

Chapitre 3

Détection de mines antipersonnel sur des données Bscan

3.1 Introduction

Dans ce chapitre, une nouvelle méthode de détection de mines antipersonnel, basée sur la détection de ruptures, est proposée afin de localiser automatiquement les réponses des mines antipersonnel sur des données Bscan.

La détection de ruptures est une problématique désormais classique en traitement du signal. Elle consiste en la recherche d'instantanés où une modification du comportement des signaux a pu avoir lieu. Dans le cadre de la détection d'objets enfouis, les signatures hyperboliques présentes sur les données Bscans sont caractéristiques de la présence d'objets enfouis. Ainsi, les deux branches d'une hyperbole caractérisant la réponse d'un objet enfoui sont plus énergétiques que le milieu de propagation (réponse du sol sans objet enfoui). On peut alors chercher les ruptures en se déplaçant suivant l'axe spatial l (horizontal) ou l'axe temporel t (vertical) du Bscan afin de localiser l'objet. Il s'agit en fait de détecter les positions suivant l où l'objet enfoui se situe et de détecter son temps de réponse suivant t .

Des méthodes de détection de ruptures à base de modèle existent et sont performantes lorsqu'un modèle physique ou statistique précis des données est disponible [BN93]. Cependant, les données du GPR sont difficiles à modéliser précisément puisque cela consiste à modéliser la propagation d'une onde électromagnétique dans un milieu hétérogène de surface rugueuse. En fait, en supposant que l'on possède une connaissance de l'interface air-sol et des propriétés électriques du sous-sol, la simple modélisation du signal reçu par la méthode FDTD ou par l'évaluation de fonctions de Green est une tâche complexe nécessitant des coûts de calculs élevés, voir [Rej02], [ML03] et [LSB⁺04]. Ainsi, l'utilisation de tels modèles de propagation, dans une routine de traitement en ligne où l'on doit prendre en compte la structure inconnue du sol n'est pas réalisable. Dans la littérature,

on peut trouver des méthodes de détection de ruptures à base de modèle statistique des signaux GPR, voir [XMR02] et [HG02]. Ces méthodes utilisent un test statistique séquentiel pour choisir entre l'hypothèse H_0 (absence de mine) et l'hypothèse H_1 (présence de mine) à chaque position l . La grande diversité des signatures de mines antipersonnel fait qu'il est difficile de trouver un modèle statistique sous l'hypothèse H_1 . Ainsi, le test statistique est construit uniquement à partir du modèle statistique des données sous l'hypothèse H_0 . Après la réduction du clutter, il est supposé sous l'hypothèse H_0 , que les échantillons du vecteur de mesure sont distribués indépendamment suivant une densité de probabilité Gaussienne. Cependant, la validité du modèle statistique sous H_0 est discutable puisque la présence de résidus de clutter pouvant être ou ne pas être distribués suivant une Gaussienne n'est pas prise en compte dans le modèle. Ceci résulte en général par un taux de fausses alarmes expérimental supérieur à celui théorique, voir [Bru99].

Ainsi, l'idée principale de notre approche est d'appliquer une technique de détection de ruptures non paramétrique sur des données Bscans de la façon suivante :

- Etape 1 : Les ruptures suivant l'axe spatial (horizontal) du Bscan sont recherchées.
- Etape 2 : Les ruptures suivant l'axe temporel (vertical) du Bscan sont recherchées. Bien sûr, l'étape 2 est implémentée uniquement dans les zones où des ruptures ont été détectées à l'étape 1. Une difficulté importante de l'étape 2 est que les bandes du clutter peuvent créer des ruptures. Le clutter doit par conséquent être préalablement réduit.

Le cadre général de la méthode est présenté dans la section 3.2. La section 3.3 présente de manière détaillée l'algorithme de détection de ruptures en ligne proposé dans [Des04], et [DDD05]. La méthode de détection de mines antipersonnel est ensuite présentée dans la section 3.4 et les résultats de simulation sur des données synthétiques et réelles sont donnés dans la section 3.5.

Cette méthode de détection a été présentée dans [PVD05] et [PVDD06].

3.2 Cadre général de la méthode

Par l'intermédiaire d'une fenêtre glissante suivant l ou t on peut extraire d'une donnée Bscan une série d'observations, notée $\{x_a\}$, avec a un indice ($a \equiv l$ ou $a \equiv t$, le symbole \equiv signifiant équivalent à). Ainsi, la problématique traitée est la détection de ruptures en ligne suivant a , pour des observations obtenues de façon séquentielle. A chaque position a , deux ensembles d'observations \mathbf{x}_1 et \mathbf{x}_2 constitués respectivement de m_1 et m_2 colonnes du Bscan si $a \equiv l$ ou de m_1 et m_2 lignes du Bscan si $a \equiv t$ sont construits et une mesure de dissimilarité entre ces deux ensembles, dénotée $D(\mathbf{x}_1, \mathbf{x}_2)$, est calculée. Les ruptures suivant a sont détectées chaque fois que la mesure de dissimilarité $D(\mathbf{x}_1, \mathbf{x}_2)$ est supérieur

au seuil de détection η_a . Une fois $D(x_1, x_2)$ calculée à la position a , les deux ensembles d'observations x_1 et x_2 sont mis à jour à la coordonnée $a + 1$. Les figures 3.1 et 3.2 montrent le résultat de la détection de ruptures dans une donnée Bscan synthétique suivant respectivement $a \equiv l$ et $a \equiv t$.

