

*Nicolas Sendrier*

Majeure d'informatique

# **Introduction la théorie de l'information**

Cours n°4

**Les séquences typiques et l'AEP**

# Processus stochastiques

Une source produit une suite de lettres dans l'alphabet  $\mathcal{X}$ .

Pour décrire cette suite de lettres nous utiliserons une suite de variables aléatoires  $X_1, X_2, \dots$  à valeurs dans  $\mathcal{X}$ . Ces variables ne sont pas nécessairement indépendantes. On parlera de *processus stochastique* pour décrire cette suite de variable aléatoires.

## Entropie par lettre

**Définition** Un processus stochastique est *stationnaire* si son comportement ne varie pas lorsque l'on décale l'observation dans le temps. Pour tous entiers positifs  $n$  et  $j$ , et tout  $(x_1, \dots, x_n) \in \mathcal{X}^n$

$$p_{X_1 \dots X_n}(x_1, \dots, x_n) = p_{X_{1+j} \dots X_{n+j}}(x_1, \dots, x_n)$$

**Théorème** Pour tout processus stochastique stationnaire, les limites ci-dessous existent et sont égales

$$H(\mathcal{X}) = \lim_{n \rightarrow \infty} \frac{1}{n} H(X_1, \dots, X_n) = \lim_{n \rightarrow \infty} H(X_n | X_1, \dots, X_{n-1}).$$

La quantité  $H(\mathcal{X})$  est appelée *entropie par lettre*.

## Processus markovien invariant dans le temps

**Définition** Un processus stochastique est dit *markovien* si pour tout entier positif  $n$  et tout  $(x_1, \dots, x_n) \in \mathcal{X}^n$

$$\Pr[X_n = x_n \mid X_1 = x_1, \dots, X_{n-1} = x_{n-1}] = \Pr[X_n = x_n \mid X_{n-1} = x_{n-1}]$$

Le processus est dit *invariant dans le temps* si ces probabilités ne dépendent pas de  $n$ .

Nous noterons  $p(x_2 \mid x_1) = \Pr[X_n = x_2 \mid X_{n-1} = x_1]$ .

**Théorème** L'entropie par lettre d'un processus markovien invariant dans le temps (irréductible) est égal à

$$H(\mathcal{X}) = H(X_2 \mid X_1) = \sum_{x_1, x_2} -\lambda(x_1) p(x_1 \mid x_2) \log_2 p(x_1 \mid x_2)$$

où  $\lambda(x), x \in \mathcal{X}$  est la *distribution stationnaire*.

## AEP Définitions

Soit une source (un processus stochastique) constituée de la suite de variables aléatoires  $X_1, X_2, \dots, X_n, \dots$  à valeur dans un alphabet  $\mathcal{X}$ . On suppose que l'entropie par lettre de cette source est définie

$$\mathcal{H} = H(\mathcal{X}) = \lim_{n \rightarrow \infty} \frac{1}{n} \log_2 H(X_1, \dots, X_n)$$

**Définition** Ensemble de séquences typiques (de longueur  $n$ )

$$A_\varepsilon^{(n)} = \left\{ (x_1, \dots, x_n) \in \mathcal{X}^n, \left| \frac{1}{n} \log_2 \frac{1}{p(x_1, \dots, x_n)} - \mathcal{H} \right| \leq \varepsilon \right\}$$

**Définition** (*Asymptotic Equipartition Property*)

Un processus stochastique (une source) vérifie l'AEP si :

$$\forall \varepsilon > 0, \lim_{n \rightarrow \infty} \Pr \left[ A_\varepsilon^{(n)} \right] = 1.$$

## Propriétés des séquences typiques

**Proposition** Pour toute source vérifiant l'AEP

- (i)  $\frac{1}{n} \log_2 \frac{1}{p(x_1, \dots, x_n)} \xrightarrow{n \rightarrow \infty} \mathcal{H}$  presque sûrement
- (ii)  $\Pr \left[ A_\varepsilon^{(n)} \right] 2^{n(\mathcal{H}-\varepsilon)} \leq |A_\varepsilon^{(n)}| \leq 2^{n(\mathcal{H}+\varepsilon)}$

Autrement dit :

Il y a  $2^{n\mathcal{H}}$  séquences typiques, ces séquences sont équiprobables de probabilité  $2^{-n\mathcal{H}}$ .

# Théorème de Shannon

**Définition** Soit  $\varphi$  un codage de  $\mathcal{X}$ , sa longueur moyenne par lettre est définie par

$$\mathcal{L}(\varphi) = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{x_1, \dots, x_n} p(x_1, \dots, x_n) |\varphi(x_1, \dots, x_n)|,$$

lorsque cette limite existe.

**Théorème (Shannon)** Soit une source discrète d'alphabet  $\mathcal{X}$  et d'entropie par lettre  $\mathcal{H}$  qui vérifie l'AEP.

1. Tout codage régulier  $\varphi$  de  $\mathcal{X}$  vérifie  $\mathcal{L}(\varphi) \geq \mathcal{H}$ .
2. Il existe un codage régulier  $\varphi$  de  $\mathcal{X}$  tel que  $\mathcal{L}(\varphi) \leq \mathcal{H} + \varepsilon, \forall \varepsilon > 0$ .

## AEP en pratique

**Proposition** Une source sans mémoire vérifie l'AEP.

**Proposition** Une source markovienne irréductible vérifie l'AEP.

**Proposition** Une source stationnaire ergodique vérifie l'AEP.