



---

**Thèse de doctorat de l'Université de Cergy-Pontoise**

Spécialité Traitement du Signal

Collaboration ONERA / UCP-ETIS

---



# Détection en Environnement non-Gaussien

## Application radar


---

Directeur de thèse	:	Patrick DUVAUT	ENSEA - ETIS
Encadrement	:	Jean-Philippe OVARLEZ	ONERA - DEMR/TSI
		David DECLERCQ	ENSEA - ETIS

---

Vendredi 14 Juin 2002

**Emmanuelle Jay**

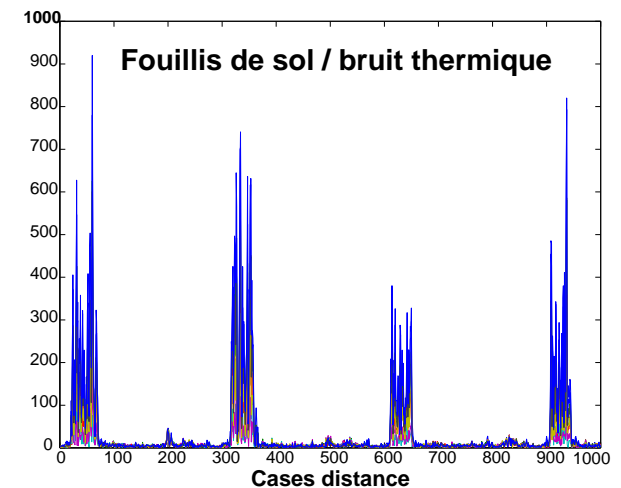
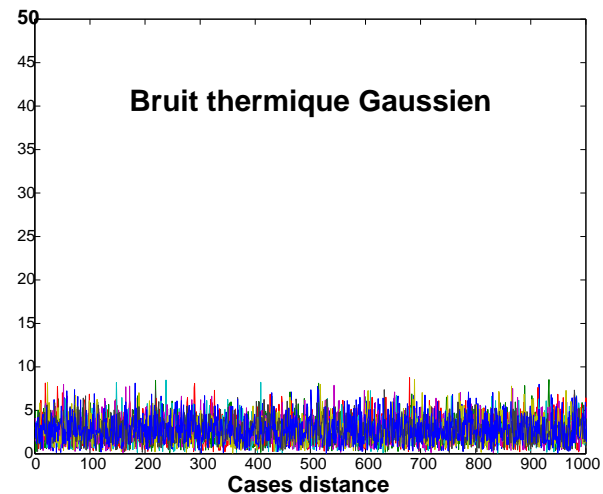
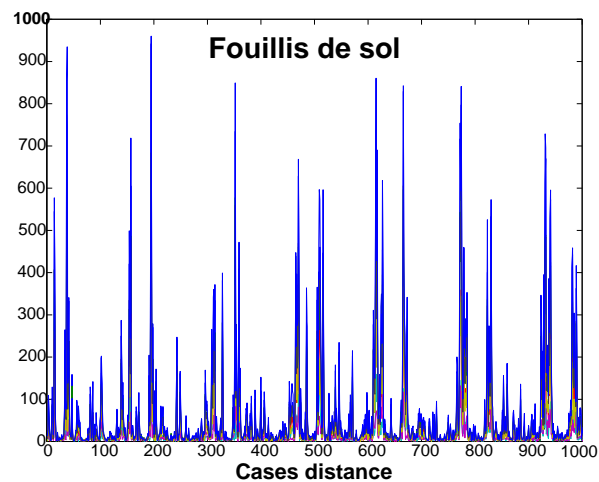



## **Plan de la présentation**

- 1 - Problématique du sujet**
- 2 - Caractérisation de l'environnement non-Gaussien**
- 3 - Le PEOD et le BORD : deux nouvelles structures de détection optimale**
- 4 - Analyse des performances du BORD sur données expérimentales**
- 5 - Conclusions et Perspectives**

# 1 - Problématique du sujet

## 1.1 - Les échos radar



**Comment s'affranchir de ces échos pour détecter le signal réfléchi par une cible ?**

# 1 - Problématique du sujet

## 1.2 - Mise en équation

- ◇ **Réflexions sur l'environnement** : Signaux aléatoires de fouillis

$$H_0 : \mathbf{y} = \mathbf{b} \quad \Rightarrow \quad \mathbf{p}(\mathbf{y}/\mathbf{H}_0) = \mathbf{p}_b(\mathbf{y}) \quad \rightarrow \quad \text{Fausse Alarme } (P_{fa}) \text{ si } H_1 \text{ au lieu de } H_0$$

- ◇ **Signal cible d'intérêt** : Signal déterministe ou aléatoire

$$H_1 : \mathbf{y} = \mathbf{b} + \mathbf{s} \quad \Rightarrow \quad \mathbf{p}(\mathbf{y}/\mathbf{H}_1) = \mathbf{p}_b(\mathbf{y} - \mathbf{s}) \quad \rightarrow \quad \text{Détection } (P_d) \text{ quand } H_1 \text{ est vérifiée}$$

- ◇ **Objectif de la détection** : Construire un test de détection

$$\boxed{D(\mathbf{y}) \underset{H_0}{\overset{H_1}{\gtrless}} \eta} \quad \text{tel que} \quad \left\{ \begin{array}{l} \text{à } \mathbf{P}_{fa} = \mathbb{P}(D(\mathbf{y}) \underset{H_0}{>} \eta) \quad \text{fixée} \\ \mathbf{P}_d = \mathbb{P}(D(\mathbf{y}) \underset{H_1}{>} \eta) \quad \text{soit optimale} \end{array} \right.$$

**Identifier la nature statistique du fouillis pour construire  $D(\mathbf{y})$**

# 1 - Problématique du sujet

## 1.3 - Etat de l'art de la détection en environnement non-Gaussien

---

- ◇ **Détection non-cohérente** : Optimisation par TFAC du filtre adapté ([Watt85, Gand88, Rifk94, Shni95])  
⇒ **Non robustes, non optimales**
- ◇ **Détection cohérente** ([Fari85]) : Modélisation par des processus complexes non-Gaussiens (les SIRP) [Yao73, Gold76, Cont87, Rang91, Rang93, Rang95, Barn96]
  - ⇒ Adéquation aux données expérimentales de fouillis de terre et de mer ([Trun70, Cont87, Bill93, ...]),
  - ⇒ Expressions analytiques des détecteurs optimaux ([Cont87, Fari87, Cont91, Gini98, Sang99, ...]),
  - ⇒ Performances de détection très largement accrues / filtre adapté
    - ⇒ **Hypothèse *a priori* nécessaire pour l'estimation des paramètres de la loi**
    - ⇒ **Les détecteurs ne sont optimaux que pour les environnements considérés**

### Objectif de la thèse

**Mise en place de détecteurs SIRP cohérents adaptatifs à l'environnement**

## 2 - Caractérisation de l'environnement non-Gaussien

Les SIRV englobent de nombreuses lois non-Gaussiennes

---

	Nature du SIRV	Détecteur optimal
	Gaussien	<b>OGD</b> - Optimum Gaussian Detector
	K-distribué	<b>OKD</b> - Optimum K Detector
	Cauchy, Student-t	<b>OCD, OStD</b> - Optimum Cauchy, Student-t Detector
	Weibull	<b>OWD</b> - Optimum Weibull Detector

## 2 - Caractérisation de l'environnement non-Gaussien

Les SIRV englobent de nombreuses lois non-Gaussiennes

Loi de la <i>texture</i>	Nature du SIRV	Détecteur optimal
Dirac en 1	Gaussien	OGD - Optimum Gaussian Detector
Gamma	K-distribué	OKD - Optimum K Detector
Inverse Gamma	Cauchy, Student-t	OCD, OStD - Optimum Cauchy, Student-t Detector
Weibull	?	?
?	Weibull	OWD - Optimum Weibull Detector

