

INFORMATION, INÉGALITÉS ET RELATIONS D'INCERTITUDE

Steve Zozor



GIPSA-Lab – CNRS – Grenoble INP, Grenoble, France

17-21 Mai 2010

PLAN DU COURS

1 ENTROPIE – MESURE D'INCERTITUDE

- Axiomes, entropie de Shannon et ses propriétés
- Entropie différentielle – cas vectoriel
- D'autres mesures d'information

2 INFORMATION MUTUELLE - DIVERGENCES

- Entropie conditionnelle, Information mutuelle
- Quelques exemples
- Divergences

3 INÉGALITÉS – RELATIONS ENTROPIQUES

- Inégalités "classiques"
- Chaînes de Markov
- Inégalité de la puissance entropique
- Estimation – relations entre informations

4 RELATIONS D'INCERTITUDE

- Relation d'incertitude d'Heisenberg et versions entropiques

PLAN DU COURS

1 ENTROPIE – MESURE D'INCERTITUDE

- Axiomes, entropie de Shannon et ses propriétés
- Entropie différentielle – cas vectoriel
- D'autres mesures d'information

2 INFORMATION MUTUELLE - DIVERGENCES

- Entropie conditionnelle, Information mutuelle
- Quelques exemples
- Divergences

3 INÉGALITÉS – RELATIONS ENTROPIQUES

- Inégalités "classiques"
- Chaînes de Markov
- Inégalité de la puissance entropique
- Estimation – relations entre informations

4 RELATIONS D'INCERTITUDE

- Relation d'incertitude d'Heisenberg et versions entropiques

PLAN DU COURS

1 ENTROPIE – MESURE D'INCERTITUDE

- Axiomes, entropie de Shannon et ses propriétés
- Entropie différentielle – cas vectoriel
- D'autres mesures d'information

2 INFORMATION MUTUELLE - DIVERGENCES

- Entropie conditionnelle, Information mutuelle
- Quelques exemples
- Divergences

3 INÉGALITÉS – RELATIONS ENTROPIQUES

- Inégalités “classiques”
- Chaînes de Markov
- Inégalité de la puissance entropique
- Estimation – relations entre informations

4 RELATIONS D'INCERTITUDE

- Relation d'incertitude d'Heisenberg et versions entropiques

PLAN DU COURS

1 ENTROPIE – MESURE D'INCERTITUDE

- Axiomes, entropie de Shannon et ses propriétés
- Entropie différentielle – cas vectoriel
- D'autres mesures d'information

2 INFORMATION MUTUELLE - DIVERGENCES

- Entropie conditionnelle, Information mutuelle
- Quelques exemples
- Divergences

3 INÉGALITÉS – RELATIONS ENTROPIQUES

- Inégalités “classiques”
- Chaînes de Markov
- Inégalité de la puissance entropique
- Estimation – relations entre informations

4 RELATIONS D'INCERTITUDE

- Relation d'incertitude d'Heisenberg et versions entropiques

PLAN DU COURS

1 ENTROPIE – MESURE D'INCERTITUDE

- Axiomes, entropie de Shannon et ses propriétés
- Entropie différentielle – cas vectoriel
- D'autres mesures d'information

2 INFORMATION MUTUELLE - DIVERGENCES

- Entropie conditionnelle, Information mutuelle
- Quelques exemples
- Divergences

3 INÉGALITÉS – RELATIONS ENTROPIQUES

- Inégalités “classiques”
- Chaînes de Markov
- Inégalité de la puissance entropique
- Estimation – relations entre informations

1 RELATIONS D'INCERTITUDE

- Relation d'incertitude d'Heisenberg et versions entropiques

QUELQUES EXEMPLES

Quel est le point commun entre les problèmes suivants?

- On dispose d'un dé à 8 faces. On souhaite coder chaque face par une séquence binaire (suite de 0 et 1) suivant les contraintes:
 - à partir d'une séquence binaire correspondant à une séquence de lancers, on souhaite retrouver la séquence des faces (décodage),
 - on souhaite, "en moyenne", utiliser le moins de bits possible.
- Une pièce a une probabilité p de tomber sur pile. X est le nombre de lancers nécessaires pour tomber sur "face" et Vall vient de faire l'expérience. En lui posant le moins possible de questions binaires du type " $X \in \{1, 2, 3\}$ " on souhaite deviner X .
- On dispose d'un générateur aléatoire X binaire de ± 1 dont on peut régler $\alpha = \Pr[X = 1]$. On émet une séquence à travers un canal qui distord le symbole (l'inverse, le bruit, ...). Comment fixer α pour "commettre le moins d'erreurs possible"?
- N particule de gaz parfait occupent un volume Λ avec chacune sa vitesse : quelle la densité de probabilité des n vitesses des particules sachant que l'énergie totale $\sum_i \frac{1}{2}mv_i^2 = E$ est fixe?

QUELQUES EXEMPLES

Quel est le point commun entre les problèmes suivants?

- On dispose d'un dé à 8 faces. On souhaite coder chaque face par une séquence binaire (suite de 0 et 1) suivant les contraintes:
 - à partir d'une séquence binaire correspondant à une séquence de lancers, on souhaite retrouver la séquence des faces (décodage),
 - on souhaite, "en moyenne", utiliser le moins de bits possible.
- Une pièce a une probabilité p de tomber sur pile. X est le nombre de lancers nécessaires pour tomber sur "face" et Vali vient de faire l'expérience. En lui posant le moins possible de questions binaires du type " $X \in \{1, 2, 3\}$ " on souhaite deviner X .
- On dispose d'un générateur aléatoire X binaire de ± 1 dont on peut régler $\alpha = \Pr[X = 1]$. On émet une séquence à travers un canal qui distord le symbole (l'inverse, le bruit, ...). Comment fixer α pour "commettre le moins d'erreurs possible"?
- N particule de gaz parfait occupent un volume Λ avec chacune sa vitesse : quelle la densité de probabilité des n vitesses des particules sachant que l'énergie totale $\sum_i \frac{1}{2} m v_i^2 = E$ est fixe?

QUELQUES EXEMPLES

Quel est le point commun entre les problèmes suivants?

- On dispose d'un dé à 8 faces. On souhaite coder chaque face par une séquence binaire (suite de 0 et 1) suivant les contraintes:
 - à partir d'une séquence binaire correspondant à une séquence de lancers, on souhaite retrouver la séquence des faces (décodage),
 - on souhaite, "en moyenne", utiliser le moins de bits possible.
- Une pièce a une probabilité p de tomber sur pile. X est le nombre de lancers nécessaires pour tomber sur "face" et Vali vient de faire l'expérience. En lui posant le moins possible de questions binaires du type " $X \in \{1, 2, 3\}$ " on souhaite deviner X .
- On dispose d'un générateur aléatoire X binaire de ± 1 dont on peut régler $\alpha = \Pr[X = 1]$. On émet une séquence à travers un canal qui distord le symbole (l'inverse, le bruit...). Comment fixer α pour "commettre le moins d'erreurs possible"?
- N particule de gaz parfait occupent un volume V avec chacune sa vitesse : quelle la densité de probabilité des n vitesses des particules sachant que l'énergie totale $\sum_{i=1}^n \frac{1}{2} m v_i^2 = E$ est fixe?

QUELQUES EXEMPLES


Quel est le point commun entre les problèmes suivants?

- On dispose d'un dé à 8 faces. On souhaite coder chaque face par une séquence binaire (suite de 0 et 1) suivant les contraintes:
 - à partir d'une séquence binaire correspondant à une séquence de lancers, on souhaite retrouver la séquence des faces (décodage),
 - on souhaite, “en moyenne”, utiliser le moins de bits possible.
- Une pièce a une probabilité p de tomber sur pile. X est le nombre de lancers nécessaires pour tomber sur “face” et Vali vient de faire l'expérience. En lui posant le moins possible de questions binaires du type “ $X \in \{1, 2, 3\}$ ” on souhaite deviner X .
- On dispose d'un générateur aléatoire X binaire de ± 1 dont on peut régler $\alpha = \Pr[X = 1]$. On émet une séquence à travers un canal qui distord le symbole (l'inverse, le bruit...). Comment fixer α pour “commettre le moins d'erreurs possible”?
- N particule de gaz parfait occupent un volume Λ avec chacune sa vitesse : quelle la densité de probabilité des n vitesses des particules sachant que l'énergie totale $\sum_i \frac{1}{2}mv_i^2 = E$ est fixe?

ENTROPIE DE SHANNON, 1948 – AXIOMES


Variable aléatoire discrète X sur $\{x_1, \dots, x_n\}$, de loi $\{p_k = \Pr[X = x_k]\}_{k=1, \dots, n}$

But : construire une mesure d'incertitude/d'information $H(X) = H(p_1, \dots, p_n)$




pas d'incertitude

obs. n'apporte pas d'information



incertitude maximum


- Invariante par permutation, continue selon les p_k
- $p_k = \frac{1}{n}$ alors $H(n)$ croissante (incertitude croissante)
- Récursivité $H = H(p_1 + p_2, p_3, \dots) + (p_1 + p_2)H\left(\frac{p_1}{p_1+p_2}, \frac{p_2}{p_1+p_2}\right)$



ENTROPIE DE SHANNON, 1948 – AXIOMES ÉQUIV.


Variable aléatoire discrète X sur $\{x_1, \dots, x_n\}$, de loi $\{p_k = \Pr[X = x_k]\}_{k=1, \dots, n}$

But : construire une mesure d'incertitude/d'information $H(X) = H(p_1, \dots, p_n)$



pas d'incertitude

obs. n'apporte pas d'information




incertitude maximum

- Incertitude élémentaire – information de Hartley $h(p_k)$,
 $H(X) = \sum p_k h(p_k)$ continue selon les p_k et symétrique
- X, Y indépendantes, alors $H(X, Y) = H(X) + H(Y)$

ENTROPIE DE SHANNON, 1948 – DÉFINITION


Variable aléatoire discrète X sur $\{x_1, \dots, x_n\}$, de loi $\{p_k = \Pr[X = x_k]\}_{k=1, \dots, n}$

But : construire une mesure d'incertitude/d'information $H(X) = H(p_1, \dots, p_n)$



pas d'incertitude

obs. n'apporte pas d'information



incertitude maximum

Intuitivement, $h(p_k q_k) = h(p_k) + h(q_k)$ impose $h(p) = \alpha \log(p)$


Seule possibilité : $H(X) = -kT \sum_k p_k \log(p_k)$ ($0 \log 0 = 0$)

S'étend au cas $k \in \mathbb{Z}$, $kT \stackrel{\text{def}}{=} \frac{1}{\log b}$.

QUELQUES PROPRIÉTÉS

- $H \geq 0$
- $p_k = \delta_{k,l} \Leftrightarrow H = 0$ minimum (pas d'incertitude)
- $p_k = \frac{1}{n} \Leftrightarrow H = \log n \Leftrightarrow$ (incertitude maximum dans le cas fini)

e.g. $\{p, 1 - p\}$



- Concavité : $P \sim \{p_k\}$, $Q \sim \{q_k\}$ et $R \sim \{\lambda p_k + (1 - \lambda)q_k\}$, $\lambda \in [0; 1]$


$$H(R) \geq \lambda H(P) + (1 - \lambda)H(Q)$$

- $H(aX) = H(X + c) = H(X)$: indépendant des valeurs prises par X

QUELQUES PROPRIÉTÉS


- $H \geq 0$
- $p_k = \delta_{k,l} \Leftrightarrow H = 0$ minimum (pas d'incertitude)
- $p_k = \frac{1}{n} \Leftrightarrow H = \log n \Leftrightarrow$ (incertitude maximum dans le cas fini)

e.g. $\{p, 1-p\}$



- Concavité : $P \sim \{p_k\}$, $Q \sim \{q_k\}$ et $R \sim \{\lambda p_k + (1-\lambda)q_k\}$, $\lambda \in [0; 1]$

$$H(R) \geq \lambda H(P) + (1-\lambda)H(Q)$$




- $H(aX) = H(X+c) = H(X)$: indépendant des valeurs prises par X

QUELQUES PROPRIÉTÉS


- $H \geq 0$
- $p_k = \delta_{k,l} \Leftrightarrow H = 0$ minimum (pas d'incertitude)
- $p_k = \frac{1}{n} \Leftrightarrow H = \log n \Leftrightarrow$ (incertitude maximum dans le cas fini)

e.g. $\{p, 1 - p\}$



- Concavité : $P \sim \{p_k\}$, $Q \sim \{q_k\}$ et $R \sim \{\lambda p_k + (1 - \lambda)q_k\}$, $\lambda \in [0 ; 1]$

$$H(R) \geq \lambda H(P) + (1 - \lambda)H(Q)$$



- $H(aX) = H(X + c) = H(X)$: indépendant des valeurs prises par X

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur 3 bits : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = 3$ bits
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = 3$ bits
- Supposons cette fois le dé pipé, $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$:

- Code optimum de taille moyenne L^* : $H(X) \leq L^* < H(X) + 1$

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur **3 bits** : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = \mathbf{3 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = 3 \text{ bits}$
 - Supposons cette fois le dé pipé, $(\frac{1}{2}, \frac{1}{2}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$:

- Code optimum de taille moyenne L^* : $H(X) \leq L^* < H(X) + 1$

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur **3 bits** : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = \mathbf{3 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = \mathbf{3 \text{ bits}}$
- Supposons cette fois le dé pipé, $(\frac{1}{2}, \frac{1}{2}, \frac{1}{8}, \frac{1}{8}, \frac{1}{16}, \frac{1}{16}, \frac{1}{16}, \frac{1}{16})$:

- Code optimum de taille moyenne L^* : $H(X) \leq L^* < H(X) + 1$

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur **3 bits** : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = \mathbf{3 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = \mathbf{3 \text{ bits}}$
- Supposons cette fois le dé pipé, $\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}\right)$:
 - Comme avant : codage sur **3 bits**, & **3 bits en moyenne**
 - "0" forte proba. d'apparition \rightarrow codage sur peu de bits
 - "7" faible proba. d'apparition \rightarrow codage sur plus de bits
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = \mathbf{2 \text{ bits}}$
 - Code optimum de taille moyenne $L^* : H(X) \leq L^* < H(X) + 1$

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur **3 bits** : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = \mathbf{3 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = \mathbf{3 \text{ bits}}$
- Supposons cette fois le dé pipé, $\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}\right)$:
 - Comme avant : codage sur **3 bits, & 3 bits en moyenne**
 - “0” forte proba. d'apparition \rightsquigarrow codage sur peu de bits
 - “7” faible proba. d'apparition \rightsquigarrow codage sur plus de bits

- séquences décodable...
- on a besoin de...6 bits !
- mais en moyenne $\frac{1}{2} \times 1 + \frac{1}{4} \times 2 + \frac{1}{8} \times 3 + \frac{1}{16} \times 4 + \frac{1}{64} \times 6 = 2 \text{ bits}$

- Entropie $H(X) = -\sum p_k \log_2(p_k) = 2 \text{ bits}$

- Code optimum de taille moyenne $L^* \leq H(X) < L^* + 1$

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur **3 bits** : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = \mathbf{3 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = \mathbf{3 \text{ bits}}$
- Supposons cette fois le dé pipé, $\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}\right)$:
 - Comme avant : codage sur **3 bits, & 3 bits en moyenne**
 - “0” forte proba. d'apparition \rightsquigarrow codage sur peu de bits
 - “7” faible proba. d'apparition \rightsquigarrow codage sur plus de bits
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - séquences décodable...
 - on a besoin de... **6 bits** !
 - mais en moyenne $\frac{1}{2} \times 1 + \frac{1}{4} \times 2 + \frac{1}{8} \times 3 + \frac{1}{16} \times 4 + \frac{1}{64} \times 6 = 2 \text{ bits}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = 2 \text{ bits}$
- Code optimum de taille moyenne $L^* \leq H(X) < L^* + 1$

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur **3 bits** : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = \mathbf{3 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = \mathbf{3 \text{ bits}}$
- Supposons cette fois le dé pipé, $\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}\right)$:
 - Comme avant : codage sur **3 bits, & 3 bits en moyenne**
 - “0” forte proba. d'apparition \rightsquigarrow codage sur peu de bits
 - “7” faible proba. d'apparition \rightsquigarrow codage sur plus de bits
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - séquences décodable...
 - on a besoin de... **6 bits !**
 - mais en moyenne $\frac{1}{2} \times 1 + \frac{1}{4} \times 2 + \frac{1}{8} \times 3 + \frac{1}{16} \times 4 + \frac{4}{64} \times 6 = \mathbf{2 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = \mathbf{2 \text{ bits}}$
- Code optimum de taille moyenne $L^* \approx H(X) \leq L^* < H(X) + 1$

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur **3 bits** : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = \mathbf{3 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = \mathbf{3 \text{ bits}}$
- Supposons cette fois le dé pipé, $\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}\right)$:
 - Comme avant : codage sur **3 bits**, & **3 bits en moyenne**
 - “0” forte proba. d'apparition \rightsquigarrow codage sur peu de bits
 - “7” faible proba. d'apparition \rightsquigarrow codage sur plus de bits
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - séquences décodable...
 - on a besoin de... **6 bits** !
 - mais en moyenne $\frac{1}{2} \times 1 + \frac{1}{4} \times 2 + \frac{1}{8} \times 3 + \frac{1}{16} \times 4 + \frac{4}{64} \times 6 = \mathbf{2 \text{ bits}}$
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = \mathbf{2 \text{ bits}}$

• Code optimum de taille moyenne $L^* \approx H(X) \leq L^* < H(X) + 1$

UN PROBLÈME DE CODAGE

- Soit un dé à 8 faces équiprobables, codage binaire de chaque face :
 - Codage sur **3 bits** : (000, 001, 010, 011, 100, 101, 110, 111)
 - En moyenne on a besoin de $\sum \frac{1}{8} \times 3 = 3$ **bits**
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = -\sum \frac{1}{8} \log_2\left(\frac{1}{8}\right) = 3$ **bits**
- Supposons cette fois le dé pipé, $\left(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}\right)$:
 - Comme avant : codage sur **3 bits**, & **3 bits en moyenne**
 - “0” forte proba. d'apparition \rightsquigarrow codage sur peu de bits
 - “7” faible proba. d'apparition \rightsquigarrow codage sur plus de bits
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - séquences décodable...
 - on a besoin de... **6 bits** !
 - mais en moyenne $\frac{1}{2} \times 1 + \frac{1}{4} \times 2 + \frac{1}{8} \times 3 + \frac{1}{16} \times 4 + \frac{4}{64} \times 6 = 2$ **bits**
 - Entropie $H(X) = -\sum p_k \log_2(p_k) = 2$ **bits**
- Code optimum de taille moyenne L^* : $H(X) \leq L^* < H(X) + 1$

APPLICATION À UN PROBLÈME DE PILE OU FACE

Une pièce a une probabilité p de tomber sur le côté “pile”.

