



N° Attribué par la bibliothèque

République Algérienne Démocratique et Populaire

Ministère de l'enseignement supérieure et de la recherche scientifique
Année univ.: 2016/2017



Sur l'estimation sous certaines classes de fonction de perte équilibrée généralisée

Mémoire présenté en vue de l'obtention du diplôme de

Master Académique

Université Dr Tahar Moulay - Saïda

Discipline : MATHÉMATIQUES

Spécialité : ASSPA

par

Cherifi Omar El Farouk¹

1. e-mail : cherifi.omar74@gmail.com

Dr.Kouider Djerfi

Soutenue le 24 Mai 2017 devant le jury composé de

N. Ait Ouali	Université Dr Tahar Moulay - Saïda	Président
K. Djerfi	Université Dr Tahar Moulay - Saïda	Encadreur
F. Madani	Université Dr Tahar Moulay - Saïda	Examineur
F. Mokhtari	Université Dr Tahar Moulay - Saïda	Examinatrice

Remerciements

Je remercie, en premier lieu, notre Dieu qui nous a donné de la force pour effectuer le présent travail.

*En second lieu, je tenée à adresser mon remerciement à mon encadreur **D.r.Kouider Djerfi** pour son aide et ses conseils, en saluant en lui son savoir faire, ses compétences et ses connaissances dont il m'a fait en profiter.*

*Je remercie mes enseignant examinateur de mon mémoire **N.Ait ouali**, **F.Madani** et **F.Mokhtari** qui nous a fait l'honneur de bien vouloir accepter de juger ce modeste travail.*

Je remercie mes très chers parents, qui ont toujours été là pour moi.

*J'adresse mes sincères remerciements à tous Les membres du laboratoire de mathématiques et a la tête le directeur **Pr.A.Kandouci**.*

Je remercie également tous mes enseignants et les enseignantes de départements de Mathématiques qui ont Aidez-nous à succès, par leurs paroles, leurs écrits, leurs conseils et leurs critiques.

Merci à tous les collègues étudiantes et étudiants de Mathématiques. Enfin, à tous les personnes qui me aidé lors de la réalisation de ce modeste travail.

«Merci à tous»

Table des matières

Introduction	9
1 Introduction à la statistique bayésienne	13
1.1 les principes bayésien	16
1.1.1 L'inférence bayésienne	16
1.1.2 Loi jointe et loi a posteriori	17
1.1.3 Principe de vraisemblance et d'exhaustivité	18
1.2 Une introduction à la théorie de la décision	21
1.2.1 La fonction de perte et risque	21
1.2.2 Les fonctions de perte usuelles	22
1.2.3 Fonction de perte intrinsèque	24
1.2.4 Estimateur bayésien (EB)	26
1.2.5 Deux optimalités minimaxité et admissibilité	27
1.2.6 Le cas particulier du modèle normal	33
1.2.7 Espace des paramètres restreint	34
1.2.8 Estimation du coût	35
2 Les estimateurs de type Stein	37
2.1 Innadmissibilité de l'estimateur usuel pour $p \geq 3$	37
2.1.1 la variance connue	37
2.1.2 La variance inconnue	41
2.2 Les estimateurs sphériquement symétriques	44

3	Probleme reliée à la fonction de perte	51
3.1	Clarifiez le problème	51
3.2	Formulation du probleme	52
3.3	L'hypothèse de normalité	54
3.4	Formulation du problème générale de l'estimation admissible avec la perte quadratique	54
4	Sur l'estimation sous certaines classes de fonction de perte équilibrée généralisée	59
4.1	Sur l'estimation sous certaines classes de fonction de perte équilibrée pondérée	59
4.1.1	Admissibilité et dominance	60
4.1.2	Minimaxité	64
4.2	Sur l'estimation de bayes sous certaines classes de fonction de perte équilibrée généralisée	69
4.2.1	Estimation de bayes sous la perte équilibrée	70
4.2.2	Quelques applications	71
4.3	La fonction de perte équilibrée prolongée	78
5	Applications	81
5.1	L'estimateur de bayes minimax	81
5.2	La performance de l'estimateur de type Stein par rapport a celle de moindre carré	84
5.2.1	L'estimateur de (MC)	85
5.2.2	L'estimateur de (JS)	85
5.2.3	Le risque de l'estimateur de (MC)	85
5.2.4	Le risque de l'estimateur de (JS)	86
5.2.5	La comparaison des risques	88

TABLE DES MATIÈRES	7
<u>5.3 L'estimation de paramètre de la loi de Bernaulli sous la fon-</u>	
tion de perte équilibrée de Zellner	91
5.3.1 L'estimateur de bayes	91
5.3.2 Admissibilité	93
5.3.3 Minimaxité	95
Conclusion et prespectives	99

Introduction

La formule de Bayes est apparue pour la première fois en 1761, dans le cadre de l'exemple binomial, exposé par [Thomas Bayes](#), et publié de façon posthume par son ami [R. Price](#) en 1763. [Pierre Simon Laplace](#) redécouvrit ensuite cette formule dans une plus grande généralité en 1773, sans, semble-t-il, avoir connaissance des travaux précédents de Bayes. L'utilisation du principe bayésien devient alors courant pendant le siècle suivant, comme le rapporte Stigler (1986), mais des critiques commencèrent à émerger vers la fin du **XIX**ème siècle, comme par exemple dans Venn (1886) ou Bertrand (1889), en particulier sur le choix de la loi a priori uniforme et des paradoxes de reparamétrisation qui en résultent.

Puis, malgré des formalisations plus poussées du paradigme bayésien par [Edgeworth](#) et [Karl Pearson](#) au tournant du siècle et plus tard par [Keynes](#) (1921), le début du **XX**ème siècle fut surtout marqué par

Tout d'abord, [Kolmogorov](#), qui proposa dans les années 1920 une axiomatisation de la théorie des probabilités semblant contredire le paradigme bayésien et la notion de probabilité subjective, ensuite par Fisher qui s'éloigna de l'approche bayésienne en 1912 et définissant la fonction de vraisemblance en 1922, puis en développant la Statistique fiduciaire en 1930, et qui ne révisa jamais son opinion négative sur la Statistique bayésienne. Cette op-

position paraît quelque peu paradoxale, car la Statistique Inductive tentait, en un certain sens de surmonter la difficulté de choisir une loi a priori en la construisant à partir de la fonction de vraisemblance (Seidenfeld en 1992), dans le même esprit que les approches non informatives de Jeffreys (1939) et Bernardo (1979).

Le phénomène de Stein est dû à l'utilisation de la fonction de coût quadratique, qui permet à l'estimateur dominant de tirer profit des autres composantes, même si celles-ci sont indépendantes et correspondent à des problèmes d'estimation sans rapport entre eux.

Stein démontré l'admissibilité de l'estimateur usuel pour ($p=2$) en (1955), et puis James et Stein en (1961) exhibèrent un estimateur qui domine uniformément $\beta_0(X) = X$ sous le cout quadratique pour $p \geq 3$ dans le cas gaussien.

La fonction de perte prend un nouveau sens en (1994), Zellner propose la fonction de perte équilibrée quadratique qui relie entre les deux critère de comparaison (la qualité d'ajustement de modèle et la précision de l'estimateur), avec une fonction de poids réduite, et un estimateur a priori (référence) de moindre carré, et puis en (1995) Shalabch proposé la fonction de perte prédictive, qui mesure la corrélation entre les deux critère de comparaison, cette dernière fonction introduit le concept simultanée de la prévision des valeurs actuelles et valeurs moyennes, enfin en (2005) Shalabch proposé la fonction de perte équilibré prolongée.

On s'intéresse en générale au l'estimateur de type Stein et la fonction de perte équilibré dans un cas généralisée (le choix de perte est arbitraire).

Dans le premier chapitre, nous présentons un rappel sur le paradigme bayésienne et l'estimateur de bayes, puis dans la théorie de décision on a défini la fonction de perte et la fonction de risque ou (coût) avec quelques exemples, et les deux notions principales d'optimalité (l'admissibilité et la minimaxité) avec quelques lemmes et propositions, à la fin de ce chapitre j'ai parlé de l'estimation de coût.

Le premier chapitre donne l'occasion de soulever le paradoxe de Stein, alors le deuxième chapitre explique l'idée de Stein en ce qui concerne l'admissibilité de l'estimateur usuel quand ($p=2$), et l'inadmissibilité quand ($p>2$) avec des démonstrations détaillées, ce qui explique l'idée fondamentale de l'amélioration de l'estimateur usuel, et j'ai donné la classe de ces estimateurs admissibles (la famille de type Stein) et les estimateurs sphériquement symétriques.

les critiques qu'il a subies de Stein en ce qui concerne la fonction de perte quadratique, et la distribution gaussienne sont indéniables, donc le troisième chapitre illustre le problème relatif à la fonction de perte l'idée de cela donne une fonction ρ en fonction de la fonction de perte quadratique sous des conditions on va étudier l'admissibilité de l'estimateur de type Stein, et à la fin de ce chapitre on va donner une condition concernant l'absence de normalité.

l'outil principal dans les chapitres précédents est la fonction de perte, donc le quatrième chapitre représente le cœur de ce mémoire, il contiendra la nouvelle conception de la fonction de perte c'est la fonction de perte équilibrée

estimateur a priori "référence" l'idée ces l'amélioration de l'estimateur usuel et la projection des propriétés d'admissibilité et de minimaxité dans le cas particulière "déséquilibré" ($w=0$), se qu'on va faire ces la généralisation de cette fonction de perte, a la fin de ce chapitre pour leur utilisation dans l'application de dernier chapitre on a définit la fonction de perte équilibrée prolongée proposé par Shalabch en 2006.

Enfin, le dernier chapitre est consacré à la partie "Applications", dans lequel on va comparer l'estimateur de type Stein avec d'autre estimateur sous certaines classes de fonction de perte équilibrée généralisée, dans le cas ou on a l'absence de normalité.

Chapitre 1

Introduction à la statistique bayésienne

Comparée à la modélisation probabiliste, l'analyse statistique se ramène fondamentalement à une inversion, car elle doit déterminer les causes-réduites aux paramètres du mécanisme probabiliste générateur-à partir des effets-résumés par les observations¹. En d'autres termes, quand nous observons un phénomène aléatoire contrôlé par le paramètre β , une méthode statistique permet de déduire de ces observations une inférence (c'est-à-dire, en résumé, une caractérisation) sur β , alors que la modélisation probabiliste caractérise le comportement des observations futures conditionnellement à β . Ce caractère d'inversion propre à la Statistique apparaît de façon évidente dans la notion de fonction de **vraisemblance**, car d'un point de vue formel, il s'agit simplement d'une densité réécrite dans le bon ordre,

$$L(\beta, x) = f(x, \beta) = \prod_{i=1}^n (f(x_i, \beta)) \quad (1.1)$$

soit donc comme fonction de β qui est inconnu, dépendant de la valeur observée x .

1. À l'époque de Bayes et de Laplace, c'est-à-dire à la fin du **XVIII**ème siècle, la Statistique était souvent appelée Probabilités inverses, à cause de cette perspective.

Historiquement l'approche fiduciaire de Fisher (1956) se fonde aussi sur cette inversion . Une description générale de l'inversion des probabilités est donnée par le théorème de Bayes : Si A et E sont des événements tels que $\mathbb{P}(E) \neq 0$, $\mathbb{P}(A/E)$ et $\mathbb{P}(E/A)$ sont reliés par :

$$\begin{aligned} \mathbb{P}(A/E) &= \frac{\mathbb{P}(E/A)\mathbb{P}(A)}{\mathbb{P}(E/A)\mathbb{P}(A) + \mathbb{P}(E/A^c)\mathbb{P}(A^c)} \\ &= \frac{\mathbb{P}(E/A)\mathbb{P}(A)}{\mathbb{P}(E)} \end{aligned}$$

En particulier,

$$\frac{\mathbb{P}(A/E)}{\mathbb{P}(B/E)} = \frac{\mathbb{P}(E/A)}{\mathbb{P}(E/B)} \tag{1.2}$$

quand $\mathbb{P}(A) = \mathbb{P}(B)$. Obtenir ce résultat à partir des axiomes de la Théorie des Probabilités est trivial. Il s'agit cependant de l'étape conceptuelle la plus importante dans l'histoire de la Statistique, constituant la première inversion des probabilités. L'équation (1.2) exprime le fait fondamental que, pour deux causes équiprobables, le rapport des probabilités pour un effet donné est égal au rapport des probabilités de ces deux causes. Ce théorème est aussi un principe d'actualisation, car il décrit la mise à jour de la **vraisemblance** de A de $\mathbb{P}(A)$ vers $\mathbb{P}(A/E)$, une fois que E a été observé. Bayes (1763) donne en réalité une version continue de ces résultats, à savoir, pour deux variables aléatoires x et y, de distributions conditionnelle² $f(x/y)$ et marginale $g(y)$, la distribution conditionnelle de y sachant x est

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

Bien que ce théorème d'inversion soit naturel d'un point de vue probabiliste, Bayes et Laplace sont allés plus loin et ont considéré que l'incertitude sur le

2. Souvent nous remplacerons distribution par densité, supposant que plus tard le concept sera mieux défini par rapport à la mesure naturelle dominante, comme la mesure de Lebesgue. C'est seulement dans un contexte plus avancé, comme pour la mesure de Haar (une connaissance plus approfondie de la théorie de la mesure sera nécessaire).

π sur Θ , appelée distribution a priori. L'inférence est alors fondée sur la distribution de β conditionnelle à x , $\pi(\beta/x)$, appelée distribution a posteriori définie par

$$\pi(\beta/x) = \frac{f(x/\beta)\pi(\beta)}{\int f(x/\beta)\pi(\beta)d\beta} \quad (1.3)$$

Notons que $\pi(\beta/x)$ est ainsi proportionnelle à la distribution de x conditionnellement à β , qui est aussi la vraisemblance, multipliée par la distribution a priori de β . (la généralité de (1.3) été perçue par Laplace , qui la développera plus avant). La contribution principale apportée par un modèle statistique bayésien est donc de considérer en sus une distribution aléatoire pour les paramètres.

Un modèle statistique bayésien est constitué d'un modèle statistique paramétrique $f(x, \beta)$, et d'une distribution a priori pour les paramètres $\pi(\beta)$.

En termes statistiques, le théorème de Bayes actualise donc l'information sur β en extrayant l'information contenue dans l'observation x . Son impact provient de la décision audacieuse de mettre causes et effets sur le même niveau conceptuel, puisque les deux sont aléatoires. Du point de vue de la modélisation statistique, il y a donc peu de différences entre observations et paramètres, car les manipulations conditionnelles permettent l'échange de leurs rôles respectifs. Notons que historiquement, cette idée que les paramètres sont aléatoires peut être perçue comme allant à l'encontre du déterminisme athée de Laplace³, ainsi que des conceptions religieuses de Bayes, qui était un ecclésiastique non-conformiste. En imposant cette modification fondamentale de la perception du phénomène aléatoire, ces deux mathématiciens ont créé l'analyse statistique moderne et plus particulièrement, l'analyse bayésienne.

3. "Nous devons envisager l'état présent de l'Univers comme un effet de l'état antérieur et comme la cause de l'état suivant." -Laplace (1795).

métrique. Elle met généralement en oeuvre des distributions a priori sur des espaces fonctionnels comme les processus de Dirichlet.

1.1 les principes bayésien

1.1.1 L'inférence bayésienne

La statistique bayésienne est une approche statistique fondée sur l'inférence bayésienne. On utilise le terme de bayésienne pour la différencier de la statistique fréquentiste (ou statistique classique) qui ne sait traiter que les grands échantillons (où elle donne les mêmes résultats que la bayésienne par des procédés moins coûteux en calcul). La statistique bayésienne est surtout utilisée lorsque l'on n'a que des petits échantillons, typiquement quand chaque observation est elle-même très coûteuse (par exemple campagne de prospection pétrolière par voie sismique). Contrairement à la statistique classique, elle n'exige pas au départ qu'on se fixe une hypothèse précise à confirmer ou infirmer, ce qui la rend utile en L'exploration de données⁴ L'inférence statistique consiste à induire les caractéristiques inconnues d'une population à partir d'un échantillon issu de cette population, et L'inférence bayésienne est une méthode d'inférence permettant de déduire la probabilité d'un événement à partir de celles d'autres événements déjà évalués. Elle s'appuie principalement sur le théorème de Bayes,

Définition 1.1.1. *Un modèle statistique est une description mathématique approximative du mécanisme qui a généré les observations, que l'on suppose être un processus stochastique et non un processus déterministe. Il s'exprime*

4. L'exploration de données connue aussi sous l'expression de fouille de données, forage de données, prospection de données, data mining, ou encore extraction de connaissances à partir de données, a pour objet l'extraction d'un savoir ou d'une connaissance à partir de grandes quantités de données, par des méthodes automatiques ou semi-automatiques.

1.1.2 Loi jointe et loi a posteriori 17

généralement à l'aide d'une famille de distributions et d'hypothèses sur les variables aléatoires X_1, \dots, X_n . Chaque membre de la famille est une approximation possible, l'inférence consiste donc à déterminer le membre qui s'accorde le mieux avec les données.

Les types principaux : modèle linéaire, modèle linéaire généralisé, modèle multi-niveau, modèle d'équation structurelle, modèle mixte.

Définition 1.1.2. (Modèle classique) On se place dans un espace probabilisé paramétrique classique avec, \mathcal{X} désigne l'espace des données, Θ celui des paramètres β inconnu,

$$X \in (\mathcal{X}, \mathcal{A}, \{\mathbb{P}_\beta, \beta \in \Theta\})$$

Exemple 1. (Le modèle de régression linéaire)

un modèle de régression linéaire est un modèle de régression qui cherche à établir une relation linéaire entre une variable, dite expliquée, et une ou plusieurs variables, dites explicatives, on rencontre principalement trois types de notations, simple (ou scalaire), vectoriel et matricielle, le modèle s'écrit alors :

$$Y = \beta X + \epsilon$$

La variable Y est appelée variable expliquée, variable dépendante, variable endogène ou encore réponse. Les variables X sont appelées variables explicatives, variable indépendante, variables exogènes ou encore prédicteurs. ϵ est appelé terme d'erreur ou perturbation.

On note généralement $\tilde{\beta}$ le vecteur des paramètres estimés. On définit la valeur de prévision ajustée $\hat{Y} = X\tilde{\beta}$ et le résidu comme la différence entre la valeur observée et la valeur prédite $\hat{\epsilon} = Y - \hat{Y}$.

1.1.2 Loi jointe et loi a posteriori

Définition 1.1.3. (La loi a priori) est une loi de probabilité π qui résume toute l'information disponible sur le paramètre d'intérêt β .

Définition 1.1.4. Dans le modèle classique, la loi **jointe** de (X, β) s'écrit :

$$\lambda_\pi(X, \beta) = f(X, \beta)\pi(\beta)$$

$$\pi(\beta/X) = \frac{f(X, \beta)\pi(\beta)}{\underbrace{\int_{\Theta} f(X, \beta)\pi(\beta)d\beta}_{*}}$$

La quantité (*) est la loi marginale de X et est une constante de normalisation de la loi a **posteriori**, indépendante de β . Nous ajoutons que par construction la loi a **posteriori** est absolument continue par rapport à la loi a priori π .

Remarque 1.1.1. Une loi impropre est une loi qui veifié :

$$\int_{\Theta} \pi(\beta)d\nu(\beta) = +\infty$$

avec ν est une mesure σ -finie. La loi a priori peut être impropre, ce choix de type de loi n'a donc plus d'intérêt que calculatoire et s'interprète difficilement. Nous verrons par la suite que la construction de lois non informative peut conduire à des lois a priori de ce type.

Définition 1.1.5. (Lois non informatives)

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

Exemple 2. Par exemple, supposons T un ensemble fini de taille q , une loi a priori non informative pourra être une loi de la forme :

$$\mathbb{P}(\beta_i) = 1/q$$

On a l'équiprobabilité, les valeurs possibles de β se voit attribuer le même poids.

1.1.3 Principe de vraisemblance et d'exhaustivité

Deux principes fondamentaux sont respectés par le paradigme bayésien : le principe de vraisemblance et le principe d'exhaustivité.

Définition 1.1.6. On appelle statistique exhaustive une statistique⁵ $T(X)$ telle que la densité de x se décompose sous la forme :

$$f(X, \beta) = h(X, T(X)) \cdot g(T(X), \beta)$$

cette égalité est connu sous le nom "Théorème de factorisation".

Remarque 1.1.2. Une statistique exhaustive $T(x)$ contient toute l'information apportée par x sur β . Selon le théorème de factorisation, sous certaines conditions de régularité, on peut écrit $\pi(\beta/X) = \pi(\beta/T(X))$ en termes informationnels.

Principe d'exhaustivité⁶ Deux observations x et y donnant la même valeur d'une statistique exhaustive T , c'est-à-dire telles que $T(x) = T(y)$, doivent conduire à la même inférence sur β .

Principe de vraisemblance

Ce deuxième principe est en partie une conséquence du principe d'exhaustivité. Il peut être attribué à Fisher (1959) ou même à Barnard (1949), mais il a été formalisé par Birnbaum (1962). Il est fortement défendu par Berger et Wolpert (1988) qui ont fourni une étude approfondie du sujet. Elle désigne de façon générale, l'ensemble des inférences possibles sur β .

Principe de vraisemblance :

L'information apportée par une observation de x sur β est entièrement contenue dans la fonction de vraisemblance $l(\beta, x)$ De plus, si $x_1 = x_1^1, \dots, x_1^n$ et $x_2 = x_2^1, \dots, x_2^n$ sont deux observations qui dépendent du même paramètre

5. C'est-à-dire une fonction des données

6. **L'importance :** Lorsqu'on utilise des lois impropres, le comportement d'une statistique peut être capricieux. Par exemple, si on considère un paramètre de la forme suivante $\beta(\beta_1, \beta_2)$ avec $\pi(\beta)$ est un loi impropre et pour T une statistique exhaustive pour β_1 , nous pouvons écrire : $f(X/\beta_1, \beta_2) = g(X/\beta_2) \cdot f(T/X)$

$$l_1(\beta, x_1) = cl_2(\beta, x_2)$$

pour tout β , elles apportent la même information sur β et doivent conduire à la même inférence. Notons que le principe de vraisemblance n'est valide que lorsque

- i) l'inférence concerne le même paramètre β .
- ii) β prend en compte tous les facteurs inconnus du modèle.

Et cela accueillerait favorablement l'occasion de parler de l'estimateur de maximum de vraisemblance.

Définition 1.1.7. (*L'estimateur de maximum de vraisemblance (MV)*)

Un estimateur $\hat{\beta}_{MV}$ est appelé un estimateur du maximum de vraisemblance de β , si

$$\hat{\beta}_{MV} = \arg \max_{\beta \in \Theta} L(\beta, X)$$

Noter qu'afin de résoudre l'équation que le gradient soit nulle, il faut déterminer la dérivée d'un produit de n fonction, ce qui peut être un calcul compliqué, pour éviter ce problème nous nous concentrons habituellement à maximiser la log-vraisemblance

$$L(\beta, X) = \log L(\beta, X)$$

au lieu de la vraisemblance puisque la fonction (log) est monotone, la vraisemblance et la log-vraisemblance ont les maximums et les minimums pour les même β , donc c'est un avantage.

Dérivation du principe de vraisemblance

Une justification du principe de vraisemblance à été avancée par Birnbaum (1962) qui a établi que le principe de vraisemblance est une conséquence du

Principe de conditionnement :

Si deux expériences sur le paramètre β , noté ξ_1 et ξ_2 sont possibles et si on choisit une de ces expériences avec probabilité \mathbb{P} , l'inférence sur β ne doit dépendre que de l'expérience choisie.

Il semble difficile de refuser ce principe quand l'expérience choisie est connue, comme on peut constater dans l'exemple classique de (Cox (1958)).

1.2 Une introduction à la théorie de la décision

1.2.1 La fonction de perte et risque

Définition 1.2.1. *La fonction de perte est une fonction mesurable de $(\Theta \times \mathcal{D})$ à valeurs réelles positives :*

$$L : \Theta \times \mathcal{D} \rightarrow \mathbb{R}^+$$

avec \mathcal{D} l'espace de décisions. Elle est définie selon le problème statistique étudié.

Définition 1.2.2. *La fonction de risque d'un estimateur $\tilde{\beta}$ de β , est définie par :*

$$R(\beta, \tilde{\beta}) = \mathbb{E}_\beta[L(\beta, \tilde{\beta})] = \int \dots \int L(\beta, \tilde{\beta}(x_1 \dots x_n)) d\mathbb{P}_\beta(x_1) \dots d\mathbb{P}_\beta(x_n)$$

Il existe plusieurs types de risque comme le risque fréquentiste, le risque à posteriori et le risque intégré qu'on va prendre comme un exemple.

