



N° Réf :.....

Centre Universitaire
Abd elhafid boussouf Mila

Institut des sciences et de la technologie

Département de Mathématiques et Informatique

Mémoire préparé En vue de l'obtention du diplôme de Licence

En: - Filière mathématiques

Thème

Analyse Statistique Bayésienne
Analyse Statistique Bayésienne

Préparé par :

- **Boucherma Meriem**
- **Bouhannache Houda**
- **Kebieche Hadjer**
- **Belkessour Roqiya**

Encadrer par : Zerari Amel

Année universitaire : 2014/2015

Remerciement

*nous remercierons Dieu le tout puissant qui ma
donné courage, patience et force jusqu'à la fin de la réalisation
de ce modeste travail*

*Nous tenons à exprimer Un remerciement particulier à notre
Encadreur « Zerari Amel » pour avoir dirigé ce travail, pour sa*

Présence, son aide et surtout pour ses précieux conseils

*Mille merci nos trop chères familles ,pour leur efforts
exeptionnels et pour nous soutenir d'une façon remarquable
pendant la realisation de ce projet de mémoire*

*Nous remercierons particulièrement à tout le personnel
de l'institut des sciences et de la technologie surtout les
enseignants qui nous ont formé durant les années d'étude*

Table des matières

Introduction Générale	4
1 l'approche bayésienne	5
1.1 Introduction	5
1.2 l'école bayésienne	6
1.2.1 le paradigme bayésienne	7
1.2.2 les avantage de l'école bayésienne	8
1.2.3 les Inconvénients	8
1.3 Annalyse statistique bayésienne	9
1.4 la règle de Bayes	10
1.5 la loi prioir et posterior	10
1.5.1 La loi a priori :	10
1.5.2 La loi a posteriori :	11
1.6 le problème de choix a priori	12
1.6.1 lois subjective	12
1.6.2 la loi conjuguée	12
1.7 la vraisemblance	13
1.7.1 principe de vraisemblance	13
1.8 la loi prédictive	14
1.8.1 La distribution predictive a posteriori	14
1.9 la loi informative	15
1.10 loi non informative	15
1.10.1 la loi jeffreys	16
1.11 Facteur de bayes	18
2 la simulation de les lois probabilités	19
2.1 Introduction	19
2.2 loi binomial	19

2.3	loi gométriqne	22
2.4	loi binomil négative	25
2.5	Lois Bernoulli	28
2.6	loi normale	31
2.7	loi gamma	35
2.8	loi exponetielle	38
2.9	loi poissan	41
	Conclusion Générale	46
	Bibliographie	46

Introduction Générale

Dans ce travail est porte sur l'étude d'analyse statistique bayésienne, avant d'expliquer ce sujet nous donnons une petit définition sur la science de statistique et sa relation avec la science de bayes.

confirme certains scientifiques et beaucoup historiens des mathématiques qui le mot statistiques ont émergé depuis les deux mille ans avant JC, par les Egyptiens et avec le passage du temps a évolué vers une connaissance de base des théories et applications invoqués dans plusieurs domaines et de la recherche scientifique, il considéré comme un ensemble des méthodes scientifiques qui peut être utilisé pour la collecte des données. led utilise de la science des statistique dans plusieurs domaines de la vie a l'attention des chercheurs qui etudent cette science, au fil de temps est née de cette études scolaires bayésienne qui dépend dans le style l'analyse et les conclusions sur les informations fournisseurs par la connaissance de statistique. bayes école se distingue des autres écoles traitées comme paramètre dans les distribution de probabilité que des variable aléatoire par cette concept nous constatons que la théorème de bayes est principalement liée a la science appellé analyse statistique bayésienne.

analyse statistique bayésienneest un ensemble de techniques statistique utilisé pour donner les solutions des problèmes de les loi probabilité il est développer par cristian robert elle est cohérente avec la théorie de probabilités et résult d'une simple appli-

cation du théoreme de bayes L'analyse statistique permet d'utiliser ces connaissances a priori et de les combiner avec l'information apportée par les données pour obtenir une information a posteriori.il est également très utilisée dans les analyses, qui mettent ensemble plusieurs études réalisées dans des conditions parfois différentes pour en extraire de l'information avec une meilleure précision.

Ce mémoire est divisé en deux chapitre :

la premier chapitre,nous présentons une concept générale sur l'approche bayésienne par donné les avantage était la base du développement de l'école en termes de précision dans les résultats et la capacité de ses prévisions pour l'avenir et les Inconvénients et aussi donné quelques définitions et propriétés des lois qui servent cette approche surtout la priori et la posteriori

la deuxième chapitre a été consacré à la présentation la simulation et rappel sur les loi de probabiliter Ce chapitre a appliqué le premier chapitre, en utilisant le programme MAPLE 13, ce qui me aide à résoudre une série exemples (binomial,poisson, gamme,béat.....) donnant courbes pour illustrer comment le travail de ces possibilités

Chapitre 1

l'approche bayésienne

1.1 Introduction

L'objet principal de la statistique est de faire, à partir d'observations d'un phénomène aléatoire, une inférence au sujet de la loi générant ces observations en vue d'analyser le phénomène ou de prévoir un événement futur. Pour réduire la complexité du phénomène étudié, deux approches statistiques sont utilisées dans la statistique : l'approche non paramétrique (classique) et paramétrique (bayésienne). Dans la première approche non paramétrique on considère que l'inférence statistique doit prendre en considération la complexité autant que possible et donc on cherche la distribution de l'ensemble du phénomène, mettant en oeuvre des fonctionnelles et les données observées sont considérées comme des observations de variables aléatoires. Elle servent alors à faire porter l'inférence sur les paramètres θ ayant leur mécanisme de génération. Autrement dit, l'information provenant des données observées est l'unique source d'information. Le paradigme classique n'offre pas l'équivalent de la distribution predictive a posteriori.

