

Hiver 2019

Méthodes d'apprentissage
IFT603

Formulation probabiliste
Par
Pierre-Marc Jodoin
et
Hugo Larochelle

1

Variable aléatoire

- La théorie des probabilités est l'outil idéal pour formaliser nos **hypothèses et incertitudes** par rapport à nos données
- On va traiter nos données comme des **variables aléatoires**
 - la valeur d'une variable aléatoire est incertaine (avant de l'observer)
 - la loi de probabilité de la variable aléatoire caractérise notre incertitude par rapport à sa valeur

2

Variable aléatoire

- Soient X et Y des variables aléatoires **discrètes**
 - X peut prendre comme valeurs x_1, \dots, x_M
 - Y peut prendre comme valeurs y_1, \dots, y_M
- La **probabilité jointe** qu'on observe $X = x_i$ et $Y = y_j$ est notée

$$P(X = x_i, Y = y_j)$$
 et se lit comme la « probabilité d'observer à **la fois** x_i **et** y_j .
- Note:

$$P(X = x_i, Y = y_j) = P(Y = y_j, X = x_i)$$

3

Probabilité marginale

Une **probabilité marginale** est lorsqu'on ne s'intéresse pas à toutes les variables aléatoire qu'on a défini

Exemple : la probabilité marginale d'observer $X = x_i$

$$P(X = x_i) = \sum_{j=1}^N P(X = x_i, Y = y_j)$$

4

Probabilité conditionnelle

Une **probabilité conditionnelle** est lorsqu'on s'intéresse la valeur d'une variable aléatoire «étant donnée» une valeur assignée à d'autres variables

$$P(X = x_i | Y = y_j)$$

Se lit : la probabilité que $X = x_i$ étant donné que $Y = y_j$

5

Probabilité conditionnelle

Exemple, élections américaines 2016

$$P(\text{Voter républicain}) = 46.1\%$$

VS

$$\begin{cases} P(\text{Voter républicain} | \text{Zone urbaine}) = 35\% \\ P(\text{Voter républicain} | \text{Zone rurale}) = 62\% \\ P(\text{Voter républicain} | \text{Banlieu}) = 50\% \end{cases}$$

6

Produit des probabilités

x_i et y_j ont disparu,
seulement pour
simplifier la notation

Une probabilité jointe peut toujours être décomposée par le produit d'une probabilité conditionnelle et marginale

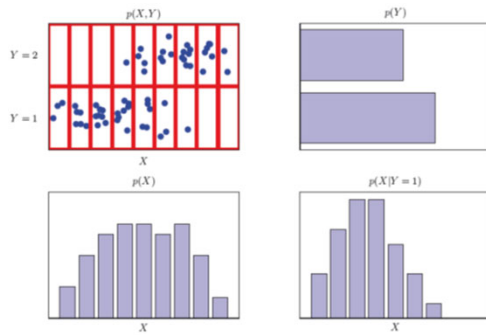
$$P(X, Y) = P(X | Y)P(Y)$$

En mots :

la probabilité d'observer $X=x_i$ ET $Y=y_j$, c'est la probabilité d'observer $Y=y_j$ multipliée par la probabilité d'observer $X=x_i$ **étant donné que** $Y=y_j$.

7

Probabilités jointes, marginale et conditionnelles



8

Bayes

La règle de Bayes permet d'inverser l'ordre de la conditionnelle

$$P(Y | X) = \frac{P(X | Y)P(Y)}{P(X)}$$

$p(Y)$ est appelée loi de probabilité **a priori** (*prior*)

$p(Y | X)$ est appelée loi de probabilité **a posteriori** (*posterior*)

9

Indépendance

Deux variables aléatoires X et Y sont indépendantes si

- > $P(X, Y) = P(X)P(Y)$ ou
- > $P(X | Y) = P(X)$ ou
- > $P(Y | X) = P(Y)$

➤ Observer la valeur d'une variable ne nous apprend rien sur la valeur de l'autre

10

Variable aléatoire continue

Soit X une **variable aléatoire continue**

- > X peut prendre un nombre infini de valeurs possibles (e.g. \mathbb{R})
- > X est associée à une **fonction de densité** de probabilité $p(x)$

la probabilité que X appartienne à un intervalle (a, b) est

$$p(x \in (a, b)) = \int_a^b p(x) dx$$

11


Variables aléatoires continues

Soit X une **variable aléatoire continue**

- > la fonction de densité doit satisfaire

$$p(x) \geq 0$$
$$\int_{-\infty}^{\infty} p(x) dx = 1$$

à noter que, contrairement aux probabilités d'une variable discrète, la fonction de densité peut être > 1 .