Exemple 3. *(Le risque intégré)*

le risque intégré à une fonction de perte donnée est défini par :

$$r(\pi, \tilde{\beta}) = \int_{\Theta} R(\beta, \tilde{\beta}) d\pi(\beta)$$

Proposition 1.2.1. *Un estimateur bayésien est un estimateur vérifié :*

$$r(\pi, \beta^\pi) = \inf_{\tilde{\beta} \in \mathcal{D}} r(\pi, \tilde{\beta})$$

La fonction de perte quadratique

Définition 1.2.3. *La fonction de perte quadratique est la fonction définie par :*

$$L(\beta, \tilde{\beta}(x)) = (\beta - \tilde{\beta}(x))^2$$

une variante de cette fonction est une fonction de perte quadratique pondérée de la forme, $L(\beta, \tilde{\beta}(x)) = q(\beta)(\beta - \tilde{\beta}(x))^2$, avec $q(\beta)$ est une fonction de poids positive.

Remarque 1.2.1. *La fonction de risque associé à la fonction de perte quadratique, c'est rien que l'erreur moyenne quadratique.*

Proposition 1.2.2. *Sous l'hypothèse de perte quadratique, l'estimateur de bayes $\beta^\pi(x)$ de β associé a la loi a priori π est la moyenne a posteriorie de β .*

$$\beta^\pi(x) = \mathbb{E}^{\pi(\cdot/x)}(\beta) = \int_{\beta \in \Theta} L(\beta, \tilde{\beta}(x)) \pi(\beta/x) d\beta$$

Démonstration :

Par définition, l'estimateur de bayes minimise le risque a posteriorie i.e $\rho(\pi, \tilde{\beta}) = \mathbb{E}^{\pi(\cdot/x)}[L(\beta, \tilde{\beta}(x))]$. Sous l'hypothèse de risque quadratique on a :

$$\begin{aligned} \rho(\pi, \tilde{\beta}) &= \mathbb{E}^{\pi(\cdot/x)}[(\beta - \tilde{\beta}(x))^2] \\ &= \mathbb{E}^{\pi(\cdot/x)}(\beta^2) - 2\tilde{\beta}(x)\mathbb{E}^{\pi(\cdot/x)}(\beta) + \tilde{\beta}^2(x) \end{aligned}$$

On remarque que la deuxième formule est un polynome de second degré en $\tilde{\beta}(x)$, il sera minimum en $\mathbb{E}^{\pi(\cdot/x)}(\beta)$.

La fonction de perte absolue

Définition 1.2.4. *La fonction de perte absolue (perte L^1), est la fonction définie par :*

$$L(\beta, \tilde{\beta}(x)) = |\beta - \tilde{\beta}(x)|$$

1.2.2 Les fonctions de perte usuelles

Proposition 1.2.3. ~~sous l'hypothèse de perte L^1 , l'estimateur de Bayes $\beta^\pi(x)$~~ 23

de β associé à la loi a priori π est la médiane de $\pi(\beta/X)$

Démonstration :

On a par définition :

$$\begin{aligned}\rho(\pi, \tilde{\beta}) &= \int_{\beta \in \Theta} |\beta - \tilde{\beta}(x)| \pi(\beta/x) d\beta \\ &= \int_{-\infty}^{\tilde{\beta}} (\tilde{\beta} - \beta(x)) \pi(\beta/x) d\beta + \int_{\tilde{\beta}}^{+\infty} (\beta - \tilde{\beta}(x)) \pi(\beta/x) d\beta\end{aligned}$$

est comme $\rho \mapsto \rho(\pi, (\tilde{\beta}/X))$ est convexe et dérivable μ -presque partout, il suffit la encore de déterminer les points critiques :

$$\frac{\partial \rho(\pi, \tilde{\beta}(x))}{\partial \tilde{\beta}} = \int_{-\infty}^{\tilde{\beta}} \pi(\beta/x) d\beta - \int_{\tilde{\beta}}^{+\infty} \pi(\beta/x) d\beta$$

Donc
$$\frac{\partial \rho(\pi, \tilde{\beta}(x))}{\partial \tilde{\beta}} = 0 \iff \mathbb{P}^\pi(\beta \leq \tilde{\beta}/X) = \mathbb{P}^\pi(\beta \geq \tilde{\beta}/X).$$

Corollaire 1.2.1. L'estimateur de Bayes β^π associé à π et au perte quadratique pondéré est

$$\beta^\pi(x) = \frac{\mathbb{E}^\pi(\omega(\beta))\beta/x}{\mathbb{E}^\pi(\omega(\beta))/x}$$

La fonction de perte 0-1

Cette fonction de perte est utilisé dans le contexte des testes, un test est la donnée d'une partition de Θ en Θ_0 et Θ_1 avec $\beta \in H_i$ correspond à l'hypothèse H_i , H_0 est appelée l'hypothèse nulle, le principe du test (décisions) $\tilde{\beta}$, est défini comme suit :

$$\begin{cases} \tilde{\beta} = 0 & \text{si } \beta \in \Theta_1 \\ \tilde{\beta} = 1 & \text{si } \beta \in \Theta_0 \end{cases}$$

$$L(\pi, \tilde{\beta}) = \mathbb{I}_{\beta \in \Theta_1} \times \mathbb{I}_{\tilde{\beta}=0} + \mathbb{I}_{\beta \in \Theta_0} \times \mathbb{I}_{\tilde{\beta}=1}$$

Remarque 1.2.2. Le risque à posteriori est alors le suivant :

$$\rho(\pi, \tilde{\beta}) = \mathbb{I}_{\tilde{\beta}=0} \mathbb{P}^\pi(\Theta_1/X) + \mathbb{I}_{\tilde{\beta}=1} \mathbb{P}^\pi(\Theta_0/X)$$

Ainsi que l'estimateur de bayes associé a cette fonction de perte, est défini par :

$$\beta^\pi(X) = 1 \iff \mathbb{P}^\pi(\Theta_0/X) \leq \mathbb{P}^\pi(\Theta_1/X)$$

C'est à dire que l'estimation permet d'accepter H_0 , si c'est l'hypothèse la plus probable à posteriori, ce qui est une reponse naturelle.

1.2.3 Fonction de perte intrinsèque

Nous nous plaçons dans le cas où $X/\beta \sim f(X, \beta)$, avec f est une fonction de densité, la fonction de perte est définie comme suit :

$$L(\beta, \tilde{\beta}) = d(f_\beta, f_{\tilde{\beta}})$$

La notion de perte intrinsèque provient de l'exigence d'invariance par transformation monotone inversible sur les données, les distances et donc les fonctions de perte, utilisées doivent donc être inchangées par l'action d'un C^1 -diffeomorphisme sur \mathcal{X} , ainsi pour $y = g(x)$ et $X \sim f_\beta$ où g est un C^1 -diffeomorphisme, on note $y \sim g_\beta(y) = f_\beta(g^{-1}(y)) \left| \frac{dx}{dy} \right|$ pour une perte intrinsèque, la distance entre f_β et $f_{\beta'}$ est la même que celle entre g_β et $g_{\beta'}$, pour un g donné, ceci correspond à une distance entre distributions (et non plus entre densités). L'invariance par C^1 -diffeomorphisme est vérifiée, pour les distances précédentes à l'exception de la norme L^2 , nous donnons la dé-

$$\begin{aligned} d_1(g_\beta, g_{\beta'}) &= \int |f_\beta(g^{-1}(y)) - f_{\beta'}(g^{-1}(y))| \left| \frac{dx}{dy} \right| dy \\ &= \int |f_\beta(x) - f_{\beta'}(x)| dx \\ &= d_1(f_\beta, f_{\beta'}) \end{aligned}$$

Définition 1.2.6. La fonction de perte intrinsèque est une fonction définie à partir d'une distance entre distributions, c'est à dire invariante par transformation monotone inversible, définie par :

$$L(\beta, \tilde{\beta}) = d(f_\beta, f_{\tilde{\beta}})$$

Exemple 4. (Distance d'Hellinger de lois normale)

En notant Φ_{μ, σ^2} la de la loi $\mathcal{N}(\mu, \sigma^2)$ et $\beta = (\mu, \sigma^2)$ nous avons :

$$\begin{aligned} d_H^2(\Phi_\beta, \Phi_{\tilde{\beta}}) &= \int_{\mathbb{R}} \left(\sqrt{\Phi_\beta} - \sqrt{\Phi_{\tilde{\beta}}} \right)^2 dx \\ &= 2 - 2 \int_{\mathbb{R}} \sqrt{\Phi_\beta - \Phi_{\tilde{\beta}}} dx \\ &= 2 - \frac{2}{\sqrt{2\pi\sigma\tilde{\sigma}}} \underbrace{\int_{\mathbb{R}} \exp\left(-\frac{(x-\mu)^2}{4\sigma^2} - \frac{(x-\tilde{\mu})^2}{4\tilde{\sigma}^2}\right) dx}_{=I} \end{aligned}$$

$$I = \int_{\mathbb{R}} \exp\left(-\frac{1}{4\Sigma^2} \left[x - \left(\frac{\mu}{\sigma^2} + \frac{\tilde{\mu}}{\tilde{\sigma}^2}\right)\Sigma^2\right]^2 - \frac{\Sigma^2}{4} \left(\frac{\mu}{\sigma^2} + \frac{\tilde{\mu}}{\tilde{\sigma}^2}\right) + \frac{\mu}{4\sigma^2} + \frac{\tilde{\mu}}{4\tilde{\sigma}^2}\right) dx$$

en notant $\Sigma^2 = \left(\frac{1}{\sigma^2} + \frac{1}{\tilde{\sigma}^2}\right)^{-1}$. D'ou en reconnaissant un intégrale gaussienne de variance $2\Sigma^2$ et en factorisant le facteur exponentiel :

$$I = \Sigma\sqrt{2\pi} \exp - \left(\frac{(\mu - \tilde{\mu})^2}{4(\sigma^2 - \tilde{\sigma}^2)}\right)$$

Ainsi nous arrivons à

$$\begin{aligned} \frac{1}{2}d_H^2(\Phi_\beta, \Phi_{\tilde{\beta}}) &= 1 - \sqrt{\frac{2\sigma\tilde{\sigma}}{\sigma^2\tilde{\sigma}^2}} \exp - \left(\frac{(\mu - \tilde{\mu})^2}{4(\sigma^2 - \tilde{\sigma}^2)}\right) \\ &= 1 - \sqrt{\frac{2(u+1)}{(u+1)^2 + 1}} \left(1 - \frac{h^2}{4(\sigma^2 - \tilde{\sigma}^2)}\right) + O(h^2) \end{aligned}$$

en notant $h = \mu - \tilde{\mu}$ et $u = \frac{\sigma}{\tilde{\sigma}} - 1$ (développement limité en (h, u)) c'est la

somme de deux termes du second ordre : et

$$\sqrt{\frac{2(u+1)}{(u+1)^2+1} \frac{h^2}{\tilde{\sigma}^2(1+(u+1)^2)}} \sim \frac{h^2}{8\tilde{\sigma}^2}$$

d'où

$$d_H^2(\Phi_\beta, \Phi_{\tilde{\beta}}) = \frac{2(\sigma - \tilde{\sigma})^2 + (\mu - \tilde{\mu})^2}{4\tilde{\sigma}^2} + O(\|h, u\|^2)$$

.

1.2.4 Estimateur bayésien (EB)

l'idée centrale de l'analyse bayésienne est de considérer le paramètre inconnu β comme aléatoire : Θ (l'espace des paramètres β) est muni d'une probabilité π telle que $(\Theta, \mathcal{A}, \pi)$ est un espace probabilisé. Nous noterons $\beta \sim \pi$. π est appelée loi a priori. Intuitivement et en termes informationnels, elle détermine ce qu'on sait et ce qu'on sait pas avant d'observer X .

Définition 1.2.7. Soit $\hat{\beta} = \hat{\beta}(x)$ un estimateur de β , On appelle estimateur de Bayes associé à la fonction de perte $L(\beta, \hat{\beta})$ et à une distribution a priori π , toute décision β^π qui minimise le risque de bayes défini par $\mathbb{E}_\pi[L(\beta, \hat{\beta})]$, ce estimateur est défini par :

$$\beta^\pi = \arg \min_{\beta \in \mathcal{D}} \mathbb{E}_\pi[L(\beta, \hat{\beta})]$$

avec \mathcal{D} l'espace de décisions possibles.

Définition 1.2.8. (Estimateur biais)

Un estimateur $\hat{\beta}$ de β est dit sans biais si est seulement si

$$\mathbb{E}(\hat{\beta}) = \beta$$

Remarque 1.2.3. une propriété moins forte est le biais asymptotique.

$$\lim_{n \rightarrow +\infty} \mathbb{E}(\hat{\beta}) = \beta$$

Définition 1.2.9. (Convergence)

un estimateur $\hat{\beta}$ de β est dit converge si et seulement si

$$\lim_{n \rightarrow +\infty} \text{Var}(\hat{\beta}) = O$$

1.2.5 Deux optimalités minimaxité et admissibilité

Cette section est consacrée à deux notions fondamentales de la Théorie de la Décision fréquentiste, présentées par Wald (1950) et Neyman et Pearson (1933). Comme il a été mentionné auparavant, et contrairement à l'approche bayésienne, le paradigme fréquentiste n'est pas assez réducteur pour conduire à un seul estimateur optimal.

Admissibilité

Définition 1.2.10. Soit $X \in (\mathcal{X}, \mathcal{A}, \{\mathbb{P}_\beta, \beta \in \Theta\})$ un modèle paramétrique, et L une fonction de perte sur $\Theta \times \mathcal{D}$ où \mathcal{D} est l'ensemble de décision, on dit que $\tilde{\beta} \in \Theta$ est **inadmissible**⁷ si et seulement si :

$$\begin{aligned} & \exists \tilde{\beta}_0 \in \mathcal{D}, \quad \forall \beta \in \Theta, \quad R(\beta, \tilde{\beta}) \geq R(\beta, \tilde{\beta}_0) \\ \text{et} \quad & \exists \beta_0 \in \Theta \quad R(\beta_0, \tilde{\beta}) > R(\beta_0, \tilde{\beta}_0) \end{aligned}$$

Un estimateur est dit **admissible** si et seulement s'il n'est pas **inadmissible**.

Remarque 1.2.4. Si

$$\forall (\beta, \tilde{\beta}), R(\beta, \tilde{\beta}) \leq R(\beta, \tilde{\beta}_0) \implies \pi \left(\beta \in \Theta, R(\beta, \tilde{\beta}) < R(\beta, \tilde{\beta}_0) \right) = 0$$

On dit que $\tilde{\beta}_0$ est (π -admissible), presque admissible par rapport à la mesure π .

Définition 1.2.11. Une classe \mathcal{D} d'estimateurs est dite complète si, quel que soit $\tilde{\beta}'$ n'appartient pas à \mathcal{D} , il existe $\tilde{\beta} \in \mathcal{D}$ qui domine $\tilde{\beta}'$. La classe est essentiellement complète si, quel que soit $\tilde{\beta}'$ n'appartient pas à \mathcal{D} , il existe $\tilde{\beta} \in \mathcal{D}$ au moins aussi bon que $\tilde{\beta}'$.

7. Un estimateur $\tilde{\beta}$ est inadmissible s'il existe un estimateur $\tilde{\beta}_0$ qui domine $\tilde{\beta}$

Théorème 1.2.1. (*Estimateurs bayesiens admissibles*) Si l'estimateur bayésien⁸ β^π associé à une fonction de perte L et une loi à priori π est unique, alors il est **admissible**.

Démonstration :

supposons β^π estimateur bayésien non admissible

$$\exists \tilde{\beta}_0 \in \mathcal{D}, \forall \beta \in \Theta, \quad R(\beta, \tilde{\beta}) \geq R(\beta, \tilde{\beta}_0)$$

$$\text{et} \quad \exists \beta_0 \in \Theta \quad R(\beta_0, \tilde{\beta}) > R(\beta_0, \tilde{\beta}_0)$$

En intégrant la première inégalité :

$$\int_{\Theta} R(\beta, \tilde{\beta}_0) d\pi(\beta) \leq \int_{\Theta} R(\beta, \beta^\pi) d\pi(\beta) = r(\pi)$$

On remarque que $\tilde{\beta}_0$ est aussi un estimateur bayésien associé à L et π avec ($\tilde{\beta}_0 \neq \beta^\pi$), le théorème se déduit par contraposée.

Remarque 1.2.5. Ce théorème s'applique notamment dans le cas d'un risque fini et d'une fonction de perte convexe, en outre l'unicité de l'estimateur bayésien implique la finitude du risque : $r(\pi) = \int_{\Theta} R(\beta, \beta^\pi) d\pi(\beta) < \infty$ (sinon, tout estimateur minimise le risque).

Proposition 1.2.4. Tout estimateur bayésien tel que $r(\pi) < \infty$ est π -admissible.

Démonstration :

Soit la dernière condition vérifiée pour $\tilde{\beta}_0$ tel que $\forall \beta$, on note :

$$A = \beta \in \Theta, R(\beta, \tilde{\beta}) < R(\beta, \tilde{\beta}_0)$$

8. Notons que pour des fonctions de pertes strictement convexes, les estimateurs de bayes sont uniques.

~~nous avons alors~~

$$\int_{\Theta} R(\beta, \tilde{\beta}_0) d\pi(\beta) - \int_{\Theta} R(\beta, \beta^\pi) d\pi(\beta) = \int_A \left(R(\beta, \tilde{\beta}) - R(\beta, \tilde{\beta}_0) \right) d\pi(\beta)$$

si et seulement si $\pi(A) = 0$, or comme β^π est bayésien et le risque finie, $r(\beta, \tilde{\beta}_0) \geq r(\beta, \beta^\pi)$, donc l'intégrale est nulle (positive et négative), d'où $\pi(A) = 0$.

Maintenant on va énoncer une condition suffisante d'admissibilité des estimateurs bayésiens.

Théorème 1.2.2. *(continuité et π - admissible) si $\pi > 0$ sur Θ et $r(\pi) < \infty$ pour une fonction de perte L donnée, donc on a si β^π l'estimateur bayésien correspondant existe, avec la fonction $R : \beta \rightarrow R(\beta, \tilde{\beta})$ soit continue, alors β^π est **admissible**.*

Démonstration :

supposons que β^π est **inadmissible**, d'après la proposition (1.2.4) β^π est π -**admissible**. Ainsi $\exists \tilde{\beta}_0$ telque pour tout β $R(\beta, \tilde{\beta}_0) \leq R(\beta, \beta^\pi)$, et $\beta_0 \in \Theta$, $R(\beta_0, \tilde{\beta}_0) < R(\beta_0, \beta^\pi)$, et on à $R : \beta \rightarrow R(\beta, \tilde{\beta}_0) - R(\beta, \beta^\pi)$ est une foncton continue definit sur Θ . Donc il existe un voisinage (ouvert) de β_0 , $\mathcal{V}_0 \subset \Theta$ telque $\forall \beta \in \mathcal{V}_0$, $R(\beta, \tilde{\beta}_0) \leq R(\beta, \beta^\pi)$. En considère A la même région que dans la proposition précédent, $\pi(A) \geq \pi(\mathcal{V}_0)$, or π est supposée strictement positive que Θ , donc en prenant un modèle **dominé** par une mesure qui charge positivement les ouverts (la mesure de lebesque par exemple) $\pi(\mathcal{V}_0) > 0$, A est donc non négligeable (de mesure non nulle), ce qui n'est pas conforme avec la π -**admissibilité**, on conclusion β^π est **admissible**.

Estimateur randomisé

L'idée a l'origine de cette notion est de rendre \mathcal{D} convexe, pour pouvoir maximiser facilement l'estimateur de Neyman-Pearson.

Définition 1.2.12. Soit le modèle $X \in (\mathcal{X}, \mathcal{A}, \{\mathbb{P}_\beta, \beta \in \Theta\})$ un modèle paramétrique, où \mathcal{D} est l'ensemble des décisions, on définit \mathcal{D}^* comme l'ensemble des probabilités sur \mathcal{D} , $\beta^* \in \mathcal{D}^*$ est appelé estimateur **randomisé**.

On définit de même les fonctions de perte et risque **randomisés** par :

$$L^*(\beta, \beta^*) = \int_{\mathcal{D}} L(\beta, a) d\beta^*(a)$$

$$R^*(\beta, \beta^*) = \mathbb{E}_\beta [L^*(\beta, \beta^*)]$$

Minimaxité

Risque et estimateur minimax

L'estimateur **minimax** correspond au point de vue (conservateur) de Judith Rousseau est faire le mieux dans le pire des cas, c'est à dire s'assurer contre le pire, il est utile dans des cadres complexes, mais trop conservateur dans certains cas où le pire très peut probable, il peut être judicieux de voir l'estimation comme un jeu entre le statistien (choix de β), et la nature (choix de β), l'estimation **minimax** rejoint alors celle de la théorie des jeux.

Définition 1.2.13. Le risque **minimax** est défini par :

$$\bar{R} = \inf_{\beta^* \in \mathcal{D}^*} \sup_{\beta \in \Theta} R(\beta, \beta^*)$$

On dit que $\tilde{\beta}_0$ est un estimateur **minimax** si et seulement si :

$$\bar{R} = \sup_{\beta \in \Theta} R(\beta, \tilde{\beta}_0)$$

Théorème 1.2.3. Si $\mathcal{D} \in \mathbb{R}^k$ est convexe et compact, et si $L(\beta, \tilde{\beta})$ est continue et convexe en tant que fonction de $\tilde{\beta}$, pour chaque $\beta \in \Theta$ il existe un estimateur **minimax** non **randomisé**⁹.

Le résultat suivant met en avant la connexion entre approche bayésienne et principe minimax, dont la démonstration est immédiate.

9. Ce résultat est un cas particulier du théorème de Rao-Blackwell voir [2].

Lemme 1.2.1. *Le risque de Bayes est toujours plus petit que le risque minimax*¹⁰

$$\underline{R} = \sup_{\pi} r(\pi) = \sup_{\pi} \inf_{\tilde{\beta} \in \mathcal{D}} r(\pi, \tilde{\beta}) \leq \bar{R} = \inf_{\tilde{\beta} \in \mathcal{D}^*} \sup_{\beta} R(\beta, \tilde{\beta})$$

Un cas particulièrement intéressant correspond à la définition suivante.

Définition 1.2.14. *Un problème d'estimation est dit admettre*¹¹ *une valeur si, $\bar{R} = \underline{R}$, c'est-à-dire quand*

$$\sup_{\pi} \inf_{\tilde{\beta} \in \mathcal{D}} r(\pi, \tilde{\beta}) \leq \bar{R} = \inf_{\tilde{\beta} \in \mathcal{D}^*} \sup_{\beta} R(\beta, \tilde{\beta})$$

Lemme 1.2.2. *Si $\tilde{\beta}_0$ est un estimateur de Bayes pour π_0 et si $R(\beta, \tilde{\beta}_0) \leq r(\pi_0)$ pour tout β dans le support de π_0 , $\tilde{\beta}_0$ est minimax et π_0 est la distribution la moins favorable.*

Puisque les estimateurs minimaxs correspondent généralement à des estimateurs de Bayes généralisés, on doit souvent recourir à un argument limite pour établir la minimaxité, plutôt que de calculer directement le risque de Bayes comme dans le Lemme (1.2.2).

Lemme 1.2.3. *S'il existe une suite (π_n) de loi a priori propres, donc si l'estimateur de Bayes généralisé $\tilde{\beta}_0$ vérifié*

$$R(\beta, \tilde{\beta}_0) \leq \lim_{n \rightarrow +\infty} r(\pi_n) < +\infty$$

pour tout $\beta \in \Theta$, alors $\tilde{\beta}_0$ est minimax.

Exemple 5. *Quand $x \sim \mathcal{N}(\beta, 1)$ l'estimateur de (MV) $\hat{\beta}_{MV}(x) = x$ est un estimateur de bayes généralisé par rapport à la mesure de lebesgue sur \mathbb{R} , pour le coût quadratique puisque*

$$R(\hat{\beta}_{MV}, \beta) = \mathbb{E}_{\beta}(x - \beta)^2 = 1$$

10. La première valeur est dite risque maximin et une distribution π^* telle que $r(\pi^*) = \underline{R}$ est appelée distribution a priori la moins favorable.

11. Quand le problème admet une valeur, certains estimateurs minimax sont des estimateurs de Bayes correspondant aux lois a priori les moins favorables. Cependant, ils peuvent être randomisés.

ce risque est la limite du risque de Bayes $r(\pi_n)$ quand π_n est égale à $\mathcal{N}(0, n)$,
comme

$$r(\pi_n) = \frac{n}{n+1}$$

Par conséquent, l'estimateur de (MV) $\hat{\beta}_{MV}$ est minimax.