La démarche statistique classique repose essentiellement sur un principe de vraisemblance qui consiste à considérer l'observation mais l'observation ne fournit qu'une

image et celle ci peut être mauvaise et donné une valeur inconnu cette inconvénient

Est la principale raison de l'émergence de l'école bayésienne

L'analyse bayésienne des problèmes statistiques propose d'introduire dans la démarche d'inférence, l'information dont dispose a priori le praticien. dans le cadre de la statistique paramétrique ceci se traduira par le choix d'un loi sur le paramètre d'intérêt. dans l'approche Bayésienne, le modèle statistique ayant un a priori sur le paramètre modélisé par une densité de probabilité que nous noterons $\pi(\theta)$, cet a priori au vu de l'observation en calculant la densité a posteriori $\pi(\theta | x)$

1.2 l'école bayésienne

Le statisticien bayésien raisonne différemment puisqu'il considère que le paramètre du modèle statistique, $[y/\theta]$ est incertain. Il va donc chercher a quantifier son incertitude en mobilisant toutes les informations disponibles. C'est ce qui fait toute la différence puisque cela revient a conférer au paramètre θ le statut de variable aléatoire, Dès lors, il y a un sens a lui attribuer une distribution de probabilité a priori qui décrit le savoir actuel sur ce paramètre. Cette distribution de probabilité, souvent appelée prior, est notée $[\theta]$. Il faut bien comprendre que le prior quantifie l'état de connaissance d'un expert sur le problème en main. Cela signifie que l'expert parie plus volontiers sur certaines valeurs de θ que sur d'autres. Cette information a d'autant plus de valeur que les données sont rares. Il doit être clair que le savoir de l'expert encodé dans le prior doit être tout a fait indépendant de l'échantillon en main, sinon la même source d'information interviendrait deux fois, ce qui ne serait pas cohérent

1.2.1 le paradigme bayésienne

Etant donné un modèle paramétrique d'observation $x \sim f(x/\theta)$ où $\theta \in \Theta$ un espace de dimension finie, l'analyse statistique bayésienne vise à exploiter le plus efficacement possible l'information apportée par x sur le paramètre θ pour ensuite construire des procédures d'inférence sur θ . l'information fournie par l'observation x est contenue dans la densité $f(x/\theta)$, que l'on représente classiquement sous la forme inversée de vraisemblance

$$L(\theta/x) = f(x/\theta)$$

pour traduire qu'il s'agit d'une fonction de θ qui est inconnu, dépendant de la valeur observée x . L'inversion des rôles de x et de θ par rapport à la modélisation probabiliste reflète le but premier de la statistique qui est de reconstruire le paramètre θ au vu de la réalisation aléatoire x . C'est donc pourquoi elle est naturellement liée au théorème de Bayes qui formalise l'inversion des conditionnements dans les probabilités :

Si A et E sont des événements tels que

$$p(A/E) = \frac{p(E/A)p(A)}{p(E/A)p(A) + p(E/A^c)p(A^c)}$$

Une version continue de ce résultat permet d'inverser les densités conditionnelles, à savoir,

$$g(y/x) = \frac{f(x/y)g(y)}{\int f(x/y)g(y)dy}$$

On considère ainsi que l'incertitude sur le paramètre θ d'un modèle peut être décrite par une distribution de probabilité π sur Θ appelée distribution a priori par opposition

à la distribution a posteriori qui inclut l'information contenue dans l'observation x ce qui revient à supposer que x est distribué suivant $\pi(\theta)$ que x ne soit généré suivant $f(x/\theta)$, le conditionnement implicite dans cette notation prenant alors tout son sens.

1.2.2 les avantages de l'école bayésienne

Un avantage de l'approche bayésienne est la capacité de considérer les probabilités non encore

- flexibilité concernant les hypothèses de départ et la taille de l'échantillon
- connaissance exacte de la distribution de probabilité a posteriori de θ qui permet de guider l'action clinique
- Possibilité de formuler des prédictions pour le futur
- Cette approche peut exprimer la probabilité d'événements uniques et d'événements répétables

1.2.3 les Inconvénients

Une des critiques les plus courantes à l'encontre de la méthode bayésienne est justement sa subjectivité; le but de la science étant d'obtenir des résultats indépendants du scientifique. Nous pensons que cette subjectivité a néanmoins l'avantage d'être explicite, obligeant l'utilisateur à établir clairement quels sont ses a priori. L'approche bayésienne est difficile à suivre d'une façon parfaitement rigoureuse pour deux raisons. D'abord les connaissances a priori d'un agent sont souvent floues, mal formulées et leur traduction en un modèle probabiliste numérique est très difficile. Ce problème est spécialement critique lorsqu'il faut formuler des a priori en grande dimension, car

l'intuition y est souvent mise en défaut. C'est pourquoi il est recommandé de mettre en place un cycle modélisation inférence évaluation permettant d'améliorer progressivement les modèles. Si le bon modèle n'a pas été considéré dès le départ, les inférences ne l'inventeront pas. Pour être parfaitement rigoureux, il faudrait considérer tous les modèles possibles avant de voir les données, afin d'être certain de ne pas en avoir oublié. Car oublier de considérer un modèle est équivalent à lui assigner une probabilité a priori nulle et donc une probabilité a posteriori tout aussi nulle, quelle que soit sa vraisemblance.

Le troisième grand problème de l'approche bayésienne est la difficulté calculatoire des inférences. Il est très tentant de définir un beau modèle génératif pour un problème, mais si il n'existe pas d'algorithme efficace suffisamment précis, ce modèle n'a pas beaucoup de valeur. Tout l'art est de trouver un compromis entre biais du modèle et faisabilité des inférences. Pour des problèmes difficiles, il faudrait en fait penser à la méthode d'inférence dès la phase de modélisation.