12

Variables aléatoires continues

Soit X une **variable aléatoire continue**

la **fonction de répartition** $P(z)$ (*cumulative distribution function*) donne la probabilité que X appartienne à l'intervalle $(-\infty, z)$

$$P(z) = \int_{-\infty}^z p(x) dx$$

13

Variables aléatoires continues

Soient X et Y deux **variables aléatoires continues**

➤ elles sont associées à une **fonction de densité jointe** $p(x,y)$ telle que :

$$p(x \in [a, b], y \in [c, d]) = \int_a^b \int_c^d p(x, y) dx dy$$

14

Variables aléatoires continues

Soient X et Y deux **variables aléatoires continues**

➤ La **fonction de densité marginale** s'obtient en intégrant l'autre variable


$$p(x) = \int p(x, y) dy$$

➤ La **fonction de densité conditionnelle** s'obtient comme auparavant

$$p(y | x) = \frac{p(x, y)}{p(x)}$$

15

Variables aléatoires continues



16

Expérance mathématique

L'**espérance** d'une **variable X** est la moyenne qu'on obtient si on répète un grand nombre de fois une expérience

$$E[X] = \sum_x xp(x) \quad (\text{cas discret})$$

$$E[X] = \int xp(x)dx \quad (\text{cas continu})$$

17

Expérance mathématique

L'**espérance** d'une **fonction f(x)** est la moyenne qu'on obtient si on génère un grand nombre de valeurs pour cette fonction

$$E[f] = \sum_x f(x)p(x) \quad (\text{cas discret})$$

$$E[f] = \int f(x)p(x)dx \quad (\text{cas continu})$$

18

Variance

- La **variance** d'une **variable** X est

$$\text{var}[X] = \mathbb{E}[(X - \mathbb{E}[X])^2]$$

- La **variance** d'une **fonction** $f(x)$ est

$$\text{var}[f] = \mathbb{E}[(f(x) - \mathbb{E}[f(x)])^2]$$

La variance mesure à quel point les valeurs varient autour de l'espérance

19

Propriétés de l'espérance et de la variance

Transformation linéaire de l'espérance

$$\begin{aligned} \mathbb{E}[ax + by] &= \sum_x \sum_y (ax + by)p(x, y) && a, b \text{ sont réels} \\ &= a\mathbb{E}[x] + b\mathbb{E}[y] && \text{Si } x, y \text{ indépendants} \end{aligned}$$

Transformation linéaire de la variance

$$\text{var}[ax + by] = a^2 \text{var}[x] + b^2 \text{var}[y] \quad \text{Si } x, y \text{ indépendants}$$

20

Espérance et variance conditionnelles

L'espérance et la variance se généralise au cas **conditionnel** :

$$\begin{aligned} \mathbb{E}[x | y] &= \sum_x xp(x | y) \\ \mathbb{E}[f(x) | y] &= \sum_x f(x)p(x | y) \end{aligned}$$

$$\begin{aligned} \text{var}[x | y] &= \mathbb{E}[(x - \mathbb{E}[x | y])^2] \\ \text{var}[f(x) | y] &= \mathbb{E}[(f(x) - \mathbb{E}[f(x) | y])^2] \end{aligned}$$

21

Covariance

La covariance entre 2 variables aléatoires X et Y

$$\begin{aligned} \text{cov}[x, y] &= E_{xy} [(x - E_x[x])(y - E_y[y])] \\ &= E_{xy}[xy] - E_x[x]E_y[y] \end{aligned}$$

mesure à quel point on peut prédire X à partir de Y (linéairement), et vice-versa
si X et Y sont indépendantes, alors la covariance est 0

22

Variabes aléatoires multidimensionnels

Une variable aléatoire peut être un vecteur

L'espérance d'un vecteur est le vecteur des espérances

$$E[\vec{x}] = (E[x_1], \dots, E[x_D])^T$$


Et la covariance de deux vecteurs est

$$\text{cov}[\vec{x}, \vec{y}] = E_{\vec{xy}} [\vec{x}\vec{y}^T] - E_{\vec{x}}[\vec{x}]E_{\vec{y}}[\vec{y}]$$