**Comment caractériser l'environnement  
directement d'après les données radar ?**

## 2 - Caractérisation de l'environnement non-Gaussien

### 2.1 - Les SIRV : Spherically Invariant Random Vector

◇ Le théorème de représentation de K. Yao, [Yao73] :

$$\mathbf{y} = \mathbf{x} \sqrt{\tau} \begin{cases} \mathbf{y} & \text{SIRV ou Vecteur Gaussien Composé complexe de taille } m \\ \tau & \text{Texture du SIRV, v.a. positive de loi } p(\tau) \\ \mathbf{x} & \text{Speckle du SIRV, stat. indépdt de la texture : } \mathbf{x} \sim \mathcal{CN}(\mathbf{0}_m, 2\mathbf{M}) \end{cases}$$

$$\Rightarrow p(\mathbf{y}) = \int_0^{+\infty} \underbrace{p(\mathbf{x}/\tau)}_{\text{Connu}} p(\tau) d\tau$$

**La loi de la texture caractérise la nature du SIRV**



## 2 - Caractérisation de l'environnement non-Gaussien

### 2.2 - Les SIRV : Propriétés

◇ Fonction caractéristique cohérente radiale : **Sphériquement invariante** :

$$\text{SIRV : } \mathbf{y} = \mathbf{y}_I + j \mathbf{y}_Q \left\{ \begin{array}{ll} \mathbf{y}_I, \mathbf{y}_Q & : \text{ Statistiquement indépendants} \\ \mathbf{y}_I, \mathbf{y}_Q / \tau & \sim \mathcal{N}(\mathbf{0}_m, \tau \mathbf{M}) \\ \arg(\mathbf{y}_I, \mathbf{y}_Q) & : \text{ Uniformément distribué entre } [-\pi, +\pi] \\ p(\mathbf{y}) & = h(\mathbf{y}^\dagger \mathbf{M}^{-1} \mathbf{y}) \end{array} \right.$$



$$F_y(\mathbf{u}) = \int_{\mathbb{R}^{2m}} p(\mathbf{y}) e^{j \mathbf{u}^\dagger \mathbf{y}} d\mathbf{y} = g(\mathbf{u}^\dagger \mathbf{M} \mathbf{u})$$

◇ Invariance par transformation linéaire :  **$\mathbf{A} \mathbf{y} + \mathbf{b}$  est encore un SIRV**, de même loi de texture que  $\mathbf{y}$

## 2 - Caractérisation de l'environnement non-Gaussien

### 2.2 - Les SIRV : Propriétés

◇ Fonction caractéristique cohérente radiale : **Sphériquement invariante** :

$$\text{SIRV : } \mathbf{y} = \mathbf{y}_I + j \mathbf{y}_Q \left\{ \begin{array}{ll} \mathbf{y}_I, \mathbf{y}_Q & : \text{ Statistiquement indépendants} \\ \mathbf{y}_I, \mathbf{y}_Q / \tau & \sim \mathcal{N}(\mathbf{0}_m, \tau \mathbf{M}) \\ \arg(\mathbf{y}_I, \mathbf{y}_Q) & : \text{ Uniformément distribué entre } [-\pi, +\pi] \\ p(\mathbf{y}) & = h(\mathbf{y}^\dagger \mathbf{M}^{-1} \mathbf{y}) \end{array} \right.$$



$$F_y(\mathbf{u}) = \int_{\mathbb{R}^{2m}} p(\mathbf{y}) e^{j \mathbf{u}^\dagger \mathbf{y}} d\mathbf{y} = g(\mathbf{u}^\dagger \mathbf{M} \mathbf{u})$$

◇ Invariance par transformation linéaire :  **$\mathbf{A} \mathbf{y} + \mathbf{b}$  est encore un SIRV**, de même loi de texture que  $\mathbf{y}$

**Solution adoptée : Approche Bayésienne**

## 2 - Caractérisation de l'environnement non-Gaussien

### 2.3 - Densité *a posteriori* de la texture

◇ La règle de Bayes :

$$p(\tau/\mathbf{y}) = \frac{\overbrace{p(\mathbf{y}/\tau)}^{\text{connue}} \overbrace{p(\tau)}^{\text{inconnue}}}{\underbrace{p(\mathbf{y})}_{\text{inconnue}}} = \frac{p(\mathbf{y}/\tau) p(\tau)}{\int_0^{+\infty} p(\mathbf{y}/\tau) p(\tau) d\tau}$$

◇ Apprentissage sur  $N$  SIRV de référence  $[\mathbf{r}_1, \dots, \mathbf{r}_N]^t$  : **Prior non-informatif de Jeffrey pour  $\tau$**

$$g(\tau) = \frac{1}{\tau}$$

$$\Rightarrow p(\tau/\mathbf{r}_i) = \frac{\overbrace{p(\mathbf{r}_i/\tau)}^{\text{connue}} \overbrace{g(\tau)}^{\text{connue}}}{\underbrace{p(\mathbf{r}_i)}_{\text{connue}}} = \frac{p(\mathbf{r}_i/\tau) g(\tau)}{\int_0^{+\infty} p(\mathbf{r}_i/\tau) g(\tau) d\tau} = \mathcal{IG} \left( m, \frac{2}{\mathbf{r}_i^\dagger \mathbf{M}^{-1} \mathbf{r}_i} \right)$$

**Nécessité d'estimer la matrice de corrélation du *speckle***

## 2 - Caractérisation de l'environnement non-Gaussien

### 2.4 - Estimation Normalisée Structurée de la Matrice de Covariance du *speckle* (NSCM)

---

◇ D'après les  $N$  vecteurs de référence de taille  $m$ ,  $[\mathbf{r}_1, \dots, \mathbf{r}_N]^t$  :

$$\mathbf{M}_r = \mathbb{E}(\mathbf{r} \mathbf{r}^\dagger) = \mathbb{E}(\tau \mathbf{x} \mathbf{x}^\dagger) = \mathbb{E}(\tau) \mathbf{M}_x = 2 \mathbb{E}(\tau) \mathbf{M}$$

$$\Rightarrow \widehat{\mathbf{M}}_x = \frac{m}{N} \sum_{i=1}^N \frac{\mathbf{r}_i \mathbf{r}_i^\dagger}{\mathbf{r}_i^\dagger \mathbf{r}_i} \iff \widehat{\mathbf{M}}_x = \frac{m}{N} \sum_{i=1}^N \frac{\mathbf{x}_i \mathbf{x}_i^\dagger}{\mathbf{x}_i^\dagger \mathbf{x}_i}$$

**Estimation statistiquement indépendante de la loi de la *texture***

[Gini99, Gini00b, Gini00c]

## 2 - Caractérisation de l'environnement non-Gaussien

### 2.5 - Estimation de la loi de la *texture*

◇ Par approximation de Padé :

$$\hat{p}(\tau) = \sum_{k=1}^M \lambda_k e^{-\alpha_k \tau}$$

i) **Retirage** de v.a. de *texture* selon sa loi *a posteriori* instantanée :  $\tilde{\tau}_{i=1}^N \sim p(\tau/\mathbf{r}_i)$

ii) Estimation des moments :  $\hat{\mu}_n = N^{-1} \sum_{i=1}^N \tilde{\tau}_i^n$

iii) Calcul des  $M$  coefficients de Padé  $\{\alpha_k\}$  et  $\{\lambda_k\}$  de taille  $M$  à partir des moments