1.3 Annalyse statistique bayésienne

On nomme annalyse statistique bayésienne la démarche logique permettant de calculer ou réviser la probabilité Cette démarche est régie par l'utilisation de règles strictes de combinaison des probabilités, des quelles dérive le théorème de Baye

1.4 la règle de Bayes

Ainsi, dans sa forme la plus simple, la règle de Bayes est la conséquence mathématique directe du théorème des probabilités conditionnelles :

$$[y/\theta][\theta] = [y, \theta] = [\theta/y][y] \Rightarrow [\theta/y] = \frac{[y/\theta][\theta]}{[y]}$$

Avant l'observation, $[y]$ est la distribution prédictive a priori

$$[y] = \int_{\Theta} [y, \theta] d\theta = \int_{\Theta} [y/\theta] [\theta] d\theta$$

une fois que l'on dispose des données, l'intégrale fournit un nombre réel, la constante de normalisation, qui garantit que le posterior $[\theta/y]$ est bien une distribution de probabilité.

1.5 la loi prior et posterior

1.5.1 La loi a priori :

Le choix de la a priori est une étape fondamentale dans l'analyse bayésienne. Ce choix peut avoir différentes motivations. Les stratégies sont diverses. Elle peuvent se baser sur des expériences du passé ou sur un intuition, une idée que le particien a du phénomène aléatoire qu'il est en train de suivre. Elles peuvent être également motivées par des aspects calculabilité .

Enfin, ces stratégies peuvent également tenir compte du fait qu'on ne sait rien par le truchement des lois non informatives

1.5.2 La loi a posteriori :

La loi a posteriori C'est la loi conditionnelle de θ sachant x , Sa densité est noté $\pi(\theta/x)$, En vertu de la formule de Bayes,et on a aussi

-La loi du couple (θ, x) : Sa densité est notée $h(\theta, x)$. On a donc :

$$h(\theta, x) = f(x/\theta) \pi(\theta)$$

-La loi marginale de x . Sa densité est notée $m(x)$, On a donc :

$$m(x) = \int_{\Theta} f(x/\theta) \pi(\theta) d\theta$$

Exemple :

$$\pi(\theta) \sim \text{Beta}(\alpha, \beta)$$

$$\pi(\theta) = \theta^{\alpha-1} (1-\theta)^{\beta-1}$$

$$f(x/\theta) = \theta^x (1-\theta)^{n-x}$$

$$\pi(\theta/x) = \frac{f(x/\theta) \pi(\theta)}{\int f(x/\theta) \pi(\theta) d\theta}$$

$$\pi(\theta/x) = \frac{\theta^x (1-\theta)^{n-x} \frac{1}{\text{Beta}(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}}{\int_0^1 \theta^x (1-\theta)^{n-x} \frac{1}{\text{Beta}(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} d\theta}$$

$$= \int_0^1 \theta^{x+\alpha-1} (1-\theta)^{\beta+n-x-1}$$

$$\pi(\theta/x) \sim \text{Béta}(x + \alpha, \beta + n - x)$$

1.6 le problème de choix a priori

L'aspect de l'analyse bayésienne le plus critiqué et le plus délicat est certainement le choix de la loi a priori des paramètres ; en particulier, le recours à des lois usuelles comme la loi normale, gamma, bêta, ne peut pas être défendu comme approche systématique plus aisée. La détermination de la loi a priori donc est basée sur l'information a priori.

1.6.1 lois subjective

Précisons tout d'abord que cette démarche n'est pas forcément facile dans la pratique. L'idée est d'utiliser les données antérieures. Par exemple, dans un cadre paramétrique, cela revient à choisir une valeur particulière du paramètre. Dans un cas concret, il peut être judicieux de baser son raisonnement sur les dires d'experts, notamment à l'aide de questionnaires. Il est alors nécessaire de veiller à ce que les questions soient compréhensibles par exemple en prenant comme base les quantiles plutôt que les moments. Pour plusieurs experts, il peut être utile de pondérer leurs réponses et d'utiliser des modèles hiérarchiques. Ainsi, la difficulté ici n'est pas mathématique mais plus psychométrique pour réduire les biais sur les réponses fournies. Nous allons nous concentrer sur le second aspect de la détermination.

1.6.2 la loi conjuguée

Une des difficultés de l'approche bayésienne est le calcul de la loi a posteriori. ce calcul est facilité lorsque loi a priori et loi a posteriori ont la même forme. Dans ce cas, on parle de loi a priori conjuguée.

définition

Une famille F de lois sur Θ est dite conjuguée si, pour tout θ appartenant à cette famille, la loi $\pi(\theta/x)$ appartient également à celle-ci. Dans ce cas, le praticien induit directement la forme dès qu'il a choisi sa loi a priori.

Exemple :

$\pi(\theta)$	$f(x/\theta)$	$\pi(\theta/x)$
$G(n, \theta)$	$G(\alpha, \beta)$	$G(\alpha + n, \beta + x)$
$B(n, \theta)$	$béat(\alpha, \beta)$	$Béat(\alpha + n, \beta + x)$
$P(\theta)$	$G(\alpha, \beta)$	$G(\alpha + x, \beta + 1)$

1.7 la vraisemblance

L'inférence statistique cherche à apprendre sur la valeur dans la population d'un paramètre θ à partir d'un échantillon de données x . Inférence traditionnelle connue, $l(x/\theta)$ (fonction de vraisemblance) quantifie à quel point certaines valeurs de θ sont compatibles avec les valeurs observées x , $l(x/\theta)$ résume toute l'information que les données fournissent sur le paramètre θ .

1.7.1 principe de vraisemblance

la vraisemblance de y est une valeur qui contient toute l'information qui peut être extraite des données. L'information apportée par une observation de x sur θ est entièrement contenue dans la fonction de vraisemblance $l(x/\theta)$. De plus, si x_1 et x_2 sont deux observations qui dépendent du même paramètre θ , et telles qu'il existe une

constante c satisfaisant

$$l_1(x/\theta) = cl_2(x/\theta)$$

Pour tout x , elles apportent la même information sur θ et doivent conduire à la même inférence.