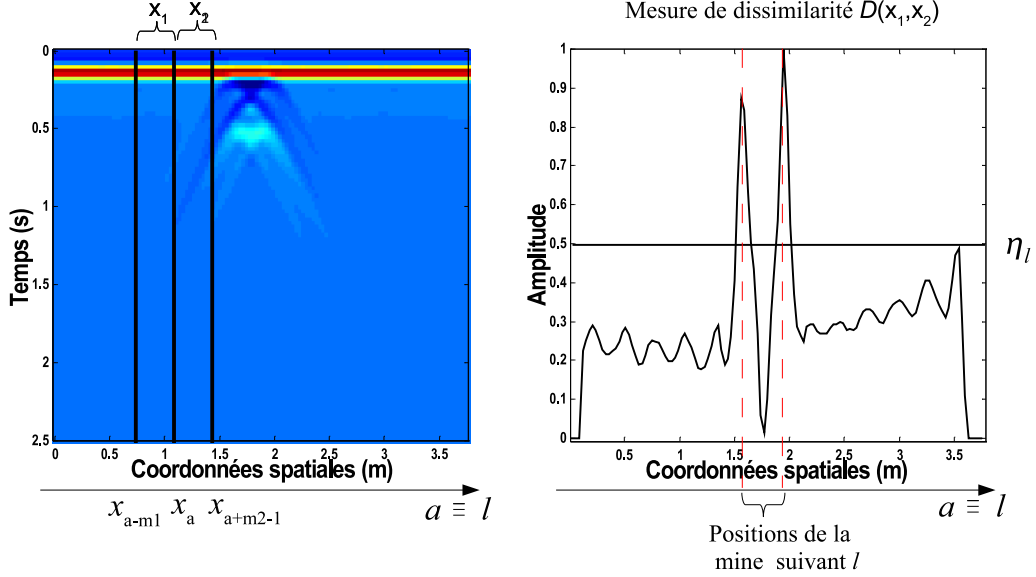


FIG. 3.1: Détection de ruptures dans une donnée Bscan synthétique suivant l'axe spatial l . A chaque position horizontale l , deux ensembles d'observations x_1 et x_1 constitués respectivement de m_1 et m_2 Ascans sont construits et une mesure de dissimilarité entre ces deux ensembles, dénotée $D(x_1, x_2)$, est calculée. Les ruptures spatiales sont détectées chaque fois que la mesure de dissimilarité $D(x_1, x_2)$ est supérieur au seuil η_l .

Un algorithme de détection de ruptures en ligne à noyau est utilisé afin de pouvoir détecter les réponses des objets enfouis dans les données Bscans. Cet algorithme, dénommé algorithme KCD, initialement conçu pour la segmentation de séries temporelles [DDD05], est modifié afin de localiser les objets dans les données Bscans. En effet, pour déterminer le temps de réponse d'un objet enfoui, il ne suffit pas juste de détecter les ruptures suivant t , il faut également donner du poids à celle provenant de la première réflexion du pulse GPR sur l'objet. Ainsi, un nouvel indice de décision est construit. La section suivante présente l'algorithme KCD.

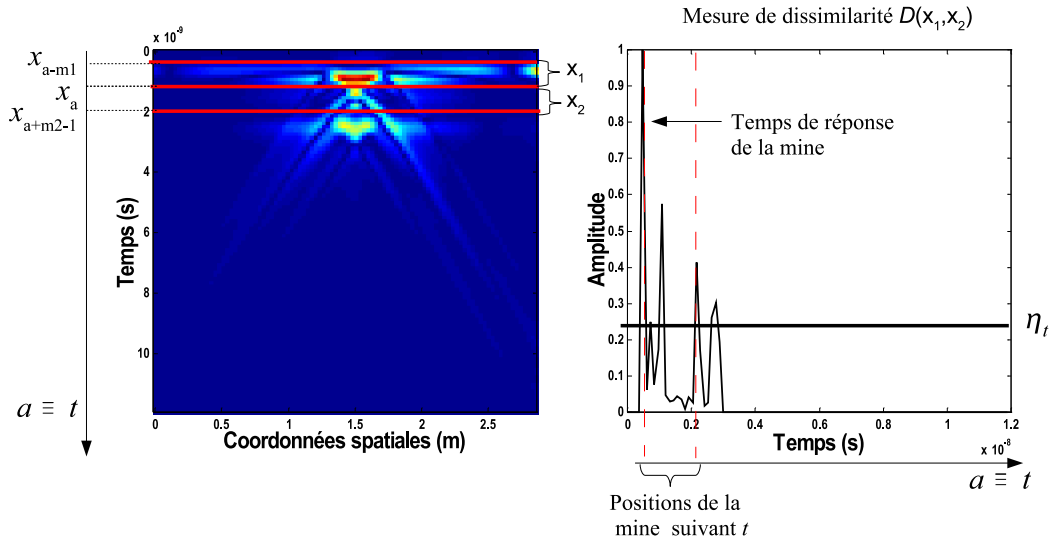


FIG. 3.2: Détection de ruptures suivant l'axe temporel t , dans la donnée Bscan de la figure 3.1, préalablement traitée par le filtre numérique conçu au chapitre précédent. A chaque position verticale t , deux ensembles d'observations \mathbf{x}_1 et \mathbf{x}_2 constitués respectivement de m_1 et m_2 lignes du Bscan sont construits et une mesure de dissimilarité entre ces deux ensembles, dénotée $D(\mathbf{x}_1, \mathbf{x}_2)$, est calculée. Les ruptures temporelles sont détectées chaque fois que la mesure de dissimilarité $D(\mathbf{x}_1, \mathbf{x}_2)$ est supérieur au seuil η_t .

3.3 Algorithme de détection de ruptures en ligne à noyau

Les éléments bibliographiques de cette partie proviennent essentiellement de [Des04], [DDD05], et [KD06].

On débute par rappeler l'approche basée sur la comparaison du passé et futur immédiats de chaque instant, utilisée de façon classique dans les approches séquentielles.

3.3.1 Le contexte en ligne

Le problème de détection de ruptures en ligne peut être présenté de la façon suivante :

On suppose que des données x_a dans un espace des observations \mathcal{X} sont extraites en ligne d'un signal. On considère un point d'analyse x_a et deux sous ensembles d'observations, le sous ensemble du passé immédiat $\mathbf{x}_1 = \{x_{a-m_1}, \dots, x_{a-1}\}$ et le sous ensemble du futur immédiat $\mathbf{x}_2 = \{x_a, \dots, x_{a+m_2-1}\}$, voir figure 3.3.

Le problème de détection de ruptures peut être énoncé dans le cadre statistique. Sous l'hypothèse que les observations de \mathbf{x}_1 (resp. \mathbf{x}_2) sont indépendantes et identiquement




FIG. 3.3: Cadre adopté pour la détection de ruptures en ligne. Les observations de la série étudiée x_a , $a = 1, 2, \dots$, sont représentées par des cercles suivant a .

distribuées (i.i.d.) selon une densité de probabilité p_1 (resp. p_2), une des deux hypothèses suivantes tient :

$$\begin{cases} H_0 : p_1 = p_2 \text{ il n'y a pas de changement en } a \\ H_1 : p_1 \neq p_2 \text{ il y a un changement en } a \end{cases}$$

Cependant, dans le cas où aucun modèle statistique des données n'est disponible, les densités de probabilité p_1 et p_2 sont inconnues. Une approche pratique standard consiste alors à utiliser une mesure de dissimilarité entre p_1 et p_2 à partir de la seule connaissance des ensembles x_1 et x_2 . Soit $D(x_1, x_2)$ une telle mesure de dissimilarité, le test d'hypothèses peut être reformulé de la façon suivante :

$$\begin{cases} H_0 : D(x_1, x_2) \leq \eta_a \text{ il n'y a pas de changement en } a \\ H_1 : D(x_1, x_2) > \eta_a \text{ il y a un changement en } a \end{cases}$$

où η_a est un seuil dont le réglage est lié au compromis sensibilité/robustesse. Pour des valeurs faibles de η_a un grand nombre de ruptures est susceptible d'être détecté même si la mesure de dissimilarité $D(\cdot, \cdot)$ ne présente pas de pic. Ce qui se traduit par une augmentation du risque de fausse alarme. À l'inverse, pour de grandes valeurs de η_a , certaines ruptures peuvent ne pas être détectées, ce qui diminue le taux de bonne détection. Il faut donc régler le seuil η_a de façon à détecter les ruptures suivant a provenant des réponses des mines enfouies dans le sol, tout en limitant au maximum le risque de fausse alarme.

