

## Révision des probabilités

Roland Memisevic

### Variables aléatoires


- ▶ L'attribut le plus important d'une variable aléatoire est sa *distribution*.
- ▶  $p(x)$  est une distribution si  $p(x) \geq 0$  and  $\sum_x p(x) = 1$
- ▶ Bizarries de notation :
  - ▶ Le symbole  $p$  est très "surchargé" : Par exemple, dans l'expression " $p(x, y) = p(x)p(y)$ ", chaque  $p$  a une signification différente !
  - ▶ Parfois on écrit  $X$  pour signifier la variable aléatoire et  $x$  pour les valeurs qu'elle prend :  $p(X = x)$ .
  - ▶  $\sum_x \dots$  signifie la somme sur toutes les valeurs que  $x$  peut avoir.
- ▶ Pour des variables continues, on remplace  $\sum$  par  $\int$  (il y a d'autres techniques différentes (dues à la théorie de la mesure) qu'on peut généralement ignorer.
- ▶ Parfois, l'expression "fonction de densité de probabilité" est utilisée pour se référer à une variable aléatoire continue et "distribution" pour se référer à une variable discrète.

### Probabilités en IA

- ▶ Les probabilités nous permettent de quantifier des incertitudes :
- ▶ Au lieu d'une *valeur*, on utilise une distribution sur plusieurs valeurs alternatives.
- ▶ Exemple : À la place de ' $x = 4$ ', on peut définir toutes les valeurs
$$p(x = 1), p(x = 2), p(x = 3), p(x = 4), p(x = 5)$$
- ▶ Avantages :
  1. Robustesse (un modèle peut communiquer toutes ses connaissances)
  2. Mesure de l'incertitude (on a des "error bars")
- ▶ On peut toujours représenter ' $x = 4$ ' comme un cas particulier (comment le feriez-vous ?)

### Certaines distributions courantes (1d)

#### Discrète

- ▶ **Bernoulli** :  $p^x(1 - p)^{1-x}$  où  $x$  est 0 ou 1
- ▶ **Distribution discrète** (parfois également appelé "multinoulli") : 
- ▶ Distribution **binomiale, multinomiale** : Somme sur Bernoulli/Discrete. (Parfois "multinomiale" est utilisé pour se référer à une distribution discrète...)
- ▶ **Poisson** :  $p(k) = \frac{\lambda^k \exp(-\lambda)}{k!}$

#### Continue

- ▶ **Densité uniforme** : 
- ▶ **Densité gaussienne (1d)** :
$$p(x) = \frac{1}{(2\pi\sigma^2)^{\frac{1}{2}}} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right)$$

## Représenter des valeurs discrètes

- ▶ Un moyen très utile pour représenter une variable qui prend une valeur  $k$  parmi  $K$  valeurs possibles :
- ▶ Vecteur de dimension  $K$ , contenant  $(K - 1)$  0, et un 1

$$\mathbf{x} = \begin{pmatrix} 0 \\ \vdots \\ 1 \\ \vdots \\ 0 \end{pmatrix}$$

- ▶ Codage **1-de- $K$** , **codage orthogonal**, **one-hot encoding**
- ▶ Notez que nous pouvons interpréter  $\mathbf{x}$  comme une distribution !

## Propriétés

- ▶ Les propriétés d'une variable aléatoire sont des propriétés de sa distribution.
- ▶ La moyenne :

## Multinoulli utilisant le codage orthogonal

- ▶ L'encodage orthogonal nous permet d'écrire la distribution discrète :

$$p(\mathbf{x}) = \prod_k \mu_k^{x_k}$$

où  $\mu_k$  signifie la probabilité d'état  $k$ .

- ▶ Cela peut considérablement simplifier les calculs.

## Propriétés

- ▶ Les propriétés d'une variable aléatoire sont des propriétés de sa distribution.
- ▶ La moyenne :

$$\mu = \sum_x p(x)x = E[x]$$

- ▶ La variance :

## Propriétés

- ▶ Les propriétés d'une variable aléatoire sont des propriétés de sa distribution.
- ▶ La moyenne :

$$\mu = \sum_x p(x)x = E[x]$$

- ▶ La variance :

$$\sigma^2 = \sum_x p(x)(x - \mu)^2 = E[(x - \mu)^2]$$

- ▶ (L'écart-type :  $\sigma = \sqrt{\sigma^2}$ )

## Plusieurs variables

- ▶ La **distribution jointe**  $p(x, y)$  de deux variables  $x, y$  satisfait aussi

$$p(x, y) > 0 \text{ and } \sum_{x,y} p(x, y) = 1,$$


- ▶ Ou également

$$p(\mathbf{x}) > 0 \text{ and } \sum_{\mathbf{x}} p(\mathbf{x}) = 1,$$

pour vecteur  $\mathbf{x}$

- ▶ Pour des variables discrètes, imaginez un *tableau*.