1.8 la loi prédictive

nous nous sommes concentrés sur l'inférence concernant la vraie valeur d'un paramètre. Cependant, dans beaucoup de situations, le but d'une analyse est de prévoir des valeurs d'un futur échantillon. Cependant, dans la pratique nous ne connaissons pas la valeur de θ . Nous savons seulement la distribution a posteriori de θ . Dans ce cas, la probabilité prédictive de y est donnée à partir de la distribution a posteriori $\pi(\theta|x)$ et $y \sim g(y/\theta)$ comme suit

$$g(y/x) = \int_0^1 g(y/\theta) \pi(\theta/x) d\theta$$

1.8.1 La distribution predictive a posteriori

L'inférence bayésienne quantifie l'incertitude sur θ en mobilisant deux sources d'information : l'expertise et les données. On souhaite maintenant quantifier l'incertitude sur une observation future y^* conditionnellement à l'échantillon déjà observé y . La distribution de probabilité de l'observable y^* est obtenue en multipliant sa densité d'échantillonnage $[y^*/\theta]$ par la distribution a posteriori $[\theta/y]$ et en intégrant ce produit par

rapport a θ

$$\begin{aligned} [y^*/y] &= \int_{\Theta} [y^*, \theta/y] d\theta \\ &= \int_{\Theta} [y^*/\theta, y] [\theta/y] d\theta \\ &= \int_{\Theta} [y^*/\theta] [\theta/y] d\theta \end{aligned}$$

La dernière égalité vient parce que l'observable y^* est conditionnellement indépendante des observations passées quand on dispose de θ

1.9 la loi informative

la loi informative est le point le plus délicat de l'analyse bayésienne. Il existe plusieurs procédés pour obtenir des lois informatives. Nous donnons la description de l'un des plus intéressants des procédés qui est celui des familles naturelles conjuguées.

1.10 loi non informative

Une loi non informative est une loi qui porte une information sur le paramètre à dont le poids dans l'inférence est réduit. Certains auteurs la définissent également comme une loi a priori qui ne contient aucune information sur ou encore comme une loi qui ne donne pas davantage de poids à telle ou telle valeur du paramètre.

Par exemple, supposons un ensemble fini de taille q , une loi a priori non informative pourra être une loi de la forme

$$\pi(\theta) = 1/q$$

1.10.1 la loi jeffreys

Jeffreys (1946, 1961) propose une approche intrinsèque qui évite effectivement le besoin de prendre en compte une structure d'invariance potentielle, tout en étant souve compatible lorsque cette structure existe Les lois a priori non informatives de Jeffreys sont fondées sur l'information de Fisher, donnée par $I(\theta) = E_{\theta} \left[\left(\frac{\partial \log f(x/\theta)}{\partial \theta} \right)^2 \right]$ dans le cas unidimensionnel. Sous certaines conditions de régularité, cette information est aussi égale à

$$I(\theta) = -E_{\theta} \left[\left(\frac{\partial^2 \log f(x/\theta)}{\partial \theta^2} \right) \right].$$

La loi de Jeffreys est $\pi(\theta) = \sqrt{I(\theta)}$, définie à un coefficient de normalisation près quand est propre. Elle vérifie effectivement l'exigence d'invariance par reparamétrisation. Le choix d'une loi dépendant de l'information de Fisher se justifie par le fait que $I(\theta)$ est largement accepté comme un indicateur de la quantité d'information apportée par le modèle sur θ (Fisher, 1956). Par conséquent, au moins à un niveau qualitatif, il paraît intuitivement justifié que les valeurs de θ pour lesquelles $I(\theta)$ est plus grande doivent être plus probables a priori. En d'autres termes, $I(\theta)$ mesure la capacité du modèle à discriminer entre θ via la pente moyenne de $\log f(x/\theta)$. Favoriser les valeurs de θ pour lesquelles $I(\theta)$ est plus grande équivaut à minimiser l'influence de la loi a priori et est donc aussi non informatif que possible. En fait, la loi de Jeffreys est fréquemment impropre.

Exemple

Si

$$x \sim B(n, \theta)$$

$$f(x/\theta) = \theta^x (1 - \theta)^{n-x}$$

on a

$$I(\theta) = -E_\theta \left[\left(\frac{\partial^2 \log f(x/\theta)}{\partial \theta^2} \right) \right].$$

$$\frac{\partial \log f(x/\theta)}{\partial \theta} = \frac{x}{\theta} - \frac{n-x}{1-\theta}$$

$$\frac{\partial^2 \log f(x/\theta)}{\partial \theta^2} = \left(-\frac{x}{\theta^2} + \frac{n-x}{(1-\theta)^2} \right)$$

on pose $E(x) = n\theta$

donc

$$-E_\theta \left[\left(\frac{\partial^2 \log f(x/\theta)}{\partial \theta^2} \right) \right] = \frac{n\theta}{\theta^2} + \frac{n-n\theta}{(1-\theta)^2} = n\theta^{-1} (1-\theta)^{-1}$$

$$I(\theta) = \theta^{-1} (1-\theta)^{-1}$$

donc la loi de Jeffreys pour ce modèle est :

$$\pi(\theta) = [\theta(1-\theta)]^{-\frac{1}{2}}$$

Dans le cas où θ est un paramètre multidimensionnel, on définit la matrice

d'information de Fisher, pour $\theta \in (\mathbb{R}^k)$, et $I(\theta)$ aux éléments suivants :

$$I_{ij}(\theta) = -E_\theta \left[\left(\frac{\partial^2}{\partial \theta_i \partial \theta_j} \log f(x/\theta) \right) \right] \quad i, j = 1, \dots, K$$

et la loi non informative de Jeffreys est alors définie par :

$$\pi(\theta) = [\det I(\theta)]^{\frac{1}{2}}$$

et est alors propre, car il s'agit de la distribution Bêta $(\frac{1}{2}, \frac{1}{2})$

1.11 Facteur de bayes

L'idée à l'origine de cette notion est de limiter l'importance du choix a priori de a_0

et a_1 introduits ci dessus. Le facteur de bayes est défini par

$$B_{0/1} = \frac{P^\pi(\Theta_0/X) \pi(\Theta_1)}{P^\pi(\Theta_1/x) \pi(\Theta_0)}$$

