
Synthèse des traitements STAP pour la détection en environnement hétérogène

Stéphanie Bidon¹, Olivier Besson¹, Jean-Yves Tournet²

1. Université de Toulouse

*Institut Supérieur de l'Aéronautique et de l'Espace
Département Électronique Optronique et Signal
10 avenue Edouard Belin
F-31055 Toulouse Cedex 4
{stephanie.bidon,olivier.besson}@isae.fr*

2. Université de Toulouse

*IRIT - ENSEEIHT - T3SA
2 rue Camichel
BP 7122
F-31071 Toulouse Cedex 7
jean-yves.tourneret@enseeiht.fr*

RÉSUMÉ. Cet article synthétise les différents algorithmes spatio-temporels adaptatifs (STAP) développés et/ou utilisés pour la détection en environnement non-homogène. Nous rappelons en premier lieu les causes principales qui peuvent conduire à un environnement hétérogène. Puis nous présentons les stratégies STAP les plus communément utilisées dans de tels environnements.

ABSTRACT. This paper presents a review of space-time adaptive processing techniques (STAP) that have been developed or used in heterogeneous environment. More specifically, the main causes that lead to non-homogeneous environments are recalled. Then, four main strategies aimed at counteracting the deleterious effect of heterogeneity are presented.

MOTS-CLÉS : filtrage, traitement spatio-temporel adaptatif, environnement hétérogène, algorithme à rang réduit, algorithme à apprentissage supervisé.

KEYWORDS: filtering, space-time adaptive processing, heterogeneous environment, reduced-rank algorithm, knowledge-aided algorithm.

DOI:10.3166/TS.28.81-112 © 2011 Lavoisier, Paris

Extended abstract

For airborne radar systems, detecting moving targets in an air-to-ground or an air-to-air mode is a challenging task. Indeed, the signal of interest received on the radar antenna (i.e., the target) is embedded in noise. The noise is mainly due to thermal noise, possibly jammers, and ground echoes that are referred to as clutter.

To detect the presence of a target, it is necessary to filter out the clutter from the received signal. For airborne radars, ground clutter is distributed in angle and in Doppler due to the motion of the platform. In other words, the clutter signal is correlated temporally from pulse to pulse and spatially between the antenna elements. To extract properly the target signal and maintain good detection performance, a space-time filtering turns out to be necessary.

The filter design relies then mostly on the knowledge of the noise present in the range cell under test: more specifically, it depends on the inverse of the noise covariance matrix. On one hand, the thermal noise is usually modeled with a good approximation by a white noise random process whose power is well known. On the other hand, the clutter component is not known precisely. It is thus necessary to estimate it so as to filter it afterwards. Usually, the noise covariance matrix is estimated in flight with a set of range cells called the training interval or the secondary data. This filtering is then referred to as a space-time adaptive processing (STAP).

The first adaptive detection algorithms have been developed under the assumption of a homogeneous environment where the clutter characteristics are independent of the range cell. Under such assumption, the sample covariance matrix (SCM) maximizes the signal-to-noise-plus-interference ratio (Brennan *et al.*, 1973) and is the maximum likelihood estimator of the noise covariance matrix (Reed *et al.*, 1974). Several detectors based on this estimator have also been derived as the Kelly's detector (Kelly, 1986).

Unfortunately, real world effects can compromise strongly the hypothesis of homogeneity and lead to a heterogeneous environment. Performance of classical detectors, which assume a homogenous environment, can then be severely degraded. This paper presents a review of STAP techniques that have been developed or used in heterogenous environment.

Firstly, the main causes that lead to non-homogeneous environment are recalled. Indeed, many phenomena can lead to a heterogenous environment: non-homogeneous ground reflectivity, presence of secondary targets in the training interval or in the cell under test, range dependence of the clutter frequencies in the angle-Doppler domain (referred to as a non-stationary clutter). Performance degradation of conventional detectors is illustrated for each type of heterogeneity with numerical simulations.

Then, four main strategies aimed at counteracting the deleterious effect of heterogeneity are described, and their performance is illustrated through numerical simulations.

A first strategy consists in using low sample support algorithms. The goal here is to decrease the presence of phenomena compromising the hypothesis of homogeneity.

Among these techniques, one can mention the diagonal loading, the reduced dimension algorithms, the reduced rank algorithms, and the algorithms based on the assumption of structured interferences. The fundamental drawback of these methods is that they do not intend to overcome directly the heterogeneity but try to reduce its presence in the training interval. In some cases, this strategy can even lead to emphasize the impact of heterogeneous samples (e.g., presence of targets in the training interval).

Another strategy is based on the selection of the secondary data. The goal here is to eliminate the range gates which may degrade the quality of the filter. Non-adaptive and adaptive techniques have been developed. The selection procedure can rely on simple criteria such as the range gate power, the power and the phase or use more complex metrics such as non-homogeneity detectors.

A third strategy consists in incorporating directly heterogeneity, via a model, in the detection scheme at the design phase. Some detectors allow, for instance, local clutter power fluctuations to be taken into account. Some estimation techniques also propose to make the clutter edge range-independent if required.

Finally, the use of prior knowledge may be a breakthrough in radar detection. Algorithms using prior information are then referred to as knowledge-aided or knowledge-based STAP. The strategy consists in using prior information provided by external databases (e.g. GPS, digital ground model) to assist and improve the detection. The amount of works found in the literature attests the recent interest in this area. Hence, the article finally closes on the description of a recent Bayesian KA-STAP algorithm that incorporates prior knowledge and an original model of heterogeneity.

To give more interest to the numerical simulations presented in this paper, most of them are performed with hybrid data provided by the French Department of Defense (Délégation Générale de l'Armement, Maîtrise de l'Information). These data are generated with real SAR (Synthetic Aperture Radar) images and merged with synthetic target signatures. More details about the hybrid data can be found in (Bidon *et al.*, 2011).

1. Introduction

Pour un système radar aéroporté, la détection de cibles en mouvement sur le sol ou dans l'air peut être une tâche ardue. L'écho du signal d'intérêt, c'est-à-dire la cible, est en effet noyé dans l'écho de sol (fouillis) et le bruit thermique du récepteur. Il peut s'ajouter à ceux-ci d'autres composantes indésirables comme, par exemple, des signaux brouilleurs dans un contexte militaire.

Afin de détecter la cible, il est nécessaire dans un premier temps de filtrer les composantes indésirables du signal reçu sur l'antenne du radar. Comme ceci a été exposé dans (Montécot *et al.*, 2011, Bidon, 2011), cette opération nécessite, de par la présence du fouillis de sol, d'être opérée dans un espace à deux dimensions que sont le temps et l'espace. La dimension du temps fait référence aux impulsions émises par le radar alors que la dimension de l'espace correspond aux voies spatiales de l'antenne radar.

Pour un grand nombre d'applications radar, le bruit thermique est bien représenté par un bruit aléatoire blanc spatialement et temporellement. De plus, la puissance de ce bruit est en pratique connue avec une bonne précision. Si la composante « bruit thermique » peut être bien maîtrisée par l'opérateur radar, il n'en est pas de même pour la composante « fouillis ». Ne pouvant être connue exactement par avance, il est ainsi nécessaire d'estimer celle-ci afin de pouvoir la filtrer par la suite. Classiquement, la matrice de covariance de la cellule sous test est ainsi estimée à partir d'un ensemble de cases distance adjacentes que l'on nomme intervalle d'entraînement.

Dans un milieu gaussien homogène, où les caractéristiques du fouillis sont indépendantes de la distance considérée, la matrice de covariance des échantillons (SCM, *Sample Covariance Matrix*) est celle qui maximise après filtrage le rapport signal sur bruit-plus-interférences (SINR) (Brennan *et al.*, 1973). Elle est également l'estimateur du maximum de vraisemblance (Reed *et al.*, 1974) de la matrice de covariance bruit-plus-interférences. Dans un scénario réel, l'hypothèse d'homogénéité est très souvent remise en cause. Autrement dit, les cases distance ne partagent plus nécessairement la même matrice de covariance que la cellule sous test. Les performances des schémas de détection basés sur l'estimateur SCM peuvent alors être fortement dégradées. Des schémas de détection alternatifs sont alors nécessaires.

Nous rappelons dans cet article les principaux types d'hétérogénéité et les phénomènes physiques qui y sont liés. Ensuite, quatre principales stratégies mises en œuvre classiquement en environnement hétérogène sont présentées.

2. Modèle de signal pour la détection en milieu homogène

Pour mieux comprendre les différentes causes d'hétérogénéité, nous rappelons d'abord brièvement dans cette section le modèle classique des signaux STAP relatif à un environnement gaussien homogène. La modélisation des signaux est détaillée dans (Bidon, 2011).

2.1. Modèle en milieu homogène : cas clairvoyant

On considère un radar aéroporté émettant une rafale de M impulsions de fréquence porteuse f_0 à la fréquence de répétition $1/T_r$. L'antenne radar est composée de N voies spatiales. Une fois le signal reçu et pré-traité (démodulation filtrage adapté distance et échantillonnage temporel), la détection s'opère classiquement case distance par case distance. Pour une cellule sous test donnée, le problème de détection consiste à décider si le vecteur de données reçues \mathbf{x} contient uniquement des composantes indésirables \mathbf{x}_u ou si une cible est également présente. Les deux hypothèses se formalisent respectivement par

$$\begin{aligned} H_0 \quad \mathbf{x} &= \mathbf{x}_u && \text{(absence de cible)} \\ H_1 \quad \mathbf{x} &= \alpha_t \mathbf{a}_t + \mathbf{x}_u && \text{(présence de cible)} \end{aligned} \quad [1]$$

où α_t et \mathbf{a}_t désigne respectivement l'amplitude et la signature spatio-temporelle de la cible sous test. La composante indésirable \mathbf{x}_u est modélisée à minima par la somme

de deux contributions aléatoires indépendantes centrées que sont le bruit thermique \mathbf{x}_n et le fouillis de sol \mathbf{x}_c . La matrice de covariance des signaux indésirables s'écrit donc

$$\mathbf{R} = \mathcal{E} \{ \mathbf{x}_u \mathbf{x}_u^H \} = \mathbf{R}_n + \mathbf{R}_c$$

où $\mathbf{R}_n = \mathcal{E} \{ \mathbf{x}_n \mathbf{x}_n^H \}$ et $\mathbf{R}_c = \mathcal{E} \{ \mathbf{x}_c \mathbf{x}_c^H \}$. Le bruit thermique étant modélisé par un bruit blanc, sa matrice de covariance s'exprime par

$$\mathbf{R}_n = \sigma^2 \mathbf{I}_{MN} \quad [2]$$

où σ^2 est la puissance du bruit et \mathbf{I}_{MN} est la matrice identité de taille NM . La matrice de covariance du fouillis de sol est construite via le principe de superposition. Plus précisément, l'écho de sol est vu comme la somme de N_p contributions élémentaires de sol indépendantes et équi-réparties en azimut à la distance ambiguë d'intérêt

$$\mathbf{R}_c = \mathcal{E} \{ \mathbf{x}_c \mathbf{x}_c^H \} = \sum_{p=1}^{N_p} P_p \{ \mathbf{\Gamma}_p \otimes \mathbf{I}_N \} \odot \{ \mathbf{a}_p \mathbf{a}_p^H \} \quad [3]$$

où P_p et \mathbf{a}_p représentent respectivement la puissance et la signature spatio-temporelle du p -ième élément de sol. La matrice $\mathbf{\Gamma}_p$ représente le phénomène de décorrélation de l'amplitude α_p du fouillis dû à son mouvement intrinsèque (ICM, *Intrinsic Clutter Motion*). Elle est définie comme suit

$$\mathbf{\Gamma}_p = \text{Toeplitz} \{ 1, \dots, \gamma_p(M-1) \} \quad \text{où} \quad \gamma_p(m) = \mathcal{E} \{ \alpha_p(m') \alpha_p^*(m' - m) \}.$$

L'ICM peut être modélisé par exemple par une loi gaussienne (Barlow, 1949) pour laquelle

$$\gamma_p(m) = \exp \left\{ -\frac{1}{2} \left(\frac{4\pi \sigma_{v,p} T_r}{\lambda_0} m \right)^2 \right\} \quad [4]$$

où $\sigma_{v,p}$ est l'écart-type de la vitesse pour l'élément de sol p et $\lambda_0 = c/f_0$ est la longueur d'onde du signal émis.