Soit X le nombre de lancers successifs nécessaires pour tomber sur “face”.

- Déterminer $p_k = \Pr[X = k]$ puis l'entropie $H(X) = f(p)$ de X .

- Quelle séquence “naive” de questions permettrait de deviner x ?
- Quel est le nombre moyen N de questions à poser pour trouver x ?
- Comparer N et $H(X)$ dans les cas $p = \frac{1}{2}$ et $p = \frac{\sqrt{2}}{2}$.
- Peut-on trouver une séquence de questions plus courte (en moyenne) ?
- Si oui, quel est le nombre moyen N^* de questions? Conclure.

APPLICATION À UN PROBLÈME DE PILE OU FACE

Une pièce a une probabilité p de tomber sur le côté “pile”.

Soit X le nombre de lancers successifs nécessaires pour tomber sur “face”.

- Déterminer $p_k = \Pr[X = k]$ puis l'entropie $H(X) = f(p)$ de X .

Vali vient de faire x lancers pour tomber enfin sur “face”. On veut deviner x en lui posant une suite de questions binaires “ $x \in \{x_1, \dots, x_k\}$?”

- Quelle séquence “naive” de questions permettrait de deviner x ?
- Quel est le nombre moyen N de questions à poser pour trouver x ?
- Comparer N et $H(X)$ dans les cas $p = \frac{1}{2}$ et $p = \frac{\sqrt{2}}{2}$.

• Peut-on trouver une séquence de questions plus courte (en moyenne) ?

• Si oui, quel est le nombre moyen N^* de questions? Conclure.

APPLICATION À UN PROBLÈME DE PILE OU FACE

Une pièce a une probabilité p de tomber sur le côté “pile”.

Soit X le nombre de lancers successifs nécessaires pour tomber sur “face”.

- Déterminer $p_k = \Pr[X = k]$ puis l'entropie $H(X) = f(p)$ de X .

Vali vient de faire x lancers pour tomber enfin sur “face”. On veut deviner x en lui posant une suite de questions binaires “ $x \in \{x_1, \dots, x_k\}$?”

- Quelle séquence “naive” de questions permettrait de deviner x ?
- Quel est le nombre moyen N de questions à poser pour trouver x ?
- Comparer N et $H(X)$ dans les cas $p = \frac{1}{2}$ et $p = \frac{\sqrt{2}}{2}$.
- Peut-on trouver une séquence de questions plus courte (en moyenne)?
- Si oui, quel est le nombre moyen N^* de questions? Conclure.

EXTENSION AU CAS CONTINU

Pour X variable aléatoire continue, par analogie :

$$H(X) = - \int p(x) \log p(x) dx \quad (\text{entropie différentielle})$$

Pas d'approche axiomatique (à ma connaissance)

EXTENSION AU CAS CONTINU

Pour X variable aléatoire continue, par analogie :


$$H(X) = - \int p(x) \log p(x) dx \quad (\text{entropie différentielle})$$

Pas d'approche axiomatique (à ma connaissance)

Lien avec l'entropie discrète :

$$\text{Soit } x_k \text{ tel que } p_k = p(x_k) \Delta = \int_{k\Delta}^{(k+1)\Delta} p(x) dx$$

$$X^\Delta = x_k \text{ sur } [k\Delta ; (k+1)\Delta), \quad X^\Delta \sim \{p_k\}$$



EXTENSION AU CAS CONTINU

Pour X variable aléatoire continue, par analogie :


$$H(X) = - \int p(x) \log p(x) dx \quad (\text{entropie différentielle})$$

Pas d'approche axiomatique (à ma connaissance)

Lien avec l'entropie discrète :

$$\text{Soit } x_k \text{ tel que } p_k = p(x_k) \Delta = \int_{k\Delta}^{(k+1)\Delta} p(x) dx$$

$$X^\Delta = x_k \text{ sur } [k\Delta ; (k+1)\Delta), \quad X^\Delta \sim \{p_k\}$$



$$\begin{aligned} H(X^\Delta) &= - \sum p_k \log p_k = - \sum p(x_k) \Delta \log(p(x_k) \Delta) \\ &= - \log \Delta - \sum p(x_k) \log p(x_k) \Delta \end{aligned}$$

EXTENSION AU CAS CONTINU

Pour X variable aléatoire continue, par analogie :


$$H(X) = - \int p(x) \log p(x) dx \quad (\text{entropie différentielle})$$

Pas d'approche axiomatique (à ma connaissance)

Lien avec l'entropie discrète :

$$\text{Soit } x_k \text{ tel que } p_k = p(x_k) \Delta = \int_{k\Delta}^{(k+1)\Delta} p(x) dx$$

$$X^\Delta = x_k \text{ sur } [k\Delta ; (k+1)\Delta), \quad X^\Delta \sim \{p_k\}$$



$$\begin{aligned} H(X^\Delta) &= - \sum p_k \log p_k = - \sum p(x_k) \Delta \log(p(x_k) \Delta) \\ &= - \log \Delta - \sum p(x_k) \log p(x_k) \Delta \end{aligned}$$

$$\lim_{\Delta \rightarrow 0} H(X^\Delta) + \log \Delta = H(X)$$

QUELQUES PROPRIÉTÉS DU CAS CONTINU

- X définie sur $[a ; b]$ borné, maximum $H = \log(b - a) \Leftrightarrow X$ uniforme
 H peut être négative et $\rightarrow -\infty$ pour $b \rightarrow a$ (pas d'incertitude)
- Concavité : $H(\lambda p + (1 - \lambda)q) \geq \lambda H(p) + (1 - \lambda)H(q)$
- Support \mathbb{R} , variance/puissance fixée σ^2 ,
maximum $H(X) = \frac{1}{2} \log(2\pi e) + \log \sigma \Leftrightarrow p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x^2}{2\sigma^2}\right)$
en Gaussien, σ^2 contient toute l'information/incertitude sur X
- $H(X + c) = H(X)$, mais $H(aX) = H(X) + \log(|a|)$:
dépend des "valeurs" prises par X
- Puissance entropique $N(X) = \frac{1}{2\pi e} \exp(2H(X))$

QUELQUES PROPRIÉTÉS DU CAS CONTINU

- X définie sur $[a ; b]$ borné, maximum $H = \log(b - a) \Leftrightarrow X$ uniforme
 H peut être négative et $\rightarrow -\infty$ pour $b \rightarrow a$ (pas d'incertitude)
- Concavité : $H(\lambda p + (1 - \lambda)q) \geq \lambda H(p) + (1 - \lambda)H(q)$
- Support \mathbb{R} , variance/puissance fixée σ^2 ,
maximum $H(X) = \frac{1}{2} \log(2\pi e) + \log \sigma \Leftrightarrow p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x^2}{2\sigma^2}\right)$
en Gaussien, σ^2 contient toute l'information/incertitude sur X
- $H(X + c) = H(X)$, mais $H(aX) = H(X) + \log(|a|)$:
dépend des "valeurs" prises par X
- Puissance entropique $N(X) = \frac{1}{2\pi e} \exp(2H(X))$

QUELQUES PROPRIÉTÉS DU CAS CONTINU

- X définie sur $[a ; b]$ borné, maximum $H = \log(b - a) \Leftrightarrow X$ uniforme
 H peut être négative et $\rightarrow -\infty$ pour $b \rightarrow a$ (pas d'incertitude)

- Concavité : $H(\lambda p + (1 - \lambda)q) \geq \lambda H(p) + (1 - \lambda)H(q)$

- Support \mathbb{R} , variance/puissance fixée σ^2 ,

$$\text{maximum } H(X) = \frac{1}{2} \log(2\pi e) + \log \sigma \Leftrightarrow p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x^2}{2\sigma^2}\right)$$

en Gaussien, σ^2 contient toute l'information/incertitude sur X

- $H(X + c) = H(X)$, mais $H(aX) = H(X) + \log(|a|)$:
dépend des "valeurs" prises par X

- Puissance entropique $N(X) = \frac{1}{2\pi e} \exp(2H(X))$

QUELQUES PROPRIÉTÉS DU CAS CONTINU

- X définie sur $[a ; b]$ borné, maximum $H = \log(b - a) \Leftrightarrow X$ uniforme
 H peut être négative et $\rightarrow -\infty$ pour $b \rightarrow a$ (pas d'incertitude)
- Concavité : $H(\lambda p + (1 - \lambda)q) \geq \lambda H(p) + (1 - \lambda)H(q)$
- Support \mathbb{R} , variance/puissance fixée σ^2 ,
maximum $H(X) = \frac{1}{2} \log(2\pi e) + \log \sigma \Leftrightarrow p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x^2}{2\sigma^2}\right)$
en Gaussien, σ^2 contient toute l'information/incertitude sur X
- $H(X + c) = H(X)$, mais $H(aX) = H(X) + \log(|a|)$:
dépend des “valeurs” prises par X
- Puissance entropique $N(X) = \frac{1}{2\pi e} \exp(2H(X))$

QUELQUES PROPRIÉTÉS DU CAS CONTINU

- X définie sur $[a ; b]$ borné, maximum $H = \log(b - a) \Leftrightarrow X$ uniforme
 H peut être négative et $\rightarrow -\infty$ pour $b \rightarrow a$ (pas d'incertitude)
- Concavité : $H(\lambda p + (1 - \lambda)q) \geq \lambda H(p) + (1 - \lambda)H(q)$
- Support \mathbb{R} , variance/puissance fixée σ^2 ,
maximum $H(X) = \frac{1}{2} \log(2\pi e) + \log \sigma \Leftrightarrow p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x^2}{2\sigma^2}\right)$
en Gaussien, σ^2 contient toute l'information/incertitude sur X
- $H(X + c) = H(X)$, mais $H(aX) = H(X) + \log(|a|)$:
dépend des “valeurs” prises par X
- Puissance entropique $N(X) = \frac{1}{2\pi e} \exp(2H(X))$
 - $N(X) \geq 0$
 - Uniforme $N(X) = \frac{(b-a)^2}{2\pi e} \rightarrow 0$ si $b - a \rightarrow 0$
 - Gaussien $N(X) = \sigma^2 \rightarrow 0$ si $\sigma^2 \rightarrow 0$

ENTROPIE D'UN VECTEUR ALÉATOIRE

Vecteur aléatoire $\mathbf{X} \sim p(\mathbf{x})$ sur un domaine \mathcal{D} de \mathbb{R}^d ou \mathbb{Z}^d , entropie de \mathbf{X}

$$H(\mathbf{X}) = - \int_{\mathcal{D}} p(\mathbf{x}) \log p(\mathbf{x}) d\mathbf{x} \quad \text{ou} \quad - \sum_{\mathcal{D}} p_{k_1, \dots, k_d} \log p_{k_1, \dots, k_d}$$

aussi appelée entropie conjointe des X_i et notée $H(X_1, \dots, X_d)$

- \mathbf{X} défini sur un support \mathcal{D} de \mathbb{R}^d de volume fini $\text{vol } \mathcal{D}$
 $H_{\max}(\mathbf{X}) = \log \text{vol } \mathcal{D} \Leftrightarrow \mathbf{X}$ uniforme sur \mathcal{D}
- support \mathbb{R}^d , matrice de covariance \mathbf{R} donnée
 $H_{\max}(\mathbf{X}) = \frac{d}{2} \log(2\pi e) + \frac{1}{2} \log |\mathbf{R}| \Leftrightarrow \mathbf{X} \sim \mathcal{N}(\cdot, \mathbf{R})$
- Puissance fixée $P = \text{Trace}(\mathbf{R})$, l'entropie décroît avec la corrélation
- Puissance entropique $N(\mathbf{X}) = \frac{1}{2\pi e} \exp\left(\frac{2}{d} H(\mathbf{X})\right)$

ENTROPIE D'UN VECTEUR ALÉATOIRE

Vecteur aléatoire $\mathbf{X} \sim p(\mathbf{x})$ sur un domaine \mathcal{D} de \mathbb{R}^d ou \mathbb{Z}^d , entropie de \mathbf{X}

$$H(\mathbf{X}) = - \int_{\mathcal{D}} p(\mathbf{x}) \log p(\mathbf{x}) d\mathbf{x} \quad \text{ou} \quad - \sum_{\mathcal{D}} p_{k_1, \dots, k_d} \log p_{k_1, \dots, k_d}$$

aussi appelée entropie conjointe des X_i et notée $H(X_1, \dots, X_d)$

- \mathbf{X} défini sur un support \mathcal{D} de \mathbb{R}^d de volume fini $\text{vol } \mathcal{D}$

$$H_{\max}(\mathbf{X}) = \log \text{vol } \mathcal{D} \Leftrightarrow \mathbf{X} \text{ uniforme sur } \mathcal{D}$$

- support \mathbb{R}^d , matrice de covariance \mathbf{R} donnée

$$H_{\max}(\mathbf{X}) = \frac{d}{2} \log(2\pi e) + \frac{1}{2} \log |\mathbf{R}| \Leftrightarrow \mathbf{X} \sim \mathcal{N}(\cdot, \mathbf{R})$$

- Puissance fixée $P = \text{Trace}(\mathbf{R})$, l'entropie décroît avec la corrélation
- Puissance entropique $N(\mathbf{X}) = \frac{1}{2\pi e} \exp\left(\frac{2}{d} H(\mathbf{X})\right)$

ENTROPIE D'UN VECTEUR ALÉATOIRE

Vecteur aléatoire $\mathbf{X} \sim p(\mathbf{x})$ sur un domaine \mathcal{D} de \mathbb{R}^d ou \mathbb{Z}^d , entropie de \mathbf{X}

$$H(\mathbf{X}) = - \int_{\mathcal{D}} p(\mathbf{x}) \log p(\mathbf{x}) d\mathbf{x} \quad \text{ou} \quad - \sum_{\mathcal{D}} p_{k_1, \dots, k_d} \log p_{k_1, \dots, k_d}$$

aussi appelée entropie conjointe des X_i et notée $H(X_1, \dots, X_d)$

- \mathbf{X} défini sur un support \mathcal{D} de \mathbb{R}^d de volume fini $\text{vol } \mathcal{D}$

$$H_{\max}(\mathbf{X}) = \log \text{vol } \mathcal{D} \Leftrightarrow \mathbf{X} \text{ uniforme sur } \mathcal{D}$$

- support \mathbb{R}^d , matrice de covariance \mathbf{R} donnée

$$H_{\max}(\mathbf{X}) = \frac{d}{2} \log(2\pi e) + \frac{1}{2} \log |\mathbf{R}| \Leftrightarrow \mathbf{X} \sim \mathcal{N}(\cdot, \mathbf{R})$$

- Puissance fixée $P = \text{Trace}(\mathbf{R})$, l'entropie décroît avec la corrélation

- Puissance entropique $N(\mathbf{X}) = \frac{1}{2\pi e} \exp\left(\frac{2}{d} H(\mathbf{X})\right)$

ENTROPIE D'UN VECTEUR ALÉATOIRE

Vecteur aléatoire $\mathbf{X} \sim p(\mathbf{x})$ sur un domaine \mathcal{D} de \mathbb{R}^d ou \mathbb{Z}^d , entropie de \mathbf{X}

$$H(\mathbf{X}) = - \int_{\mathcal{D}} p(\mathbf{x}) \log p(\mathbf{x}) d\mathbf{x} \quad \text{ou} \quad - \sum_{\mathcal{D}} p_{k_1, \dots, k_d} \log p_{k_1, \dots, k_d}$$

aussi appelée entropie conjointe des X_i et notée $H(X_1, \dots, X_d)$

- \mathbf{X} défini sur un support \mathcal{D} de \mathbb{R}^d de volume fini $\text{vol } \mathcal{D}$

$$H_{\max}(\mathbf{X}) = \log \text{vol } \mathcal{D} \Leftrightarrow \mathbf{X} \text{ uniforme sur } \mathcal{D}$$

- support \mathbb{R}^d , matrice de covariance \mathbf{R} donnée

$$H_{\max}(\mathbf{X}) = \frac{d}{2} \log(2\pi e) + \frac{1}{2} \log |\mathbf{R}| \Leftrightarrow \mathbf{X} \sim \mathcal{N}(\cdot, \mathbf{R})$$

- Puissance fixée $P = \text{Trace}(\mathbf{R})$, l'entropie décroît avec la corrélation
- Puissance entropique $N(\mathbf{X}) = \frac{1}{2\pi e} \exp\left(\frac{2}{d} H(\mathbf{X})\right)$

Taux d'entropie : $\mathcal{H}(\mathbf{X}) = \frac{1}{d} H(\mathbf{X})$; iid $\mathcal{H}(\mathcal{X}) = H(X_1)$

D'AUTRES MESURE D'INCERTITUDE

- (Co)variance : l'incertitude est nulle si $\sigma^2 = 0$ et augmente avec σ^2

- Matrice/information de Fisher : $\int \frac{(\nabla p)(\nabla p)^t}{p}$ et sa trace

- Entropie de Rényi : $H_\lambda = \frac{1}{1-\lambda} \log \int p^\lambda$ (phys. stat., détec.)

- Entropie de Havrda et Charvat'67 : $T_q = \frac{1}{q-1} (\int p^q - 1)$ (phys.)