Ainsi, pour le Bscan de la figure 3.1, il faut choisir $\eta_t \geq 0.5$ afin de détecter uniquement les positions horizontales de l'objet dans le Bscan. Pour détecter les positions verticales de l'objet, il faut choisir un seuil $\eta_t \geq 0.3$, voir figure 3.2. Cependant, si l'on souhaite détecter uniquement le temps de réponse de l'objet, il faut choisir $\eta_t \geq 0.6$.

Les méthodes de détection de ruptures à base de modèle donnent de bons résultats, lorsqu'il est possible de décrire précisément et suffisamment simplement, par exemple, le modèle physique à l'origine des données. Le rapport de vraisemblance généralisé (RVG) est ainsi très couramment utilisé en pratique, voir [BN93]. En revanche, dans le contexte de la détection de mines antipersonnel puisqu'aucun modèle physique ou statistique pré-

cis des données du GPR n'est utilisable, on se dirige vers une approche non paramétrique pour la détection de ruptures.

3.3.2 Détection non paramétrique de ruptures

Dans l'application considérée, l'utilisation de descripteurs temps-espace ou espace-temps selon la direction suivant laquelle les descripteurs sont extraits du Bscan (l ou t), induit un espace des observations de grande dimension. Comparer les densités de probabilité p_1 et p_2 par le biais d'estimateurs empiriques n'est alors pas intéressant pour calculer une dissimilarité entre les deux ensembles à cause de la malédiction de la dimensionnalité. On cherche ainsi des méthodes dont le but est de comparer les ensembles \mathbf{x}_1 et \mathbf{x}_2 sans l'étape intermédiaire d'estimation-amont des densités p_1 et p_2 . Dans de nombreuses applications telles que la détection d'observations anormales, la segmentation de signaux audio, les supports des densités de probabilité p_1 et p_2 sont suffisamment discriminants pour permettre de mesurer la dissimilarité entre les ensembles \mathbf{x}_1 et \mathbf{x}_2 , voir ([DDD05], [DDGD06]). Pour utiliser cette approche, il est nécessaire de définir un estimateur de support de densité précis et robuste ainsi qu'une mesure de dissimilarité pour comparer les estimés des supports de p_1 et p_2 .

3.3.3 Apprendre une fonction de décision

L'estimation du support de densité peut être vu comme un problème de classification à une classe. Une bonne vision de la théorie peut être trouvée dans ([SPST⁺01], [SS02], [MMR⁺01]).

Soit $\mathbf{x} = \{x_1, \dots, x_m\}$ un ensemble de m vecteurs d'apprentissage dans l'espace des observations \mathcal{X} . On suppose que pour tout $i = 1, \dots, m$, le vecteur d'apprentissage x_i , est échantillonné selon une distribution inconnue $p(\cdot)$, indépendamment de x_j , $j \neq i$. L'objectif de la classification à une classe est d'estimer une région $R_{\mathbf{x}}$ de \mathcal{X} de volume minimal contenant la plupart des données x_i , $i = 1, \dots, m$. Le problème d'estimation de la région $R_{\mathbf{x}}$ peut être abordé sous l'angle de l'estimation d'une fonction de décision $F_{\mathbf{x}}$ telle que :

$$F_{\mathbf{x}}(x) > 0 \text{ si } x \in R_{\mathbf{x}} \text{ et } F_{\mathbf{x}}(x) < 0 \text{ sinon}$$

La fonction de décision $F_{\mathbf{x}}$ est valide uniquement si elle a le plus petit risque possible d'effectuer des erreurs de classification. Celles-ci se produisent lorsque des vecteurs d'apprentissage ne sont pas situés dans $R_{\mathbf{x}}$ alors qu'ils sont en réalité distribués selon $p(\cdot)$. Une fonction de coût $c(\cdot, \cdot)$ est utilisée afin de quantifier ces erreurs. Ainsi, le risque $R[F]$ d'une fonction de décision F est défini comme l'espérance du coût et s'exprime de la façon suivante :

$$R[F] = \int c(x, F(x)) dp(x) \quad (3.1)$$

La fonction de décision F_x optimale est celle qui minimise le risque $R[F]$. La densité de probabilité $p(\cdot)$ étant inconnue en pratique le risque ne peut être calculé directement. Le risque réel $R[F]$ peut cependant toujours être estimé à partir de l'ensemble d'apprentissage. Le risque empirique $R^{\text{emp}}[F]$ est un estimateur du risque $R[F]$ basé sur l'information fournie par l'ensemble d'apprentissage x . En choisissant, par exemple la fonction de coût charnière, le risque empirique s'écrit :

$$R^{\text{emp}}[F] = \frac{1}{m} \sum_{i=1}^m \max(0, 1 - F(x_i)) \quad (3.2)$$

L'apprentissage de F_x par minimisation du risque empirique est cependant un problème mal posé puisqu'il existe souvent de nombreuses fonctions F telles que $R^{\text{emp}}[F] = 0$. La fonction de décision F_x optimale doit avoir de bonnes performances de généralisation. Elle doit être capable de décider correctement si une nouvelle donnée $x \notin x$ est située dans R_x ou non. F_x doit donc être suffisamment simple pour éviter le *sur-apprentissage* et favoriser la bonne généralisation. Ainsi, on interdit certaines solutions en cherchant F_x dans un ensemble de fonction \mathcal{F} restreint, qui ne contient pas de solutions indésirables. La fonction de décision F_x optimale apprise sur l'ensemble d'apprentissage x est ainsi obtenue en résolvant le problème suivant :

$$F_x = \arg \min_{F \in \mathcal{F}} R^{\text{reg}}(F) \quad (3.3)$$

où le risque régularisé $R^{\text{reg}}[F]$ est défini par :

$$R^{\text{reg}}[F] = R^{\text{emp}}[F] + \lambda \Omega(F) \quad (3.4)$$

Le terme de pénalité $\Omega(F)$ permet de mesurer la "complexité" de F , il est indépendant de l'ensemble d'apprentissage. λ le coefficient de régularisation pondère l'influence du terme de régularisation par rapport à celle du terme d'erreur, dans l'expression à minimiser.