On rappelle que le filtre optimal, c'est-à-dire celui qui maximise après filtrage le SINR, s'exprime en fonction de la matrice de covariance \mathbf{R} par $\mathbf{w}_{opt} \propto \mathbf{R}^{-1} \mathbf{a}_t$ (Bidon, 2011).

2.2. Modèle en milieu homogène

En pratique, la matrice de covariance \mathbf{R} utile pour construire le filtre STAP n'est pas connue mais est estimée à partir de K données secondaires \mathbf{x}_k . Dans un environnement gaussien homogène où les données sont indépendantes et identiquement distribuées (iid), l'hypothèse binaire [1] de détection devient alors

$$\begin{aligned}
 H_0 & \begin{cases} \mathbf{x} & \sim \mathcal{CN}(\mathbf{0}, \mathbf{R}) \\ \mathbf{x}_k & \sim \mathcal{CN}(\mathbf{0}, \mathbf{R}) \quad k = 1, \dots, K \end{cases} \\
 H_1 & \begin{cases} \mathbf{x} & \sim \mathcal{CN}(\alpha_t \mathbf{a}_t, \mathbf{R}) \\ \mathbf{x}_k & \sim \mathcal{CN}(\mathbf{0}, \mathbf{R}) \quad k = 1, \dots, K \end{cases}
 \end{aligned}$$

où \mathcal{CN} désigne une distribution complexe gaussienne. Dans un tel milieu, l'estimateur SCM défini par

$$\mathbf{R}_{SCM} = \frac{1}{K} \mathbf{S} \quad \text{avec} \quad \mathbf{S} = \sum_{k=1}^K \mathbf{x}_k \mathbf{x}_k^H$$

est l'estimateur du maximum de vraisemblance de \mathbf{R} à partir des données \mathbf{x}_k qui maximise le SINR. Le filtrage STAP associé $\mathbf{w}_{SMI} \propto \hat{\mathbf{R}}_{SCM}^{-1} \mathbf{a}_t$ est dénommé algorithme SMI (*Sample Matrix Inversion*) (Reed *et al.*, 1974).

Également, le détecteur basé sur le principe du rapport de vraisemblance généralisé (GLRT, *Generalized Likelihood Ratio Test*) est le détecteur de Kelly (Kelly, 1986)

$$T_{Kelly}(\mathbf{x}) = \frac{|\mathbf{a}_t^H \mathbf{S}^{-1} \mathbf{x}|^2}{(\mathbf{a}_t^H \mathbf{S}^{-1} \mathbf{a}_t) (1 + \mathbf{x}^H \mathbf{S}^{-1} \mathbf{x})} \underset{H_0}{\overset{H_1}{\gtrless}} \eta_{Kelly} \tag{7}$$

pour lequel le seuil de détection η s'exprime aisément en fonction de la probabilité de fausse alarme (PFA) P_{fa}

$$\eta_{Kelly} = 1 - P_{fa}^{\frac{1}{K+1-MN}}. \tag{8}$$

Par la suite, l'estimateur [6] et le détecteur [7], développés tous deux pour un milieu homogène, nous serviront de point de référence pour illustrer les pertes de performance des traitements classiques STAP en milieu hétérogène.

3. Classification des types d'hétérogénéité

Dans cette section, trois types majeurs d'hétérogénéité sont présentés. Pour chacun d'entre eux, nous soulignons quelles hypothèses sont remises en cause par rapport au modèle gaussien homogène rappelé dans la section précédente. Nous illustrons également par des simulations simples les dégradations en performance dues à chaque type d'hétérogénéité. Les paramètres du scénario STAP sont définis par le scénario de la DGA-Maîtrise de l'Information (DGA/MI) présenté dans (Bidon *et al.*, 2011b). Nous utiliserons soit les données et matrices de covariance générées à partir du modèle classique STAP rappelé brièvement à la section 2, soit les données de la DGA/MI.

3.1. Hétérogénéité de réflexion du sol

3.1.1. Réflectivité

La puissance P_p de l'écho d'un élément de sol introduite dans [3] est, d'après l'équation du radar (Skolnik, 1970), proportionnelle à la réflectivité du sol. Il est

courant de prédire cette réflectivité par des modèles déterministes qui dépendent entre autres de l'élévation θ et du type d'environnement (urbain, forêt, etc.). Par exemple, il est courant de considérer un modèle dit « gamma constant » tel que

$$P_p \propto \gamma \sin(|\theta|)$$

où γ est une constante fonction de l'environnement (par exemple $\gamma = -3\text{dB}$). Ces modèles peuvent éventuellement être corrigés par des mesures expérimentales.

Un modèle déterministe peut ne pas être approprié dans des environnements où la réflectivité varie fortement. Il est alors plus réaliste de modéliser celle-ci comme une variable aléatoire. Ceci peut être le cas d'un radar à haute résolution distance. Dans (Nitzberg, 1990), (Armstrong *et al.*, 1993) et (Melvin, 2000), la puissance est plutôt modélisée par une variable aléatoire de loi Gamma contrôlée par un facteur d'étalement qui règle le degré d'hétérogénéité du milieu. Les études montrent que les dégradations de performance des traitements classiques peuvent être significatives en milieu très hétérogène.

3.1.2. Étalement spectral

Du fait du mouvement intrinsèque du fouillis, l'amplitude des éléments de sol se décorrèle d'impulsion à impulsion. Ceci provoque donc un étalement de la bande Doppler du fouillis contrôlé par le paramètre $\sigma_{v,p}$ introduit dans [3] et [4]. Une disparité en angle et/ou en distance de $\sigma_{v,p}$ dans le scénario observé correspond ainsi à un autre type d'hétérogénéité pour la réflexion du sol. Les études conduites dans (Armstrong *et al.*, 1993) et (Melvin, 2000) montrent en particulier qu'une sous-estimation de l'étalement spectral conduit à de fortes pertes en SINR.

3.1.3. Effet de transition

L'hétérogénéité peut être également causée par une variation brutale en distance de la nature du fouillis (amplitude et/ou étalement spectral). Les études conduites dans (Armstrong *et al.*, 1993), (Cai *et al.*, 1994) et (Melvin, 2000) montrent que, en présence de transition brutale de la nature du fouillis, l'amplitude et/ou l'étalement spectral peuvent être mal estimés, ce qui conduit à une dégradation de performances des traitements classiques.

3.1.4. Illustration

Pour illustrer le problème d'hétérogénéité dû à un effet de transition, on s'intéresse aux pertes en SINR asymptotiques (par rapport au cas clairvoyant sans fouillis) pour un scénario comportant deux régions dans le domaine d'entraînement :

- dans la première région, il n'y a pas de mouvement intrinsèque du fouillis $\sigma_v = 0$ m/s ;
- dans la seconde région, on observe un étalement spectral égal à $\sigma_v = 0,15$ m/s.

\mathbf{R}_1 et \mathbf{R}_2 dénotent les matrices de covariance respectives de ces deux régions. Nous construisons à partir de cet intervalle d'entraînement le filtre STAP utilisant la matrice SCM [6] asymptotique définie comme

$$\mathcal{E} \left\{ \hat{\mathbf{R}}_{SCM} \right\} = \frac{1}{2} [\mathbf{R}_1 + \mathbf{R}_2] \quad [9]$$

où nous avons supposé qu'il y a autant de données d'entraînement dans les deux régions. On suppose que la cellule sous test a pour matrice de covariance $\mathbf{R} = \mathbf{R}_1$. Les données secondaires relatives à la région 2 sur-estiment ainsi l'étalement spectral.

On considère un premier scénario où les rapports fouillis-à-bruit définis par

$$CNR_i = \frac{\text{tr}\{\mathbf{R}_{c,i}\}}{\text{tr}\{\mathbf{R}_n\}} \quad i = 1,2$$

sont identiques pour les deux régions et égaux à $CNR_1 = CNR_2 = 24$ dB. Dans un second scénario, les rapports fouillis-à-bruit sont choisis tels que $CNR_1 = 24$ dB et $CNR_2 = 40$ dB. Autrement dit, les données de la région 2 sur-estiment la puissance du fouillis. Les résultats sont présentés sur la figure 1. On observe que la région 2 du domaine d'entraînement contribue à élargir le filtre STAP autour de la fréquence de coupure du fouillis. En effet, la région 2 suppose que le fouillis occupe une bande spectrale Doppler plus large que la région 1. Les pertes en SINR de l'estimateur [9] sont d'autant plus prononcées dans le second scénario où la puissance du fouillis est de surcroît mal estimée.

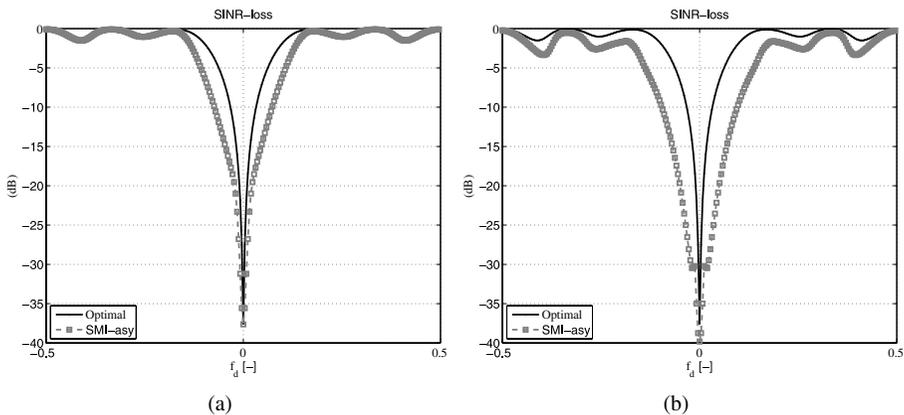


Figure 1. Pertes en SINR asymptotique dans un scénario avec transition brutale de la nature du fouillis. (a) Sur-estimation de l'étalement spectral, $CNR_1 = CNR_2 = 24$ dB. (b) Sur-estimation de l'étalement spectral et de l'amplitude, $CNR_1 = 24$ dB, $CNR_2 = 40$ dB.

3.2. Présence de cibles secondaires

3.2.1. Principe

La présence de cibles « secondaires » constitue une autre grande classe d'hétérogénéité. Ces cibles secondaires peuvent être situées dans les données d'entraînement ou peuvent appartenir à la case distance sous-test. Dans les deux cas, la présence de telles cibles vient remettre en cause l'hypothèse binaire [1].

Dans le cas d'une contamination des données secondaires, les performances des traitements sont d'autant plus dégradées que les cibles secondaires sont proches en angle de la cible de la cellule sous test (Borson, 1980), (Cai *et al.*, 1994), (Gerlach, 1995), (Melvin, 2000). Dans le cas d'une contamination de la donnée primaire, les performances de détection peuvent être également fortement dégradées (Klemm, 2004, Chapitre 10).

3.2.2. Illustration

3.2.2.1. Données synthétiques issues du modèle classique STAP

Pour illustrer ce type d'hétérogénéité, nous considérons un scénario pour lequel une seule cellule d'entraînement est contaminée par une cible secondaire de fréquence Doppler $f_{d,t} = 0,27^1$. Le rapport signal contaminant à bruit défini par

$$SNR_{cont} = \frac{P_{cont} \mathbf{a}_{cont}^H \mathbf{a}_{cont}}{\text{tr}\{\mathbf{R}_n\}} \quad [10]$$

est choisi égal à 20 dB. Dans [10], P_{cont} et \mathbf{a}_{cont} désignent respectivement la puissance et le vecteur de pointage spatio-temporel de la cible secondaire. Les pertes en SINR sont représentées sur la figure 2 pour l'algorithme SMI avec $K = 2NM$ données secondaires. Les pertes asymptotiques obtenues avec la matrice

$$\mathcal{E}\{\hat{\mathbf{R}}_{SCM}\} = \mathbf{R}_n + \mathbf{R}_c + \frac{1}{K} P_{cont} \mathbf{a}_{cont} \mathbf{a}_{cont}^H \quad [11]$$

sont également montrées. On observe ainsi de fortes pertes pour l'algorithme classique SMI pour une cible sous test dont la vitesse est proche de celle de la cible secondaire. En effet, lors de l'entraînement le filtre STAP apprend à couper les signaux présents à cette fréquence Doppler.