Chapitre 2

la simulation de les lois probabilités

2.1 Introduction

Ce chapitre compléter le premier chapitre propose une d'applications sur les lois de la probabilité en utilisant programme avancé à partir qui calcul les expressions mathématiques difficile et donner un graphiques pour illustrer

2.2 loi binomial

Exemple :

la loi prioir est donné par :

$$\pi(\theta) \sim \text{Bêta}(\alpha, \beta)$$

Rappele : Soient α et $\beta \in \mathbb{R}_+^*$. On appelle loi Beta de paramètres α et β la loi de probabilité absolument continue dont une densité est donnée par :

$$p(x) = \frac{x^{\alpha-1} (1-x)^{\beta-1}}{B(\alpha, \beta)} : x \in \mathbb{R}$$


Cette mesure est identifiée par la notation $\text{Bêta}(\alpha, \beta)$

on :

$$B(\alpha, \beta) = \frac{\Gamma(\alpha)\Gamma(\beta)}{\Gamma(\alpha + \beta)} = \int_0^1 x^{\alpha-1} (1-x)^{\beta-1} dx.$$

Donc :

$$\pi(\theta) = \frac{1}{\text{Bêta}(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}$$



priori Bêta(2, 3)

la vraisemblance est donné par :


$$f(x/\theta) \sim \text{Bin}(n, \theta)$$

Rapelle : Soient $n \in \mathbb{N}^*$ et $p \in [0, 1]$ On appelle la loi binomiale de paramètres

n et P la loi de probabilité discrète p telle que $p(x) = p^x (1-p)^{n-x}$

Cette mesure est identifiée par la notation $B(n, p)$

$$f(x/\theta) = \theta^x (1-\theta)^{n-x}$$



vraisemblance $Bin(2, \theta), x = 1$


la loi de posteriori est donné par :

$$\pi(\theta/x) = \frac{\theta^x (1 - \theta)^{n-x} \frac{1}{\text{Bêta}(\alpha, \beta)} \theta^{\alpha-1} (1 - \theta)^{\beta-1}}{\int_0^1 \theta^x (1 - \theta)^{n-x} \frac{1}{\text{Bêta}(\alpha, \beta)} \theta^{\alpha-1} (1 - \theta)^{\beta-1} d\theta}$$

$$\pi(\theta/x) = \frac{\theta^x (1 - \theta)^{n-x} \theta^{\alpha-1} (1 - \theta)^{\beta-1} \Gamma(\alpha + n + \beta)}{\Gamma(\alpha + x) \Gamma(\beta + n + x)}$$

$$= \frac{1}{\text{Bêta}(\alpha + x, \beta + n - x)} \theta^{\alpha+x-1} (1 - \theta)^{\beta+n-x-1}$$

Ils'agit d'une loi béat de paramètres $\text{Bêta}(\alpha + x, \beta + n - x)$



posteriori Bêta(3,4)


2.3 loi géométrique

Exemple :

la loi de prior est donné par :

$$\pi(\theta) \sim \text{Bêta}(\alpha, \beta)$$

$$\pi(\theta) = \frac{1}{B(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}$$



priori Bêta (2, 3)

la vraisemblance est donné par :


$$f(x/\theta) \sim G(n, \theta)$$

Rappale : Soit $p \in]0, 1]$ On appelle loi géométrique de paramètre p la loi de probabilité discrète p de support \mathbb{N}^* vérifiant $p(n) = p(1-p)^{n-1}$

Cette mesure est identifiée par la notation $G(p)$

on

$$f(x/\theta) = \theta(1-\theta)^{n-1}$$




vraisemblance $G(2, \theta)$

la loi de posteriori est donné par :

$$\begin{aligned}
 \pi(\theta/x) &= \frac{\theta(1-\theta)^{n-1} \frac{1}{\text{Bêta}(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}}{\int_0^1 \theta(1-\theta)^{n-1} \frac{1}{\text{Bêta}(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} d\theta} \\
 &= \frac{\theta(1-\theta)^{n-1} \theta^{\alpha-1} (1-\theta)^{\beta-1} \Gamma(\alpha+n+\beta)}{\Gamma(n+\beta-1)\Gamma(\alpha+1)} \\
 &= \frac{\theta^\alpha (1-\theta)^{n+\beta-2} \Gamma(\alpha+n+\beta)}{\Gamma(n+\beta-1)\Gamma(\alpha+1)} \\
 &= \frac{1}{\Gamma(\alpha+1, n+\beta-1)} \theta^{(\alpha+1)-1} (1-\theta)^{(n+\beta-1)-1}
 \end{aligned}$$

Il s'agit d'une loi bêta de paramètres $\text{Bêta}(\alpha+1, n+\beta-1)$



posteriori $B\acute{e}ta(3, 4)$


2.4 loi binomil negative

Exemple :

la loi de prioir est donne par :

$$\pi(\theta) \sim B\acute{e}ta(\alpha, \beta)$$

$$\pi(\theta) = \frac{1}{B(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}$$



prior Bêta (3,4)

la vraisemblance est donne par :


$$f(x/\theta) \sim \text{Binneg}(n, \theta)$$

Rappale : Soient $p \in]0, 1]$ et $k \in \mathbb{N}^*$ On appelle loi binomiale négative de paramètres k et p la loi de probabilité discrète p vérifiant $p(x) = p^n (1 - p)^x$

Cette mesure est identifiée par la notation $\text{Binneg}(n, p)$

Donc :

$$f(x/\theta) = \theta^n (1 - \theta)^x$$



vraisemblance Binomial (2, 1)


la loi de posteriori est donnée par :

$$\begin{aligned} \pi(\theta/x) &= \frac{\theta^n (1-\theta)^x \frac{1}{\text{Bêta}(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}}{\int_0^1 \theta^n (1-\theta)^x \frac{1}{\text{Bêta}(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} d\theta} \\ &= \frac{\theta^n (1-\theta)^x \theta^{\alpha-1} (1-\theta)^{\beta-1} \Gamma(x+\alpha+n+\beta)}{\Gamma(x+\beta)\Gamma(n+\alpha)} \\ &= \frac{1}{\text{Bêta}(n+\alpha, x+\beta)} \theta^{n+\alpha-1} (1-\theta)^{x+\beta-1} \end{aligned}$$

on a :

$$\frac{1}{\text{Bêta}(n+\alpha, x+\beta)} = \frac{\Gamma(x+\alpha+n+\beta)}{\Gamma(x+\beta)\Gamma(n+\alpha)}$$

