

Théorie de l'estimation et de la décision statistique

Paul Honeine

en collaboration avec
Régis Lengellé

– Université de technologie de Troyes –
2013-2014

Decision and estimation theory

J.L. Melsa, D.L. Cohn
éd. McGraw-Hill (1978)

Décision en traitement du signal

P.Y. Arques
éd. Masson (1982)

Statistical signal processing :

Detection, estimation, and time series analysis

L.L. Scharf
éd. Addison-Wesley (1990)

Signaux aléatoires (3 tomes)

B. Picinbono
éd. Dunod (1994)

Fundamentals of statistical signal processing :

Estimation theory (1993), Detection theory (1998)

S.M. Kay
éd. Prentice Hall

Signal : detection and estimation

M. Barkat
éd. Artech-House (2005)

- Estimation
 - de paramètres
 - de signaux/images (et prédiction)

- Détection

- Classification

1 Théorie de l'estimation

- Problématique
- Estimateur sans biais à variance minimum
- Borne de Cramer Rao
- Recherche de l'estimateur sans biais à variance minimum
- Méthode du maximum de vraisemblance
- Méthode des moments
- Approche Bayésienne

2 Théorie de la décision

- Introduction
- Formulation du problème
- Les principaux critères de décision
 - Critère de Bayes
 - Critère minimax
 - Critère de Neyman Pearson
 - Notion de statistique suffisante
- Caractéristique opérationnelle d'un récepteur (Définition, Propriétés, Intérêt)
- Le problème Gaussien
- Généralisation aux mesures multiples
- Cas des hypothèses composites
- Éléments de détection séquentielle

3 Détection à structure imposée

- Éléments de théorie de l'apprentissage
- Machines à vecteurs supports

Théorie de l'estimation

Problématique

Estimation ponctuelle

Densité de probabilité :

$$(Z_1, Z_2, \dots, Z_N) \approx p(z_1, z_2, \dots, z_N, \theta)$$

- En théorie des probabilités, θ est déterministe
- En statistique, θ est une variable aléatoire

$\hat{\theta}$: estimateur de θ (v. a. fonction des v. a. de l'échantillon)

$$\hat{\theta} = g(Z_1, Z_2, \dots, Z_N)$$

Loi de vraisemblance :

$$\begin{aligned} L(Z_1, Z_2, \dots, Z_N) &= p(z_1, z_2, \dots, z_N, \theta) \Big|_{z_1=Z_1, z_2=Z_2, \dots, z_N=Z_N} \\ &= p(Z_1, Z_2, \dots, Z_N, \theta) \end{aligned}$$

Exemple 0 : ...

Problématique

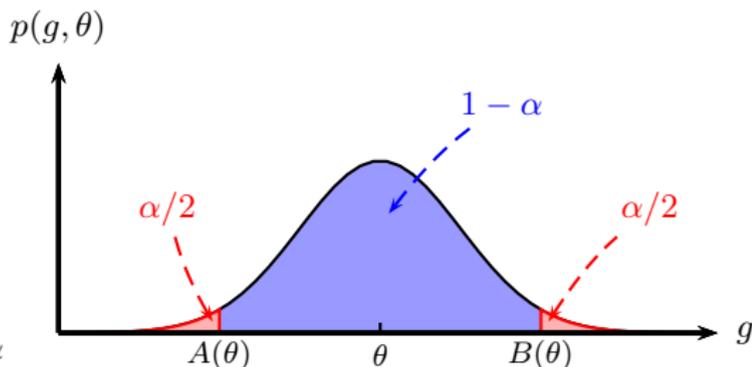
Estimation par intervalle de confiance

$$\hat{\theta} = g(Z_1, Z_2, \dots, Z_N) \approx p(g, \theta)$$

$$p(A(\theta) \leq \hat{\theta} \leq B(\theta)) = 1 - \alpha$$

ou encore

$$p(A^{-1}(\hat{\theta}) \leq \theta \leq B^{-1}(\hat{\theta})) = 1 - \alpha$$



Exemple 1 : $Z_i = B_i + \theta$, avec $B_i \approx \mathcal{N}(0, \sigma^2)$, σ étant connu.

$$\hat{\theta}_1 = \frac{1}{N} \sum_{i=1}^N Z_i \text{ et } \hat{\theta}_2 = Z_1$$

Un estimateur est une variable aléatoire. Ses performances ne peuvent être décrites que statistiquement

Estimateur sans biais à variance minimale

= Minimum variance unbiased (MVU) estimator

Estimateur sans biais à variance minimale

= Minimum variance unbiased (MVU) estimator

$$\text{Biais : } b(\hat{\theta}) = E(\hat{\theta}) - \theta$$

$$\text{Estimateur sans biais : } E(\hat{\theta}) = \theta$$

$$\hat{\theta} = g(Z_1, Z_2, \dots, Z_N)$$

$$\begin{aligned} E(\hat{\theta}) &= E(g(Z_1, Z_2, \dots, Z_N)) \\ &= \iiint g(z_1, z_2, \dots, z_N) p(z_1, z_2, \dots, z_N, \theta) dz_1 dz_2 \dots dz_N \\ &= \iiint g p(g, \theta) dg \end{aligned}$$

$$\text{Exemple : } \hat{\theta}_3 = \frac{1}{2N} \sum_{i=1}^N Z_i$$

Estimateur sans biais à variance minimale

Motivation : critère d'erreur quadratique moyenne minimale

Definition (Erreur quadratique moyenne)

$$mse(\hat{\theta}) = E \left((\hat{\theta} - \theta)^2 \right)$$

$$\begin{aligned} mse(\hat{\theta}) &= E \left((\hat{\theta} - \theta)^2 \right) \\ &= E \left((\hat{\theta} - E(\hat{\theta}) + E(\hat{\theta}) - \theta)^2 \right) \\ &= var(\hat{\theta}) + b^2(\hat{\theta}) \end{aligned}$$

Exemple : $\hat{\theta}_4 = \frac{a}{N} \sum_{i=1}^N Z_i$

L'estimateur MVU existe t'il ?
et, si oui, comment le trouver ?

Estimateur sans biais à variance minimale : estimateur efficace et borne de Cramer-Rao

Retour sur la loi de vraisemblance :

$$p(Z, \theta) = p(Z_1, Z_2, \dots, Z_N, \theta)$$

est fonction de θ à $Z = [Z_1 \ Z_2 \ \dots \ Z_N]^T$ fixé.

Exemple 1 : ...

Remarque : La loi de vraisemblance porte l'information sur le paramètre à estimer. Plus les variations de celles-ci sont importantes par rapport au paramètre, et plus celui-ci est aisé à estimer.