## La Gaussienne (1d)



$$p(x) = \mathcal{N}(x|\mu, \sigma^2) = \frac{1}{(2\pi\sigma^2)^{\frac{1}{2}}} \exp\left(-\frac{1}{2\sigma^2}(x - \mu)^2\right)$$

## Probabilité conditionnelle et marginale

- ▶ Tout ce qu'on pourrait désirer savoir à propos d'un vecteur aléatoire peut être dérivé de la distribution jointe.
- ▶ **distribution marginale** :

$$p(x) = \sum_y p(x, y) \text{ and } p(y) = \sum_x p(x, y)$$

- ▶ Imaginez l'effondrement de toutes les valeurs dans une dimension du tableau.
- ▶ **distribution conditionnelle** :

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

- ▶ Imaginez une famille de distributions, indexée par la variable conditionnante. (On peut également écrire  $p(y|x)$  comme  $p_x(y)$ ).

## Propriétés

- ▶ La moyenne :

$$\boldsymbol{\mu} = \sum_{\mathbf{x}} p(\mathbf{x})\mathbf{x} = E[\mathbf{x}]$$

- ▶ La covariance :

$$\text{cov}(x_i, x_j) = E[(x_i - \mu_i)(x_j - \mu_j)]$$

- ▶ Matrice de covariance :

$$\Sigma_{ij} = \text{cov}(x_i, x_j) \quad (\Sigma = \sum_{\mathbf{x}} p(\mathbf{x})(\mathbf{x} - \boldsymbol{\mu})(\mathbf{x} - \boldsymbol{\mu})^T)$$

- ▶ Le coefficient de corrélation :

$$\text{corr}(x_i, x_j) = \frac{\text{cov}(x_i, x_j)}{\sqrt{\sigma_i^2 \sigma_j^2}}$$


## Une formule fondamentale

$$p(x|y)p(y) = p(x, y) = p(y|x)p(x)$$

- ▶ Peut être généralisée à plus de deux variables ("règle de la chaîne des probabilités").
- ▶ Un cas particulier est **la règle de Bayes** :

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

## La Gaussienne multivariée



$$p(\mathbf{x}) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma|^{\frac{1}{2}}} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^T \Sigma^{-1} (\mathbf{x} - \boldsymbol{\mu})\right)$$

## Indépendance

- ▶ Deux variables aléatoires sont **indépendantes** si

$$p(x, y) = p(x)p(y)$$

- ▶ Notez que cette définition implique

$$p(y|x) = p(y)$$

- ▶ (Être indépendant implique d'être décorrélé, mais pas l'inverse)
- ▶ Deux variables aléatoires sont **conditionnellement indépendantes**, sachant une troisième  $z$ , si

$$p(x, y|z) = p(x|z)p(y|z)$$

- ▶ (Notez que tous ces concepts sont toujours des propriétés de la distribution jointe.)

## L'utilité de l'indépendance

- ▶ Imaginez un ensemble de variables,  $x_1, x_2, \dots, x_K$
- ▶ Simplement définir leur densité jointe (sans parler de faire des calculs avec elle) est tout à fait impossible pour une grande valeur de  $K$  !
- ▶ Mais si tous les  $x_i$  sont indépendants ?
- ▶ Dans ce cas, il faut simplement définir  $K$  probabilités, car *la densité jointe en est le produit*.
- ▶ On peut étendre cette idée (très loin) en utilisant l'indépendance conditionnelle ("modèles graphiques").

## Maximum de vraisemblance

- ▶ Cela est facile si les exemples sont indépendants et distribués identiquement ("iid") :

$$p(\mathbf{x}_1, \dots, \mathbf{x}_N; \mathbf{w}) = \prod_i p(\mathbf{x}_i; \mathbf{w})$$

- ▶ Au lieu de maximiser la probabilité, nous pouvons maximiser la log-probabilité, car le log est monotone :

$$L(\mathbf{w}) := \log \prod_i p(\mathbf{x}_i; \mathbf{w}) = \sum_i \log p(\mathbf{x}_i; \mathbf{w})$$

- ▶ Chaque exemple  $\mathbf{x}_i$  contribue un terme additif à l'objectif.

## Maximum de vraisemblance

- ▶ Une autre propriété utile de l'indépendance :
- ▶ Imaginez que nous avons un ensemble de données

$$(x_1, \dots, x_N)$$

et que nous voulons construire un modèle du processus qui a généré ces données.

- ▶ Approche : Ajuster un modèle probabiliste  $p(x; \mathbf{w})$ , qui contient des paramètres  $\mathbf{w}$ .
- ▶ Comment ? Maximisez la probabilité de "voir" ces données selon ce modèle !

## Maximum de vraisemblance pour la moyenne d'une Gaussienne

- ▶ Il faut maximiser

$$L(\mu) = \sum_i \log p(x_i; \mu) = \sum_i \left( -\frac{1}{2\sigma^2} (x_i - \mu)^2 \right) - \text{const.}$$

- ▶ La dérivée est :

$$\frac{\partial L(\mu)}{\partial \mu} = \frac{1}{\sigma^2} \sum_i (x_i - \mu) = \frac{1}{\sigma^2} \left( \sum_i x_i - N\mu \right)$$

- ▶ Mettre à zero :

$$\mu = \frac{1}{N} \sum_i x_i$$