◇ Par un estimateur Monte-Carlo Bayésien :

$$p(\tau) = \int_{\mathbb{R}^m} p(\tau/\mathbf{r}) p(\mathbf{r}) d\mathbf{r} \quad \xrightarrow{\text{MC}}$$

$$\hat{p}_N(\tau) = \frac{1}{N} \sum_{i=1}^N p(\tau/\mathbf{r}_i)$$

## 2 - Caractérisation de l'environnement non-Gaussien

### 2.5 - Estimation de la loi de la *texture*

◇ Par approximation de Padé :

$$\hat{p}(\tau) = \sum_{k=1}^M \lambda_k e^{-\alpha_k \tau}$$

i) **Retirage** de v.a. de *texture* selon sa loi *a posteriori* instantanée :  $\tilde{\tau}_{i=1}^N \sim p(\tau/\mathbf{r}_i)$

ii) Estimation des moments :  $\hat{\mu}_n = N^{-1} \sum_{i=1}^N \tilde{\tau}_i^n$

iii) Calcul des  $M$  coefficients de Padé  $\{\alpha_k\}$  et  $\{\lambda_k\}$  de taille  $M$  à partir des moments

◇ Par un estimateur Monte-Carlo Bayésien :

$$p(\tau) = \int_{\mathbb{R}^m} p(\tau/\mathbf{r}) p(\mathbf{r}) d\mathbf{r} \quad \xrightarrow{\text{MC}}$$

$$\hat{p}_N(\tau) = \frac{1}{N} \sum_{i=1}^N p(\tau/\mathbf{r}_i)$$

**Deux nouvelles structures de détecteurs en découlent**

## 2 - Caractérisation de l'environnement non-Gaussien

### 2.5 - Estimation de la loi de la *texture*

◇ Par approximation de Padé :

$$\hat{p}(\tau) = \sum_{k=1}^M \lambda_k e^{-\alpha_k \tau}$$

PEOD

i) **Retirage** de v.a. de *texture* selon sa loi *a posteriori* instantanée :  $\tilde{\tau}_{i=1}^N \sim p(\tau/\mathbf{r}_i)$

ii) Estimation des moments :  $\hat{\mu}_n = N^{-1} \sum_{i=1}^N \tilde{\tau}_i^n$

iii) Calcul des  $M$  coefficients de Padé  $\{\alpha_k\}$  et  $\{\lambda_k\}$  de taille  $M$  à partir des moments

◇ Par un estimateur Monte-Carlo Bayésien :

$$p(\tau) = \int_{\mathbb{R}^m} p(\tau/\mathbf{r}) p(\mathbf{r}) d\mathbf{r} \quad \xrightarrow{\text{MC}}$$

$$\hat{p}_N(\tau) = \frac{1}{N} \sum_{i=1}^N p(\tau/\mathbf{r}_i)$$

Deux nouvelles structures de détecteurs en découlent

## 2 - Caractérisation de l'environnement non-Gaussien

### 2.5 - Estimation de la loi de la *texture*

◇ Par approximation de Padé :

$$\hat{p}(\tau) = \sum_{k=1}^M \lambda_k e^{-\alpha_k \tau}$$

PEOD

i) **Retirage** de v.a. de *texture* selon sa loi *a posteriori* instantanée :  $\tilde{\tau}_{i=1}^N \sim p(\tau/\mathbf{r}_i)$

ii) Estimation des moments :  $\hat{\mu}_n = N^{-1} \sum_{i=1}^N \tilde{\tau}_i^n$

iii) Calcul des  $M$  coefficients de Padé  $\{\alpha_k\}$  et  $\{\lambda_k\}$  de taille  $M$  à partir des moments

◇ Par un estimateur Monte-Carlo Bayésien :

BORD

$$p(\tau) = \int_{\mathbb{R}^m} p(\tau/\mathbf{r}) p(\mathbf{r}) d\mathbf{r}$$

MC

$$\hat{p}_N(\tau) = \frac{1}{N} \sum_{i=1}^N p(\tau/\mathbf{r}_i)$$

Deux nouvelles structures de détecteurs en découlent



## 3 - Mise en place des détecteurs optimaux

### 3.1 - Théorie de la détection cohérente avec les SIRV

◇ Chaque observation  $\mathbf{y}_{obs}$  est un **SIRV** de taille  $m$  :

$$\mathbf{y}_{obs} = \zeta \mathbf{s} + \mathbf{b} = \zeta \mathbf{s} + \mathbf{x} \sqrt{\tau} \begin{cases} \mathbf{b} & : \text{ SIRV de loi : } p_{\mathbf{b}}(\mathbf{b}) = p_{\mathbf{b}}(\sqrt{\tau} x_1, \dots, \sqrt{\tau} x_m) \\ \mathbf{s} & = \mathbf{s}(A, \underline{\theta}) : \text{ Signal cible d'amplitude } A \text{ et où } \underline{\theta} = (f_d, \tau, \dots) \end{cases}$$

$$\diamond \text{Hypothèses} \begin{cases} H_0 & : \zeta = 0 \Rightarrow p(\mathbf{y}_{obs} / H_0) = p_{\mathbf{b}}(\mathbf{y}_{obs}) \\ H_1 & : \zeta = 1 \Rightarrow p(\mathbf{y}_{obs} / H_1) = p_{\mathbf{b}}(\mathbf{y}_{obs} - \mathbf{s}) \end{cases}$$

$$\diamond \text{Erreurs possibles} \begin{cases} \text{Décider } H_0 \text{ si } H_1 & : \text{ Non-détection : } 1 - P_d \\ \text{Décider } H_1 \text{ si } H_0 & : \text{ Fausse Alarme : } P_{fa} \end{cases}$$

### 3 - Mise en place des détecteurs optimaux

#### Critère de décision

◇ Critère de Neymann-Pearson : **Fixer**  $P_{fa}$  **et optimiser**  $P_d$

◇ **Décision optimale** : Le rapport de vraisemblance :  $\Lambda(\mathbf{y}_{obs}) = \frac{p_{\mathbf{b}}(\mathbf{y}_{obs} - \mathbf{s} / H_0)}{p_{\mathbf{b}}(\mathbf{y}_{obs} / H_0)} \underset{H_0}{\overset{H_1}{\gtrless}} \eta$

◇ **Cas d'une cible d'amplitude inconnue** : Le rapport de vraisemblance généralisé

$$\mathbf{s}(A, \theta) = A \mathbf{p} \begin{cases} \hat{A}_{mv} = \frac{|\mathbf{p}^\dagger \mathbf{M}^{-1} \mathbf{y}_{obs}|^2}{\mathbf{p}^\dagger \mathbf{M}^{-1} \mathbf{p}} \\ \Lambda(\mathbf{y}_{obs}, \hat{A}_{mv}) = \frac{\int_0^{+\infty} \tau^{-m} \exp\left(-\frac{q_1(\mathbf{y}_{obs})}{2\tau}\right) p(\tau) d\tau}{\int_0^{+\infty} \tau^{-m} \exp\left(-\frac{q_0(\mathbf{y}_{obs})}{2\tau}\right) p(\tau) d\tau} \underset{H_0}{\overset{H_1}{\gtrless}} \eta \end{cases}$$

**Tout repose sur la loi de la *texture* du SIRV**

### 3 - Mise en place des détecteurs optimaux

#### 3.2 - Le PEOD - Padé Estimated Optimum Detector

◇ Loi de la *texture* estimée par Padé (sur  $N$  références) :

$$p(\tau) \longleftrightarrow \hat{p}(\tau) = \sum_{k=1}^M \lambda_k e^{-\alpha_k \tau}$$

◇ Estimation NSCM de la matrice de covariance (sur  $N$  références) :

$$\hat{\mathbf{M}} = \frac{m}{N} \sum_{i=1}^N \frac{\mathbf{r}_i \mathbf{r}_i^\dagger}{\mathbf{r}_i^\dagger \mathbf{r}_i}$$