Il s'agit d'une loi bêta de paramètres $\text{Bêta}(n+\alpha, x+\beta)$



posteriori $B\hat{e}ta(5, 5)$


2.5 Lois Bernoulli

Exemple :

la loi de prior est donné par

$$\pi(\theta) \sim B\hat{e}ta(\alpha, \beta)$$

$$\pi(\theta) = \frac{1}{B(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}$$



priori Bêta (2, 3)

la vraisemblance est donne par :


$$f(x/\theta) \sim Ber(x, \theta)$$

Rappale : Soit $P \in [0, 1]$. On appelle loi de Bernoulli de paramètre p la loi de probabilité discrète $P(x)$ vérifiant $P(x) = P^x(1 - P)^{1-x}$

Cette mesure est identifiée par la notation $Ber(1, P)$

on :

$$f(x/\theta) = \theta^x(1 - \theta)^{1-x}$$




vraisemblance $Ber(2, \theta)$

la loi de posteriori est donne par :

$$\begin{aligned} \pi(\theta/x) &= \frac{\theta^x (1-\theta)^{1-x} \frac{1}{B\hat{e}ta(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1}}{\int_0^1 \theta^x (1-\theta)^{1-x} \frac{1}{B\hat{e}ta(\alpha, \beta)} \theta^{\alpha-1} (1-\theta)^{\beta-1} d\theta} \\ &= \frac{\theta^x (1-\theta)^{1-x} \theta^{\alpha-1} (1-\theta)^{\beta-1} \Gamma(\alpha+1+\beta)}{\Gamma(\beta-x+1)\Gamma(x+\alpha)} \\ &= \frac{1}{B(\beta-x+1, x+\alpha)} \theta^{x+\alpha-1} (1-\theta)^{(\beta-x+1)-1} \end{aligned}$$

Il s'agit d'une loi béta de paramètres $B\hat{e}ta(\beta-x+1, x+\alpha)$



posteriori $B\hat{e}ta(2, 4)$

2.6 loi normale

Exemple :

Rappale : Soient $\lambda \in \mathbb{R}$ et $\delta \in \mathbb{R}_+^*$. On appelle loi normale de moyennem et de variance δ^2 la loi de probabilité absolument continue dont une densité est donnée par :


$$p(x) = \frac{1}{\sqrt{2\pi\delta^2}} \exp - ((x - m)^2 / 2\delta^2) : x \in \mathbb{R}$$

Cette mesure est identifiée par la notation $N(m, \delta^2)$

la loi de prioir est donné par :

$$\pi(\theta) \sim N(\mu, T^2)$$

$$\pi(\theta) = \frac{1}{\sqrt{2\pi T^2}} \exp - ((\theta - \mu)^2 / 2T^2)$$




priori $N(1, 2), \pi = 1$

la vraisemblance est donné par :

$$f(x/\theta) \sim N(\theta, \sigma^2)$$

$$f(x/\theta) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp - ((x - \theta)^2 / 2\sigma^2)$$




vraisemblance $N(\theta, 1)$, $x = 3$, $\pi = 1$

la loi de posteriori est donné par :

$$\begin{aligned} \pi(\theta/x) &= \frac{\frac{1}{\sqrt{2\pi T^2}} \exp - ((\theta - \mu)^2 / 2T^2) \frac{1}{\sqrt{2\pi \delta^2}} \exp - ((x - \theta)^2 / 2\sigma^2)}{-\infty \int^{\infty} \frac{1}{\sqrt{2\pi T^2}} \exp - ((\theta - \mu)^2 / 2T^2) \frac{1}{\sqrt{2\pi \delta^2}} \exp - ((x - \theta)^2 / 2\sigma^2) d\theta} \\ &= \frac{1}{2} \frac{\exp - ((\theta - \mu)^2 / 2T^2) \exp - ((x - \theta)^2 / 2\sigma^2)}{\sqrt{\pi \sigma^2} \sqrt{\pi T^2} \left(1/2 \frac{\sqrt{\pi} \sqrt{2} \exp - \frac{(\mu^2 + x^2 - 2\mu x)}{2(\sigma^2 + T^2)} \operatorname{csgn}(\pi T) \operatorname{csgn}(\pi \sigma)}{\pi T \pi \sigma \sqrt{\frac{\sigma^2 + T^2}{T^2 \sigma^2}}} (\operatorname{csgn}(\frac{1}{2T^2} + \frac{1}{2\sigma^2})) = 1 \right)} \\ &= \frac{1}{2} \frac{\sqrt{2} \exp - ((\theta - \mu)^2 / 2T^2) \exp - ((x - \theta)^2 / 2\sigma^2) \sqrt{T^2 + \sigma^2}}{T \sigma \sqrt{\pi}} \\ &= \frac{1}{2} \frac{\sqrt{2} \exp - \frac{1}{2} ((\theta - \mu)^2 / T^2 + (x - \theta)^2 / \sigma^2) \sqrt{T^2 + \sigma^2}}{T \sigma \sqrt{\pi}} \end{aligned}$$