Les SVMs sont des systèmes d'apprentissage obéissant à ce schéma de régularisation.

3.3.4 L'approche SVM pour l'estimation du support de densité

Les SVMs sont des systèmes d'apprentissage résolvant le problème d'apprentissage par minimisation du risque régularisé, défini par l'équation (3.3), en recherchant la solution optimale F_x dans un espace de fonctions \mathcal{H} appelé espace de Hilbert à noyau reproduisant. La fonction noyau est dénotée $k(\cdot, \cdot)$.

Définition : Espace de Hilbert à noyau reproduisant [KD06]

Un espace de Hilbert \mathcal{H} est un espace non vide tel que :

1. \mathcal{H} est un espace vectoriel
2. \mathcal{H} est muni d'un produit scalaire $\langle \cdot, \cdot \rangle_{\mathcal{H}}$ et d'une norme induite telle que pour tout $f \in \mathcal{H}$, $\|f(\cdot)\|_{\mathcal{H}}^2 = \langle f(\cdot), f(\cdot) \rangle_{\mathcal{H}}$
3. \mathcal{H} est complet pour cette norme

De plus, en supposant que \mathcal{H} est un espace de fonctions $f(\cdot) : \mathcal{X} \rightarrow \mathbb{R}$, \mathcal{H} est un espace de Hilbert à noyau reproduisant si et seulement si il existe une fonction noyau $k(\cdot, \cdot)$ définie sur $\mathcal{X} \times \mathcal{X}$ et à valeurs dans \mathbb{R} possédant la propriété reproduisante : Soit f une fonction de \mathcal{H} et x une observation de \mathcal{X} pour laquelle $k(x, \cdot) \in \mathcal{H}$, alors $\langle k(x, \cdot), f(\cdot) \rangle_{\mathcal{H}} = f(x)$.

Pour les SVMs, les fonctions de décision F appartiennent à l'ensemble des fonctions \mathcal{F} suivant :

$$\mathcal{F} = \{F(\cdot) = f(\cdot) + b \text{ tel que } f \in \mathcal{H} \text{ et } b \in \mathbb{R}\} \quad (3.5)$$

En pratique, le produit scalaire défini sur \mathcal{H} , ne peut généralement pas être écrit sous une forme explicite. Cependant, tout ce que nous avons besoin de savoir est qu'il a les propriétés d'un produit scalaire et qu'il permet à un noyau d'avoir la propriété reproduisante. Ceci signifie que pour tout $x, x' \in \mathcal{X}$ on a $\langle k(x, \cdot), k(x', \cdot) \rangle_{\mathcal{H}} = k(x, x')$. L'ensemble \mathcal{F} des fonctions de décision possibles est spécifié par la sélection d'un noyau $k(\cdot, \cdot)$. Pour que ce noyau soit un noyau reproduisant d'un certain espace de Hilbert \mathcal{H} il faut qu'il soit défini positif (conditions de Mercer). Un noyau très utilisé en apprentissage automatique est le noyau gaussien :

$$\text{Pour } x \text{ et } x' \in \mathcal{X}, k(x, x') = \exp\left(-\frac{\|x - x'\|_{\mathcal{X}}^2}{2\sigma^2}\right) \text{ avec } \sigma > 0 \quad (3.6)$$

Pour les SVMs, la fonction de coût charnière $c(x, F(x)) = \max(0, 1 - F(x))$ est choisie et le terme de pénalité $\Omega(F)$ est le carré de la norme induite dans \mathcal{H} , i.e., $\Omega(F) = \|f\|_{\mathcal{H}}^2$. Pour tout x , à partir de la propriété reproduisante, $F(x) = \langle k(x, \cdot), f(\cdot) \rangle_{\mathcal{H}} + b$, ce qui signifie qu'évaluer F pour une donnée x est une opération affine en terme d'éléments de \mathcal{H} et une opération non-linéaire en termes d'éléments de \mathcal{X} . Ainsi, le risque régularisé de l'équation (3.4), pour les SVMs s'écrit :

$$R^{\text{reg}}[F] = \frac{1}{m} \sum_{i=1}^m \max(0, 1 - \langle k(x_i, \cdot), f(\cdot) \rangle_{\mathcal{H}} - b) + \lambda \|f\|_{\mathcal{H}}^2 \quad (3.7)$$

Dans la section suivante, l'approche SVM pour l'estimation de support de densité est présentée en termes de considérations géométriques dans l'espace des hypothèses \mathcal{H} . Ainsi, le problème de minimisation du risque $R^{\text{reg}}[F]$ de l'équation (3.7) peut se mettre sous la forme d'un problème d'optimisation quadratique.

3.3.5 Interprétation géométrique de l'approche SVM

3.3.5.1 Mise en forme du problème

Soit un ensemble de m observations $\mathbf{x} = \{x_1, \dots, x_m\}$ de l'espace des observations \mathcal{X} échantillonnées selon une densité de probabilité inconnue $p(\cdot)$ et soit \mathcal{H} un espace de Hilbert à noyau reproduisant. La fonction noyau $k(\cdot, \cdot)$ définie sur $\mathcal{X} \times \mathcal{X}$ est telle que :

$$\forall (x_i, x_j) \in \mathcal{X} \times \mathcal{X}, \quad k(x_i, x_j) = \langle k(x_i, \cdot), k(x_j, \cdot) \rangle_{\mathcal{H}} \quad (3.8)$$

où le vecteur $k(x_i, \cdot)$ représentent l'observation x_i de \mathcal{X} dans l'espace \mathcal{H} .