PEOD ([Jay01]) :

$$\left( \frac{q_1(\mathbf{y}_{obs})}{q_0(\mathbf{y}_{obs})} \right)^{\frac{1-m}{2}} \frac{\sum_{k=1}^M \lambda_k (\alpha_k)^{\frac{m-1}{2}} K_{1-m} \left( \sqrt{2 \alpha_k q_1(\mathbf{y}_{obs})} \right)}{\sum_{k=1}^M \lambda_k (\alpha_k)^{\frac{m-1}{2}} K_{1-m} \left( \sqrt{2 \alpha_k q_0(\mathbf{y}_{obs})} \right)} \underset{H_0}{\overset{H_1}{>}} \eta$$

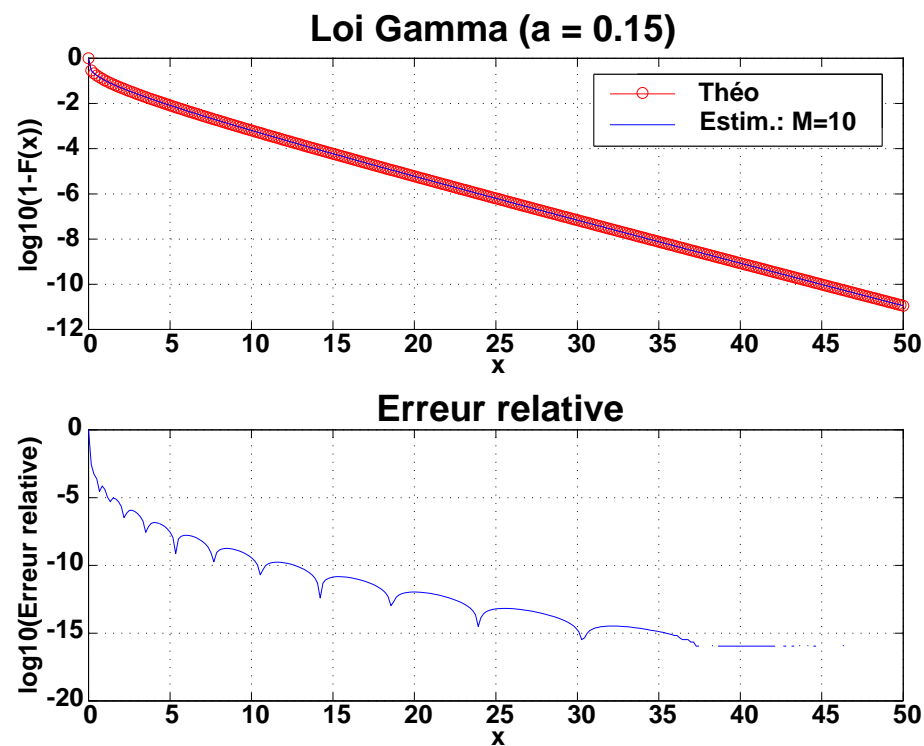
$q_0(\mathbf{y}_{obs}) = \mathbf{y}_{obs}^\dagger \hat{\mathbf{M}}^{-1} \mathbf{y}_{obs}$	$q_1(\mathbf{y}_{obs}) = \mathbf{y}_{obs}^\dagger \hat{\mathbf{M}}^{-1} \mathbf{y}_{obs} - \frac{ \mathbf{p}^\dagger \hat{\mathbf{M}}^{-1} \mathbf{y}_{obs} ^2}{\mathbf{p}^\dagger \hat{\mathbf{M}}^{-1} \mathbf{p}}$	F.A. $\equiv q_0(\mathbf{y}) - q_1(\mathbf{y})$
---	---	---

## 3.2 - Le PEOD - Padé Estimated Optimum Detector

### Pertinence de l'approximation de Padé


D'après les moments théoriques

Loi Gamma -  $\log_{10}(1 - F(x))$



D'après les moments estimés

K-dist ( $\nu = 0.1$ ) - EQM en fonction de  $N$

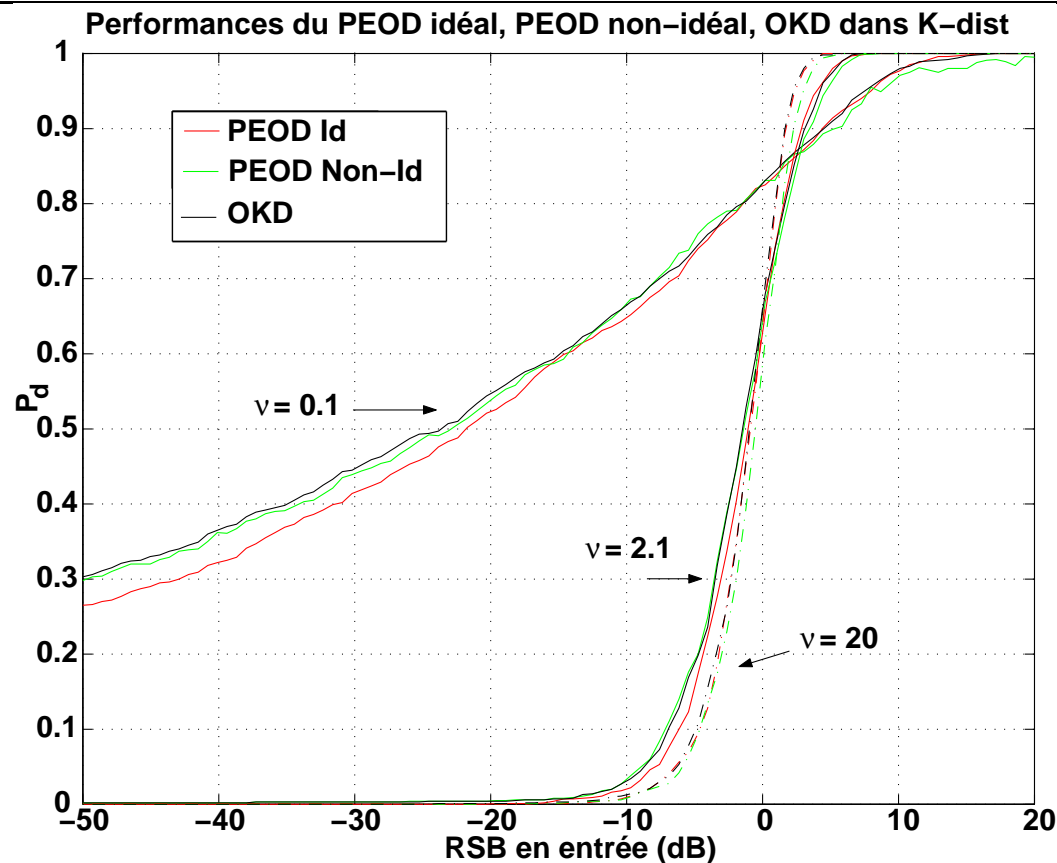


## 3.2 - Le PEOD - Padé Estimated Optimum Detector

### Performances de détection - $m = 10$

Comparaison PEOD "idéal" / PEOD "non-idéal" -  $P_{fa} = 10^{-3}$

K-dist.  $M_{\nu=0.1} = 9, M_{\nu=2.1} = 6, M_{\nu=20} = 3$



## 3 - Mise en place des détecteurs optimaux

### 3.3 - Le BORD - Bayesian Optimum Radar Detector

◇ Estimée MC-bayésienne de  $p(\tau)$  :

$$\hat{p}_N(\tau) = \frac{\tau^{-m-1}}{2^m \Gamma(m) N} \sum_{i=1}^N \left( \mathbf{r}_i^\dagger \hat{\mathbf{M}}^{-1} \mathbf{r}_i \right)^m \exp \left( -\frac{\mathbf{r}_i^\dagger \hat{\mathbf{M}}^{-1} \mathbf{r}_i}{2\tau} \right)$$