Exemple : La loi uniforme $\mathcal{U}(0, a)$

Estimateur sans biais à variance minimale

Estimateur efficace et borne de Cramer-Rao

Theorem (Estimateur efficace et borne de Cramer-Rao)

Soit $\hat{\theta}$ un estimateur sans biais de θ . Si $p(Z, \theta)$ vérifie, pour tout θ ,

$$E \left(\frac{\partial \ln p(Z, \theta)}{\partial \theta} \right) = 0, \quad \text{alors} \quad \text{var}(\hat{\theta}) \geq \frac{-1}{E \left(\frac{\partial^2 \ln p(Z, \theta)}{\partial \theta^2} \right)}.$$

De plus, si et seulement si il existe $g(\cdot)$ et $I(N, \theta)$ telles que

$$\frac{\partial \ln p(Z, \theta)}{\partial \theta} = I(N, \theta) (g(Z) - \theta),$$

alors $g(Z)$ est un estimateur sans biais dont la variance atteint la borne. L'estimateur $\hat{\theta}$ est dit efficace.

Exemple 1 : $\hat{\theta}_{eff} = \frac{1}{N} \sum_{i=1}^N Z_i$, et $\text{var}(\hat{\theta}_{eff}) = \sigma^2/N$

Estimateur sans biais à variance minimale

Estimateur efficace et borne de Cramer-Rao : démonstration

Démonstration (1/3) :

Soit $\hat{\theta}$ un estimateur sans biais de θ .

D'une part, la condition permet d'écrire

$$0 = E\left(\frac{\partial \ln p(Z, \theta)}{\partial \theta}\right) = \int \frac{\partial \ln p(z, \theta)}{\partial \theta} p(z, \theta) dz \stackrel{\textcircled{1}}{=} \int \frac{\partial p(z, \theta)}{\partial \theta} dz \stackrel{\textcircled{2}}{=} \frac{\partial}{\partial \theta} \int p(z, \theta) dz,$$

où $\stackrel{\textcircled{1}}{=}$ est due à la relation $\frac{\partial u(\theta)}{\partial \theta} = u(\theta) \frac{\partial \ln u(\theta)}{\partial \theta}$ car $\frac{\partial \ln u(\theta)}{\partial \theta} = \frac{\partial u(\theta)}{\partial \theta} \frac{1}{u(\theta)}$

et $\stackrel{\textcircled{2}}{=}$ vraie si les bornes ne dépendent pas de θ , donc les supports de p

D'autre part, l'estimateur est sans biais, c'est-à-dire $E(\hat{\theta}) = \theta$, soit en dérivant

$$\begin{aligned} 1 &= \frac{\partial}{\partial \theta} \int f(z) p(z, \theta) dz = \int f(z) \frac{\partial}{\partial \theta} p(z, \theta) dz = \int f(z) \frac{\partial \ln p(z, \theta)}{\partial \theta} p(z, \theta) dz \\ &= \int (f(z) - \theta) \frac{\partial \ln p(z, \theta)}{\partial \theta} p(z, \theta) dz \end{aligned}$$

où on peut introduire θ car $\int \theta \frac{\partial \ln p(z, \theta)}{\partial \theta} p(z, \theta) dz = \theta E\left(\frac{\partial \ln p(z, \theta)}{\partial \theta}\right) = 0$

Estimateur sans biais à variance minimale

Estimateur efficace et borne de Cramer-Rao : démonstration

Démonstration (2/3) :

Rappel : inégalité de Cauchy-Schwarz : pour tout $w(z) \geq 0$, on a

$$\left| \int w(z) k(z) h(z) dz \right|^2 \leq \int w(z) k^2(z) dz \int w(z) h^2(z) dz,$$

avec égalité si il existe un c tel que $k(z) = c h(z)$.

Posons $w(z) = p(z, \theta)$, $k(z) = f(z) - \theta$, et $h(z) = \frac{\partial}{\partial \theta} \ln p(z, \theta)$, alors

$$1 \leq \int p(z, \theta) (f(z) - \theta)^2 dz \int p(z, \theta) \left(\frac{\partial}{\partial \theta} \ln p(z, \theta) \right)^2 dz$$

Le premier terme vaut $E\left((f(z) - \theta)^2\right) = \text{var}(\hat{\theta})$, et le second $E\left(\left(\frac{\partial}{\partial \theta} \ln p(z, \theta)\right)^2\right)$

$$\text{var}(\hat{\theta}) \geq \frac{1}{E\left(\left(\frac{\partial}{\partial \theta} \ln p(z, \theta)\right)^2\right)}$$

Estimateur sans biais à variance minimale

Estimateur efficace et borne de Cramer-Rao : démonstration

Démonstration (3/3) :

Par ailleurs,

$$0 = E \left(\frac{\partial \ln p(z, \theta)}{\partial \theta} \right) = \int \frac{\partial \ln p(z, \theta)}{\partial \theta} p(z, \theta) dz$$

On dérive à nouveau

$$0 = \int \frac{\partial}{\partial \theta} \left(\frac{\partial \ln p(z, \theta)}{\partial \theta} p(z, \theta) \right) dz = \int \frac{\partial^2 \ln p(z, \theta)}{\partial \theta^2} p(z, \theta) + \frac{\partial \ln p(z, \theta)}{\partial \theta} \frac{\partial p(z, \theta)}{\partial \theta} dz$$

Or, le second terme vaut $E \left(\left(\frac{\partial \ln p(z, \theta)}{\partial \theta} \right)^2 \right)$ car $\frac{\partial p(z, \theta)}{\partial \theta} = \frac{\partial \ln p(z, \theta)}{\partial \theta} p(z, \theta)$.

Donc

$$E \left(\frac{\partial^2 \ln p(z, \theta)}{\partial \theta^2} \right) = -E \left(\left(\frac{\partial \ln p(z, \theta)}{\partial \theta} \right)^2 \right)$$

$$\text{var}(\hat{\theta}) \geq \frac{-1}{E \left(\frac{\partial^2 \ln p(z, \theta)}{\partial \theta^2} \right)}$$

Estimateur sans biais à variance minimale

Estimateur efficace et borne de Cramer-Rao : démonstration

Démonstration (3⁺/3) :

La borne est atteinte lorsque l'inégalité de Cauchy-Schwarz devient égalité, c'est-à-dire lorsque $h(z) = I(\theta)k(z)$.

$$\frac{\partial \ln p(z, \theta)}{\partial \theta} = I(\theta)(f(z) - \theta)$$

En dérivant, on obtient

$$\frac{\partial^2 \ln p(z, \theta)}{\partial \theta^2} = -I(\theta) + \frac{\partial I(\theta)}{\partial \theta}(f(z) - \theta)$$

et en considérant l'espérance de cette expression, on obtient

$$E\left(\frac{\partial^2 \ln p(z, \theta)}{\partial \theta^2}\right) = -I(\theta) + (E(\hat{\theta}) - \theta)$$

où le dernier terme est nul car $\hat{\theta}$ est sans biais.