On suppose que le noyau $k(\cdot, \cdot)$ est normalisé de sorte que pour tout $x \in \mathcal{X}$, $k(x, x) = 1$. En fait, il est possible de définir à partir de tout noyau k satisfaisant l'équation (3.8) un noyau admissible k' tel que $k'(x, x) = 1$ en posant :

$$k'(x_i, x_j) = \frac{k(x_i, x_j)}{\sqrt{k(x_i, x_i)}\sqrt{k(x_j, x_j)}} \quad (3.9)$$

on note que $k(x, x)$ ne peut être nul puisque le noyau k est défini positif. Ainsi pour tout $x \in \mathcal{X}$, $\|k(x, \cdot)\|^2 = \langle k(x, \cdot), k(x, \cdot) \rangle_{\mathcal{H}} = k(x, x) = 1$. Les vecteurs $k(x, \cdot)$ représentant les observations de \mathcal{X} dans l'espace \mathcal{H} sont par conséquent situés sur la sphère \mathcal{S} de rayon 1 et ayant pour centre l'origine \mathcal{O} de \mathcal{H} . L'approche SVM pour la classification consiste à construire un hyperplan \mathcal{W} dans \mathcal{H} qui sépare la majeure partie des vecteurs $k(x, \cdot)$ du centre \mathcal{O} de l'hypersphère \mathcal{S} , voir figure 3.4.

Un hyperplan de l'espace des hypothèses est défini de la façon suivante :

$$\{k(x, \cdot) \in \mathcal{H} \mid \langle f(\cdot), k(x, \cdot) \rangle_{\mathcal{H}} + b = 0\} \quad \text{avec } f(\cdot) \in \mathcal{H}, \text{ et } b \in \mathbb{R} \quad (3.10)$$

L'hyperplan séparateur \mathcal{W} est telle que pour la majeure partie des vecteurs $k(x, \cdot)$ on a : $\langle f(\cdot), k(x, \cdot) \rangle_{\mathcal{H}} + b \geq 0$. Ainsi, choisir l'hyperplan \mathcal{W} est équivalent à choisir la fonction de décision $F_x(x) = \langle f(\cdot), k(x, \cdot) \rangle_{\mathcal{H}} + b$ avec $f(\cdot) \in \mathcal{H}$. $F_x(x)$ définit le segment de l'hypersphère dans \mathcal{H} où $F_x(x) \geq 0$, c'est à dire le support de la densité de probabilité inconnue $p(\cdot)$ dans \mathcal{X} (i.e. R_x).

L'hyperplan séparateur \mathcal{W} est choisi de sorte que la distance le séparant de l'origine \mathcal{O} de l'espace des hypothèses soit maximale. La distance de l'origine \mathcal{O} à l'hyperplan \mathcal{W} vaut $\frac{b}{\|f(\cdot)\|_{\mathcal{H}}}$, ainsi maximiser cette distance est donc équivalent à résoudre le problème :

$$\min_{f(\cdot) \in \mathcal{H}, b \in \mathbb{R}} \frac{1}{2} \|f(\cdot)\|_{\mathcal{H}}^2 - b \quad (3.11)$$

Pour que tous les $k(x_i, \cdot)$ soient dans le demi-espace délimité par \mathcal{W} qui ne contient pas \mathcal{O} , il faut que $\langle f(\cdot), k(x_i, \cdot) \rangle_{\mathcal{H}} \geq b$. Cependant, en pratique certains vecteurs de l'espace




FIG. 3.4: Dans l'espace des hypothèses, l'estimée du support de densité R_x est le segment de l'hypersphère \mathcal{S} délimité par l'hyperplan séparateur \mathcal{W} . L'approche SVM pour l'estimation de la région R_x minimise le volume de la boule de \mathcal{H} contenant la plupart des observations de l'ensemble d'apprentissage. Ceci est équivalent à maximiser la distance entre l'hyperplan \mathcal{W} et l'origine \mathcal{O} de \mathcal{H} .

d'observation \mathcal{X} peuvent ne pas être représentatifs de la donnée considérée, on parle d'observations *anormales*¹. Une version à *marge douce* de la méthode (approche ν -SVM) permet alors de relâcher cette contrainte pour certains points grâce à l'introduction de variables de relâchement $\xi_i \geq 0$:

$$\langle f(\cdot), k(x_i, \cdot) \rangle_{\mathcal{H}} \geq b - \xi_i \quad \text{pour } i = 1, \dots, m$$

où $\frac{\xi_i}{\|f(\cdot)\|_{\mathcal{H}}}$ est la distance de $k(x_i, \cdot)$ à l'hyperplan \mathcal{W} lorsque $k(x_i, \cdot)$ est situé du mauvais côté de l'hyperplan. On peut noter que $\xi_i = 0$ lorsque $k(x_i, \cdot)$ est situé du bon côté de l'hyperplan. Pour minimiser le nombre de ces points, le critère (3.11) est pénalisé pour des valeurs non nulles de ξ_i :

$$\min_{f(\cdot) \in \mathcal{H}, \xi \in \mathbb{R}^m, b \in \mathbb{R}} \frac{1}{2} \|f(\cdot)\|_{\mathcal{H}}^2 + \frac{1}{\nu m} \sum_{i=1}^m \xi_i - b$$

où $\frac{1}{\nu m}$ est le paramètre qui pondère l'influence respective de la maximisation de la distance $\frac{b}{\|f(\cdot)\|_{\mathcal{H}}}$ et de la relaxation.

Ainsi, dans l'approche ν -SVM pour l'estimation de support de densité, le problème géométrique dans \mathcal{H} revient à résoudre le problème d'optimisation défini par le critère

¹ *Outliers* en anglais

quadratique suivant :

$$\min_{f(\cdot) \in \mathcal{H}, \xi \in \mathbb{R}^m, b \in \mathbb{R}} \frac{1}{2} \|f(\cdot)\|_{\mathcal{H}}^2 + \frac{1}{\nu m} \sum_{i=1}^m \xi_i - b \quad (3.12)$$

sous les contraintes linéaires :

$$\langle f(\cdot), k(x_i, \cdot) \rangle_{\mathcal{H}} \geq b - \xi_i \quad , \quad \xi_i \geq 0 \quad \text{pour } i = 1, \dots, m \quad (3.13)$$

3.3.5.2 Résolution du problème d'optimisation

Le critère défini par l'équation (3.12) étant quadratique, et les contraintes (3.13) linéaires, la méthode des multiplicateurs de Lagrange peut être utilisée. En introduisant les multiplicateurs de Lagrange positifs $\alpha = \{\alpha_1, \dots, \alpha_m\}$, $\beta = \{\beta_1, \dots, \beta_m\}$ et γ , respectivement associés aux contraintes d'adéquation aux données $\langle f(\cdot), k(x_i, \cdot) \rangle_{\mathcal{H}} \geq b - \xi_i$, de relâchement $\xi_i \geq 0$ et de positivité de la constante b on peut former le Lagrangien $L(f(\cdot), b, \xi, \alpha, \beta, \gamma)$:

$$L(f(\cdot), b, \xi, \alpha, \beta, \gamma) = \frac{1}{2} \|f(\cdot)\|_{\mathcal{H}}^2 + \frac{1}{\nu m} \sum_{i=1}^m \xi_i - b - \sum_{i=1}^m \alpha_i (\langle f(\cdot), k(x_i, \cdot) \rangle_{\mathcal{H}} - b + \xi_i) - \sum_{i=1}^m \beta_i \xi_i - \gamma b \quad (3.14)$$