$$\begin{aligned}
&= \frac{1}{2} \frac{\sqrt{2} \exp -\frac{1}{2} ((\theta^2 + \mu^2 - 2\theta\mu) / T^2 + (x^2 + \theta^2 - 2x\theta) / \sigma^2) \sqrt{T^2 + \sigma^2}}{T\sigma\sqrt{\pi}} \\
&= \frac{1}{2} \frac{\sqrt{2} \exp -\frac{1}{2} (\theta^2 (\frac{1}{\sigma^2} + \frac{1}{T^2}) - 2\theta (\frac{x}{\sigma^2} + \frac{\mu}{T^2}) + (\frac{x^2}{\sigma^2} + \frac{\mu^2}{T^2})) \sqrt{T^2 + \sigma^2}}{T\sigma\sqrt{\pi}} \\
&= \frac{1}{2} \frac{\sqrt{2} \exp -\frac{1}{2} (\theta^2 - 2\theta (\frac{\frac{x}{\sigma^2} + \frac{\mu}{T^2}}{\frac{1}{\sigma^2} + \frac{1}{T^2}}) + (\frac{\frac{x^2}{\sigma^2} + \frac{\mu^2}{T^2}}{\frac{1}{\sigma^2} + \frac{1}{T^2}})) \sqrt{T^2 + \sigma^2}}{T\sigma\sqrt{\pi}} \\
&= \frac{1}{2} \frac{\sqrt{2} \exp -\frac{1}{2} (\theta - \frac{\frac{x}{\sigma^2} + \frac{\mu}{T^2}}{\frac{1}{\sigma^2} + \frac{1}{T^2}})^2 \sqrt{T^2 + \sigma^2}}{T\sigma\sqrt{\pi}} \\
&= \frac{1}{2} \frac{\sqrt{2} \exp -\frac{1}{2} (\theta - \frac{\frac{xT^2 + \mu\sigma^2}{T^2 + \sigma^2})^2 \sqrt{T^2 + \sigma^2}}{T\sigma\sqrt{\pi}} \\
&= \frac{1}{\sqrt{\pi 2 \frac{\sigma^2 T^2}{T^2 + \sigma^2}}} \exp -\left(\frac{1}{2} (\theta - \frac{xT^2 + \mu\sigma^2}{T^2 + \sigma^2})^2\right)
\end{aligned}$$

Il s'agit d'une loi normale de paramètres $N\left(\frac{xT^2 + \mu\sigma^2}{T^2 + \sigma^2}, \frac{\sigma^2 T^2}{T^2 + \sigma^2}\right)$



$$\text{posteriori}N\left(\frac{7}{3}, \frac{2}{3}\right)$$

2.7 loi gamma

Exemple :

Rappale Soient $\lambda \in \mathbb{R}_+^*$ et $a \in \mathbb{R}_+^*$. On appelle loi Gamma de paramètres a et

λ la loi de probabilité absolument continue dont une densité est donnée par :

$$p(x) = \frac{\lambda^a}{\Gamma(a)} x^{a-1} \exp(-\lambda x)$$

Cette mesure est identifiée par la notation $\Gamma(a, \lambda)$

Γ est la fonction gamma définie par l'intégrale pour $a > 0$:


$$\Gamma(a) = \int_0^\infty t^{a-1} \exp(-t) dt.$$

on :

la loi de prior est donné par :

$$\pi(\theta) \sim \text{Gam}(\alpha, \beta)$$

$$\pi(\theta) = \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta)$$




priori Gam(2, 3)

la vraisemblance est donné par :

$$f(x/\theta) \sim \text{Gam}(v, \theta)$$

$$f(x/\theta) = \frac{\theta^v}{\Gamma(v)} x^{v-1} \exp(-x\theta)$$




vraisemblance $Gam(2, \theta)$, $x = 1$

la loi de posteriori est donné par :

$$\begin{aligned}
 \pi(\theta/x) &= \frac{\frac{\theta^v}{\Gamma(v)} x^{v-1} \exp(-x\theta) \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta)}{\int_0^\infty \frac{\theta^v}{\Gamma(v)} x^{v-1} \exp(-x\theta) \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta) d\theta} \\
 &= \frac{\theta^v x^{v-1} \exp(-x\theta) \beta^\alpha \theta^{\alpha-1} \exp(-\beta\theta)}{\Gamma(v)\Gamma(\alpha) \int_0^\infty \frac{\theta^v x^{v-1} \exp(-x\theta) \beta^\alpha \theta^{\alpha-1} \exp(-\beta\theta)}{\Gamma(v)\Gamma(\alpha)} d\theta} \\
 &= \frac{\exp(-\theta(x+\beta)) (\theta(x+\beta))^{v+\alpha}}{\theta \Gamma(v+\alpha)} \\
 &= \frac{\exp(-\theta(x+\beta)) \theta^{v+\alpha} (x+\beta)^{v+\alpha} \theta^{-1}}{\Gamma(v+\alpha)} \\
 &= \frac{(x+\beta)^{v+\alpha} \theta^{v+\alpha-1} \exp(-\theta(x+\beta))}{\Gamma(v+\alpha)}
 \end{aligned}$$

$$= \frac{(x + \beta)^{v+\alpha}}{\Gamma(v + \alpha)} \theta^{v+\alpha-1} \exp(-\theta(x + \beta))$$

Il s'agit d'une loi gamme de paramètres $G(v + \alpha, x + \beta)$



posteriori Gam(5, 3)


2.8 loi exponentielle

Exemple :

la loi de prioir est donné par :

$$\pi(\theta) \sim \text{Gam}(\alpha, \beta)$$

$$\pi(\theta) = \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta)$$



prioriGam (4, 2)

la vraisemblance est donné par :

$$f(x/\theta) \sim \exp(n, \theta)$$


Rappale : Soit $\lambda \in \mathbb{R}_+^*$ On appelle loi exponentielle de paramètre λ la loi de probabilité absolument continue dont une densité est donnée par :

$$p(x) = \lambda \exp(-\lambda x) : x \in \mathbb{R}$$

Cette mesure est identifiée par la notation $p(\lambda)$

Donc :

$$f(x/\theta) = \theta^n \exp(-\theta x)$$




vraisemblance $\exp(1, \theta)$, $x = 2$

la loi de posteriori est donné par :

$$\begin{aligned}
 \pi(\theta/x) &= \frac{\theta^n \exp(-\theta x) \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta)}{\int_0^\infty \theta^n \exp(-\theta x) \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta) d\theta} \\
 &= \frac{\theta^n \exp(-\theta x) \beta^\alpha \theta^{\alpha-1} \exp(-\beta\theta)}{\int_0^\infty \theta^n \exp(-\theta x) \beta^\alpha \theta^{\alpha-1} \exp(-\beta\theta) d\theta} \\
 &= \frac{\exp(-\theta(x+\beta)) (\theta(x+\beta))^{n+\alpha}}{\theta \Gamma(n+\alpha)} \\
 &= \frac{\exp(-\theta(x+\beta)) \theta^{n+\alpha} (x+\beta)^{n+\alpha} \theta^{-1}}{\Gamma(n+\alpha)} \\
 &= \frac{(x+\beta)^{n+\alpha}}{\Gamma(n+\alpha)} \theta^{n+\alpha-1} \exp(-\theta(x+\beta))
 \end{aligned}$$