Notons que cet argument peut être étendu directement au cas $x \sim \mathcal{N}_p(\beta, I_p)$ pour établir que $\hat{\beta}_{MV}$ est minimax pour tout p .

Proposition 1.2.5. *S'il existe un unique estimateur minimax, cet estimateur est admissible.*

Démonstration :

Si β^* est le seul estimateur minimax, pour tout estimateur $\tilde{\beta} \neq \beta^*$:

$$\sup_{\beta} R(\beta, \tilde{\beta}) > \sup_{\beta} R(\beta, \beta^*)$$

Donc $\tilde{\beta}$ ne peut pas dominer β^* .

Remarque 1.2.6. *Notons que la réciproque de ce résultat est fautive, car il peut exister plusieurs estimateurs minimax admissibles. Par exemple, dans le cas $\mathcal{N}_p(\beta, I_p)$, il existe des estimateurs de Bayes réguliers minimax pour $p \geq 5$.*

Proposition 1.2.6. *Si $\tilde{\beta}_0$ admissible de risque constant, alors $\tilde{\beta}_0$ est l'unique estimateur minimax.*

Démonstration :

Pour tout $\beta_0 \in \Theta$, $\sup_{\beta} R(\beta, \tilde{\beta}_0) = R(\beta_0, \tilde{\beta}_0)$. Aors s'il existe $\tilde{\beta}_1$ telque

$$\bar{R} \leq \sup_{\beta} R(\beta, \tilde{\beta}_1) < R(\beta_0, \tilde{\beta}_0)$$

$\tilde{\beta}_0$ ne peut pas être admissible. De la même façon, si

$$R = \sup_{\beta} R(\beta, \tilde{\beta}_1) = R(\beta_0, \tilde{\beta}_0)$$

1.2.6 Le cas particulier du modèle normal 33
~~et si $\exists \tilde{\beta}_1$ tel que $R(\tilde{\beta}_1, \tilde{\beta}_1) < R, \tilde{\beta}_1$ domine $\tilde{\beta}_0$. Par conséquent quand $\tilde{\beta}_0$ est~~
admissible, le seul cas possible est qu'il existe $\tilde{\beta}_1$ tel que $R(\beta, \tilde{\beta}_1) = R(\beta, \tilde{\beta}_0)$
pour tout $\beta \in \Theta$. Ce qui est aussi impossible quand $\tilde{\beta}_0$ est admissible.

Remarque 1.2.7. *Remarquons à nouveau que la réciproque de ce résultat est fautive. Il peut exister des estimateurs minimax ayant un risque constant qui soient inadmissibles. En fait, ils sont inadmissibles dès qu'il existe d'autres estimateurs minimax. C'est le cas par exemple pour $\tilde{\beta}_0(x) = x$ quand $x \sim \mathcal{N}_p(\beta, I_p)$ et $p \geq 3$, Il y a aussi des cas où il n'existe pas d'estimateur minimax admissible.*

1.2.6 Le cas particulier du modèle normal

Lorsque Gauss introduisit la distribution normale aux alentours de 1810, Laplace estima qu'il s'agissait en fait de la loi d'erreur idéale. Par la suite, s'appuyant sur le Théorème Central Limit, les statisticiens de la première moitié du **XIX**ième siècle se référaient presque toujours à la distribution normale. Il y'a bien sûr, des nombreux phénomènes pour lesquels un modèle normal n'est pas applicable, mais ce dernier reste considérablement utilisé, en particulier en économétrie et dans des domaines où on peut justifier l'approximation du Théorème Central Limit (physique particulière, etc.). En réalité, l'approximation normale est souvent justifiée par des raisons asymptotiques. Il est donc intéressant d'étudier en détail cette distribution particulière d'un point de vue bayésien.

Pour l'observation d'une distribution normale multivariée $\mathcal{N}_p(\beta, \Sigma)$, de matrice de covariance connue Σ , et la loi à priori¹² $\pi(\beta) \sim \mathcal{N}_p(\mu, A)$ avec A est un hyperparamètre, et la loi a posteriori $\pi(\beta/x)$ est

$$\mathcal{N}_p(\underbrace{x - \Sigma(\Sigma + A)^{-1}(x - \mu)}_{\text{moyenne}}, \overbrace{(A^{-1} + \Sigma^{-1})^{-1}}^{\text{covariance}})$$

12. on peut dit aussi la loi conjuguée

Sous un coût quadratique, l'estimateur de Bayes s'écrit comme une combinaison convexe de l'observation x et la moyenne a priori μ

$$\begin{aligned}\beta^\pi(x) &= x - \Sigma(\Sigma + A)^{-1}(x - \mu) \\ &= (\Sigma^{-1} + A^{-1})^{-1}(\Sigma^{-1}x + A^{-1}\mu)\end{aligned}$$

Estimation de la variance

Dans la plupart des cas, la variance du modèle est partiellement ou totalement inconnue. Il est alors nécessaire de considérer des lois a priori pour le paramètre (β, Σ) . Si la variance est connue à une constante multiplicative près, σ^2 , il est généralement possible de revenir à un cadre unidimensionnel, c'est-à-dire lorsque x_1, \dots, x_n sont i.i.d $\mathcal{N}(\beta, \sigma^2)$ pour des raisons d'exhaustivité.

Si nous définissons les statistiques $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$ et $s^2 = \sum_{i=1}^n (x_i - \bar{x})^2$

la vraisemblance¹³ peut s'écrire

$$l(\beta, \sigma, \bar{x}, s^2) = \sigma^{-n} \exp \left[-\frac{1}{2\sigma^2} \{s^2 + n(\bar{x} - \beta)^2\} \right]$$

1.2.7 Espace des paramètres restreint

Berger (1985) remarque l'intérêt d'une approche bayésienne non informative pour des espaces des paramètres restreints, la loi a priori étant simplement la troncation d'une loi non informative sans contrainte. D'un point de vue classique, le calcul d'estimateurs du maximum de vraisemblance restreints est souvent compliqué, notamment quand les contraintes sont non linéaires. En revanche la mise en oeuvre d'une approche bayésienne via des méthodes de simulation de Monte Carlo permet un calcul aisé des estimateurs de Bayes.

13. l'estimateur de Bayes ne dépend que de \bar{x} et s^2 .

(Cet avantage peut même être utilisé pour calculer des estimateurs du maximum de vraisemblance restreints à travers des techniques bayésiennes.

1.2.8 Estimation du coût

pour un coût donné $L(\beta, \tilde{\beta})$, d'un point de vue décisionnel comme l'estimation du coût $L(\beta, \beta^\pi(x))$ par $\gamma(x)$, sous une seconde fonction de coût, comme

$$\bar{L}(\beta, \beta^\pi, \gamma) = L \underbrace{[\gamma(x) - L(\beta, \beta^\pi(x))]}_Q$$

De nouveau, le coût quadratique (Q) n'est pas plus justifié comme choix automatique dans ce contexte que dans d'autres cas d'estimation. Mais en dehors de son côté pratique, le choix du coût quadratique peut se défendre par l'absence de justification en termes d'utilité et par conséquent, une perception plus proche de l'erreur comme une variance. Sous (Q), l'évaluation bayésienne des performances de β^π est donnée par le résultat suivant.

Proposition 1.2.7. *L'estimateur de Bayes du coût $L(\beta, \beta^\pi(x))$ sous (Q) pour la loi a priori π est*

$$\gamma^\pi(x) = \mathbb{E}^\pi(L(\beta, \beta^\pi(x))/x)$$

Remarque 1.2.8. *Le but est d'estimer une fonction particulière de β sous un coût quadratique. Notons que la dépendance de cette fonction à x n'a pas d'importance d'un point de vue bayésien car, une fois x observé, x est fixé. De même, pour un coût d'erreur absolue, l'estimateur de Bayes du coût est la médiane de la distribution a posteriori de $L(\beta, \beta^\pi(x))$, moins facile à obtenir. quand L est le coût quadratique, la variance a posteriori, $\text{var}^\pi(x)$, est par conséquent l'estimateur de Bayes du coût associé avec β^π .*

$f(x, \beta)$	$\pi(\beta)$	$\pi(\beta/x)$
Normal $\mathcal{N}(\beta, \sigma^2)$	Normal $\mathcal{N}(\hat{\beta}, \tau^2)$	$\mathcal{N}(\varphi(\sigma^2 \hat{\beta} + \tau^2 x), \varphi \sigma^2 \tau^2)$ $\varphi^{-1} = \sigma^2 + \tau^2$
Poisson $p(\beta)$	Gamma $\Gamma(\alpha, \hat{\beta})$	$\Gamma(\alpha + x, \hat{\beta} + 1)$
Gamma $\Gamma(\nu, \beta)$	Gamma $\Gamma(\alpha, \hat{\beta})$	$\Gamma(\alpha + \nu, \hat{\beta} + x)$
Binomial $B(n, \beta)$	Bêta $Be(\alpha, \hat{\beta})$	$Be(\alpha + x, \hat{\beta} + n - x)$
Binomial negative $Neg(m, \beta)$	Bêta $Be(\alpha, \hat{\beta})$	$Be(\alpha + m, \hat{\beta} + x)$
Multinomial $M_k(\beta_1, \dots, \beta_k)$	Dirichlet $D(\hat{\beta}_1, \dots, \hat{\beta}_k)$	$D(\hat{\beta}_1 + x_1, \dots, \hat{\beta}_k + x_k)$
Normal $\mathcal{N}(\mu, \frac{1}{\beta})$	Gamma $\Gamma(\alpha, \hat{\beta})$	$\Gamma(\alpha + 0.5, \hat{\beta} + \frac{(\mu-x)^2}{2})$

Tableau de quelques lois a priori et a posteriori

Chapitre 2

Les estimateurs de type Stein

Soit $X_1 \dots X_p$ une suite de variable aléatoire réelle indépendante suit la distribution normal (Gauss) avec moyenne $\mu_1 \dots \mu_p$ inconnue et variance 1, c'est habituel de estimer μ_i avec X_i ($i = 1 \dots p$), ce estimateur est appelé l'estimateur usuel (de bayes), si la perte utiliser et la perte quadratique, alors Stein en (1956) montrer que X est un estimateur admissible pour $p=1,2$ et puis en (1961) James et Stein ont prouvé que X est inadmissible pour $p \geq 3$.

On consider le probleme de l'estimation de μ avec la fonction de perte L definit par,

$$l(\mu, \hat{\mu}) = (\mu - \hat{\mu})^2 = \sum_{i=1}^p (\mu_i - \hat{\mu}_i)^2$$

on le note que $\hat{\mu}$ definit le vecteur d'estimateur.

2.1 Innadmissibilite de l'estimateur usuel pour

$$p \geq 3$$

2.1.1 la variance connue

Soit X suit la distribution normal de dimension p, avec une moyenne inconnue $\mu = \mathbb{E}(X)$ et une matrice de covariance égale à la matrice d'identité $\mathbb{E}(X - \mu)(X - \mu)^t = I$, nous sommes intéressé à estimer μ , par l'estimateur $\hat{\mu}$ avec

$$L(\mu, \hat{\mu}) = (\mu - \hat{\mu})(\mu - \hat{\mu})^t = \|\mu - \hat{\mu}\|^2 \quad (2.1)$$

L'estimateur usuel est definit par,

$$\bar{\mu}(X) = X$$

Le risque de l'estimateur usuel est definit par,

$$R(\mu, \bar{\mu}) = \mathbb{E}(L(\mu, X)) = \mathbb{E}(\|X - \mu\|^2) = p$$

ce resultat est obtenue puisque la quantité $\|X - \mu\|^2 \sim \chi_p^2$ alors $R(\mu, \bar{\mu}) = p$ pour tout $\mu \in \mathbb{R}^p$. On definit l'estimateur de type Stein ou bien (James et Stein) par,

$$\mu_1^{JS}(X) = \left(1 - \frac{c}{\|X\|^2}\right) X \quad c > 0 \quad (2.2)$$

Le risque de l'estimateur $\mu_1^{JS}(X)$ est definit par,

$$\begin{aligned} R(\mu, \mu_1^{JS}) &= \mathbb{E} \left[\left\| \left(1 - \frac{c}{\|X\|^2}\right) X - \mu \right\|^2 \right] \\ &= \mathbb{E}[\|X - \mu\|^2] - 2c \mathbb{E} \left[\frac{(X - \mu)^t X}{\|X\|^2} \right] + c^2 \mathbb{E} \left[\frac{1}{\|X\|^2} \right] \\ &= p - 2c \mathbb{E} \left[\frac{(X - \mu)^t X}{\|X\|^2} \right] + c^2 \mathbb{E} \left[\frac{1}{\|X\|^2} \right] \end{aligned} \quad (2.3)$$

Il est bien connue que $\|X\|^2$ suit la loi de χ^2 noncentre avec p le degré de liberte et $\|\mu\|^2$ le paramètre de noncentralité, on prend

$$U = \frac{\mu^t X}{\|\mu\|} \quad V = \|X - \frac{\mu^t X}{\|\mu\|^2} \mu\|^2 \quad (2.4)$$

alors,

$$W = \|X\|^2 = U^2 + V \quad (2.5)$$

2.1.1 la variance connue

avec $U \sim \mathcal{N}(\|\mu\|, 1)$ et V independant de U avec $V \sim \chi_{p-1}^2$, si on prend k

39

suit la loi de poisson de paramètre $\frac{1}{2}\|\mu\|^2$, donc la distribution conditionnel de W donne k est distribué de la même manière que $\|X\|^2$ avec la distribution centre de χ_{p+2k}^2 , ainsi

$$\mathbb{E} \left[\frac{1}{\|X\|^2} \right] = \mathbb{E} \left[\frac{1}{\chi_{p+2k}^2} \right] = \mathbb{E} \left(\mathbb{E} \left[\frac{1}{\chi_{p+2k}^2} / k \right] \right) = \mathbb{E} \left(\frac{1}{p-2+2k} \right) \quad (2.6)$$

On va calculer le deuxième terme de l'égalite (2.3), on à la densité conjointe de U et V est donne comme suit,

$$\begin{cases} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(u-\|\mu\|)^2} \frac{1}{2^{\frac{(p-1)}{2}} \Gamma[(p-1)/2]} v^{\frac{(p-1)}{2}} e^{-\frac{v}{2}} & \text{si } v \geq 0 \\ 0 & \text{sinon} \end{cases} \quad (2.7)$$

La densité conjointe de U et W est definit par,

$$\begin{cases} \frac{1}{\sqrt{2\pi} 2^{\frac{(p-1)}{2}} \Gamma[(p-1)/2]} (w-u^2)^{\frac{(p-3)}{2}} e^{-\frac{1}{2}\|\mu\|^2 + \|\mu\|u - \frac{1}{2}w} & \text{si } u^2 \leq w \\ 0 & \text{sinon} \end{cases} \quad (2.8)$$

Il s'ensuite que,

$$\mathbb{E} \left(\frac{U}{W} \right) = \frac{e^{-\frac{1}{2}\|\mu\|^2}}{\sqrt{2\pi} 2^{\frac{(p-1)}{2}} \Gamma[(p-1)/2]} \underbrace{\int_0^\infty dw \int_{-\sqrt{w}}^{\sqrt{w}} \frac{u}{w} (w-u^2)^{\frac{(p-3)}{2}} e^{\|\mu\|u - \frac{1}{2}w} du}_{(2.9)}$$

avec le changement de variable suivant $t = \frac{u}{\sqrt{w}}$ on trouve,

$$\begin{aligned}
& \int_0^\infty dw \int_{-\sqrt{w}}^{\sqrt{w}} \frac{u}{w} (w - u^2)^{\frac{(p-3)}{2}} e^{\|\mu\|u - \frac{1}{2}w} du & (2.10) \\
&= \int_0^\infty w^{\frac{(p-3)}{2}} e^{\|\mu\|u - \frac{1}{2}w} dw \int_{-1}^1 t(1 - t^2)^{\frac{(p-3)}{2}} e^{\|\mu\|t\sqrt{w}} dt \\
&= \int_0^\infty w^{\frac{(p-3)}{2}} e^{\|\mu\|u - \frac{1}{2}w} dw \sum_{i=0}^\infty \frac{(\|\mu\|\sqrt{w})^i}{i!} \int_{-1}^1 t^{i+1}(1 - t^2)^{\frac{(p-3)}{2}} dt \\
&= \sum_{j=0}^\infty \frac{\|\mu\|^{2j+1}}{(2j+1)!} \int_0^\infty w^{\frac{p}{2}+j-1} e^{-\frac{1}{2}w} dw \int_{-1}^1 t^{2(j+1)}(1 - t^2)^{\frac{(p-3)}{2}} dt \\
&= \sum_{j=0}^\infty \frac{\|\mu\|^{2j+1}}{(2j+1)!} 2^{\frac{p}{2}+j} \Gamma\left(\frac{p}{2} + j\right) B\left(j + \frac{3}{2}, \frac{p-1}{2}\right) \\
&= \sum_{j=0}^\infty \frac{\|\mu\|^{2j+1} 2^{\frac{p}{2}+j} \Gamma\left(j + \frac{3}{2}\right) \Gamma\left(\frac{p-1}{2}\right)}{(2j+1)! \left(\frac{p}{2} + j\right)} \\
&= \Gamma\left(\frac{p-1}{2}\right) 2^{\frac{p}{2}} \sum_{j=0}^\infty \frac{2^j \Gamma\left(\frac{1}{2}\right) \|\mu\|^{2j+1}}{2^{2j+1} \Gamma(j+1) \left(\frac{p}{2} + j\right)}
\end{aligned}$$

de l'equations (2.4)(2.5)(2.9) et (2.10) on a

$$\begin{aligned}
\mathbb{E} \left[\frac{(X - \mu)^t X}{\|X\|^2} \right] &= 1 - \|\mu\| \mathbb{E}\left(\frac{u}{w}\right) & (2.11) \\
&= 1 - \|\mu\| \frac{e^{-\frac{1}{2}\|\mu\|^2}}{\sqrt{\pi}} \sum_{j=0}^\infty \frac{\Gamma\left(\frac{1}{2}\right) \|\mu\|^{2j+1}}{2^{j+1} \Gamma(j+1) \left(\frac{p}{2} + j\right)} \\
&= e^{-\frac{1}{2}\|\mu\|^2} \left[\sum_{i=0}^\infty \frac{\left(\frac{1}{2}\|\mu\|^2\right)^i}{i!} - \|\mu\|^2 \sum_{j=0}^\infty \frac{\left(\frac{1}{2}\|\mu\|^2\right)^j}{j!(p+2j)} \right] \\
&= e^{-\frac{1}{2}\|\mu\|^2} \sum_{i=0}^\infty \frac{\left(\frac{1}{2}\|\mu\|^2\right)^i}{i!} \frac{(p-2)}{p-2+2i} \\
&= (p-2) \mathbb{E} \left[\frac{1}{p-2+2k} \right]
\end{aligned}$$

avec $k \rightsquigarrow p\left(\frac{\|\mu\|^2}{2}\right)$, donc depuis les resultats de (2.3)(2.6)(2.11), on trouve,

$$\begin{aligned}
R(\mu, \mu_1^{js}) &= \mathbb{E} \left[\left\| \left(1 - \frac{c}{\|X\|^2} \right) X - \mu \right\|^2 \right] \\
&= p - 2(p-2)c \mathbb{E} \left[\frac{1}{p-2+2k} \right] + c^2 \mathbb{E} \left[\frac{1}{p-2+2k} \right]
\end{aligned}$$

Cette quantité est minimiser au point $c = p - 2$ pour tout μ , cela conduit à l'utilisation de l'estimateur

$$\mu_2^{JS}(X) = \left(1 - \frac{(p-2)}{\|X\|^2} \right) X$$

avec le risque,

$$R(\mu, \mu_2^{js}) = p - \mathbb{E} \left[\frac{(p-2)^2}{p-2+2k} \right] < p \quad \text{si } p \geq 3.$$

2.1.2 La variance inconnue

Maintenant, regardons le cas où X à une moyenne μ et matrice de variance covariance donné par,

$$\mathbb{E}(X - \mu)(X - \mu)^t = \sigma^2 I$$

et nous observons que $S \sim \sigma^2 \chi_p^2$ indépendant de X , avec μ et σ^2 soit inconnues, on considère l'estimateur suivant,

$$\mu_3^{js}(X, S) = \mu_3^{js} = \left(1 - \frac{aS}{\|X\|^2} \right) X \quad a > 0. \quad (2.12)$$

on va calculer le risque de ce estimateur, on à

$$\begin{aligned}
R(\mu, \mu_3^{js}) &= \mathbb{E} [\|\mu_3^{js} - \mu\|^2] & (2.13) \\
&= \mathbb{E} [\|X - \mu\|^2] - 2a \mathbb{E} \left[\frac{S(X - \mu)^t}{\|X\|^2} X \right] + a^2 \mathbb{E} \left[\frac{S^2}{\|X\|^2} \right] \\
&= \sigma^2 \left\{ p - 2a \mathbb{E} \left[\frac{S}{\sigma^2} \right] \mathbb{E} \left[\frac{(\frac{X}{\sigma} - \frac{\mu}{\sigma})^t \frac{X}{\sigma}}{\|\frac{X}{\sigma}\|^2} \right] + a^2 \mathbb{E} \left[\frac{S}{\|X\|^2} \right]^2 \mathbb{E} \left[\frac{1}{\|\frac{X}{\sigma}\|^2} \right] \right\} \\
&= \sigma^2 \left\{ p - 2an(p-2) \mathbb{E} \left[\frac{1}{p-2+2k} \right] + a^2 n(n+2) \mathbb{E} \left[\frac{1}{p-2+2k} \right] \right\}
\end{aligned}$$

Si on remplace $(X$ par $X/\sigma)$ et $(\mu$ par $\mu/\sigma)$ dans (2.6) et (2.11), alors $k \rightsquigarrow (\|\mu\|^2/2\sigma^2)$, le choix qui minimise (2.13) est $a = \frac{(p-2)}{(n+2)}$ pour tout μ , donc on obtient,

$$R(\mu, \mu_3^{js}) = \sigma^2 \left\{ p - \frac{n}{(n+2)}(p-2)^2 \mathbb{E}\left[\frac{1}{p-2+2k}\right] \right\} \quad (2.14)$$

Définition 2.1.1. (*Loi de Wishart*)

En théorie de probabilité et en statistique la loi de Wishart est la généralisation multidimensionnelle de la loi de χ^2 , la loi est dénommée en l'honneur de John Wishart qui la formula pour la première fois en 1928, c'est une loi de probabilité définies sur les matrice (positives, symétrique), une variable aléatoire S de loi de Wishart est donc une matrice aléatoire, on notera $S \rightsquigarrow W(v, p, n)$.

la loi de Wishart apparait comme loi d'une matrice de variance covariance d'un échantillon de valeurs suit la loi normal multidimensionnell, on définit ca densité par,

$$\begin{cases} \frac{1}{2^{\frac{np}{2}} |v|^{\frac{1}{2}} \Gamma_p(\frac{n}{2})} |X|^{\frac{n-p-1}{2}} e^{-\frac{1}{2}tr(v^{-1}X)} & \text{si } n \geq p \\ 0 & \text{sinon} \end{cases}$$

Γ_p est la fonction gamma multidimensionnelle définie par,

$$\Gamma_p\left(\frac{n}{2}\right) = \pi^{p(p-1)/4} \prod_{j=1}^p \Gamma(n/2 + (1-j)/2)$$

On a définit la loi de Wishart parceque, nous pouvons aussi traiter le cas ou la matrice de covariance inconnue, mais une estimation basée sur la matrice de Wishart, soit X et S indépendant, X est de dimension p suit la distribution normal $\mathcal{N}(\mu, \Sigma)$, et S est distribuer comme matrice de Wishart de dimension $(p \times p)$ avec n degre de libertie et l'esperance égale $n\Sigma$, ou les deux paramètres (μ, Σ) soit inconnue. Supposons que nous voulons estimer μ par μ par $\hat{\mu}$ avec la fonction de perte suivant,

$$L(\mu, \hat{\mu}) = (\mu - \hat{\mu})^t \Sigma^{-1} (\mu - \hat{\mu}) \quad (2.15)$$

$$\mu_4^{js}(X, S) = \mu_4^{js} = \left(1 - \frac{e}{X^t S^{-1} X}\right) X \quad (2.16)$$

le risque de l'estimateur μ_4^{js} est donner par,

$$\begin{aligned} R(\mu, \mu_4^{js}) &= \mathbb{E}_{\mu\Sigma} [(\mu_4^{js} - \mu)^t \Sigma^{-1} (\mu_4^{js} - \mu)] \quad (2.17) \\ &= \mathbb{E}_{\mu\Sigma} \left\{ \left[\left(1 - \frac{e}{X^t S^{-1} X}\right) X - \mu \right]^t \Sigma^{-1} \left[\left(1 - \frac{e}{X^t S^{-1} X}\right) X - \mu \right] \right\} \\ &= \mathbb{E}_{\mu^* I} \left\{ \left[\left(1 - \frac{e}{X^t S^{-1} X}\right) X - \mu^* \right]^t \Sigma^{-1} \left[\left(1 - \frac{e}{X^t S^{-1} X}\right) X - \mu^* \right] \right\} \end{aligned}$$

telque $\mu^* [(\mu^t \Sigma^{-1} \mu)^{\frac{1}{2}}, 0, \dots, 0]$, mais c'est bien connu que la distribution conditionnel de $X^t S^{-1} X$ donné X est de la forme $X^t X / S^*$, ou $S^* \sim \chi_{n-p+1}^2$ indépendant de X.