- Entropies d'ordre (r, s) (Varma'66) : $H_{s,r} = \frac{1}{s-r} \log \int \frac{p^r}{p^s}$

- Entropies de degré (r, s) (Kapur'67) : $T_{s,r} = \frac{1}{s-r} \int (p^r - p^s)$

- f -entropies (Arimoto'71) : $H_f = \inf_{\tilde{p}} \int p f(\tilde{p})$

f convexe, continuellement dérivable ; $A_t = \frac{1}{t-1} \left(\left(\int p^{\frac{1}{t}} \right)^t - 1 \right)$

D'AUTRES MESURE D'INCERTITUDE

- (Co)variance : l'incertitude est nulle si $\sigma^2 = 0$ et augmente avec σ^2
- Matrice/information de Fisher : $\int \frac{(\nabla p)(\nabla p)^t}{p}$ et sa trace
- Entropie de Rényi : $H_\lambda = \frac{1}{1-\lambda} \log \int p^\lambda$ (phys. stat., détec.)
- Entropie de Havrda et Charvat'67 : $T_q = \frac{1}{q-1} (\int p^q - 1)$ (phys.)
- Entropies d'ordre (r, s) (Varma'66) : $H_{s,r} = \frac{1}{s-r} \log \int \frac{p^r}{p^s}$
- Entropies de degré (r, s) (Kapur'67) : $T_{s,r} = \frac{1}{s-r} \int (p^r - p^s)$
- f -entropies (Arimoto'71) : $H_f = \inf_{\tilde{p}} \int p f(\tilde{p})$
 f convexe, continuellement dérivable ; $A_t = \frac{1}{t-1} \left(\left(\int p^{\frac{1}{t}} \right)^t - 1 \right)$

D'AUTRES MESURE D'INCERTITUDE

- (Co)variance : l'incertitude est nulle si $\sigma^2 = 0$ et augmente avec σ^2
- Matrice/information de Fisher : $\int \frac{(\nabla p)(\nabla p)^t}{p}$ et sa trace
- Entropie de Rényi : $H_\lambda = \frac{1}{1-\lambda} \log \int p^\lambda$ (phys. stat., détec.)
- Entropie de Havrda et Charvat'67 : $T_q = \frac{1}{q-1} (\int p^q - 1)$ (phys.)
- Entropies d'ordre (r, s) (Varma'66) : $H_{s,r} = \frac{1}{s-r} \log \frac{\int p^r}{\int p^s}$
- Entropies de degré (r, s) (Kapur'67) : $T_{s,r} = \frac{1}{s-r} \int (p^r - p^s)$
- f -entropies (Arimoto'71) : $H_f = \inf_{\tilde{p}} \int p f(\tilde{p})$
 f convexe, continuellement dérivable ; $A_t = \frac{1}{t-1} \left(\left(\int p^{\frac{1}{t}} \right)^t - 1 \right)$

ENTROPIE DE RÉNYI, 1961

Généralisation de Shannon :

- Continuité ; information élémentaire $h(p_k)$
- Indépendance $H_r(X, Y) = H_r(X) + H_r(Y)$
 $h(p_k q_l) = h(p_k) + h(q_l)$ implique $h(p) = -\log(p)$

• Moyenne quasi-linéaire (exponentielle) :

$$H_r(X) = \varphi^{-1} \left(\sum p_k \varphi(h(p_k)) \right) \text{ avec } \varphi \text{ continue croissante (KN)}$$

• $\varphi(x) = ax + b$, conduisant à Shannon

• $\varphi(x) = a e^{(1-\lambda)x} + b$ avec $\lambda \geq 0, \neq 1$ conduisant à Rényi :

$$H_\lambda(X) = \frac{1}{1-\lambda} \log \sum_k p_k^\lambda \quad \frac{1}{1-\lambda} \log \int p^\lambda(x) dx$$

ENTROPIE DE RÉNYI, 1961

Généralisation de Shannon :

- Continuité ; information élémentaire $h(p_k)$
- Indépendance $H_r(X, Y) = H_r(X) + H_r(Y)$
 $h(p_k q_l) = h(p_k) + h(q_l)$ implique $h(p) = -\log(p)$
- Moyenne quasi-linéaire (exponentielle) :

$$H_r(X) = \varphi^{-1} \left(\sum p_k \varphi(h(p_k)) \right) \text{ avec } \varphi \text{ continue croissante (KN)}$$

• $\varphi(x) = ax + b$, conduisant à Shannon

• $\varphi(x) = a e^{(\lambda-1)x} + b$ avec $\lambda \geq 0, \neq 1$ conduisant à Rényi :

$$H_\lambda(X) = \frac{1}{1-\lambda} \log \sum_k p_k^\lambda \quad \frac{1}{1-\lambda} \log \int p^\lambda(x) dx$$

ENTROPIE DE RÉNYI, 1961

Généralisation de Shannon :

- Continuité ; information élémentaire $h(p_k)$
- Indépendance $H_r(X, Y) = H_r(X) + H_r(Y)$
 $h(p_k q_l) = h(p_k) + h(q_l)$ implique $h(p) = -\log(p)$
- Moyenne quasi-linéaire (exponentielle) :

$$H_r(X) = \varphi^{-1} \left(\sum p_k \varphi(h(p_k)) \right) \text{ avec } \varphi \text{ continue croissante (KN)}$$

Seules solutions admissibles :

- $\varphi(x) = ax + b$, conduisant à Shannon

• $\varphi(x) = a e^{(\lambda-1)x} + b$ avec $\lambda \geq 0, \neq 1$ conduisant à Rényi :

$$H_\lambda(X) = \frac{1}{1-\lambda} \log \sum_k p_k^\lambda \quad \frac{1}{1-\lambda} \log \int p^\lambda(x) dx$$

ENTROPIE DE RÉNYI, 1961

Généralisation de Shannon :

- Continuité ; information élémentaire $h(p_k)$
- Indépendance $H_r(X, Y) = H_r(X) + H_r(Y)$
 $h(p_k q_l) = h(p_k) + h(q_l)$ implique $h(p) = -\log(p)$
- Moyenne quasi-linéaire (exponentielle) :

$$H_r(X) = \varphi^{-1} \left(\sum p_k \varphi(h(p_k)) \right) \text{ avec } \varphi \text{ continue croissante (KN)}$$

Seules solutions admissibles :

- $\varphi(x) = ax + b$, conduisant à Shannon
- $\varphi(x) = a e^{(1-\lambda)x} + b$ avec $\lambda \geq 0, \neq 1$ conduisant à Rényi :

$$H_\lambda(\mathbf{X}) = \frac{1}{1-\lambda} \log \sum_{\mathbf{k}} p_{\mathbf{k}}^\lambda \quad \frac{1}{1-\lambda} \log \int p^\lambda(\mathbf{x}) d\mathbf{x}$$

ENTROPIE DE RÉNYI, 1961

Généralisation de Shannon :

- Continuité ; information élémentaire $h(p_k)$
- Indépendance $H_r(X, Y) = H_r(X) + H_r(Y)$
 $h(p_k q_l) = h(p_k) + h(q_l)$ implique $h(p) = -\log(p)$
- Moyenne quasi-linéaire (exponentielle) :

$$H_r(X) = \varphi^{-1} \left(\sum p_k \varphi(h(p_k)) \right) \text{ avec } \varphi \text{ continue croissante (KN)}$$

Seules solutions admissibles :

- $\varphi(x) = ax + b$, conduisant à Shannon
- $\varphi(x) = a e^{(1-\lambda)x} + b$ avec $\lambda \geq 0, \neq 1$ conduisant à Rényi :

$$H_\lambda(\mathbf{X}) = \frac{1}{1-\lambda} \log \sum_{\mathbf{k}} p_{\mathbf{k}}^\lambda \quad \frac{1}{1-\lambda} \log \int p^\lambda(\mathbf{x}) d\mathbf{x}$$

$\lambda \rightarrow 1$ donne $H_\lambda \rightarrow H$ λ joue un rôle de “loupe”

QUELQUES PROPRIÉTÉS DES ENTROPIES DE RÉNYI

- Concavité pour $\lambda \leq 1$
 - H_λ décroît avec λ de $H_0 = \log \text{vol } \mathcal{D}$ à $H_\infty = -\log \sup p$
 - $p_k = \delta_{k,l} \Leftrightarrow H_\lambda = 0$ minimum
 - $X \in \prod_i \{1, \dots, n_i\}$ et $p_k = \prod_i \frac{1}{n_i} \Leftrightarrow H_\lambda = \log(\prod_i n_i)$ maximum
 - Discret $H_\lambda \geq 0$ – continu $N_\lambda \propto \exp\left(\frac{2H_\lambda}{\lambda}\right)$
 - Continu, support fini, maximum en uniforme $H_\lambda = \log(\text{vol } \mathcal{D})$
 - Contrainte de (co)variance, maximisantes :

$$\lambda > 1 : f(x) \propto (1 - x^t R^{-1} x)^{\frac{\lambda-1}{\lambda}} \quad \text{Student-r} \quad \xrightarrow{\lambda \rightarrow 1} \mathcal{N}$$

$$1 - \frac{2}{\lambda} < \lambda < 1 : f(x) \propto (1 + x^t R^{-1} x)^{\frac{\lambda-1}{\lambda}} \quad \text{Student-t} \quad \xrightarrow{\lambda \rightarrow 1} \mathcal{N}$$

QUELQUES PROPRIÉTÉS DES ENTROPIES DE RÉNYI

- Concavité pour $\lambda \leq 1$
- H_λ décroît avec λ de $H_0 = \log \text{vol } \mathcal{D}$ à $H_\infty = -\log \sup p$
- $p_k = \delta_{k,l} \Leftrightarrow H_\lambda = 0$ minimum
- $X \in \prod_i \{1, \dots, n_i\}$ et $p_k = \prod_i \frac{1}{n_i} \Leftrightarrow H_\lambda = \log(\prod_i n_i)$ maximum
- Discret $H_\lambda \geq 0$ – continu $N_\lambda \propto \exp\left(\frac{2H_\lambda}{\lambda}\right)$
- Continu, support fini, maximum en uniforme $H_\lambda = \log(\text{vol } \mathcal{D})$
- Contrainte de (co)variance, maximisantes :

$$\lambda > 1 : f(x) \propto (1 - x^t R^{-1} x)^{\frac{\lambda-1}{\lambda}} \quad \text{Student-r} \quad \xrightarrow{\lambda \rightarrow 1} \mathcal{N}$$

$$1 - \frac{2}{\lambda} < \lambda < 1 : f(x) \propto (1 + x^t R^{-1} x)^{\frac{\lambda-1}{\lambda}} \quad \text{Student-t} \quad \xrightarrow{\lambda \rightarrow 1} \mathcal{N}$$

QUELQUES PROPRIÉTÉS DES ENTROPIES DE RÉNYI

- Concavité pour $\lambda \leq 1$
- H_λ décroît avec λ de $H_0 = \log \text{vol } \mathcal{D}$ à $H_\infty = -\log \sup p$
- $p_{\mathbf{k}} = \delta_{\mathbf{k}, \mathbf{l}} \Leftrightarrow H_\lambda = 0$ minimum
- $\mathbf{X} \in \prod_i \{1, \dots, n_i\}$ et $p_{\mathbf{k}} = \frac{1}{\prod_i n_i} \Leftrightarrow H_\lambda = \log(\prod n_i)$ maximum
- Discret $H_\lambda \geq 0$ – continu $N_\lambda \propto \exp\left(\frac{2H_\lambda}{\lambda}\right)$
- Continu, support fini, maximum en uniforme $H_\lambda = \log(\text{vol } \mathcal{D})$
- Contrainte de (co)variance, maximisantes :

$$\lambda > 1 : f(x) \propto (1 - x^t R^{-1} x)^{\frac{1}{\lambda-1}} \quad \text{Student-t} \quad \xrightarrow{\lambda \rightarrow 1} \mathcal{N}$$

$$1 - \frac{2}{\lambda} < \lambda < 1 : f(x) \propto (1 + x^t R^{-1} x)^{\frac{1}{\lambda-1}} \quad \text{Student-t} \quad \xrightarrow{\lambda \rightarrow 1} \mathcal{N}$$

QUELQUES PROPRIÉTÉS DES ENTROPIES DE RÉNYI

- Concavité pour $\lambda \leq 1$
- H_λ décroît avec λ de $H_0 = \log \text{vol } \mathcal{D}$ à $H_\infty = -\log \sup p$
- $p_{\mathbf{k}} = \delta_{\mathbf{k}, \mathbf{l}} \Leftrightarrow H_\lambda = 0$ minimum
- $\mathbf{X} \in \prod_i \{1, \dots, n_i\}$ et $p_{\mathbf{k}} = \frac{1}{\prod_i n_i} \Leftrightarrow H_\lambda = \log(\prod n_i)$ maximum
- Discret $H_\lambda \geq 0$ – continu $N_\lambda \propto \exp\left(\frac{2H_\lambda}{d}\right)$
- Continu, support fini, maximum en uniforme $H_\lambda = \log(\text{vol } \mathcal{D})$
- Contrainte de (co)variance, maximisantes :

$$\lambda > 1 : f(x) \propto (1 - x^t R^{-1} x)^{\frac{1}{\lambda-1}} \quad \text{Student-}t \quad \xrightarrow{\lambda-1} \mathcal{N}$$

$$1 - \frac{2}{\lambda} < \lambda < 1 : f(x) \propto (1 + x^t R^{-1} x)^{\frac{1}{\lambda-1}} \quad \text{Student-t} \quad \xrightarrow{\lambda-1} \mathcal{N}$$

QUELQUES PROPRIÉTÉS DES ENTROPIES DE RÉNYI

- Concavité pour $\lambda \leq 1$
- H_λ décroît avec λ de $H_0 = \log \text{vol } \mathcal{D}$ à $H_\infty = -\log \sup p$
- $p_{\mathbf{k}} = \delta_{\mathbf{k}, \mathbf{l}} \Leftrightarrow H_\lambda = 0$ minimum
- $\mathbf{X} \in \prod_i \{1, \dots, n_i\}$ et $p_{\mathbf{k}} = \frac{1}{\prod_i n_i} \Leftrightarrow H_\lambda = \log(\prod n_i)$ maximum
- Discret $H_\lambda \geq 0$ – continu $N_\lambda \propto \exp\left(\frac{2H_\lambda}{d}\right)$
- Continu, support fini, maximum en uniforme $H_\lambda = \log(\text{vol } \mathcal{D})$
- Contrainte de (co)variance, maximisantes :

$$\lambda > 1 : f(\mathbf{x}) \propto (1 - \mathbf{x}^t \mathbf{R}^{-1} \mathbf{x})_+^{\frac{1}{\lambda-1}} \quad \text{Student-r} \quad \xrightarrow{\lambda \rightarrow 1} \mathcal{N}$$

$$1 - \frac{2}{d} < \lambda < 1 : f(\mathbf{x}) \propto (1 + \mathbf{x}^t \mathbf{R}^{-1} \mathbf{x})^{\frac{1}{\lambda-1}} \quad \text{Student-t} \quad \xrightarrow{\lambda \rightarrow 1} \mathcal{N}$$

Rappel : λ joue un rôle de loupe

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

• de longueur moyenne: $L = \sum_i p_i l_i$ minimale

• Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $l_i = -\log_2 p_i$ et $L = H(X)$ ($l_i = \lceil -\log_2 p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $l_i = -\log_2 p_i$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
 - Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\lambda} \log_2 \sum_i p_i 2^{\lambda l_i}$

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $l_i = -\log_2 p_i$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits

• Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\lambda} \log_2 \sum_i p_i 2^{\lambda l_i}$

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $l_i = -\log_2 p_i$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$
 - $C_0 = L$ et $C_\infty = \max_i l_i$

- $l_i = -\log_2 \tilde{p}_i$ et $C_\alpha = H_\alpha(X)$, avec $\lambda = \frac{1}{1+\alpha}$ et $\tilde{p}_i = \frac{p_i^{1+\alpha}}{\sum_k p_k^{1+\alpha}}$
- Pénalisation $M_\alpha = \sum_i \tilde{p}_i l_i$ et code / distrib. compagne $\{\tilde{p}_i\}$.
- $\alpha = 1$, $(\frac{10\sqrt{2}-12}{7}, \frac{10-8\sqrt{2}}{7}, \frac{2\sqrt{2}-6}{7}, \frac{2-3\sqrt{2}}{14}, \frac{2-3\sqrt{2}}{14}, \frac{2-3\sqrt{2}}{14}, \frac{2-3\sqrt{2}}{14}, \frac{-3\sqrt{2}}{14})$
- $L = 2.31 > L^*$, mais besoin de 4 bits
- $H_5(X) = 2.42$ et $C_1 = 2.46$; $H(\tilde{X}) = 1.85$ et $M_1 = 2.69$.

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $l_i = -\log_2 p_i$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$
 - $C_0 = L$ et $C_\infty = \max_i l_i$
 - $l_i = -\log_2 \tilde{p}_i$ et $C_\alpha = H_\lambda(X)$, avec $\lambda = \frac{1}{1+\alpha}$ et $\tilde{p}_i = \frac{p_i^\lambda}{\sum_k p_k^\lambda}$

• Pénalisation $M_\lambda = \sum_i \tilde{p}_i l_i$ et code / distrib. compagne $\{\tilde{p}_i\}$.

• $\alpha = 1$, $(\frac{10\sqrt{2}-12}{7}, \frac{10-8\sqrt{2}}{7}, \frac{2\sqrt{2}-6}{7}, \frac{8-3\sqrt{2}}{7}, \frac{8-3\sqrt{2}}{14}, \frac{8-3\sqrt{2}}{14}, \frac{8-3\sqrt{2}}{14}, \frac{8-3\sqrt{2}}{14})$

• $L = 2.31 > L^*$, mais besoin de 4 bits

• $H_{0.5}(X) = 2.42$ et $C_1 = 2.46$; $H(\tilde{X}) = 1.85$ et $M_{0.5} = 2.69$.

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $\underline{l_i = -\log_2 p_i}$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$
 - $C_0 = L$ et $C_\infty = \max_i l_i$
 - $\underline{l_i = -\log_2 \tilde{p}_i}$ et $C_\alpha = H_\lambda(X)$, avec $\lambda = \frac{1}{1+\alpha}$ et $\tilde{p}_i = \frac{p_i^\lambda}{\sum_k p_k^\lambda}$

• Pénalisation $M_\lambda = \sum_i \tilde{p}_i l_i$ et code / distrib. compagne $\{\tilde{p}_i\}$.

• $\alpha = 1$, $(\frac{10\sqrt{2}-12}{7}, \frac{10-8\sqrt{2}}{7}, \frac{2\sqrt{2}-6}{7}, \frac{8-3\sqrt{2}}{7}, \frac{8-3\sqrt{2}}{14}, \frac{8-3\sqrt{2}}{14}, \frac{8-3\sqrt{2}}{14}, \frac{8-3\sqrt{2}}{14})$

• $L = 2.31 > L^*$, mais besoin de 4 bits

• $H_5(X) = 2.42$ et $C_1 = 2.46$; $H(\tilde{X}) = 1.85$ et $M_5 = 2.69$.