23

Loi de probabilité gaussienne

$$N(x | \mu, \sigma) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}}$$




Moyenne : $E[x] = \int_{-\infty}^{\infty} N(x; \mu, \sigma) x dx = \mu$

Variance : $\text{var}[x] = \int_{-\infty}^{\infty} N(x; \mu, \sigma) (x - \mu)^2 dx = \sigma^2$

Écart type : $\sqrt{\text{var}[x]} = \sigma$

24

Loi de probabilité gaussienne



25

Gaussienne multivariée

$$N(\vec{x} | \vec{\mu}, \Sigma) = \frac{1}{(2\pi)^{D/2} |\Sigma|^{1/2}} \exp\left\{-\frac{1}{2}(\vec{x} - \vec{\mu})^T \Sigma^{-1} (\vec{x} - \vec{\mu})\right\}$$


Moyenne : $E[\vec{x}] = \vec{\mu}$

Variance : $\text{cov}[\vec{x}] = \Sigma$

26

Gaussienne multivariée

Exemple : $\vec{x} = (x_1, x_2)$




27

Gaussienne multivariée

Exemple : $\bar{x} = (x_1, x_2)$

Courbes de niveaux de $N(\bar{x} | \bar{\mu}, \Sigma)$




28

Gaussienne multivariée

Exemple : $\bar{x} = (x_1, x_2)$

Courbes de niveaux de $N(\bar{x} | \bar{\mu}, \Sigma)$




29

Gaussienne multivariée

Exemple : $\bar{x} = (x_1, x_2)$

Courbes de niveaux de $N(\bar{x} | \bar{\mu}, \Sigma)$



30

Gaussienne multivariée

Une **combinaison linéaire** de variables aléatoires gaussiennes est également gaussienne

- Exemple

- soit x une variable gaussienne de moyenne μ_1 et variance σ_1^2
- soit y une variable gaussienne de moyenne μ_2 et variance σ_2^2
- alors $ax + by$ suit une loi gaussienne de moyenne $a\mu_1 + b\mu_2$ et variance $a^2\sigma_1^2 + b^2\sigma_2^2$ (x et y sont indépendantes)

31

Régression:

Maximum de vraisemblance
vs
Maximum a posteriori

32

32

Introduction au tableau

Maximum de vraisemblance
vs
Maximum a posteriori

33

33

Régression 1D

Retourons à notre exemple de régression


- **Données**
 - ✓ entrée : scalaire x
 - ✓ cible : scalaire t

➤ Ensemble d'entraînement D contient:

- ✓ $X = (x_1, \dots, x_N)^T$
- ✓ $T = (t_1, \dots, t_N)^T$

➤ **Objectif :**

- ✓ Faire une prédiction \hat{t} pour chaque nouvelle entrée \hat{x}



34

34

Régression polynomiale


➤ On va supposer que nos données suivent une **forme polynomiale**

$$y_W(x) = w_0 + w_1x + w_2x^2 + \dots + w_Mx^M$$

$$= \sum_{i=0}^M w_i x^i$$

➤ $y_W(x)$ est notre **modèle**

- ✓ Représente nos hypothèses sur le problème à résoudre
- ✓ Un modèle a toujours des paramètres qu'on doit trouver (ici \vec{W})




35

35

Régression polynomiale

Loi gaussienne conditionnelle




36

Régression polynomiale

Loi gaussienne conditionnelle

On va formuler l'hypothèse que chaque donnée t a été générée selon une gaussienne de moyenne $y_W(x)$ et de variance σ^2



$$p(T | X, \bar{W}, \sigma^2) = \prod_{n=1}^N p(t_n | x_n, \bar{W}, \sigma^2)$$

$$= \prod_{n=1}^N N(t_n | y_W(x_n), \sigma^2)$$

Variables indépendantes et identiquement distribuées (i.i.d)

37

Régression polynomiale

Maximum de vraisemblance
(cf. notes au tableau)

