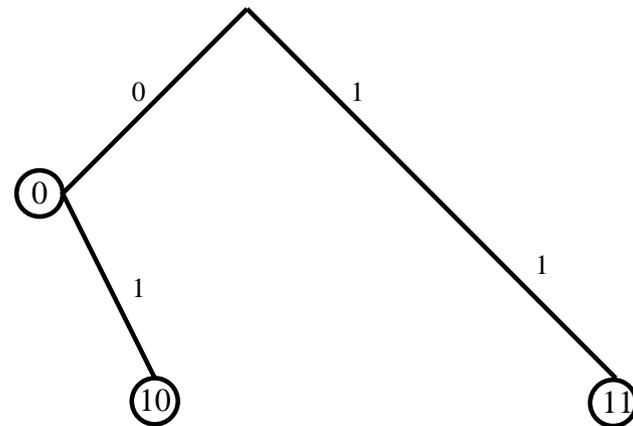
Dictionnaires complets de suffixes

- Un ensemble de mots \mathcal{T} est un **dictionnaire complet de suffixes** (DCS) si $\forall x_{-\infty}^0 \in E^{\mathbb{Z}^-}, \exists ! k \in \mathbb{N} : x_{-k}^0 \in \mathcal{T}$.
- Exemples :
 - $\mathcal{T} = \{00, 10, 1\}$ en est un.
 - $\mathcal{T} = \{0, 10, 11\}$ n'en est pas un, car $\mathcal{T}(\dots 010)$ n'est pas défini.
 - $\mathcal{T} = \{10^k : k \in \mathbb{N}\}$ en est un infini.
- On note $\mathcal{T}(y)$ l'unique suffixe d'un mot y dans \mathcal{T} .
- Pour $x = x_{-\infty}^n$ et $s \in \mathcal{T}$, le sous-mot de x qui apparaît dans le contexte s est $\mathcal{T}(x, s) = \odot_{i=1, \mathcal{T}}^n (x_{-\infty}^{i-1})=s x_i$

Tries et arbres de suffixes

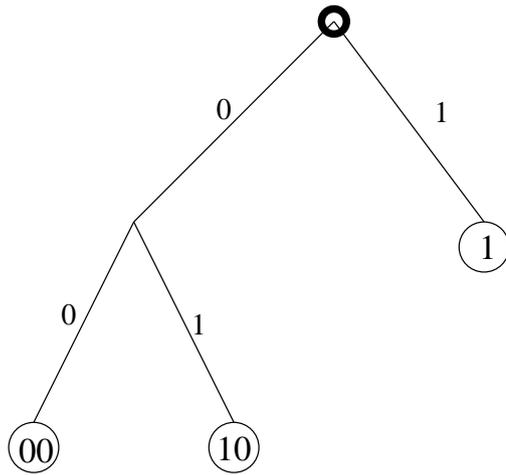
- Un **trie** est un arbre dont les arêtes sont étiquetées par des lettres.
- Aux noeuds d'un trie sont associés les mots obtenues en lisant les étiquettes *remontant* à la racine.
- Réciproquement, on peut associer un trie à tout ensemble de mots (comme ici $\{10, 0, 11\}$).

Mais il se peut que certains ne soient pas des feuilles !

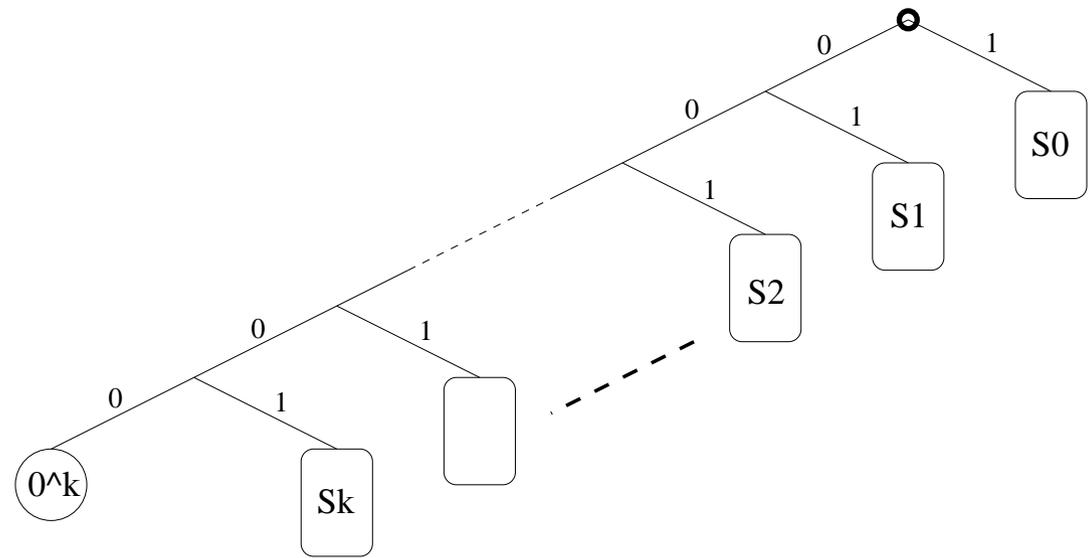


Représentation des DCS comme trie

- A tout DCS \mathcal{T} correspond un trie dont les feuilles sont associées les éléments de \mathcal{T} , et réciproquement.
- Exemples :



$$\mathcal{T} = \{00, 10, 1\}$$



$$\mathcal{T} = \{0^k\} \cup \{10^j : 0 \leq j < k\}$$

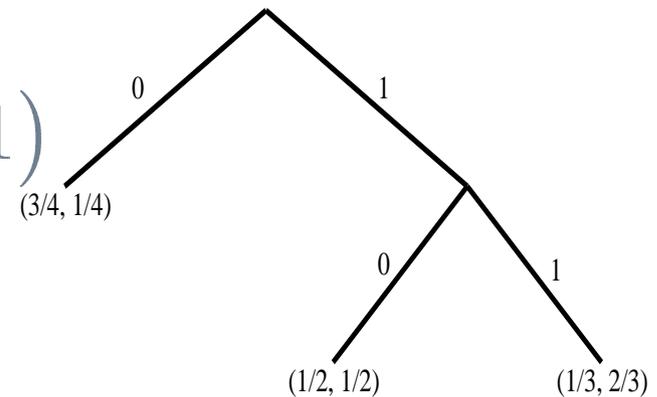
Sources à arbre de contexte

- Etant donné un DCS \mathcal{T} , appelé par la suite **arbre de contexte**, et $|\mathcal{T}|$ lois de probabilité sur E notées $p = (p(\cdot|w))_{w \in \mathcal{T}}$, la **source à arbre de contexte** $\mathbb{P}_{\mathcal{T},p}$ est la loi stationnaire sur $E^{\mathbb{Z}}$ définie par

$$\mathbb{P}_{\mathcal{T},p} (X_1 = x_1 | X_{-\infty}^0 = x_{-\infty}^0) = p(x_1 | \mathcal{T}(x_{-\infty}^0)).$$

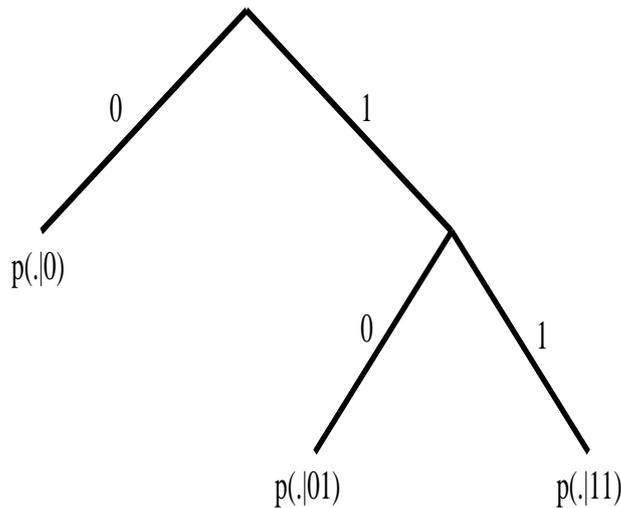
- Exemple :

$$\begin{aligned} \mathbb{P} (X_1^4 = 1001 | X_{-\infty}^0 = \dots 01) \\ = \frac{1}{2} \times \frac{1}{3} \times \frac{3}{4} \times \frac{1}{4} \end{aligned}$$



Les CTS *finies* sont des chaînes de Markov

- La profondeur de l'arbre est alors l'ordre markovien.