Par la comparaison de (2.13) (2.17) on voi que le choix optimum de e est $\frac{(p-2)}{(n-p+3)}$ et donc la fonction de risque devient,

$$R(\mu, \mu_4^{js}) = p - \frac{n-p+1}{n-p+3} (p-2)^2 \mathbb{E} \left[\frac{1}{p-2+2k} \right] \quad (2.18)$$

avec $k \sim p((\frac{1}{2})\mu^t \Sigma^{-1} \mu)$.

L'amélioration obtenue par ces estimateurs sur l'estimateur usuel peut être mieux compris, si on considère le cas ou la matrice de covariance est connue et égale à I_p , et si on considère que l'erreur orthogonal de tout estimateur X est $\mu - (\frac{\mu^t X}{\|X\|^2})X$, et sont moyenne quadratique est,

$$\begin{aligned} \mathbb{E}_{\mu} [\| \mu - (\frac{\mu^t X}{\|X\|^2}) X \|^2] &= \|\mu\|^2 - \mathbb{E}_{\mu} \left[\frac{(\mu^t X)^2}{\|X\|^2} \right] \quad (2.19) \\ &= \|\mu\|^2 \left(1 - \mathbb{E}_{\mu} \left[\frac{1+2k}{p+2k} \right] \right) \\ &= (p-1) \|\mu\|^2 \mathbb{E}_{\mu} \left[\frac{1}{p+2k} \right] \\ &= (p-1) \left[1 - (p-2) \mathbb{E}_{\mu} \left[\frac{1}{p-2+2k} \right] \right] \end{aligned}$$

ainsi que la moyenne quadratique de l'erreur de $\mu_2^{js} = \left[1 - \frac{(p-2)}{\|X\|^2}\right] X$ est,

$$\left[p - (p-2)^2 \mathbb{E}_\mu \left(\frac{1}{p-2+2k} \right) \right] - (p-1) \left[1 - (p-2) \mathbb{E}_\mu \left(\frac{1}{p-2+2k} \right) \right] = 1 + (p-2) \mathbb{E}_\mu \left(\frac{1}{p-2+2k} \right) \leq 2 \quad (2.20)$$

2.2 Les estimateurs spheriquement symétriques

Définition 2.2.1. *Un estimateur $\hat{\mu}$ est dit spheriquement symétrique (SS) (sur l'origine) si il écrit de la forme suivante,*

$$\hat{\mu}(X) = [1 - h(X^2)]X \quad (2.21)$$

Remarque 2.2.1. *On remarque que les estimateurs de type Stein sont spheriquement symétrique, on peut dit que l'estimateur de type Stein **Shrink** l'estimateur usuel X (vers 0) par un facteur $[1 - h(X^2)]$.*

maintenant on va démontrer que si un estimateur (SS), $\hat{\mu}_2$ est admissible par comparaison avec tous les estimateurs spheriquement symétrique, donc il est admissible dans la classe de tout les estimateurs. On à par la transformation orthogonal g ,

$$g \circ \hat{\mu} \circ g^{-1} = g[\hat{\mu}(g^{-1}(x))] = \hat{\mu}(x) \quad \text{pour tout } x \quad (2.22)$$

si $\hat{\mu}$ est de la forme (2.21), alors

$$g[\hat{\mu}(g^{-1}(x))] = g[(1 - h(x^2))g^{-1}(x)] = \hat{\mu}(x)$$

Suppose inversement que $\hat{\mu}$ verifié (2.22) pour tout g orthogonal, en particulière pour $g[\hat{\mu}(x)] = \hat{\mu}(x)$, donc $\hat{\mu}(x)$ se trouve au long de X , c'est definit par,

$$\hat{\mu}(x) = [1 - h'(X)]X$$

pour quelques fonctions h' à valeur réel, tantque le vecteur X , peut prend dans un autre vecteur à la même norme au carré x^2 avec une transformation

La preuve est basé la capacité du groupe orthogonal G , et la continuité du problème, c'est similaire à un groupe finie, avec la condition de la convexité du fonction de perte quadratique, nous pouvons limiter notre attention aux procédures non randomisées.

Suppose que l'estimateur $\hat{\mu}$ est mieux que l'estimateur (SS) $\hat{\mu}_2$, donc

$$R_{\hat{\mu}}(\mu) = \mathbb{E}_{\mu}[\hat{\mu}(X) - \mu]^2 \leq \mathbb{E}_{\mu}[\hat{\mu}_2(X) - \mu]^2 \quad \forall \mu \quad (2.23)$$

avec la condition de continuité de $R_{\hat{\mu}}$ et $R_{\hat{\mu}_2}$, l'innégalité précédent reste verifié pour $\mu \in S$ (S un ensemble ouvert non vide), tantque $\hat{\mu}_2$ est (SS) alors (2.23) restera vraie si on remplace $\hat{\mu}$ par $g \circ \hat{\mu} \circ g^{-1}$ avec g orthogonal, on obtient pour un $\mu \in S$ fixé,

$$\begin{aligned} R_{g \circ \hat{\mu} \circ g^{-1}}(\mu) &= \mathbb{E}_{\mu}[g\{\hat{\mu}(g^{-1}(X))\} - \mu]^2 \\ &= \mathbb{E}_{\mu}[\hat{\mu}(g^{-1}(X)) - g^{-1}(\mu)]^2 = R_{\hat{\mu}}(g^{-1}(\mu)). \end{aligned} \quad (2.24)$$

L'ensemble de g dans lequel $R_{g \circ \hat{\mu} \circ g^{-1}}(\mu) < R_{\hat{\mu}_2}(\mu)$, est un ensemble ouvert non vide.

Soit γ la mesure de probabilité invariant sur G , qui attribue une mesure strictement positive pour un ensemble ouvert non vide (pour l'existence de cette mesure voir [Chapitre 2,\[22\]](#)), alors,

$$\mu' = \int g \circ \mu \circ g^{-1} d\gamma(g) \quad (2.25)$$

est un estimateur (SS), et avec la condition du convexite du fonction de perte quadratique,

$$R_{\hat{\mu}'_2}(\mu) \leq \int R_{g \circ \hat{\mu} \circ g^{-1}} d\gamma(g) \leq R_{\hat{\mu}_2}(\mu) \quad \text{pour tout } \mu \in S \quad (2.26)$$

Donc on conclure que $\hat{\mu}_2$ n'est pas admissible dans la classe des estimateurs (SS), alors on obtient le resultat par contraposé.

TABLE DES MATIÈRES

2.3 L'admissibilité de l'estimateur usuel pour $p=2$

Cette preuve à été démentrer avec Stein on (1956) dans [26] , avec l'aide des resultats obtenue sur les estimateurs (SS) dans la partie précédente, on va montrer que pour ($p=2$) l'estimateur usuel definit par $\bar{\mu}(X) = X$ est admissible.

Soit $\hat{\mu}$ un estimateur de μ avec un risque finie, et soit b le biais de $\hat{\mu}$ definit par,

$$b(\hat{\mu}) = \mathbb{E}_{\mu}[\hat{\mu}(X)] - \mu \quad (2.27)$$

donc, avec l'innégalité d'information,

$$R(\hat{\mu}) \geq b^2(\hat{\mu}) + \sum_i \left\{ \sum_j \eta_{ij} [\delta_{ij} + b_{ij}(\hat{\mu})] \right\}^2 \quad (2.28)$$

pour tout η avec $\sum_i \eta_{ij}^2 = 1$, pour tout i , et

$$\delta_{ij} = \begin{cases} 1 & \text{si } i = j \\ 0 & \text{sinon} \end{cases}$$

$$b_{ij}(\hat{\mu}) = \frac{\partial}{\partial \mu_j} b_i(\hat{\mu}) \quad (2.29)$$

avec $b_i(\hat{\mu})$ est la i -éme coordonné de partie biais $b(\hat{\mu})$ choisir,

$$\eta_{ij} = \frac{\delta_{ij} + b_{ij}(\hat{\mu})}{\sqrt{\sum_j [\delta_{ij} + b_{ij}(\hat{\mu})]^2}} \quad (2.30)$$

afin de maximiser la quantité à droit de l'innégalité (2.28), on obtient

$$\begin{aligned} R(\hat{\mu}) &\geq b^2(\hat{\mu}) + \sum_{i,j} [\delta_{ij} + b_{ij}(\hat{\mu})]^2 \\ &= b^2(\hat{\mu}) + p + 2 \sum_i b_{ii}(\hat{\mu}) + \underbrace{\sum_{i,j} b_{ij}^2(\hat{\mu})} \end{aligned} \quad (2.31)$$

biais devient,

$$b(\hat{\mu}) = -\varphi(\mu^2)\mu \quad (2.32)$$

ou φ est une fonction différentiable à valeur réelle, dans ce cas laisser tomber le dernier terme de (2.31) donne,

$$R(\hat{\mu}) \geq p + \mu^2\varphi^2(\mu^2) - 2p\varphi(\mu^2) - 4\mu^2\varphi'(\mu^2) \quad (2.33)$$

On va utiliser cette formule pour montrer notre resultat, si on pose que $\bar{\mu}(X)$ n'est pas admissible, alors il existe un estimateur (SS) $\hat{\mu}$ qui est mieux que $\bar{\mu}$, on plus il existe une fonction φ (ne pas disparaître de façon identique), telque

$$2 \geq R(\hat{\mu}) \geq 2 + \mu^2\varphi^2(\mu^2) - 4\varphi(\mu^2) - 4\mu^2\varphi'(\mu^2) \quad (2.34)$$

avec le changement de variable suivant, pour tout $\mu^2 > 0$, soit $t = \mu^2$ et $\psi(t) = t\varphi(t)$, on obtient donc,

$$0 \geq \frac{1}{t}\psi^2(t) - 4\psi'(t) \quad t > 0 \quad (2.35)$$

Ceci montre que $\psi(t)$ est une fonction croissante, on va montrer que (2.35), implique que ψ est identiquement nul.

Suppose que $\psi(t_0) < 0$ pour $t_0 > 0$, donc l'intégrale de l'innégalité suivante sur l'intervalle $]0, t_0[$,

$$\frac{\psi'(t)}{\psi^2(t)} \geq \frac{1}{4t} \quad (2.36)$$

est donne,

$$-\frac{1}{\psi(t_0)} + \frac{1}{\psi(t)} \geq \frac{1}{4} \log\left(\frac{t_0}{t}\right) \quad (2.37)$$

la quantité à gauche est borné quand ($t \mapsto 0$), tandis que la quantité à droit tend vers l'infinie, et c'est une contradiction.

Suppose maintenant que $\psi(t_0) > 0$, pour tout $t_0 > 0$ alors

$$\frac{1}{\psi(t_0)} - \frac{1}{\psi(t)} \geq \frac{1}{4} \log\left(\frac{t}{t_0}\right) \quad t > t_0. \quad (2.38)$$

quand ($t \mapsto \infty$), la quantité à gauche est bornée, tandis que la quantité à droit tend vers l'infinie ($+\infty$), et encore c'est une contradiction, donc la fonction ($\psi = 0$), ce qui fallait demontrer.

Maintenant, on utilise (2.31), pour montrer que pour $p \geq 3$, il n'existe pas $c > (p-2)^2$ et $\bar{\mu}^2$, telque pour tout $\mu^2 \geq \bar{\mu}^2$, on a

$$R(\hat{\mu}) \leq p - \frac{c}{\mu^2} \quad (2.39)$$

Il faut montrer que l'innégalité differentiable suivante,

$$p - \frac{c}{\mu^2} \geq p + \mu^2 \varphi^2(\mu^2) - 2p\varphi(\mu^2) - 4\mu^2 \varphi'(\mu^2) \quad (2.40)$$

obtenue de (2.33) et (2.39), n'a pas de solution pour tout $\mu^2 \geq \bar{\mu}^2$, pour avoir ce resultat soit,

$$\varphi(\mu^2) = \frac{(p-2)}{\mu^2} + f(\mu^2) \quad (2.41)$$

donc (2.40) devient,

$$\frac{c - (p-2)^2}{\mu^2} \geq \mu^2 f^2(\mu^2) - 4f(\mu^2) - 4\mu^2 f'(\mu^2) \quad (2.42)$$

a l'aide de changement de variable suivant, $t = \mu^2$ et $\psi(t) = tf(t)$, on obtient,

$$- \frac{c - (p-2)^2}{t} \geq \frac{1}{t} \psi^2(t) - 4\psi'(t) \quad (2.43)$$

$$\frac{\psi'(t)}{a^2 + \psi^2(t)} \geq \frac{1}{4t} \quad (2.44)$$

2.3 L'admissibilité de l'estimateur usuel pour $p=2$

avec $a=c=(p-2)^{-1}$, depuis l'inégalité (2.35) pour $(t \geq t_0)$, qui est plus faible que (1.43), on conclure que $\psi(t) < 0$, on a comme resultat pour tout $t_0 < t$,

$$\tan^{-1}\left(\frac{\psi(t)}{a}\right) - \tan^{-1}\left(\frac{\psi(t_0)}{a}\right) \geq \frac{1}{4a} \log\left(\frac{t}{t_0}\right) \quad (2.45)$$

La quantité à gauche est bornée (tantque ψ ne change pas le signe), et la quantité à droit tend vers $(+\infty)$ quand $t \mapsto \infty$, ce qui est contradiction.

Chapitre 3

Probleme reliée à la fonction de perte

3.1 Clarifiez le problème

En voyant les resultats donnée dans le chapitre précédent, plusieurs personnes ont exprimé la créante qu'elles étaient étroitement liées avec l'utilisation d'une fonction de perte illimitée, que beaucoup de gens considèrent comme déraisonnable, Charles stein et James donne un exemple pour montrer qu'au moins qualitativement, ce n'est pas le cas pour simplifier on suppose X un p -vecteur de variable aléatoire distribuer selon la loi normal de moyenne μ , et matrice de covariance égale à I_p .

Supposons que nous sommes intéressés à estimer μ par $\hat{\mu}$ avec la fonction de perte definie par

$$L(\mu, \hat{\mu}) = \rho(\|\mu - \hat{\mu}\|^2) \tag{3.1}$$

sous l'hypothèse que ρ a une dérivé borné et soit continument differentiable, positive croissant et concave ($\rho''(t) \leq 0$, pour tout $t > 0$).

On va démontrer que pour un petit b , et grand a (indépendant de μ), l'estimateur¹ $\mu_5^{JS}(X)$ définie par

$$\mu_5^{JS} = \left(1 - \frac{b}{a + \|X\|^2}\right)X \quad (3.2)$$

à un petit risque par rapport à le risque de l'estimateur usuel X .

on pose que ($Y = X - \mu$) on obtient

$$\begin{aligned} R(\mu, \mu_5^{JS}) &= \mathbb{E}_\mu \rho \left[\left\| \left(1 - \frac{b}{a + \|X\|^2}\right)X - \mu \right\|^2 \right] \\ &= \mathbb{E}_\mu \rho \left[\|X - \mu\|^2 - 2b \frac{X^t(X - \mu)}{a + \|X\|^2} + b^2 \frac{\|X\|^2}{(a + \|X\|^2)^2} \right] \\ &\leq \mathbb{E}_\mu [\rho(\|X - \mu\|^2)] - 2b \mathbb{E}_\mu \left[\frac{X^t(X - \mu) - \frac{b}{2}}{a + \|X\|^2} \right] \rho'(\|X - \mu\|^2) \\ &= \underbrace{\mathbb{E}_\mu [\rho(\|Y\|^2)] - 2b \mathbb{E}_\mu \left[\frac{(Y + \mu)^t Y - \frac{b}{2}}{a + \|Y + \mu\|^2} \right] \rho'(\|Y\|^2)} \end{aligned} \quad (3.3)$$

juste comme [Stein 1956 \[26\]](#) on peut obtenir avec le développement de Taylor de

$$\frac{1}{1+x} = 1 - x + \frac{x^2}{1+x} \quad (3.4)$$

puis on remplace (3.4) par $\frac{1}{a + \|Y + \mu\|^2}$, le dernier terme à droite de l'égalité (3.3) est donné

1. Ce estimateur est défini pour la première fois par Stein en 1956 [26], et il a démontré que $\mu_5^{JS}(X)$ est admissible sous la perte quadratique si ($p > 2$).

$$\begin{aligned}
\mathbb{E}_\mu \left[\frac{(Y + \mu)^t Y - \frac{b}{2}}{a + \|Y + \mu\|^2} \right] \rho'(\|Y\|^2) &= \mathbb{E}_\mu \left[\frac{(Y + \mu)^t Y - \frac{b}{2}}{a + \|Y\|^2 + \|\mu\|^2} \right] \left(1 - \frac{2\mu^t Y}{a + \|Y\|^2 + \|\mu\|^2} \right) \\
&\quad \rho'(\|Y\|^2) + O\left(\frac{1}{a + \|\mu\|^2}\right) \\
&= \mathbb{E}_\mu \left[\mathbb{E}_\mu \left\{ \frac{(Y + \mu)^t Y - \frac{b}{2}}{a + \|Y\|^2 + \|\mu\|^2} \left(1 - \frac{2\mu^t Y}{a + \|Y\|^2 + \|\mu\|^2} \right) / \|Y\|^2 \right\} \right] \\
&\quad \rho'(\|Y\|^2) + O\left(\frac{1}{a + \|\mu\|^2}\right) \\
&= \mathbb{E}_\mu \left\{ \frac{\|Y\|^2 - \frac{b}{2}}{a + \|Y\|^2 + \|\mu\|^2} \left(\frac{2\|\mu\|^2 \|Y\|/2}{(a + \|Y\|^2 + \|\mu\|^2)^2} \right) / \|Y\|^2 \right\} \\
&\quad \rho'(\|Y\|^2) + O\left(\frac{1}{a + \|\mu\|^2}\right) \\
&\geq \mathbb{E}_\mu \left[\frac{(1 - \frac{2}{p})\|Y\|^2 - \frac{b}{2}}{a + \|Y\|^2 + \|\mu\|^2} \right] \\
&\quad \rho'(\|Y\|^2) + O\left(\frac{1}{a + \|\mu\|^2}\right)
\end{aligned} \tag{3.5}$$

Pour voir que cette quantité est positive, sous la condition que (b) est petit, et (a) est grand nous regardons,

$$f(A) = A\mathbb{E} \left(\frac{\|Y\|^2 \rho'(\|Y\|^2)}{A + \|Y\|^2} \right) \tag{3.6}$$

$$\text{et } g(A) = A\mathbb{E} \left(\frac{\rho'(\|Y\|^2)}{A + \|Y\|^2} \right) \tag{3.7}$$

C'est clair que f et g deux fonctions continues strictement positives sur $[1, \infty[$, avec une limite non nulle à l'infini, il s'ensuit que

$$c = \inf_{A \geq 1} f(A) = 0 \tag{3.8}$$

$$d = \sup_{A \geq 1} g(A) > \infty \tag{3.9}$$

Si b est choisi de sorte que

$$\left(1 - \frac{2}{p}\right)c - \frac{b}{2}d > 0 \tag{3.10}$$

$$R(\mu, \mu_5^{js}) \leq \mathbb{E}_\mu \rho(\|X - \mu\|^2) \quad \text{pour tout } \mu \tag{3.11}$$

3.3 L'hypothèse de normalité

L'innadmissibilité de l'estimateur usuel pour $p \geq 3$, n'exige pas l'hypothèse de normalité, nous donnerons ce resultat sans preuve, Soit X un p -vecteur de variables aléatoire, avec moyenne μ , et du moment d'ordre 4 finie,

$$\mathbb{E}_\mu (X_i - \mu_i)^4 \leq M < \infty \tag{3.12}$$

pour simplifier la notation, nous supposons que les X_i ne sont pas corrélés, est on écrit

$$\mathbb{E}_\mu [(X_i - \mu_i)^2] = \sigma_i^2 \tag{3.13}$$

alors pour $p \geq 3$, $b < 2(p - 2) \min \sigma_i^2$ et suffisamment grand a , depend seulement de M , on a

$$\mathbb{E}_\mu \sum_{i=1}^p \left[\left(1 - \frac{b}{\sigma_i^2 [a + \sum \frac{X_i^2}{\sigma_i^2}]} \right) X_i - \mu_i \right]^2 < \mathbb{E}_\mu \left[\sum_{i=1}^p (X_i - \mu_i)^2 \right] = \sum_{i=1}^p \sigma_i^2 \tag{3.14}$$

Remarque 3.3.0.1. *Il serait souhaitable d'obtenir des formules explicites pour les estimateurs que l'on peut sérieusement recommander dans les deux cas précédents.*

3.4 Formulation du problème générale de l'estimation admissible avec la perte quadratique

Soit l'espace $(Z, \mathcal{A}, \lambda)$ avec Z l'espace d'échantillon, et \mathcal{A} une tribue et λ la mesure σ -finie sur \mathcal{A} , et soit l'espace $(\Theta, \mathcal{C}, \mathbb{P}(\cdot/\cdot))$, avec Θ l'espace des

3.4 Formulation du problème générale de l'estimation admissible avec la perte quadratique

paramètres $\beta \in \Theta$, et \mathcal{C} une tribue et $\mathbb{P}(\cdot/\cdot)$ la fonction \mathcal{A} -mesurable à valeur positive dans $(Z \times \Theta)$, telque pour tout $\beta \in \Theta$ on a $\mathbb{P}(\cdot/\beta)$ est une densité de probabilité par rapport à λ , definit par

$$\int \mathbb{P}(z/\beta)d\lambda(z) = 1 \quad (3.15)$$

Soit A l'espace d'action ou (l'espace de decision) de dimension k avec des coordonnés réeles, et α la fonction \mathcal{C} -mesurable definit sur Θ a l'ensemble des matrices symétriques semidefinit positive de dimension $(k \times k)$, et η la fonction \mathcal{C} -mesurable definit sur Θ a A .

On remarque que z est distribuer sur Z , selon la densité de probabilité $\mathbb{P}(\cdot/\beta)$ par rapport à λ , ou β est inconnue, si on choisie une action $a \in A$, alors on definit la fonction de perte suivante

$$L(\beta, a) = [a - \eta(\beta)]^t \alpha(\beta) [a - \eta(\beta)] \quad (3.16)$$

Un estimateur $\hat{\eta}$ de $\eta(\beta)$, est une fonction \mathcal{A} -mesurable definit sur Z à A , ca fonction de risque $R(\cdot, \hat{\eta})$ est la fonction sur Θ , definit par

$$R(\beta, \hat{\eta}) = \mathbb{E}_\beta ([\hat{\eta}(z) - \eta(\beta)]^t \alpha(\beta) [\hat{\eta}(z) - \eta(\beta)]) \quad (3.17)$$

On veut choisir $\hat{\eta}$ afin de garder $R(\beta, \hat{\eta})$ petit, mais ce n'est pas une déclaration précise, pour tout estimateur $\hat{\eta}$ donné, on peut modifier $\hat{\eta}$, pour diminuer $R(\beta, \hat{\eta})$ pour quelque β , mais l'augmenter avec d'autres β , dans beaucoup de problemes il existe un estimateur couramment utilisé, par exemple, l'estimateur de maximum de vraisemblance, donc il est naturel de poser la question que ce estimateur est admissible au sens de Wald.

