

# Théorie de l'information

## Cours 5 - Entropies conjointe et conditionnelles, information mutuelle

Laurent Oudre  
laurent.oudre@univ-paris13.fr

Université Paris 13, Institut Galilée  
Master Ingénierie et Innovations en Images et Réseaux - 1<sup>ère</sup> année  
2017-2018

## Sommaire

Entropie conjointe  
Définition  
Propriétés

Entropies conditionnelles

Information mutuelle

## Sommaire

Entropie conjointe  
Définition  
Propriétés

Entropies conditionnelles  
Définition  
Propriétés  
Bilan

Information mutuelle  
Définition  
Propriétés

## Passage à deux variables aléatoires

- ▶ On a vu que l'entropie mesurait l'information moyenne apportée par une source (ou de façon équivalente par une variable aléatoire)
- ▶ Nous allons dans ce cours estimer l'information moyenne apportée par un système de deux variables aléatoires
- ▶ Cela va nous servir à étudier deux sources, mais surtout à étudier les liens entre l'entrée et la sortie d'un canal de communication.

# Entropie conjointe

## Entropie conjointe

Étant données deux variables aléatoires  $X$  et  $Y$  à valeurs respectivement dans  $\mathcal{X}$  et  $\mathcal{Y}$ , on définit l'**entropie conjointe** des variables aléatoires  $X$  et  $Y$  et on note  $H(X, Y)$  la quantité :

$$H(X, Y) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{XY}(X = x, Y = y) \log_2(P_{XY}(X = x, Y = y))$$

## Démonstration propriété 3 : $H(X, Y) \leq H(X) + H(Y)$

► Notons :

- $p_{XY}(x, y) = P_{XY}(X = x, Y = y)$
- $q_{XY}(x, y) = P_X(X = x)P_Y(Y = y)$

► Ce sont bien toutes les deux des lois de probabilités car :

$$\sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} q_{XY}(x, y) = \sum_{x \in \mathcal{X}} P_X(X = x) \sum_{y \in \mathcal{Y}} P_Y(Y = y) = 1$$

► Nous allons comparer  $p_{XY}(x, y)$  et  $q_{XY}(x, y)$  grâce à l'entropie relative.

# Propriétés

►  $H(X, Y)$  correspond à l'information apportée par le système  $(X, Y)$

► On a les propriétés :

1.  $H(X, Y) = H(Y, X)$
2.  $H(X, Y) \geq 0$
3.  $H(X, Y) \leq H(X) + H(Y)$   
avec égalité si et seulement si  $X$  et  $Y$  sont indépendantes
4.  $H(X, Y) \geq H(X)$

► 1 et 2 sont triviales : dans la suite, démonstration de 3 et 4

## Démonstration propriété 3 : $H(X, Y) \leq H(X) + H(Y)$

On a d'après la propriété démontrée au cours précédent :

$$\begin{aligned} D_{KL}(p||q) \geq 0 &\iff \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{XY}(x, y) \log_2 \left( \frac{p_{XY}(x, y)}{q_{XY}(x, y)} \right) \geq 0 \\ &\iff \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{XY}(X = x, Y = y) \log_2 \left( \frac{P_{XY}(X = x, Y = y)}{P_X(X = x)P_Y(Y = y)} \right) \geq 0 \\ &\iff \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{XY}(X = x, Y = y) \log_2(P_{XY}(X = x, Y = y)) \\ &\quad - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{XY}(X = x, Y = y) \log_2(P_X(X = x)P_Y(Y = y)) \geq 0 \\ &\iff -H(X, Y) - \sum_{x \in \mathcal{X}} \log_2(P_X(X = x)) \sum_{y \in \mathcal{Y}} P_{XY}(X = x, Y = y) \\ &\quad - \sum_{y \in \mathcal{Y}} \log_2(P_Y(Y = y)) \sum_{x \in \mathcal{X}} P_{XY}(X = x, Y = y) \geq 0 \\ &\iff H(X, Y) \leq H(X) + H(Y) \end{aligned}$$

Interprétation propriété 3 :  $H(X, Y) \leq H(X) + H(Y)$ 

- ▶ On a une égalité ssi  $p_{XY}(x, y) = q_{XY}(x, y)$ , donc ssi  $P_{XY}(X = x, Y = y) = P_X(X = x)P_Y(Y = y) \iff X$  et  $Y$  sont indépendantes
- ▶ Cette propriété nous dit que, si l'on considère deux sources  $X$  et  $Y$  ensemble, elles ne peuvent pas apporter plus d'information que la somme des apports d'information de chacune