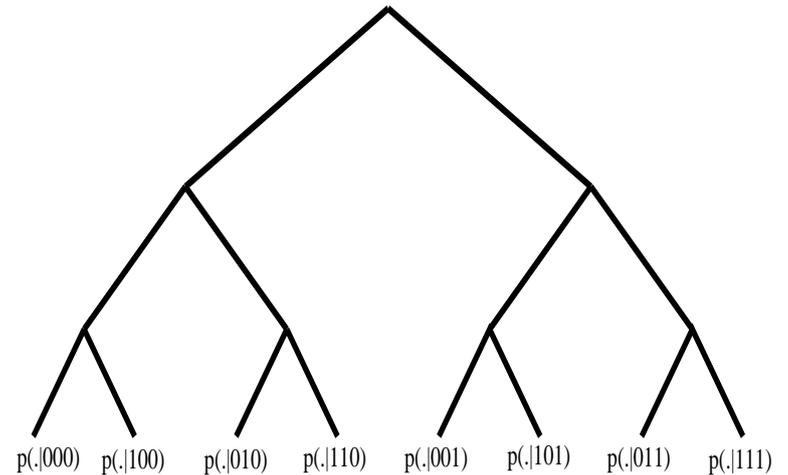
$$\rightarrow M = \begin{pmatrix} p(.|0) \\ p(.|0) \\ p(.|01) \\ p(.|11) \end{pmatrix}$$

- Variable Length* Markov Chains : les CTS peuvent avoir moins de degrés de liberté pour une même taille de mémoire.

Les chaînes de Markov sont des CTS

- Le trie correspond est l'arbre plein de profondeur égal à l'ordre markovien :

$$M = \begin{pmatrix} p(.|000) \\ p(.|100) \\ \vdots \\ p(.|111) \end{pmatrix}$$



- ⇒ les CTS ont le pouvoir d'universalité des CDM et peuvent approcher toutes les sources stationnaires ergodiques.
- pas plus difficile à utiliser.

Expression de la vraisemblance

- $x = \odot_{s \in \mathcal{T}} \mathcal{T}(x, s) \rightarrow$ vraisemblance s'écrit :

$$\begin{aligned} P_{\mathcal{T}, p}(x_1^n | x_{-\infty}^0) &= \prod_{i=1}^n p(x_i | \mathcal{T}(x_{-\infty}^{i-1})) \\ &= \prod_{s \in \mathcal{T}} p_s(\mathcal{T}(x, s)) \end{aligned}$$

- D'où l'expression du maximum de vraisemblance :

$$-\log \hat{P}_{\mathcal{T}}(x) = \sum_{s \in \mathcal{T}} H(\mathcal{T}(x, s))$$

Mélange de \mathcal{KT} pour un modèle

- On définit

$$\mathcal{KT}_{\mathcal{T}}(x_1^n | x_{-\infty}^0) = \prod_{s \in \mathcal{T}} \mathcal{KT}(\mathcal{T}(x, s))$$

- **Théorème** : il existe une constante C telle que :

$$\begin{aligned} -\log_2 \mathcal{KT}_{\mathcal{T}}(x_1^n | x_{-\infty}^{-1}) &\leq \inf_{\theta \in \Theta^{\mathcal{T}}} -\log_2 \mathbb{P}_{\mathcal{T}, \theta}(x_1^n | x_{-\infty}^{-1}) \\ &\quad + |\mathcal{T}| \frac{|E| - 1}{2} \log \left(\frac{n}{|\mathcal{T}|} \right) + C |\mathcal{T}| \end{aligned}$$

- Cette redondance (ponctuelle) est minimax dans ce modèle.

Plan de l'exposé

- Notions de théorie de l'information
- Le modèle des sources à arbres de contexte
- Identification par MDL
- Prédiction et mélanges

Le principe MDL

- Idée du codage en 2 temps : le modèle \mathcal{M} puis les données x sachant \mathcal{M} .
- Plus le modèle est riche, plus il peut facilement décrire les données.
- Mais il est lui-même plus difficile à décrire !
- \implies Minimum Description Length : choisir le modèle qui minimise le coût *total* de représentation des données.

MDL et estimateur BIC

- Coût “idéal” pour représenter x dans le modèle \mathcal{T} : $-\log \hat{P}_{\mathcal{T}}(x)$
- Nombre de bits nécessaires pour décrire les paramètres d’une source basée sur l’arbre \mathcal{T} : $|\mathcal{T}| (|E| - 1) \log n$
- \implies On minimise en \mathcal{T} le **critère BIC** :

$$\hat{\mathcal{T}}_{BIC}(x) = \min_{\mathcal{T}} -\log \hat{P}_{\mathcal{T}}(x) + \frac{1}{2} |\mathcal{T}| (|E| - 1) \log n$$

MDL et estimateur \mathcal{KT}

- Le coût de x avec la loi de codage $\mathcal{KT}_{\mathcal{T}}$ est :

$$-\log \mathcal{KT}_{\mathcal{T}}(x)$$

- \implies On minimise en \mathcal{T} le **critère** \mathcal{KT} :

$$\hat{\mathcal{T}}_{\mathcal{KT}}(x) = \min_{\mathcal{T}} -\log \mathcal{KT}_{\mathcal{T}}(x)$$

- Remarque : \mathcal{KT} un peu moins que BIC car

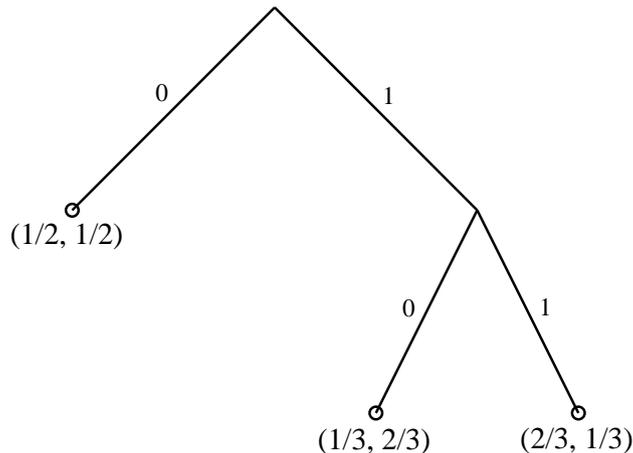
$$-\log_2 \mathcal{KT}_{\mathcal{T}}(x_1^n) \leq -\log_2 \hat{\mathbb{P}}_{\mathcal{T}}(x_1^n) + |\mathcal{T}| \frac{|E| - 1}{2} \log \left(\frac{n}{|\mathcal{T}|} \right) + C |\mathcal{T}|$$

Algorithme original context - Rissanen '81

- Pour tout $s \in \mathcal{T}$:

$$D(P_s. || P_s) = \sum_{a \in E} H(\mathcal{T}(x, sa)) - H(\mathcal{T}(x, s)) \geq 0$$

- Idée : casser les s tq $D(P_s. || P_s) \geq \frac{|E|-1}{2} \log n$
- Problème [Weinberger...]:

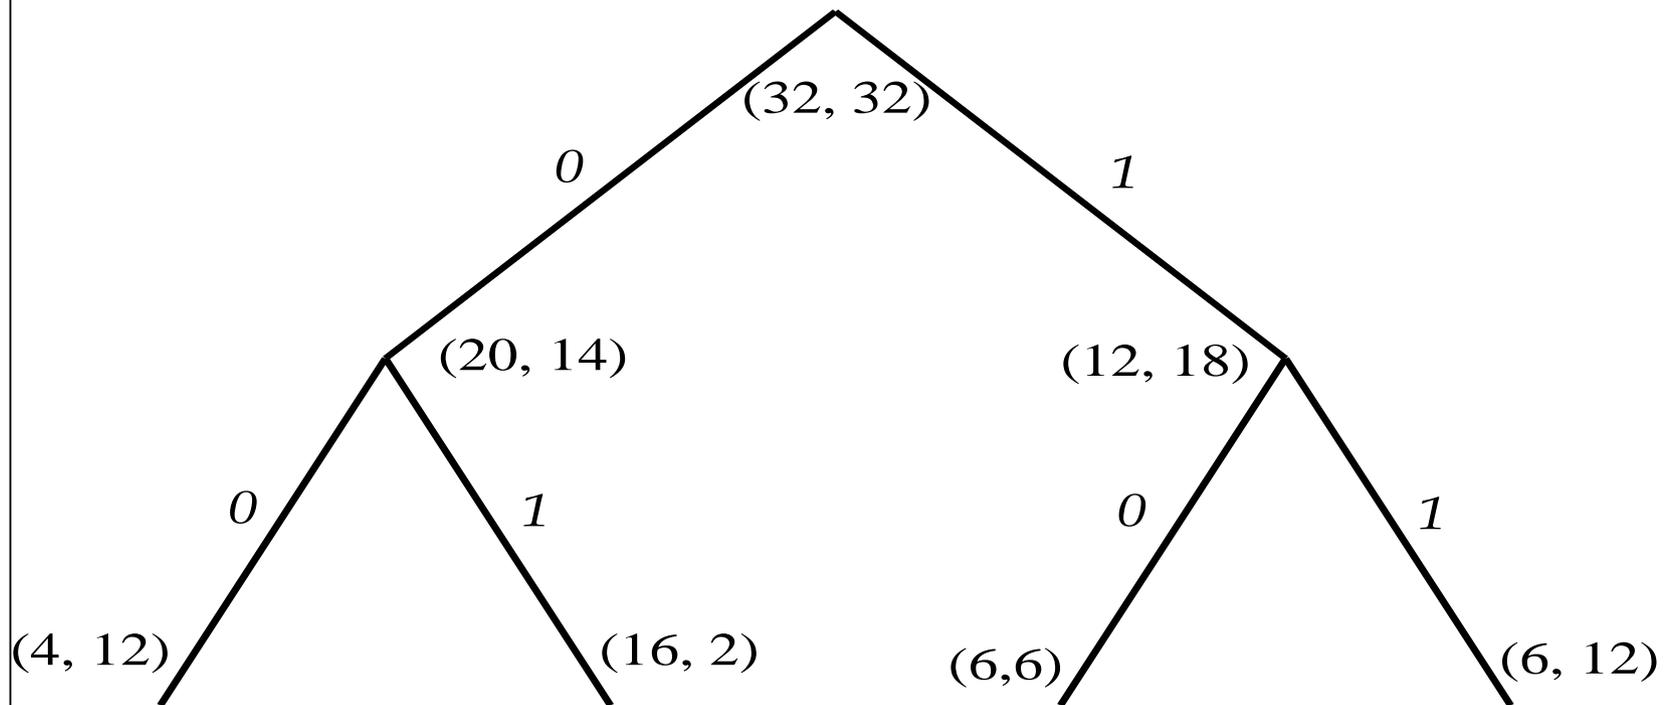


on ne casse
jamais la racine !

- Idée : partir du *bas* de l'arbre
- Pour chaque noeud s calculer :
 - son **cout propre** $CP(s) = H(\mathcal{T}(x, s))$
 - son **sous-coût** $SC(s) = \sum_{a \in E} MC(sa) + \frac{1}{2} \log n$
 - et son **meilleur cout** $MC(s) = \min CP(s), SC(s)$
- Trouver les **noeuds actifs** s tq $MC(s) = SC(s)$
- Choix final : partant de la racine, casser tous les noeuds actifs.