$$I(\theta) = -E\left(\frac{\partial^2 \ln p(z, \theta)}{\partial \theta^2}\right)$$

Estimateur sans biais à variance minimale

Estimateur efficace et borne de Cramer Rao

Theorem (Estimateur efficace et borne de Cramer-Rao, extension au cas vectoriel)

Soit $\hat{\theta}$ un estimateur sans biais de $\theta = [\theta_1 \ \theta_2 \ \dots \ \theta_p]^\top$. Si $p(Z, \theta)$ vérifie, pour tout θ , $E\left(\frac{\partial \ln p(Z, \theta)}{\partial \theta}\right) = 0$, alors la matrice de covariance $C_{\hat{\theta}}$ de $\hat{\theta}$ vérifie :

$$C_{\hat{\theta}} - I^{-1}(\hat{\theta}) \geq 0, \text{ où } [I(\hat{\theta})]_{i,j} = -E\left(\frac{\partial^2 \ln p(Z, \theta)}{\partial \theta_i \partial \theta_j}\right).$$

De plus, si et seulement s'il existe une fonction vectorielle $g(\cdot)$ et une matrice $I(N, \theta)$, de taille $p \times p$, telles que

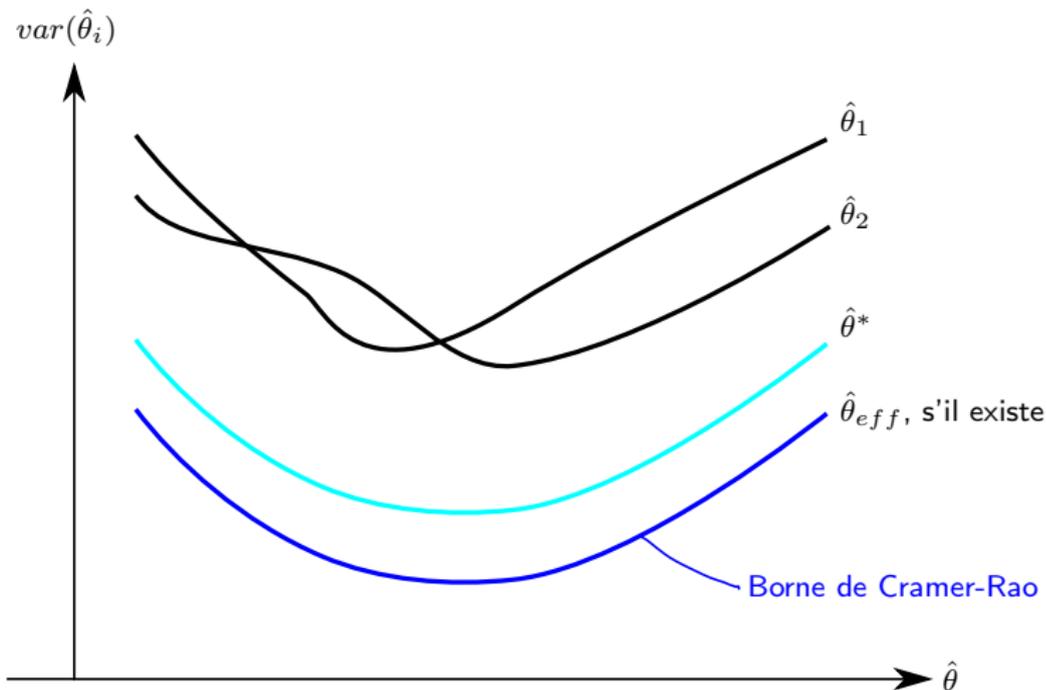
$$\frac{\partial \ln p(Z, \theta)}{\partial \theta} = I(N, \theta) (g(Z) - \theta),$$

alors $g(Z)$ est un estimateur sans biais dont la variance atteint la borne. L'estimateur $\hat{\theta}$ est dit efficace, avec $C_{\hat{\theta}} = I^{-1}(\hat{\theta})$.

Recherche de l'estimateur sans biais à variance minimale

L'estimateur efficace $\hat{\theta}_{eff}$ n'existe pas toujours ...

Comment faire pour trouver l'estimateur sans biais à variance minimale $\hat{\theta}^*$?



Recherche de l'estimateur sans biais à variance minimale

Notion de statistique suffisante

Exemple 1 : $\hat{\theta}_1 = \frac{1}{N} \sum_{i=1}^N Z_i$

Quelles sont les données utiles pour estimer θ ?

- Z_1, Z_2, \dots, Z_N
- $Z_1 + Z_2, Z_3, \dots, Z_N$
- $\sum_{i=1}^N Z_i$

Chacune de ces statistiques est suffisante pour estimer θ .

Toutefois, $\sum_{i=1}^N Z_i$ est de *dimension minimale*.

Definition (statistique suffisante)

Une statistique $T(z_1, z_2, \dots, z_N)$ est suffisante pour un paramètre θ si $p(z_1, z_2, \dots, z_N \mid T(z_1, z_2, \dots, z_N), \theta)$ est indépendant de θ .

Recherche de l'estimateur sans biais à variance minimale

Notion de statistique suffisante

Theorem (factorisation de Neyman Fisher)

Si $p(Z_1, \dots, Z_N, \theta) = g(T(Z_1, \dots, Z_N), \theta) h(Z_1, \dots, Z_N)$, alors $T(Z_1, Z_2, \dots, Z_N)$ est une statistique suffisante pour θ

Exemple 1

Theorem (Rao Blackwell Lehmann Scheffé)

Soit $\hat{\theta}$ un estimateur sans biais de θ et $T(Z_1, Z_2, \dots, Z_N)$ une statistique suffisante. Alors $E(\hat{\theta} \mid T(Z_1, Z_2, \dots, Z_N))$ est un estimateur sans biais de variance plus faible que celle de $\hat{\theta}$.

De plus, si la statistique est complète, alors $E(\hat{\theta} \mid T(Z_1, Z_2, \dots, Z_N))$ est l'estimateur à variance minimale

Definition (statistique complète)

Une statistique est dite complète s'il existe une seule fonction de celle-ci qui est sans biais.

Recherche de l'estimateur sans biais à variance minimale

Application :

$\tilde{\theta} = E(\hat{\theta} | T(Z_1, Z_2, \dots, Z_N))$ est un estimateur sans biais de θ de variance plus faible que $\hat{\theta}$. Mais $\tilde{\theta} = E(\hat{\theta} | T(Z_1, Z_2, \dots, Z_N))$ est une fonction $g(T(Z_1, Z_2, \dots, Z_N))$. Si la statistique est complète alors g est unique. $\tilde{\theta}$ est donc unique (indépendant du choix initial de $\hat{\theta}$). C'est donc l'estimateur sans biais de variance minimale (s'il existe). De manière duale, si la statistique est complète, il suffit de trouver la fonction $g(T(Z_1, Z_2, \dots, Z_N))$ qui soit sans biais.