On donne un condition suffisente pour la classe des estimateurs presque admissible, il faut dit que dans [30], la condition de bornéture du risque a été omis par inadvertance dans les théorèmes de [29] ,(il est necessaire de justifié

$$\hat{\eta}_\pi \left[\int \alpha(\beta) \mathbb{P}(x/\beta) d\pi(\beta) \right]^{-1} \int \alpha(\beta) \eta(\beta) \mathbb{P}(x/\beta) d\pi(\beta) \quad (3.18)$$

avec la condition que les intégrales précédents soit finie, on remarque que si π est une mesure de probabilité, alors $\hat{\eta}_\pi$ est l'estimateur de bayes de $\eta(\beta)$, telque $\hat{\eta} = \hat{\eta}_\pi$, qui minimiser

$$\int \mathbb{E}_\beta ([\hat{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\hat{\eta}(X) - \eta(\beta)]) d\pi(\beta) \quad (3.19)$$

si q est une densité de probabilité par rapport à π , alors on peut ecrit,

$$(q, \pi)(S) = \int_S q(\beta) d\pi(\beta) \quad (3.20)$$

Théorème 3.4.1. *Si $\hat{\eta}$ est un estimateur de $\eta(\beta)$ avec un risque borné, telque pour tout ensemble $\mathcal{C} \subseteq \mathcal{F}$ (\mathcal{F} est une famille dénombrable des ensembles dont l'union est Θ), on a*

$$\inf_{q \in S(\mathcal{C})} \frac{\int \mathbb{E}_\beta ([\hat{\eta}(X) - \hat{\eta}_\pi(X)]^t \alpha(\beta) [\hat{\eta}(X) - \hat{\eta}_\pi(X)]) q(\beta) d\pi(\beta)}{\int_{\mathcal{C}} q(\beta) d\pi(\beta)} = 0 \quad (3.21)$$

ou $S(\mathcal{C})$ est l'ensembes des densités de probabilité par rapport à π , qui sont constant (mais pas nulle) sur \mathcal{C} .

Alors, $\hat{\eta}$ est un estimateur **presque admissible** par rapport à π .

Démonstration :

Suppose le contraire, c'est à dire il existe un estimateur $\bar{\eta}$, telque

$$\mathbb{E}_\beta ([\bar{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\bar{\eta}(X) - \eta(\beta)]) \leq \mathbb{E}_\beta ([\hat{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\hat{\eta}(X) - \eta(\beta)]) \quad (3.22)$$

Avec une inégalité stricte sur un ensemble S de partie positive π -mesurable, on choisir $\varepsilon > 0$ et $C \subseteq \mathcal{F}$, telque $\pi(C \cap S_\varepsilon) > 0$ ou S_ε est l'ensemble de β

$$\mathbb{E}_\beta ([\bar{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\bar{\eta}(X) - \eta(\beta)]) \leq \mathbb{E}_\beta ([\hat{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\hat{\eta}(X) - \eta(\beta)]) - \varepsilon \quad (3.23)$$

donc pour tout $q \in S(C)$

$$\int \mathbb{E}_\beta ([\bar{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\bar{\eta}(X) - \eta(\beta)]) q(\beta) d\pi(\beta) \leq \int \mathbb{E}_\beta ([\hat{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\hat{\eta}(X) - \eta(\beta)]) q(\beta) d\pi(\beta) - \varepsilon \int_{C \cap S_\varepsilon} q(\beta) d\pi(\beta)$$

il s'ensuit que $\frac{\varepsilon \pi(C \cap S_\varepsilon)}{\pi(C)}$ est égale,

$$\begin{aligned} &= \varepsilon \frac{\int_{C \cap S_\varepsilon} q(\beta) d\pi(\beta)}{\int_C q(\beta) d\pi(\beta)} \\ &\leq \frac{1}{\int_C q(\beta) d\pi(\beta)} \int \mathbb{E}_\beta ([\hat{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\hat{\eta}(X) - \eta(\beta)]) q(\beta) d\pi(\beta) \\ &\quad - \int \mathbb{E}_\beta ([\bar{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\bar{\eta}(X) - \eta(\beta)]) q(\beta) d\pi(\beta) \\ &\leq \frac{1}{\int_C q(\beta) d\pi(\beta)} \int \mathbb{E}_\beta ([\hat{\eta}(X) - \eta(\beta)]^t \alpha(\beta) [\hat{\eta}(X) - \eta(\beta)]) q(\beta) d\pi(\beta) \\ &\quad - \int \mathbb{E}_\beta ([\hat{\eta}_\pi(X) - \eta(\beta)]^t \alpha(\beta) [\hat{\eta}_\pi(X) - \eta(\beta)]) q(\beta) d\pi(\beta) \\ &= \frac{\int \mathbb{E}_\beta ([\hat{\eta}(X) - \hat{\eta}_\pi(X)]^t \alpha(\beta) [\hat{\eta}(X) - \hat{\eta}_\pi(X)]) q(\beta) d\pi(\beta)}{\int_C q(\beta) d\pi(\beta)} \end{aligned}$$

on à contradiction avec (3.21).

Chapitre 4

Sur l'estimation sous certaines classes de fonction de perte équilibrée généralisée

4.1 Sur l'estimation sous certaines classes de fonction de perte équilibrée pondérée

Dans cette section, nous présentons une classe de fonction de perte, pour estimer un paramètre inconnue β , qui connue sous le non (la fonction de perte équilibré pondéré) definit par

$$L_{w,\beta_0}(\beta, \hat{\beta}) = wq(\beta)(\hat{\beta} - \beta_0)^2 + (1 - w)q(\beta)(\hat{\beta} - \beta)^2 \quad (4.1)$$

avec $0 \leq w \leq 1$, $q(\beta)$ est une fonction de poids positive, et β_0 un estimateur référence "priori", plusieurs exemples sont donnés en ce qui concerne (admissibilité, dominonce, bayésianité et minimaxité) dans plusieurs cas comme dans [11], on va montrer que les resultats pour la perte L_{w,β_0} , peuvent être déduit directement du perte quadratique pondéré ($w=0$), des problemes spécifiques liés à l'espace des paramètres contraints, qui comprennent le choix de l'estimateur référence β_0 , on prend β_0 est l'estimateur de maximum de vraisemblance de β , dans cette section on va estimer le paramètre inconnue

β , sous le modèle $(X_1, \dots, X_p) \sim F_\beta$, et la perte (4.1). Ce terme dépend de la valeur observée de $\beta_0(X)$, et reflète la proximité de $\hat{\beta}$ à β sous la perte quadratique pondérée, et la proximité de $\hat{\beta}$ à β_0 sous le carré de distance pondéré, le premier terme à droite de (1.1) est analogue à un terme de pénalité pour manque de régularité dans la régression non paramétrique, le poids w détermine l'importance relative de ces deux critères, le choix de la perte (4.1) est inspiré par Zellner 1994 [1] dans le cas $q(\beta) = 1$ (la fonction de perte équilibrée), et β_0 est l'estimateur de moindres carrés, en particulier si $\beta_0(X) = \bar{X}$, alors la perte (4.1) devient

$$\frac{w}{p} \sum_{i=1}^p (X_i - \hat{\beta})^2 + (1 - w)(\hat{\beta} - \beta)^2$$

cependant, il est utile de considérer β_0 comme un estimateur de référence plus général que l'estimateur de moindres carrés, comme un schéma unificateur pour établir des propriétés théoriques de décision, de plus nous étudions l'application de (4.1) dans le contexte d'espace de paramètres restreints Θ , ou il sera souhaitable que l'estimateur de référence prenne des valeurs uniquement dans Θ .

Comme le montre [Dey 1999 [11]] le problème de l'admissibilité, la dominance et la bayésianité pour la fonction de perte équilibrée (FPE) ne dépend pas de w , et peut être déduit par des résultats précédemment ou à être établis sous la perte quadratique ($w = 0$).

4.1.1 Admissibilité et dominance

Pour l'estimateur $\hat{\beta}(X)$, on note le risque associé à la perte (4.1) par $R_{w,\beta_0}(\beta, \hat{\beta})$, dans le cas ($w = 0$) on écrit tout simplement $R_0(\beta, \hat{\beta})$, le risque est donc indépendant de β_0 , et on note la fonction de perte L_{0,β_0} par L_0 , et la différence entre les pertes Δ_{0,β_0} par Δ_0 , comme dans [11], rappelons que Δ_{w,β_0} est défini

$$\Delta_{w,\beta_0}(\beta, \widehat{\beta}_1, \widehat{\beta}_2) = L_{w,\beta_0}(\beta, \widehat{\beta}_1) - L_{w,\beta_0}(\beta, \widehat{\beta}_2)$$

Lemme 4.1.1. *Se lemme est donne la relations entres les fonctions de pertes L_{w,β_0} , R_{w,β_0} et Δ_{w,β_0} quand $0 \leq w < 1$, on à*

1. $\Delta_{w,\beta_0}(\beta, \beta_0 + (1-w)g, \beta_0) = (1-w)^2 \Delta_0(\beta, \beta_0 + g, \beta_0)$
2. $\Delta_{w,\beta_0}(\beta, \beta_0 + (1-w)g_1, \beta_0 + (1-w)g_2) = (1-w)^2 \Delta_0(\beta, \beta_0 + g_1, \beta_0 + g_2)$
3. $R_{w,\beta_0}(\beta, \beta_0(X) + (1-w)g(X)) = w(1-w)R_0(\beta, \beta_0(X)) + (1-w)^2 R_0(\beta, \beta_0(X) + g(X))$

Démonstration :

Prener d'abord l'esperance de l'égalité 1 on obtient alors,

$$R_{w,\beta_0}(\beta, \beta_0(X) + (1-w)g(X)) = R_{w,\beta_0}(\beta, \beta_0(X)) + (1-w)^2 \{R_0(\beta, \beta_0(X) + g(X)) - R_0(\beta, \beta_0(X))\}$$

l'égalité 3 étant donné que

$$R_{w,\beta_0}(\beta, \beta_0(X)) = (1-w)R_0(\beta, \beta_0(X))$$

l'égalité 2 est déduit directement comme resultats de 1

$$\Delta_{w,\beta_0}(\beta, \beta_0 + (1-w)g_1, \beta_0 + (1-w)g_2) = \Delta_{w,\beta_0}(\beta, \beta_0 + (1-w)g_1, \beta_0) - \Delta_{w,\beta_0}(\beta, \beta_0 + (1-w)g_2, \beta_0)$$

finallement, l'égalité 1 implique de simlifier le terme suivant

$$\begin{aligned} L_{w,\beta_0}(\beta, \beta_0 + (1-w)g) &= q(\beta) \{g^2(1-w)^2 + 2g(1-w)^2(\beta_0 - \beta) \\ &\quad + (1-w)(\beta_0 - \beta)^2\} \\ &= q(\beta)(1-w)^2 \{g^2(1-w)^2 + 2g(\beta_0 - \beta)\} + L_{w,\beta_0}(\beta, \beta_0) \end{aligned}$$

alors on à

$$\Delta_{w,\beta_0}(\beta, \beta_0 + (1-w)g, \beta_0) = q(\beta)(1-w)^2 \{g^2(1-w)^2 + 2g(\beta_0 - \beta)\}$$

maintenat ce qui suit est immédiate.

1. *l'estimateur $\beta_0(X) + (1 - w)g(X)$ est admissible sous la perte L_{w,β_0} , si est seulement si l'estimateur $\beta_0(X) + g(X)$ est admissible sous la perte L_0 .*
2. *$\beta_0(X) + (1 - w)g_1(X)$ domine $\beta_0(X) + (1 - w)g_2(X)$ sous la perte L_{w,β_0} , si est seulement si $\beta_0(X) + g_1(X)$ domine $\beta_0(X) + g_2(X)$ sous la perte L_0 .*

Remarque 4.1.1. *Pour compléter ce qui précède en ce qui concerne l'admissibilité et la dominance, des connexions similaires entre les estimateurs de bayes pour la variable w , sont facilement dérivées et données dans le lemme suivant, en particulière l'estimateur de bayes sous la perte L_{w,β_0} , peut être exprimé simplement comme une combinaison linéaire convexe de l'estimateur de bayes sous la perte L_0 (poids $(1 - w)$) et β_0 (poids (w)).*

Lemme 4.1.2. *sous la perte (4.1), l'estimateur de bayes de β avec la loi à priori π , admet la représentation suivante*

$$\beta_\pi(X) = w\beta_0(X) + (1 - w) \frac{\mathbb{E}_\pi[\beta q(\beta)/X]}{\mathbb{E}_\pi[q(\beta)/X]}$$

de manière équivalente,

$$\beta_\pi(X) = \beta_0(X) + (1 - w) \left\{ \frac{\mathbb{E}_\pi[\beta q(\beta)/X]}{\mathbb{E}_\pi[q(\beta)/X]} - \beta_0(X) \right\} \quad (4.2)$$

avec $\mathbb{E}_\pi[\beta^i q(\beta)/X] < \infty$, $i = 0, 1$, avec probabilité 1.

Démonstration :

La preuve est similaire à celle donnée par [11] dans le cas ou $q(\cdot) = 1$, il découle même de resultat de [11] pour le cas $q(\cdot) = 1$, est donne que l'estimateur de bayes pour (q, π) est équivalent à l'estimateur de bayes pour $(q = 1, \pi' = q \times \pi)$.

Remarque 4.1.2. *Les resultats concernant la dominance, l'admissibilité et la bayésianité d'un paramètre sous l'erreur quadratique, ou ou la perte quadratique pondéré sont bien sûr abondants dans la littérature, par exemple de*

4.1.1 Admissibilité et dominance 63

~~nombreux résultats peuvent être trouvés dans [2], ainsi que dans divers do-~~
cuments datant d'au moins 50 ans, le corollaire 1, et lemme 2, impliquent
que pour arbitraire $\beta_0(X)$, l'inverse est également vraie, par conséquent, les
problèmes qui traitent les questions (dominance, admissibilité et bayésianité)
par rapport à une fonction de perte L_{w,β_0} , peut être déjà traités par une
analyse de perte L_0 .

Exemple 6. (Estimateurs linéaires affines) Ce exemple donne le résultat
connu concernant la performance des estimateurs linéaires affines, sous les
hypothèses : $\mathbb{E}_\beta(X) = \beta$, $\text{var}_\beta(X) = \sigma^2(\beta) = \sigma^2$ voir [3] indiquent que pour
estimer β sous la perte quadratique :

i $cX + d$ est inadmissible quand $c > 1$, $c < 0$, ou $c = 1$, $d \neq 0$

ii $cX + d$ avec $X \sim \mathcal{N}(\beta, 1)$ est admissible si et seulement si

$$c = 1, d = 0 \quad \text{ou} \quad c \in [0, 1[, d \in \mathbb{R}$$

iii $cX + d$ avec $X \sim \Gamma(\alpha, \beta/\alpha)$, est admissible si et seulement si $c =$
 $\alpha/(\alpha + 1), d = 0$ ou $c \in]0, \alpha/(\alpha + 1)], d > 0$.

le résultat d'inadmissibilité dans (i) se traduit, pour un estimateur référence
arbitraire $\beta_0(X)$, au l'inadmissibilité sous la perte L_{w,β_0} de l'estimateur de la
forme

$$\beta_0(X) + (1 - w)(cX + d - \beta_0(X)) = w\beta_0(X) + (1 - w)(cX + d)$$

pour $c > 1$, $c < 0$, ou $c = 1$, $d \neq 0$.

en revanche, étant donné (ii) les estimateurs de la forme

$$w\beta_0(X) + (1 - w)(cX + d) \quad \text{avec} \quad X \sim \mathcal{N}(\beta, 1)$$

sont admissible si et seulement si $c = 1$, $d = 0$ ou $c \in [0, 1[, d \in \mathbb{R}$, en
particulière si $\beta_0(X) = X$, on obtient l'inadmissibilité de $c'X + d'$ (sous la
perte L_{w,β_0}) pour $c' > 1, c' < w$, ou $c' = w, d' \neq 0$, et on obtient l'admissibilité
si et seulement si $c' = 1, d' = 0$ ou $c' \in [w, 1[, d' \in \mathbb{R}$.

On peut tirer des conclusions de (iii), avec $X \sim \Gamma(\alpha, \beta/\alpha)$, $c'X + d'$ (sous
la perte L_{w,β_0} , $\beta_0(X) = X$) est admissible (pour estimer β , si et seulement
si $c' = (\alpha + w)/(\alpha + 1), d' = 0$ ou $c' \in]w, (\alpha + w)/(\alpha + 1)], d > 0$.

Exemple 64.7. (*estimateurs équivoques à risque minimum (ERM)*)

On considère le modèle $X \sim f_0(x - \beta)$ avec $\mathbb{E}_0(X^2 < \infty)$, et on prend la perte (4.1) avec ($q \equiv 1$), il est bien connu que sous la perte L_0 , les estimateurs invariants de position de la forme $X + c$ a un risque constante, et le choix optimal de (ERM) est donné par $\beta^*(X) = X + c^*$ (ou $c^* = -\mathbb{E}_0(X)$).

l'estimateur $\beta^*(X)$ (sous la perte L_0) est minimax, admissible et de bayes, par rapport à la la loi à priori de Haar (invariants à droit) $\pi^*(\beta) = 1$.

Remarque 4.1.3. Les resultats précédents nous disent que sous la perte L_{w,β_0} , l'estimateur $\beta^{**}(X) = w\beta_0(X) + (1 - w)\beta^*(X)$ est admissible et de bayes par rapport à ($\pi^*(\beta) = 1$), en particulière si l'estimateur $\beta_0(X) = X + c_0$ (estimateur invariants de position), alors l'estimateur donné par $X + wc_0 + (1 - w)c^*$, est égale à $\beta^{**}(X)$ si $c_0 = c^*$, et on a aussi,

I A un risque constant (partie donnée (3) de lemme (4.1.1)).

II Est optimale entre les estimateurs invariants de position (localisation)

$$X + c.$$

III Est en vertu du théorème suivante minimax.

4.1.2 Minimaxité

Maintenant nous capitalisons sur les resultats du lemme (4.1.1), pour présenter les resultats généraux, et divers exemples concernant les estimateurs minimaxs sous la perte L_{w,β_0} , dans les deux cas ou l'estimateur référence $\beta_0(X)$ a un risque constante et n'a pas de risque constant.

β_0 a un risque constant sous L_0

.

Théorème 4.1.1. Suppose que $\beta_0(X)$ a un risque constant γ sous la perte L_0 , alors l'estimateur $(\beta_0(X) + (1 - w)g(X))$ est minimax sous la perte L_{w,β_0} , avec un risque minimax égale $(1 - w)(w\gamma + (1 - w)r)$ si et seulement si, $\beta_0 + g(X)$ est minimax sous la perte L_0 , avec un risque minimax égale r .

Démonstration :

tant que $R_0(\beta, \beta_0(X)) = \gamma$ par hypothèse, on obtient de (3),

$$R_{w,\beta_0}(\beta, \beta_0(X) + (1-w)g(X)) = w(1-w)\gamma + (1-w)^2 R_0(\beta, \beta_0(X) + g(X)) \quad (4.3)$$

ce qui fallait que,

$$\sup_{\beta} R_{w,\beta_0}(\beta, \beta_0(X) + (1-w)g(X)) = w(1-w)\gamma + (1-w)^2 \sup_{\beta} R_0(\beta, \beta_0(X) + g(X))$$

et donné le resultat.

Corollaire 4.1.2. *Suppose que l'estimateur $\beta_0(X)$ a un risque constant sous la perte L_0 , alors $\beta_0(X)$ est minimax sous la perte L_{w,β_0} , avec un risque minimax constant égale $(1-w)\gamma$ si et seulement si $\beta_0(X)$ est minimax sous la perte L_0 avec un risque minimax constant γ .*

Démonstration :

(Applique le théorème précédent avec $g(X) = 0$), Nous poursuivons avec une selection d'application du théorème et corollaire précédents.

Exemple 8. (Poison) soit $X \sim P(\beta)$, $\beta \in]0, +\infty[$, avec la perte (perte d'information normalisé) défini par

$$L_0(\beta, \hat{\beta}) = \frac{(\hat{\beta} - \beta)^2}{\beta}$$

tant que $\beta_0(X)$ est minimax sous la perte L_0 , avec un risque minimax réduit, le corollaire (4.1.2) montrer que $\beta_0(X)$ est aussi minimax sous la perte L_{w,β_0} , ($w \in]0, 1[$, poids $q(\beta) = \frac{1}{\beta}$), avec un risque minimax constant $(1-w)$.

Exemple 9. (Binomiale) soit $X \sim B_i(n, \beta)$, $\beta \in]0, 1[$, avec la perte (perte d'information normalisé) défini par

$$L_0(\beta, \hat{\beta}) = \frac{(\hat{\beta} - \beta)^2}{\beta(1-\beta)}$$

tant que $\beta_0(X) = \frac{X}{n}$, est minimax sous la perte L_0 avec un risque minimax constant $\frac{1}{n}$, le corollaire précédent montre que $\beta_0(X)$, est aussi minimax sous

la perte $L_{w,\beta_0}(w \in]0, 1[)$, poids $q(\beta) = \frac{1}{\beta(1-\beta)}$, avec un risque minimax constant $\frac{(1-w)}{n}$.

En revanche si on a la fonction de perte quadratique

$$L_0(\beta, \hat{\beta}) = (\hat{\beta} - \beta)^2$$

le corollaire (4.1.2) applique sur l'estimateur $\beta_0(X) = \frac{X+(\sqrt{n}/2)}{n+\sqrt{n}}$, avec un risque minimax constant, et implique la minimaxité de $\beta_0(X)$, sous la perte $L_{w,\beta_0}(w \in]0, 1[)$.

finallement, si on a l'estimateur $\beta_0(X) = \frac{X}{n}$ sous la perte quadratique, le théorème precedent ne s'applique pas, et on peut procéde directement en trouvant un risque de bayes (constant), et donc estimateur minimax voir [4].

Dans l'exemple suivant, l'estimateur référence $\beta_0(X)$ n'est pas minimax, mais le théorème precedent reste applicable.

Exemple 10. (Binomiale negative), soit $X \sim NB_i(\alpha, \beta)$, $\alpha > 0$ connu, $\beta \in]0, 1[$ inconnu, avec $\beta = \mathbb{E}(X) = \alpha(\frac{1}{p} - 1)$ et $Var_\beta(X) = \alpha\beta(1 + \beta)$ et ca densité est definit par :

$$\mathbb{P}_\beta(X = x) = \frac{\Gamma(\alpha + x)}{x!\Gamma(\alpha)} \left(\frac{\beta}{\alpha + \beta} \right)^x \mathbb{I}_{\{0,1,\dots\}}(x)$$

On considère la fonction de perte definit par

$$L_0(\beta, \hat{\beta}) = \frac{(\hat{\beta} - \beta)^2}{Var_\beta(X)}$$

avec $\beta_0(X) = X$ est l'estimateur de maximum de vraisemblance, avec un risque constant égale a $\gamma = 1$, étant donné que sous la perte L_0 , $\frac{X}{1+\alpha}(X - \frac{\alpha}{1+\alpha}X)$ est minimax, avec le risque minimax $r = \frac{\alpha}{1+\alpha}$ [5].

Le théorème precedent montrer que $X - (1-w)\frac{\alpha}{1+\alpha}X = (\frac{1+w\alpha}{1+\alpha})X$ est minimax sous la perte L_{w,β_0} , avec le risque minimax $(1-w)(w + (1-w)(\frac{\alpha}{1+\alpha})) = \frac{(1-w)(\alpha+w)}{(1+\alpha)}$, de plus tantque $\frac{X}{1+\alpha}$ est admissible et domine $\beta_0(X) = X$ sous la perte L_0 , donc comme resultat de corollaire precedent, $(\frac{1+w\alpha}{1+\alpha})X$ est admissible

et domine $\beta_0(X) = X$ sous la perte $L_{w,\beta_0}(w \in]0, 1])$.

Finallement, nous soulignons que d'autres résultats de d'admissibilité et de bayésianité sous la perte L_0 , tels que ceux donnés par [[6]], peut être traduit via (corollaire et théorème précédent) au résultat d'admissibilité et de bayésianité sous la perte L_{w,β_0} .

Dans l'exemple suivant, il existe plusieurs estimateurs minimaxs.

Exemple 11. (Paramètre d'échelle à borne inférieure), soit le modèle $X \sim \Gamma(\alpha, \beta)$, (densité proportionnelle à $x^{\alpha-1} e^{-x/\beta}$), on considère l'estimation d'une borne inférieure β , $\beta \geq a > 0$ (a connu), sous la perte (1.1) et $q(\beta) = \beta^{-2}$ soit

$$h_\alpha(z) = \frac{z^{\alpha+1} e^{-z}}{\int_0^z t^{\alpha+1} e^{-t} dt}$$

[7] a montré que sous la perte L_0 , l'estimateur de Bayes $\beta_a^*(X)$ par rapport à la loi a priori $\pi_a^*(\beta) = \beta^{-1} \mathbb{I}_{]a, \infty[}(\beta)$, défini par

$$\beta_a^*(X) = \frac{X}{\alpha + 1} \left(1 + h_{\alpha+2} \left(\frac{X}{a} \right) \right)$$

est admissible, minimax de β , avec le risque minimax $r = \frac{1}{\alpha+1}$ voir [8].

Pour un estimateur de référence plus générale $\beta_0(X)$ on a montré dans les résultats précédents que $\beta_a^{**}(X) = w\beta_0(X) + (1-w)\beta_a^*(X)$, est un estimateur généralisé de Bayes admissible, par rapport à π_a^* .