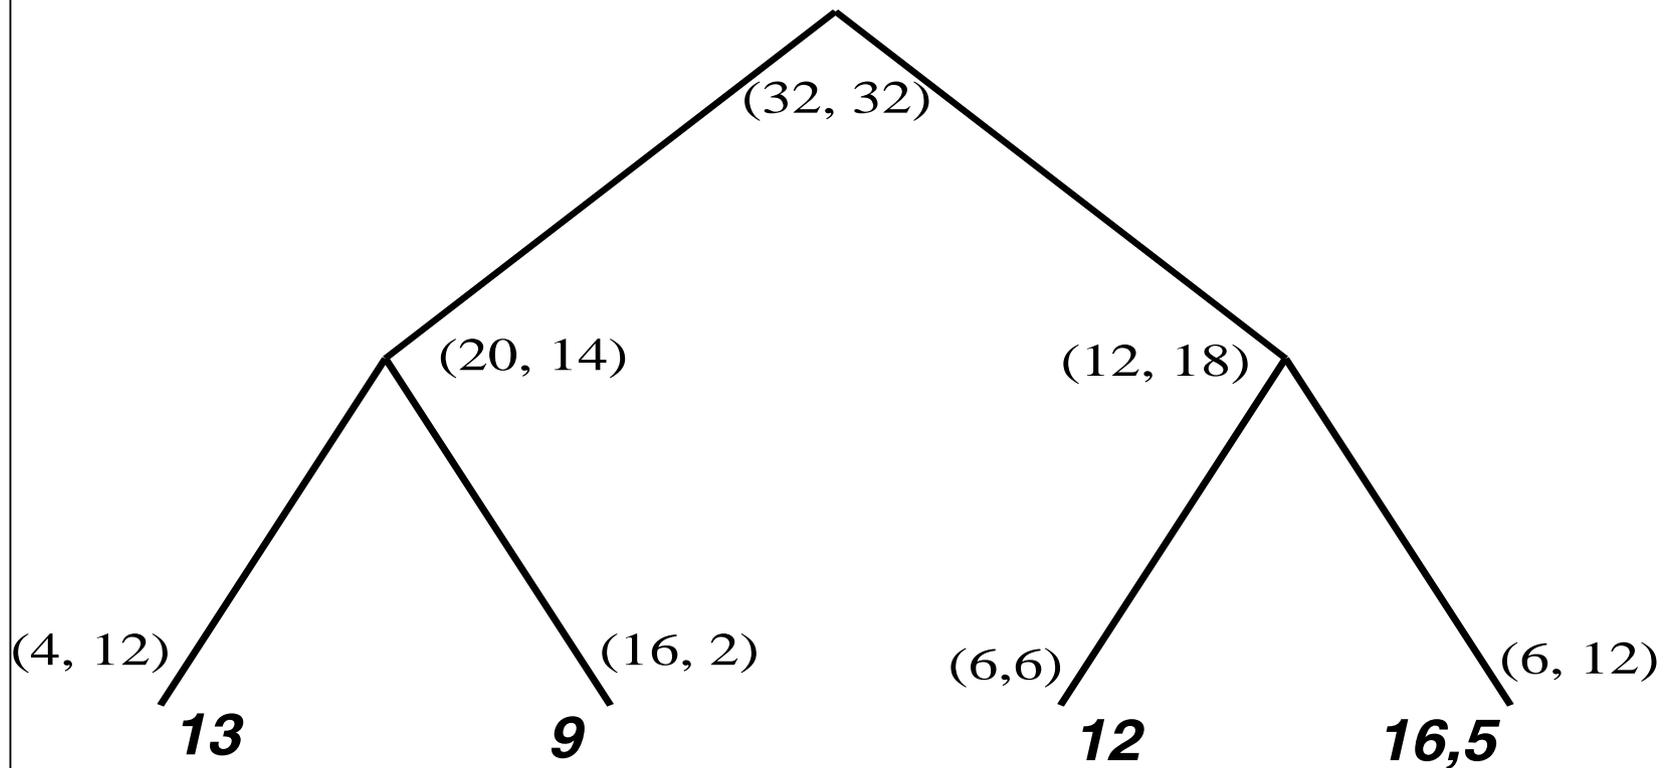
Exemple

$$n = 64 \implies pen = \frac{1}{2} \log 64 = 3$$



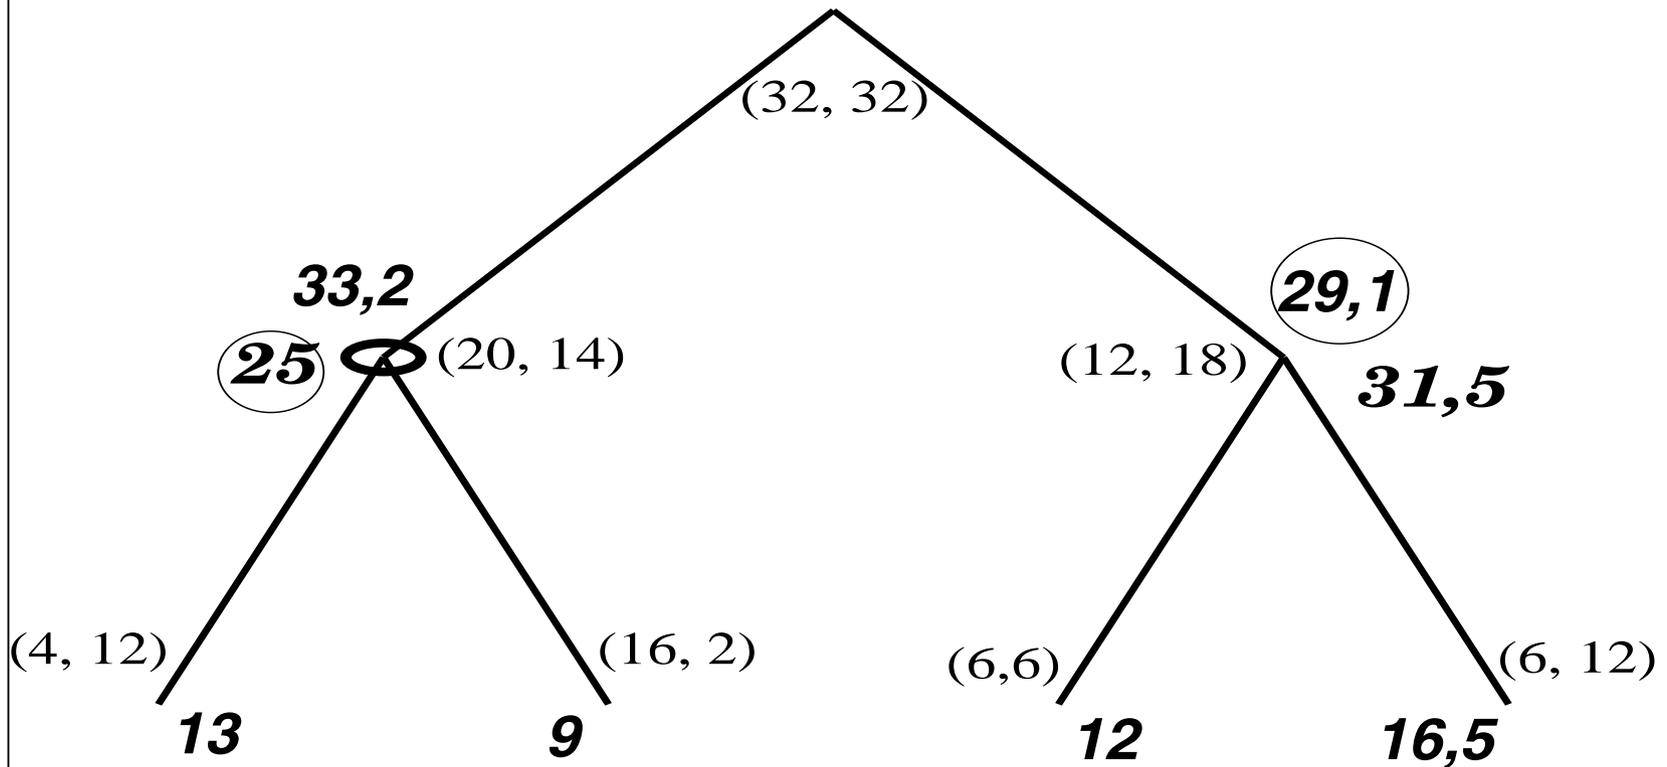
Exemple

$$n = 64 \implies pen = \frac{1}{2} \log 64 = 3$$



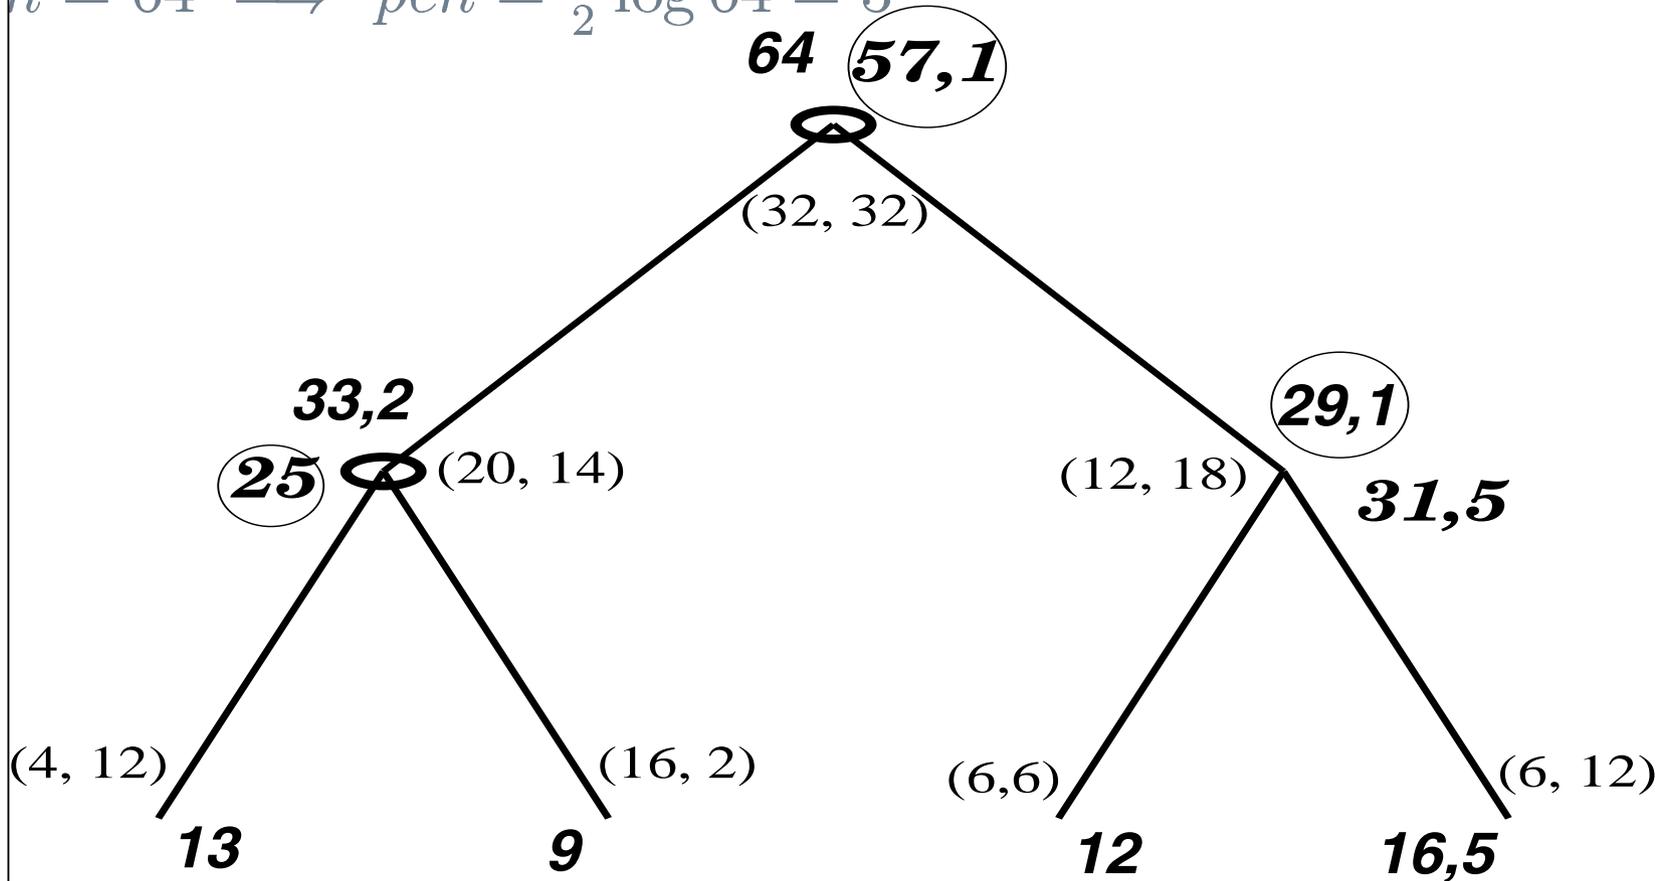
Exemple

$$n = 64 \implies pen = \frac{1}{2} \log 64 = 3$$



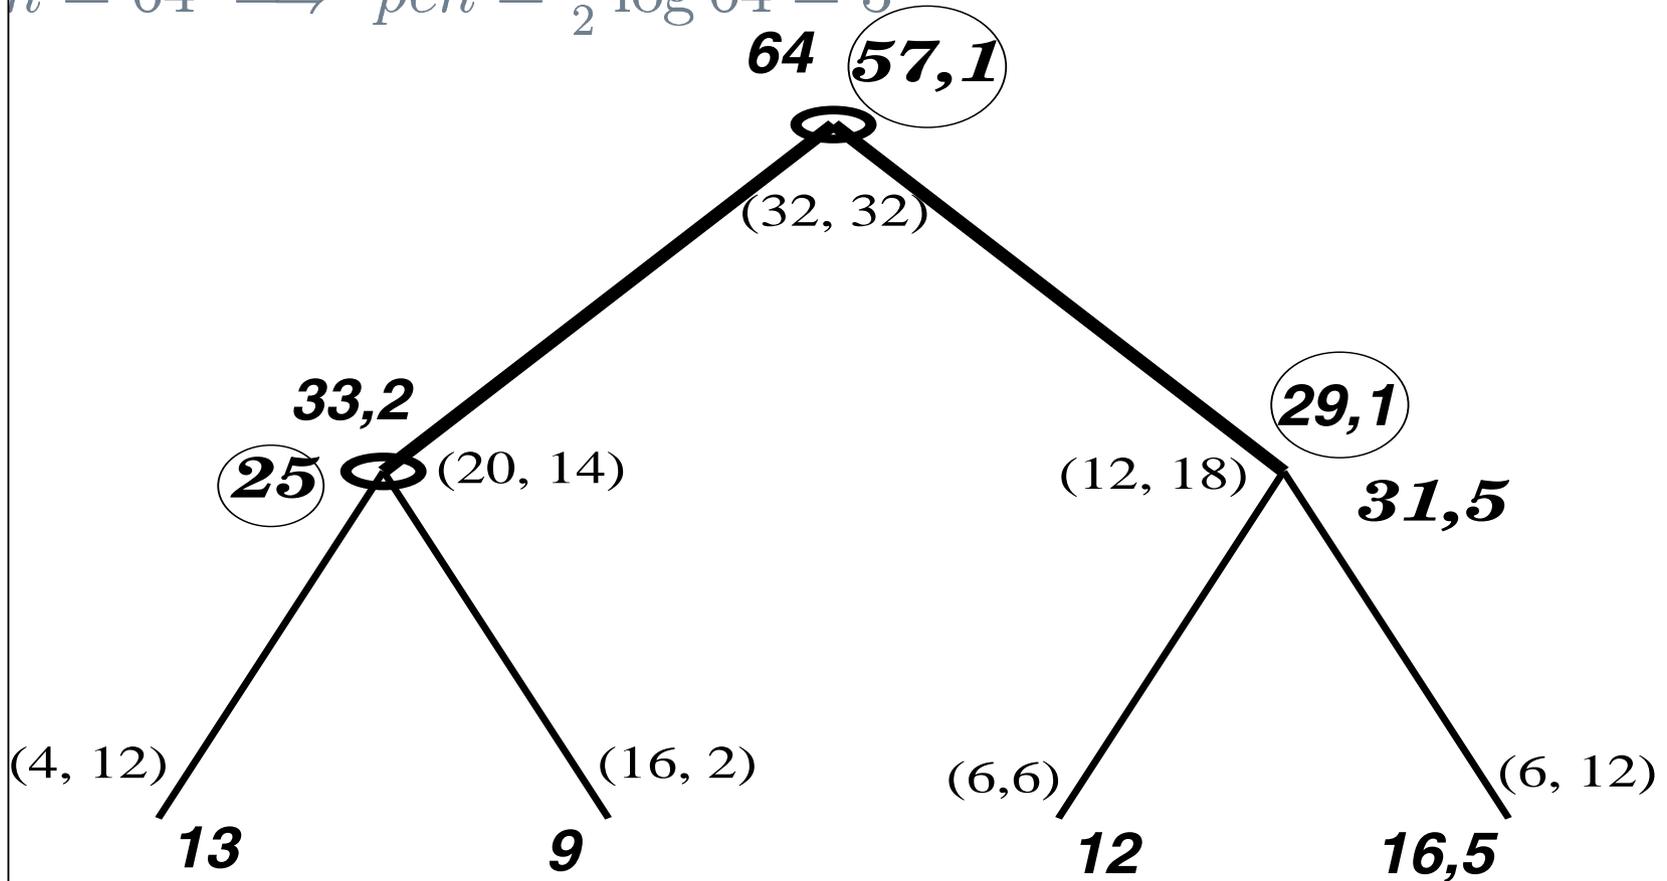
Exemple

$$n = 64 \implies pen = \frac{1}{2} \log 64 = 3$$



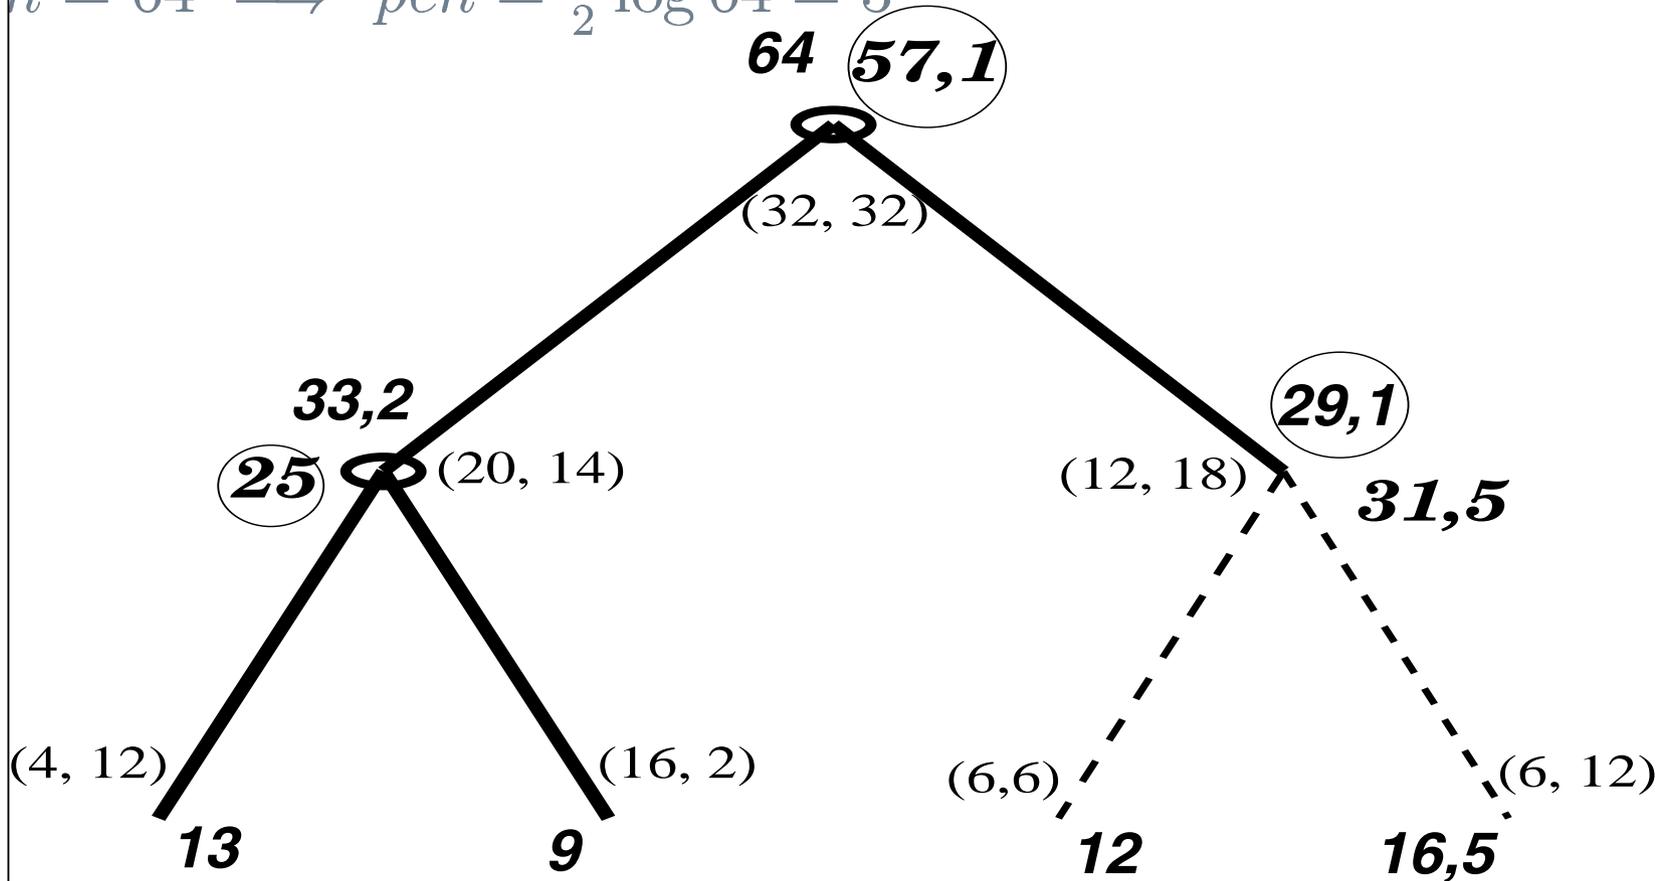
Exemple

$$n = 64 \implies pen = \frac{1}{2} \log 64 = 3$$



Exemple

$$n = 64 \implies pen = \frac{1}{2} \log 64 = 3$$



Théorèmes de consistance

- (Csiszár-Talata 2004, Garivier 2005)
