



Codage et entropie métrique : l'exemple des classes enveloppes.

Aurélien Garivier, CNRS et ENST

Réunion de rentrée de l'équipe MAFIA
Université Paul Sabatier - Toulouse.

Plan de l'exposé

- . Codage source sans perte
- . Entropie métrique
- . Le cas des classes enveloppe

Codage source



ATCAGAATC




0011011000110011010

compression sans perte

Winzip, compress, etc.

**But : minimiser la longueur
de code**



Codage source : Shannon



Source P

= processus stationnaire sur l'**alphabet A**

ici, $A = \{A, C, T, G\}$



code $\phi_n : A \rightarrow \{0, 1\}^*$

ATCAGAATC



0011011000110011010

message X_1^n ($n=9$)

compression sans perte

Winzip, compress, etc.

mot de code

$\phi_n(X_1^n)$

**But : minimiser la longueur
de code moyenne**

$$E_P[|\phi_n(X_1^n)|]$$



Entropie

- **Théorème (Shannon '48) :**

$$\mathbb{E}_{\mathbb{P}} [|\phi_n(x)|] \geq H_n(\mathbb{P}) \triangleq \mathbb{E}_{\mathbb{P}} [-\log \mathbb{P}^n(X_1^n)]$$

... et il existe un code qui atteint ce taux (à 1 bit près).

- En outre,

$$\frac{1}{n} H_n(\mathbb{P}) \rightarrow H(\mathbb{P})$$

taux entropique de la source \mathbb{P}
= nombre minimal de bit par symbole.

Loi de codage

- A chaque code $\phi_n(x)$ on peut associer une (sous-)probabilité q_n sur A^n telle que

$$q_n(\cdot) = 2^{-|\phi_n(\cdot)|}$$

- Inversement, grâce au **codage arithmétique**, on peut associer à toute (sous-)probabilité q_n sur A^n un code ϕ_n tel que $|\phi_n(\cdot)| = -\log q_n(\cdot)$ (+Cte).

Conclusion: code $\phi_n \iff$ loi de codage q_n

En particulier, $-\log q_n(x) =$ longueur de code.

- le théorème de Shannon '48 dit que **la meilleure loi de codage est la loi du processus !**
- La perte obtenue en utilisant une autre loi q_n est appelée **regret**
$$-\log q_n(X_1^n) - (-\log P^n(X_1^n)) = \log \frac{P^n(X_1^n)}{q_n(X_1^n)}.$$

Codage universel

- Que faire si la loi de la source est inconnue ??
- ... et si on veut un seul code pour plusieurs sources à la fois ?

⇒ on a besoin d'une seule loi de codage q_n pour toute une classe de sources

$$\Lambda = \{P_\theta, \theta \in \Theta\}$$

c'est donc un problème d'estimation de densité...

⇒ Redondance inévitable :

$$\begin{aligned}\mathbb{E}_{P_\theta} [|\phi(X_1^n)|] - H(X_1^n) &= \mathbb{E}_{P_\theta} [\log q_n(X_1^n) + \log P_\theta(X_1^n)] \\ &= KL(P_\theta, q_n)\end{aligned}$$

... avec perte logarithmique = information de Kullback-Leibler entre P_θ et q_n .

Exemples de codeurs universels

1. Codage deux-temps

- Code d'abord $\hat{\theta}(X_1^n) = \arg \min_{\theta \in \Theta} -\log P_{\theta}(X_1^n) \dots$
- ... puis X_1^n avec la loi de codage $\mathbb{P}_{\hat{\theta}}^n$.

Ex: (i.i.d.)


$$X_1^9 = AAATACAGT : \hat{\theta} = (5, 1, 2, 1)/9$$

$$\Rightarrow \text{regret } \frac{|A| - 1}{2} \log n.$$

2. Codage par mélange si ν est un prior sur Θ , on prend

$$q_n^{\nu}(x_1^n) = \int_{\Theta} P_{\theta}(x_1^n) d\nu(\theta)$$

Ex: (i.i.d.) $\rightarrow \nu = \text{Dirichlet}(\frac{1}{2}, \dots, \frac{1}{2})$



- Krichevsky-Trofimov **inégalité de mélange**

$$-\log q_n^{\nu}(x_1^n) \leq \inf_{\theta} -\log P_{\theta}^n(x_1^n) + \frac{|A| - 1}{2} \log n.$$

Mesures d'universalité

1. Redondance dans le pire des cas :

$$R^+(q_n, \Theta) = \sup_{\theta \in \Theta} \mathbb{E}_{P_\theta} \left[\log \frac{P_\theta^n (X_1^n)}{q_n (X_1^n)} \right] = \sup_{\theta \in \Theta} KL (P_\theta, q_n)$$