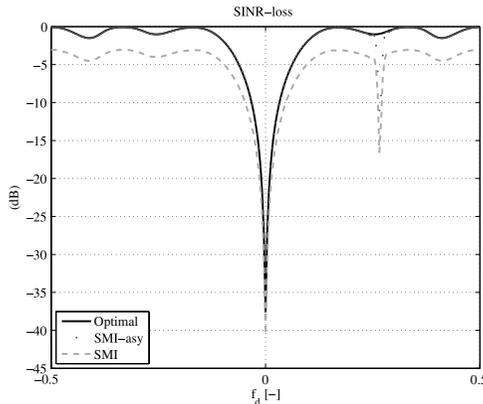


Figure 2. Pertes en SINR dans un scénario avec une cible secondaire dans l'intervalle d'entraînement

1. Le cas d'une contamination de la cellule sous test sera illustrée plus loin dans la section 4.1.5.

3.2.2.2. Données de la DGA-Maîtrise de l'information

On observe le même type de comportement en s'intéressant cette fois-ci aux signaux mis à la disposition du club STAP par la DGA/MI (Bidon *et al.*, 2011b). Nous présentons ici les cartes de détection obtenus grâce au détecteur de Kelly [7]. On s'intéresse en particulier à la rafale 4 de l'essai 1 obtenu grâce à un fond d'image SAR (*Synthetic Aperture Radar*) synthétique de type « mire gaussienne ». L'essai est décrit plus précisément dans (Bidon *et al.*, 2011b). Dans ce jeu de données, trois cibles de même puissance sont présentes et ont respectivement pour cases distance et vitesses

$$\ell_1 = 216, v_1 = 4 \text{ m/s}$$

$$\ell_2 = 256, v_2 = 4 \text{ m/s}$$

$$\ell_3 = 296, v_3 = -4 \text{ m/s.}$$

La puissance reçue sur la rafale d'intérêt est représentée en fonction de la distance sur la figure 3. On y retrouve clairement les cibles qui sont de forte puissance.

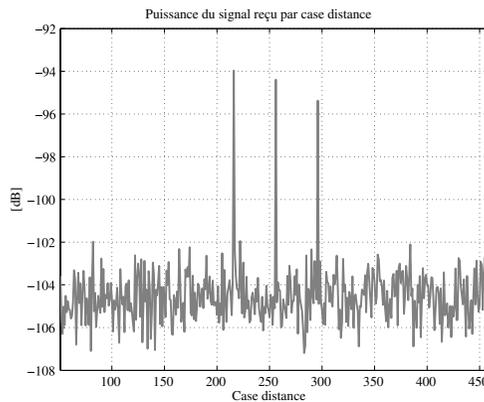


Figure 3. Puissance reçue pour une rafale en fonction de la distance

La cellule sous test considérée ici est la case distance 256. Un nombre d'environ $K \approx 1,6NM$ données secondaires sont à disposition. Nous considérons deux intervalles d'entraînement.

- Pour le premier intervalle, toutes les cases distance à disposition sont prises à l'exception de la cellule sous test et de deux cellules de garde de part et d'autre de celle-ci.

- Le second intervalle est construit à partir du premier en rejetant en plus la case distance 216.

On représente sur la figure 4 la statistique de test du détecteur de Kelly $T_{Kelly}(\mathbf{x}(256))$ que l'on compare au seuil $\eta_{Kelly} = -12,2 \text{ dB}$, ce qui correspond d'après [8] à une fausse alarme égale à $P_{fa} = 10^{-4}$. On observe sur la figure 4(a) que les points de la carte de détection sont tous en dessous du seuil de détection. Ainsi,

lorsque le domaine d'entraînement contient une cible de même fréquence Doppler que celle de la cible contenue dans la cellule sous test, celle-ci peut ne pas être détectée. En revanche, lorsque la cellule 216 est retirée des données d'entraînement, la cible présente à 4 m/s soit $f_{d,t} = 0,27$ est détectée sans problème à la case 256 comme représenté sur la figure 4(b). De plus, aucune fausse alarme n'apparaît dans cette cellule. Notons que, pour cet intervalle d'entraînement, la cible secondaire à -4 m/s présente à la case distance 296 n'est pas alignée avec la signature de la cible d'intérêt et ne perturbe ainsi donc pas la détection de cette dernière comme le prévoit la théorie (Gerlach, 1995).

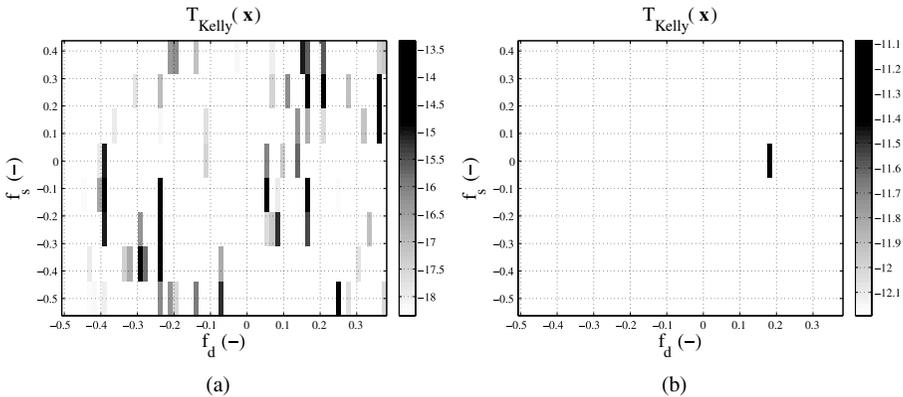


Figure 4. Statistique de test de Kelly pour la case distance numéro 256.
 (a) Données d'entraînement contenant les deux cellules contaminées 216 et 296.
 (b) Données d'entraînement contenant une seule cellule contaminée 296

3.3. Non-stationnarité du fouillis

La troisième grande classe d'hétérogénéité correspond à la variation du lieu du fouillis dans l'espace angle-Doppler en fonction de la distance. On appelle ce type d'hétérogénéité la non-stationnarité du fouillis. Ce phénomène est lié à la configuration géométrique du scénario. Pour un radar aéroporté mono-statique, nous avons vu dans (Bidon, 2011) que le lieu du fouillis de sol pour une visée latérale pure est représenté par une droite dont la pente est invariante avec la distance². En pratique, l'avion peut avoir un angle de dérive (la direction du fuselage est désalignée avec le vecteur vitesse, c'est-à-dire $\phi_a \neq 0$), ce qui entraîne une modification du lieu du fouillis en une ellipse dont la taille dépend de la case distance considérée. La non-stationnarité est maximale lorsque l'antenne est disposée cette fois-ci dans la pointe avant de l'avion, ceci correspond à un angle $\phi_a = -\pi/2$.

Pour illustrer le problème de non-stationnarité du fouillis, nous considérons les deux cas limites $\phi_a = 0$ et $\phi_a = -\pi/2$. Les données sont générées ici suivant le

1. On rappelle que dans ce cas l'angle ϕ_a entre la direction d'alignement des éléments d'antenne et le vecteur vitesse est nul.

modèle classique STAP rappelé dans (Bidon, 2011) et les paramètres du scénario sont ceux de la DGA/MI à l'exception de la distance d'intérêt qui est ici égale à 10 km. Les pertes en SINR optimales sont représentées aux figures 5(a) et 5(c) pour les deux configurations autour de la distance 10 km. Comme attendu, dans le cas d'une visée latérale $\phi_a = 0$, le lieu du fouillis ne varie pas avec la distance. En revanche, pour une visée frontale $\phi_a = -\pi/2$, le lieu du fouillis varie fortement avec la distance. Le filtrage STAP est opéré ici dans une structure EFA (*Extended Factored Algorithm*) (Dipietro, 1992) pour laquelle on choisit de réaliser l'adaptation sur $M' = 3$ cases Doppler. Les pertes en SINR de l'EFA obtenues avec la matrice SCM sont observées pour $K = NM' = 24$ données secondaires et comparées à celles obtenues avec la matrice exacte (cas clairvoyant). La cellule sous test considérée est la case 14. Les données d'entraînement sont prises de part et d'autre de cette cellule avec une case de garde. Dans le cas d'un fouillis stationnaire en distance $\phi_a = 0$, les pertes en SINR pour la SCM sont à 3dB de l'optimal comme le prédit la loi de Reed, Mallett et Brennan (Reed *et al.*, 1974). En revanche, les pertes sont bien plus importantes lorsque le fouillis est non stationnaire. En particulier, le filtre s'élargit largement autour de la fréquence Doppler du lobe principal du fouillis. En effet, le filtre basé sur la SCM apprend à couper toutes les fréquences Doppler du fouillis présentes sur l'intervalle d'entraînement.

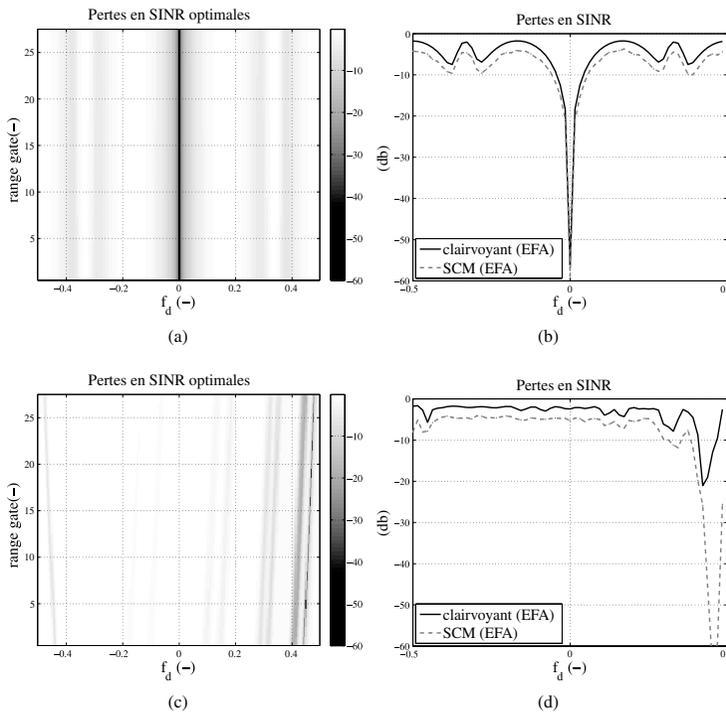


Figure 5. Non-stationnarité du fouillis. (a) Pertes en SINR optimal pour un radar en visée latérale $\phi_a = 0$. (b) Pertes en SINR pour la case 14 pour un radar en visée latérale $\phi_a = 0$. (c) Pertes en SINR optimal pour un radar en visée frontale $\phi_a = -\pi/2$. (d) Pertes en SINR pour la case 14 pour un radar en visée frontale $\phi_a = -\pi/2$

4. Stratégies de traitement en environnement non homogène

Nous avons vu dans la section précédente que les performances des schémas d'estimation et de détection classiques sont dégradées en présence d'hétérogénéité(s). Nous présentons ici les principales stratégies qui peuvent être adoptées pour contrer ces effets néfastes.

4.1. Algorithmes à faible support d'entraînement

Une première stratégie pour lutter contre l'hétérogénéité est d'utiliser des algorithmes nécessitant peu de données secondaires. En effet, parmi l'ensemble des $L \approx BT_r$ cases distance disponibles dans un cube de données, il est probable qu'un grand nombre ne soit pas homogène avec la case distance sous test (présence de cibles secondaires, non-homogénéité de réflexion du sol, non-stationnarité du fouillis). Dans un mode à haute fréquence de répétition le nombre de cases distance L existantes peut même être inférieur à la dimension NM du filtre STAP. Il est donc intéressant d'utiliser des algorithmes à faible support d'entraînement. Parmi les techniques développées, on compte les algorithmes à dimension réduite, les algorithmes à rang réduit, le *diagonal loading* et enfin les techniques qui supposent une structure sur les interférences. À la limite, on peut également envisager des traitements n'utilisant pas de données secondaires (Savy *et al.*, 2011).

