

Beste de savoir

Beta & Dirichlet distribution, les
probabilités des probabilités

mercredi 01 mai 2024

Table des matières

	Introduction	1
1.	Bernouilli	1
2.	Beta distribution	2
3.	Dirichlet distribution	4
	Conclusion	5

Introduction

Au boulot, un collègue a commencé à noter s'il prenait de la vinaigrette ou de la mayonnaise avec sa salade.

Depuis le début de la semaine, voici ce qu'il a consigné :

Lundi	Mardi	Mer-credi	Jeudi
Vinai-grette	Mayon-naise	Vinai-grette	

Que peut-on prédire pour demain sur base de ces observations ? Intuitivement, on pourrait se dire qu'il a 2 chances sur 3 (66%) de reprendre de la vinaigrette.

Mais est-ce qu'il est possible de faire mieux ? Exprimer, par exemple, que la probabilité qu'il reprenne de la vinaigrette est de 66% avec un intervalle de confiance de plus ou moins 20% ?

1. Bernouilli

Ce genre d'expériences où chaque jour correspond à une nouvelle expérience, indépendante de la veille et où le résultat est binaire (vinaigrette ou mayonnaise) est qualifié de processus de Bernouilli.

Ici, au lieu d'avoir une distribution de Bernouilli connue (probabilité d'avoir vinaigrette = $p\%$ et mayonnaise = $(1 - p\%) = q\%$), celle-ci est inconnue. L'expérience est également répétée n fois ; on se retrouve plutôt dans le cas d'une distribution Binomiale à paramètres inconnus.

Pour rappel, la probabilité d'avoir exactement k 'succès' au bout de n expériences et est donné par la formule suivante :

$$Pr(k; n, p) = \binom{n}{k} p^k (1 - p)^{n-k}$$

2. Beta distribution

Le problème devient inverse. Pour quelle valeur de p , la probabilité de nos observations est-elle maximale ? Quelle est la valeur la plus probable pour p afin d'obtenir nos résultats. C'est une approche qu'on qualifie d'*inférence bayésienne*.

En essayant d'optimiser la valeur de p par les techniques de *maximum likelihood estimator* ou celles des *moments*, nous arrivons à un estimateur qui est également optimal¹ :

$$\hat{p} = \frac{k}{n}$$

Cela fait sens que le meilleur estimateur de la probabilité que nous avons soit le rapport du nombre de succès (k) sur le nombre de tentatives réalisées (n).

Un intervalle de confiance sur une distribution binomiale peut être donnée par une approximation de la (distribution) normale, aussi appelé "intervale de Wald"². On a que :

$$p \approx \hat{p} \pm \frac{z_\alpha}{\sqrt{n}} \sqrt{\hat{p}(1 - \hat{p})}$$

où z_α est le quantile de la distribution normale (95% = 1.96). On retrouve bien la relation étroite qu'entretient la distribution normale et binomiale dans cette relation.

2. Beta distribution

Mais est-il possible de modéliser la distribution de probabilité la plus probable pour un p connu dans le cadre d'une loi binomiale ?

On cherche une distribution telles que :

- elle soit définie entre 0 et 1 (ce sont des probabilités que l'on cherche) ;
- positive ;
- l'intégrale doit être égale à 1 ;
- la moyenne devrait être proche de notre \hat{p} ;
- ainsi que l'erreur $var[\hat{p}]$;
- chaque élément est indépendant et identiquement distribué ;

La distribution qui correspond à ces propriétés est la distribution Beta :

$$\begin{aligned} f(x; \alpha, \beta) &= \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} x^{\alpha-1} (1-x)^{\beta-1} \\ &= \frac{1}{(\alpha, \beta)} x^{\alpha-1} (1-x)^{\beta-1} \end{aligned}$$

Plusieurs remarques :

- $\Gamma(z)$ est la fonction "Gamma", la généralisation de la fonction exponentielle ($\Gamma(z) = (z-1)!$) ;

1. https://en.wikipedia.org/wiki/Lehmann%E2%80%93Scheff%C3%A9_theorem ↗

2. https://en.wikipedia.org/wiki/Binomial_proportion_confidence_interval#Wald_interval ↗

2. Beta distribution

- (z_1, z_2) est la fonction "Beta", qui peut s'interpréter comme la généralisation des coefficients binomiaux ;
- α est généralement considéré comme le nombre de succès k "+ 1", β est le nombre d'échecs $(n - k)$ "+ 1". Ces "+ 1" apparaissent notamment à cause de la définition de ces fonctions Γ et ;
- On peut remarquer une très grande symétrie dans cette définition et celle de la Binomiale ;

Cette distribution possède plusieurs bonnes propriétés :