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $\underline{l_i = -\log_2 p_i}$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$
 - $C_0 = L$ et $C_\infty = \max_i l_i$
 - $\underline{l_i = -\log_2 \tilde{p}_i}$ et $C_\alpha = H_\lambda(X)$, avec $\lambda = \frac{1}{1+\alpha}$ et $\tilde{p}_i = \frac{p_i^\lambda}{\sum_k p_k^\lambda}$
 - Pénalisation $M_\lambda = \sum_i \tilde{p}_i l_i$ et code / distrib. compagne $\{\tilde{p}_i\}_i$

• $\alpha = 1, (\frac{10\sqrt{2}-12}{7}, \frac{10-\sqrt{2}}{7}, \frac{10+3\sqrt{2}}{7}, \frac{8-3\sqrt{2}}{7}, \frac{8+3\sqrt{2}}{7}, \frac{8-3\sqrt{2}}{7}, \frac{8+3\sqrt{2}}{7}, \frac{8-3\sqrt{2}}{7})$

• $L = 2.31 > L^*$, mais besoin de 4 bits

• $H_\alpha(X) = 2.42$ et $C_1 = 2.46$; $H(\tilde{p}) = 1.85$ et $M_\lambda = 2.69$.

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $\underline{l_i = -\log_2 p_i}$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$
 - $C_0 = L$ et $C_\infty = \max_i l_i$
 - $\underline{l_i = -\log_2 \tilde{p}_i}$ et $C_\alpha = H_\lambda(X)$, avec $\lambda = \frac{1}{1+\alpha}$ et $\tilde{p}_i = \frac{p_i^\lambda}{\sum_k p_k^\lambda}$
 - Pénalisation $M_\lambda = \sum_i \tilde{p}_i l_i$ et code / distrib. compagne $\{\tilde{p}_i\}_i$
 - $\alpha = 1$, $(\frac{10\sqrt{2}-12}{7}, \frac{10-6\sqrt{2}}{7}, \frac{5\sqrt{2}-6}{7}, \frac{5-3\sqrt{2}}{7}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14})$
 - $L = 2.31 > L^*$, mais besoin de 4 bits
 - $H_\alpha(X) = 2.42$ et $C_1 = 2.46$; $H(\tilde{p}) = 1.85$ et $M_1 = 2.69$.

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $\underline{l_i = -\log_2 p_i}$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$
 - $C_0 = L$ et $C_\infty = \max_i l_i$
 - $\underline{l_i = -\log_2 \tilde{p}_i}$ et $C_\alpha = H_\lambda(X)$, avec $\lambda = \frac{1}{1+\alpha}$ et $\tilde{p}_i = \frac{p_i^\lambda}{\sum_k p_k^\lambda}$
 - Pénalisation $M_\lambda = \sum_i \tilde{p}_i l_i$ et code / distrib. compagne $\{\tilde{p}_i\}_i$
 - $\alpha = 1$, $(\frac{10\sqrt{2}-12}{7}, \frac{10-6\sqrt{2}}{7}, \frac{5\sqrt{2}-6}{7}, \frac{5-3\sqrt{2}}{7}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14})$
 Choix (00, 01, 100, 101, 1100, 1101, 1110, 1111)
 - $L = 2.31 > L^*$, mais besoin de 4 bits
 - $H_\alpha(X) = 2.42$ et $C_1 = 2.46$; $H(\tilde{p}) = 1.85$ et $M_1 = 2.69$.

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $\underline{l_i = -\log_2 p_i}$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$
 - $C_0 = L$ et $C_\infty = \max_i l_i$
 - $\underline{l_i = -\log_2 \tilde{p}_i}$ et $C_\alpha = H_\lambda(X)$, avec $\lambda = \frac{1}{1+\alpha}$ et $\tilde{p}_i = \frac{p_i^\lambda}{\sum_k p_k^\lambda}$
 - Pénalisation $M_\lambda = \sum_i \tilde{p}_i l_i$ et code / distrib. compagne $\{\tilde{p}_i\}_i$
 - $\alpha = 1$, $(\frac{10\sqrt{2}-12}{7}, \frac{10-6\sqrt{2}}{7}, \frac{5\sqrt{2}-6}{7}, \frac{5-3\sqrt{2}}{7}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14})$
 Choix (00, 01, 100, 101, 1100, 1101, 1110, 1111)
 - $L = 2.31 > L^*$, mais besoin de 4 bits
 - $H_\alpha(X) = 2.42$ et $C_1 = 2.46$; $H(\tilde{p}) = 1.85$ et $M_1 = 2.69$.

EXEMPLE DE CODAGE CAMPBELL '65, BERCHER '09

Codage binaire des faces du dé à 8 faces pipé de loi $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$.

Code instantané (mot non préfixe d'un autre) \rightarrow Kraft $\sum_i 2^{-l_i} \leq 1$

- de longueur moyenne: $L = \sum_i p_i l_i$ minimale
 - $\underline{l_i = -\log_2 p_i}$ et $L^* = H(X)$ ($l_i = \lceil -\log p_i \rceil$ et $L \geq H(X)$)
 - choix (0, 10, 110, 1110, 111100, 111101, 111110, 111111)
 - $L = 2 = H(X)$ mais malgré tout, besoin de 6 bits
- Pénalisation des mots longs : minimisation de $C_\lambda = \frac{1}{\alpha} \log_2 \sum_i p_i 2^{\alpha l_i}$
 - $C_0 = L$ et $C_\infty = \max_i l_i$
 - $\underline{l_i = -\log_2 \tilde{p}_i}$ et $C_\alpha = H_\lambda(X)$, avec $\lambda = \frac{1}{1+\alpha}$ et $\tilde{p}_i = \frac{p_i^\lambda}{\sum_k p_k^\lambda}$
 - Pénalisation $M_\lambda = \sum_i \tilde{p}_i l_i$ et code / distrib. compagne $\{\tilde{p}_i\}_i$
 - $\alpha = 1$, $(\frac{10\sqrt{2}-12}{7}, \frac{10-6\sqrt{2}}{7}, \frac{5\sqrt{2}-6}{7}, \frac{5-3\sqrt{2}}{7}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14}, \frac{5-3\sqrt{2}}{14})$
 Choix (00, 01, 100, 101, 1100, 1101, 1110, 1111)
 - $L = 2.31 > L^*$, mais besoin de 4 bits
 - $H_{.5}(X) = 2.42$ et $C_1 = 2.46$; $H(\tilde{X}) = 1.85$ et $M_{.5} = 2.69$.

UN PEU DE PHYSIQUE

GAZ PARFAIT :

N particules, volume Λ ,

$$\Omega_{\Lambda, N, E} = \left\{ (v_1, \dots, v_N) \left| \mathcal{H} = \sum_{i=1}^N \frac{1}{2} m v_i^2 = E \right. \right\} \quad (\text{hypersphère})$$

répartition uniforme sur la surface $\Omega_{\Lambda, N, E}$ (entropie maximum)

UN PEU DE PHYSIQUE

GAZ PARFAIT :

N particules, volume Λ ,

$$\Omega_{\Lambda, N, E} = \left\{ (v_1, \dots, v_N) \left| \mathcal{H} = \sum_{i=1}^N \frac{1}{2} m v_i^2 = E \right. \right\} \quad (\text{hypersphère})$$

répartition uniforme sur la surface $\Omega_{\Lambda, N, E}$ (entropie maximum)

Sous-ensemble $\Lambda_0 \subset \Lambda$ de $N_0 < N$ particules :

$$p(v_1, \dots, v_{N_0}) \propto \left(1 - \frac{m}{2E} \mathbf{v}_0^t \mathbf{v}_0 \right)^{\frac{3(N-N_0)-2}{2}}$$

UN PEU DE PHYSIQUE

GAZ PARFAIT :

N particules, volume Λ ,

$$\Omega_{\Lambda, N, E} = \left\{ (v_1, \dots, v_N) \left| \mathcal{H} = \sum_{i=1}^N \frac{1}{2} m v_i^2 = E \right. \right\} \quad (\text{hypersphère})$$

répartition uniforme sur la surface $\Omega_{\Lambda, N, E}$ (entropie maximum)

Sous-ensemble $\Lambda_0 \subset \Lambda$ de $N_0 < N$ particules :

$$p(v_1, \dots, v_{N_0}) \propto \left(1 - \frac{m}{2E} \mathbf{v}_0^t \mathbf{v}_0 \right)^{\frac{3(N-N_0)-2}{2}}$$

Limite thermodynamique : $\Lambda \rightarrow \mathbb{R}^3$, $\frac{N}{|\Lambda|} \rightarrow \rho$ et $\frac{E}{|\Lambda|} \rightarrow e$

$$p(v_1, \dots, v_{N_0}) \propto \exp \left(- \frac{3m\rho}{4e} \mathbf{v}_0^t \mathbf{v}_0 \right) \quad (\text{Boltzmann})$$

UN PEU DE PHYSIQUE

GAZ PARFAIT :

N particules, volume Λ ,

$$\Omega_{\Lambda, N, E} = \left\{ (v_1, \dots, v_N) \left| \mathcal{H} = \sum_{i=1}^N \frac{1}{2} m v_i^2 = E \right. \right\} \quad (\text{hypersphère})$$

répartition uniforme sur la surface $\Omega_{\Lambda, N, E}$ (entropie maximum)

Sous-ensemble $\Lambda_0 \subset \Lambda$ de $N_0 < N$ particules :

$$p(v_1, \dots, v_{N_0}) \propto \left(1 - \frac{m}{2E} \mathbf{v}_0^t \mathbf{v}_0 \right)^{\frac{3(N-N_0)-2}{2}}$$

Limite thermodynamique : $\Lambda \rightarrow \mathbb{R}^3$, $\frac{N}{|\Lambda|} \rightarrow \rho$ et $\frac{E}{|\Lambda|} \rightarrow e$

$$p(v_1, \dots, v_{N_0}) \propto \exp \left(- \frac{3m\rho}{4e} \mathbf{v}_0^t \mathbf{v}_0 \right) \quad (\text{Boltzmann}) \Rightarrow \text{Shannon}$$

UN PEU DE PHYSIQUE

GAZ PARFAIT :

N particules, volume Λ ,

$$\Omega_{\Lambda, N, E} = \left\{ (v_1, \dots, v_N) \left| \mathcal{H} = \sum_{i=1}^N \frac{1}{2} m v_i^2 = E \right. \right\} \quad (\text{hypersphère})$$

répartition uniforme sur la surface $\Omega_{\Lambda, N, E}$ (entropie maximum)

Sous-ensemble $\Lambda_0 \subset \Lambda$ de $N_0 < N$ particules :

$$p(v_1, \dots, v_{N_0}) \propto \left(1 - \frac{m}{2E} \mathbf{v}_0^t \mathbf{v}_0 \right)^{\frac{3(N-N_0)-2}{2}} \Rightarrow \text{Rényi, } \alpha = \frac{3N - 3N_0}{3N - 3N_0 - 2} > 1$$

Limite thermodynamique : $\Lambda \rightarrow \mathbb{R}^3$, $\frac{N}{|\Lambda|} \rightarrow \rho$ et $\frac{E}{|\Lambda|} \rightarrow e$

$$p(v_1, \dots, v_{N_0}) \propto \exp \left(- \frac{3m\rho}{4e} \mathbf{v}_0^t \mathbf{v}_0 \right) \quad (\text{Boltzmann}) \Rightarrow \text{Shannon}$$

PLAN DU COURS

1 ENTROPIE – MESURE D'INCERTITUDE

- Axiomes, entropie de Shannon et ses propriétés
- Entropie différentielle – cas vectoriel
- D'autres mesures d'information

2 INFORMATION MUTUELLE - DIVERGENCES

- Entropie conditionnelle, Information mutuelle
- Quelques exemples
- Divergences

3 INÉGALITÉS – RELATIONS ENTROPIQUES

- Inégalités “classiques”
- Chaînes de Markov
- Inégalité de la puissance entropique
- Estimation – relations entre informations

1 RELATIONS D'INCERTITUDE

- Relation d'incertitude d'Heisenberg et versions entropiques

ENTROPIE CONDITIONNELLE

Soient \mathbf{X} et \mathbf{Y} : degré d'incertitude $H(\mathbf{X})$ et $H(\mathbf{Y})$

Quelle information/incertitude commune \mathbf{X} et \mathbf{Y} partagent-ils ?

ENTROPIE CONDITIONNELLE

Soient \mathbf{X} et \mathbf{Y} : degré d'incertitude $H(\mathbf{X})$ et $H(\mathbf{Y})$

Quelle information/incertitude commune \mathbf{X} et \mathbf{Y} partagent-ils ?

Entropie conditionnelle ou incertitude sur \mathbf{X} connaissant \mathbf{Y}

$$\begin{aligned} H(\mathbf{X}|\mathbf{Y}) &= E_{\mathbf{Y}} [H(\mathbf{X}|\mathbf{Y})] \\ &= \int p_{\mathbf{Y}}(\mathbf{y}) \left(- \int p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}, \mathbf{y}) \log p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}, \mathbf{y}) d\mathbf{x} \right) d\mathbf{y} \\ &= - \iint p_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y}) \log p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}, \mathbf{y}) d\mathbf{x}d\mathbf{y} \end{aligned}$$




Diagramme de Venn

ENTROPIE CONDITIONNELLE

Soient \mathbf{X} et \mathbf{Y} : degré d'incertitude $H(\mathbf{X})$ et $H(\mathbf{Y})$

Quelle information/incertitude commune \mathbf{X} et \mathbf{Y} partagent-ils ?

Entropie conditionnelle ou incertitude sur \mathbf{X} connaissant \mathbf{Y}

$$\begin{aligned} H(\mathbf{X}|\mathbf{Y}) &= E_{\mathbf{Y}} [H(\mathbf{X}|\mathbf{Y})] \\ &= \int p_{\mathbf{Y}}(\mathbf{y}) \left(- \int p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}, \mathbf{y}) \log p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}, \mathbf{y}) d\mathbf{x} \right) d\mathbf{y} \\ &= - \iint p_{\mathbf{X},\mathbf{Y}}(\mathbf{x}, \mathbf{y}) \log p_{\mathbf{X}|\mathbf{Y}}(\mathbf{x}, \mathbf{y}) d\mathbf{x} d\mathbf{y} \end{aligned}$$





Diagramme de Venn


$$H(\mathbf{X}, \mathbf{Y}) = H(\mathbf{X}|\mathbf{Y}) + H(\mathbf{Y})$$

INFORMATION MUTUELLE




$$H(X, Y) = H(X|Y) + H(Y)$$

INFORMATION MUTUELLE



$$\begin{aligned} H(\mathbf{X}, \mathbf{Y}) &= H(\mathbf{X}|\mathbf{Y}) + H(\mathbf{Y}) \\ &= H(\mathbf{Y}|\mathbf{X}) + H(\mathbf{X}) \end{aligned}$$


INFORMATION MUTUELLE



$$\begin{aligned}H(\mathbf{X}, \mathbf{Y}) &= H(\mathbf{X}|\mathbf{Y}) + H(\mathbf{Y}) \\ &= H(\mathbf{Y}|\mathbf{X}) + H(\mathbf{X})\end{aligned}$$

$$H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y})$$


INFORMATION MUTUELLE



$$\begin{aligned}H(\mathbf{X}, \mathbf{Y}) &= H(\mathbf{X}|\mathbf{Y}) + H(\mathbf{Y}) \\ &= H(\mathbf{Y}|\mathbf{X}) + H(\mathbf{X})\end{aligned}$$

$$H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}) = H(\mathbf{Y}) - H(\mathbf{Y}|\mathbf{X})$$

INFORMATION MUTUELLE




$$\begin{aligned}H(X, Y) &= H(X|Y) + H(Y) \\ &= H(Y|X) + H(X)\end{aligned}$$

$$H(X) - H(X|Y) = H(Y) - H(Y|X)$$

Information mutuelle :

$$I(X; Y) = H(X) - H(X|Y) = H(Y) - H(Y|X) = H(X) + H(Y) - H(X, Y)$$

INFORMATION MUTUELLE



$$\begin{aligned} H(X, Y) &= H(X|Y) + H(Y) \\ &= H(Y|X) + H(X) \end{aligned}$$


$$H(X) - H(X|Y) = H(Y) - H(Y|X)$$

Information mutuelle :

$$I(X; Y) = H(X) - H(X|Y) = H(Y) - H(Y|X) = H(X) + H(Y) - H(X, Y)$$

$$I(X; Y) = \int p_{X,Y}(x, y) \log \left(\frac{p_{X,Y}(x, y)}{p_X(x)p_Y(y)} \right) dx dy$$

INFORMATION MUTUELLE



$$\begin{aligned} H(\mathbf{X}, \mathbf{Y}) &= H(\mathbf{X}|\mathbf{Y}) + H(\mathbf{Y}) \\ &= H(\mathbf{Y}|\mathbf{X}) + H(\mathbf{X}) \end{aligned}$$

$$H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}) = H(\mathbf{Y}) - H(\mathbf{Y}|\mathbf{X})$$

Information mutuelle :

$$I(\mathbf{X}; \mathbf{Y}) = H(\mathbf{X}) - H(\mathbf{X}|\mathbf{Y}) = H(\mathbf{Y}) - H(\mathbf{Y}|\mathbf{X}) = H(\mathbf{X}) + H(\mathbf{Y}) - H(\mathbf{X}, \mathbf{Y})$$

$$I(\mathbf{X}; \mathbf{Y}) = \int p_{\mathbf{X}, \mathbf{Y}}(\mathbf{x}, \mathbf{y}) \log \left(\frac{p_{\mathbf{X}, \mathbf{Y}}(\mathbf{x}, \mathbf{y})}{p_{\mathbf{X}}(\mathbf{x})p_{\mathbf{Y}}(\mathbf{y})} \right) dx dy$$

Information conditionnelle : $I(\mathbf{X}; \mathbf{Y}|\mathbf{Z}) = H(\mathbf{X}|\mathbf{Z}) - H(\mathbf{X}|\mathbf{Y}, \mathbf{Z})$

$$I(\mathbf{X}; \mathbf{Y}|\mathbf{Z}) = \int p_{\mathbf{X}, \mathbf{Y}, \mathbf{Z}}(\mathbf{x}, \mathbf{y}, \mathbf{z}) \log \left(\frac{p_{\mathbf{X}, \mathbf{Y}|\mathbf{Z}}(\mathbf{x}, \mathbf{y}, \mathbf{z})}{p_{\mathbf{X}|\mathbf{Z}}(\mathbf{x}, \mathbf{z})p_{\mathbf{Y}|\mathbf{Z}}(\mathbf{y}, \mathbf{z})} \right) dx dy dz$$

INFORMATION MUTUELLE : EXEMPLES JOUETS

Calculer entropies, entropies conditionnelles et information mutuelle pour :

Exemple 1

Y	X	1	2
	1	0	$\frac{1}{4}$
2	$\frac{3}{4}$	0	

Exemple 2

Y	X	1	2
	1	$\frac{3}{16}$	$\frac{1}{16}$
2	$\frac{9}{16}$	$\frac{3}{16}$	


Exemple 3

Y	X	1	2
	1	0	$\frac{3}{4}$
2	$\frac{1}{8}$	$\frac{1}{8}$	

INFORMATION MUTUELLE : CANAL GAUSSIEN

Canal Gaussien et capacité canal :

Transmission d'un signal \mathbf{X} dans un canal supposé être un "fil", mais perturbé par un bruit Gaussien.