Si l'estimateur $\beta_0(X)$ est un estimateur (ERM) défini par $\frac{X}{\alpha+1}$, donc comme résultat de théorème précédent, l'estimateur $\beta_a^{**}(X)$ défini par,

$$\frac{X}{1+\alpha} + (1-w)\beta_a^*(X) = \frac{X}{\alpha+1} \left(1 + (1-w)h_{\alpha+2} \left(\frac{X}{a} \right) \right)$$

n'est pas seulement admissible, mais aussi minimax avec le risque minimax $(\frac{1-w}{\alpha+1})$ (tant que $\gamma = R(\beta, \frac{X}{\alpha+1}) = \frac{1}{\alpha+1}$).

Remarque 4.1.4. On remarque qu'il existe de nombreux estimateurs minimax sous la perte L_0 et donc beaucoup sous la perte L_{w,β_0} , quand $\beta_0(X)$ est un (ERM), des développements similaires pour les paramètres d'échelle à borne inférieure sous la perte L_0 , qui peuvent être appliquées aux pertes L_{w,β_0} , voir [9].

Remarque 4.1.5. *En ce qui concerne l'exemple précédent, si l'estimateur de référence β_0 prend des valeurs en dehors de l'espace des paramètres $[a, \infty[$, il n'y a aucune garantie que $\mathbb{P}(\beta_a^{**}(X) \in [a, \infty]) = 1$, en effet si $\beta_0(X) = \frac{X}{\alpha+1}$ alors,*

$$\lim_{x \rightarrow 0} \beta_a^{**}(x) = (1 - w) \lim_{x \rightarrow 0} \beta_a^*(x) = (1 - w) \frac{(\alpha + 2)}{(\alpha + 1)} a$$

donc $\lim_{x \rightarrow 0} \beta_a^*(x) = \frac{(\alpha + 2)}{(\alpha + 1)} a$ [7], on peut conclure que $\beta_a^{**}(x)$ prendrait des valeurs dans l'espace des paramètres si et seulement si, $w \leq \frac{1}{\alpha+2}$, ce phénomène n'est pas limité à cet exemple et se produit, puisque la fonction de perte reflète la proximité de $\hat{\beta}$ à $\beta_0(X)$, plutôt que le critère $\hat{\beta} \in \Theta$.

C'est motivation pour étudier, et présenter des exemples et avoir des résultats disponible pour un estimateur généralisée $\beta_0(X)$, qui n'est pas nécessairement de moindre carré et qui prend des valeurs uniquement dans l'espace des paramètres.

Les propriétés d'admissibilité et bayesianité de $\beta_a^{**}(x)$ dans l'exemple précédent, reste vérifié dans le cas où $\beta_0(X)$ est la version tranqué de (ERM), défini par, $\beta_0(X) = \max(a, \frac{X}{\alpha+1})$, ou dans le cas de l'estimateur du maximum de vraisemblance défini par $\beta_0(X) = \max(a, X/\alpha)$.

$\beta_0(X)$ dans un cas plus généralisé

Malgré tout les différentes applications d'estimation minimax du théorème et corollaire donné dans les exemples précédents, elles sont limitées aux cas où l'estimateur référence $\beta_0(X)$ présente un risque constant, en revanche le développement suivant se rapporte à des situations où $\beta_0(X)$, n'a pas de risque constant, mais possède plutôt des propriétés de risque nous permettant d'exploiter les critères pour la minimaxité, voir ([2] section 5.1).

Lemme 4.1.3. *Si β_π est un estimateur de bayes par rapport à la loi a priori propre π , et $S_\pi = \left\{ \beta \in \Theta, \sup_{\beta} R(\beta, \beta_\pi), \beta \in \Theta = R(\beta, \beta_\pi) \right\}$, alors β_π est minimax, quand $\mathbb{P}_\pi(\beta \in S_\pi) = 1$.*

$$S_{w,\beta_0}(\widehat{\beta}) = \left\{ \beta \in \Theta, \sup_{\beta} R_{w,\beta_0}(\beta, \widehat{\beta}), \beta \in \Theta = R_{w,\beta_0}(\beta, \widehat{\beta}) \right\}$$

(c-à-d, l'ensemble des β tel que $\widehat{\beta}(X)$ atteint sont risque maximum sous la perte L_{w,β_0} , on note $S_0(\widehat{\beta})$ au lieu de $S_{0,\beta_0}(\widehat{\beta})$.

Lemme 4.1.4. (★) suppose que $\beta_\pi(X) = \beta_0(X) + g_\pi(X)$ est un estimateur de bayes unique sous la perte L_0 pour la loi a priori propre π , suppose aussi que $\mathbb{P}_\pi(\beta \in S_0(\beta_\pi)) = \mathbb{P}_\pi(\beta \in S_0(\beta_0)) = 1$, alors l'estimateur $\beta_\pi(X) = \beta_0(X) + g_\pi(X)$, est minimax et unique sous la perte¹ L_{w,β_0} .

Démonstration :

Étant donné que sous la perte L_{w,β_0} , l'estimateur de bayes $\beta'_\pi(X) = \beta_0(X) + (1-w)g_\pi(X)$ est unique par rapport à π , comme resultat de (4.2), il suffit de montrer que

$$\mathbb{P}_\pi(\beta \in S_{w,\beta_0}(\beta'_\pi)) \tag{4.4}$$

puisque nous pourrions alors appliquer le lemme (4.1.3) de cette partie, pour déduire le résultat, mais (4.4) suit par le lemme (4.1.1) partie (3), étant donné que par la représentation du risque $R_{w,\beta_0}(\beta, \beta'_\pi)$ et par hypothèse, que les deux risques $R_0(\beta, \beta_0)$ et $R_0(\beta, \beta'_\pi)$, atteint leur sup avec la même probabilité 1.

4.2 Sur l'estimation de bayes sous certaines classes de fonction de perte équilibrée généralisée

Dans cette section on va generaliser la fonction de perte équilibrée de la section précédent, on ne va pas donc se restreindre au cas de la fonction de

1. On note que ces hypothèses implique que $\beta_0(X) + g_\pi(X)$ est minimax sous la perte L_0

$$L_{\rho,w,\beta_0}(\beta, \widehat{\beta}) = w\rho(\beta_0, \widehat{\beta}) + (1 - w)\rho(\beta, \widehat{\beta}) \quad (4.5)$$

ainsi que la version pondéré $q(\beta)L_{\rho,w,\beta_0}$, avec $q(\cdot)$ soit une fonction de poids positive, et $\rho(\beta, \widehat{\beta})$ est une fonction de perte arbitraire, β_0 est l'estimateur référence "cible" de β , et $w \in [0, 1[$.

Un développement générale en ce qui concerne les estimateurs bayésiennes pour le cas déséquilibré ($w = 0$), des représentations sont donné pour différents choix de ρ , par exemple la perte absolu, entropie, linex, intrinsèque et généralisation du perte quadratique.

Cette section concerne l'estimation ponctuelle bayésienne du paramètre inconnue β , avec le même modèle de section précédent sous la perte (4.5), et l'estimateur référence $\beta_0(X)$ comme un estimateur de maximum de vraisemblance (MV) ou de moindre carré (MC), ou d'autre estimateurs.

4.2.1 Estimation de bayes sous la perte équilibrée

On considère l'estimation de bayes sous la perte (4.5) avec $w = 0$ (cas déséquilibré), on le note comme la section précédente L_0 , on va montrer comment l'estimateur de bayes de β sous la perte L_{ρ,w,β_0} peut être dérivé ou exprimé en termes d'un estimateur de bayes sous β sous la perte L_0 , sous l'hypothèse que la perte $\rho(\widehat{\beta}, \beta_0) < \infty$ pour au moins un $\widehat{\beta} \neq \beta_0$.

Lemme 4.2.1. *pour l'estimation de β sous la fonction de perte (4.5), avec la loi a priori $\pi(\beta)$, l'estimateur de bayes $\beta_{\pi,w}(X)$ correspond à la solution de bayes $\beta^*(X)$ par rapport a $(\pi^*(\beta/X), L_0)$ pour tout x , alors que*

$$\pi^*(\beta/X) = w\mathbb{I}_{\beta_0(X)}(\beta) + (1 - w)\pi(\beta/X)$$

c-à-d, un mélange d'une masse ponctuelle à $\beta_0(X)$ et la loi a posteriori $\pi(\beta/X)$.

Démonstration :

4.2.2 Quelques applications

Indiquer $\mu_*(\cdot)$ et $\nu_*(\cdot)$, deux mesures dominants respectivement de $\pi(\beta/X)$

et $\pi^*(\beta/X)$, on a par définition de $\beta_{\pi,w}(X)$, $\beta^*(X)$ et L_0

$$\begin{aligned}\beta_{\pi,w}(X) &= \arg \min_{\hat{\beta}} \int_{\Theta} \left\{ w\rho(\beta_0, \hat{\beta}) + (1-w)\rho(\beta, \hat{\beta}) \right\} \pi(\beta/X) d\mu_*(\beta) \\ &= \arg \min_{\hat{\beta}} \int_{\Theta \cup \{\beta_0(X)\}} L_0(\beta, \hat{\beta}) \pi^*(\beta/X) d\nu_*(\beta) = \beta^*(X)\end{aligned}$$

Remarque 4.2.1. Nous avertissons que $\beta^*(X)$ n'est pas un estimateur de bayes sous la perte L_0 , parce que $\pi^*(\beta/X)$ n'est pas la loi a posteriori associée avec π , tandis que $\beta_{\pi,w}(X)$ est en effet un estimateur de bayes sous la perte L_{ρ,w,β_0} et la loi a priori π .

Remarque 4.2.2. Le lemme précédent s'applique aussi dans le cas de la fonction de perte pondéré défini par

$$L_{\rho,w,\beta_0}^q(\beta, \hat{\beta}) = q(\beta)L_{\rho,w,\beta_0}(\beta, \hat{\beta})$$

avec $q(\beta)$ une fonction de poids positive, en effet, il est facile de voir que l'estimateur de bayes de β sous la perte L_{ρ,w,β_0}^q , avec la loi a priori π_0 est équivalent à l'estimateur de bayes de β , sous la perte L_{ρ,w,β_0} , avec la loi a priori $\pi = q \times \pi_0$.

4.2.2 Quelques applications

Une généralisation de la perte quadratique

Le choix de ρ est le suivant

$$\rho(\beta, \hat{\beta}) = \tau(\beta)(\beta - \hat{\beta})^2 \quad \tau(\cdot) > 0$$

alors (4.5) devient

$$w\tau(\beta_0)(\beta - \beta_0)^2 + (1-w)\tau(\beta)(\beta - \hat{\beta})^2$$

on a l'estimateur de bayes sous L_0 , avec la loi a priori π , donnée par

$$\delta_{0,\pi}(x) = \frac{\mathbb{E}_{\pi}(\beta\tau(\beta)/x)}{\mathbb{E}_{\pi}(\tau(\beta)/x)}$$

Sous la condition $\mathbb{E}_\pi(\beta^i \tau(\beta)/x) < \infty$, $i = 0, 1$ par tout x , le lemme précédent

donne,

$$\beta_{w,\pi}(x) = \frac{\mathbb{E}_{\pi^*}(\beta \tau(\beta)/x)}{\mathbb{E}_{\pi^*}(\tau(\beta)/x)} = \frac{w\beta_0(x)\tau(\beta_0(x)) + (1-w)\mathbb{E}_\pi(\beta \tau(\beta)/x)}{w\tau(\beta_0(x)) + (1-w)\mathbb{E}_\pi(\tau(\beta)/x)}$$

le cas ou $(\tau(\beta) = 1, \beta_0$ est un estimateur de (MC), est le cas de la fonction de perte quadratique équilibré et $(\beta_{w,\pi}(x) = w\beta_0(x) + (1-w)\mathbb{E}_\pi(\beta/x))$, comme présentée par [38], et [11], étudier le cas ou $\tau(\beta) = 1$ mais $\beta_0(x)$ est un choix arbitraire, ainsi que la version pondéré de cas précédent (quadratique), a été étudié par [17] par rapport aux critère de la théorie de decision, tels que la bayésianité, dominance, admissibilité et minimaxité, sachant que [14] et aussi étudier le cas (quadratique avec $\tau(\beta) = 1$).

Le perte d'entropie équilibré

Le choix de ρ est le suivant

$$\rho(\beta, \hat{\beta}) = \frac{\beta}{\hat{\beta}} - \log\left(\frac{\beta}{\hat{\beta}}\right) - 1$$

alors (4.5) devient

$$w \left(\frac{\beta_0}{\hat{\beta}} - \log\left(\frac{\beta_0}{\hat{\beta}}\right) - 1 \right) + (1-w) \left(\frac{\beta}{\hat{\beta}} - \log\left(\frac{\beta}{\hat{\beta}}\right) - 1 \right) \quad (4.6)$$

la solution de bayes sous la perte L_0 , avec la loi a priori π , est donné par

$$\beta_{0,\pi}(x) = \mathbb{E}_\pi(\beta/x)$$

sous la condition $\mathbb{E}_\pi(\beta/x) < \infty$ et $\mathbb{E}_\pi((\log(\beta)/x) < \infty, \forall x)$, le lemme précédent donne

$$\beta_{w,\pi}(x) = \mathbb{E}_{\pi^*}(\beta/x) = w\beta_0(x) + (1-w)\mathbb{E}_\pi(\beta/x)$$

comme exemple particulière, en prend le modèle $X \sim \Gamma(\alpha, \beta)$, α est connu, $\beta > 0$, (densité proportionnelle à $x^{\alpha-1}e^{-x/\beta}$), on considère l'estimation de β

telque, $\beta^{-1} \sim \Gamma(\gamma, \frac{1}{h})$, $\gamma > -\alpha$, $h \geq 0$.

La loi a posteriori de β^{-1} , suit la loi $\Gamma(\alpha + \gamma, \frac{1}{h+x})$, alors l'estimateur de bayes unique de β , sous la perte d'entropie équilibré (4.6), definit comme suit

$$\beta_{w,\pi}(x) = w\beta_0(x) + (1-w)\frac{h+x}{\alpha+\gamma-1}$$

Le perte de Stein

Ce perte est definit par

$$\rho(\beta, \hat{\beta}) = \left(\frac{\hat{\beta}}{\beta}\right)^\iota - \iota \log\left(\frac{\hat{\beta}}{\beta}\right) - 1 \quad \iota \neq 0$$

cette classe de perte est une généralisation du perte d'entropie équilibré ($\iota = 1$), ainsi que la perte de Stein dans le cas ($\iota = -1$), illustre bien le lemme précédent.

Sous la perte L_0 , on a la solution de bayes $\beta_{0,\pi}(x) = (\mathbb{E}_\pi(\frac{1}{\beta^\iota}/x))^{-\frac{1}{\iota}}$, avec la condition que le risque soit finie, le lemme précédent montrer que

$$\beta_{w,\pi}(x) = (\mathbb{E}_{\pi^*}(\frac{1}{\beta^\iota}/x))^{-\frac{1}{\iota}} = \left\{ \frac{w}{(\beta_0(x))^\iota} + (1-w)\mathbb{E}_\pi(\frac{1}{\beta^\iota}/x) \right\}^{-\frac{1}{\iota}}$$

Le perte $((\beta/\hat{\beta}) - 1)^2$

La solution de bayes sous la perte L_0 avec la loi a priori π definit sur $]0, \infty[$, est definit par

$$\beta_{0,\pi}(x) = \frac{\mathbb{E}_\pi(\beta^2/x)}{\mathbb{E}_\pi(\beta/x)}$$

avec la condition que $\mathbb{E}_\pi(\beta^2/x) < \infty$, $\forall x$, le lemme précédent montrer que

$$\beta_{w,\pi}(x) = \frac{\mathbb{E}_{\pi^*}(\beta^2/x)}{\mathbb{E}_{\pi^*}(\beta/x)} = \frac{w\beta_0^2 + (1-w)\mathbb{E}_\pi(\beta^2/x)}{w\beta_0 + (1-w)\mathbb{E}_\pi(\beta/x)}$$

dans [29]⁷⁴ Rodrigues et Zellner en 1994 étudié l'estimateur de bayes sous cette fonction de perte mais avec $(\beta_0(X))$ est l'estimateur de moindre carré) et sous le modèle exponentiel.

La fonction de perte de linex

Cette fonction de perte est défini par

$$\rho(\beta, \hat{\beta}) = e^{a(\hat{\beta}-\beta)} - a(\hat{\beta} - \beta) - 1, \quad a \neq 0$$

la solution de bayes sous la perte L_0 est donné par

$$\beta_{0,\pi}(x) = -\frac{1}{a} \log \mathbb{E}_\pi(e^{-a\beta}/x)$$

avec la condition que le risque soit finie, par conséquent, en utilisant le lemme précédent donc on obtient

$$\begin{aligned} \beta_{w,\pi}(x) &= -\frac{1}{a} \log \mathbb{E}_{\pi^*}(e^{-a\beta}/x) \\ &= -\frac{1}{a} \log(w e^{-a\beta_0(x)} + (1-w) \mathbb{E}_\pi(e^{-a\beta}/x)) \\ &= -\frac{1}{a} \log(w e^{-a\beta_0(x)} + (1-w) e^{-a\beta_{0,\pi}(x)}) \end{aligned}$$

Remarque 4.2.2.1. *Pour des exemples concerne la perte linex voir [39] [27].*

La fonction de perte intrinsèque équilibrée

On travaille sous le modèle $X/\beta \sim f(X/\beta)$ avec la fonction de perte

$$\rho(\beta, \hat{\beta}) = d(f(\cdot/\beta), f(\cdot/\hat{\beta}))$$

c-à-d la distance entre deux fonctions, donc la perte intrinsèque équilibrée est défini par

$$w d(f(\cdot/\beta_0), f(\cdot/\hat{\beta})) + (1-w) d(f(\cdot/\beta), f(\cdot/\hat{\beta})) \tag{4.7}$$

on a deux candidats intérêt pour d , sont la distance de Hillinger et la distance de Kulback-Leibler, donc on obtient

$$L_{w,\beta_0}^{KL}(\beta, \widehat{\beta}) = w \mathbb{E}_{\beta_0} \left[\ln \frac{f(X/\beta_0)}{f(X/\beta)} \right] + (1-w) \mathbb{E}_{\beta} \left[\ln \frac{f(X/\beta)}{f(X/\widehat{\beta})} \right] \quad (4.8)$$

✖ Le perte équilibré de Hillinger

$$L_{w,\beta_0}^H(\beta, \widehat{\beta}) = w \frac{1}{2} \mathbb{E}_{\beta_0} \left[\left(\sqrt{\frac{f(X/\widehat{\beta})}{f(X/\beta_0)}} - 1 \right)^2 \right] - (1-w) \frac{1}{2} \mathbb{E}_{\beta} \left[\left(\sqrt{\frac{f(X/\widehat{\beta})}{f(X/\beta)}} - 1 \right)^2 \right] \quad (4.9)$$

ou de manière équivalente

$$L_{w,\beta_0}^H(\beta, \widehat{\beta}) = 1 - w \mathbb{E}_{\beta_0} \left[\sqrt{\frac{f(X/\widehat{\beta})}{f(X/\beta_0)}} \right] - (1-w) \mathbb{E}_{\beta} \left[\sqrt{\frac{f(X/\widehat{\beta})}{f(X/\beta)}} \right] \quad (4.10)$$

Par conséquent, avec les représentation bayésienne commeNT dans le cas déséquilibré ($w = 0$) [2] [30] et avec le lemme précédent, on pèut construire representation bayésienne pour L^H, L^{KL} .

On prend comme exemple la famille exponentielle de paramètre naturelle des destributions avec des densités

$$f(x, \beta) = e^{\beta T(x) - \psi(\beta)} h(x)$$

(par rapport a la la mesure σ -finie ν definit sur χ), avec le paramètre naturelle inconnu β , donc la fonction de perte de Kullback-Lielber devient

$$w \left[(\beta_0 - \widehat{\beta}) \psi'(\beta_0) + \psi(\widehat{\beta}) - \psi(\beta_0) \right] + (1-w) \left[(\beta - \widehat{\beta}) \psi'(\beta) + \psi(\widehat{\beta}) - \psi(\beta) \right] \quad (4.11)$$

de plus, sous la perte L_0 ($w = 0$ dans (4.10)) avec la loi a priori π , l'estimateur de bayes $\beta_{0,\pi}(x)$ est donné comme solution de $\psi'(\beta_{0,\pi}(x)) = \mathbb{E}_{\pi}[\psi'(\beta)/x]$, alors comme resultat l'estimateur de bayes $\beta_{w,\pi}(x)$ admet la representation suivant

$$\psi'(\beta_{w,\pi}(x)) = w \psi'(\beta_0(x)) + (1-w) \psi'(\beta_{0,\pi}(x))$$

on obtient

$$\beta_{w,\pi}(x) = w\beta_0(x) + (1 - w)\beta_{0,\pi}(x)$$

Un combinaison lineaire convexe de β_0 et l'estimateur de bayes $\beta_{0,\pi}(x)$, également, pour la famille exponentielle naturelle des distributions comme ci-dissus, la fonction de perte équilibré de Hillinger (4.9) devient

$$1 - we^{\left\{ \psi\left(\frac{\beta_0 + \hat{\beta}}{2}\right) - \frac{\psi(\beta_0) + \psi(\hat{\beta})}{2} \right\}} - (1 - w)e^{\left\{ \psi\left(\frac{\beta + \hat{\beta}}{2}\right) - \frac{\psi(\beta) + \psi(\hat{\beta})}{2} \right\}} \quad (4.12)$$

sous le modèle $\mathcal{N}(\beta, \infty)$ la perte (4.11) devient

$$1 - we^{-\frac{(\beta_0 - \hat{\beta})^2}{8}} - (1 - w)e^{-\frac{(\beta - \hat{\beta})^2}{8}}$$

est qui réffète la perte normal équilibré borné, voir [32] pou le cas $w = 0$.

Remarque 4.2.3. *Le perte d'entropie équilibré est équivalent au perte équilibré de Kullback-Leibler sous le modèle $\Gamma(\alpha, \beta)$, avec $\alpha > 0$ connu, et le paramtre inconnue β , voir aussi [28] [30].*

Le perte équilibré absolue ou L^1

Cette fonction de perte est definit par

$$\rho(\beta, \hat{\beta}) = |\hat{\beta} - \beta|$$

donc la fonction de perte équilibrée absolue est definit par

$$L_{w,\beta_0}(\beta, \hat{\beta}) = w|\hat{\beta} - \beta_0| + (1 - w)|\beta - \hat{\beta}| \quad (4.13)$$

onà la solution de bayes associé à L_0 , est la mediane a posteriorie (voir chapitre 1), le lemme précédent donne que l'estimateur de bayes $\beta_{w,\pi}(x)$ de β , par rapport au perte (4.13) et la loi a priori π , est la medianne de $\pi^*(\beta/x)$, pour tout x.

Maintenant, on va travailler sous le modèle $f(\cdot/\beta)$, donc avec la loi a priori

π , on obtient un unique medianne a posteriori definit par

$$\begin{aligned} \beta_{w,\pi}(x) &= F_{\beta/x}^{-1} \left(\frac{1-2w}{2(1-w)} \right) \mathbb{I}_{[0, \frac{1}{2}-w]}(\alpha(x)) + \beta_0(x) \mathbb{I}_{[\frac{1}{2}-w, \frac{1}{2}]}(\alpha(x)) \\ &+ F_{\beta/x}^{-1} \left(\frac{1}{2(1-w)} \right) \mathbb{I}_{[\frac{1}{2}, 1]}(\alpha(x)), \quad \forall x \end{aligned} \quad (4.14)$$

avec $\alpha(x) = (1-w)\mathbb{P}_\pi(\beta \leq \beta_0(x)|x)$, et $F_{\beta/x}^{-1}$ est l'inverse de la fonction de repartition a posteriori, on remarque que si $w \geq \frac{1}{2}$ alors $\beta_{w,\pi}(x) = \beta_0(x)$ (c-à-d la masse ponctuelle de $\beta_0(x)$ a une probabilité assez grand pour forcer la mediane a $\beta_0(x)$).

Maintenant, nous donnons quelques application de (4.13).

✂ Le cas de la loi normal avec moyenne positive :

Soit $X/\beta \sim \mathcal{N}(\beta, \sigma^2)$ avec $\beta > 0$ inconnu et σ^2 connu, et soit la fonction de repartition F_0 , la théorie de decision concernant l'estimation de β a un longue histoire, voir [19].