4.1.1. Algorithmes à dimension réduite

Les algorithmes à dimension réduite consistent à transformer le problème de filtrage de grande dimension NM en plusieurs problèmes de filtrage sur une dimension plus petite. Pour ceci, une série de transformations fixes (qui ne dépendent pas des données) est appliquée sur les vecteurs des données primaire et secondaires. En sortie, la taille des vecteurs étant réduite, l'adaptation s'effectue sur un espace plus petit. Le nombre de données secondaires nécessaires pour estimer correctement la matrice de covariance est donc diminué. Bien évidemment, la nouvelle dimension de l'espace sur lequel s'opère le filtrage ne doit pas être trop petite. Le filtre doit en effet avoir assez de degrés de liberté pour rejeter le fouillis tout en maintenant un gain sur la cible sous test. Les principaux algorithmes à dimension réduite sont présentés dans (Ward, 1994) ; pour ceux-ci :

- soit l'adaptation a lieu sur l'ensemble des voies de réception de l'antenne mais sur un nombre réduit d'impulsions ou de cases Doppler ; on parle respectivement des algorithmes *element-space pre-Doppler* et *element-space post-Doppler* (par exemple l'EFA (Dipietro, 1992)),

- soit l'adaptation a lieu sur quelques faisceaux spatiaux ; on recense deux types d'algorithmes : le *beam-space pre-Doppler* et *beam-space post-Doppler* (par exemple le JDL, *Joint Domain Localized algorithm* (Wang *et al.*, 1994)).

Ces algorithmes contiennent tous un filtrage Doppler ainsi qu'une transformée de réduction de dimension. Si le traitement Doppler a lieu après l'adaptation on parle de traitement *pre-Doppler*, autrement on parle de traitement *post-Doppler*.

4.1.2. Algorithmes à rang réduit

Les techniques à rang réduit ne sont pas spécifiques au domaine du STAP mais y sont particulièrement adaptées. Elles peuvent être appliquées dans tout problème de filtrage linéaire multidimensionnel pour lequel la matrice de covariance des signaux non-désirés se décompose en la somme d'une matrice proportionnelle à l'identité (partie blanche du signal) et d'une matrice hermitienne de faible rang r (partie colorée du signal). Les méthodes à rang réduit permettent de réaliser l'étape d'adaptation sur un espace de dimension réduite obtenu après une transformation adaptative sur les données. Ainsi, on peut espérer par exemple réduire le domaine d'entraînement d'une taille égale à $2NM$ à une taille égale à $2r$ pour obtenir des pertes en SINR à 3dB du filtrage optimal.

Parmi les techniques à rang réduit, citons en premier lieu la méthode PC (*Principal Component*) (Kirsteins *et al.*, 1994), (Haimovich, 1996) qui est basée sur la sélection des r vecteurs propres principaux de la matrice de covariance empirique. Une autre technique est la méthode CSM (*Cross Spectral Metric*) (Berger *et al.*, 1999), (Goldstein *et al.*, 1997). Celle-ci cherche plutôt à sélectionner les r vecteurs propres de la matrice de covariance empirique qui maximisent le SINR. Une troisième méthode est le MWF tronqué (*Multistage Wiener Filter*) (Goldstein *et al.*, 1998). Elle consiste à trouver une base qui permet une représentation la plus compacte possible du signal. On peut citer les articles (Kirsteins *et al.*, 1994), (Goldstein *et al.*, 1997) et (Ayoub *et al.*, 2000) où les performances en détection de ces algorithmes à rang réduit ont été étudiées. Enfin, récemment, une technique rang réduit permettant de prendre en compte la non-stationnarité du fouillis a été proposée dans la littérature et est rappelée dans (Marcos *et al.*, 2011). Notons dans tous les cas que, pour une application au STAP, la connaissance du rang r de la matrice de covariance du fouillis est un point dur : la règle de Brennan rappelée dans (Bidon, 2011) et donnant le rang du fouillis ne prend en effet pas en compte de nombreux phénomènes qui peuvent conduire à une augmentation de celui-ci.

4.1.3. Le diagonal loading

Tout comme les algorithmes à rang réduit, la méthode du *diagonal loading* (DL) n'est pas spécifique au domaine du STAP mais y est particulièrement adaptée. Elle s'appuie également sur les propriétés de faible rang du fouillis et permet ainsi de diminuer le domaine d'entraînement (Abramovich *et al.*, 1981). La méthode DL consiste à ajouter à l'estimée de la matrice de covariance \mathbf{R} une surcharge σ_{DL}^2 sur la diagonale telle que

$$\hat{\mathbf{R}}_{DL} = \hat{\mathbf{R}}_{SCM} + \sigma_{DL}^2 \mathbf{I}.$$

Le DL accélère la convergence de l'estimation et stabilise les lobes secondaires du filtre adaptatif (Carlson, 1988). De nouveaux détecteurs basés sur la technique DL (Ayoub *et al.*, 2000) permettent d'obtenir de meilleures performances que le détecteur de Kelly [7]. Le choix du niveau de surcharge σ_{DL}^2 reste en revanche un point délicat.

4.1.4. Interférences structurées

Enfin, pour diminuer la taille du domaine d'entraînement, certaines techniques d'estimation imposent une structure sur les interférences. Le nombre de coefficients à estimer pour construire le filtre STAP est alors réduit ce qui permet de diminuer le nombre de données secondaires.

Parmi les techniques développées, une première approche consiste à imposer une structure sur la matrice de covariance à estimer.

Par exemple, dans (Steiner *et al.*, 2000), l'estimateur est contraint à être décrit comme la somme d'une matrice inconnue hermitienne semi-définie positive et de la matrice identité.

Une autre technique consiste à imposer une structure Toeplitz par bloc (cas d'une période de répétition T_r constante) ou Toeplitz (cas d'une antenne radar linéaire uniforme). De nouveaux schémas d'estimation sont proposés ainsi dans (Burg *et al.*, 1982 ; Fuhrmann, 1991 ; Barton *et al.*, 1997), et dans (Fante *et al.*, 1994 ; Pillai *et al.*, 2000) où la technique FBS (*Forward/backward Smoothing*) est décrite. Si l'estimation peut être améliorée via une structure de type Toeplitz, il faut en revanche veiller à ce que certains phénomènes (par exemple les multitrajets) ne viennent pas corrompre l'hypothèse de structure imposée sur la matrice de covariance.

De manière analogue, les propriétés de persymétrie (symétrie par rapport à l'anti-diagonale) peuvent être utilisées pour construire de nouveaux estimateurs de la matrice de covariance (Pailloux *et al.*, n.d. ; Ovarlez *et al.*, 2011 ; Ginolhac *et al.*, 2011).

Enfin, citons les méthodes paramétriques basées sur un modèle auto-régressif (AR). Le modèle AR suppose que le signal reçu à l'impulsion m sur les N voies spatiales de l'antenne peut s'exprimer comme une combinaison linéaire des $P < M$ impulsions précédentes. Les méthodes PAMF (*Parametric Adaptive Matched Filter*) (Román *et al.*, 2000), STAR (*Space-Time Autoregressive*) (Parker *et al.*, 2003) et la méthode AR de (Klemm, 2004, Chapitre 2) découlent de ce principe. Des études plus approfondies sur le PAMF et le STAR sont disponibles dans (Russ *et al.*, 2004). Récemment, une méthode originale pour estimer les coefficients AR grâce à un filtrage de Kalman a été proposée dans (Petitjean *et al.*, 2011).

4.1.5. Illustration

Nous illustrons l'intérêt des algorithmes à faible support d'entraînement sur les données fournies par la DGA/MI pour l'algorithme à dimension réduite EFA (Dipietro, 1992). L'EFA réalise l'adaptation dans le domaine espace-Doppler en sélectionnant quelques cases Doppler uniquement ; l'algorithme est rappelé dans (Bidon, 2011).

Le cube de données considéré correspond à la rafale 1 de l'essai 6 ; celui-ci est décrit plus précisément dans (Bidon *et al.*, 2011b). On rappelle que dix cibles sont présentes dans le cube de données à la case distance 256 et ont respectivement pour vitesses -5,-4,-3,-2,-1,1,2,3,4,5 m/s. On compare alors les statistiques de test du détecteur de Kelly sans réduction de dimension ainsi qu'à la sortie d'un filtrage de type EFA pour lequel on choisit $M' = 3$ cases Doppler pour réaliser le filtrage STAP. Le nombre de données secondaires est pour la pleine dimension égale à $K = 408$ et

pour l'EFA $K = 48$. La PFA est fixée à $P_{fa} = 10^{-4}$, ce qui correspond respectivement à un seuil $\eta_{Kelly} = -12,2$ dB et $\eta_{Kelly} = -6,6$ dB. Les résultats sont présentés sur la figure 6.

En pleine dimension, le test d'hypothèses [1] est remis en cause par la présence de cibles secondaires dans la case sous test. Aucune des dix cibles n'est détectée et une fausse détection a lieu à la fréquence Doppler (f_d, f_s) $\approx (-0,38; -0,5)$. Dans une structure EFA, au contraire, un filtrage Doppler s'opère avant l'adaptation. Cette étape permet de localiser dans un premier temps les cibles suivant leur vitesse. En sélectionnant quelques cases Doppler autour de la fréquence Doppler sous test, on se ramène alors au test d'hypothèses [1] pour lequel une seule cible réside dans la cellule sous test. Notons que pour respecter au mieux cette hypothèse, une fenêtre d'apodisation de type Chebyshev avec une atténuation de 60 dB des lobes secondaires a été choisie pour appliquer la FFT (*Fast Fourier Transform*) sur chacune des voies spatiales de l'antenne (première étape de l'algorithme EFA).

Ainsi, en plus de diminuer le nombre de données secondaires nécessaires pour l'étape d'entraînement, l'EFA a l'avantage d'être robuste à la présence de cibles secondaires présentes dans la cellule sous test.

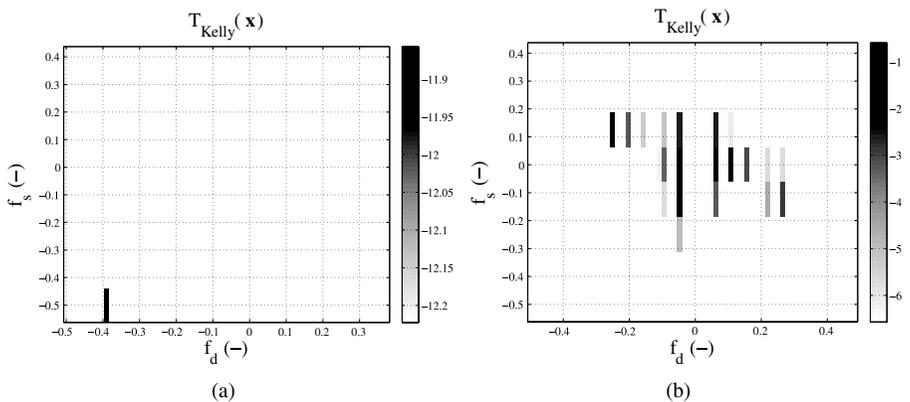


Figure 6. Statistique de test du détecteur de Kelly pour un cas multicibles. (a) Détection sur la pleine dimension NM . (b) Détection dans une structure EFA sur la dimension $NM \ll NM$

4.2. Sélection des données secondaires

Une autre approche pour lutter contre l'hétérogénéité consiste à sélectionner avec soin les données d'entraînement. Plusieurs techniques ont vu le jour.

Les premières techniques proposées sont des méthodes non-adaptatives, c'est-à-dire qui ne dépendent pas des données reçues. On compte parmi elles le *local training* et l'*overnulling* (Borsari *et al.*, 1995). La première méthode consiste à sélectionner les cases distance adjacentes à la case sous test. De plus, pour s'assurer que la cible sous test n'est pas présente dans l'intervalle d'entraînement, quelques cases de garde sont prises de part et d'autre de la cellule sous test. La seconde

méthode consiste à sélectionner plutôt les cases distance correspondant aux régions où l'équation du radar prédit les plus fortes puissances de fouillis.

Bien évidemment, dans de nombreux cas de telles méthodes ne sont pas adaptées et des techniques adaptatives ont alors plutôt été proposées. Celles-ci reposent essentiellement sur des critères de puissance et de phase ou sur des métriques plus complexes que sont les détecteurs de non-homogénéité (NHD, *Non-Homogeneity Detector*).