$\mathbf{Y} = \mathbf{X} + \mathbf{G}$ avec \mathbf{G} Gaussien de covariance \mathbf{R} et \mathbf{X} indépendant de \mathbf{G} . Par soucis de simplicité et sans perte de généralité on suppose \mathbf{X} et \mathbf{G} centrés. On suppose de plus que la puissance du signal est limitée à $E[\mathbf{X}^t \mathbf{X}] \leq P_X$.


- Quelle est l'information mutuelle maximum possible entre \mathbf{X} et \mathbf{Y} ? Cette quantité est appelée **capacité du canal**.
- Pour quelle distribution de \mathbf{X} atteint-t-on ce maximum ? On effectuera la détermination complète de p_X dans le cas 1 dimension.

INFORMATION MUTUELLE : CANAL SYMÉTRIQUE

Canal binaire et capacité canal : transmission d'un signal $X \in \{-1; 1\} \sim \{\alpha, 1 - \alpha\}$ dans un canal représenté par la figure de droite.



- Les probabilités de transition étant fixées, pour quelle valeur de α atteint-t-on $I(X; Y)$ maximum ?
- Que devient α pour $p = q$ (canal binaire symétrique) ?
- Quelle est la capacité canal dans ce dernier cas ?
- On peut représenter ce canal de la manière suivante :



symbole $X \in \{-\sigma_X, \sigma_X\}$ émis, G Gaussien centré de variance σ^2 .
 Déterminer p , q et conclure.

DIVERGENCE DE KULLBACK-LEIBLER

“Distance” entre vecteurs aléatoires \mathbf{P} et \mathbf{Q} , de distributions p et q :
Divergence de Kullback-Leibler (entropie relative)

$$D_{\text{kl}}(p||q) = \int p(\mathbf{x}) \log \left(\frac{p(\mathbf{x})}{q(\mathbf{x})} \right) d\mathbf{x}$$

- Non-symétrique : q est une “référence”
- $D_{\text{kl}} \geq 0$
- $D_{\text{kl}} = 0 \Leftrightarrow p = q$ (p.p.)
- $I(X; Y) = D_{\text{kl}}(p_{X,Y} || p_X p_Y)$ (symétrique) :
 $I \geq 0$ et est nulle si et seulement si il y a indépendance

DIVERGENCE DE KULLBACK-LEIBLER

“Distance” entre vecteurs aléatoires P et Q , de distributions p et q :
Divergence de Kullback-Leibler (entropie relative)

$$D_{\text{kl}}(p||q) = \int p(\mathbf{x}) \log \left(\frac{p(\mathbf{x})}{q(\mathbf{x})} \right) d\mathbf{x}$$

- Non-symétrique : q est une “référence”
- $D_{\text{kl}} \geq 0$
- $D_{\text{kl}} = 0 \Leftrightarrow p = q$ (p.p.)
- $I(X;Y) = D_{\text{kl}}(p_{X,Y}||p_X p_Y)$ (symétrique) :
• $I \geq 0$ et est nulle si et seulement si il y a indépendance

DIVERGENCE DE KULLBACK-LEIBLER

“Distance” entre vecteurs aléatoires \mathbf{P} et \mathbf{Q} , de distributions p et q :
Divergence de Kullback-Leibler (entropie relative)

$$D_{\text{kl}}(p||q) = \int p(\mathbf{x}) \log \left(\frac{p(\mathbf{x})}{q(\mathbf{x})} \right) d\mathbf{x}$$

- Non-symétrique : q est une “référence”
- $D_{\text{kl}} \geq 0$
- $D_{\text{kl}} = 0 \Leftrightarrow p = q$ (p.p.)
- $I(\mathbf{X}; \mathbf{Y}) = D_{\text{kl}}(p_{X,Y} || p_X p_Y)$ (symétrique) :
 $I \geq 0$ et est nulle si et seulement si il y a indépendance

DIVERGENCE DE KULLBACK-LEIBLER

“Distance” entre vecteurs aléatoires \mathbf{P} et \mathbf{Q} , de distributions p et q :
Divergence de Kullback-Leibler (entropie relative)

$$D_{\text{kl}}(p||q) = \int p(\mathbf{x}) \log \left(\frac{p(\mathbf{x})}{q(\mathbf{x})} \right) d\mathbf{x}$$

- Non-symétrique : q est une “référence”
- $D_{\text{kl}} \geq 0$
- $D_{\text{kl}} = 0 \Leftrightarrow p = q$ (p.p.)
- $I(\mathbf{X}; \mathbf{Y}) = D_{\text{kl}}(p_{X,Y} || p_X p_Y)$ (symétrique) :
 $I \geq 0$ et est nulle si et seulement si il y a indépendance

Divergence de Kullback-Leibler conditionnelle :

$$D_{\text{kl}}(p_{X|Y} || q_{X|Y}) = \int p_{X,Y}(\mathbf{x}, \mathbf{y}) \log \left(\frac{p_{X|Y}(\mathbf{x}, \mathbf{y})}{q_{X|Y}(\mathbf{x}, \mathbf{y})} \right) d\mathbf{x} d\mathbf{y}$$

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(t) = t \log t$: divergence de Kullback-Leibler
- $f(t) = |\pi_0 - \pi_1 t|$: divergence de Kolmogorov ($P_{e,\min}$ détec. bin.)
- $f(t) = t^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(t) = \frac{t^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(t) = -t^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)
- $f(t) = |t - 1|$: divergence de la variation totale (distance L^1)
- $f(t) = (t - 1)^2$ ou $t^2 - 1$: divergence χ^2 -Pearson (estimation)
- Plus généralement $f(t) = |t - 1|^\alpha$, $\alpha \geq 1$ (Vajda'73)

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(l) = l \log l$: divergence de Kullback-Leibler
- $f(l) = |\pi_0 - \pi_1 l|$: divergence de Kolmogorov ($P_{e,\min}$ détec. bin.)
- $f(l) = l^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(l) = \frac{l^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(l) = -l^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)
- $f(l) = |l - 1|$: divergence de la variation totale (distance L^1)
- $f(l) = (l - 1)^2$ ou $l^2 - 1$: divergence χ^2 -Pearson (estimation)
- Plus généralement $f(l) = |l - 1|^\alpha$, $\alpha \geq 1$ (Vajda'73)

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(l) = l \log l$: divergence de Kullback-Leibler
- $f(l) = |\pi_0 - \pi_1 l|$: divergence de Kolmogorov ($P_{e,\min}$ détec. bin.)
- $f(l) = l^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(l) = \frac{l^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(l) = -l^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)
- $f(l) = |l - 1|$: divergence de la variation totale (distance L^1)
- $f(l) = (l - 1)^2$ ou $l^2 - 1$: divergence χ^2 -Pearson (estimation)
- Plus généralement $f(l) = |l - 1|^\alpha$, $\alpha \geq 1$ (Vajda'73)

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(l) = l \log l$: divergence de Kullback-Leibler
- $f(l) = |\pi_0 - \pi_1 l|$: divergence de Kolmogorov ($P_{e,min}$ détec. bin.)
- $f(l) = l^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(l) = \frac{l^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(l) = -l^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)
- $f(l) = |l - 1|$: divergence de la variation totale (distance L^1)
- $f(l) = (l - 1)^2$ ou $l^2 - 1$: divergence χ^2 -Pearson (estimation)
- Plus généralement $f(l) = |l - 1|^\alpha$, $\alpha \geq 1$ (Vajda'73)

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(l) = l \log l$: divergence de Kullback-Leibler
- $f(l) = |\pi_0 - \pi_1 l|$: divergence de Kolmogorov ($P_{e,\min}$ détec. bin.)
- $f(l) = l^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(l) = \frac{l^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(l) = -l^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)
- $f(l) = |l - 1|$: divergence de la variation totale (distance L^1)
- $f(l) = (l - 1)^2$ ou $l^2 - 1$: divergence χ^2 -Pearson (estimation)
- Plus généralement $f(l) = |l - 1|^\alpha$, $\alpha \geq 1$ (Vajda'73)

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(l) = l \log l$: divergence de Kullback-Leibler
- $f(l) = |\pi_0 - \pi_1 l|$: divergence de Kolmogorov ($P_{e,min}$ détec. bin.)
- $f(l) = l^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(l) = \frac{l^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(l) = -l^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)

• $f(l) = |l - 1|$: divergence de la variation totale (distance L^1)

• $f(l) = (l - 1)^2$ ou $l^2 - 1$: divergence χ^2 -Pearson (estimation)

• Plus généralement $f(l) = |l - 1|^\alpha$, $\alpha \geq 1$ (Vajda'73)

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(l) = l \log l$: divergence de Kullback-Leibler
- $f(l) = |\pi_0 - \pi_1 l|$: divergence de Kolmogorov ($P_{e,min}$ détec. bin.)
- $f(l) = l^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(l) = \frac{l^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(l) = -l^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)
- $f(l) = |l - 1|$: divergence de la variation totale (distance L^1)
- $f(l) = (l - 1)^2$ ou $l^2 - 1$: divergence χ^2 -Pearson (estimation)
- Plus généralement $f(l) = |l - 1|^\alpha$, $\alpha \geq 1$ (Vajda'73)

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(l) = l \log l$: divergence de Kullback-Leibler
- $f(l) = |\pi_0 - \pi_1 l|$: divergence de Kolmogorov ($P_{e,\min}$ détec. bin.)
- $f(l) = l^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(l) = \frac{l^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(l) = -l^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)
- $f(l) = |l - 1|$: divergence de la variation totale (distance L^1)
- $f(l) = (l - 1)^2$ ou $l^2 - 1$: divergence χ^2 -Pearson (estimation)

• Plus généralement $f(l) = |l - 1|^\alpha, \alpha \geq 1$ (Vajda'73)

D'AUTRES DIVERGENCES

f -divergence (Ali-Silvey'66 ou Csizàr'67)

$$D_f(p||q) = g \left(E_q \left[f \left(\frac{p}{q} \right) \right] \right)$$

avec f convexe et g fonction croissante

- $f(l) = l \log l$: divergence de Kullback-Leibler
- $f(l) = |\pi_0 - \pi_1 l|$: divergence de Kolmogorov ($P_{e,\min}$ détec. bin.)
- $f(l) = l^\lambda$ et $g = \frac{1}{\lambda-1} \log$: $D_\lambda = \frac{1}{\lambda-1} \log \int q \left(\frac{p}{q} \right)^\lambda$ divergence de Rényi
- $f(l) = \frac{l^\alpha - 1}{\alpha - 1}$: divergence d'Hellinger (classification, estimation)
- $f(l) = -l^\alpha$ pour $0 < \alpha < 1$: la divergence de Chernoff (détection) ; pour $\alpha = 1/2$: divergence de Bhattacharya (estimation, détection)
- $f(l) = |l - 1|$: divergence de la variation totale (distance L^1)
- $f(l) = (l - 1)^2$ ou $l^2 - 1$: divergence χ^2 -Pearson (estimation)
- Plus généralement $f(l) = |l - 1|^\alpha$, $\alpha \geq 1$ (Vajda'73)

ZOOM SUR LA MATRICE INFORMATION DE FISHER

Soit $\mathbf{X}_\theta \sim p_\theta$ paramétré par θ

- Matrice de Fisher :

$$\mathbf{J}(\theta) = E [(\nabla_\theta \log p_\theta)(\nabla_\theta \log p_\theta)^t]$$

C'est la covariance de la fonction score $\mathbf{S}_\theta = \nabla_\theta \log p_\theta = \frac{\nabla_\theta p_\theta}{p_\theta}$

- Information de Fisher :

$$\mathbf{J}(\theta) = E [(\nabla_\theta \log p_\theta)^t (\nabla_\theta \log p_\theta)]$$

C'est la trace de la matrice de Fisher

- θ paramètre de position : $p_\theta(\mathbf{x}) = p(\mathbf{x} - \theta)$ et $\nabla_\theta p_\theta = -\nabla_{\mathbf{x}} p_X(\mathbf{x})$
 le score devient $\mathbf{S} = -\nabla_{\mathbf{x}} \log p_X$

Matrice et information de Fisher de \mathbf{X} : $\mathbf{J}(\mathbf{X})$ et $J(\mathbf{X}) = \text{Tr}(\mathbf{J}(\mathbf{X}))$

$\mathbf{J}(a\mathbf{X}) = \frac{1}{a^2} \mathbf{J}(\mathbf{X})$: si $a \rightarrow \infty$ la matrice de Fisher est nulle...

ESTIMATION ET INFORMATION DE FISHER

Soit $X \sim p_{\theta_0}$ où $p_{\theta_0} \in \{p_{\theta}\}_{\theta}$. On veut estimer θ_0 à partir de X

ESTIMATION ET INFORMATION DE FISHER

Soit $X \sim p_{\theta_0}$ où $p_{\theta_0} \in \{p_{\theta}\}_{\theta}$. On veut estimer θ_0 à partir de X

$$D(p_{\theta} \parallel p_{\theta_0}) \geq 0 ; \text{ égalité ssi } \theta = \theta_0 \Rightarrow \nabla_{\theta} D|_{\theta_0} = \mathbf{0} \text{ et } \mathcal{H}_{\theta} D|_{\theta_0} \geq 0$$

ESTIMATION ET INFORMATION DE FISHER

Soit $X \sim p_{\theta_0}$ où $p_{\theta_0} \in \{p_{\theta}\}_{\theta}$. On veut estimer θ_0 à partir de X

$$D(p_{\theta} \parallel p_{\theta_0}) \geq 0 ; \text{ égalité ssi } \theta = \theta_0 \Rightarrow \nabla_{\theta} D|_{\theta_0} = \mathbf{0} \text{ et } \mathcal{H}_{\theta} D|_{\theta_0} \geq 0$$

On montre que $\mathcal{H}_{\theta} D(p_{\theta} \parallel p_{\theta_0})|_{\theta_0} = J(\theta_0)$ matrice de Fisher



ESTIMATION ET INFORMATION DE FISHER

Soit $\mathbf{X} \sim p_{\theta_0}$ où $p_{\theta_0} \in \{p_{\theta}\}_{\theta}$. On veut estimer θ_0 à partir de \mathbf{X}

$$D(p_{\theta} \parallel p_{\theta_0}) \geq 0 ; \text{ égalité ssi } \theta = \theta_0 \Rightarrow \nabla_{\theta} D|_{\theta_0} = \mathbf{0} \text{ et } \mathcal{H}_{\theta} D|_{\theta_0} \geq 0$$

On montre que $\mathcal{H}_{\theta} D(p_{\theta} \parallel p_{\theta_0})|_{\theta_0} = \mathbf{J}(\theta_0)$ matrice de Fisher

$$D(p_{\theta} \parallel p_{\theta_0}) = \frac{1}{2} (\theta - \theta_0)^t \mathbf{J}(\theta_0) (\theta - \theta_0) + o(\|\theta - \theta_0\|^2)$$



PLAN DU COURS

1 ENTROPIE – MESURE D’INCERTITUDE

- Axiomes, entropie de Shannon et ses propriétés
- Entropie différentielle – cas vectoriel
- D’autres mesures d’information

2 INFORMATION MUTUELLE - DIVERGENCES

- Entropie conditionnelle, Information mutuelle
- Quelques exemples
- Divergences

3 INÉGALITÉS – RELATIONS ENTROPIQUES

- Inégalités “classiques”
- Chaînes de Markov
- Inégalité de la puissance entropique
- Estimation – relations entre informations

1 RELATIONS D’INCERTITUDE

- Relation d’incertitude d’Heisenberg et versions entropiques

INÉGALITÉS TRIVIALES

- X discret sur un alphabet \mathcal{X} de taille finie $|\mathcal{X}|$,

$$0 \leq H(X) \leq \log |\mathcal{X}| \quad (\text{max. uniforme})$$

- X continu sur un domaine \mathcal{D} borné,

$$H(X) \leq \log \text{vol } \mathcal{D} \quad (\text{max. uniforme})$$

- X continu sur \mathbb{R}^d , de covariance donnée R ,

$$H(X) \leq \frac{1}{2} \log \left((2\pi e)^d |R| \right) \quad (\text{max. Gaussien})$$

INÉGALITÉS TRIVIALES

- X discret sur un alphabet \mathcal{X} de taille finie $|\mathcal{X}|$,

$$0 \leq H(X) \leq \log |\mathcal{X}| \quad (\text{max. uniforme})$$

- X continu sur un domaine \mathcal{D} borné,

$$H(X) \leq \log \text{vol } \mathcal{D} \quad (\text{max. uniforme})$$

- X continu sur \mathbb{R}^d , de covariance donnée R ,

$$H(X) \leq \frac{1}{2} \log \left((2\pi e)^d |R| \right) \quad (\text{max. Gaussien})$$

INÉGALITÉS TRIVIALES

- X discret sur un alphabet \mathcal{X} de taille finie $|\mathcal{X}|$,

$$0 \leq H(X) \leq \log |\mathcal{X}| \quad (\text{max. uniforme})$$

- X continu sur un domaine \mathcal{D} borné,

$$H(X) \leq \log \text{vol } \mathcal{D} \quad (\text{max. uniforme})$$

- X continu sur \mathbb{R}^d , de covariance donnée \mathbf{R} ,

$$H(X) \leq \frac{1}{2} \log \left((2\pi e)^d |\mathbf{R}| \right) \quad (\text{max. Gaussien})$$

INÉGALITÉS TRIVIALES

- X discret sur un alphabet \mathcal{X} de taille finie $|\mathcal{X}|$,

$$0 \leq H(X) \leq \log |\mathcal{X}| \quad (\text{max. uniforme})$$

- X continu sur un domaine \mathcal{D} borné,

$$H(X) \leq \log \text{vol } \mathcal{D} \quad (\text{max. uniforme})$$

- X continu sur \mathbb{R}^d , de covariance donnée \mathbf{R} ,

$$H(X) \leq \frac{1}{2} \log \left((2\pi e)^d |\mathbf{R}| \right) \quad (\text{max. Gaussien})$$

Toute densité de proba peut être vue comme maximisante de H , sous contrainte adéquate (loi expo./moyenne, loi de Cauchy/contrainte log.)