◇ Le BORD dépend **directement** des données reçues par le radar (Références et Observations)

**BORD ([Jay02a,b]) :**

$$\frac{\sum_{i=1}^N \left[ \frac{\mathbf{r}_i^\dagger \hat{\mathbf{M}}^{-1} \mathbf{r}_i}{(q_1(\mathbf{y}_{obs}) + \mathbf{r}_i^\dagger \hat{\mathbf{M}}^{-1} \mathbf{r}_i)^2} \right]^m}{\sum_{i=1}^N \left[ \frac{\mathbf{r}_i^\dagger \hat{\mathbf{M}}^{-1} \mathbf{r}_i}{(q_0(\mathbf{y}_{obs}) + \mathbf{r}_i^\dagger \hat{\mathbf{M}}^{-1} \mathbf{r}_i)^2} \right]^m} \underset{H_0}{\overset{H_1}{>}} \eta$$

$q_0(\mathbf{y}_{obs}) = \mathbf{y}_{obs}^\dagger \hat{\mathbf{M}}^{-1} \mathbf{y}_{obs}$	$\hat{\mathbf{M}} = \frac{m}{N} \sum_{i=1}^N \frac{\mathbf{r}_i \mathbf{r}_i^\dagger}{\mathbf{r}_i^\dagger \mathbf{r}_i}$	$q_1(\mathbf{y}_{obs}) = \mathbf{y}_{obs}^\dagger \hat{\mathbf{M}}^{-1} \mathbf{y}_{obs} - \frac{ \mathbf{p}^\dagger \hat{\mathbf{M}}^{-1} \mathbf{y}_{obs} ^2}{\mathbf{p}^\dagger \hat{\mathbf{M}}^{-1} \mathbf{p}}$
---	---	---

## 3 - Mise en place des détecteurs optimaux

### Caractéristiques attendues pour un détecteur

---

- ◇ Calcul du seuil de détection

$$P_{fa} = \mathbb{P} \left( \int D(\mathbf{y}/\tau) p(\tau) d\tau \stackrel{H_0}{>} \eta \right)$$

- ◇ Si indépendance par rapport à la loi de la texture :

Propriété TFAC (Taux de Fausse Alarme Constant) par rapport à la loi de la texture



⇒ **Indépendant de la statistique de l'environnement**

- ◇ Capacité d'adaptation à la nature de l'environnement, Optimalité
- ◇ Détermination de la loi du test de détection

# 3.3 - Le BORD - Bayesian Optimum Radar Detector

## Caractéristiques opérationnelles

- ◇ Détecteur **adaptatif**
- ◇ Conserve la **propriété TFAC** par rapport à la loi de la *texture* :





## 3.3 - Le BORD - Bayesian Optimum Radar Detector

### Comportement asymptotique

- ◇ Asymptotique : le nombre de données de références  $N \rightarrow \infty$

$$\hat{\mathbf{M}} \xrightarrow{p.s.} \mathbf{M} \quad \text{ET} \quad \text{BORD} \xrightarrow{\text{Loi}} \left( \frac{q_0(\mathbf{y}_{obs})}{q_1(\mathbf{y}_{obs})} \right)^m$$

- ◇ Le BORD Asymptotique **coïncide avec l'ALQ** ([Gini97a])
- ◇ Le BORD Asymptotique est **TFAC** par rapport à la *texture* :

$$\text{BORD Asymptotique équivale à } \left( \begin{array}{c} \text{F.Q.Gauss} \\ \underbrace{q_0(\mathbf{x}_{obs})} \\ \hline \underbrace{q_1(\mathbf{x}_{obs})} \\ \text{Gauss} \end{array} \right)^m$$

# Le BORD Asymptotique

## Loi du BORD Asymptotique

- ◇ Le BORD Asymptotique **ne dépend que du speckle** des observations (vecteurs Gaussiens complexes)

### Loi du BORD Asymptotique


- Test du BORD Asymptotique équivalent à :

$$\frac{|\mathbf{p}^\dagger \mathbf{M}^{-1} \mathbf{x}_{obs}|^2}{(\mathbf{p}^\dagger \mathbf{M}^{-1} \mathbf{p}) (\mathbf{x}_{obs}^\dagger \mathbf{M}^{-1} \mathbf{x}_{obs})} \underset{H_0}{\overset{H_1}{\approx}} \frac{m\sqrt{\eta} - 1}{m\sqrt{\eta}}$$

- Th. de Cochran (quand M non singulière) :