Cherchez les meilleurs paramètres \bar{W} en maximisant la vraisemblance

Connue \rightarrow Inconnue

$$W = \arg \max_W p(T | X, \bar{W}, \sigma^2)$$

$$= \arg \max_W \prod_{n=1}^N N(t_n | x_n, \bar{W}, \sigma^2) \quad \Rightarrow \text{Données gaussiennes et (i.i.d)}$$

$$= \arg \max_W \ln \left[\prod_{n=1}^N N(t_n | y_W(x_n), \sigma^2) \right]$$

$$= \arg \max_W \sum_{n=1}^N \ln N(t_n | y_W(x_n), \sigma^2)$$

38

Régression polynomiale

Maximum de vraisemblance
(cf. notes au tableau)

Cherchez les meilleurs paramètres W en maximisant la vraisemblance

$$W = \arg \max_W \sum_{n=1}^N \ln N(t_n | y_W(x_n), \sigma^2)$$

$$= \arg \max_W \sum_{n=1}^N \ln \left[\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(t_n - y_W(x_n))^2}{2\sigma^2}} \right]$$

Indépendant de W

$$= \arg \max_W \sum_{n=1}^N \left[-\frac{(t_n - y_W(x_n))^2}{2\sigma^2} + \ln \left[\frac{1}{\sqrt{2\pi}\sigma} \right] \right]$$

$$= \arg \min_W \frac{1}{2} \sum_{n=1}^N (t_n - y_W(x_n))^2$$

39

Régression polynomiale

Maximum de vraisemblance

Cherche les meilleurs paramètres W en **maximisant la vraisemblance**

$$W = \arg \min_W \frac{1}{2} \sum_{n=1}^N (t_n - y_W(x_n))^2$$

40

Régression polynomiale

Maximum *a posteriori* (MAP)
(cf. notes au tableau)

Cherche les meilleurs paramètres W en **maximisant la probabilité *a posteriori***

Inconnue → **Connues**

$$\begin{aligned} W &= \arg \max_W p(W | X, T, \sigma^2) \\ &= \arg \max_W \frac{p(T | X, W, \sigma^2) p(W)}{P(X, T, \sigma^2)} \quad \Rightarrow \text{Par le théorème de Bayes} \\ &= \arg \max_W p(T | X, W, \sigma^2) p(W) \quad \leftarrow \text{Constante par rapport à } W \\ &= \arg \max_W \prod_{n=1}^N N(t_n | y_W(x_n), \sigma^2) p(W) \quad \Rightarrow \text{Données gaussiennes et (i.i.d)} \end{aligned}$$

41

Régression polynomiale

Maximum *a posteriori* (MAP)
(cf. notes au tableau)

Cherche les meilleurs paramètres W en **maximisant la probabilité *a posteriori***

$$W = \arg \max_W \prod_{n=1}^N N(t_n | y_W(x_n), \sigma^2) p(W)$$

Si on présuppose que les paramètres W suivent une distribution gaussienne centrée à zéro avec une matrice de variance Σ

$$W = \arg \max_W \prod_{n=1}^N N(t_n | y_W(x_n), \sigma^2) N(W | 0, \Sigma)$$

$$W = \arg \max_W \ln \left[\prod_{n=1}^N N(t_n | y_W(x_n), \sigma^2) N(W | 0, \Sigma) \right]$$

42

Régression polynomiale

Maximum *a posteriori* (MAP)
(cf. notes au tableau)

Cherche les meilleurs paramètres W en maximisant la probabilité *a posteriori*

$$\begin{aligned} W &= \arg \max_W \ln \left[\prod_{n=1}^N N(t_n | y_W(x_n), \sigma^2) N(W | 0, \Sigma) \right] \\ &= \arg \max_W \sum_{n=1}^N \ln [N(t_n | y_W(x_n), \sigma^2) N(W | 0, \Sigma)] \\ &= \arg \max_W \sum_{n=1}^N \ln \left[\frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(t_n - y_W(x_n))^2}{2\sigma^2}} \right] + \ln \left[\frac{1}{(2\pi)^{1/M} |\Sigma|} e^{-\frac{W^T \Sigma^{-1} W}{2}} \right] \\ &= \arg \max_W \sum_{n=1}^N \left[-\frac{(t_n - y_W(x_n))^2}{2\sigma^2} - \frac{W^T \Sigma^{-1} W}{2} \right] + \ln \left[\frac{1}{\sqrt{2\pi}\sigma} \right] + \ln \left[\frac{1}{(2\pi)^{1/M} |\Sigma|} \right] \end{aligned}$$