RÈGLES DE CHÂINAGE

- Sur l'entropie :

$$H(\mathbf{X}_n, \dots, \mathbf{X}_1) = \sum_i H(\mathbf{X}_i | \mathbf{X}_{i-1}, \dots, \mathbf{X}_1)$$

- Sur l'information mutuelle :

$$I(\mathbf{X}_n, \dots, \mathbf{X}_1; Y) = \sum_i I(\mathbf{X}_i; Y | \mathbf{X}_{i-1}, \dots, \mathbf{X}_1)$$

- Sur la divergence de Kullback-Leibler :

$$D(p(x_n, \dots, x_1) || q(x_n, \dots, x_1)) = \sum_i D(p(x_i | x_{i-1}, \dots, x_1) || q(x_i | x_{i-1}, \dots, x_1))$$

RÈGLES DE CHÂINAGE

- Sur l'entropie :

$$H(\mathbf{X}_n, \dots, \mathbf{X}_1) = \sum_i H(\mathbf{X}_i | \mathbf{X}_{i-1}, \dots, \mathbf{X}_1)$$

- Sur l'information mutuelle :

$$I(\mathbf{X}_n, \dots, \mathbf{X}_1; \mathbf{Y}) = \sum_i I(\mathbf{X}_i; \mathbf{Y} | \mathbf{X}_{i-1}, \dots, \mathbf{X}_1)$$

- Sur la divergence de Kullback-Leibler :

$$D(p(x_n, \dots, x_1) || q(x_n, \dots, x_1)) = \sum_i D(p(x_i | x_{i-1}, \dots, x_1) || q(x_i | x_{i-1}, \dots, x_1))$$

RÈGLES DE CHÂINAGE

- Sur l'entropie :

$$H(\mathbf{X}_n, \dots, \mathbf{X}_1) = \sum_i H(\mathbf{X}_i | \mathbf{X}_{i-1}, \dots, \mathbf{X}_1)$$

- Sur l'information mutuelle :

$$I(\mathbf{X}_n, \dots, \mathbf{X}_1; \mathbf{Y}) = \sum_i I(\mathbf{X}_i; \mathbf{Y} | \mathbf{X}_{i-1}, \dots, \mathbf{X}_1)$$

- Sur la divergence de Kullback-Leibler :

$$D(p(\mathbf{x}_n, \dots, \mathbf{x}_1) || q(\mathbf{x}_n, \dots, \mathbf{x}_1)) = \sum_i D(p(\mathbf{x}_i | \mathbf{x}_{i-1}, \dots, \mathbf{x}_1) || q(\mathbf{x}_i | \mathbf{x}_{i-1}, \dots, \mathbf{x}_1))$$

CONDITIONNEMENT, MARGINALES, CONCAVITÉ

- Conditionner réduit l'entropie :

$$H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X}) \text{ avec égalité ssi } \mathbf{X} \text{ et } \mathbf{Y} \text{ sont indépendants}$$

- Incertitude globale plus petite que la somme des incertitudes :

$$H(X_1, \dots, X_n) \leq \sum_i H(X_i) \text{ égalité ssi les } X_i \text{ sont indépendants}$$

- Concavité de H : pour $\lambda_i \geq 0$ tels que $\sum_i \lambda_i = 1$,

$$H\left(\sum_i \lambda_i X_i\right) \geq \sum_i \lambda_i H(X_i)$$

CONDITIONNEMENT, MARGINALES, CONCAVITÉ

- Conditionner réduit l'entropie :

$$H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X}) \quad \text{avec égalité ssi } \mathbf{X} \text{ et } \mathbf{Y} \text{ sont indépendants}$$

- Incertitude globale plus petite que la somme des incertitudes :

$$H(\mathbf{X}_1, \dots, \mathbf{X}_n) \leq \sum_i H(\mathbf{X}_i) \quad \text{égalité ssi les } \mathbf{X}_i \text{ sont indépendants}$$

- Inégalité de Hadamard : $|R| \leq \prod_i R_i$

- Processus stationnaire : $\mathcal{H}(\mathbf{X}) \leq H(\mathbf{X}_1)$, égalité ssi cas iid

- Concavité de H : pour $\lambda_i \geq 0$ tels que $\sum_i \lambda_i = 1$,

$$H\left(\sum_i \lambda_i \mathbf{X}_i\right) \geq \sum_i \lambda_i H(\mathbf{X}_i)$$

CONDITIONNEMENT, MARGINALES, CONCAVITÉ

- Conditionner réduit l'entropie :

$$H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X}) \text{ avec égalité ssi } \mathbf{X} \text{ et } \mathbf{Y} \text{ sont indépendants}$$

- Incertitude globale plus petite que la somme des incertitudes :

$$H(\mathbf{X}_1, \dots, \mathbf{X}_n) \leq \sum_i H(\mathbf{X}_i) \text{ égalité ssi les } \mathbf{X}_i \text{ sont indépendants}$$

- Inégalité de Hadamard : $|\mathbf{R}| \leq \prod_i R_{i,i}$

• Processus stationnaire : $H(\mathbf{X}) \leq H(\mathbf{X}_1)$, égalité ssi cas iid

- Concavité de H : pour $\lambda_i \geq 0$ tels que $\sum_i \lambda_i = 1$,

$$H\left(\sum_i \lambda_i \mathbf{X}_i\right) \geq \sum_i \lambda_i H(\mathbf{X}_i)$$

CONDITIONNEMENT, MARGINALES, CONCAVITÉ

- Conditionner réduit l'entropie :

$$H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X}) \text{ avec égalité ssi } \mathbf{X} \text{ et } \mathbf{Y} \text{ sont indépendants}$$

- Incertitude globale plus petite que la somme des incertitudes :

$$H(\mathbf{X}_1, \dots, \mathbf{X}_n) \leq \sum_i H(\mathbf{X}_i) \text{ égalité ssi les } \mathbf{X}_i \text{ sont indépendants}$$

- Inégalité de Hadamard : $|\mathbf{R}| \leq \prod_i R_{i,i}$

- Processus stationnaire : $\mathcal{H}(\mathbf{X}) \leq H(\mathbf{X}_1)$, égalité ssi cas iid

- Concavité de H : pour $\lambda_i \geq 0$ tels que $\sum_i \lambda_i = 1$,

$$H\left(\sum_i \lambda_i \mathbf{X}_i\right) \geq \sum_i \lambda_i H(\mathbf{X}_i)$$

CONDITIONNEMENT, MARGINALES, CONCAVITÉ

- Conditionner réduit l'entropie :

$$H(\mathbf{X}|\mathbf{Y}) \leq H(\mathbf{X}) \quad \text{avec égalité ssi } \mathbf{X} \text{ et } \mathbf{Y} \text{ sont indépendants}$$

- Incertitude globale plus petite que la somme des incertitudes :

$$H(\mathbf{X}_1, \dots, \mathbf{X}_n) \leq \sum_i H(\mathbf{X}_i) \quad \text{égalité ssi les } \mathbf{X}_i \text{ sont indépendants}$$

- Inégalité de Hadamard : $|\mathbf{R}| \leq \prod_i R_{i,i}$

- Processus stationnaire : $\mathcal{H}(\mathbf{X}) \leq H(\mathbf{X}_1)$, égalité ssi cas iid

- Concavité de H : pour $\lambda_i \geq 0$ tels que $\sum_i \lambda_i = 1$,

$$H\left(\sum_i \lambda_i \mathbf{X}_i\right) \geq \sum_i \lambda_i H(\mathbf{X}_i)$$

INÉGALITÉS ET CHAÎNES DE MARKOV

Chaîne de Markov $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z}$

si $p(\mathbf{x}, \mathbf{z} | \mathbf{y}) = p(\mathbf{x} | \mathbf{y})p(\mathbf{z} | \mathbf{y}) \Leftrightarrow p(\mathbf{z} | \mathbf{y}, \mathbf{x}) = p(\mathbf{z} | \mathbf{y})$ (relation symétrique)

Processus de Markov : $\mathbf{X}_1 \mapsto \dots \mathbf{X}_n \mapsto \dots$ $p(\mathbf{x}_i | \mathbf{x}_{i-1})$ proba. de transition

- Data Processing Theorem :

$$\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z} \Rightarrow I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{Z})$$

- 2nd loi de la thermodynamique (système isolé, H est croissante)
Soit $\{\mathbf{X}_n\}$ processus de Markov

INÉGALITÉS ET CHAÎNES DE MARKOV

Chaîne de Markov $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z}$

si $p(\mathbf{x}, \mathbf{z} | \mathbf{y}) = p(\mathbf{x} | \mathbf{y})p(\mathbf{z} | \mathbf{y}) \Leftrightarrow p(\mathbf{z} | \mathbf{y}, \mathbf{x}) = p(\mathbf{z} | \mathbf{y})$ (relation symétrique)

Processus de Markov : $\mathbf{X}_1 \mapsto \dots \mathbf{X}_n \mapsto \dots$ $p(\mathbf{x}_i | \mathbf{x}_{i-1})$ proba. de transition

- Data Processing Theorem :

$$\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z} \Rightarrow I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{Z})$$

- 2nd loi de la thermodynamique (système isolé, H est croissante)
Soit $\{\mathbf{X}_n\}$ processus de Markov

INÉGALITÉS ET CHAÎNES DE MARKOV

Chaîne de Markov $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z}$

si $p(\mathbf{x}, \mathbf{z} | \mathbf{y}) = p(\mathbf{x} | \mathbf{y})p(\mathbf{z} | \mathbf{y}) \Leftrightarrow p(\mathbf{z} | \mathbf{y}, \mathbf{x}) = p(\mathbf{z} | \mathbf{y})$ (relation symétrique)

Processus de Markov : $\mathbf{X}_1 \mapsto \dots \mathbf{X}_n \mapsto \dots$ $p(\mathbf{x}_i | \mathbf{x}_{i-1})$ proba. de transition

- Data Processing Theorem :

$$\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z} \Rightarrow I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{Z})$$

Exemple : $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{f}(\mathbf{Y})$ et donc $I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{f}(\mathbf{Y}))$

Transformer des données ne fait que dégrader l'information

- 2nd loi de la thermodynamique (système isolé, H est croissante)
Soit $\{\mathbf{X}_n\}$ processus de Markov

INÉGALITÉS ET CHAÎNES DE MARKOV

Chaîne de Markov $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z}$

si $p(\mathbf{x}, \mathbf{z} | \mathbf{y}) = p(\mathbf{x} | \mathbf{y})p(\mathbf{z} | \mathbf{y}) \Leftrightarrow p(\mathbf{z} | \mathbf{y}, \mathbf{x}) = p(\mathbf{z} | \mathbf{y})$ (relation symétrique)

Processus de Markov : $\mathbf{X}_1 \mapsto \dots \mathbf{X}_n \mapsto \dots$ $p(\mathbf{x}_i | \mathbf{x}_{i-1})$ proba. de transition

- Data Processing Theorem :

$$\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z} \Rightarrow I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{Z})$$

Exemple : $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{f}(\mathbf{Y})$ et donc $I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{f}(\mathbf{Y}))$

Transformer des données ne fait que dégrader l'information

- 2nd loi de la thermodynamique (système isolé, H est croissante)

Soit $\{\mathbf{X}_n\}$ processus de Markov

- p_n et q_n deux densités de probabilités de \mathbf{X}_n (C.I. \neq) :

$$D_{kl}(p_{n+1} || q_{n+1}) \leq D_{kl}(p_n || q_n)$$

- soit p^* densité de probabilité stationnaire :

$$D_{kl}(p_{n+1} || p^*) \leq D_{kl}(p_n || p^*)$$

- si p^* est uniforme sur \mathcal{D} et p_n définie sur le même domaine :

$$H(\mathbf{X}_{n+1}) \geq H(\mathbf{X}_n)$$

INÉGALITÉS ET CHAÎNES DE MARKOV

Chaîne de Markov $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z}$

si $p(\mathbf{x}, \mathbf{z} | \mathbf{y}) = p(\mathbf{x} | \mathbf{y})p(\mathbf{z} | \mathbf{y}) \Leftrightarrow p(\mathbf{z} | \mathbf{y}, \mathbf{x}) = p(\mathbf{z} | \mathbf{y})$ (relation symétrique)

Processus de Markov : $\mathbf{X}_1 \mapsto \dots \mathbf{X}_n \mapsto \dots$ $p(\mathbf{x}_i | \mathbf{x}_{i-1})$ proba. de transition

- Data Processing Theorem :

$$\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z} \Rightarrow I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{Z})$$

Exemple : $\mathbf{X} \mapsto \mathbf{Y} \mapsto f(\mathbf{Y})$ et donc $I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; f(\mathbf{Y}))$

Transformer des données ne fait que dégrader l'information

- 2nd loi de la thermodynamique (système isolé, H est croissante)

Soit $\{\mathbf{X}_n\}$ processus de Markov

- p_n et q_n deux densités de probabilités de \mathbf{X}_n (C.I. \neq) :

$$D_{\text{kl}}(p_{n+1} \| q_{n+1}) \leq D_{\text{kl}}(p_n \| q_n)$$

- soit p^* densité de probabilité stationnaire :

$$D_{\text{kl}}(p_{n+1} \| p^*) \leq D_{\text{kl}}(p_n \| p^*)$$

- si p^* est uniforme sur \mathcal{D} et p_n définie sur le même domaine :

$$H(\mathbf{X}_{n+1}) \geq H(\mathbf{X}_n)$$

INÉGALITÉS ET CHAÎNES DE MARKOV

Chaîne de Markov $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z}$

si $p(\mathbf{x}, \mathbf{z} | \mathbf{y}) = p(\mathbf{x} | \mathbf{y})p(\mathbf{z} | \mathbf{y}) \Leftrightarrow p(\mathbf{z} | \mathbf{y}, \mathbf{x}) = p(\mathbf{z} | \mathbf{y})$ (relation symétrique)

Processus de Markov : $\mathbf{X}_1 \mapsto \dots \mathbf{X}_n \mapsto \dots$ $p(\mathbf{x}_i | \mathbf{x}_{i-1})$ proba. de transition

- Data Processing Theorem :

$$\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z} \Rightarrow I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{Z})$$

Exemple : $\mathbf{X} \mapsto \mathbf{Y} \mapsto f(\mathbf{Y})$ et donc $I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; f(\mathbf{Y}))$

Transformer des données ne fait que dégrader l'information

- 2nd loi de la thermodynamique (système isolé, H est croissante)

Soit $\{\mathbf{X}_n\}$ processus de Markov

- p_n et q_n deux densités de probabilités de \mathbf{X}_n (C.I. \neq) :

$$D_{\text{kl}}(p_{n+1} || q_{n+1}) \leq D_{\text{kl}}(p_n || q_n)$$

- soit p^* densité de probabilité stationnaire :

$$D_{\text{kl}}(p_{n+1} || p^*) \leq D_{\text{kl}}(p_n || p^*)$$

• si p^* est uniforme sur \mathcal{D} et p_n définie sur le même domaine :

$$H(\mathbf{X}_{n+1}) \geq H(\mathbf{X}_n)$$

INÉGALITÉS ET CHAÎNES DE MARKOV

Chaîne de Markov $\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z}$

si $p(\mathbf{x}, \mathbf{z} | \mathbf{y}) = p(\mathbf{x} | \mathbf{y})p(\mathbf{z} | \mathbf{y}) \Leftrightarrow p(\mathbf{z} | \mathbf{y}, \mathbf{x}) = p(\mathbf{z} | \mathbf{y})$ (relation symétrique)

Processus de Markov : $\mathbf{X}_1 \mapsto \dots \mathbf{X}_n \mapsto \dots$ $p(\mathbf{x}_i | \mathbf{x}_{i-1})$ proba. de transition

- Data Processing Theorem :

$$\mathbf{X} \mapsto \mathbf{Y} \mapsto \mathbf{Z} \Rightarrow I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; \mathbf{Z})$$

Exemple : $\mathbf{X} \mapsto \mathbf{Y} \mapsto f(\mathbf{Y})$ et donc $I(\mathbf{X}; \mathbf{Y}) \geq I(\mathbf{X}; f(\mathbf{Y}))$

Transformer des données ne fait que dégrader l'information

- 2nd loi de la thermodynamique (système isolé, H est croissante)

Soit $\{\mathbf{X}_n\}$ processus de Markov

- p_n et q_n deux densités de probabilités de \mathbf{X}_n (C.I. \neq) :

$$D_{\text{kl}}(p_{n+1} \| q_{n+1}) \leq D_{\text{kl}}(p_n \| q_n)$$

- soit p^* densité de probabilité stationnaire :

$$D_{\text{kl}}(p_{n+1} \| p^*) \leq D_{\text{kl}}(p_n \| p^*)$$

- si p^* est uniforme sur \mathcal{D} et p_n définie sur le même domaine :

$$H(\mathbf{X}_{n+1}) \geq H(\mathbf{X}_n)$$

EXERCICE SUR UNE CHAÎNE DE MARKOV

Soit la chaîne de Markov $\{X_n\}$ binaire de matrice de transition

$$P = \begin{pmatrix} p & 1 - q \\ 1 - p & q \end{pmatrix} \text{ (processus homogène car } P \text{ indépendant de } n).$$

P : transition du canal binaire.