2. Redondance bayésienne avec le prior π :

$$R_\pi^-(q_n, \Theta) = \mathbb{E}_\pi \left[\mathbb{E}_{P_\theta} \left[\log \frac{P_\theta^n (X_1^n)}{q_n (X_1^n)} \right] \right] = \mathbb{E}_\pi [KL (P_\theta, q_n)]$$

$$\implies R^-(q_n, \Theta) \leq R^+(q_n, \Theta)$$

Mesures de complexité

1. Redondance minimax:

$$R_n^+(\Theta) = \inf_{q_n} R^+(q_n, \Theta) = \min_{q_n} \max_{\theta} KL(P_{\theta}^n, q_n)$$

2. Redondance bayésienne:

$$R_{\pi, n}^-(\Theta) = \min_{q_n} \mathbb{E}_{\pi} [KL(P_{\theta}^n, q_n)]$$

$$R_n^-(\Theta) = \max_{\pi} \min_{q_n} \mathbb{E}_{\pi} [KL(P_{\theta}^n, q_n)]$$

$$\implies R_n^-(\Theta) \leq R_n^+(\Theta).$$

Theorème maximin (Haussler '97, Sion)

$$R_n^-(\Theta) = R_n^+(\Theta).$$

Plan de l'exposé

- . Codage source sans perte
- . Entropie métrique
- . Le cas des classes enveloppe

Affinités et “distances”

- Pour $\alpha \neq 1$, la *D-divergence d'ordre α* entre P et Q est définie par

$$D_\alpha(P||Q) = \frac{1}{1-\alpha} \left(1 - \int (dP)^\alpha (dQ)^{(1-\alpha)} \right).$$

- Pour $\alpha = 1$, la *D-divergence d'ordre 1* est l'information de Küllback-Leibler :

$$D_1(P||Q) = KL(P||Q) = \int dP \log \frac{dP}{dQ}.$$

- D_α est positive et croissante en α .
- $D_{\frac{1}{2}} = D^2(P, Q)$ définit une vraie métrique : le carré de la distance de Hellinger.

La borne de Haussler-Opper

On se concentre maintenant sur le cas **i.i.d.**

Pour tout prior π sur Θ , pour tout $\alpha \in]0, 1[$ et pour tout $n \geq 1$:

$$\begin{aligned} & - \int_{\Theta} d\pi(\theta^*) \log \int_{\Theta} d\pi(\tilde{\theta}) e^{-n(1-\alpha)D_{\alpha}(P_{\theta^*} \| P_{\tilde{\theta}})} \\ & \leq R_{n,\pi}^- \leq - \int_{\Theta} d\pi(\theta^*) \log \int_{\Theta} d\pi(\tilde{\theta}) e^{-nD_1(P_{\theta^*} \| Q_{\tilde{\theta}})}. \end{aligned}$$

Entropie métrique

- $\mathcal{D}_\epsilon(\Theta, D_{\frac{1}{2}})$ = cardinal minimal d'une partition de Θ de D -diamètre ϵ .
- $\mathcal{M}_\epsilon(\Theta, D_{\frac{1}{2}})$ = cardinal maximal d'une partie de Θ ϵ -séparée.

- **Propriété :**

$$\mathcal{M}_\epsilon(\Theta, D) \leq \mathcal{D}_\epsilon(\Theta, D) \leq \mathcal{M}_{\frac{\epsilon}{2}}(\Theta, D).$$

- Si la limite existe quand $\epsilon \rightarrow 0$,

$$\frac{\log \mathcal{D}_\epsilon \left(\Theta, D_{\frac{1}{2}} \right)}{\log \frac{1}{\epsilon}} \rightarrow \dim(\Theta) = \text{dimension métrique de } \Theta.$$

Bornes sur la redondance

• Soit

$$b(\epsilon) = \sup \left\{ \frac{D_1(P_{\tilde{\theta}} || P_{\theta^*})}{D_{\frac{1}{2}}(P_{\tilde{\theta}} || P_{\theta^*})} : \tilde{\theta}, \theta^* \in \Theta \text{ et } D_{\frac{1}{2}}(P_{\tilde{\theta}} || P_{\theta^*}) \leq \epsilon \right\}.$$

• Alors

$$\begin{aligned} \sup_{\epsilon > 0} \min \left\{ \log \mathcal{D}_\epsilon(\Theta, D_{\frac{1}{2}}), n \frac{\epsilon^2}{8} \right\} - \log 2 &\leq R_{n,\pi}^- \\ &\leq \inf_{\epsilon > 0} \left\{ \log \mathcal{D}_\epsilon(\Theta, D_{\frac{1}{2}}) + b(\epsilon)n\epsilon^2 \right\}. \end{aligned}$$