Démonstration propriété 4 :  $H(X, Y) \geq H(X)$ 

$$\begin{aligned}
 H(X, Y) &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{XY}(X = x, Y = y) \log_2(P_{XY}(X = x, Y = y)) \\
 &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{Y|X=x}(Y = y|X = x)P_X(X = x) \log_2(P_{Y|X=x}(Y = y|X = x)P_X(X = x)) \\
 &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{Y|X=x}(Y = y|X = x)P_X(X = x) \log_2(P_{Y|X=x}(Y = y|X = x)) \\
 &\quad - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{Y|X=x}(Y = y|X = x)P_X(X = x) \log_2(P_X(X = x))
 \end{aligned}$$

Or  $P_{Y|X=x}(Y = y|X = x) \leq 1$  donc le premier terme est  $\geq 0$

$$\begin{aligned}
 H(X, Y) &\geq - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{Y|X=x}(Y = y|X = x)P_X(X = x) \log_2(P_X(X = x)) \\
 &\geq - \sum_{x \in \mathcal{X}} P_X(X = x) \log_2(P_X(X = x)) \sum_{y \in \mathcal{Y}} P_{Y|X=x}(Y = y|X = x) \\
 &\geq - \sum_{x \in \mathcal{X}} P_X(X = x) \log_2(P_X(X = x)) = H(X)
 \end{aligned}$$

Interprétation propriété 3 :  $H(X, Y) \leq H(X) + H(Y)$ 

## Prévisions météo

$X$  source qui nous dit s'il fera *soleil* ou *pluie*

$Y$  source qui nous dit s'il fera *chaud* ou *froid*

$X, Y$	$Y = \text{chaud}$	$Y = \text{froid}$
$X = \text{soleil}$	0.3	0.2
$X = \text{pluie}$	0.1	0.4

$H(X, Y) = 1.8464$  bits,  $H(X) = 1$  bit,  $H(Y) = 0.9710$  bits

$$H(X, Y) < H(X) + H(Y)$$

Individuellement les sources nous donnent beaucoup d'information, mais ensemble on a finalement moins d'information que la somme des deux informations car il existe un lien entre elles.

Interprétation propriété 4 :  $H(X, Y) \geq H(X)$ 

- ▶ On pourrait démontrer de la même manière que  $H(X, Y) \geq H(Y)$
- ▶ Cette propriété nous dit que deux sources donnent forcément plus d'information qu'une seule source, ce qui est conforme à notre intuition
- ▶ On a une égalité si les deux sources contiennent exactement la même information

## Sommaire

Entropie conjointe

Entropies conditionnelles

Définition  
Propriétés  
Bilan

Information mutuelle

## Entropie conditionnelle

## Entropie conditionnelle

Étant données deux variables aléatoires  $X$  et  $Y$  à valeurs respectivement dans  $\mathcal{X}$  et  $\mathcal{Y}$ , on définit l'**entropie conditionnelle** de  $Y$  sachant  $X$  et on note  $H(Y|X)$  la quantité :

$$H(Y|X) = - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{XY}(X = x, Y = y) \log_2 (P_{Y|X=x}(Y = y|X = x))$$

## Liens entre variables aléatoires

- ▶ On a vu que ce n'était pas parce qu'on considérait deux sources qu'on obtenait beaucoup plus d'information
- ▶ On a en effet :

$$H(X) \leq H(X, Y) \leq H(X) + H(Y)$$

- ▶ Qu'est-ce qui explique les variations de  $H(X, Y)$  entre ces deux bornes ?
- ▶ Les liens éventuels entre les variables : il arrive parfois que connaissant  $Y$ , la source  $X$  donne moins d'information, tout simplement parce que  $Y$  nous a déjà transmis une partie de l'information contenue dans  $X$
- ▶ Pour étudier ceci, on va introduire la notion d'entropie conditionnelle

## Propriétés

- ▶  $H(Y|X)$  correspond à l'incertitude restante sur  $Y$  lorsqu'on connaît  $X$ .
- ▶ Si on appelle  $X$  et  $Y$  respectivement l'entrée et la sortie d'un canal de communication,  $H(X|Y)$  représente l'incertitude restant sur le symbole émis une fois qu'on l'a reçu
- ▶ On a les propriétés suivantes :
  1.  $H(Y|X) \geq 0$
  2.  $H(X, Y) = H(X) + H(Y|X) = H(Y) + H(X|Y)$
  3.  $H(X) \geq H(X|Y)$
  4.  $H(X|X) = 0$
- ▶ 1 est triviale : dans la suite, démonstration des autres

Démonstration propriété 2 :  $H(X, Y) = H(X) + H(Y|X)$ 

$$\begin{aligned}
H(X, Y) &= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{XY}(x, y) \log_2(p_{XY}(x, y)) \\
&= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{XY}(x, y) \log_2(p_{Y|X}(y|x)p_X(x)) \\
&= - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{XY}(x, y) \log_2(p_{Y|X}(y|x)) - \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} p_{XY}(x, y) \log_2(p_X(x)) \\
&= H(Y|X) - \sum_{x \in \mathcal{X}} \log_2(p_X(x)) \sum_{y \in \mathcal{Y}} p_{XY}(x, y) \\
&= H(Y|X) + H(X)
\end{aligned}$$