- Calculer le(s) vecteur(s) de probabilité stationnaire(s) \mathbf{p}^* . Sous quelle condition y en a-t-il un uniforme ?
- Canal sans erreur, $p = q = 1$: quel est le comportement de $H(X_n)$ et de $D_{\text{kl}}(\mathbf{p}_n \parallel \mathbf{q}_n)$?
- Canal “inverseur”, $p = q = 0$: quel est le comportement de $H(X_n)$, de $D_{\text{kl}}(\mathbf{p}_n \parallel \mathbf{q}_n)$ et de $D_{\text{kl}}(\mathbf{p}_n \parallel \mathbf{p}^*)$? Comment se comporte \mathbf{p}_n ?
- $p \neq 0, 1$ et $q \neq 0, 1$:
 - Montrer que $\mathbf{p}_n \rightarrow \mathbf{p}^*$
 - Soit $p = 0.7$, $q = 0.5$ et $\mathbf{p}_0 = \begin{pmatrix} 0.3 \\ 0.7 \end{pmatrix}$. Calculer $H(X_0)$, $H(X_1)$ et $H(X_2)$ ainsi que $H(X_\infty)$. Conclusion.

INÉGALITÉ DE LA PUISSANCE ENTROPIQUE

- Inégalité de la puissance entropique :
 \mathbf{X}, \mathbf{Y} continus sur \mathbb{R}^d et indépendants,

$$N(\mathbf{X} + \mathbf{Y}) \geq N(\mathbf{X}) + N(\mathbf{Y}) \quad (\text{non triviale})$$

égalité si et seulement si $\mathbf{X}, \mathbf{Y} \sim \mathcal{N}(\cdot, \mathbf{R}_{X,Y})$ avec $\mathbf{R}_Y \propto \mathbf{R}_X$

- Conséquence : inégalité matricielle de Minkovsky ; \mathbf{R}_1 et \mathbf{R}_2 symétriques définies positives, $|\mathbf{R}_1 + \mathbf{R}_2|^{\frac{1}{2}} \geq |\mathbf{R}_1|^{\frac{1}{2}} + |\mathbf{R}_2|^{\frac{1}{2}}$
- Equivalence : \mathbf{X} et \mathbf{Y} continus sur \mathbb{R}^d , indépendants, $\tilde{\mathbf{X}}$ et $\tilde{\mathbf{Y}}$ Gaussiens indépendants de matrices de covariances proportionnelles et tels que $H(\tilde{\mathbf{X}}) = H(\mathbf{X})$ et $H(\tilde{\mathbf{Y}}) = H(\mathbf{Y})$,
$$H(\mathbf{X} + \mathbf{Y}) \geq H(\tilde{\mathbf{X}} + \tilde{\mathbf{Y}})$$
- Inégalité dite de préservation de covariance (équivalente)

$$H(\sqrt{\lambda}\mathbf{X} + \sqrt{1-\lambda}\mathbf{Y}) \geq \lambda H(\mathbf{X}) + (1-\lambda)H(\mathbf{Y})$$

INÉGALITÉ DE LA PUISSANCE ENTROPIQUE

- Inégalité de la puissance entropique :
 \mathbf{X}, \mathbf{Y} continus sur \mathbb{R}^d et indépendants,

$$N(\mathbf{X} + \mathbf{Y}) \geq N(\mathbf{X}) + N(\mathbf{Y}) \quad (\text{non triviale})$$

égalité si et seulement si $\mathbf{X}, \mathbf{Y} \sim \mathcal{N}(\cdot, \mathbf{R}_{X,Y})$ avec $\mathbf{R}_Y \propto \mathbf{R}_X$

- Conséquence : inégalité matricielle de Minkovsky ; \mathbf{R}_1 et \mathbf{R}_2
 symétriques définies positives, $|\mathbf{R}_1 + \mathbf{R}_2|^{\frac{1}{d}} \geq |\mathbf{R}_1|^{\frac{1}{d}} + |\mathbf{R}_2|^{\frac{1}{d}}$

- Equivalence : \mathbf{X} et \mathbf{Y} continus sur \mathbb{R}^d , indépendants, $\tilde{\mathbf{X}}$ et $\tilde{\mathbf{Y}}$ Gaussiens
 indépendants de matrices de covariances proportionnelles et tels que
 $H(\tilde{\mathbf{X}}) = H(\mathbf{X})$ et $H(\tilde{\mathbf{Y}}) = H(\mathbf{Y})$,

$$H(\mathbf{X} + \mathbf{Y}) \geq H(\tilde{\mathbf{X}} + \tilde{\mathbf{Y}})$$

- Inégalité dite de préservation de covariance (équivalente)

$$H(\sqrt{\lambda}\mathbf{X} + \sqrt{1-\lambda}\mathbf{Y}) \geq \lambda H(\mathbf{X}) + (1-\lambda)H(\mathbf{Y})$$

INÉGALITÉ DE LA PUISSANCE ENTROPIQUE

- Inégalité de la puissance entropique :
 \mathbf{X}, \mathbf{Y} continus sur \mathbb{R}^d et indépendants,

$$N(\mathbf{X} + \mathbf{Y}) \geq N(\mathbf{X}) + N(\mathbf{Y}) \quad (\text{non triviale})$$

égalité si et seulement si $\mathbf{X}, \mathbf{Y} \sim \mathcal{N}(\cdot, \mathbf{R}_{X,Y})$ avec $\mathbf{R}_Y \propto \mathbf{R}_X$

- Conséquence : inégalité matricielle de Minkovsky ; \mathbf{R}_1 et \mathbf{R}_2 symétriques définies positives, $|\mathbf{R}_1 + \mathbf{R}_2|^{\frac{1}{d}} \geq |\mathbf{R}_1|^{\frac{1}{d}} + |\mathbf{R}_2|^{\frac{1}{d}}$
- Equivalence : \mathbf{X} et \mathbf{Y} continus sur \mathbb{R}^d , indépendants, $\tilde{\mathbf{X}}$ et $\tilde{\mathbf{Y}}$ Gaussiens indépendants de matrices de covariances proportionnelles et tels que $H(\tilde{\mathbf{X}}) = H(\mathbf{X})$ et $H(\tilde{\mathbf{Y}}) = H(\mathbf{Y})$,

$$H(\mathbf{X} + \mathbf{Y}) \geq H(\tilde{\mathbf{X}} + \tilde{\mathbf{Y}})$$

- Inégalité dite de préservation de covariance (équivalente)

$$H(\sqrt{\lambda}\mathbf{X} + \sqrt{1-\lambda}\mathbf{Y}) \geq \lambda H(\mathbf{X}) + (1-\lambda)H(\mathbf{Y})$$

INÉGALITÉ DE LA PUISSANCE ENTROPIQUE

- Inégalité de la puissance entropique :
 \mathbf{X}, \mathbf{Y} continus sur \mathbb{R}^d et indépendants,

$$N(\mathbf{X} + \mathbf{Y}) \geq N(\mathbf{X}) + N(\mathbf{Y}) \quad (\text{non triviale})$$

égalité si et seulement si $\mathbf{X}, \mathbf{Y} \sim \mathcal{N}(\cdot, \mathbf{R}_{X,Y})$ avec $\mathbf{R}_Y \propto \mathbf{R}_X$

- Conséquence : inégalité matricielle de Minkovsky ; \mathbf{R}_1 et \mathbf{R}_2 symétriques définies positives, $|\mathbf{R}_1 + \mathbf{R}_2|^{\frac{1}{d}} \geq |\mathbf{R}_1|^{\frac{1}{d}} + |\mathbf{R}_2|^{\frac{1}{d}}$
- Equivalence : \mathbf{X} et \mathbf{Y} continus sur \mathbb{R}^d , indépendants, $\tilde{\mathbf{X}}$ et $\tilde{\mathbf{Y}}$ Gaussiens indépendants de matrices de covariances proportionnelles et tels que $H(\tilde{\mathbf{X}}) = H(\mathbf{X})$ et $H(\tilde{\mathbf{Y}}) = H(\mathbf{Y})$,

$$H(\mathbf{X} + \mathbf{Y}) \geq H(\tilde{\mathbf{X}} + \tilde{\mathbf{Y}})$$

- Inégalité dite de préservation de covariance (équivalente)

$$H(\sqrt{\lambda} \mathbf{X} + \sqrt{1-\lambda} \mathbf{Y}) \geq \lambda H(\mathbf{X}) + (1-\lambda)H(\mathbf{Y})$$

INÉGALITÉ DE LA PUISSANCE ENTROPIQUE

- Inégalité de la puissance entropique :
 \mathbf{X}, \mathbf{Y} continus sur \mathbb{R}^d et indépendants,

$$N(\mathbf{X} + \mathbf{Y}) \geq N(\mathbf{X}) + N(\mathbf{Y}) \quad (\text{non triviale})$$

égalité si et seulement si $\mathbf{X}, \mathbf{Y} \sim \mathcal{N}(\cdot, \mathbf{R}_{X,Y})$ avec $\mathbf{R}_Y \propto \mathbf{R}_X$

- Conséquence : inégalité matricielle de Minkovsky ; \mathbf{R}_1 et \mathbf{R}_2 symétriques définies positives, $|\mathbf{R}_1 + \mathbf{R}_2|^{\frac{1}{d}} \geq |\mathbf{R}_1|^{\frac{1}{d}} + |\mathbf{R}_2|^{\frac{1}{d}}$
- Equivalence : \mathbf{X} et \mathbf{Y} continus sur \mathbb{R}^d , indépendants, $\tilde{\mathbf{X}}$ et $\tilde{\mathbf{Y}}$ Gaussiens indépendants de matrices de covariances proportionnelles et tels que $H(\tilde{\mathbf{X}}) = H(\mathbf{X})$ et $H(\tilde{\mathbf{Y}}) = H(\mathbf{Y})$,

$$H(\mathbf{X} + \mathbf{Y}) \geq H(\tilde{\mathbf{X}} + \tilde{\mathbf{Y}})$$

- Inégalité dite de préservation de covariance (équivalente)

$$H(\sqrt{\lambda}\mathbf{X} + \sqrt{1-\lambda}\mathbf{Y}) \geq \lambda H(\mathbf{X}) + (1-\lambda)H(\mathbf{Y})$$

On peut en tirer entre autre des inégalités matricielles...

ESTIMATION : FISHER, VARIANCE ET DIVERGENCE

Soit $\mathbf{X} \sim p_{\theta_0}$ où $p_{\theta_0} \in \{p_{\theta}\}_{\theta}$. On veut estimer θ_0 à partir de \mathbf{X}

$$D(p_{\theta} \parallel p_{\theta_0}) = \frac{1}{2} (\theta - \theta_0)^t J(\theta_0) (\theta - \theta_0) + o(\|\theta - \theta_0\|^2)$$

ESTIMATION : FISHER, VARIANCE ET DIVERGENCE

Soit $\mathbf{X} \sim p_{\theta_0}$ où $p_{\theta_0} \in \{p_{\theta}\}_{\theta}$. On veut estimer θ_0 à partir de \mathbf{X}

$$D(p_{\theta} \parallel p_{\theta_0}) = \frac{1}{2} (\theta - \theta_0)^t \mathbf{J}(\theta_0) (\theta - \theta_0) + o(\|\theta - \theta_0\|^2)$$

Cramér-Rao : estimateur $\hat{\theta}_0$ de θ_0 , non-biaisé et de covariance \mathbf{R}_{θ_0} ,

$$\mathbf{R}_{\theta_0} - \mathbf{J}(\theta_0)^{-1} \geq 0 \quad (\mathbf{R}_{\mathbf{X}} - \mathbf{J}(\mathbf{X})^{-1} \geq 0)$$

Preuve : $\mathbf{J}(\theta_0) = E[\mathbf{S}\mathbf{S}^t]$ avec $\mathbf{S} = \nabla_{\theta} \log p_{\theta_0}$ et $E[\mathbf{S}(\hat{\theta}_0 - \theta_0)^t] = \mathbf{I}$

Cauchy-Schwarz $E[\mathbf{u}^t \mathbf{S}(\hat{\theta}_0 - \theta_0)^t \mathbf{v}] \leq \mathbf{u}^t \mathbf{J}(\theta_0) \mathbf{u} \mathbf{v}^t \mathbf{R}_{\theta_0} \mathbf{v}$ en $\mathbf{u} = \mathbf{J}(\theta_0)^{-1} \mathbf{v}$

ESTIMATION : FISHER, VARIANCE ET DIVERGENCE

Soit $\mathbf{X} \sim p_{\theta_0}$ où $p_{\theta_0} \in \{p_{\theta}\}_{\theta}$. On veut estimer θ_0 à partir de \mathbf{X}

$$D(p_{\theta} \parallel p_{\theta_0}) = \frac{1}{2} (\theta - \theta_0)^t \mathbf{J}(\theta_0) (\theta - \theta_0) + o(\|\theta - \theta_0\|^2)$$

Cramér-Rao : estimateur $\hat{\theta}_0$ de θ_0 , non-biaisé et de covariance \mathbf{R}_{θ_0} ,

$$\mathbf{R}_{\theta_0} - \mathbf{J}(\theta_0)^{-1} \geq 0 \quad (\mathbf{R}_{\mathbf{X}} - \mathbf{J}(\mathbf{X})^{-1} \geq 0)$$


Preuve : $\mathbf{J}(\theta_0) = E[\mathbf{S}\mathbf{S}^t]$ avec $\mathbf{S} = \nabla_{\theta} \log p_{\theta_0}$ et $E[\mathbf{S}(\hat{\theta}_0 - \theta_0)^t] = \mathbf{I}$

Cauchy-Schwarz $E[\mathbf{u}^t \mathbf{S}(\hat{\theta}_0 - \theta_0)^t \mathbf{v}] \leq \mathbf{u}^t \mathbf{J}(\theta_0) \mathbf{u} \mathbf{v}^t \mathbf{R}_{\theta_0} \mathbf{v}$ en $\mathbf{u} = \mathbf{J}(\theta_0)^{-1} \mathbf{v}$

Cas particulier : $R_{ii} \geq (\mathbf{J}^{-1})_{ii}$ (scalaire $\sigma^2 \geq \frac{1}{J}$) et $\text{Tr}(\mathbf{R}) \geq \frac{d^2}{\text{Tr}(\mathbf{J})}$

IDENTITÉ DE DE BRUIJN

Soient \mathbf{X} et \mathbf{G} avec $\mathbf{G} \sim \mathcal{N}(\cdot, \mathbf{I})$ indépendant de \mathbf{X} . On a alors



$$\frac{\partial}{\partial \varepsilon} H(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G}) = \frac{1}{2} J(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G})$$


- Inégalité de la puissance entropique
- Inégalité isopérimétrique entropique

$$J(\mathbf{X})N(\mathbf{X}) \geq d$$

- “Cramér-Rao” sur la somme des variances $\text{Tr}(\mathbf{R}_x) \geq \frac{d}{\text{Tr}(J(\mathbf{X}))}$

IDENTITÉ DE DE BRUIJN

Soient \mathbf{X} et \mathbf{G} avec $\mathbf{G} \sim \mathcal{N}(\cdot, \mathbf{I})$ indépendant de \mathbf{X} . On a alors



$$\frac{\partial}{\partial \varepsilon} H(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G}) = \frac{1}{2} J(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G})$$

Conséquences :

- Inégalité de la puissance entropique


- Inégalité isopérimétrique entropique

$$J(\mathbf{X})N(\mathbf{X}) \geq d$$

- "Cramér-Rao" sur la somme des variances $\text{Tr}(\mathbf{R}_x) \geq \frac{d}{\text{Tr}(J(\mathbf{X}))}$

IDENTITÉ DE DE BRUIJN

Soient \mathbf{X} et \mathbf{G} avec $\mathbf{G} \sim \mathcal{N}(\cdot, \mathbf{I})$ indépendant de \mathbf{X} . On a alors



$$\frac{\partial}{\partial \varepsilon} H(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G}) = \frac{1}{2} J(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G})$$

Conséquences :


- Inégalité de la puissance entropique
- Inégalité isopérimétrique entropique

$$J(\mathbf{X})N(\mathbf{X}) \geq d$$

- “Cramér-Rao” sur la somme des variances $\text{Tr}(\mathbf{R}_x) \geq \frac{d}{\text{Tr}(J(\mathbf{X}))}$

IDENTITÉ DE DE BRUIJN

Soient \mathbf{X} et \mathbf{G} avec $\mathbf{G} \sim \mathcal{N}(\cdot, \mathbf{I})$ indépendant de \mathbf{X} . On a alors



$$\frac{\partial}{\partial \varepsilon} H(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G}) = \frac{1}{2} J(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G})$$

Conséquences :


- Inégalité de la puissance entropique
- Inégalité isopérimétrique entropique

$$J(\mathbf{X})N(\mathbf{X}) \geq d$$

- “Cramér-Rao” sur la somme des variances $\text{Tr}(\mathbf{R}_X) \geq \frac{d^2}{\text{Tr}(\mathbf{J}(\mathbf{X}))}$

IDENTITÉ DE DE BRUIJN

Soient \mathbf{X} et \mathbf{G} avec $\mathbf{G} \sim \mathcal{N}(\cdot, \mathbf{I})$ indépendant de \mathbf{X} . On a alors



$$\frac{\partial}{\partial \varepsilon} H(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G}) = \frac{1}{2} J(\mathbf{X} + \sqrt{\varepsilon} \mathbf{G})$$

Conséquences :

- Inégalité de la puissance entropique
- Inégalité isopérimétrique entropique

$$J(\mathbf{X})N(\mathbf{X}) \geq d$$

- “Cramér-Rao” sur la somme des variances $\text{Tr}(\mathbf{R}_X) \geq \frac{d^2}{\text{Tr}(J(\mathbf{X}))}$

$$\text{Verdú'05 : } \frac{\partial}{\partial \varepsilon} I(\mathbf{X}; \sqrt{\varepsilon} \mathbf{X} + \mathbf{G}) = \frac{1}{2} E \left[\left(\mathbf{X} - \left[\mathbf{X} \middle| \sqrt{\varepsilon} \mathbf{X} + \mathbf{G} \right] \right)^2 \right]$$

PLAN DU COURS

1 ENTROPIE – MESURE D'INCERTITUDE

- Axiomes, entropie de Shannon et ses propriétés
- Entropie différentielle – cas vectoriel
- D'autres mesures d'information

2 INFORMATION MUTUELLE - DIVERGENCES

- Entropie conditionnelle, Information mutuelle
- Quelques exemples
- Divergences

3 INÉGALITÉS – RELATIONS ENTROPIQUES

- Inégalités “classiques”
- Chaînes de Markov
- Inégalité de la puissance entropique
- Estimation – relations entre informations