Exemple 1 :

Méthode du maximum de vraisemblance

Si

- l'estimateur efficace n'existe pas
- le calcul de $E(\hat{\theta} \mid \hat{\theta}_{suff})$ est très difficile
- on ne peut trouver de fonction $g(\hat{\theta}_{suff})$ qui soit sans biais (et unique ...)

alors

- on cherche un estimateur asymptotiquement efficace (attention à la taille de l'échantillon ...)

Definition (estimateur du maximum de vraisemblance)

L'estimateur du maximum de vraisemblance est celui qui maximise la loi de vraisemblance

$$\hat{\theta}_{MV} = \arg \max_{\theta} p(Z, \theta)$$

En général, on maximise plutôt $\ln(p(Z, \theta))$

$$\frac{\partial \ln p(Z, \theta)}{\partial \theta} = 0, \quad \text{et} \quad \frac{\partial^2 \ln p(Z, \theta)}{\partial \theta^2} < 0.$$

Exemple 1 : Appliquer la méthode du maximum de vraisemblance revient à retenir la valeur de θ qui maximise la densité de probabilité des données observées.

Méthode du maximum de vraisemblance

Exemple 1 : Appliquer la méthode du maximum de vraisemblance revient à retenir la valeur de θ qui maximise la densité de probabilité des données observés.

Exemple 1 : $\hat{\theta}_{MV} = \frac{1}{N} \sum_{i=1}^N Z_i$, sur cet exemple, on constate que $\hat{\theta}_{MV}$ est efficace.

En effet, si l'estimateur efficace existe, alors $\frac{\partial \ln p(Z, \theta)}{\partial \theta} = I(\theta)(\hat{\theta}_{eff} - \theta)$. On a alors $\frac{\partial \ln p(Z, \theta)}{\partial \theta} = 0$ pour $\theta = \hat{\theta}_{MV} = \hat{\theta}_{eff}$.

Conclusion :

Si l'estimateur efficace existe, il est donné de manière unique par la méthode du maximum de vraisemblance. **Attention, la réciproque n'est pas vraie.**

Méthode du maximum de vraisemblance

Theorem

Si les dérivées première et seconde de $\ln p(Z, \theta)$ existent, et si

$$E \left(\frac{\partial \ln p(Z, \theta)}{\partial \theta} \right) = 0$$

pour tout θ , alors $\hat{\theta} \rightarrow \mathcal{N}(\theta, I^{-1}(\theta))$ lorsque $N \rightarrow \infty$

Theorem

Si $g(\cdot)$ est bijective, alors l'estimateur du maximum de vraisemblance de $g(\theta)$ est $g(\hat{\theta}_{MV})$, soit

$$\widehat{(g(\theta))}_{MV} = g(\hat{\theta}_{MV}).$$

Méthode des moments

Méthode des moments

Supposons qu'il existe une fonction $b(\theta) = E(g(Z)) = \int g(z) p(z, \theta) dz$, où la fonction $b(\cdot)$ est continue et monotone, alors

$$\theta = b^{-1}(E(g(Z))).$$

La méthode des moments consiste à remplacer le moment théorique $E(g(Z))$ par le moment empirique correspondant $\frac{1}{N} \sum_{i=1}^N g(Z_i)$. On en déduit alors un estimateur de θ :

$$\theta = b^{-1} \left(\frac{1}{N} \sum_{i=1}^N g(Z_i) \right).$$

Si la fonction $b^{-1}(\cdot)$ est continue, alors l'estimateur obtenu est convergent.

Exemple 1 : $E(Z) = \theta$, alors $\hat{\theta}_{mom} = \frac{1}{N} \sum_{i=1}^N Z_i$

Approche Bayésienne

θ est supposé aléatoire de loi de probabilité a priori $p(\theta)$. On a alors

$$p(\theta) = \int p(Z, \theta) dZ$$

$$p(Z, \theta) = p(\theta | Z) p(Z)$$

Par exemple :

$$mse(\hat{\theta}) = \iint (\hat{\theta} - \theta)^2 p(Z, \theta) dZ d\theta$$

$$= \left(\iint (\hat{\theta} - \theta)^2 p(\theta|Z) d\theta \right) p(Z) dZ$$

L'estimateur qui minimise la mse est : $\hat{\theta} = E(\theta|Z)$

On peut aussi imaginer d'autres fonctions coût $C(\hat{\theta} - \theta)$:

- $C(\hat{\theta} - \theta) = |\hat{\theta} - \theta|$, qui donne la médiane de $p(\theta|Z)$
- $C(\hat{\theta} - \theta) = \begin{cases} 0 & \text{si } |\hat{\theta} - \theta| < \delta \\ 1 & \text{si } |\hat{\theta} - \theta| \geq \delta \end{cases}$, qui correspond au mode de $p(\theta|Z)$

Approche Bayésienne

Exemple :

$$p(z_k|\theta) = \begin{cases} \theta \exp(-\theta z_k) & \text{si } z_k \geq 0 \\ 0 & \text{sinon} \end{cases}$$

$$p(\theta) = \begin{cases} \lambda \exp(-\lambda\theta) & \text{si } \theta \geq 0 \\ 0 & \text{sinon} \end{cases}$$

Alors

$$\hat{\theta}_{MAP} = \frac{1}{\frac{1}{N} \sum_{i=1}^N Z_i + \frac{\lambda}{N}}$$

Théorie de la décision binaire

Théorie de la décision binaire

- 1 Introduction
- 2 Formulation du problème
 - Etude d'une règle de décision
 - Hypothèses et notations
- 3 Les principaux critères de décision
 - Critère de Bayes
 - Critère minimax
 - Critère de Neyman Pearson
 - Notion de statistique suffisante
- 4 Caractéristique opérationnelle d'un récepteur
 - Définition
 - Propriétés
 - Intérêt
- 5 Le problème Gaussien

Introduction

Exemple introductif 1

EXEMPLE INTRODUCTIF 1

Problème :

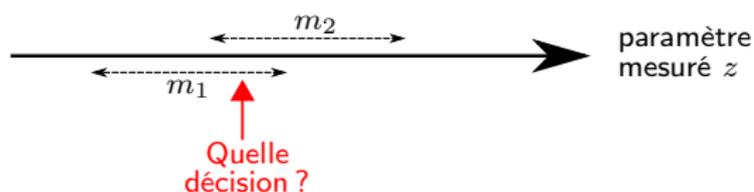
- Reconnaître à l'aide d'une caméra deux types de pièces plates

Méthode :

- Extraction d'un paramètre de l'image (i.e., surface)
- Classer les pièces en fonction du paramètre choisi

Difficulté :

- Pour un type de pièces données, la mesure est aléatoire (fabrication, mesure, ...)