L'estimateur BIC choisit le bon CT ps à partir d'un certain rang.
- **Si on se limite** à chercher des arbres de hauteur $o(\log n)$, l'estimateur de Krichevsky-Trofimov est également consistant ps à partir d'un certain rang.
- Si la source est un CT infini, toute troncature est correctement identifiée à partir d'un certain rang, ps.

Idées pour la preuve pour BIC

- **Sousestimation** : les plus petits modèles sont strictement moins puissants au premier ordre.
- **Surestimation** :
 - profondeur $< \log n$ typicalité

$$\forall \alpha > 0, \forall \delta > 0 : l(s) < \kappa \log n, N_n(s) \geq n^\alpha$$
$$\implies \left| \frac{N_n(sa)}{N_n(s)} - Q(a|s) \right| < \sqrt{\frac{\delta \log N_n(s)}{N_n(s)}}$$

- arbres avec plus de $\log n$ noeuds jamais choisis : argument de théorie de l'information.

Plan de l'exposé

- Notions de théorie de l'information
- Le modèle des sources à arbres de contexte
- Identification par MDL
- Prédiction et mélanges

Double mélange

- On présente le cas *binaire* pour simplifier
- Prior π sur les arbres: il y a $Catalan_s$ arbres à s feuilles d'où

$$\pi(\mathcal{T}) = 2^{-2|\mathcal{T}|+1}$$

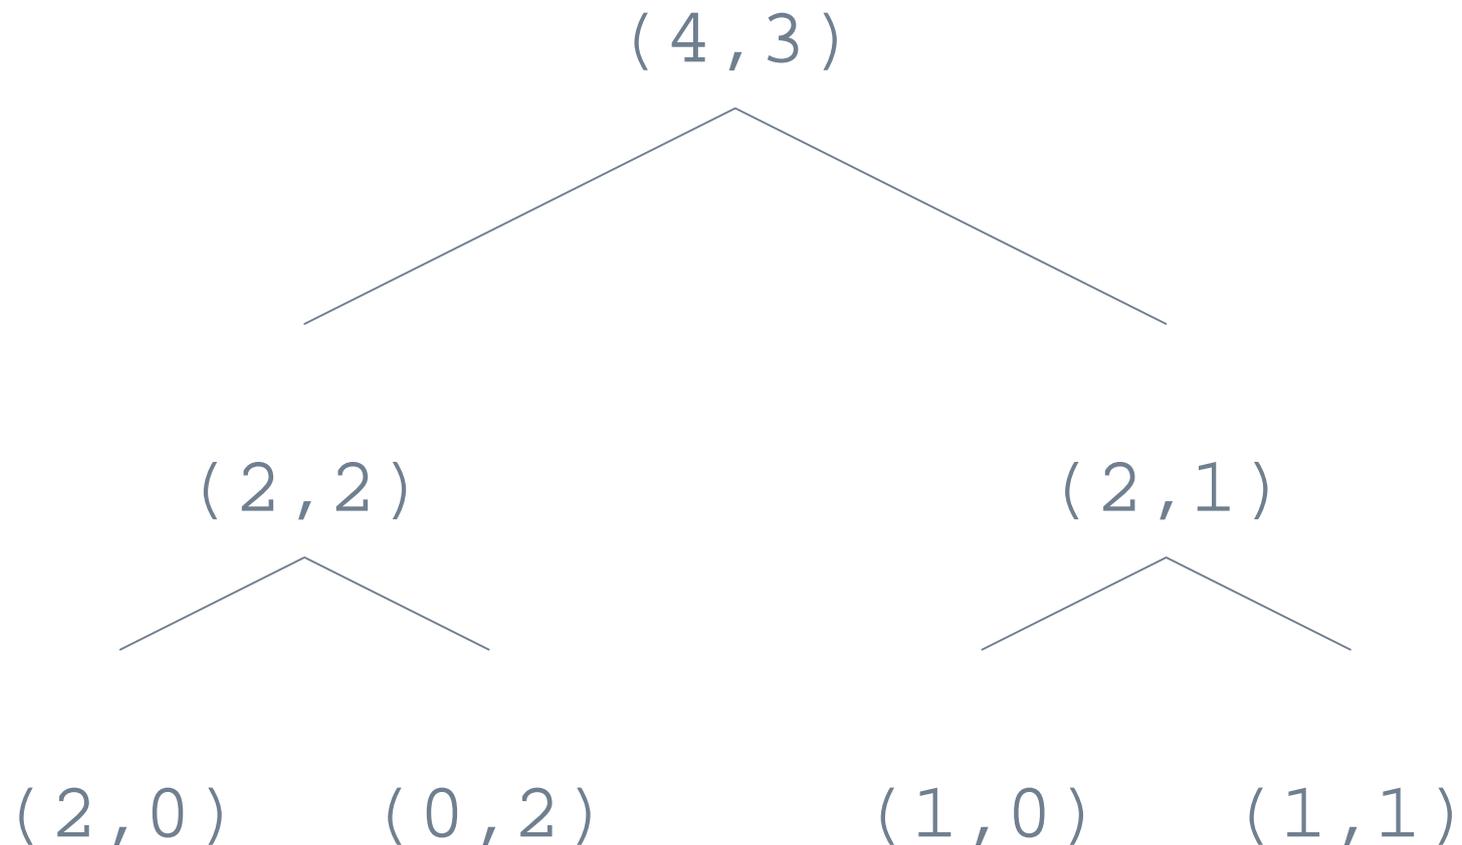
- On définit pour une collection \mathbb{T} d'arbres