$$\eta = P_{fa}^{\frac{m}{1-m}}$$

### Validation de $\eta$ sur simulations

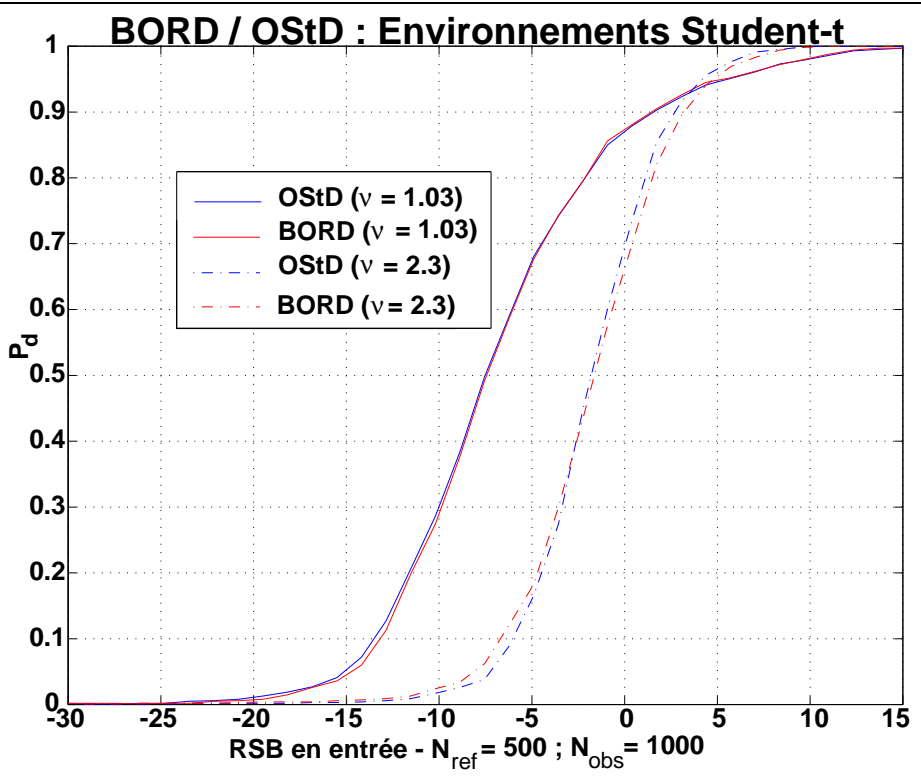


# 3.3 - Le BORD - Bayesian Optimum Radar Detector

Performances de détection -  $m = 10$  -  $\rho_1 \approx 0.1$

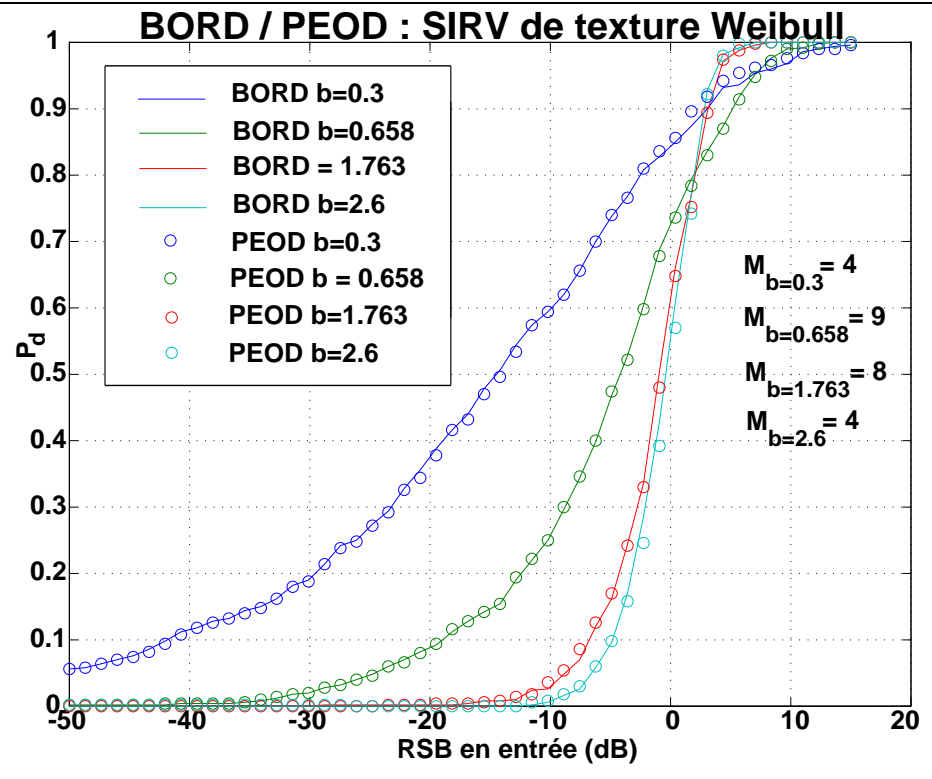
Comparaison avec l'OStD -  $P_{fa} = 10^{-3}$

Student-t  $\nu = 1.03$  et  $\nu = 2.3$  -  $N_{ref} = 500$



Comparaison PEOD "idéal" -  $P_{fa} = 10^{-3}$

Env. dont texture Weibull ( $b = 0.3, 0.658, 1.763, 2.6$ )




## 4 - Le BORD sur données expérimentales

### Description des données

#### Données fournies par Thalès TAD

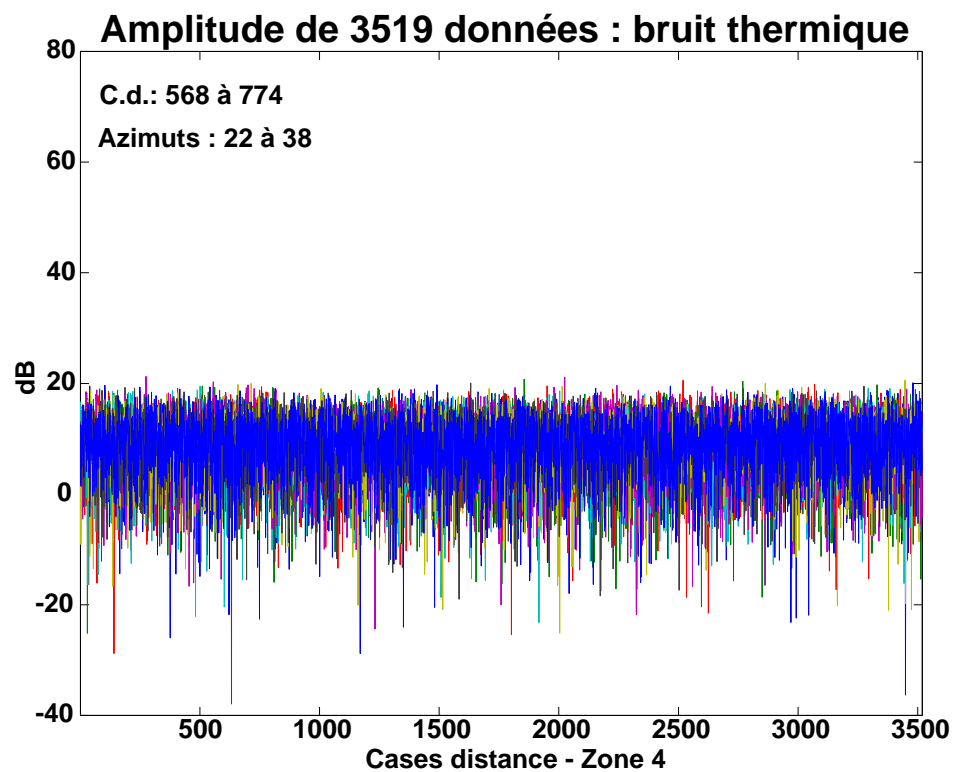
- Fouillis de sol (site bas)
- 70 azimuts
- 868 cases distance de 60 m.
- 8 impulsions émises
- Horizon radio-électrique à  $\sim 15$  kms ( $\sim$  cd 250)



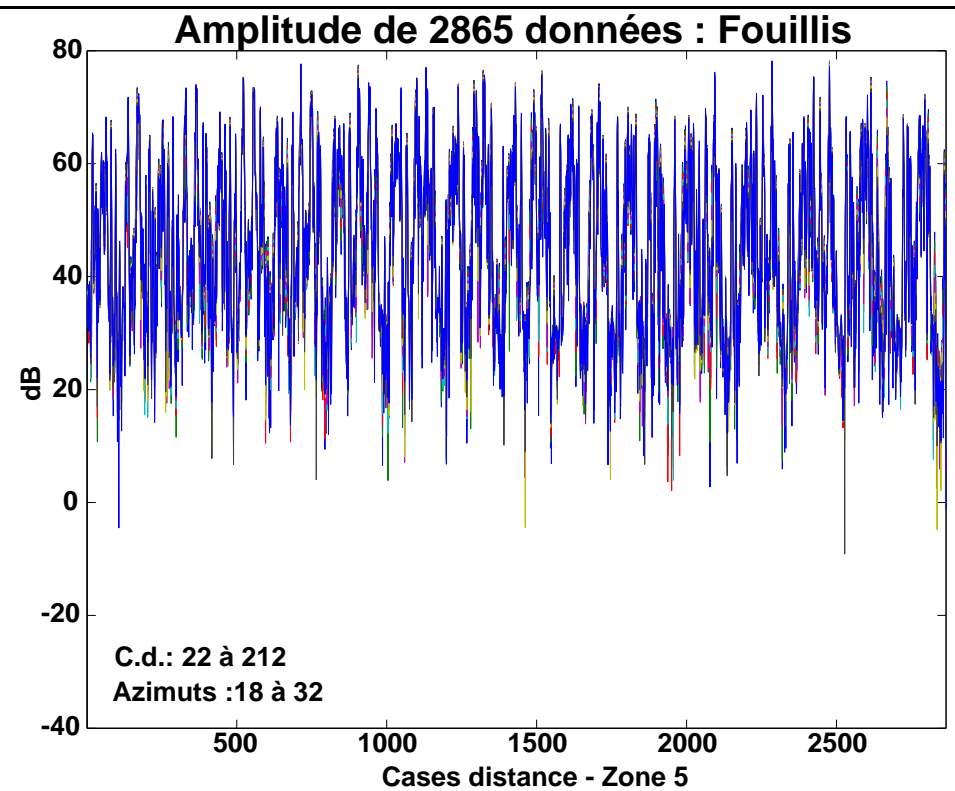
# 4 - Le BORD sur données expérimentales