Dans (Rabideau *et al.*, 1999), les auteurs proposent la méthode PST (*Power Selected Training*), qui consiste à calculer le niveau de puissance par case distance non plus à partir de l'équation du radar mais à partir du signal effectivement reçu. Les techniques PSD (*Power Selected Deemphasis*) et PDE (*Projection Deemphasis*) y sont également proposées. Elles consistent à introduire dans l'estimée de la matrice de covariance \mathbf{R} une partie du signal de la cellule sous test. Le fouillis de la cellule sous test est ainsi réellement pris en compte dans la matrice estimée. Notons que dans (Kogon, 2004), une version améliorée de la méthode PST est proposée et intègre également un critère de phase qui a démontré son utilité sur données réelles.

Les NHD sont des techniques plus complexes que les méthodes pré-citées et consistent à identifier les données hétérogènes par rapport à un jeu de données supposées homogènes entre elles. Parmi elles, on peut citer essentiellement le GIP (*Generalized Inner Product*) (Chen *et al.*, 1999) (Melvin, 1998) (Adve *et al.*, 1999) et l'APR (*Adaptive Power Residue*) (Gerlach *et al.*, 2004). Ces deux métriques sont données respectivement par

$$\text{GIP} : \mathbf{x}_{k'}^H \mathbf{S}^{-1} \mathbf{x}_{k'}$$

$$\text{APR} : |\mathbf{a}_t^H \mathbf{S}^{-1} \mathbf{x}_{k'}|^2$$

où $\mathbf{x}_{k'}$ est la donnée qui est comparée à un jeu de données secondaires (supposées homogènes entre elles) à partir duquel la SCM \mathbf{S} est construite. L'avantage de la mesure APR est qu'elle prend en compte la signature de la cible sous test \mathbf{a}_t et a donc tendance à moins rejeter les cellules contaminées par des cibles, dont la signature est désalignée avec celle sous test, et s'avèrent donc non perturbantes.

4.3. Intégration d'un modèle d'hétérogénéité dans le design du détecteur

Une troisième stratégie pour lutter contre l'hétérogénéité est de prendre en compte celle-ci à l'étape même du design du détecteur. Deux techniques essentiellement peuvent être envisagées. En premier lieu, l'hypothèse binaire [5] peut être modifiée afin de modéliser au mieux l'environnement et ainsi obtenir une statistique de test $T(\mathbf{x})$ plus pertinente. En second lieu, on peut plutôt considérer une étape de pré-traitement sur les données qui permette de se ramener à un milieu homogène [5]. On présente ci-après quelques exemples illustrant ces deux approches.

4.3.1. Modification du modèle des données

4.3.1.1. Variation de la puissance

La puissance du signal reçu peut varier en fonction de la distance. Il existe dans la littérature essentiellement deux modèles permettant de prendre en compte une telle variation.

Le premier modèle est le milieu partiellement homogène pour lequel il existe un facteur γ constant et inconnu entre la matrice de covariance des données primaire et secondaires. Le modèle [5] est modifié ainsi par la relation

$$\mathcal{E} \{ \mathbf{x}_k \mathbf{x}_k^H \} = \gamma \mathcal{E} \{ \mathbf{x} \mathbf{x}^H | H_0 \} = \gamma \mathbf{R}.$$

Le détecteur ACE (*Adaptive Coherent Estimator*) correspond au GLRT de ce modèle et s'exprime par (Scharf *et al.*, 1996)

$$T_{ACE}(\mathbf{x}) = \frac{|\mathbf{a}_t^H \mathbf{S}^{-1} \mathbf{x}|^2}{(\mathbf{a}_t^H \mathbf{S}^{-1} \mathbf{a}_t) (\mathbf{x}^H \mathbf{S}^{-1} \mathbf{x})} \underset{H_0}{\overset{H_1}{\geq}} \eta_{ACE}. \quad [12]$$

L'ACE [12] est CFAR (*Constant False Alarm Rate*) par rapport à la matrice de covariance \mathbf{R} et le facteur γ . L'ACE est de plus très intéressant de par son invariance au changement de puissance de la cellule sous test et/ou des données secondaires. Plus précisément, la statistique $T_{ACE}(\mathbf{x})$ correspond à une mesure d'angle entre la donnée primaire et la cible sous test après blanchiment par la matrice de covariance des échantillons \mathbf{S} . Les performances de l'ACE ont été étudiées dans (Mcworther *et al.*, 1996), (Richmond, 2000), (McDonald *et al.*, 2000), (Kraut *et al.*, 2001) et (Kraut *et al.*, 2005). L'ACE est remarquable car il est le GLRT pour de nombreux autres types d'environnement (Besson, 2007), (Bidon *et al.*, 2008c).

Le second modèle permet de rendre compte des variations de puissance du fouillis plus impulsives. Ceci peut être le cas par exemple pour des radars hautement résolus en distance. Plus précisément, le modèle en question est un bruit composé SIRV (*Spherically Invariant Random Vectors*) qui se définit comme un processus gaussien dont la puissance ou texture est aléatoire. À partir de ce modèle, de nouveaux estimateurs et détecteurs ont été proposés dans la littérature (Sangston *et al.*, 1994 ; Conte *et al.*, 1995 ; Conte *et al.*, 1996 ; Conte *et al.*, 1998 ; Pascal, 2006) et (Ginolhac *et al.*, 2011 ; Ovarlez *et al.*, 2011). Ceux-ci permettent entre autres de réduire les fausses alarmes observées avec des détecteurs classiques.

4.3.1.2. Variation de la structure des interférences

Le modèle des données peut également intégrer de l'hétérogénéité due à la variation du lieu du fouillis en distance. Ainsi, citons par exemple la technique DBU (*Derivative Based Updating*) proposée dans (Hayward, 1996). Celle-ci contraint le modèle de données en imposant au filtre STAP de varier de manière linéaire en fonction de la case distance, c'est-à-dire

$$\mathbf{w}_k = \mathbf{w}_0 + k \Delta \mathbf{w}_0. \quad [13]$$

La relation [13] impose une relation implicite entre les matrices \mathbf{R}_k . Cette technique s'avère efficace sur un fouillis dont le lieu varie de manière « continue » en distance (Klemm, 2002), (Guerci, 2003), (Ayoub *et al.*, 1999), (Parker *et al.*, 2003). À titre d'exemple, le fouillis observé sur la figure 5(c) correspond à une telle variation continue.

4.3.2. Pré-traitement pour se ramener à un milieu homogène

Comme souligné plus haut, plutôt que de modifier le modèle des données, on peut tenter de se ramener à un jeu de données homogènes. Ceci est envisageable par exemple dans le cas d'un fouillis non stationnaire en distance (voir section 3.3). Plus précisément, en connaissant la géométrie du problème, il est possible de prédire le lieu du fouillis en fonction de la distance. Diverses techniques de pré-compensation ont ainsi été proposées. Celles-ci visent à rendre le milieu homogène en rendant le lieu du fouillis indépendant de la distance. On peut citer par exemple la technique du *Doppler warping* (Borsari, 1998) et la méthode de compensation de (Kreyenkamp *et al.*, 2001) qui compensent la variation de la fréquence Doppler du fouillis reçu dans le lobe principal de l'antenne. Une version améliorée décrite dans (Pearson *et al.*, 2001) permet elle de compenser cette variation pour les lobes secondaires également. De nombreuses variantes de ces techniques peuvent être trouvées dans (Friedlander, 2000), (Lapierre *et al.*, 2003), (Melvin *et al.*, 2003), (Varadarajan *et al.*, 2006).

4.4. Algorithme à apprentissage supervisé

Enfin, l'une des stratégies les plus prometteuses pour lutter contre l'hétérogénéité est l'utilisation de données *a priori*. Les traitements basés sur cette philosophie sont répertoriés sous le nom de KA-STAP (*Knowledge-Aided*). Les données *a priori* peuvent provenir, par exemple, de cartes numériques de terrain, de données inertielles et/ou GPS sur la plateforme, ou de signaux reçus sur des rafales ultérieures. Il est envisageable d'utiliser ces données *a priori* de plusieurs manières (Guerci *et al.*, 2006 ; Melvin *et al.*, 2006a) : elles peuvent, par exemple, aider à sélectionner l'intervalle d'entraînement (Capraro *et al.*, 2006), (Conte *et al.*, 2006) ou, plus directement, à construire le filtre STAP. Concernant ce dernier point, l'information *a priori* est généralement utilisée pour construire une matrice de covariance *a priori* que nous noterons $\overline{\mathbf{R}}$. Plus précisément, la structure de la matrice est fixée par le modèle classique STAP [2], [3] alors que les paramètres de $\overline{\mathbf{R}}$ sont assignés par des valeurs obtenues grâce, entre autres, aux données *a priori*. Une fois cette matrice construite, il reste à l'intégrer dans le schéma de détection.

Pour ceci, on recense dans la littérature l'estimation FML (*Fast Maximum Likelihood*) (Gerlach *et al.*, 2003), l'estimation paramétrique KA (Melvin *et al.*, 2006b), la technique du *Colored Loading* (CL), et enfin des techniques d'estimation Bayésienne (DeMaio *et al.*, 2006 ; DeMaio *et al.*, 2007 ; Besson *et al.*, 2007 ; Bidon *et al.*, 2008a ; Besson *et al.*, 2008 ; Bidon *et al.*, 2011a). La technique CL est une extension de la méthode DL rappelée à la section 4.1.3. Plus spécifiquement, l'estimateur de la matrice de covariance est exprimé comme la combinaison linéaire de la matrice SCM et de la matrice *a priori* (Hiemstra, 2002 ; Teixeira *et al.*, 2003 ; Bergin *et al.*, 2004 ; Page *et al.*, 2004 ; Blunt *et al.*, 2006 ; Zhu *et al.*, 2007 ; Stoica *et al.*, 2008 ; Besson *et al.*, 2008), soit

$$\hat{\mathbf{R}}_{CL} = w\hat{\mathbf{R}}_{SCM} + \overline{\mathbf{R}}. \quad [14]$$

La méthode CL peut être implémentée en deux étapes : une étape de blanchiment réalisée par la matrice *a priori* suivie d'une étape adaptative (Bergin *et al.*, 2003). Il

est intéressant de noter que l'estimateur CL [14] s'avère être la solution à divers problèmes d'estimation. Par exemple, cette structure est retrouvée pour le formateur MVDR (*Minimum Variance Distorsionless Reponse*) auquel une contrainte quadratique est ajoutée (Bergin *et al.*, 2003 ; Teixeira *et al.*, 2003 ; Bergin *et al.*, 2004). Également, dans (Besson *et al.*, 2007 ; DeMaio *et al.*, 2006 ; DeMaio *et al.*, 2007), une approche bayésienne est invoquée pour intégrer la matrice *a priori* $\bar{\mathbf{R}}$ et conduit également à un estimateur CL. Bien qu'attractif de par sa simplicité de mise en œuvre, l'estimateur CL nécessite en revanche de choisir avec soin les poids (w, \bar{w}) qui contrôlent respectivement la part d'information apportée par les données secondaires et les données *a priori*. Une telle discussion peut se trouver dans (Melvin *et al.*, 2006a ; Zhu *et al.*, 2007 ; Stoica *et al.*, 2008 ; Besson *et al.*, 2008 ; Bidon *et al.*, 2011a).

4.4.1. Illustration

4.4.1.1. Description d'un algorithme KA-STAP Bayésien

Nous illustrons ici l'apport d'information *a priori* en environnement hétérogène. Plus précisément, on s'intéresse à l'algorithme d'estimation bayésienne (Bidon *et al.*, 2008b), (Bidon *et al.*, 2011a) qui permet de réunir trois des stratégies de lutte contre l'hétérogénéité présentées dans cet article :

- il intègre un modèle d'hétérogénéité dans le schéma de détection ;
- il incorpore également de la connaissance *a priori* via une matrice de covariance *a priori* $\bar{\mathbf{R}}$;
- il est implémenté ici dans une structure post-Doppler – plus précisément l'EFA introduit dans (Dipietro, 1992) et rappelé brièvement dans (Bidon, 2011) – afin de diminuer la charge calculatoire et le nombre de données secondaires nécessaires à l'entraînement.