- $E[X] = \frac{\alpha}{\alpha+\beta}$. Si l'on remplace les valeurs de α et β par nos observations, nous obtenons : $\frac{k+1}{n+2}$ qui, lorsque n tend vers l'infini, retombe sur notre \hat{p} ;
- $var[X] = \frac{\alpha\beta}{(\alpha+\beta)^2}(\alpha+\beta+1)$. Avec nos valeurs, on a : $\frac{(k+1)*(n-k+1)}{(n+2)^2(n+3)}$ et à la limite : $\sigma^2 \approx \frac{\hat{p}(1-\hat{p})}{n}$ qui est ce que l'on recherchait ;
- Le mode = $\frac{\alpha-1}{\alpha+\beta-2}$ est exactement notre \hat{p} , ce qui tombe bien puisque c'est là où la probabilité est maximale. La moyenne peut être très légèrement décalée par rapport au mode à cause du côté où penche la queue ;




FIGURE 2.1. – Différentes distributions Beta

Par exemple, nous voyons que :

- Pour $B(1, 1)$, comme il n'y a eu ni succès, ni échec, la distribution est constante sur tout le domaine. Aucune probabilité n'est préférée a priori ;
- Pour $B(2, 2)$, on voit la courbe se centrer à la moitié mais avoir une base relativement large (σ) ;
- Pour $B(10, 5)$, on commence à pencher vers une probabilité vers $2/3$ et l'on observe un pic bien plus resserré pour cette valeur ;
- Lorsque l'on met des valeurs de α ou β inférieure à 1, les probabilités deviennent très polarisées, très extrêmes ;

Vous reconnaîtrez que c'est un outil puissant de statistique a priori, qui permet une analyse bien plus puissante que la donnée brute par elle-même.

3. Dirichlet distribution

Il est naturel de se demander comment ce concept peut être étendu. Une direction possible est d'étudier sa généralisation à plusieurs variables.

Supposons que vous effectuiez un relevé des causes d'admission à l'hôpital. Vous savez que les gens peuvent se retrouver dans l'une des K catégories. Vous vous demandez à quel point ses résultats sont représentatifs de la population. Est-il possible d'obtenir également des marges d'erreur sur notre échantillon ?

On peut définir la distribution de Dirichlet $\text{Dir}(\alpha)$:

$$f(x; \alpha) = \frac{1}{(\alpha)} \prod_{i=1}^K x_i^{\alpha_i-1}$$

où

$$(\alpha) = \frac{\prod_{i=1}^K \Gamma(\alpha_i)}{\Gamma(\alpha_0)} \quad \text{et} \quad \alpha_0 = \sum_{i=1}^K \alpha_i$$

Cela peut sembler extrêmement barbare à première vue, mais décomposons les morceaux :

- $\alpha_0 = \sum_{i=1}^K \alpha_i$, on définit α_0 comme la somme de nos valeurs α_i , nos observations.
- $(\alpha) = \frac{\prod_{i=1}^K \Gamma(\alpha_i)}{\Gamma(\alpha_0)}$, on retrouve une généralisation des coefficients *multi*-nomiaux.
- $\frac{1}{(\alpha)} \prod_{i=1}^K x_i^{\alpha_i-1}$, toutes nos probabilités x_i .

Attention qu'il faut que toutes nos probabilités x_i soit comprises entre 0 et 1 et que leur somme soit égale à 1 ($\sum_{i=1}^K x_i = 1$).

On peut effectuer deux observations :

- Si $K = 2$, on retombe bien sur la distribution Beta.
- Cet ensemble de x_i forme ce qu'on appelle un *simplex*, la généralisation d'un triangle sur plusieurs dimensions.




FIGURE 3.2. – Quelques exemples de distributions de Dirichlet, ici en 3D

Conclusion

Attention que ces trois distributions font toute l'hypothèse que les événements sont indépendants et identiquement distribués.

Si l'on pioche au sein d'une boîte contenant un nombre fini de balles, *sans remplacement*, on obtient :

- Binomiale -> Hypergéométrique
- Beta -> Beta-binomiale
- Dirichlet -> Dirichlet-multinomiale

À noter qu'il y a tout un ensemble de subtilités qui peuvent s'adjoindre à ces notions. Par exemple, il existe la distribution *categorical* quand les observations peuvent faire partie de K catégories. S'intéresse-t-on aux distributions a priori et non a posteriori, sur un échantillon ou sur toute la population ?

Bref, je voulais surtout présenter comment une tentative de réponse à la question des marges d'erreurs sur les résultats obtenus et comment avoir une meilleure idée des paramètres sous-jacents du modèle sur base d'un résultat.