## Amplitudes des données

### Bruit thermique



### Fouillis

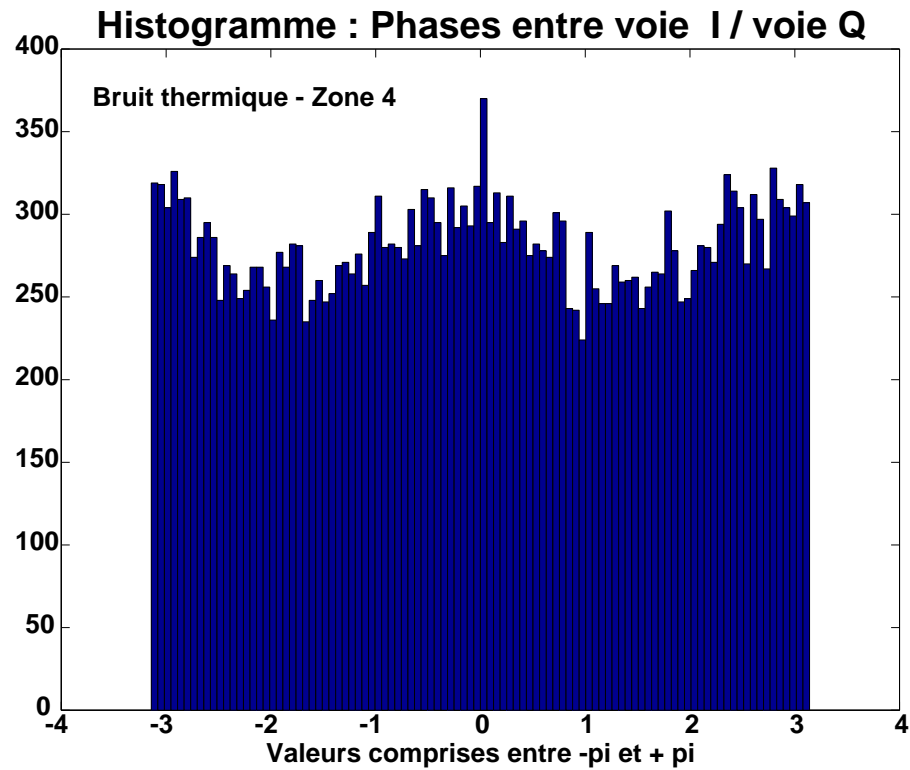


## 4 - Le BORD sur données expérimentales

### Phases des données entre voie I et Q : Hypothèse phase uniforme vérifiée


**Zone de bruit thermique**

$8 \times 1617$  phases



**Zone de Fouillis**

$8 \times 1441$  phases



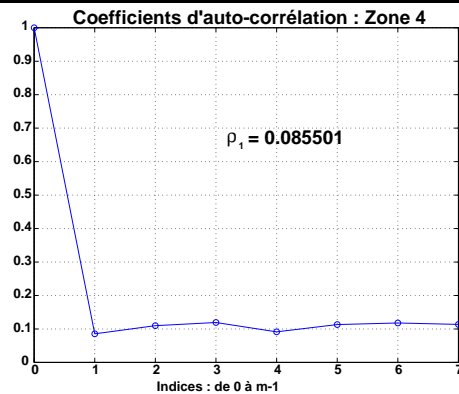
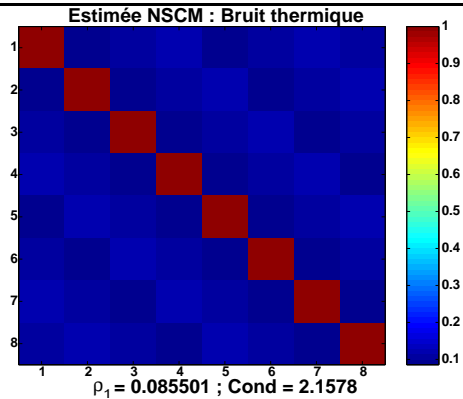
## 4 - Le BORD sur données expérimentales

### Corrélation des données

**Bruit thermique** :  $\hat{\rho}_1 = 0.0855$

$$\text{Cond}(\hat{\mathbf{M}}) = 2.1578$$

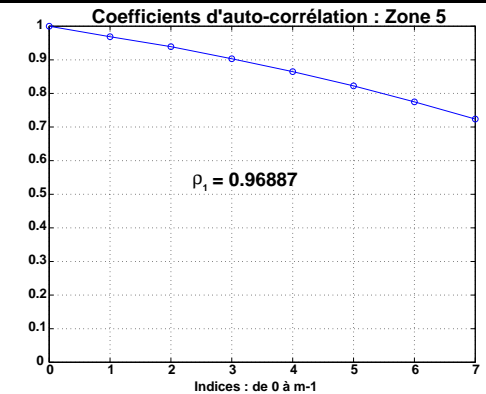
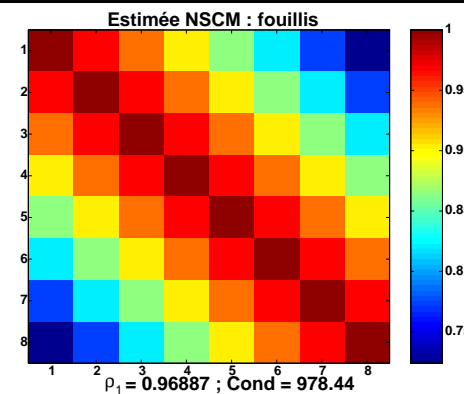
Matrice bien conditionnée