Le modèle des données adopté pour construire l'algorithme est représenté sur la figure 7. À partir de celui-ci, l'estimateur MMSE (*Minimum Mean Square Error*) de la matrice de covariance \mathbf{R} est ensuite calculé. Le modèle proposé comprend trois niveaux hiérarchiques.

1) Le premier niveau correspond à celui des données observées. Les données secondaires \mathbf{x}_k sont supposées gaussiennes iid et de même matrice de covariance secondaire \mathbf{R}_s . La donnée primaire est supposée quant à elle avoir une matrice de covariance \mathbf{R} potentiellement différente de la matrice \mathbf{R}_s , soit

$$\mathcal{E} \{ \mathbf{x} \mathbf{x}^H | \mathbf{R}, H_0 \} = \mathbf{R}$$

$$\mathbf{x}_k | \mathbf{R}_s \sim \mathcal{CN}(\mathbf{0}, \mathbf{R}_s).$$

2) Le second niveau décrit les relations supposées entre les matrices de covariance du modèle. Plus précisément, les matrices de covariance primaire et secondaire sont supposées être des matrices aléatoires distribuées respectivement selon une loi de Wishart complexe et une loi de Wishart inverse complexe, soit

$$\mathbf{R} | \bar{\mathbf{R}}, \mu \sim \mathcal{CW}(\mu^{-1} \bar{\mathbf{R}}, \mu) \quad [15]$$

$$\mathbf{R}_s | \mathbf{R}, \nu \sim \mathcal{CW}^{-1}((\nu - N)\mathbf{R}, \nu) \quad [16]$$

où μ et ν désignent les degrés de liberté respectifs de ces lois. Notons que les distributions [15] et [16] sont choisies parmi une famille de lois conjuguées pour permettre une manipulation mathématique plus aisée du modèle. Malgré ces contraintes pratiques, le modèle est choisi avec une attention particulière pour représenter un environnement pour lequel on dispose d'information *a priori*. Ainsi, d'après [15] et [16], on peut noter qu'en *moyenne* l'information *a priori* est exacte et que le milieu est homogène, c'est-à-dire

$$\mathcal{E} \{ \mathbf{R} | \bar{\mathbf{R}}, \mu \} = \bar{\mathbf{R}} \quad \text{et} \quad \mathcal{E} \{ \mathbf{R}_s | \mathbf{R}, \nu \} = \mathbf{R}.$$

En revanche, pour une réalisation donnée ces matrices diffèrent et vérifient

$$\mathcal{E} \left\{ \|\mathbf{R} - \bar{\mathbf{R}}\|^2 \right\} \xrightarrow{\mu \rightarrow +\infty} 0 \quad \text{et} \quad \mathcal{E} \left\{ \|\mathbf{R}_s - \mathbf{R}\|^2 \right\} \xrightarrow{\nu \rightarrow +\infty} 0.$$

L'hyperparamètre μ permet ainsi de contrôler la distance entre les matrices de covariance *a priori* $\bar{\mathbf{R}}$ et primaire \mathbf{R} . Nous désignerons donc μ comme le degré d'*a priori*. L'hyperparamètre ν permet quant à lui de contrôler la distance entre les matrices de covariance primaire \mathbf{R} et secondaire \mathbf{R}_s . Nous désignerons donc ν comme le degré d'hétérogénéité de l'environnement.

3) Enfin, le troisième et dernier niveau hiérarchique décrit les lois *a priori* pour les hyperparamètres ν et μ . En effet, ceux-ci ne sont pas connus pour un scénario radar réel et doivent donc être estimés. En absence d'information sur ces deux paramètres, on les suppose distribués suivant des lois discrètes uniformes telles que

$$\begin{aligned} \nu &\sim \mathcal{U}_{\{\nu_{\min}, \dots, \nu_{\max}\}} \\ \mu &\sim \mathcal{U}_{\{\mu_{\min}, \dots, \mu_{\max}\}} \end{aligned}$$

où les bornes ν_{\min}, ν_{\max} sont choisies assez petites et assez grandes respectivement pour correspondre à un environnement très hétérogène et très homogène (il en est de même pour les bornes μ_{\min}, μ_{\max}).

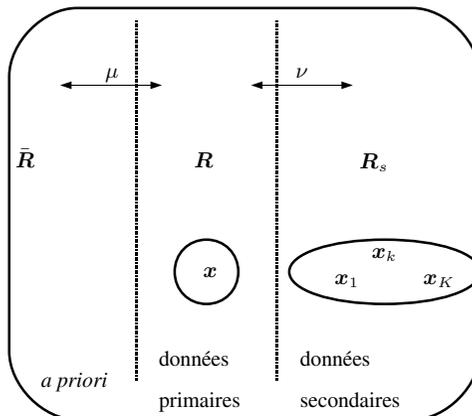


Figure 7. Représentation des niveaux hiérarchiques de l'algorithme bayésien KA étudié. Représentation pour la pleine dimension NM

À partir de ce modèle hiérarchique Bayésien, les estimateurs MMSE de \mathbf{R} , \mathbf{R}_s , ν et μ sont alors calculés (Bidon *et al.*, 2011a). Ainsi, non seulement la matrice $\hat{\mathbf{R}}_{MMSE}$ permet de construire le filtre KA-STAP, mais également les estimateurs $\hat{\nu}_{MMSE}$ et $\hat{\mu}_{MMSE}$ permettent d'évaluer le degré d'*a priori* et d'hétérogénéité de l'environnement. Notons que le calcul des estimateurs MMSE pour ce modèle pose des problèmes d'intégration que l'on résout grâce à l'utilisation d'une méthode de Monte Carlo par chaînes de Markov.

NOTE. – On rappelle que pour un paramètre θ , l'estimateur MMSE est défini comme la moyenne de la distribution *a posteriori*, soit

$$\hat{\theta}_{MMSE} = \mathcal{E} \{ \theta | \{x_k\} \}.$$

4.4.1.2. Performances de l'algorithme KA-STAP sur les données de la DGA/MI

Dans (Bidon *et al.*, 2011a), les performances de l'algorithme sont évaluées par rapport à l'erreur quadratique moyenne et les pertes en SINR sur des données générées suivant le modèle classique STAP (Ward, 1994). On propose de pousser l'analyse un peu plus loin ici, en s'intéressant aux cartes de détection sur les données de la DGA/MI en particulier sur la rafale 1 de l'essai 10, qui est générée en mixant un fond d'image SAR réelle avec des cibles synthétiques. Plus spécifiquement trois détecteurs de type ACE sont comparés. La statistique de test de tels détecteurs est définie par

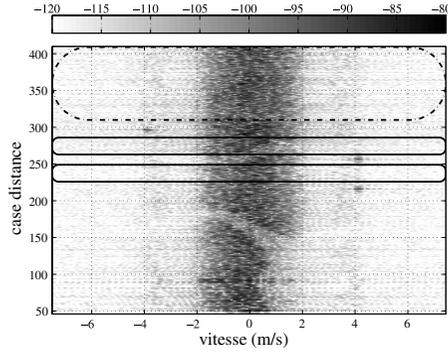
$$T_{type-ACE}(\mathbf{x}) = \frac{\left| \mathbf{a}_t^H \hat{\mathbf{R}}^{-1} \mathbf{x} \right|^2}{\left(\mathbf{a}_t^H \hat{\mathbf{R}}^{-1} \mathbf{a}_t \right) \left(\mathbf{x}^H \hat{\mathbf{R}}^{-1} \mathbf{x} \right)} \quad [17]$$

où la matrice de covariance $\hat{\mathbf{R}}$ est prise successivement égale à $\hat{\mathbf{R}}_{SCM}$, $\hat{\mathbf{R}}_{MMSE}$, et $\bar{\mathbf{R}}$.

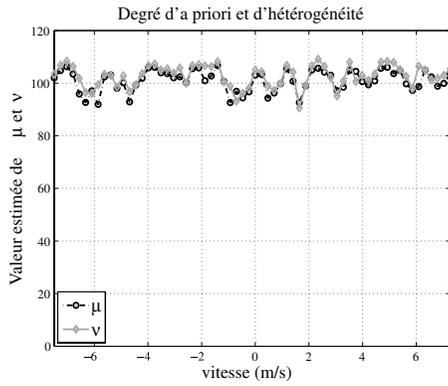
NOTE. – Lorsque $\hat{\mathbf{R}}$ est prise égale à \mathbf{R}_{SCM} , on retrouve le détecteur ACE rappelé plus haut [12].

Pour les simulations, l'attention est portée sur la cellule sous test 256 qui contient une cible à la vitesse 4 m/s. Les données d'entraînement sont prises en nombre égal de part et d'autre de la cellule sous test. La matrice *a priori* est construite (à titre illustratif ici) comme la matrice de covariance des échantillons à partir d'un autre jeu de cases distance sur la même rafale. Ce jeu est choisi de trois manières différentes. Les cartes de détection ainsi obtenues et les valeurs estimées des hyperparamètres ν et μ sont représentées sur les figures 8, 9 et 10.

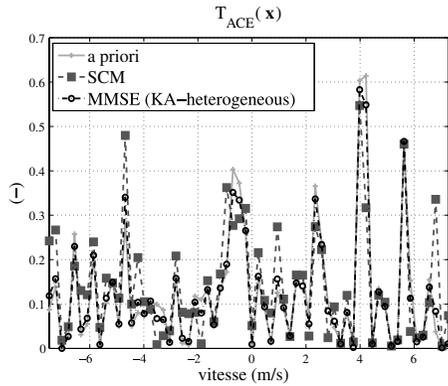
– Au vu de la figure 8(a), la première matrice *a priori* est construite à partir de données relativement homogènes entre elles et avec l'intervalle d'entraînement. L'algorithme bayésien identifie que l'*a priori* est très bon (grande valeur de μ) et que le milieu est très homogène (grande valeur de ν) indépendamment de la vitesse considérée. Du point de vue de la détection, on observe que le détecteur ACE basé sur la matrice SCM ne permet pas de mettre bien en valeur le pic de cible attendu à 4 m/s. Également, on observe un fort pic non attendu vers $-4,7$ m/s. Le détecteur [17] basé sur la matrice $\bar{\mathbf{R}}$ permet de faire ressortir un peu mieux la cible et ces valeurs sont en moyenne moins fortes aux autres vitesses ce qui est souhaité ici puisque la cellule ne contient qu'une cible. Le détecteur basé sur l'estimateur MMSE de la matrice \mathbf{R} se comporte globalement comme celui basé sur la matrice *a priori*.