Prenez $\beta_0(X) = \beta_{MV}(X) = \max(0, x)$ et $w < \frac{1}{2}$ dans (4.12), on considère l'estimateur $\beta_{w,\pi}(X)$ associé à la loi a priori (flat) $\pi(\beta) = \mathbb{I}_{]0, \infty[}(\beta)$, pour simplifier (4.14) on a

1. $\mathbb{P}_\pi(\beta \geq y|x) = \frac{F_0(x-y)}{F_0(x)} \quad \forall y \geq 0.$
2. $F_{\beta/x}^{-1}(z) = x - F_0^{-1}((1-z)F_0(x))$
3. $\alpha(x) = (1-w)\mathbb{P}_\pi(\beta \leq \beta_0(x)|x) = (1-w)(1 - \frac{1}{2F_0(x)})\mathbb{I}_{]0, \infty[}(x)$

donc, tantque $\alpha(x) < \frac{1}{2}$ et $x \leq F_0^{-1}(1-w)$ on obtient,

$$\begin{aligned} \beta_{w,\pi}(x) &= F_{\beta/x}^{-1} \left(1 - \frac{1}{2(1-w)} \right) \mathbb{I}_{]-\infty, F_0^{-1}(1-w)}(x) + \beta_0(x) \mathbb{I}_{]F_0^{-1}(1-w), \infty}(x) \\ &= \left\{ x - F_0^{-1} \left(\frac{F_0(x)}{2(1-w)} \right) \right\} \mathbb{I}_{]-\infty, F_0^{-1}(1-w)}(x) + x \mathbb{I}_{]F_0^{-1}(1-w), \infty}(x) \\ &= x - \left\{ F_0^{-1} \left(\frac{F_0(x)}{2(1-w)} \right) \right\} \mathbb{I}_{]-\infty, F_0^{-1}(1-w)}(x) \end{aligned}$$

Notons que cette expression reste vérifiée dans le cas déséquilibré ($w=0$),

tandis qu'un développement similaire se présente pour les modèles $X|\beta \sim f_0(x - \beta)$ avec $\beta \geq 0$ et f_0 connue et symétrique.

✂ Soit $X|\beta \sim \mathcal{N}(\beta, \sigma^2)$ avec $\beta \in \mathbb{R}$, σ^2 connue, avec la fonction de répartition définie par $\Phi(\frac{x-\beta}{\sigma})$, on a sous la loi a priori $\beta \sim \pi(\beta) = \mathcal{N}(\mu, \tau^2)$, (μ, τ^2) connue, et la perte (4.12) avec $\beta_0(X) = X$, $w < \frac{1}{2}$, et tant que la loi a posteriori $X|\beta \sim \mathcal{N}(\frac{\tau^2}{\tau^2+\sigma^2}x + \frac{\sigma^2}{\tau^2+\sigma^2}\mu, \frac{\tau^2\sigma^2}{\tau^2+\sigma^2})$ on a

$$\alpha(x) = (1 - w)\mathbb{P}_\pi(\beta \leq x|x) = (1 - w)\Phi(d(x - \mu))$$

avec

$$d = \frac{\sigma}{\tau\sqrt{\tau^2 + \sigma^2}}$$

et

$$F_{\beta|x}^{-1}(\alpha) = \frac{\tau^2}{\tau^2 + \sigma^2}x + \frac{\sigma^2}{\tau^2 + \sigma^2}\mu + \sqrt{\frac{\tau^2\sigma^2}{\tau^2 + \sigma^2}}\Phi^{-1}(\alpha)$$

donc de (4.14), on obtient l'estimateur linéaire par morceaux suivant

$$\beta_{w,\pi}(x) \begin{cases} \frac{x\tau^2 + \mu\sigma^2}{\tau^2 + \sigma^2} + \sqrt{\frac{\tau^2\sigma^2}{\tau^2 + \sigma^2}}\Phi^{-1}\left(\frac{1-2w}{2(1-w)}\right) & \text{si } x \leq \mu + \frac{1}{d}\Phi^{-1}\left(\frac{1-2w}{2(1-w)}\right) \\ x & \text{si } x \in \left[\mu + \frac{1}{d}\Phi^{-1}\left(\frac{1-2w}{2(1-w)}\right), \mu + \frac{1}{d}\Phi^{-1}\left(\frac{1}{2(1-w)}\right)\right] \\ \frac{x\tau^2 + \mu\sigma^2}{\tau^2 + \sigma^2} + \sqrt{\frac{\tau^2\sigma^2}{\tau^2 + \sigma^2}}\Phi^{-1}\left(\frac{1}{2(1-w)}\right) & \text{si } x \geq \mu + \frac{1}{d}\Phi^{-1}\left(\frac{1}{2(1-w)}\right) \end{cases}$$

4.3 La fonction de perte équilibrée prolongée

Dans cette section on va présenter une fonction de perte généralisée, [Shalabch, H. Toutenburg et C.Heuman le 5 decembre 2007][33], sont prolongent et présentent une fonction de perte générale appelée la fonction de perte équilibrée prolongée, dans laquelle la fonction de perte prédictive proposée par Zellner 1994 [38], est un cas particulier.

On travaille sous le modèle de régression linéaire $Y = \beta X + \epsilon$ avec $\hat{\beta}$ est l'estimateur de β . donc la fonction de perte quadratique qui reflète la qualité

$$(X\hat{\beta} - Y)^t(X\hat{\beta} - Y) \quad (4.15)$$

on a $\hat{Y} = X\hat{\beta}$ (prévision de Y), de même la précision de l'estimateur $\hat{\beta}$ est mesurer par la fonction de perte pondéré défini par

$$(\hat{\beta} - \beta)^t X^t X (\hat{\beta} - \beta) \quad (4.16)$$

[Zellner 1994][38] a considéré a la fois les deux critères et proposé la fonction de perte pondérée défini par

$$BL(\hat{\beta}) = w(X\hat{\beta} - Y)^t(X\hat{\beta} - Y) + (1 - w)(\hat{\beta} - \beta)^t X^t X (\hat{\beta} - \beta) \quad (4.17)$$

avec $w \in [0, 1]$ (qui fournit le poids attribué a la qualité d'ajustement du modèle). Si on considère la prédiction de l'échantillon, alors le prédicteur $\hat{Y} = X\hat{\beta}$ est utilisé pour prédire la valeur actuel Y ainsi que la valeur moyenne $\mathbb{E}(Y)$, dans certains cas, il peut être souhaitable d'envisager la prédiction simultanée de Y et $\mathbb{E}(Y)$, et définit la fonction cible suivante

$$T = \lambda Y + (1 - \lambda)\mathbb{E}(Y) \quad \lambda \in [0, 1] \quad (4.18)$$

si on utilisons le prédicteur $X\hat{\beta}$ pour la prévision simultanée des valeurs actuel et moyenne de Y à travers la fonction cible, on obtient la fonction de perte prédictive défini par

$$\begin{aligned} PL(\hat{\beta}) &= (X\hat{\beta} - T)^t(X\hat{\beta} - T) & (4.19) \\ &= \lambda^2(X\hat{\beta} - Y)^t(X\hat{\beta} - Y) + (1 - \lambda)^2(\hat{\beta} - \beta)^t X^t X (\hat{\beta} - \beta) \\ &+ 2\lambda(1 - w)(X\hat{\beta} - T)^t X (X\hat{\beta} - T) \end{aligned}$$

si on prend la fonction de perte équilibrée et la fonction de perte prédictive [Shalabch 2007][33] proposons la fonction de perte pondérée (généralisée)

$$\begin{aligned} WL(\widehat{\beta}) &= \lambda_1(X\widehat{\beta} - Y)^t(X\widehat{\beta} - Y) + \lambda_2(\widehat{\beta} - \beta)^t X^t X(\widehat{\beta} - \beta) \quad (4.20) \\ &+ (1 - \lambda_1 - \lambda_2)(X\widehat{\beta} - Y)^t X(\widehat{\beta} - \beta) \end{aligned}$$

avec $\lambda_1 \in [0, 1]$ $\lambda_2 \in [0, 1]$, cette fonction de perte prolongée englobe la perte (4.15)(4.16)(4.17)(4.18), comme ces cas particulières, elle est donc assez générale et suffisamment souple.

Chapitre 5

Applications

5.1 L'estimateur de bayes minimax

On va donner une application du lemme (★), à la distribution normale dans le cas $X \sim \mathcal{N}(\beta, \sigma^2)$ ou $\beta \in [-m, m]$, et on prend l'estimateur de référence $\beta_0(X)$ comme l'estimateur de maximum de vraisemblance $\beta_{MV}(X) = (m \wedge X) \text{sgn}(X)$.

Incidentement, [Marchand et Perron (2001)][24] fournit divers estimateurs de la forme $(\beta_0(X) + g(X))$ dominants $\beta_{MV}(X)$, sous la perte quadratique L_0 , qui se traduisent par divers estimateurs de la forme $(\beta_0(X) + (1 - w)g(X))$ dominants $\beta_{MV}(X)$, sous la perte L_{w, β_0} avec $\beta_0(X) = \beta_{MV}(X)$.

Un exemple est donné par l'estimateur minimax du théorème suivant, quand $m \leq \sigma$, en revenant à l'estimation minimax de β , à l'aide du travail de [Casella et Strawderman 1981][9] qui donne des conditions à l'estimateurs de bayes (on le note $\beta_{BU}(X)$), par rapport à la loi a priori bornée uniforme π_{BU} sur $\{-m, m\}$ soit minimax.

Théorème 5.1.1. *Pour l'estimation de $\beta \in [-m, m]$ sous la perte définie dans (4.1), avec $q(\beta) = 1$ et $\beta_0 = \beta_{MV}$, sous le modèle $X \sim \mathcal{N}(\beta, \sigma^2)$, avec la densité définie par $\frac{1}{\sigma} \Phi(\frac{x-\beta}{\sigma})$, et fonction de répartition définie par $\Phi(\frac{x-\beta}{\sigma})$,*

$$(1 - w)\beta_{BU}(X) + w\beta_{MV}(X)$$

est minima et unique, tant que $m \leq m_0\sigma$, avec $m_0 \simeq 1,0567$, et

$$\beta_{BU}(X) = \frac{m}{\sigma} \tanh(mx/\sigma^2).$$

Démonstration :

On utilise le lemme (★) et lemme ce qui propose plus tard dans cette section, on a d'après [Casella et Strawderman 1981 ||9],

$$\mathbb{P}_\pi(\beta \in S_0(\beta_\pi)) = 1 \text{ pour } \pi = \pi_{BU} \text{ et } m \leq m_0\sigma \blacksquare$$

dans le lemme suivant on va montrer que la valeur maximum du risque $R(\beta, \beta_{MV}(X))$ nécessairement atteint à $\beta = (+-)m$, n'importe quand $m \leq \sqrt{2}\sigma$ puisque $m_0 \leq \sqrt{2}$, en d'autre terme la condition (■) est vérifié, donc le résultat suit directement comme une conséquence du lemme (★).

Lemme 5.1.1. Pour $X \sim \mathcal{N}(\beta, \sigma^2)$, avec $|\beta| \leq m$, le risque maximum sous la perte quadratique de l'estimateur $\beta_{MV}(X)$ est atteinte sur la frontière $\{-m, m\}$, n'importe quand $m \leq \sqrt{2}\sigma$.

Démonstration :

sans perte de généralité, soit $\sigma = 1$, d'abord on va montrer que pour tout $m \in]0, \sqrt{2}[$

$$(A) \quad \sup_{\beta \in [-m, m]} \{R_0(\beta, \beta_{MV}(X))\} = \max\{R_0(0, \beta_{MV}(X))R_0(m, \beta_{MV}(X))\}$$

puis on montre que

$$(B) \quad R_0(0, \beta_{MV}(X)) \leq R_0(m, \beta_{MV}(X)) \text{ ssi } m \leq m_1 \simeq 1.96422$$

c'est clair que (A) et (B) (qui sont tous deux d'intérêts indépendants), pour établir (A), on procède directement en montrant que pour $m \leq \sqrt{2}$.

$$\frac{\partial}{\partial^3 \beta} R_0(\beta, \beta_{MV}(X)) \geq 0$$

pour $\beta \in [0, m]$, en effet on observe que

i La convexité de $R_0(\beta, \beta_{MV}(X))$ pour $\beta \in [0, m]$, ou

ii Un changement de concavité à convexité de $R_0(\beta, \beta_{MV}(X))$ sur $[0, m]$.

Les deux impliquent (A), notons que la suffisance de (ii) exploite le fait que le risque de β_{MV} est une fonction de β , ce qui implique que son dérivé à $\beta = 0^+$ est nulle, et que le risque soit décroissante pour un $\beta > 0$ dans un voisinage de 0.

avec le développement de risque $\mathbb{E}[(\beta_{MV}(X) - \beta)^2]$ on obtient

$$\begin{aligned} R_0(\beta, \beta_{MV}(X)) &= \int_{-m}^m (x - \beta)^2 \Phi(x - \beta) dx + (m - \beta)^2 \Phi(\beta - m) \\ &+ (m + \beta)^2 \Phi(-(\beta + m)) \end{aligned} \quad (5.1)$$

avec des calculs directs on obtient

$$\begin{aligned} \frac{1}{2} \frac{\partial}{\partial \beta} R_0(\beta, \beta_{MV}(X)) &= (m + \beta) \Phi(-(\beta + m)) + (\beta - m) \Phi(\beta - m) \\ \frac{1}{2} \frac{\partial}{\partial^2 \beta} R_0(\beta, \beta_{MV}(X)) &= \Phi(-\beta - m) + \Phi(\beta - m) - (m + \beta) \Phi(\beta + m) \\ &+ (\beta - m) \Phi(\beta - m) \\ \frac{1}{2} \frac{\partial}{\partial^3 \beta} R_0(\beta, \beta_{MV}(X)) &= \Phi(\beta - m) (2 - (m - \beta)^2) - \Phi(\beta + m) \\ &(2 - (m + \beta)^2) \end{aligned}$$

Enfin, le resultat (A) suit de $\Phi(\beta - m) \geq \Phi(\beta + m) \geq 0$ et $2 - (m - \beta)^2 \geq 2 - (m + \beta)^2$ et $2 - (m - \beta)^2 \geq 0$ pour $\beta \in [0, m]$, avec $m \leq \sqrt{2}$.

Pour établir (B) utilisé (5.1) on écrit

$$\begin{aligned} R_0(0, \beta_{MV}(X)) &= 2m^2 \Phi(-m) + 2 \int_0^m x^2 \Phi(x) dx \\ \text{et } R_0(m, \beta_{MV}(X)) &= 4m^2 \Phi(-2m) + \int_0^{2m} x^2 \Phi(x) dx \end{aligned}$$

$$\begin{aligned} \Delta(0, m, \beta_{MV}) &= R_0(m, \beta_{MV}(X)) - R_0(m, \beta_{MV}(X)) \\ \frac{\partial \Delta(0, m, \beta_{MV})}{\partial m} &= 4m \underbrace{\{2\Phi(-2m) - m\Phi(2m) - \Phi(-m)\}} \\ &= 4mN(m) \end{aligned}$$

et on a

$$\frac{\partial N(m)}{\partial m} = \Phi(2m)\{e^{3m^2} + 4m^2 - 5\}$$

maintenant, on observe que $N(0) = \frac{1}{2} > 0$, $\lim_{m \rightarrow \infty} N(m) = 0$, et que $\frac{\partial}{\partial m} N(m)$ changer le sign du - au + dans $]0, \infty[$, cette condition implique que $N(m)$ changer le sign une fois du + au - quand $m \in]0, \infty[$, ce qui montre que $\Delta(0, m, \beta_{MV})$ a au plus un sign change de + au - pour $m \in]0, \infty[$, ($\Delta(0, 0, \beta_{MV}) = 0$), enfin, avec une évaluation numérique $\Delta(0, m, \beta_{MV}) = 0$ pour $m = m_1 = 1,96422$.

5.2 La performance de l'estimateur de type Stein par rapport a celle de moindre carré

La plupart de la litterature traitaient l'estimation de Stien des coefficients de regression, suppose que les X_i distribuer selon la distribution de Gauss (Normal) comme on a vu dans le deuxième chapitre, mais en pratique cette hypothèse pèut ne pas être vraie, comment la performance de l'estimateur de Stein change quand la distribution n'est pas gaussien (ne suit pas la loi normal) ?

Dans cette section an va etudier la performance de l'estimateur de moindre carrée par rapport à l'estimateur de Stein sous la fonction de perte équilibré prolongé (qu'on a vu dans la dernière section de chapitre 4), dans la structure de perte quadratique, dans le cas ou la distribution n'est pas neécessairement

On va comparer les fonctions de risque associé aux deux estimateurs (MC-JS), et on cherche des conditions caractérisant les scalaires, pour la dominance de l'estimateur (JS) par rapport a l'estimateur de (MC), on va coincide avec plusieurs formes populaires de fonction de perte qui se présentent comme des cas particulières de la fonction de perte équilibré prolongé, rappelons qu'on a travailler sous le modèle de regression lineaire

$$Y = \beta X + \epsilon$$

5.2.1 L'estimateur de (MC)

l'estimateur de (MC) de coefficient β est donné par

$$\beta_{MC} = (X^t X)^{-1} X^t Y \tag{5.2}$$

qui est bien connue pour son optimalité dans la classe des estimateurs linéaires et sans biais.

5.2.2 L'estimateur de (JS)

C'est une famille intéressante d'estimateurs non linéaires et biaisés de X, connus sous le nom d'estimateur de Stein, definit par

$$\beta_{JS}^6 = \left[1 - \left(\frac{k}{n - p + 2} \right) \frac{Y^t (I - H) Y}{Y^t H Y} \right] \beta_{MC} \tag{5.3}$$

$$\text{avec } H = X(X^t X)^{-1} X^t \tag{5.4}$$

et k est un scalaire positive voir [Shalabh 2006][33].

5.2.3 Le risque de l'estimateur de (MC)

On va voir la performance de ces deux estimateurs sous la fonction de perte équilibré prolongé definit dans la dernière section de chapitre(5) (WL), on

$$WL(\widehat{\beta}) = \lambda \epsilon^t \epsilon - \sigma(1 + \lambda_1 - \lambda_2) \epsilon^t X(\widehat{\beta} - \beta) + (\widehat{\beta} - \beta)^t X^t X(\widehat{\beta} - \beta) \quad (5.5)$$

On remplace $\widehat{\beta}$ par β_{MC} , on obtient le risque de (MC) défini par

$$R(\beta_{MC}) = \mathbb{E}(WL(\beta_{MC})) = \sigma^2 \lambda_1 n - \sigma^2 p(\lambda_1 - \lambda_2) \quad (5.6)$$

5.2.4 Le risque de l'estimateur de (JS)

L'expression exacte de la fonction de risque de l'estimateur (JS) dérivée de leur nature, serait suffisamment compliquée, nous utilisons donc la théorie d'approximation asymptotique des échantillons de grands tailles, pour dériver la fonction de risque.

Nous supposons que les variables explicatives sont asymptotiquement coopératives (c-à-d la forme limite de la matrice $n^{-1}X^tX$ est finie quand $n \mapsto +\infty$), cette hypothèse est nécessaire pour l'approximation asymptotique des grands échantillons),

maintenant, si on pose

$$\varepsilon = n^{\frac{1}{2}} X^t \epsilon$$

et

$$\delta = n^{\frac{1}{2}} \left(\frac{\epsilon^t \epsilon}{n} - 1 \right)$$

on obtient

$$\beta_{MC} - \beta = \frac{1}{n^{\frac{1}{2}}} S^{-1} \varepsilon \quad (5.7)$$

avec $S = \frac{1}{n} X^t X$

$$Y^t(I - H)Y = n + n^{\frac{1}{2}} \delta - \varepsilon^t S^{-1} \varepsilon$$

$$\begin{aligned} \frac{Y^t(I-H)Y}{(n-p+2)Y^tHY} &= \frac{1}{n\beta^tS\beta} \left(1 + \frac{\delta}{n^{\frac{1}{2}}} - \frac{1}{n}\varepsilon^tS^{-1}\varepsilon\right) \left(1 - \frac{p-2}{n}\right)^{-1} \\ &\quad \left(1 + \frac{2\beta^t\varepsilon}{n^{\frac{1}{2}}\beta^tS\beta} + \frac{\varepsilon^tS^{-1}\varepsilon}{n\beta^tS\beta}\right)^{-1} \\ &= \frac{1}{n\beta^tS\beta} + \frac{1}{n^{\frac{3}{2}}\beta^tS\beta} \left(\delta - \frac{2\beta^t\varepsilon}{\beta^tS\beta}\right) + O_p(n^{-2}) \quad (5.8) \end{aligned}$$

Si on remplace (5.7) (5.8) dans (5.3) on trouve

$$\begin{aligned} (\beta_{JS}^6 - \beta) &= \frac{1}{n^{\frac{1}{2}}}S^{-1}\varepsilon - \frac{k}{n^{\frac{3}{2}}\beta^tS\beta}[\delta\beta + (S^{-1} - \frac{2}{\beta^tS\beta}\beta\beta^t) \\ &\quad \varepsilon] + O_p(n^{-2}) \quad (5.9) \end{aligned}$$

avec l'utilisation des propriétés distributives de ε , ces resultats est on négligeant les termes d'ordre supérieur de petitesse que $O(n^{-1})$, on obtient avec (5.9), la forme suivante

$$\mathbb{E}[\varepsilon^tX(\beta_{JS}^6 - \beta)] = \sigma p - \frac{\sigma^2k}{n\beta^tS\beta} \left[\frac{\gamma_1}{n}e^tX\beta + \sigma(p-2)\right] \quad (5.10)$$

$$\begin{aligned} \mathbb{E}[(\beta_{JS}^6 - \beta)^tX^tX(\beta_{JS}^6 - \beta)] &= \sigma^2p - \frac{\sigma^3k}{n\beta^tS\beta} \left[\frac{2\gamma_1}{n}e^tX\beta \right. \\ &\quad \left. + 2\sigma(p-2) - 6k\right] \quad (5.11) \end{aligned}$$

on remplace $\widehat{\beta}$ par β_{JS}^6 dans l'equation (5.5), en utilisant les resultats ci-dessus et en concervant les termes a l'ordre $O(n^{-1})$, on obtient,

$$\begin{aligned} R(\beta_{JS}^6) &= \mathbb{E}[WL(\beta_{JS}^6)] \quad (5.12) \\ &= \sigma^2\lambda_1n - \sigma^2p(\lambda_1 - \lambda_2) - \frac{\sigma^4k}{n\beta^tS\beta} [(1 - \lambda_1 + \lambda_2) \\ &\quad \left(\frac{\gamma_1}{\sigma}\overline{X}^t\beta + p - 2\right) - k] \end{aligned}$$

avec \overline{X} est un vecteur de dimension p, représentent les moyennes des colonnes de matrice X (variable explicative).

On remarque de (5.6) et (5.12) que les deux critères de performance (qualité d'ajustement et précision de l'estimation), affectent la performance de risque de l'estimateur (MC) et (JS), et l'utilisation des deux critères ensemble a plus d'intérêt que l'utilisation de l'un des deux.

5.2.5 La comparaison des risques

On observe que l'estimateur de (JS) a un risque plus faible, par rapport à l'estimateur de (MC), quand

$$k < (1 - \lambda_1 + \lambda_2) \left(\frac{\gamma_1 \bar{X}^t}{\sigma} \beta + p - 2 \right) \quad (5.13)$$

à condition que

$$(\lambda_1 - \lambda_2) < 1 \quad \text{et} \quad \left(\frac{\gamma_1 \bar{X}^t}{\sigma} \beta + p - 2 \right) > 0 \quad (5.14)$$

ou

$$(\lambda_1 - \lambda_2) > 1 \quad \text{et} \quad \left(\frac{\gamma_1 \bar{X}^t}{\sigma} \beta + p - 2 \right) < 0 \quad (5.15)$$

quand la distribution est symétrique et/ou $\bar{X} = 0$, (c-à-d les observations sur les variables explicatives sont considérées comme des écarts par rapport à leur moyennes correspondants).

Donc, la condition (5.13) ne depend pas du paramètre inconnue β , et est satisfaite lorsque l'une des deux conditions suivantes est vraie

$$k < (1 - \lambda_1 + \lambda_2)(p - 2) \quad \text{et} \quad (\lambda_1 - \lambda_2) < 1 \quad \text{si} \quad p > 2. \quad (5.16)$$

$$k < (\lambda_1 - \lambda_2 - 1)(2 - p) \quad \text{et} \quad (\lambda_1 - \lambda_2) > 1 \quad \text{si} \quad p = 1, 2. \quad (5.17)$$

maintenant, nous examinons la performance des deux estimateurs précédents sous certaines fonctions de perte intéressantes,

✦ On considère le critère de la qualité d'ajustement du modèle, qui est un cas particulière de (WL) quand $\lambda_1 = 1$ et $\lambda_2 = 0$, on remarque de (5.6)

l'estimateur de (MC) reste invaincu par tout les estimateurs de type stein, quelque soit la nature des observations sur les variables explicatives, et leur distributions, cela correspond au résultats obtenue par [\[Srivastava et Shalabch 1996 page 143\]](#) [\[34\]](#).