$$CTW(x) = \sum_{\mathcal{T} \in \mathbb{T}} \mathcal{K}_{\mathcal{T}}(x) \pi(\mathcal{T})$$

- C'est une loi de probabilité sur chaque E^n

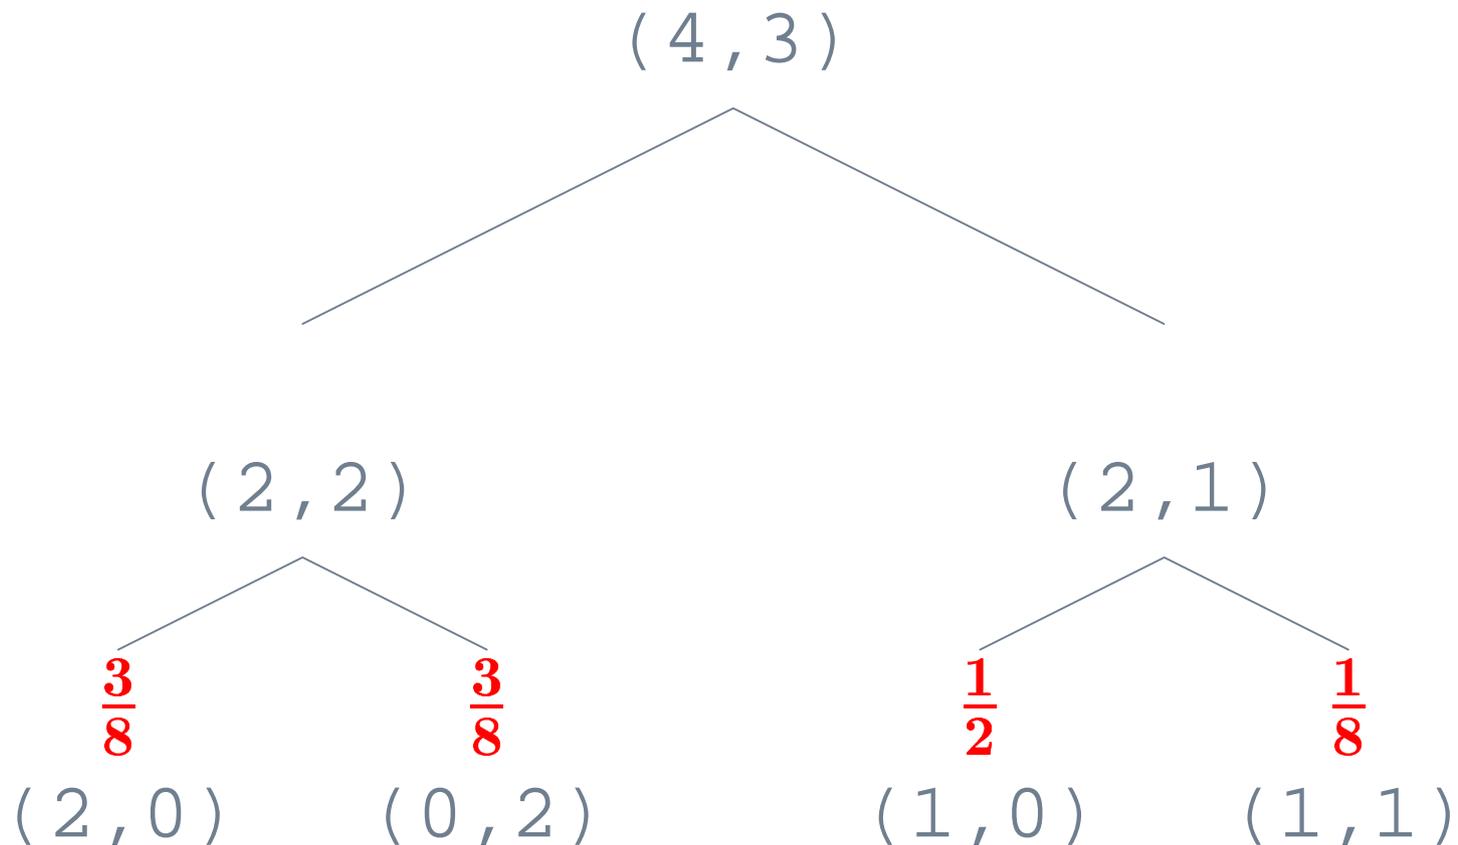
Calcul pratique de CTW

En chaque noeud, on fait la moyenne du coût propre et du sous-coût.