(a)

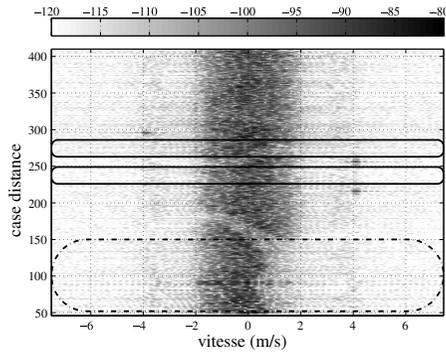


(b)

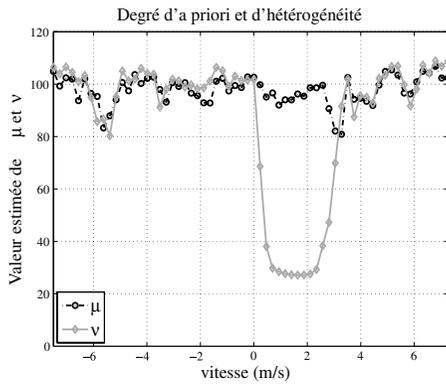


(c)

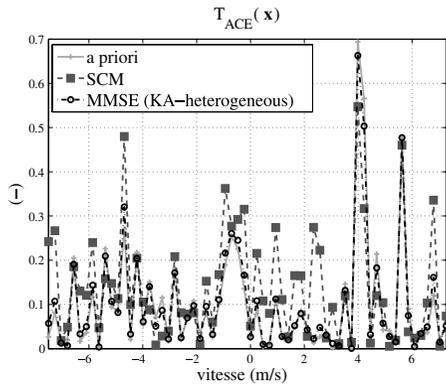
Figure 8. Détecteur KA-STAP testé pour la case distance 256 de la rafale 1 de l'essai 10 des données de la DGA/MI. (a) Intervalle d'entraînement (en trait plein) et intervalle pour construire la matrice a priori (en trait pointillé). (b) Valeur estimée du degré d'a priori μ et du degré d'hétérogénéité v . (c) Comparaison de détecteurs de type ACE



(a)

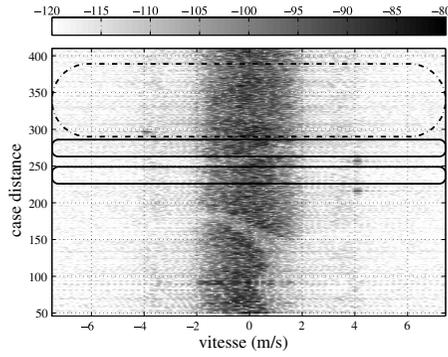


(b)

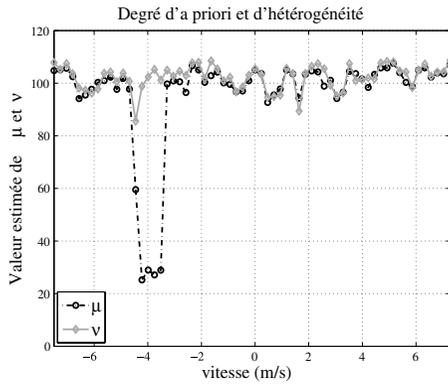


(c)

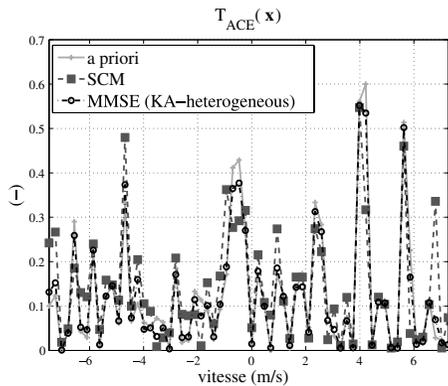
Figure 9. Détecteur KA-STAP testé pour la case distance 256 de la rafale 1 de l'essai 10 des données de la DGA/MI. (a) Intervalle d'entraînement (en trait plein) et intervalle pour construire la matrice a priori (en trait pointillé). (b) Valeur estimée du degré d'a priori μ et du degré d'hétérogénéité v . (c) Comparaison de détecteurs de type ACE



(a)



(b)



(c)

Figure 10. Détecteur KA-STAP testé pour la case distance 256 de la rafale 1 de l'essai 10 des données de la DGA/MI. (a) Intervalle d'entraînement (en trait plein) et intervalle pour construire la matrice a priori (en trait pointillé). (b) Valeur estimée du degré d'a priori μ et du degré d'hétérogénéité v . (c) Comparaison de détecteurs de type ACE

– Au vu de la figure 9(a), la seconde matrice *a priori* est construite à partir de données relativement homogènes entre elles mais hétérogènes avec la cellule sous test. En effet, la réflectivité du fouillis *a priori* est largement atténuée sur le domaine des vitesses positives. L'algorithme bayésien identifie que l'*a priori* est très bon (grande valeur de μ) sur tout le domaine des vitesses et que le milieu y est très homogène (grande valeur de ν) sauf dans la zone où la réflectivité du fouillis *a priori* est atténuée. Du point de vue de la détection, on observe les mêmes tendances qu'observées sur le précédent scénario. Notons tout de même que le pic de cible à 4 m/s est encore mieux mis en évidence grâce aux détecteurs basés sur les matrices $\hat{\mathbf{R}}$ et $\hat{\mathbf{R}}_{MMSE}$.

– Enfin, au vu de la figure 10(a), la troisième matrice *a priori* est construite à partir d'un groupe de cellules homogènes à l'exception des cases distance comprenant la cible centrée sur la cellule 296. L'algorithme Bayésien identifie que l'*a priori* est très bon sauf dans la zone des vitesses où la cible secondaire est présente. Le milieu, lui, y est vu comme très homogène (grande valeur de ν) sur tout le domaine des vitesses. Du point de vue de la détection, l'avantage des détecteurs basés sur $\hat{\mathbf{R}}$ et $\hat{\mathbf{R}}_{MMSE}$ devant l'ACE est en revanche moins évidente que dans les deux scénarios d'étude précédents.

Ainsi, ces trois simulations tentent à montrer que l'algorithme KA-STAP proposé permet d'identifier convenablement d'une part, les zones où la matrice de covariance *a priori* apporte une information fiable pour le détecteur, et, d'autre part, les zones où les données *a priori* (lorsqu'elles sont fiables) sont hétérogènes avec les données secondaires. De plus, le détecteur de type ACE basé sur l'estimateur MMSE de la matrice de covariance \mathbf{R} à tendance à mieux mettre en valeur la cible dans la carte de détection. Dans de futurs travaux, on pourra étudier d'autres schémas de détection utilisant l'estimateur MMSE pour améliorer encore les performances de détection.

5. Conclusion

Cet article a fait le bilan dans un premier temps des principales causes d'hétérogénéité dans le cadre de la détection radar pour un système aéroporté. Parmi elles, on compte l'hétérogénéité de la réflectivité du sol, la présence de cibles secondaires dans les données d'entraînement ou dans la case sous test, et enfin la non-stationnarité du lieu du fouillis en fonction de la distance. Par des exemples simples, nous avons illustré les pertes que subissaient les algorithmes classiques d'estimation et de détection pour chaque type d'hétérogénéité.

Une synthèse sur les algorithmes STAP permettant de lutter contre l'hétérogénéité a ensuite été dressée. Ceux-ci peuvent être classés en quatre grandes catégories qui ne sont pas exclusives les unes des autres. On distingue ainsi les algorithmes ne nécessitant que peu de données d'entraînement, les algorithmes utilisant des détecteurs NHD visant à rejeter les cellules les plus hétérogènes de l'intervalle d'entraînement, les schémas de détection intégrant directement un modèle d'hétérogénéité pour en tirer partie par la suite, et les algorithmes KA-STAP utilisant de l'information *a priori* créant ainsi un espace d'observation additionnel de la cellule sous test.

Une emphase a été mise en particulier sur un algorithme Bayésien hiérarchique récemment proposé dans la littérature et étudié sur signaux synthétiques. Ce dernier a été testé dans cet article sur des signaux hybrides quasi réels fournis par la DGA/MI. L'étude a permis ainsi de valider les performances d'estimation observées initialement sur données synthétiques.

Remerciements

Les auteurs souhaitent remercier la DGA/MI pour la fourniture des données STAP utilisées dans cet article.

Bibliographie

- Abramovich Y., Nevrev A. (1981). « *n* analysis of effectiveness of adaptive maximization of the signal-to-noise ratio which utilizes the inversion of the estimated correlation matrix ». *Radio Eng. Electron. Phys.*, vol. 27, n° 10, p. 69-77.
- Adve R. S., Hale T. B., Wicks M. C. (1999). « Transform Domain Localized Processing Using Measured Steering Vectors and Non-Homogeneity Detection ». *Proc. IEEE Radar Conference*, Boston, MA, p. 285-290, April.
- Armstrong B. C., Griffiths H. D. (1993). « Performance of Adaptive Optimal Doppler Processors in Heterogeneous Clutter ». *Proc. IEEE National, Radar Conference*, Boston, MA, p. 140-145, April.
- Ayoub T. F., Haimovich A. M. (2000). « Modified GLRT Signal Detection Algorithm ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 36, n° 3, p. 810-818, July.
- Ayoub T. F., Haimovich A. M., Pugh M. L. (1999). « Reduced-Rank STAP for High PRF Radar ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 35, n° 03, p. 953-962, July.
- Barlow E. J. (1949). « Doppler Radar ». *Proc. IRE*, vol. 37, p. 340-355, April.
- Barton T. A., Smith S. T. (1997). « Structured Covariance Estimation for Space-Time Adaptive Processing ». *Proc. ICASSP*, Munich, Germany, April.
- Berger S. D., Welsh B. M. (1999). « Selecting a Reduced-Rank Transformation for STAP— A Direct Form Perspective ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 35, n° 2, p. 722-729, April.
- Bergin J. S., Teixeira C. M., Techau P. M., Guerci J. R. (2004). « STAP with Knowledge-Aided Data Pre-Whitening ». *Proc. IEEE Radar Conf., Philadelphia*, PA, p. 289-294, April 26-29.
- Bergin J., Teixeira C. M., Techau P. M., Guerci J. R. (2003). « Space-Time Beamforming with Knowledge-Aided Constraints ». *Proc. Adaptive Sensor Array Processing Workshp*, March 11-13.
- Besson O. (2007). « Detection in the Presence of Surprise or Undernulled Interference ». *IEEE Signal Processing Lett.*, vol. 14, n° 5, p. 352-354, May.
- Besson O., Bidon S., Tourneret J.-Y. (2008). « Covariance Matrix Estimation With Heterogeneous Samples ». *IEEE Trans. Signal Processing*, vol. 56, n° 3, p. 909-920, March.

- Besson O., Tourneret J.-Y., Bidon S. (2007). « Knowledge-Aided Bayesian Detection in Heterogenous Environments ». *IEEE Signal Processing Lett.*, vol. 14, n° 5, p. 355-358, May.
- Bidon S. (2011). « Introduction au STAP. Partie II : Modèle des signaux et principe du filtrage ». *Revue Traitement du Signal*.
- Bidon S., Besson O., Tourneret J.-Y. (2008a). « A Bayesian Approach to Adaptive Detection in Non-homogeneous Environments ». *IEEE Trans. Signal Processing*, vol. 56, n° 1, p. 205-217, January.
- Bidon S., Besson O., Tourneret J.-Y. (2008b). « Characterization of Clutter Heterogeneity and Estimation of its Covariance Matrix ». *Proc. IEEE Radar Conference*, Rome, p. 359-362, May.
- Bidon S., Besson O., Tourneret J.-Y. (2008c). « The Adaptive Coherence Estimator is the Generalized Likelihood Ratio Test for a Class of Heterogeneous Environments ». *IEEE Signal Processing Lett.*, vol. 15, p. 281-284.
- Bidon S., Besson O., Tourneret J.-Y. (2011a). « Knowledge-Aided STAP in heterogeneous clutter using a hierarchical Bayesian algorithm ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 47, n° 3, p. 1863-1879.
- Bidon S. (2011b). Montécot M., Savy L., « Introduction au STAP. Partie III : Les données du club STAP ». *Revue Traitement du Signal*.
- Blunt S. D., Gerlach K., Rangaswamy M. (2006). « STAP using Knowledge-Aided Covariance Matrix Estimation and the FRACTA algorithm ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 42, n° 3, p. 1043-1057, July.
- Borson D. M. (1980). « Sample Size Considerations for Adaptive Arrays ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 16, n° 4, p. 446-451, July.
- Borsari G. K. (1998). « Mitigating Effects on STAP Processing Caused by an Inclined Array ». *Proc. IEEE Radar Conference*, Dallas, TX, p. 135-140, May.
- Borsari G. K., Steinhardt A. O. (1995). « Cost-Efficient Training Strategies for Space-Time Adaptive Processing Algorithms ». *Proc. Asilomar Conference on Signals, Systems and Computers*, p. 650-654.
- Brennan L. E., Reed I. S. (1973). « Theory of adaptive radar ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 9, p. 237-252, March.
- Burg J., Luenberger D., Wenger D. (1982). « Estimation of structured covariance matrices ». *Proc. IEEE*, vol. 70, n° 9, p. 963-974, September.
- Cai L., Wang H. (1994). « Further Results on Adaptive Filtering with Embedded CFAR ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 30, n° 4, p. 1009-1020, October.
- Capraro C. T., Capraro G. T., Bradaric I., Wicks M. C., Baldygo W. J. (2006). « Implementing Digital Terrain Data in Knowledge-Aided Space-Time Adaptive Processing ». *IEEE Trans. Aerosp. Electron. Syst.*, July.
- Carlson B. D. (1988). « Covariance Matrix Estimation Errors and Diagonal Loading in Adaptive Ar-rays ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 24, n° 4, p. 397-401, July.
- Chen P., Melvin W. L., Wicks M. C. (1999). « Screening Among Multivariate Normal Data ». *Journal of Multivariate Analysis*, vol. 69, p. 10-29.
- Conte E., De Maio A., Farina A., Foglia G. (2006). « Design and Analysis of a Knowledge-Aided Radar Detector for Doppler Processing ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 42, n° 3, p. 1058-1079, July.