Interprétation propriété 2 :  $H(X, Y) = H(X) + H(Y|X)$ Interprétation propriété 2 :  $H(X, Y) = H(X) + H(Y|X)$ 

- ▶ On démontrerait de la même façon que  $H(X, Y) = H(X|Y) + H(Y)$
- ▶ Considérons deux sources  $X$  et  $Y$  : cette propriété nous dit que l'information fournie par les deux sources est la somme de l'information fournie par l'une des sources et de l'incertitude restante sur l'autre source

Démonstration propriété 3 :  $H(X|Y) \leq H(X)$ 

## Prévisions météo

$X$  source qui nous dit s'il fera *soleil* ou *pluie*  
 $Y$  source qui nous dit s'il fera *chaud* ou *froid*

$X, Y$	$Y = \text{chaud}$	$Y = \text{froid}$	$Y X$	$Y = \text{chaud}$	$Y = \text{froid}$
$X = \text{soleil}$	0.3	0.2	$X = \text{soleil}$	0.6	0.4
$X = \text{pluie}$	0.1	0.4	$X = \text{pluie}$	0.2	0.8

$H(X, Y) = 1.8464$  bits,  $X(X) = 1$  bit,  $H(Y|X) = 0.8464$  bits et  $H(Y) = 0.9710$  bits

$$\underbrace{H(X, Y)}_{\text{information fournie par les deux sources}} = \underbrace{H(X)}_{\text{information fournie par } X} + \underbrace{H(Y|X)}_{\text{incertitude restante sur } Y}$$

On vérifie ici que si l'on connaît déjà  $X$ ,  $Y$  donne moins d'information que si on avait aucune information a priori

- ▶ On a démontré tout à l'heure que  $H(X, Y) \leq H(X) + H(Y)$
- ▶ Comme on a également  $H(X, Y) = H(X|Y) + H(Y)$ , on a naturellement

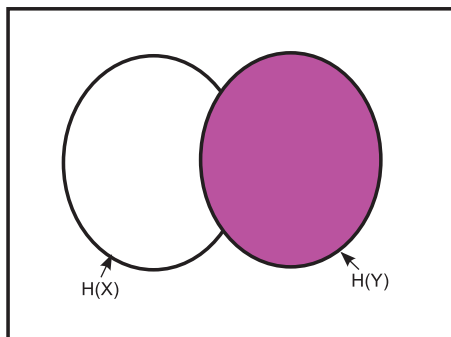
$$H(X|Y) \leq H(X)$$

- ▶ Cela signifie qu'une connaissance a priori ne peut que diminuer l'incertitude que l'on a, ce qui est conforme à notre intuition

## Démonstration propriété 4 : $H(X|X) = 0$

- ▶ On a  $p_{X|X}(x|x) = \frac{p_{XX}(x,x)}{p_X(x)} = 1$
- ▶ Il arrive naturellement que  $H(X|X) = 0$
- ▶ Ceci est logique, car si on connaît déjà  $X$ , il ne reste plus aucune incertitude sur  $X$  !


## Bilan



$H(Y)$  : Entropie de  $Y$

- ▶ Information moyenne fournie par  $Y$
- ▶ Incertitude sur la variable aléatoire  $Y$


## Bilan



$H(X)$  : Entropie de  $X$

- ▶ Information moyenne fournie par  $X$
- ▶ Incertitude sur la variable aléatoire  $X$


## Bilan



$H(X, Y)$  : Entropie conjointe de  $X$  et  $Y$

- ▶ Information moyenne fournie par le système  $(X, Y)$
- ▶ Attention, non égale a priori à la somme de  $H(X)$  et  $H(Y)$

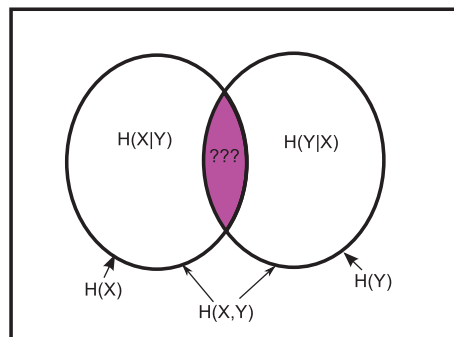
## Bilan



$H(X|Y)$  : Entropie conditionnelle de  $X$  sachant  $Y$

- ▶ Incertitude restante sur  $X$  si l'on connaît  $Y$
- ▶ Information manquante sur  $X$  malgré la connaissance de  $Y$


## Bilan



Il reste une quantité à considérer :