43

Régression polynomiale

Maximum *a posteriori* (MAP)
(cf. notes au tableau)

Cherche les meilleurs paramètres W en maximisant la probabilité *a posteriori*

$$W = \arg \max_W \sum_{n=1}^N \left[-\frac{(t_n - y_W(x_n))^2}{2\sigma^2} - \frac{W^T \Sigma^{-1} W}{2} \right] + \ln \left[\frac{1}{\sqrt{2\pi}\sigma} \right] + \ln \left[\frac{1}{(2\pi)^{1/M} |\Sigma|} \right]$$

Constante par rapport à W

De plus, comme on ne connaît généralement pas Σ , on suppose qu'elle est isotropique

$$\Sigma = \begin{pmatrix} \alpha^2 & 0 & \dots & 0 \\ 0 & \alpha^2 & & \vdots \\ \vdots & & \ddots & \\ 0 & 0 & \dots & \alpha^2 \end{pmatrix} = \alpha^2 I$$

44

Régression polynomiale

Maximum *a posteriori* (MAP)
(cf. notes au tableau)

Cherche les meilleurs paramètres W en maximisant la probabilité *a posteriori*

$$\begin{aligned} W &= \arg \max_W \sum_{n=1}^N \left[-\frac{(t_n - y_W(x_n))^2}{2\sigma^2} - \frac{W^T \Sigma^{-1} W}{2} \right] \\ &= \arg \max_W \sum_{n=1}^N \left[-\frac{(t_n - y_W(x_n))^2}{2\sigma^2} - \frac{W^T W}{2\alpha^2} \right] \\ &= \arg \min_W \sum_{n=1}^N \left[\frac{(t_n - y_W(x_n))^2}{2} + \lambda \frac{W^T W}{2} \right] \quad \text{où } \lambda = \frac{\sigma^2}{\alpha^2} \end{aligned}$$

45

Régression polynomiale

Maximum *a posteriori* (MAP)

Cherche les meilleurs paramètres W en **maximisant la probabilité *a posteriori***

$$W = \arg \min_W \sum_{n=1}^N \frac{(t_n - y_W(x_n))^2}{2} + \lambda \frac{W^T W}{2}$$



Formule également connue sous le nom de «**régression de Ridge**»

Voir sklearn pour une implémentation simple
scikit-learn.org/stable/modules/generated/sklearn.linear_model.Ridge.html

46

Théorie de l'information

47

47

Théorie de l'information

- Les probabilités sont également utiles pour **quantifier l'information** présente dans des données
exemple : quel est le nombre minimum de bits nécessaire pour encoder un message ?
- Cette question est intimement liée à la **probabilité d'observer ce message**
plus le message est «surprenant» (improbable), plus on aura besoin de bits

48

48

Théorie de l'information

Codage de Huffman :

- façon optimale d'encoder des symboles indépendants de façon binaire
- plus un symbole est «fréquent» (probable), plus son code sera court


'a'	'b'	'c'	'd'
0.4	0.05	0.2	0.35

49

Théorie de l'information

Codage de Huffman :

- façon optimale d'encoder des symboles indépendants de façon binaire
- plus un symbole est «fréquent» (probable), plus son code sera court




50

Théorie de l'information

Codage de Huffman :

- façon optimale d'encoder des symboles indépendants de façon binaire
- plus un symbole est «fréquent» (probable), plus son code sera court




51

Théorie de l'information

Codage de Huffman :

- façon optimale d'encoder des symboles indépendants de façon binaire
- plus un symbole est «fréquent» (probable), plus son code sera court




52

Théorie de l'information

Codage de Huffman :

- façon optimale d'encoder des symboles indépendants de façon binaire
- plus un symbole est «fréquent» (probable), plus son code sera court



Symbole	Code	Prob
'a'	0	40%
'b'	100	5%
'c'	101	20%
'd'	11	35%

53

Entropie

Symbole	Code	Prob
'a'	0	40%
'b'	100	5%
'c'	101	20%
'd'	11	35%

• Soit $p(x)$ la probabilité d'observer le symbole x

la taille moyenne du code d'un symbole est

$$0.4 \times 1 + 0.05 \times 3 + 0.2 \times 3 + 0.35 \times 2 = \mathbf{1.85 \text{ (bits)}}$$