- ✠ On considère le critère de précision de l'estimation, qui obtenue comme cas particulière de (WL) quand $\lambda_1 = 0$ et $\lambda_2 = 1$ donc l'estimateur de (JS) est mieux que l'estimateur de (MC), quand

$$k < 2\left(\frac{\gamma_1}{\sigma} \bar{X}^t \beta + p - 2\right) \quad (5.18)$$

sachant que la quantité à droit est positive, cette condition se reduit à

$$k < 2(p - 2), \quad p > 2 \quad (5.19)$$

quand la distribution est symétrique indepépendamment de la nature des données sur les variables explicatives, ou $\bar{X} = 0$, si les distributions sont symétriques ou asymétriques.

De même la condition (5.18) est satisfaittant que (5.19) est verifiée, à condition que $(\gamma_1 \text{ et } \bar{X}^t \beta)$ a le même sign (c-à-d $\bar{X}^t \beta$ est positive pour la distribution asymétrique positive, et negative pour la distribution asymétrique negative), en effet, c'est possible de trouver un estimateur de (JS) avec une meilleure performance que l'estimateur de (MC) même pou $p = 1$ et $p = 2$, quand

$$\gamma_1 \bar{X}^t \beta > 2\sigma \quad (5.20)$$

comme une remarque, la condition (5.19) est bien connue de la supériorité des estimateurs de type stein, sous la distribution normale.

- ✠ Si on remplace par $\lambda_1 = \theta$ et $\lambda_2 = (1 - \theta)$ dans (WL), on obtient la fonction de perte proposer par [Zellner 1994](#) pour $(0 \leq \theta < 1)$, une condition

suffisante pour que l'estimateur de (JS) est mieux que l'estimateur de (MC), est quand

$$k < 2(1 - \theta) \left(\frac{\gamma_1}{\sigma} \bar{X}^t \beta + p - 2 \right) \quad (5.21)$$

quand $\gamma_1 = 0$ et/ou $\bar{X} = 0$, la condition (5.21) prend la forme simple suivante

$$k < 2(1 - \theta)(p - 2), \quad p > 2 \quad (5.22)$$

ceci constitue une condition suffisante pour la supériorité des estimateurs de (JS) par rapport à l'estimateur de (MC), dans le cas où la distribution est asymétrique, à condition que $\text{sgn}(\gamma_1) = \text{sgn}(\bar{X}^t \beta)$.

De plus la condition (5.21) est vraie on peut trouver des estimateurs de (JS) mieux que l'estimateur de (MC) même si ($p = 1, 2$). Cette condition a été dérivée par [15], sous distribution normal, voir aussi [26].

✂ Maintenant, on considère le cas où $\lambda_1 = \lambda^2$ et $\lambda_2 = (1 - \lambda)^2$ dans (WL), on obtient la fonction de perte suivante

$$\lambda^2 (X\hat{\beta} - Y)^t (X\hat{\beta} - Y) + (1 - \lambda)^2 (\hat{\beta} - \beta)^t X^t X (\hat{\beta} - \beta) + 2\lambda(1 - \lambda) (X\hat{\beta} - Y)^t X (\hat{\beta} - \beta)$$

c'est une combinaison de la somme des carrés des résidus, et la somme pondérée des carrés d'erreurs d'estimation, et leur produit.

Et c'est la somme des carrés des erreurs de prédiction lorsque $X\hat{\beta}$ est utilisé pour la prédiction d'une combinaison convexe des valeurs actuelles et moyennes.

Donc depuis (5.6) et (5.12), l'estimateur de (JS) a un risque petit par rapport à l'estimateur de (MC), quand

$$k < 2(1 - \lambda) \left(\frac{\gamma_1}{\sigma} \bar{X}^t \beta + p - 2 \right) \quad (5.23)$$

de perte équilibré.

Enfin, la comparaison sous la condition (5.23) avec $\gamma_1 = 0$ correspond à la condition de [Shalabh 1995][35].

5.3 L'estimation de paramètre de la loi de Bernaulli sous la fonction de perte équilibrée de Zellner

Soit X_1, X_2, \dots, X_n une suite de variable aléatoire suit la loi de Bernaulli avec la densité

$$f(x, p) = p^x(1 - p)^{1-x} \quad x = 0, 1 \quad \text{et} \quad 0 < p < 1$$

on va estimer p sous la fonction de perte équilibrée

$$L(p, \hat{p}) = \frac{w}{n} \sum_{i=1}^n (X_i - \hat{p})^2 + (1 - w)(p - \hat{p})^2 \quad 0 < w < 1 \quad (5.24)$$

Dans cette application on va étudier l'admissibilité de l'estimateur lineaire (affine) de la forme $c\bar{X} + d$ pour l'estimation de la moyenne de la loi de Bernaulli, ou la moyenne de telles distributions exponentielles, sous la fonction de perte (5.24).

5.3.1 L'estimateur de bayes

Proposition 5.3.1. *La fonction de risque de l'estimateur $c\bar{X} + d$, sous la fonction de perte (5.24) est*

$$\begin{aligned} R(p, c\bar{X} + d) &= [(c - 1)p + d]^2 + \frac{p(p - 1)}{n} [(c - w)^2 + w(n - w)] \\ &= [(c - 1)^2 - \frac{(c - w)^2 + w(n - w)}{n}] p^2 \\ &+ [2d(c - 1) + \frac{(c - w)^2 + w(n - w)}{n}] p + d^2 \end{aligned}$$

$$r(\pi, c\bar{X} + d) = [(c-1)^2 - \frac{(c-w)^2 + w(n-w)}{n}] \frac{c(c+1)}{(\alpha+\beta)(\alpha+\beta+1)} \\ + [2d(c-1) + \frac{(c-w)^2 + w(n-w)}{n}] \frac{\alpha}{\alpha+\beta} + d^2$$

On peut facilement remarquer que la loi a priori de l'estimateur de bayes de p, suit la distribution beta $B(\alpha, \beta)$ avec la densité

$$\pi(p) = \frac{\Gamma(\alpha + \beta)}{\Gamma(\alpha)\Gamma(\beta)} p^{\alpha-1} (1-p)^{\beta-1} \quad 0 < p < 1 \quad (5.25)$$

avec $\alpha > 0$ et $\beta > 0$, alors la loi a posteriori est définie par

$$B(\alpha + \sum_{i=1}^n x_i, n - \sum_{i=1}^n x_i + \beta)$$

le risque a posteriori de l'estimateur \hat{p} sous (5.24) est

$$\mathbb{E}(L(\hat{p}, p)) = \frac{w}{n} \sum_{i=1}^n (X_i - \hat{p})^2 + (1-w) \mathbb{E}[(p - \hat{p})^2]$$

après résoudre l'équation suivante

$$\frac{\partial \mathbb{E}[L(\hat{p}, p)]}{\partial \hat{p}} = 0$$

on obtient

$$p^\pi = w\bar{X} + (1-w)\bar{p}$$

avec \bar{p} est la moyenne a posteriori, l'estimateur de bayes sous la loi a priori beta est

$$p^\pi = w\bar{X} + (1-w) \frac{a + \sum_{i=1}^n x_i}{n + \alpha + \beta} \quad (5.26) \\ = \frac{n + \alpha w + \beta w}{n + \alpha + \beta} \bar{X} + (1-w) \frac{\alpha}{n + \alpha + \beta}$$

telque $0 < \frac{n + \alpha w + \beta w}{n + \alpha + \beta} < 1$. On peut aussi conclure le risque de p^π depuis la proposition (5.3.1).

Théorème 5.3.1. *L'estimateur $c\bar{X}+d$ est inadmissible sous la perte (5.24), sous les conditions suivantes :*

- (i) $c > 1$.
- (ii) $c < w$.
- (iii) $w < c < 1$ et $c+d > 1$.
- (iv) $w < c < 1$ et $d < 0$.
- (v) $c=1$ et $d \neq 0$.
- (vi) $c=w$ et $d < 0$.

Démonstration :

(i) Si $c > 1$ alors $(c-w)^2 > (1-w)^2$ et d'après la proposition précédente

$$R(p, c\bar{X} + d) > R(p, \bar{X})$$

(ii) Si $c < w$ alors $(c-1)^2 > (w-1)^2$ et

$$R(p, c\bar{X} + d) > R(p, w\bar{X} + \frac{d(w-1)}{(c-1)})$$

(iii) Si $w < c < 1$ et $c+d > 1$ alors

$$(c-1)p + d > (c-1)p + 1 - c = (c-1)(p-1) > 0$$

on obtient,

$$R(p, c\bar{X} + d) > R(p, c\bar{X} + 1 - c)$$

(iv) pour $w < c < 1$ et $d < 0$, l'estimateur $c\bar{X} + d$ est dominé par $c\bar{X} - d$.

(v) Dans ce cas $c\bar{X} + d = \bar{X} + d$ est dominé par \bar{X} .

(vi) Il est facile de voir que l'estimateur $w\bar{X} + d$ est dominé par $w\bar{X}$.

Théorème 5.3.2. *L'estimateur $c\bar{X} + d$ est admissible sous la condition (★) $w < c < 1$ et $0 \leq d < 1 - c$.*

On considère

$$\alpha^* = \frac{nd}{c-w} \quad \beta^* = \frac{n(1-c-d)}{c-w}$$

la condition (★) assure que $\alpha^* > 0$ et $\beta^* > 0$ depuis (5.26), tanque

$$\frac{n + \alpha^*w + \beta^*w}{n + \alpha^* + \beta^*} = c$$

$$\frac{(1-w)\alpha^*}{n + \alpha^* + \beta^*} = d$$

Il s'ensuit que $c\bar{X} + d$ est un estimateur de bayes de p, sous la priori $B(\alpha^*, \beta^*)$, on a aussi la perte (5.24) alors (5.26) est unique et admissible.

Il s'ensuit aussi que $c\bar{X} + d$ est admissible quand $w < c < 1$ et $0 < d < 1-c$.

Dans le cas $d=0$, on va montrer que l'estimateur $c\bar{X}$, est admissible quand $a \in]w, 1[$, on considère l'estimateur

$$\hat{p} = \left(\frac{n + \beta w}{n + \beta}\right)\bar{X}$$

On remarque que \hat{p} est la limite de l'estimateur de bayes sous la priori $B(\alpha, \beta)$ quand $a \mapsto 0$, on va établir l'admissibilité de \hat{p} , avec la technique de limite de Bayes et Blyth (1951) [3], on considère la priori impropre

$$\pi_k = p^{\frac{1}{k}-1}(1-p)^{\beta-1} \quad \beta > 0$$

si A est un sous ensemble convexe non dégénérée de $]0,1[$, il existe k_0 telque

$$\int_A \pi_k(p)dp \geq \varepsilon \text{ pour un } \varepsilon > 0, \text{ et pour tout } k \geq k_0.$$

L'estimateur de bayes par rapport a π_k depuis (5.26) est donné par

$$p_k^\pi = \frac{nk + w + \beta kw}{nk + 1 + \beta k} \bar{X} + \frac{1-w}{nk + 1 + \beta k}$$

On trouve que la limite de la différence entre le risque de bayes par rapport a p_k^π et p^π est nulle

$$\lim_{k \rightarrow \infty} r(\pi_k, p^\pi) - r(\pi_k, p_k^\pi) = 0$$

Théorème 5.3.3. *Sous la fonction de perte (5.24) \bar{X} est admissible.*

Démonstration :

On considère la priori impropre

$$\pi_k = p^{\frac{1}{k}-1}(1-p)^{\frac{1}{k}-1} \quad k > 0$$

l'estimateur de bayes \tilde{p}_k^π par rapport a π_k , depuis (5.26) est donné par

$$\tilde{p}_k^\pi = \frac{nk + 2w}{nk + 2}\bar{X} + \frac{1-w}{nk + 2}$$

et avec la même méthode de démonstration précédente

$$\lim_{k \rightarrow \infty} r(\pi_k, \bar{X}) - r(\pi_k, \tilde{p}_k^\pi) = 0$$

alors, \bar{X} est admissible avec le lemme de Blyth's (1951)[3].

5.3.3 Minimaxité

Pour déterminer un estimateur minimax, on considère l'estimateur de bayes (5.26) et on fixe des valeurs $\alpha > 0$ et $\beta > 0$, telque la fonction de risque de l'estimateur de bayes soit constante, depuis la proposition (5.3.1) la fonction de risque de p^π est donné par

$$\begin{aligned} R(p, p^\pi) &= \left[\frac{(1-w)^2(\alpha + \beta)^2}{(n + \alpha + \beta)^2} - \frac{n(1-w)}{(n + \alpha + \beta)^2} - \frac{w(n-w)}{n} \right] p^2 \quad (5.27) \\ &+ \left[-2\alpha(\alpha + \beta)(1-w)^2 + \frac{n(1-w)^2}{(n + \alpha + \beta)^2} + \frac{w(n-w)}{n} \right] p \\ &+ \frac{(1-w)^2\alpha^2}{(n + \alpha + \beta)^2} \end{aligned}$$

On va montrer que (5.27) est constante, si et seulement si

$$\begin{cases} n(\alpha + \beta)^2(1-w)^2 &= n^2(1-w)^2 + w(n-w)(n + \alpha + \beta)^2 \\ 2n\alpha(\alpha + \beta)(1-w)^2 &= n^2(1-w)^2 + w(n-w)(n + \alpha + \beta)^2 \end{cases} \quad (5.28)$$

maintenant, supposons que $0 < w < \frac{3n - \sqrt{n(5n-4)}}{2(n+1)}$.

Noté que $\frac{3n - \sqrt{n(5n-4)}}{2(n+1)} \leq \frac{1}{2}$, la résolution des équations (5.28) pour α et

β donne

$$\alpha = \beta = \frac{nw(n-w) + n(1-w)\sqrt{n(1-w)^2 + w(n-1)(n-w)}}{2n(1-w)^2 - 2w(n-w)} = C_n(w)$$

on a par hypothèse $C_n > 0$, et donc l'estimateur suivant

$$\delta = \frac{n + 2C_n(w)w}{n + 2C_n(w)}\bar{X} + \frac{(1-w)C_n(w)}{n + 2C_n(w)}$$

est l'unique estimateur minimax de p sous (5.24) avec

$$0 < w < \frac{3n - \sqrt{n(5n-4)}}{2(n+1)}$$

la fonction de risque de l'estimateur δ est

$$R(p, \delta) = \frac{(1-w)^2 C_n^2(w)}{(n + 2C_n)^2}$$

Dans le tableau suivant on va calculer les valeurs de $C_n(w)$ pour les différents valeurs de n quand $w = \frac{1}{3}, \frac{1}{4}$ et $\frac{1}{5}$, si on veut choisir entre les deux estimateurs δ et \bar{X} ce qui a un risque n'est pas constant défini par

$$R(p, \bar{X}) = \frac{p(1-p)}{n} [(1-w)^2 + w(n-w)]$$

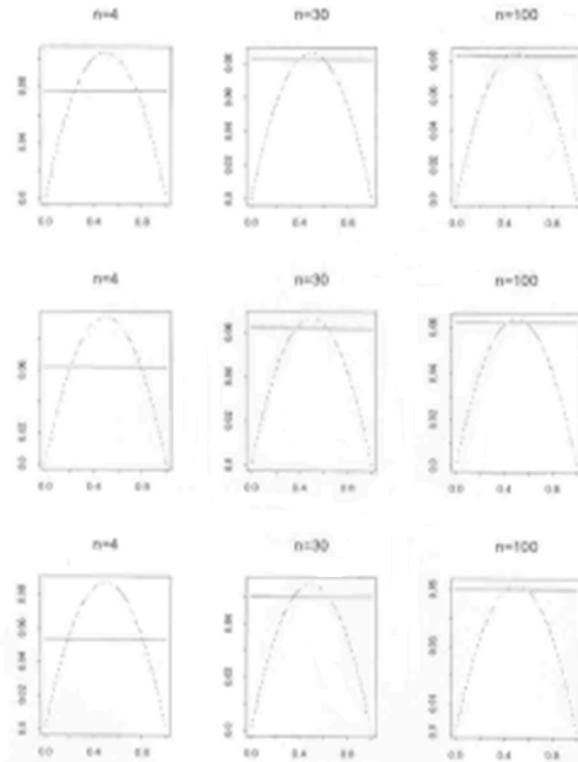


FIGURE 5.1 – La comparaison entre les deux estimateurs \bar{X} et δ .

	$w=\frac{1}{3}$	$w=\frac{1}{4}$	$w=\frac{1}{5}$
n	$C_n(w)$	$C_n(w)$	$C_n(w)$
2	4.07	2	1.50
3	6.97	3	2.16
4	10	4	2.80
5	13.10	5	3.44
10	28.95	10	6.62
15	45.00	15	9.80
20	61.10	20	12.97
25	77.22	25	16.14
30	93.36	30	19.31
50	157.95	50	31.99
100	319.51	100	63.68

TABLE DES MATIÈRES

98

Dans (la figure 5.1) on compare le risque de \bar{X} par rapport à δ , pour $n =$
4, 30, 100 et $w = \frac{1}{3}, \frac{1}{4}$ et $\frac{1}{5}$ (respectivement), on remarque que pour un petit
 n , δ est mieux que \bar{X} et pour un grand n (même si n modéré) \bar{X} est mieux
que δ .

Conclusion et perspectives

Dans ce mémoire on a présenté quelques travaux sur l'amélioration des estimateurs usuels et de type "Stein", dans le cadre paramétrique, et paramétrique bayésienne.

Ce travail peut être généraliser, à une étude dans le cadre non paramétrique, pour l'amélioration de l'estimateur à noyau, en utilisant une fonction de perte généralisée inspirée de celle définie par Arnold Zellner en 1994.

Bibliographie

- [1] **A.Weil**, L'intergration dans les groupes topologiques et ses applications, Paris, Hermann, (1938).
- [2] **Brown, L.D**, Fonction of exponential families, IMS lecture Notes, Monographeseries 9, Hayward, California, (1986).
- [3] **Blyth, C.R**, On minimax statistical decesion procedures and their admissibility, Ann. Math. Statist. Vol. 22 (22-42), (1951).
- [4] **Chou, J.p**, Admissibility of conjugate bayes estimators for the mean of a negative binomial distribution, Statistics and Decisions, 13, 301-306, (1995).
- [5] **Charles Stein**, The inadmissibility of the usual estimator for the mean of a multivariate normal distribution, University of stanford, 1956.
- [6] **Charles M. Stein**, Estimation of the mean of a multivariate normal distribution, Institute of mathematical statistics, The annals of statistics, Vol.9,NO,6 (1135-1151), Nov 1981.
- [7] **C.Stein**, A necessary and sufficient condition for admissibility, An, Math statist, Vol.26, p 518-522, (1955).
- [8] **C.Blyth**, On minimax statistical decision procedures and their admissibility, An, Math statist, Vol.22, p 22-42, (1951).
- [9] **Casella, G., Strawderman, W.E.** . Estimating a bounded normal mean. Annals of Statistics, 9, 870-878, (1981).

- [10] ~~Christian P. Robert~~, ~~Le choix bayésien Principes et pratique~~, Université Paris Dauphine et CREST, INSEE, Paris, (2006).
- [11] **Dey, D.Ghosh, M.Strawderman, W.E**, On estimation with balanced loss functions, *Statistics and Probability letters*, 45, 97-101, (1999).
- [12] **Ferguson .T.S**, *Mathematical Statistics ; A decision theoretic approach*, Academic press, Newyork London, (1967).
- [13] **Gupta**, On the admissibility of linear estimates for estimating the mean of distributions of the one paramètre exponential family, *Calcul statistical association Bulletin*, 15, 14-19, (1966).
- [14] **Gomez Déniz, E**, On the use of the weighted balanced loss function to obtain credibility premiums, *International conference of Enrique Castillo*, June 28-30, (2006).
- [15] **Giles, J.A., Giles, D.E.A. and Ohtani K.**, The exact risks of some pre-test and Stein-type regression estimates under balanced loss, *Communications in Statistics - Theory and Methods*, 25, pp 2901-2924, (1996).
- [16] **Jafari Jozani,M., Nematollahi, N., Shafie, K.**, An admissible minimax estimators of a bounded scale-parameter in subclass of the exponential family under scale-invariant squared error loss, *Statistics and Probability letters*, 60, 437-444, (2002).
- [17] **Jafari Jozani,M.Marchand,E.Parsian** ,On estimation with weighed balanced type loss function,*Statistics and Probability letters*, 76(773-780) 2006.
- [18] **Lehman, E.L, Casella,G.**, *Theory of point estimation*, Springer-Verlag, Newyork, 2nd edition, (1998).
- [19] **Marchand, É., Strawderman, W.E**, On improving on the minimum risk equivariant estimator of a location parameter which is constrained

- to an Interval or a half-interval, *Annals of the institute of statistical mathematics*, 57, 129-143, (2005a).
- [20] **Marchand, É., Strawderman, W.E**, On improving on the minimum risk equivariant estimator of a scale parameter under a lower-bound constraint, *Journal of statistical planning and Inference*, 134,90-101, (2005b).
- [21] **Marchand, E., Strawderman.W.E** , Estimation in restricted parameter spaces : A review .AFests-chrift for Herman Robin, IMS lecture Notes-Monographe series 45, Institut of mathematical statistics, Hayward, Clifornia, 21-44, (2004).
- [22] **Mohammad Jafari Jozani, Eric Marchand, Ahmad Parsian**, Bayes Estimation Under a General Class of Balanced Loss Functions, School of Mathematics, Statistics and Computer Science, University of Tehran, Tehran, IRAN, Université de Sherbrooke, Département de mathématiques, Sherbrooke, QC, CANADA, J1K 2R1.
- [23] **Mohammad Jafari Jozani, Eric Marchand, Ahmad Parsian**, On estimation with weighted balanced type loss function, Department of Statistics, Faculty of Mathematical Sciences, Shahid Beheshti University, Tehran, IRAN, University of New Brunswick and Université de Sherbrooke, Département de mathématiques, Sherbrooke Qc, CANADA, School of Mathematical Sciences, Isfahan University of Technology, Isfahan, 84156, IRAN.
- [24] **Marchand, Eric, Perron, François**. Improving on the MLE of a Bounded Normal Mean. *Annals of Statistics*, 29, 1078-1093, (2001).
- [25] **N.Sanjari Fraspour and A. Asgarsadzadeh**, Estimation of the parameter of a Bernoulli distribution using a balanced loss function, the

(2002).

- [26] **Ohtani, K.**, The exact risk of a weighted average estimator of the OLS and Stein-rule estimators in regression under balanced loss, *Statistics and Decisions*, 16, pp. 35-45,(1998).
- [27] **Parsian.A and Kirmani, S.N.U.A**, Estimation under linex loss function, *Handbook of applied econometrics and statistical inference, statistics textbooks Monographe*, 53-76, (2002).
- [28] **Parsian, A., Nematollahi, N.**, Estimation of scale parametre under entropy loss function, *journalof statistical planing and inference*, 52, 77-91, (1996).
- [29] **Rodrigues, J.Zellner, A. ,** Weighted balanced loss function and estimation of the mean time to failure, *communications in statistics : theory and methods*, 23, 3609-3616, (1994).
- [30] **Robert, C.P**, Intrinsic loss function, *theory and decision*, 40, 192-214, (1996).
- [31] **Sanjari Farsipour, N. et Asgharzadeh, A. ,** Estimation of the paramètre of a Bernoulli distribution using a balanced loss function, *Personal communication*, (2004).
- [32] **Spring, F.A ,** The reflected normal loss function *canadian journal of statistics*, 21, 321, (1993).
- [33] **Shalabh and Helge Toutenburg and Christian Heumann**, Stein-Rule Estimation under an Extended, Balanced Loss Function, *Department of Statistics University of Munich, Number 007*, 2007, December 5, 2007.

- [34] ~~Srivastava, A.K. and Shalabh~~, Efficiency properties of least squares and Stein-rule predictions in linear regression model, Journal of Applied Statistical Science, 4, pp. 141-145, (1996).
- [35] **Shalabh**, Performance of Stein-rule procedure for simultaneous prediction of actual and average values of study variable in linear regression model, Jan Tinbergen Award Paper, Bulletin of the 50th Session of the International Statistical Institute, pp. 1375- 1390, (1995).
- [36] **Van Eeden, C.**, Minimax estimation of a lower bounded scale parameter of a gamma distribution for scale-invariant square error loss, Canadian Journal of statistics, 23, 245-256, (1995).
- [37] **W.James, Charles Stein**, Estimation with quadratic loss, Fresno state college, Stanford university, 1961.
- [38] **Zellner.A** , Bayesian and non bayesian estimation using balanced loss function, Statistical decision theory and methods V,(J.O.Berger and S.S.Gupta EDS). Newyork : Springer-Verlag, 337-390, (1994).
- [39] **Zellner.A**, Bayesian estimation and prediction using asymmetric loss functions, Journal of the American statistical association, 81, 446-451, (1986).