Applications

- Si $\Theta < \infty$ alors

$$R_n^+ \rightarrow \log |\Theta| \text{ quand } n \rightarrow \infty.$$

- Si $\dim(\Theta, D_{\frac{1}{2}}) = 0$ alors

$$R_n^+ = o(\log n).$$

- Si $\dim(\Theta, D_{\frac{1}{2}}) = k < \infty$ alors

$$R_n^+ \sim \frac{k}{2} \log n.$$

- Si $\log \mathcal{D}_\epsilon(\Theta, D_{\frac{1}{2}}) \sim \left(\frac{1}{\epsilon}\right)^\alpha$ alors

$$R_n^+ \approx n^{\frac{\alpha}{\alpha+2}}.$$

Plan de l'exposé

- . Codage source sans perte
- . Entropie métrique
- . Le cas des classes enveloppe

Les classes enveloppes

- **Définition** Soit $f : \mathbb{N}_+ \mapsto [0, 1]$. La **classe enveloppe** Λ_f associée à la fonction f est la collection de sources sans mémoire dont chaque marginale est dominée par f :

$$\Lambda_f = \left\{ P : \forall x \in \mathbb{N}_+, P^1(x) \leq f(x), \text{ et } P \text{ sans mémoire} \right\}.$$

- **Théorème (Boucheron-G.-Gassiat '06)**

$$R_n^+(\Lambda_f) < \infty \iff \sum_{k \in \mathbb{N}_+} f(k) < \infty.$$

Enveloppe algébrique

Theorem (Boucheron-G.-Gassiat '06): Soit $\alpha > 1$, $\zeta(\alpha) = \sum_{k \geq 1} \frac{1}{k^\alpha}$, et C tel que $C\zeta(\alpha) \geq 2^\alpha$. Soit $\Lambda_{C \cdot -\alpha}$ la classe enveloppe associée à la fonction lentement décroissante :

$$f_{\alpha, C} : x \mapsto \frac{C}{x^\alpha}.$$

Alors

$$\begin{aligned} n^{1/\alpha} A(\alpha) \log [C\zeta(\alpha)] &\leq R_n^-(\Lambda_{C \cdot -\alpha}) \\ &\leq \left(\frac{2Cn}{\alpha - 1} \right)^{1/\alpha} (\log n)^{1-1/\alpha} + O(1). \end{aligned}$$

avec

$$A(\alpha) = \frac{1}{\alpha} \int_1^\infty \frac{1}{u^{1-1/\alpha}} \left(1 - e^{-1/(\zeta(\alpha)u)} \right) du.$$

Enveloppe exponentielle

Theorème (Boucheron-G.-Gassiat '06): Soit C et α une constante positive telle que $C > e^{2\alpha}$. Soit $\Lambda_{Ce^{-\alpha\cdot}}$ la classe enveloppe associée à la fonction plus rapidement décroissante

$$f_{\alpha,C} : x \mapsto Ce^{-\alpha x}.$$

Alors

$$R_n^+(\Lambda_{Ce^{-\alpha\cdot}}) \sim \frac{1}{4\alpha} \log^2 n.$$

Algorithme CensoringCode

Etant donnée une chaîne $x \in \mathbb{N}_+^n$ et une stratégie de censure $(K_i)_{1 \leq i \leq n}$, soit $\tilde{x} \in \{0, K_n\}^n$ défini par

$$\tilde{x}_i = \begin{cases} x_i & \text{if } x_i \leq K_i \\ 0 & \text{otherwise (le symbole est censuré)} \end{cases}$$

Soit également \check{x} la séquence des symboles censurés, c'est-à-dire $(x_i)_{x_i > K_i, i \leq n}$.

Algorithme (Boucheron-G.-Gassiat '06): Code séparément

- \tilde{x}_i avec un codeur efficace sur l'alphabet $\{0, K_n\}^n$,
- et \check{x} avec un code d'Elias pour les entiers

Ex: si $\forall i, K_i = 6$ alors

x	2	1	7	3	5	9	2	1	1	2	3	6	2	2	9	8	1	2	...
\tilde{x}	2	1	0	3	5	0	2	1	1	2	3	6	2	2	0	0	1	2	...
\check{x}			7			9									9	8			...

Performance - Adaptativité

Theorème (Boucheron-G.-Gassiat '06) Soit C et α des nombres positifs. On considère la stratégie de censure $(K_i)_{i \leq n}$ donnée par

$$K_i = \left\lfloor \left(\frac{2C i}{\alpha - 1} \right)^{1/\alpha} \right\rfloor.$$

La redondance moyenne de l'algorithme `CensoringCode` sur la classe $\Lambda_{C, -\alpha}$ vérifie :

$$R_n^+ (\text{CensoringCode}, \Lambda_{C, -\alpha}) \leq \left(\frac{2Cn}{\alpha - 1} \right)^{\frac{1}{\alpha}} \log n (1 + o(1)).$$

- presque optimal: à un facteur $\log n$ de la borne inf $n^{1/\alpha} A(\alpha) \log [C\zeta(\alpha)] \leq R_n^- (\Lambda_{C, -\alpha})$.
- nous proposons aussi une **estimation adaptative** de la censure avec $\hat{K}_n = \mu C_n$, où $C_n = \text{Card}\{X_1, \dots, X_n\}$ est le nombre de symboles différents dans le message.