• Entropie :

$$H[x] = -\sum_x p(x) \log_2 p(x) \approx \mathbf{1.739 \text{ (bits)}}$$

Claude Shannon a démontré qu'il est impossible de compresser l'information dans un plus petit code moyen **sans perte d'information**


$-\log_2 p(x)$ est l'information contenue par x

54

Entropie

Plus $p(x)$ est proche d'une **loi uniforme**, plus l'**entropie est élevée**

exemple : $x \in \{a, b, c, d, e, f, g, h\}$




$$\begin{aligned}
 H[x] &= -\sum_x p(x) \log_2 p(x) \\
 &= -\left(\frac{1}{8} \log_2 \left(\frac{1}{8}\right) + \frac{1}{8} \log_2 \left(\frac{1}{8}\right) + \frac{1}{8} \log_2 \left(\frac{1}{8}\right) + \frac{1}{8} \log_2 \left(\frac{1}{8}\right) + \frac{1}{8} \log_2 \left(\frac{1}{8}\right) + \frac{1}{8} \log_2 \left(\frac{1}{8}\right) + \frac{1}{8} \log_2 \left(\frac{1}{8}\right) + \frac{1}{8} \log_2 \left(\frac{1}{8}\right)\right) \\
 &= -8 \left(\frac{1}{8} \log_2 \left(\frac{1}{8}\right)\right) \\
 &= 3 \text{ bits}
 \end{aligned}$$

55

Entropie

Plus $q(x)$ s'éloigne d'une **loi uniforme**, plus l'**entropie est faible**

exemple : $x \in \{a, b, c, d, e, f, g, h\}$



$$\begin{aligned}
 H[x] &= -\sum_x q(x) \log_2 q(x) \\
 &= -\left(\frac{1}{2} \log_2 \left(\frac{1}{2}\right) + \frac{1}{4} \log_2 \left(\frac{1}{4}\right) + \frac{1}{8} \log_2 \left(\frac{1}{8}\right) + \frac{1}{16} \log_2 \left(\frac{1}{16}\right) + \frac{1}{32} \log_2 \left(\frac{1}{32}\right) + \frac{1}{64} \log_2 \left(\frac{1}{64}\right) + \frac{1}{128} \log_2 \left(\frac{1}{128}\right) + \frac{1}{256} \log_2 \left(\frac{1}{256}\right)\right) \\
 &= 2.06 \text{ bits}
 \end{aligned}$$

56

Entropie

L'entropie se généralise aux variables continues

$$H[x] = - \int_{-\infty}^{\infty} p(x) \log_2 p(x) dx$$

57

Entropie relative et divergence de Kullback-Leibler

- Si on ne connaît pas $p(x)$, on va vouloir l'estimer
- Si $q(x)$ est notre estimation, on définit la **divergence de Kullback-Leibler (K-L)** comme suit :

$$KL(p(x) \parallel q(x)) = -\sum_x p(x) \log_2 q(x) - \left(-\sum_x p(x) \log_2 p(x) \right) \\ = \sum_x p(x) \log_2 \frac{p(x)}{q(x)}$$

➤ correspond au **nombre de bits additionnels** par rapport à ce qui serait optimal

58

Entropie jointe

L'entropie est une fonction d'une loi de probabilité

- elle reflète l'**incertitude représentée par la loi**
- si $p(x) = 1$ pour une seule valeur de x , l'entropie est 0

On peut généraliser l'entropie à **plusieurs variables**

$$H[x, y] = -\sum_x \sum_y p(x, y) \log_2 p(x, y)$$

59

Entropie conditionnelle

L'entropie conditionnelle quantifie l'**information additionnelle** qu'apporte une **nouvelle observation y**

$$H[x | y] = -\sum_x \sum_y p(x, y) \log_2 p(x | y)$$

On peut démontrer que

$$H[x, y] = H[y | x] + H[x]$$

60

Information mutuelle

- Mesure à quel point deux variables sont indépendantes

$$\begin{aligned} I(x, y) &= KL(p(x, y) \parallel p(x)p(y)) \\ &= \sum_{x,y} p(x, y) \log_2 \frac{p(x, y)}{p(x)p(y)} \end{aligned}$$

➤ On appelle cette mesure l'**information mutuelle**