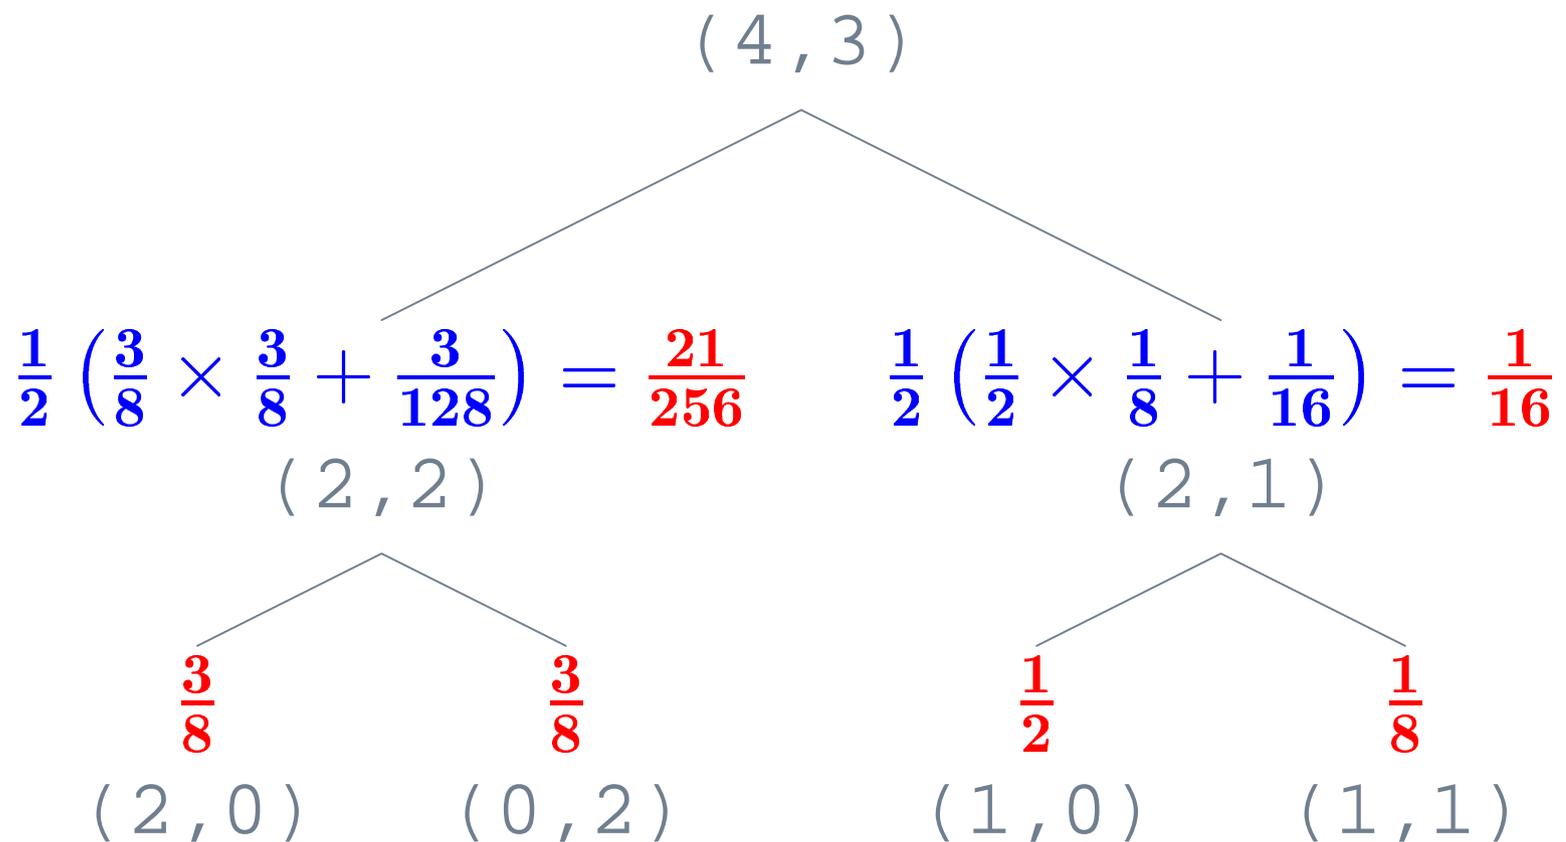
Calcul pratique de CTW

En chaque noeud, on fait la moyenne du coût propre et du sous-coût.



Calcul pratique de CTW

En chaque noeud, on fait la moyenne du coût propre et du sous-coût.



Calcul pratique de CTW

En chaque noeud, on fait la moyenne du coût propre et du sous-coût.

$$\frac{1}{2} \left(\frac{21}{256} \times \frac{1}{16} + \frac{5}{2058} \right) = \frac{31}{8192}$$

$(4, 3)$

$$\frac{1}{2} \left(\frac{3}{8} \times \frac{3}{8} + \frac{3}{128} \right) = \frac{21}{256}$$

$(2, 2)$

$$\frac{1}{2} \left(\frac{1}{2} \times \frac{1}{8} + \frac{1}{16} \right) = \frac{1}{16}$$

$(2, 1)$

$$\frac{3}{8}$$

$(2, 0)$

$$\frac{3}{8}$$

$(0, 2)$

$$\frac{1}{2}$$

$(1, 0)$

$$\frac{1}{8}$$

$(1, 1)$

Efficacité - optimalité

- **Théorème** : Pour tout $n \in \mathbb{N}$, pour tout $x \in E^n$:

$$-\log \mathcal{CTW}(x) \leq \inf_{\mathcal{T} \in \mathbb{T}} -\log \hat{P}_{\mathcal{T}}(x) + |\mathcal{T}| \log \left(\frac{n}{|\mathcal{T}|} \right) + 2|\mathcal{T}|$$

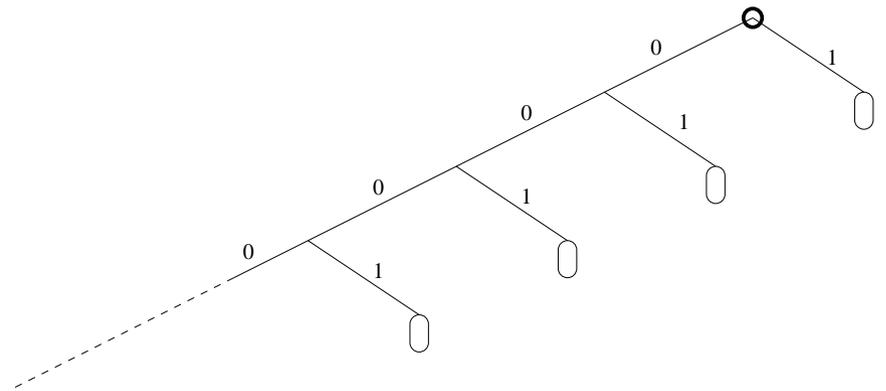
- Optimal au second ordre (minimax).
- Inégalité oracle non asymptotique.

Les processus de renouvellement

- Les cdm ont une redondance minimax en $O(\log n)$, la classe des processus stationnaire ergodique n'admet pas de redondance non triviale.
- Csiszár et Shields : classe des P.R. = la seule connue avec une complexité intermédiaire.
- **Définition** : sur $E = \{0, 1\}$, $(X_n)_{n \in \mathbb{Z}}$ est un P.R. si les distances entre les symboles '1' successifs de X sont i.i.d.
- **Théorème** : Csiszár et Shields - La redondance (moyenne et ponctuelle) minimax dans la classe des P.R. est de l'ordre de \sqrt{n} .

Redondance de CTW sur les P.R.

On peut visualiser les P.R. comme des sources à arbres de contexte infini



Théorème : (Garivier 2004) Il existe des constantes positives C_1 et C_2 telles que pour tous les arbres de contexte \mathcal{T} et tout $n \in \mathbb{N}$:

$$C_1 \sqrt{n} \log n \leq R_n(CTW, P.R.) \leq C_2 \sqrt{n} \log n$$

Implications

- CTW est donc presque *adaptatif* dans cette classe de processus de complexité intermédiaire, à très longue mémoire.
- Note : On utilise vraiment des arbres profonds et très déséquilibrés : c'est toute la *souplesse* des modèles à arbres de contexte.
- Ce résultat suggère que CTW est adapté pour le traitement des processus plus irréguliers que des cdm , à longue mémoire.

Micro-bibliographie

- **Universal modeling and coding** - Rissanen, Langdon, IEEE-IT 1981
- **Universal coding, Information, Prediction, and Estimation** - Rissanen, IEEE-IT 1984
- **The Context-Tree Weighting Method : basic Properties** - Willems, Shtarkov, Tjalkens IEEE-IT 1995
- **Redundancy Rates for Renewal and Other Processes** - Csiszár, Shields - IEEE-IT 1996
- **Variable length Markov chains** - Bühlmann, Wyner, Abraham, Annals of Statistics 1999
- **Context Tree Estimation for Not Necessarily Finite Memory Processes, via BIC and MDL.** - Csiszár, Talata (Budapest), IEEE-IT 2004