- Conte E., Lops M., Ricci G. (1995). « Asymptotically Optimum Radar Detection in Compound-Gaussian Clutter ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 31, n° 2, p. 617-625, April.
- Conte E., Lops M., Ricci G. (1996). « Adaptive Matched Filter Detection in Spherically Invariant Noise ». *IEEE Signal Processing Lett.*, vol. 3, n° 8, p. 248-250, August.
- Conte E., Lops M., Ricci G. (1998). « Adaptive Detection Schemes in Compound-Gaussian Clutter ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 34, n° 4, p. 1058-1069, October.
- De Maio A., Farina A. (2006). « Adaptive radar detection : a Bayesian approach ». *Proc. 2006 Int. Radar Symp.*, Krakow, Poland, May 24–26.
- De Maio A., Farina A., Foglia G. (2007). « Adaptive Radar Detection : A Bayesian Approach ». *Proc. IEEE Radar Conf.*, Waltham, MA, p. 624-629, April 17–20.
- DiPietro R. C. (1992). « Extended Factored Space-Time Processing for Airborne Radar Systems ». *Proc. Asilomar Conference on Signals, Systems, and Computers*, vol. 1, p. 425-430, October.
- Fante R. L., Barile E. C., Guella T. P. (1994). « Clutter Covariance Smoothing by Subaperture Averaging ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 30, n° 3, p. 941-945, July.
- Friedlander B. (2000). « The MVDR Beamformer for Circular Arrays ». *Proc. Asilomar Conference on Signals, Systems and Computers*, vol. 1, p. 25-29.
- Fuhrmann D. R. (1991). « Application of Toeplitz Estimation to Adaptive Beamforming and Detection ». *IEEE Trans. Signal Processing*, vol. 39, n° 10, p. 2194-2198, October.
- Gerlach K. (1995). « The Effects of Signal Contamination on Two Adaptive Detectors ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 31, n° 1, p. 297-309, January.
- Gerlach K., Blunt S. D., Picciolo M. L. (2004). « Robust Adaptive Matched Filtering Using the FRACTA Algorithm ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 40, n° 3, p. 929-945, July.
- Gerlach K., Picciolo M. L. (2003). « Airborne/Spacebased Radar STAP Using a Structured Covariance Matrix ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 39, n° 1, p. 269-281, January.
- Ginolhac G., Forster P., Ovarlez J.-P., Pascal F. (2011). « STAP à rang réduit, robuste et persymétrique ». *Revue Traitement du Signal*.
- Goldstein J. S., Reed I. S. (1997). « Theory of Partially Adaptive Radar ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 33, n° 4, p. 1309-1325, October.
- Goldstein J. S., Reed I. S., Scharf L. L. (1998). « A Multistage Representation of the Wiener Filter Based on Orthogonal Projections ». *IEEE Trans. Inform. Theory*, vol. 44, n° 7, p. 2943-2959, November.
- Guerci J. R. (2003). *Space-Time Adaptive Processing for Radar*. Artech House, Norwood, MA.
- Guerci J. R., Baranoski E. J. (2006). « Knowledge-Aided Adaptive Radar at DARPA ». *IEEE Signal Processing Mag.*, vol. 23, n° 1, p. 41-50, January.
- Haimovich A. (1996). « The Eigencanceler : Adaptive Radar by Eigenanalysis Methods ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 32, n° 2, p. 532-542, April.
- Hayward S. D. (1996). « Adaptive Beamforming for Rapidly Moving Arrays ». *Proc. International Conference of Radar*, Beijing, China, p. 480-483, October.

- Hiemstra J. D. (2002). « Colored Diagonal Loading ». *Proc. IEEE Radar Conf.*, Chantilly, VA, USA, p. 386-390, April 22–25.
- Kelly E. J. (1986). « An Adaptive Detection Algorithm ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 22, n° 1, p. 115-127, March.
- Kirsteins I. P., Tufts D. W. (1994). « Adaptive Detection Using Low Rank Approximation to a Data Matrix ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 30, n° 1, p. 55-67, January.
- Klemm R. (2002). *Principles of Space-Time Adaptive Processing*. IEE Press, London, U.K.
- Klemm R. (2004). *Applications of Space-Time Adaptive Processing*. IEE Press, London, U.K.
- Kogon S. M. (2004). « Adaptive weight training for post-Doppler STAP algorithms in non-homogenous clutter », chapter 11, p. 359-374.
- Kraut S., Scharf L. L., Butler R. W. (2005). « The Adaptive Coherence Estimator : A Uniformly Most-Powerful-Invariant Adaptive Detection Statistic ». *IEEE Trans. Signal Processing*, vol. 53, n° 2, p. 427-438, February.
- Kraut S., Scharf L. L., McWhorter L. T. (2001). « Adaptive Subspace Detectors ». *IEEE Trans. Signal Processing*, vol. 49, n° 1, p. 1-16, January.
- Kreyenkamp O., Klemm R. (2001). « Doppler Compensation in Forward-Looking STAP Radar ». *IEE Proc. Radar, Sonar and Navigation*, vol. 148, n° 5, p. 253-258, October.
- Lapierre F. D., Verly J. G., Droogenbroeck M. V. (2003). « New Solutions to the Problem of Range De-pendence in Bistatic STAP Radars ». *Proc. IEEE Radar Conference*, Huntsville, Alabama, p. 452-459, May.
- Marcos S., Beau S. (2011). « STAP à rang réduit, récursif en distance et utilisant un développement de Taylor ». *Revue Traitement du Signal*.
- McDonald K. F., Blum R. S. (2000). « Exact Performance of STAP Algorithms with Mismatched Steering and Clutter Statistics ». *IEEE Trans. Signal Processing*, vol. 48, n° 10, p. 2750-2763, October.
- McWhorter L. T., Scharf L. L., Griffiths L. J. (1996). « Adaptive Coherence Estimation for Radar Signal Processing ». *Proc. Asilomar Conference on Signals, Systems, and Computers*, p. 536-540, November.
- Melvin W. L. (1998). « Eigenbased modeling of nonhomogeneous airborne radar environments ». *Proc. IEEE Radar Conference*, Dallas, Texas, p. 171-176, May.
- Melvin W. L. (2000). « Space-Time Adaptive Radar Performance in Heterogeneous Clutter ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 36, n° 2, p. 621-633, April.
- Melvin W. L., Guerci J. R. (2006a). « Knowledge-Aided Signal Processing : A New Paradigm for Radar and Other Advanced Sensors ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 42, n° 3, p. 983-996, July.
- Melvin W. L., Himed B., Davis M. E. (2003). « Doubly Adaptive Bistatic Clutter Filtering ». *Proc. IEEE Radar Conference*, Huntsville, Alabama, p. 171-178, May.
- Melvin W. L., Showman G. A. (2006b). « An Approach to Knowledge-Aided Covariance Estimation ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 42, n° 3, p. 1021-1042, July.
- Montécot M., Le Chevalier F., Savy L. (2011). « Introduction au STAP. Partie I : Contexte radar et enjeu du filtrage ». *Revue Traitement du signal*.
- Nitzberg R. (1990). « An Effect of Range-Heterogeneous Clutter On Adaptive Doppler Filters ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 26, n° 3, p. 475-480, May.

- Ovarlez J.-P., Pascal F., Forster P., Ginolhac G., Mahot M. (2011). « Traitement STAP et modélisation SIRV : robustesse et persymétrie ». *Revue Traitement du Signal*.
- Page D., Scarborough S., Orwirka G., Crooks S. (2004). « Improving Knowledge-Aided STAP Performance using Past CPI Data ». *Proc. IEEE Radar Conf.*, p. 295-300, April 26–29.
- Pailloux G., Ovarlez J.-P., Pascal F., Forster P., « Persymmetric adaptive radar detectors ». *IEEE Trans. Aerosp. Electron. Syst.*, n.d.
- Parker P., Swindlehurst A. (2003). « Space-Time Autoregressive Filtering for Matched Subspace STAP ». *IEEE Trans. Aerosp. Electron. Syst.*, April.
- Pascal F. (2006). Détection et Estimation en Environnement Non gaussien, PhD thesis, Université Paris X, Nanterre, France, December.
- Pearson F., Borsari G. (2001). « Simulation and Analysis of Adaptive Interference Suppression for Bistatic Surveillance Radars ». *Proc. ASAP Workshop*, Lexington, MA, March.
- Petitjean J., Grivel E. (2011). « STAP fondé sur une modélisation autoregressive (AR) des interférences : estimation des paramètres AR par filtrage de Kalman ». *Revue Traitement du Signal*.
- Pillai S. U., Kim Y. L., Guerci J. R. (2000). « Generalized Forward/Backward Subaperture Smoothing Techniques for Sample Starved STAP ». *IEEE Trans. Signal Processing*, vol. 48, n° 12, p. 3569-3574, December.
- Rabideau D. J., Steinhardt A. O. (1999). « Improved Adaptive Clutter Cancellation Through Data-Adaptive Training ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 35, n° 3, p. 879-891, July.
- Reed I. S., Mallett J. D., Brennan L. E. (1974). « Rapid Convergence Rate in Adaptive Arrays ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 10, n° 6, p. 853-863, November.
- Richmond C. D. (2000). « Performance of a Class of Adaptive Detection Algorithms in Nonhomogeneous Environments ». *IEEE Trans. Signal Processing*, vol. 48, n° 5, p. 1248-1262, May.
- Román J. R., Rangaswamy M., Davis D. W., Zhang Q., Himed B., Michels J. H. (2000). « Parametric Adaptive Matched Filter for Airborne Radar Applications ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 36, n° 2, p. 677-692, April.
- Russ J. A., Casbeer D. W., Swindlehurst A. L. (2004). « STAP Detection Using Space-Time Autoregressive Filtering ». *Proc. IEEE Radar Conference*, Philadelphia, p. 541-545, April.
- Sangston K. J., Gerlach K. R. (1994). « Coherent Detection of Radar Targets in a Non-Gaussian Background ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 30, n° 2, p. 330-340, April.
- Savy L., Degurse J.-F. (2011). « Stop-Band APES : Traitement STAP sur données fortement hétérogènes ». *Revue Traitement du Signal*.
- Scharf L. L., McWhorter L. T. (1996). « Adaptive Matched Subspace Detectors and Adaptive Coherence Estimators ». *Proc. Asilomar Conference Signals Systems Computers*, Pacific Grove, CA, p. 1114-1117, November.
- Skolnik M. I. (1970). *Radar Handbook*. McGraw-Hill.
- Steiner M., Gerlach K. (2000). « Fast Converging Adaptive Processor for a Structured Covariance Matrix ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 36, n° 4, p. 1115-1126, October.

- Stoica P., Li J., Zhu X., Guerci J. R. (2008). « On Using a priori Knowledge in Space-Time Adaptive Processing ». *IEEE Trans. Signal Processing*, vol. 56, n° 6, p. 2598-2602, June.
- Teixeira C., Bergin J., Techau P. (2003). « Reduced Degree-of-Freedom STAP with Knowledge-Aided Data Pre-Whitening ». *Proc. KASSPER Workshops 2003*, Las Vegas, NV, April.
- Varadarajan V., Krolik J. L. (2006). « Joint Space-Time Interpolation for Distorted Linear and Bistatic Array Geometries ». *IEEE Trans. Signal Processing*, vol. 53, p. 848-860, March.
- Wang H., Cai L. (1994). « On Adaptive Spatial-Temporal Processing for Airborne Surveillance Radar Systems ». *IEEE Trans. Aerosp. Electron. Syst.*, vol. 30, n° 3, p. 660-670, July.
- Ward J. (1994). *Space-Time Adaptive Processing for Airborne Radar*, Technical Report n° 1015, Lincoln Laboratory, MIT, Lexington, MA, December.
- Zhu X., Li J., Stoica P., Guerci J. R. (2007). « Knowledge-Aided Space-Time Adaptive Processing ». *Proc. 41st Asilomar Conf.*, Pacific Grove, CA, p. 1830-1834, November 4-7.