Le Lagrangien doit être minimisé par rapport aux variables primales $f(\cdot)$, b , ξ et maximisé par rapport aux variables duales α , β , γ . Pour des problèmes d'optimisation convexe, les conditions de Karush-Kuhn Tucker garantissent l'existence d'un point selle et l'optimalité globale. En minimisant le Lagrangien par rapport aux variables primales, on obtient les conditions suivantes :

$$\frac{\partial}{\partial f(\cdot)} L(f(\cdot), b, \xi, \alpha, \beta, \gamma) = 0 \iff f(\cdot) = \sum_{i=1}^m \alpha_i k(x_i, \cdot) \quad (3.15)$$

$$\frac{\partial}{\partial \xi} L(f(\cdot), b, \xi, \alpha, \beta, \gamma) = 0 \iff 0 \leq \alpha_i \leq \frac{1}{\nu m} \quad (3.16)$$

$$\frac{\partial}{\partial b} L(f(\cdot), b, \xi, \alpha, \beta, \gamma) = 0 \iff \sum_{i=1}^m \alpha_i = 1 \quad (3.17)$$

Puisque $F_x(x) = \langle f(\cdot), k(x, \cdot) \rangle_{\mathcal{H}} + b$, à partir de l'expression (3.15) on peut écrire la fonction de décision sous la forme suivante :

$$F_x(\cdot) = \sum_{i=1}^m \alpha_i \langle k(x_i, \cdot), k(x, \cdot) \rangle_{\mathcal{H}} + b \quad (3.18)$$

L'espace des hypothèses \mathcal{H} étant un espace de Hilbert à noyau reproduisant, l'astuce du noyau est le passage du produit scalaire $\langle \cdot, \cdot \rangle_{\mathcal{H}}$ au noyau $k(\cdot, \cdot) = \langle \cdot, \cdot \rangle_{\mathcal{H}}$. Ce qui donne

pour la fonction de décision $F_x(\cdot)$:

$$F_x(\cdot) = \sum_{i=1}^m \alpha_i k(x_i, \cdot) + b \quad (3.19)$$

En introduisant les expressions (3.15) et (3.17) dans le Lagrangien, le problème d'optimisation sous contraintes admet la formulation duale suivante (voir [MMR⁺01]) :

$$\max_{\alpha \in \mathbb{R}^m} -\frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j k(x_i, x_j) \quad (3.20)$$

sous les contraintes linéaires :

$$0 \leq \alpha_i \leq \frac{1}{\nu m} \quad \text{pour } i = 1, \dots, m \quad \text{et} \quad \sum_{i=1}^m \alpha_i = 1 \quad (3.21)$$

Les multiplicateurs de Lagrange α_i , $i = 1, \dots, m$ obtenus par la résolution du problème dual conduisent à la fonction de décision optimale $F_x(x)$ qui s'écrit pour tout $x \in \mathcal{X}$:

$$F_x(x) = \sum_{i=1}^m \alpha_i k(x_i, x) + b \quad (3.22)$$

Ainsi, le support estimé de R_x (i.e. $\{x \in \mathcal{X} | F_x(x) = 0\}$) est obtenue en coupant l'hyper-surface $\sum_{i=1}^m \alpha_i k(x_i, x)$ à l'altitude $-b$.

Toutes les observations x_i pour lesquelles $F_x(x_i) \leq 0$ sont appelées *Observations support* (OS). Seuls les poids α_i correspondant à ces points ne sont pas nuls, les OS suffisent donc à déterminer $F_x(\cdot)$. Les OS se divisent en deux ensembles : les OS *de marge*, qui annulent la fonction de décision ($F_x(x_i) = 0$), et les OS *hors marge* qui sont tels que $F_x(x_i) < 0$, voir figure 3.5. Dans [SPST⁺01], il est montré que le paramètre de régularisation ν majore le taux d'observations support hors marge et minore le taux d'observations support. De plus, en faisant des hypothèses faibles sur la distribution à l'origine des données, ces taux sont asymptotiquement égaux à ν avec la probabilité 1. En d'autres termes, en supposant que $\nu = 0.2$, le calcul de la fonction de décision $F_x(x)$ nécessite au plus de 20% des données x_i , $i = 1, \dots, m$ de l'espace des observations \mathcal{X} .

Soit x^* l'ensemble des observations support de marge contenant m^* observations. Dans (3.22), b peut être calculé de la façon suivante :

$$b = -\frac{1}{m^*} \sum_{x_i^* \in x^*} \sum_{j=1}^m \alpha_j k(x_j, x_i^*) \quad (3.23)$$

Dans la section suivante, un algorithme de détection de ruptures en ligne à noyau, basé sur l'estimation du support de densité par SVM est présenté dans sa généralité.




FIG. 3.5: Les observations support hors de marge sont à l'extérieur de R_x . Les observations support de marge sont situées sur le support de R_x . Les observations non support sont à l'intérieur de R_x , soit au dessus de l'hyperplan \mathcal{W} de \mathcal{H} .