Il s'agit d'une loi gamme de paramètres $G(n+\alpha, x+\beta)$



posteriori G (5, 4)


2.9 loi poissan

Exemple :

la loi de prior est donné par :

$$\pi(\theta) \sim \text{Gam}(\alpha, \beta)$$

$$\pi(\theta) = \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta)$$



priori Gam (2, 1)

la vraisemblance est donné par :


$$f(x/\theta) \sim p(x, \theta)$$

Rappale : Soit $\lambda \in \mathbb{R}_+$ On appelle loi de Poisson de paramètre λ la loi de probabilité discrète p de support \mathbb{N} vérifiant $p(n) = \frac{\lambda^n}{n!} \exp(-\lambda)$

Cette mesure est identifi´ee par la notation $p(\lambda)$

Donc :

$$f(x/\theta) = \frac{\theta^x}{x!} \exp(-\theta)$$




vraisemblance $p(\theta)$, $x = 1$

la loi de posteriori est donné par :

$$\begin{aligned}
 \pi(\theta/x) &= \frac{\frac{\theta^x}{x!} \exp(-\theta) \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta)}{\int_0^\infty \frac{\theta^x}{x!} \exp(-\theta) \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta) d\theta} \\
 &= \frac{\theta^x \exp(-\theta) \beta^\alpha \theta^{\alpha-1} \exp(-\beta\theta)}{x! \Gamma(\alpha) \int_0^\infty \frac{\theta^x}{x!} \exp(-\theta) \frac{\beta^\alpha}{\Gamma(\alpha)} \theta^{\alpha-1} \exp(-\beta\theta) d\theta} \\
 &= \frac{\exp(-\theta(1+\beta)) (\theta(1+\beta))^{x+\alpha}}{\theta \Gamma(\alpha+x)} \\
 &= \frac{\exp(-\theta(1+\beta)) \theta^{x+\alpha} (1+\beta)^{x+\alpha} \theta^{-1}}{\Gamma(\alpha+x)} \\
 &= \frac{\exp(-\theta(1+\beta)) \theta^{x+\alpha} (1+\beta)^{x+\alpha} \theta^{-1}}{\Gamma(\alpha+x)}
 \end{aligned}$$

$$\pi(\theta/x) = \frac{(1 + \beta)^{x+a}}{\Gamma(\alpha + x)} \theta^{x+\alpha-1} \exp(-\theta(1 + \beta))$$

Il s'agit d'une loi gamma de paramètres $G(x + \alpha, 1 + \beta)$



posteriori $G(3, 2)$

Notation :

$\Gamma(a)$	<i>fonction gamma</i> ($a > 0$)
$\det I(\theta)$	<i>déterminant de la matrice</i> $I(\theta)$
x, y	<i>variable aléatoire</i>
$E_\theta[g(X)]$	<i>espérance de</i> $g(x)$ <i>pour la loi</i> $f(x \theta)$ <i>sur</i> x
$x \sim f(x \theta)$	<i>x est distribuée suivant la loi de densité</i>
P_θ	<i>loi de probabilité, indexée par le paramètre</i> θ
Θ	<i>espace des paramètres</i>
$I(\theta)$	<i>information de Fisher</i>
$l(\theta x)$	<i>vraisemblance, en tant que fonction de</i> θ , <i>identique à</i> $f(x \theta)$
$m(x)$	<i>loi marginale</i>
$\pi(\theta)$	<i>loi a priori générique sur</i> θ
$\pi(\theta/x)$	<i>loi a posteriori générique sur</i> θ
θ, λ	<i>paramètres (lettres grecques minuscules)</i>
y^*	<i>données latentes ou manquantes</i>
p^π	<i>facteur de bayes</i>

Conclusion Générale

Le but de cette mémoire est d'étudier avec l'inférence statistique en utilisant former la recherche Bayes, car il fournit plus d'objectivité dans la méthode statistique. Comme nous avons étudié les applications et la simulation numérique pour calculer les probabilités de plusieurs façons.

Bibliographie

- [1] Christian P Robert (2006). Le choix bayésien Principe et pratique.25-24, 49-48 ,584 ,587.
- [2] Jerome Dupuis. (2007). Statistique bayésienne et algorithmes. 5-4
- [3] Jean Michel Marin, Christian P Robert. Paris. Les bases de la statistique bayésienne. 4
- [4] Judith ROUSSEAU. (2010). STATISTIQUE BAYÉSIENNE. 22, 39.
- [5] Christian P Robert (2006).pratique du calcule bayésienne.33-31, 40-34
- [6] Mme halil Néé khorsi Rachida .2011.inference bayesienne en series chronologiques.10-11
- [7] pierre Bunouf.2006.Lois bayésiennes a priori dans un plan binomial séquentiel 6,9,12.
- [8] Christian P Robert, Jean Michel Marin, Gilles CELEUX. SÉLECTION BAYÉSIENNE DE VARIABLE EN RÉGRESSION LINÉAIRE. 61.
- [9] Laurence GRAMMONT. (2004). COURS DE PROBABILITÉ 2ième année d'économie et de gestion, semestre 2. 7,8,9,10.
- [10] A Mallet, A J Valleron, F Carrat, S Tézenas, V Morice. (2014). Université Pierre et Marie Curie Biostatistique, 100