- ▶ Elle représente l'information contenue à la fois dans  $X$  et dans  $Y$
- ▶ On l'appellera **information mutuelle** (ou transinformation)

## Bilan



$H(Y|X)$  : Entropie conditionnelle de  $Y$  sachant  $X$

- ▶ Incertitude restante sur  $Y$  si l'on connaît  $X$
- ▶ Information manquante sur  $Y$  malgré la connaissance de  $X$

## Sommaire

Entropie conjointe

Entropies conditionnelles

Information mutuelle

Définition

Propriétés

## Information mutuelle

### Information mutuelle

Étant données deux variables aléatoires  $X$  et  $Y$  à valeurs respectivement dans  $\mathcal{X}$  et  $\mathcal{Y}$ , on définit l'**information mutuelle** de  $X$  et  $Y$  (ou la transinformation) et on note  $I(X; Y)$  la quantité :

$$I(X; Y) = \sum_{x \in \mathcal{X}} \sum_{y \in \mathcal{Y}} P_{XY}(X = x, Y = y) \log_2 \left( \frac{P_{XY}(X = x, Y = y)}{P_X(X = x)P_Y(Y = y)} \right)$$

## Information mutuelle

On a les propriétés suivantes :

1.  $I(X; Y) = I(Y; X)$

2.  $I(X; Y) = H(X) - H(X|Y) = H(Y) - H(Y|X)$

Interprétation : l'information mutuelle correspond à la diminution du degré d'incertitude sur  $X$  due à  $Y$  (ou l'inverse)

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

4.  $I(X; X) = H(X)$

5.  $I(X; Y) \geq 0$

Égalité si et seulement si  $X$  et  $Y$  sont indépendantes

Ces résultats seront démontrés en exercice

## Interprétation

- ▶ On peut remarquer que :  $I(X; Y) = D_{KL}(p_{XY}(x, y) || p_X(x)p_Y(y))$
- ▶  $I(X; Y)$  est donc un indicateur d'indépendance de variables aléatoires.
- ▶ Plus  $p_{XY}(x, y)$  ressemble à  $p_X(x)p_Y(y)$ , plus  $I(X, Y)$  sera faible et moins les variables seront corrélées.

## Information mutuelle

### Prévisions météo

$X$  source qui nous dit s'il fera *soleil* ou *pluie*

$Y$  source qui nous dit s'il fera *chaud* ou *froid*

$X, Y$	$Y = \text{chaud}$	$Y = \text{froid}$
$X = \text{soleil}$	0.3	0.2
$X = \text{pluie}$	0.1	0.4

$H(X, Y) = 1.8464$  bits,  $H(X) = 1$  bit,  $H(Y) = 0.9710$  bits donc  $I(X; Y) = 0.1246$  bits  
Exprime le fait qu'il y a une dépendance entre  $X$  et  $Y$  et mesure l'information commune aux deux sources.



## Exemple d'un canal

Canal binaire symétrique

On suppose que les symboles 0 et 1 sont équiprobables à l'émission

- ▶  $H(X) = -\frac{1}{2} \log_2 \left(\frac{1}{2}\right) - \frac{1}{2} \log_2 \left(\frac{1}{2}\right) = 1$  bit
- ▶  $p_Y(0) = p_{Y|X}(0|0)p_X(0) + p_{Y|X}(0|1)p_X(1) = \frac{1-\epsilon}{2} + \frac{\epsilon}{2} = \frac{1}{2}$
- ▶  $p_Y(1) = \frac{1}{2}$
- ▶  $H(Y) = 1$  bit

$$H(Y|X) = -\frac{1-\epsilon}{2} \log_2(1-\epsilon) - \frac{\epsilon}{2} \log_2(\epsilon) - \frac{1-\epsilon}{2} \log_2(1-\epsilon) - \frac{\epsilon}{2} \log_2(\epsilon)$$

$$I(X; Y) = 1 + (1-\epsilon) \log_2(1-\epsilon) + \epsilon \log_2(\epsilon)$$

## Exemple d'un canal

Canal binaire symétrique (suite)

$$I(X; Y) = 1 + (1-\epsilon) \log_2(1-\epsilon) + \epsilon \log_2(\epsilon)$$

- ▶ Si  $\epsilon = \frac{1}{2}$ , il y a tellement d'erreurs qu'il n'y a plus de liens entre  $X$  et  $Y$
- ▶ Si  $\epsilon = 0$ ,  $X = Y$  donc  $X$  et  $Y$  contiennent la même information : leur information mutuelle est donc maximale
- ▶ Si  $\epsilon = 1$ ,  $X$  est exactement l'inverse de  $Y$  donc ils contiennent d'une certaine façon la même information
- ▶ Plus  $I(X; Y)$  est faible, plus on aura du mal à retrouver la valeur de  $X$  à partir de  $Y$