3.3.6 Algorithme KCD

3.3.6.1 Description de l'algorithme KCD

Considérons, un point d'analyse x_a , et deux sous-ensembles de $\mathcal{X} : \mathbf{x}_1 = \{x_{a-m_1}, \dots, x_{a-1}\}$ le sous ensemble du passé immédiat et $\mathbf{x}_2 = \{x_a, \dots, x_{a+m_2-1}\}$ le sous ensemble du futur immédiat. L'estimation SVM des supports de densité à l'origine de \mathbf{x}_1 et \mathbf{x}_2 est effectuée via le calcul des paramètres $f_1(\cdot)$, b_1 de l'hyperplan séparateur \mathcal{W}_1 et $f_2(\cdot)$, b_2 de l'hyperplan séparateur \mathcal{W}_2 , et définit les régions $R_{\mathbf{x}_1}$ et $R_{\mathbf{x}_2}$. Ainsi, lorsqu'une rupture se produit à un indice a dans la distribution des observations x , on peut s'attendre à ce que les régions $R_{\mathbf{x}_1}$ et $R_{\mathbf{x}_2}$ ne coïncident pas fortement, voir figure 3.6. En pratique, une mesure du contraste, notée $I(a)$, exprimant la dissimilarité entre \mathbf{x}_1 et \mathbf{x}_2 , via une mesure de la dissimilarité entre $R_{\mathbf{x}_1}$ et $R_{\mathbf{x}_2}$ est construite, voir [DD04]. (Le calcul de $I(a)$ pour a fixé est décrit dans la sous-section suivante.) Une fois $I(a)$ calculé, on incrémente a et l'on met à jour les sous-ensembles \mathbf{x}_1 et \mathbf{x}_2 . Les paramètres SVM b_1 , $f_1(\cdot)$ et b_2 , $f_2(\cdot)$ sont mis à jour par une technique séquentielle présentée dans ([GD03], [DDGD06]). Celle-ci permet d'éviter de recalculer complètement $f(\cdot)$, b pour chaque nouveau a . Des ruptures sont finalement détectées chaque fois que l'indice $I(a)$ présente un pic supérieur à un seuil η_a .

3.3.6.2 Mesure de dissimilarité

Dans l'espace des hypothèses, les régions Σ_1 et Σ_2 images de $R_{\mathbf{x}_1}$ et $R_{\mathbf{x}_2}$ sont de forme géométrique simple (leurs frontières sont des hypercercles \mathcal{C}_1 et \mathcal{C}_2). Une bonne




FIG. 3.6: Les estimateurs SV de support de densité permettent de définir deux régions Σ_1 et Σ_2 qui sont les estimées des supports de densité de x_1 et x_2 dans \mathcal{H} . Le cercle représenté correspond à l'intersection du plan \mathcal{P} (défini de façon unique par $f_1(\cdot)$ et $f_2(\cdot)$) et la sphère \mathcal{S} . L'intersection de la droite passant par \mathcal{O} et de vecteur directeur $f_1(\cdot)$ (resp. $f_2(\cdot)$) avec \mathcal{S} permet de définir c_1 (resp. c_2). De même, l'intersection de l'hyperplan \mathcal{W}_1 (resp. \mathcal{W}_2) avec \mathcal{S} permet de définir dans le plan \mathcal{P} deux points, dont l'un est noté p_1 (resp. p_2). La situation représentée correspond à une rupture à l'indice a , puisque les deux régions Σ_1 et Σ_2 ne se recouvrent pas.

indication de la dissimilarité entre Σ_1 et Σ_2 est donnée par la longueur de l'arc sur la sphère \mathcal{S} entre les centres de ces deux régions : c_1 et c_2 (voir figure 3.6). On note par la suite $d_{\text{arc}}(c_1, c_2)$ cette valeur. Toutefois cette mesure de dissimilarité n'est pas adapté à la détection de ruptures puisqu'elle n'est pas normalisée par rapport à la dispersion de chacun des ensembles d'apprentissage. Dans ([DD04], [DDD05]), les auteurs proposent d'utiliser une mesure du contraste entre les supports estimés des régions R_{x_1} et R_{x_2} , définie dans l'espace des hypothèses (voir figure 3.6 pour la définition de p_1 et p_2) comme :

$$D_{\mathcal{H}}(x_1, x_2) = \frac{d_{\text{arc}}(c_1, c_2)}{d_{\text{arc}}(c_1, p_1) + d_{\text{arc}}(c_2, p_2)} \quad (3.24)$$

L'équation (3.24), définit $D_{\mathcal{H}}$ comme un rapport inter-régions et intra-régions de \mathcal{H} . En se restreignant à l'ensemble d'apprentissage x_1 on peut voir que la longueur de l'arc entre c_1 et p_1 est une mesure de l'étalement des échantillons de $k(x_1, \cdot)$ dans \mathcal{H} . Plus ils sont dispersés, plus grande est la valeur de $d_{\text{arc}}(c_1, p_1)$, et plus faible est la marge $b_1 / \|f_1(\cdot)\|_{\mathcal{H}}$. La mesure de dissimilarité $D_{\mathcal{H}}$ a le comportement souhaité dans \mathcal{H} puisqu'elle prend des valeurs grandes pour deux ensembles d'apprentissage bien séparés, et des valeurs faibles lorsqu'ils occupent la même région de l'espace.

La mesure de dissimilarité $D_{\mathcal{H}}$ est définie dans l'espace des hypothèses \mathcal{H} . Pour être exploitable en pratique, il faut pouvoir la calculer dans l'espace des observations \mathcal{X} . Le

calcul de $D_{\mathcal{H}}$ dans \mathcal{X} est possible uniquement s'il peut être exprimé comme une fonction d'un noyau $k(.,.)$ appliquée aux observations de \mathcal{X} .

Dans l'espace des hypothèses, la longueur de l'arc entre deux vecteurs \mathbf{a} et \mathbf{b} de norme 1 vaut :

$$d_{\text{arc}}(\mathbf{a}, \mathbf{b}) = \widehat{\mathbf{aOb}} \quad (3.25)$$

où $\widehat{\mathbf{aOb}}$ est l'angle entre \mathbf{a} et \mathbf{b} . De plus, en supposant toujours que \mathbf{a} et \mathbf{b} sont de norme 1 on a :

$$\langle \mathbf{a}, \mathbf{b} \rangle_{\mathcal{H}} = \|\mathbf{a}\|_{\mathcal{H}} \|\mathbf{b}\|_{\mathcal{H}} \cos(\widehat{\mathbf{aOb}}) = \cos(\widehat{\mathbf{aOb}}) \quad (3.26)$$

En réunissant ces deux équations, il devient possible d'exprimer la longueur de l'arc entre \mathbf{a} et \mathbf{b} de la façon suivante :

$$d_{\text{arc}}(\mathbf{a}, \mathbf{b}) = \arccos(\langle \mathbf{a}, \mathbf{b} \rangle_{\mathcal{H}}) \quad (3.27)$$

Le produit scalaire qui apparaît à l'équation (3.26) s'exprime en fonction d'un noyau $k(.,.)$ évalué sur l'ensemble d'apprentissage seulement si \mathbf{a} et \mathbf{b} sont dans l'espace vectoriel engendré par les images des observations de \mathcal{X} . Dans notre cas, $d_{\text{arc}}(\mathbf{c}_1, \mathbf{c}_2)$ peut effectivement s'exprimer en fonction de noyaux $k(.,.)$. Comme $\mathbf{c}_1 = \mathbf{f}_1(./)\|\mathbf{f}_1(.)\|_{\mathcal{H}}$ et $\mathbf{c}_2 = \mathbf{f}_2(./)\|\mathbf{f}_2(.)\|_{\mathcal{H}}$ il vient :

$$d_{\text{arc}}(\mathbf{c}_1, \mathbf{c}_2) = \arccos\left(\frac{\langle \mathbf{f}_1(.), \mathbf{f}_2(.) \rangle_{\mathcal{H}}}{\|\mathbf{f}_1(.)\|_{\mathcal{H}} \|\mathbf{f}_2(.)\|_{\mathcal{H}}}\right) \quad (3.28)$$