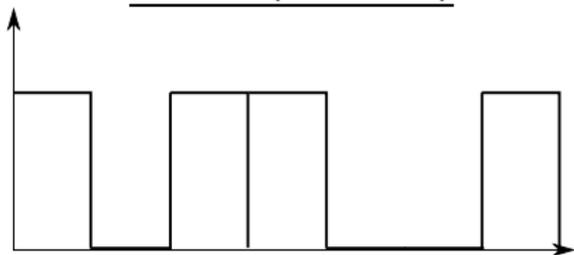


Introduction

Exemple introductif 2

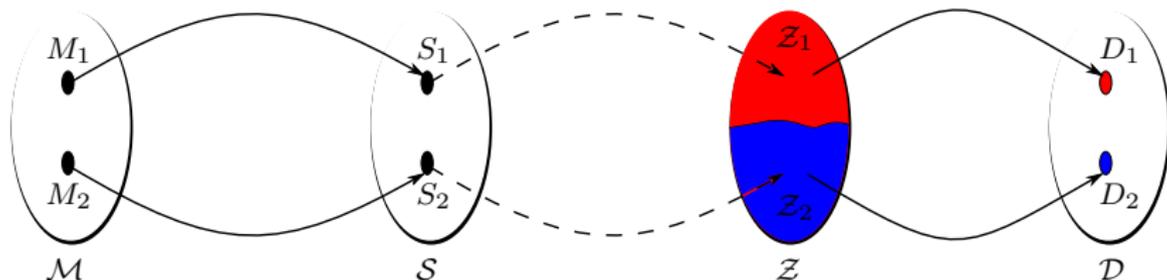
EXEMPLE INTRODUCTIF 2 : Communication binaire synchrone**Principe :**

signal \rightarrow échantillonnage \rightarrow conversion analogique-numérique

Emission (suite 0 – 1)Réception**Décision :**

A-t-on reçu 0 ou 1 ?

Formulation du problème



- \mathcal{M} : espace des messages, source (les 2 pièces)
- \mathcal{S} : espace des signaux (les images)
- \mathcal{Z} : espace des observations (les mesures $z \in \mathbb{R}$)
- \mathcal{D} : espace des décisions (quelle pièce ?)

Comment passer de \mathcal{Z} à \mathcal{D} ? Quelle partition de \mathcal{Z} ?

Formulation du problème

Hypothèses et notations

Messages :

Probabilité des messages : $P(M_1), P(M_2)$, avec $P(M_1) + P(M_2) = 1$

Signaux :

Probabilité des signaux : $P(S_i) = P(M_i)$, pour $i = 1, 2$

Probabilités a priori : $P(S_i), P(M_i)$

Observations (mesures) :

Le vecteur des mesures \mathbf{z} est la réalisation d'un vecteur aléatoire \mathbf{Z}

Probabilités conditionnelles des mesures : $p(\mathbf{z} | S_i)$, pour $i = 1, 2$

Probabilité des mesures :

$$p(\mathbf{z}) = p(\mathbf{z} | S_1) P(S_1) + p(\mathbf{z} | S_2) P(S_2)$$

Remarque :

\mathbf{Z} est un vecteur aléatoire discret ou continue

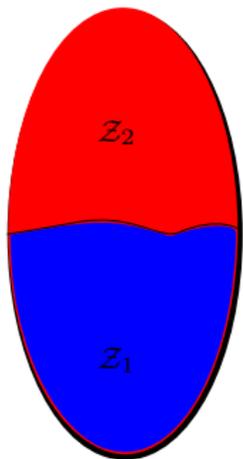
Si \mathbf{Z} est continu, alors $p(\mathbf{z} | S_i)$ et $p(\mathbf{z})$ sont des densités de probabilités, avec

$$\int_{\mathbf{Z}} p(\mathbf{z}) d\mathbf{z} = 1 \text{ et } \int_{\mathbf{Z}} p(\mathbf{z} | S_i) d\mathbf{z} = 1$$

Formulation du problème

De l'observation à la décision :

Partition de l'espace des observations, Z_1 et Z_2 ,
avec $Z_1 \cup Z_2 = Z$ et $Z_1 \cap Z_2 = \emptyset$



Décision :

- Décision D_1 si $z \in Z_1$
- Décision D_2 si $z \in Z_2$

Formulation du problème

Probabilités de décision :

- Conditionnelle

$$P(\mathbf{D}_i | S_j) = \int_{\mathbf{Z}_i} p(\mathbf{z} | S_j) d\mathbf{z}$$

$$P(\mathbf{D}_1 | S_j) + P(\mathbf{D}_2 | S_j) = 1$$

- Totale

$$P(\mathbf{D}_i) = \int_{\mathbf{Z}_i} p(\mathbf{z}) d\mathbf{z}$$

$$P(\mathbf{D}_i) = P(\mathbf{D}_i | S_1)P(S_1) + P(\mathbf{D}_i | S_2)P(S_2)$$

- Bonnes décisions : $S_i \Leftrightarrow \mathbf{D}_i$, pour $i = 1, 2$

$$P_{BD} = P(\mathbf{D}_1 | S_1)P(S_1) + P(\mathbf{D}_2 | S_2)P(S_2)$$

- Mauvaises décisions : $S_i \Leftrightarrow \mathbf{D}_j$, pour $i \neq j$

$$P_{MD} = P(\mathbf{D}_2 | S_1)P(S_1) + P(\mathbf{D}_1 | S_2)P(S_2)$$

Formulation du problème

Etude d'une règle de décision

Principe :

Les mesures étant connues, on choisit l'hypothèse qui a la probabilité maximum

- Décision D_1 si $p(S_1 | z) > p(S_2 | z)$
- Décision D_2 si $p(S_1 | z) < p(S_2 | z)$

$$\frac{p(S_2 | z)}{p(S_1 | z)} \underset{D_1}{\overset{D_2}{\gtrless}} 1$$

Critère du maximum de probabilité a postériori

Règle :

$$\frac{p(z | S_2)}{p(z | S_1)} \underset{D_1}{\overset{D_2}{\gtrless}} \frac{p(S_1)}{p(S_2)}$$

ceci correspond à comparer le rapport de vraisemblance à un seuil :

$$\Lambda(z) \underset{D_1}{\overset{D_2}{\gtrless}} \lambda$$

Formulation du problème

Etude d'un problème (classification de pièces)

Hypothèses :

- Paramètres : m_1, m_2 , avec $m_1 < m_2$
- Mesures bruitées $z = m_j + v$, avec v une variable aléatoire Gaussienne $\mathcal{N}(0, \sigma^2)$.
- Probabilités a priori : $P(S_1), P(S_2)$