**Fouillis** :  $\hat{\rho}_1 = 0.96887$

$$\text{Cond}(\hat{\mathbf{M}}) = 978.44$$

Matrice mal conditionnée

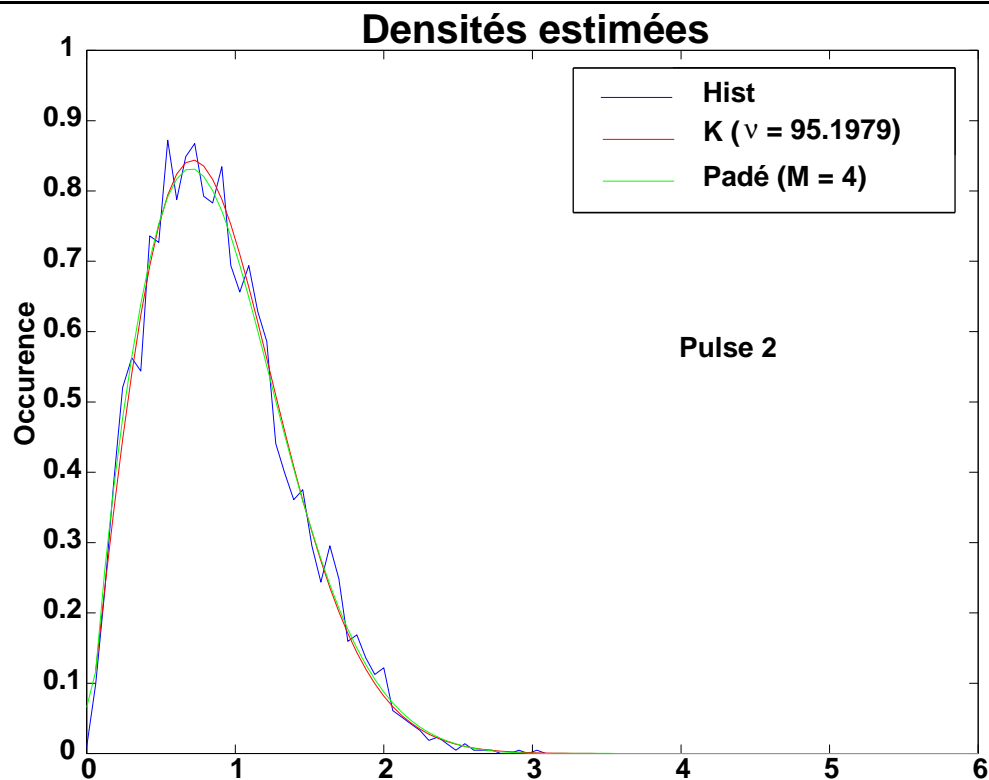


# 4 - Le BORD sur données expérimentales

## Comparaison à une K-distribution

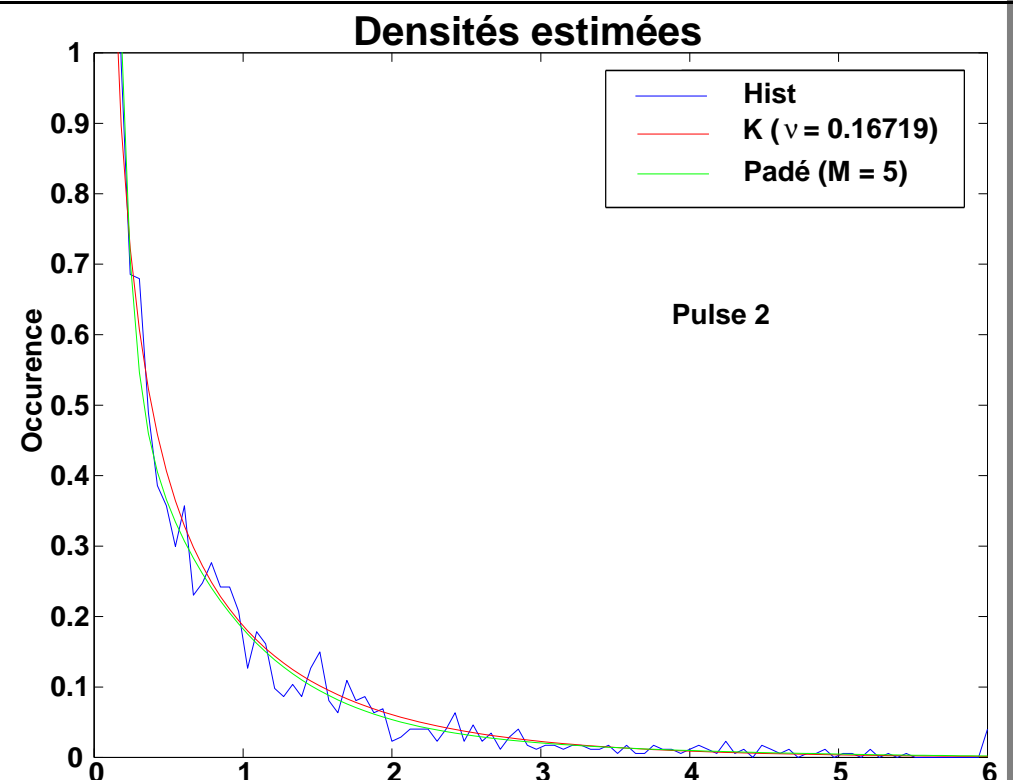
### Bruit thermique (Zone 4)

Histogrammes / Padé ( $M = 4$  ou  $M = 5$ )



### Fouillis (Zone 5)

Histogrammes / Padé ( $M = 5$  ou  $M = 6$ )






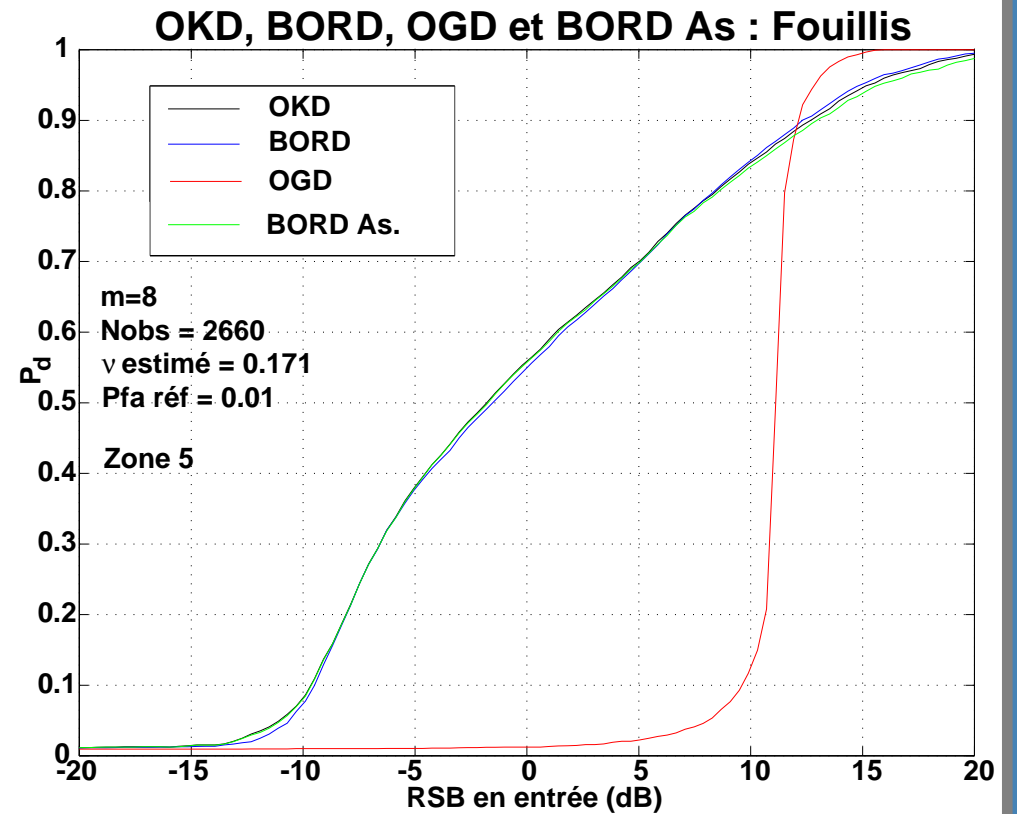
# 4 - Le BORD sur données expérimentales

## Performances de détection

### Bruit thermique : Zone 4



### Fouillis : Zone 5



## 5 - Conclusions

Apport de ma thèse : **Approche bayésienne pour la caractérisation de l'environnement SIRV**

- Le PEOD "idéal" : Détecteur "**étalon**" si détecteur optimal inconnu,
- Le PEOD "non-idéal" adaptatif : **Robuste** si un grand nombre de références est disponible,
- Le BORD : **Adaptatif, TFAC** / loi de la *texture*, **Optimal**, Asymptotiquement convergent,
- Le BORD Asymptotique : coïncide avec l'ALQ, loi du test identifiée, directement relié au F.A.,  
**Adaptatif, TFAC** / loi de la *texture*, **Performances théoriques**, **Mise en œuvre immédiate**,
- Expérimentalement : **Validation** du modèle SIRV et des détecteurs associés.

**Le BORD généralise les détecteurs SIRV existants : Adaptatif à l'environnement**

Travaux inscrits dans le PEA TRA réalisé avec TAD (Thalès Air Defence)

## Perspectives

### ◇ Etudes théoriques :

- Recherche d'un *prior* empirique adaptatif,
- Loi du BORD Asymptotique : cas où la matrice est singulière, aléatoire (Wishart)

**Résultat pressenti : expression dépendante du rang de la matrice**

### ◇ Etudes numériques :

- Utilisation de méthodes numériques pour la régularisation de la matrice de covariance, pour atteindre des valeurs de  $P_{fa}$  plus faibles (Echantillonnage d'importance, échantillonnage pondéré),

### ◇ Etudes expérimentales :

- Extension des travaux à du fouillis de mer, du fouillis type transition terre/mer, à des modèles de cibles fluctuantes, à des images SAR pour la segmentation / classification de zones de terrain...
- Mise en œuvre TFAC par fenêtre glissante du BORD et du BORD Asymptotique.