4 RELATIONS D'INCERTITUDE

- Relation d'incertitude d'Heisenberg et versions entropiques

PRINCIPE D’INCERTITUDE D’HEISENBERG

Fonction d’onde $\Psi_d(\mathbf{x})$, $\mathbf{x} \in \mathbb{R}^d$

i.e. $p = |\Psi_d|^2$ est la densité de probabilité d’un vecteur aléatoire \mathbf{X}

Transformation de Fourier $\widehat{\Psi}_d(\mathbf{x}) = (2\pi)^{-\frac{d}{2}} \int_{\mathbb{R}^d} \Psi_d(\mathbf{u}) e^{-i\mathbf{u}^t \mathbf{x}} d\mathbf{u}$

i.e. $\bar{p} = |\widehat{\Psi}_d|^2$ densité de probabilité du vecteur aléatoire “conjugué” $\bar{\mathbf{X}}$

PRINCIPE D'INCERTITUDE D'HEISENBERG

Fonction d'onde $\Psi_d(\mathbf{x})$, $\mathbf{x} \in \mathbb{R}^d$

i.e. $p = |\Psi_d|^2$ est la densité de probabilité d'un vecteur aléatoire \mathbf{X}

Transformation de Fourier $\widehat{\Psi}_d(\mathbf{x}) = (2\pi)^{-\frac{d}{2}} \int_{\mathbb{R}^d} \Psi_d(\mathbf{u}) e^{-i\mathbf{u}^t \mathbf{x}} d\mathbf{u}$

i.e. $\bar{p} = |\widehat{\Psi}_d|^2$ densité de probabilité du vecteur aléatoire "conjugué" $\bar{\mathbf{X}}$

Principe d'incertitude d'Heisenberg :

$$4R_{\mathbf{X}} - R_{\bar{\mathbf{X}}} \geq 0$$

$$\left(\frac{E[\mathbf{X}^t \mathbf{X}]}{d} - \frac{E[\bar{\mathbf{X}}^t \bar{\mathbf{X}}]}{d} \right)^{\frac{1}{2}} \geq \frac{1}{2}$$

égalité ssi $\mathbf{X} \sim \mathcal{N}$

PRINCIPE D'INCERTITUDE D'HEISENBERG

Fonction d'onde $\Psi_d(\mathbf{x})$, $\mathbf{x} \in \mathbb{R}^d$

i.e. $p = |\Psi_d|^2$ est la densité de probabilité d'un vecteur aléatoire \mathbf{X}

Transformation de Fourier $\widehat{\Psi}_d(\mathbf{x}) = (2\pi)^{-\frac{d}{2}} \int_{\mathbb{R}^d} \Psi_d(\mathbf{u}) e^{-i\mathbf{u}^t \mathbf{x}} d\mathbf{u}$

i.e. $\bar{p} = |\widehat{\Psi}_d|^2$ densité de probabilité du vecteur aléatoire "conjugué" $\bar{\mathbf{X}}$

Principe d'incertitude d'Heisenberg :

$$4R_{\mathbf{X}} - R_{\bar{\mathbf{X}}} \geq 0$$

$$\left(\frac{E[\mathbf{X}^t \mathbf{X}]}{d} - \frac{E[\bar{\mathbf{X}}^t \bar{\mathbf{X}}]}{d} \right)^{\frac{1}{2}} \geq \frac{1}{2} \quad \text{égalité ssi } \mathbf{X} \sim \mathcal{N}$$

Ces relations ont un sens si les covariances existent :

Quid *e.g.* du cas Cauchy $p(\mathbf{x}) = \frac{\Gamma(\frac{d+1}{2})}{\pi^{\frac{d+1}{2}} |\Sigma|^{\frac{1}{2}} (1 + \mathbf{x}^t \Sigma^{-1} \mathbf{x})^{\frac{d+1}{2}}}$?

VERSION ENTROPIQUE (BIALYNICKI-BIRULA & MYCIELSKI, COM. IN MATH. PHYS. '75)

$$\frac{H(\mathbf{X}) + H(\tilde{\mathbf{X}})}{d} \geq 1 + \log \pi$$

VERSION ENTROPIQUE (BIALYNICKI-BIRULA & MYCIELSKI, COM. IN MATH. PHYS. '75)

$$\frac{H(\mathbf{X}) + H(\bar{\mathbf{X}})}{d} \geq 1 + \log \pi$$

Babenko'61 : $\|\hat{\Psi}\|_{2\alpha^*} \leq (C_{\alpha,\alpha^*}) \|\Psi\|_{2\alpha}$

$$C_{\alpha,\alpha^*} = \left(\frac{\pi}{\alpha^*}\right)^{\frac{1}{4\alpha^*}} \left(\frac{\pi}{\alpha}\right)^{-\frac{1}{4\alpha}} \text{ avec } \alpha \in \left[\frac{1}{2}; 1\right] \text{ et } \frac{1}{2\alpha} + \frac{1}{2\alpha^*} = 1$$

VERSION ENTROPIQUE (BIALYNICKI-BIRULA & MYCIELSKI, COM. IN MATH. PHYS. '75)

$$\frac{H(\mathbf{X}) + H(\bar{\mathbf{X}})}{d} \geq 1 + \log \pi$$

Beckner'75 : $\|\widehat{\Psi}_d\|_{2\alpha^*} \leq (C_{\alpha, \alpha^*})^d \|\Psi_d\|_{2\alpha}$

$$C_{\alpha, \alpha^*} = \left(\frac{\pi}{\alpha^*}\right)^{\frac{1}{4\alpha^*}} \left(\frac{\pi}{\alpha}\right)^{-\frac{1}{4\alpha}} \text{ avec } \alpha \in \left[\frac{1}{2}; 1\right] \text{ et } \frac{1}{2\alpha} + \frac{1}{2\alpha^*} = 1$$

VERSION ENTROPIQUE (BIALYNICKI-BIRULA & MYCIELSKI, COM. IN MATH. PHYS. '75)


$$\frac{H(\mathbf{X}) + H(\bar{\mathbf{X}})}{d} \geq 1 + \log \pi$$

Beckner'75 : $\|\widehat{\Psi}_d\|_{2\alpha^*} \leq (C_{\alpha, \alpha^*})^d \|\Psi_d\|_{2\alpha}$

$$C_{\alpha, \alpha^*} = \left(\frac{\pi}{\alpha^*}\right)^{\frac{1}{4\alpha^*}} \left(\frac{\pi}{\alpha}\right)^{-\frac{1}{4\alpha}} \text{ avec } \alpha \in \left[\frac{1}{2}; 1\right] \text{ et } \frac{1}{2\alpha} + \frac{1}{2\alpha^*} = 1$$

$$W(\alpha^*) = (C_{\alpha, \alpha^*})^d \|\Psi_d\|_{2\alpha} - \|\widehat{\Psi}_d\|_{2\alpha^*} \geq 0 \text{ avec égalité pour } \alpha^* = 1 \text{ (Parseval)}$$

$$\Rightarrow \left. \frac{dW}{d\beta} \right|_{\alpha^*=1+} \geq 0$$



VERSION ENTROPIQUE (BIALYNICKI-BIRULA & MYCIELSKI, COM. IN MATH. PHYS. '75)


$$\frac{H(\mathbf{X}) + H(\bar{\mathbf{X}})}{d} \geq 1 + \log \pi$$

Beckner'75 : $\|\widehat{\Psi}_d\|_{2\alpha^*} \leq (C_{\alpha, \alpha^*})^d \|\Psi_d\|_{2\alpha}$

$$C_{\alpha, \alpha^*} = \left(\frac{\pi}{\alpha^*}\right)^{\frac{1}{4\alpha^*}} \left(\frac{\pi}{\alpha}\right)^{-\frac{1}{4\alpha}} \text{ avec } \alpha \in \left[\frac{1}{2}; 1\right] \text{ et } \frac{1}{2\alpha} + \frac{1}{2\alpha^*} = 1$$

$$W(\alpha^*) = (C_{\alpha, \alpha^*})^d \|\Psi_d\|_{2\alpha} - \|\widehat{\Psi}_d\|_{2\alpha^*} \geq 0 \text{ avec égalité pour } \alpha^* = 1 \text{ (Parseval)}$$

$$\Rightarrow \left. \frac{dW}{d\beta} \right|_{\alpha^*=1+} \geq 0$$



- Insensible aux facteurs d'échelle $H(\mathbf{A}\mathbf{X}) + H(\overline{\mathbf{A}\mathbf{X}}) = H(\mathbf{X}) + H(\bar{\mathbf{X}})$
- Implique Heisenberg : $(N(\mathbf{X})N(\bar{\mathbf{X}}))^{\frac{1}{2}} \geq \frac{1}{2}$
- Egalité ssi \mathbf{X} est Gaussien, minimisante de $N(\mathbf{X})N(\bar{\mathbf{X}})$

GÉNÉRALISATION À RÉNYI

Directement de la relation de Beckner, via $H_\alpha(\mathbf{X}) = \frac{1}{1-\alpha} \log \|\psi_d\|_{2\alpha}^{2\alpha}$:

$$\frac{H_\alpha(\mathbf{X}) + H_{\alpha^*}(\bar{\mathbf{X}})}{d} \geq \log \pi + \frac{\log \alpha}{2(\alpha - 1)} + \frac{\log \alpha^*}{2(\alpha^* - 1)} = B(\alpha)$$

- Valable pour $\alpha \geq \frac{1}{2}$ par involution $\bar{\bar{\mathbf{X}}} \stackrel{d}{=} \mathbf{X}$
- Insensible aux facteurs d'échelle (matriciel inversible)
- $\alpha \rightarrow 1$ Białynicki-Birula & Mycielski est retrouvé
- égalité si et seulement si \mathbf{X} est Gaussien
- Décroissance de H_λ versus λ :

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \begin{cases} 2\pi & \text{si } (\alpha, \beta) \in [0; 1/2]^2 \\ B(\max(\alpha, \beta)) & \text{sinon et } \beta \leq \alpha^* \\ \text{pas de rel. incert.} & \text{sinon} \end{cases}$$

GÉNÉRALISATION À RÉNYI

Directement de la relation de Beckner, via $H_\alpha(\mathbf{X}) = \frac{1}{1-\alpha} \log \|\psi_d\|_{2\alpha}^{2\alpha}$:

$$\frac{H_\alpha(\mathbf{X}) + H_{\alpha^*}(\bar{\mathbf{X}})}{d} \geq \log \pi + \frac{\log \alpha}{2(\alpha - 1)} + \frac{\log \alpha^*}{2(\alpha^* - 1)} = B(\alpha)$$

- Valable pour $\alpha \geq \frac{1}{2}$ par involution $\bar{\bar{\mathbf{X}}} \stackrel{d}{=} \mathbf{X}$
- Insensible aux facteurs d'échelle (matriciel inversible)
- $\alpha \rightarrow 1$ Bialynicki-Birula & Mycielski est retrouvé
- égalité si et seulement si \mathbf{X} est Gaussien

• Décroissance de H_λ versus λ :

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \begin{cases} 2\pi & \text{si } (\alpha, \beta) \in [0; 1/2]^2 \\ B(\max\{\alpha, \beta\}) & \text{sinon et } \beta \leq \alpha^* \\ \text{pas de rel. incert.} & \text{sinon} \end{cases}$$

GÉNÉRALISATION À RÉNYI

Directement de la relation de Beckner, via $H_\alpha(\mathbf{X}) = \frac{1}{1-\alpha} \log \|\psi_d\|_{2\alpha}^{2\alpha}$:

$$\frac{H_\alpha(\mathbf{X}) + H_{\alpha^*}(\bar{\mathbf{X}})}{d} \geq \log \pi + \frac{\log \alpha}{2(\alpha - 1)} + \frac{\log \alpha^*}{2(\alpha^* - 1)} = B(\alpha)$$

- Valable pour $\alpha \geq \frac{1}{2}$ par involution $\bar{\bar{\mathbf{X}}} \stackrel{d}{=} \mathbf{X}$
- Insensible aux facteurs d'échelle (matriciel inversible)
- $\alpha \rightarrow 1$ Bialynicki-Birula & Mycielski est retrouvé
- égalité si et seulement si \mathbf{X} est Gaussien
- Décroissance de H_λ versus λ :

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \begin{cases} 2\pi & \text{si } (\alpha, \beta) \in [0; 1/2]^2 \\ B(\max(\alpha, \beta)) & \text{sinon et } \beta \leq \alpha^* \\ \text{pas de rel. incert.} & \text{sinon} \end{cases}$$

CAS DISCRET – CAS PÉRIODIQUE

Ψ_d défini sur $\mathcal{A} = \{0, \dots, n-1\}^d$, \mathbf{X} vecteur aléatoire associé

• TF "réduite" : $\hat{\Psi}_d^{(\alpha)}(\mathbf{x}) = (2\pi)^{-d} \sum_{\mathbf{u} \in \mathcal{A}} \Psi_d(\mathbf{u}) e^{-i\mathbf{u}^t \mathbf{x}} \quad \mathbf{x} \in [0; 2\pi)^d$

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \log(2\pi) \quad \text{pour } \beta \leq \alpha^*, \text{ égalité ssi } \mathbf{X} \text{ est déterministe}$$

• TF "discrète" : $\hat{\Psi}_d^{(d)}(\mathbf{k}) = n^{-d/2} \sum_{\mathbf{u} \in \mathcal{A}} \Psi_d(\mathbf{u}) e^{-\frac{2i\pi}{n} \mathbf{u}^t \mathbf{k}} \quad \mathbf{k} \in \mathcal{A}^d$

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \log n \quad \text{pour } \beta \leq \alpha^*, \text{ égalité ssi } \mathbf{X} \text{ est déterministe}$$

CAS DISCRET – CAS PÉRIODIQUE

Ψ_d défini sur $\mathcal{A} = \{0, \dots, n-1\}^d$, \mathbf{X} vecteur aléatoire associé

- TF “réduite” : $\widehat{\Psi}_d^{(r)}(\mathbf{x}) = (2\pi)^{-\frac{d}{2}} \sum_{\mathbf{u} \in \mathcal{A}} \Psi_d(\mathbf{u}) e^{-i\mathbf{u}^t \mathbf{x}} \quad \mathbf{x} \in [0; 2\pi)^d$

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \log(2\pi) \quad \text{pour } \beta \leq \alpha^*, \text{ égalité ssi } \mathbf{X} \text{ est déterministe}$$

- TF “discrète” : $\widehat{\Psi}_d^{(d)}(\mathbf{k}) = n^{-\frac{d}{2}} \sum_{\mathbf{u} \in \mathcal{A}} \Psi_d(\mathbf{u}) e^{-\frac{2\pi i}{n} \mathbf{u}^t \mathbf{k}} \quad \mathbf{k} \in \mathcal{A}^d$

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \log n \quad \text{pour } \beta \leq \alpha^*, \text{ égalité ssi } \mathbf{X} \text{ est déterministe}$$

CAS DISCRET – CAS PÉRIODIQUE

Ψ_d défini sur $\mathcal{A} = \{0, \dots, n-1\}^d$, \mathbf{X} vecteur aléatoire associé

- TF “réduite” : $\widehat{\Psi}_d^{(r)}(\mathbf{x}) = (2\pi)^{-\frac{d}{2}} \sum_{\mathbf{u} \in \mathcal{A}} \Psi_d(\mathbf{u}) e^{-i\mathbf{u}^t \mathbf{x}} \quad \mathbf{x} \in [0; 2\pi)^d$

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \log(2\pi) \quad \text{pour } \beta \leq \alpha^*, \text{ égalité ssi } \mathbf{X} \text{ est déterministe}$$

- TF “discrète” : $\widehat{\Psi}_d^{(d)}(\mathbf{k}) = n^{-\frac{d}{2}} \sum_{\mathbf{u} \in \mathcal{A}} \Psi_d(\mathbf{u}) e^{-\frac{2i\pi}{n} \mathbf{u}^t \mathbf{k}} \quad \mathbf{k} \in \mathcal{A}^d$

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \log n \quad \text{pour } \beta \leq \alpha^*, \text{ égalité ssi } \mathbf{X} \text{ est déterministe}$$

CAS DISCRET – CAS PÉRIODIQUE

Ψ_d défini sur $\mathcal{A} = \{0, \dots, n-1\}^d$, \mathbf{X} vecteur aléatoire associé

- TF “réduite” : $\widehat{\Psi}_d^{(r)}(\mathbf{x}) = (2\pi)^{-\frac{d}{2}} \sum_{\mathbf{u} \in \mathcal{A}} \Psi_d(\mathbf{u}) e^{-i\mathbf{u}^t \mathbf{x}} \quad \mathbf{x} \in [0; 2\pi)^d$

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \log(2\pi) \quad \text{pour } \beta \leq \alpha^*, \text{ égalité ssi } \mathbf{X} \text{ est déterministe}$$





- TF “discrète” : $\widehat{\Psi}_d^{(d)}(\mathbf{k}) = n^{-\frac{d}{2}} \sum_{\mathbf{u} \in \mathcal{A}} \Psi_d(\mathbf{u}) e^{-\frac{2i\pi}{n} \mathbf{u}^t \mathbf{k}} \quad \mathbf{k} \in \mathcal{A}^d$

$$\frac{H_\alpha(\mathbf{X}) + H_\beta(\bar{\mathbf{X}})}{d} \geq \log n \quad \text{pour } \beta \leq \alpha^*, \text{ égalité ssi } \mathbf{X} \text{ est déterministe}$$

Basés sur l'inégalité de Young-Hausdorff $\|\widehat{\Psi}\|_{2\alpha^*} \leq \left(C^{\frac{1}{4\alpha^*} - \frac{1}{4\alpha}}\right)^d \|\Psi\|_{2\alpha}$

avec $\alpha \in [\frac{1}{2}; 1]$ et $C = 2\pi$ (TFR) ou n (TFD)

QUELQUES RÉFÉRENCES

-  T. M. Cover and J. A. Thomas.
Elements of Information Theory.
John Wiley & Sons, New-York, 1991.
-  A. Dembo, T. M. Cover, and J. A. Thomas.
Information theoretic inequalities.
IEEE Transactions on Information Theory, 37(6):1501–1518,
November 1991.
-  A. Rényi.
On measures of entropy and information.
in Proceeding of the 4th Berkeley Symposium on Mathematical
Statistics and Probability, 1:547–561, 1961.
-  C. E. Shannon.
A mathematical theory of communication.
The Bell System Technical Journal, 27:623–656, October 1948.