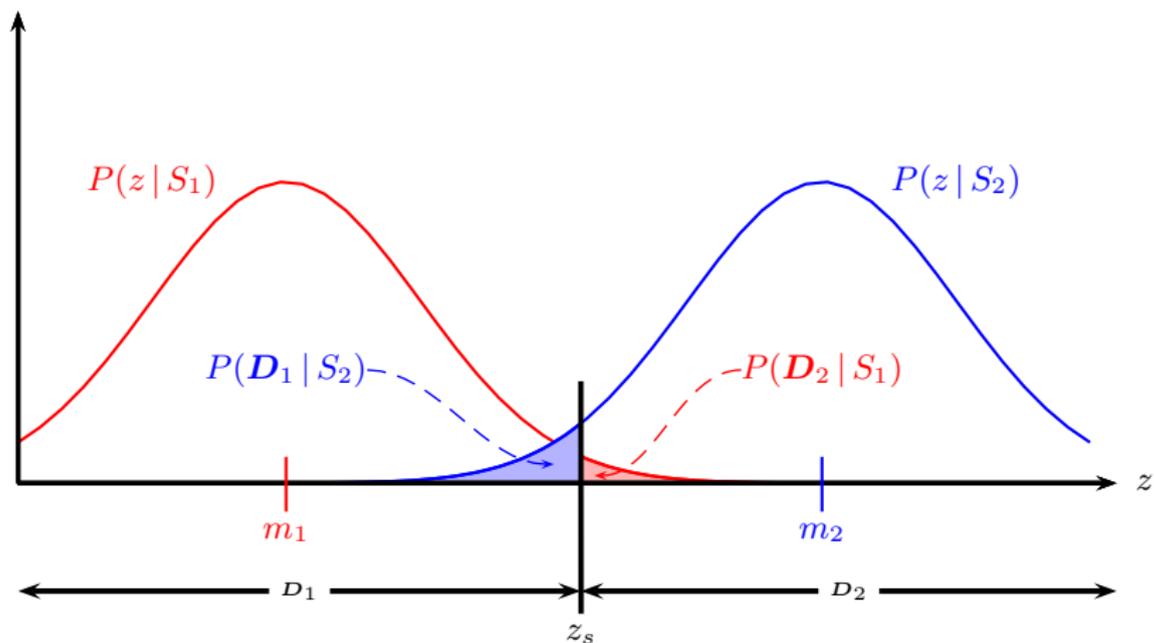
Solution :

$$p(S_2 | z) \underset{D_1}{\overset{D_2}{\geq}} p(S_1 | z)$$

$$z \underset{D_1}{\geq} \frac{m_2 + m_1}{2} + \frac{\sigma^2}{m_2 - m_1} \ln \frac{P(S_1)}{P(S_2)}$$

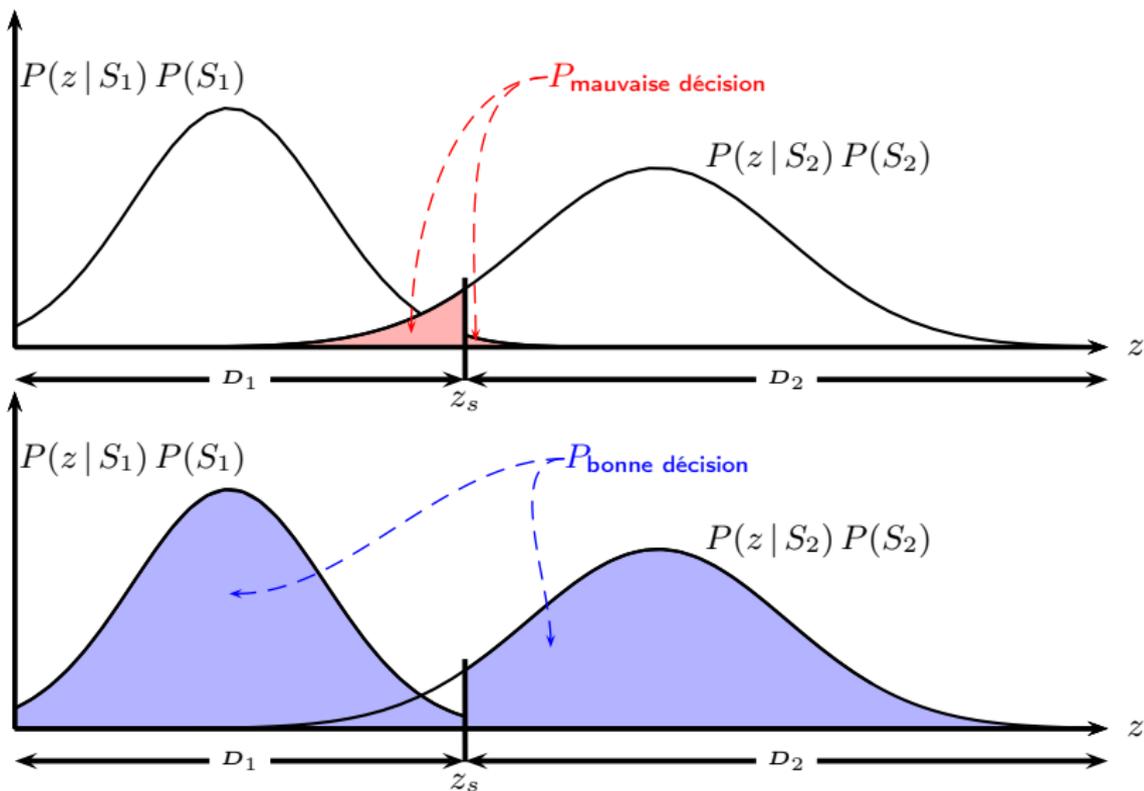
Formulation du problème

Etude d'un problème (classification de pièces)



Formulation du problème

Etude d'un problème (classification de pièces)



Formulation du problème

Etude d'un problème (classification de pièces)

Les probabilités de décision :

$$P(\mathbf{D}_2 | S_i) = \int_{z_s}^{\infty} p(\mathbf{z} | S_i) d\mathbf{z} = 1 - \operatorname{erf}\left(\frac{z_s - m_i}{\sigma}\right)$$

$$P(\mathbf{D}_1 | S_i) = \int_{-\infty}^{z_s} p(\mathbf{z} | S_i) d\mathbf{z} = \operatorname{erf}\left(\frac{z_s - m_i}{\sigma}\right)$$

avec

$$\operatorname{erf}(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x \exp\left(-\frac{u^2}{2}\right) du$$

Formulation du problème

Etude du rapport de vraisemblance

- z mesure \Leftrightarrow réalisation de la variable aléatoire Z
- $\Lambda(z)$ \Leftrightarrow réalisation de la variable aléatoire $\Lambda(Z)$

Lois de $\Lambda(Z)$:

- Lois conditionnelles $p(\Lambda | S_i)$
- $p(\Lambda) = p(\Lambda | S_1)P(S_1) + p(\Lambda | S_2)P(S_2)$
- ... se déduisent des lois de z
- $\Lambda(z) \geq 0$, pour tout z

Probabilités de décision :

- Décision D_1 si $\Lambda(z) < \lambda$

$$P(D_1 | S_j) = \int_0^\lambda p_\Lambda(\lambda' | S_j) d\lambda'$$

- Décision D_2 si $\Lambda(z) \geq \lambda$

$$P(D_2 | S_j) = \int_\lambda^\infty p_\Lambda(\lambda' | S_j) d\lambda'$$

Critère de Bayes

Hypothèses de base :

- Toutes les décisions ne sont pas équivalentes
Exemples : détection d'un défaut dans une pièce, détection radar, ...
- On associe un coût à toute décision conditionnelle :
 C_{ij} le coût associé à D_i pour S_j
- $P(S_i)$ et $P(z | S_i)$ sont connues, pour $i = 1, 2$
- On définit un *coût moyen* de Bayes

$$\bar{C} = \sum_{i=1}^2 \sum_{j=1}^2 C_{ij} P(D_i \cap S_j)$$

Objectif :

Recherche d'une partition de \mathcal{Z} qui rende \bar{C} minimum

Critère de Bayes

Solution :

$$\frac{p(\mathbf{z} | S_2)}{p(\mathbf{z} | S_1)} \underset{D_1}{\underset{D_2}{\gtrless}} \frac{(C_{11} - C_{21}) p(S_1)}{(C_{22} - C_{12}) p(S_2)}$$

Pourquoi ?

$$\bar{C} = \underbrace{C_{21}p(S_1)}_{\text{coût fixé}} + \underbrace{C_{22}p(S_2)}_{\text{coût contrôlé}} + \int I(\mathbf{z})d\mathbf{z}$$

$$I(\mathbf{z}) = (C_{11} - C_{21}) p(\mathbf{z} | S_1)P(S_1) + (C_{12} - C_{22}) p(\mathbf{z} | S_2)P(S_2)$$

- $\mathbf{Z}_1 = \{\mathbf{z} | I(\mathbf{z}) \leq 0\}$
- $\mathbf{Z}_2 = \{\mathbf{z} | I(\mathbf{z}) > 0\}$

FIGURE

Critère minimax

Hypothèses de base :

- Les mêmes que celles du critère de Bayes,
- mais les $P(S_i)$ sont inconnus

Objectif :

Se placer dans le cas le plus défavorable du critère de Bayes

$$\max_{P(S_2)} \overline{C}(P(S_2))$$

Solution :

$$\frac{p(\mathbf{z} | S_2)}{p(\mathbf{z} | S_1)} \underset{D_1}{\overset{D_2}{\geq}} \frac{(C_{11} - C_{21}) p(S_1)}{(C_{22} - C_{12}) p(S_2)}$$

où $P(S_2)$ est solution de l'équation caractéristique

$$(C_{22} - C_{11}) + (C_{12} - C_{22}) P(\mathbf{D}_1 | S_2) - (C_{21} - C_{11}) P(\mathbf{D}_2 | S_1) = 0$$

Critère minimax

Coût moyen :

$$C(P(S_2)) = C_{21}P(\mathbf{D}_2 | S_1) + C_{11}(1 - P(\mathbf{D}_2 | S_1)) \\ + P(S_2) \left((C_{22} - C_{11}) + (C_{12} - C_{22})P(\mathbf{D}_1 | S_2) - (C_{21} - C_{11})P(\mathbf{D}_2 | S_1) \right)$$

Coût minimum :

- Dépend de $P(S_2)$ (P_2)
de façon explicite $\Rightarrow P(S_2)$
de façon implicite $\Rightarrow \lambda \Leftrightarrow P(\mathbf{D}_i | S_j)$
- Fixons $P_2 = P_2^*$, alors λ^* , $P(\mathbf{D}_1 | S_2)$ et $P(\mathbf{D}_2 | S_1)$ déterminés

Variation explicite $C_e(P_2)$ de $C(P_2)$ en fonction de P_2

$$\overline{C} \Rightarrow \text{variation linéaire par rapport à } P_2 \\ \Rightarrow \text{passe par } C(P_2^*)$$

FIGURE

Critère minimax

Etude de $C(P(S_2))$:

$$C(P(S_2)) = C_{21}P(\mathbf{D}_2 | S_1) + C_{11}(1 - P(\mathbf{D}_2 | S_1)) \\ + P(S_2) \left((C_{22} - C_{11}) + (C_{12} - C_{22})P(\mathbf{D}_1 | S_2) - (C_{21} - C_{11})P(\mathbf{D}_2 | S_1) \right)$$

FIGURE

FIGURE

Critère minimax

Cas possibles :

FIGURE

FIGURE

Critère minimax

- La valeur seuil λ est déterminée par l'équation caractéristique,

$$(C_{22} - C_{11}) + (C_{12} - C_{22}) P(\mathbf{D}_1 | S_2) - (C_{21} - C_{11}) P(\mathbf{D}_2 | S_1) = 0$$

avec $P(\mathbf{D}_1 | S_2) = \int_0^\lambda p_\Lambda(\lambda' | S_2) d\lambda'$ et
 $P(\mathbf{D}_2 | S_1) = \int_\lambda^\infty p_\Lambda(\lambda' | S_1) d\lambda'$

- Règle de décision

$$\frac{p(\mathbf{z} | S_2)}{p(\mathbf{z} | S_1)} \underset{D_1}{\overset{D_2}{\geq}} \lambda$$

Cas particulier : $C_{ij} = 1 - \delta_{ij}$

$$P(\mathbf{D}_1 | S_2) = P(\mathbf{D}_2 | S_1) \text{ et } C = P(\mathbf{D}_2 | S_1) = P_{MD}$$

Critère de Neyman-Pearson

Hypothèses de base :

- Les C_{ij} et les $P(S_i)$ sont inconnus
- Seules les $p(\mathbf{z} | S_i)$ sont connus

Objectif :

$P(\mathbf{D}_2 | S_1) = \alpha$ étant imposée

$$\max P(\mathbf{D}_2 | S_2)$$

Solution :

Recherche d'une partition de \mathbf{Z} telle que J est maximum, avec

$$J = P(\mathbf{D}_2 | S_2) - \lambda(P(\mathbf{D}_2 | S_1) - \alpha)$$

où λ est le *multiplicateur de Lagrange*. On a alors

$$\mathbf{Z}_2 = \{\mathbf{z} | p(\mathbf{z}|S_2) - \lambda p(\mathbf{z} | S_1) > 0\}$$

où $\alpha = \int_{\lambda}^{\infty} p_{\Lambda}(\lambda' | S_1) d\lambda'$

Règle de décision :

$$\Lambda(\mathbf{z}) \underset{D_1}{\overset{D_2}{\geq}} \lambda$$

Critère de Neyman-Pearson

Rappel : optimization avec contraintes

Objectif :

$$\begin{array}{ll} \text{minimiser} & C = f(x, y) \\ \text{sous la contrainte} & g(x, y) = 0 \end{array}$$

Solution :

- Minimisation sans contrainte : $\frac{\partial f(x,y)}{\partial x} = 0$ et $\frac{\partial f(x,y)}{\partial y} = 0$, avec Δx et Δy indépendants
- Minimisation avec contrainte
FIGURE

Contrainte : $\mathbf{grad}gdr = \mathbf{0}$

minimisation : $\mathbf{grad}fdr = \mathbf{0} \Rightarrow \mathbf{grad}f(x, y) = -\lambda \mathbf{grad}g(x, y)$, avec λ le *multiplicateur de Lagrange*

Grandeur à minimiser : $f(x, y) + \lambda g(x, y)$

Critère de Neyman-Pearson

Application : communication binaire synchrone

Hypothèse :

- S_1 : signal d'amplitude 0 ; S_2 : signal d'amplitude m
- Bruit additif Gaussien $\mathcal{N}(0, \sigma_v^2)$
- Contrainte $P(\mathbf{D}_2 | S_1) = \alpha$

Solution :

$$\Lambda(z) = \exp\left(-\frac{m}{2\sigma_v^2}(m - 2z)\right) \underset{\mathbf{D}_1}{\overset{\mathbf{D}_2}{\gtrless}} \lambda$$

$$z \underset{\mathbf{D}_1}{\overset{\mathbf{D}_2}{\gtrless}} z_s, \quad z_s = ?$$

$$\Rightarrow P(\mathbf{D}_2 | S_1) = 1 - \text{erf}(z_s/\sigma_v) = \alpha_0$$

$$\Rightarrow z_s = \sigma_v \text{erf}^{-1}(1 - \alpha_0)$$

$$P(\mathbf{D}_2 | S_2) = 1 - \text{erf}\left(\frac{z_s - m}{\sigma_v}\right)$$

Critère de Neyman-Pearson

Application : communication binaire synchrone (suite)Application numérique : $m = 1$ et $\sigma = 1$

FIGURE

| $P(\mathbf{D}_2 S_1)$ | z_s | λ | $P(\mathbf{D}_2 S_2)$ |
|-------------------------|-------|-----------|-------------------------|
| 0.25 | 0.675 | 1.19 | 0.63 |
| 0.2 | 0.842 | 1.41 | 0.60 |
| 0.1 | 1.28 | 2.18 | 0.39 |
| 0.05 | 1.645 | 3.14 | 0.26 |
| 0.01 | 2.326 | 6.2 | 0.09 |

Statistique suffisante

FIGURE

Si toute l'information nécessaire à la prise de décision est dans Λ , alors Λ est dite statistique suffisante

Definition (Statistique suffisante)

On appelle *statistique suffisante* toute variable aléatoire ou ensemble de variables aléatoires qui contient toute l'information nécessaire à la prise de décision.

Statistique suffisante

Application : communication binaire synchrone

Détection d'un signal binaire d'amplitude m noyé dans un bruit blanc Gaussien.
Sur une période, N échantillons sont prélevés.

$$S_2 : z_n = m + v_n$$

$$S_1 : z_n = v_n$$

où $n = 1, 2, \dots, N$, $E(v_n) = 0$, and $E(v_n v_{n'}) = \sigma_v^2 \delta_{nn'}$

Solution :

Bruit blanc \Rightarrow Echantillons indépendants

$$\Lambda(\mathbf{z}) = \exp \left(-\frac{1}{\sigma_v^2} (\mathbf{m}^\top \mathbf{z} - \frac{1}{2} \mathbf{m}^\top \mathbf{m}) \right)$$

$$\Lambda(\mathbf{z}) \underset{D_1}{\overset{D_2}{\geq}} \lambda$$

$$\bar{z} = \frac{1}{N} \sum_{n=1}^N z_n \underset{D_1}{\overset{D_2}{\geq}} \frac{\sigma_v^2}{Nm} \ln \lambda + \frac{m}{2} = z_s$$

\bar{z} est une statistique suffisante.

Caractéristique opérationnelle d'un récepteur

Propriétés des courbes COR :

- $P(\mathbf{D}_2 | S_j)$ sont des fonctions décroissantes de λ , avec

$$P(\mathbf{D}_2 | S_j) = \int_{\lambda}^{\infty} p_{\Lambda}(\lambda' | S_j) d\lambda'.$$
- La courbe COR passe par les valeurs (0, 0) et (1, 1)
- $P(\mathbf{D}_2 | S_2) > P(\mathbf{D}_2 | S_1)$
- $\frac{dP_D}{dP_F} = \lambda$
- La concavité est toujours négative

Caractéristique opérationnelle d'un récepteur

Critère minimax :

FIGURE

Cas particulier : $C_{ij} = 1 - \delta_{ij}$

FIGURE

Critère de Neyman-Pearson :

Les courbes COR permettent de choisir $P(D_2 | S_1)$

Caractéristique opérationnelle d'un récepteur

Le problème Gaussien :

Mesures multiples : hypothèses binaires :

$$S_1 : p(\mathbf{z} | S_1) \Rightarrow \mathcal{N}(\mathbf{m}_1, \Sigma_1)$$

$$S_2 : p(\mathbf{z} | S_2) \Rightarrow \mathcal{N}(\mathbf{m}_2, \Sigma_2)$$

- Identification de signaux dans un bruit Gaussien coloré
- Tri de pièces mécaniques (plusieurs paramètres)

$$\Lambda(\mathbf{z}) = \sqrt{\frac{\det \Sigma_1}{\det \Sigma_2}} \exp \left(-\frac{1}{2} \left((\mathbf{z} - \mathbf{m}_2)^\top \Sigma_2^{-1} (\mathbf{z} - \mathbf{m}_2) - (\mathbf{z} - \mathbf{m}_1)^\top \Sigma_1^{-1} (\mathbf{z} - \mathbf{m}_1) \right) \right)$$

Règle de décision :

$$(\mathbf{z} - \mathbf{m}_1)^\top \Sigma_1^{-1} (\mathbf{z} - \mathbf{m}_1) - (\mathbf{z} - \mathbf{m}_2)^\top \Sigma_2^{-1} (\mathbf{z} - \mathbf{m}_2) \underset{D_1}{\overset{D_2}{\gtrless}} \ln \left(\lambda \sqrt{\frac{\det \Sigma_1}{\det \Sigma_2}} \right)$$

Surface de décision : conique dans \mathbf{Z}

Cas particuliers :

- Bruit identique : $\Sigma_1 = \Sigma_2$
- Mesures indépendantes : Σ_i identiques