En utilisant le fait que $\mathbf{f}_1(.)$ et $\mathbf{f}_2(.)$ s'écrivent comme des combinaisons linéaires de noyaux (voir équation 3.15), il vient :

$$\frac{\langle \mathbf{f}_1(.), \mathbf{f}_2(.) \rangle_{\mathcal{H}}}{\|\mathbf{f}_1(.)\|_{\mathcal{H}} \|\mathbf{f}_2(.)\|_{\mathcal{H}}} = \frac{\boldsymbol{\alpha}_1^T \mathbf{K}_{12} \boldsymbol{\alpha}_2}{\sqrt{\boldsymbol{\alpha}_1^T \mathbf{K}_{11} \boldsymbol{\alpha}_2} \sqrt{\boldsymbol{\alpha}_2^T \mathbf{K}_{22} \boldsymbol{\alpha}_2}} \quad (3.29)$$

où $\boldsymbol{\alpha}_1$ (resp. $\boldsymbol{\alpha}_2$) est le vecteur colonne composé des multiplicateurs de Lagrange définissant $\mathbf{f}_1(.)$ (resp. $\mathbf{f}_2(.)$) calculés pendant l'apprentissage. La matrice noyau K_{uv} , $(u, v) \in \{1, 2\} \times \{1, 2\}$ a son élément courant à la ligne $\#i$ et la colonne $\#j$ donnée par : $k(x_u^i, x_v^j)$ où x_u^i est l'observation $\#i$ dans l'ensemble d'apprentissage \mathbf{x}_u .

Des calculs semblables permettent de calculer $d_{\text{arc}}(\mathbf{c}_1, \mathbf{p}_1)$ et $d_{\text{arc}}(\mathbf{c}_2, \mathbf{p}_2)$ dans \mathcal{X} :

$$d_{\text{arc}}(\mathbf{c}_i, \mathbf{p}_i) = \arccos \frac{b_i}{\sqrt{\boldsymbol{\alpha}_i^T \mathbf{K}_{ii} \boldsymbol{\alpha}_i}} \quad , \quad i = \{1, 2\} \quad (3.30)$$

Ainsi la mesure du contraste $I(a) = \mathcal{D}_{\mathcal{H}}(\mathbf{x}_1, \mathbf{x}_2)$ pour a fixé peut être calculé dans l'espace des observations \mathcal{X} .

3.3.6.3 Synthèse

La mesure de dissimilarité étant définie on peut présenter l'algorithme de détection de ruptures en ligne à noyau dans son ensemble. L'algorithme 1 résume toute la procédure. On suppose qu'une étape intermédiaire a permis l'extraction d'une série d'observations d'une donnée Bscan, notée x_a , $a = 1, 2, \dots$

Algorithme 1 : Algorithme de détection de ruptures à noyaux (KCD) [DDD05]

Etape 0 : Initialisation

- Choisir la taille des ensembles d'apprentissage m_1 , m_2 , le paramètre de régularisation ν et la valeur du seuil η_a .
- Choisir $k(\cdot, \cdot)$ un noyau gaussien et régler le paramètre de dispersion σ .
- Prendre $a \leftarrow m_1 + 1$.

Etape 1 : Détection de ruptures en ligne à noyau

- Les supports des densités de probabilité de l'ensemble du passé immédiat $\mathbf{x}_1 = \{x_{a-m_1}, \dots, x_{a-1}\}$ et de celui du futur immédiat $\mathbf{x}_2 = \{x_a, \dots, x_{a+m_2-1}\}$ pour l'indice a sont estimés indépendamment grâce à des estimateurs SV de support de densité. Les paramètres $(f_1(\cdot), b_1)$ et $(f_2(\cdot), b_2)$ sont obtenus.
 - Calculer l'indice de décision $I(a) = \mathcal{D}_{\mathcal{H}}(\mathbf{x}_1, \mathbf{x}_2)$ définie par (3.24).
 - Selon $I(a)$ décider :
 - si $I(a) \geq \eta_a$ alors un changement est détecté à l'indice a .
 - si $I(a) < \eta_a$ alors aucun changement n'est détecté à l'indice a .
 - Incrémenter $a \leftarrow a + 1$ et retourner à l'Étape 1.
-

Dans l'algorithme 1, une rupture est détectée à chaque fois que l'indice de décision $I(a)$ présente un pic au dessus d'un certain seuil η_a . Cette approche est classique [BN93], et le seuil η_a règle le taux de faux positifs et de faux négatifs. Pour tester l'indice a , il faut connaître la série des observations jusqu'à l'indice $a + m_2 - 1$.

Grâce à la technique séquentielle présentée dans ([GD03], [DDGD06]) les paramètres SVM $(f_i(\cdot), b_i)$ ($i = 1, 2$) sont mis à jour sans recalculer complètement $(f(\cdot), b)$ pour chaque nouveau a . Le coût de calcul de l'algorithme KCD est par conséquent faible.

Dans la section suivante la méthode de détection et de localisation des mines antipersonnel est présentée.

3.4 Méthode de détection de mines antipersonnel

La méthode de détection de mines antipersonnel proposée consiste à détecter les ruptures dans des données Bscan, suivant à la fois une dimension spatiale l et une dimension temporelle t . Des informations relatives à la profondeur et la position des mines pourront ainsi être extraites par la suite. Plus précisément, la procédure est constituée de deux étapes :

- Etape 1 : Les ruptures spatiales (suivant l) sont recherchées afin de détecter les positions horizontales des mines dans la donnée Bscan considérée.
- Etape 2 : Les ruptures temporelles (suivant t) sont recherchées afin de détecter les temps de réponse des objets. Le clutter doit être préalablement réduit afin d'éviter de détecter les bandes du clutter à la place d'objets enfouis.

Les étapes 1 et 2 de la méthode sont décrites précisément dans les sections 3.4.1 et 3.4.2.

3.4.1 Etape 1 : Détection des positions horizontales

Les données utilisées par l'algorithme de détection de ruptures pour former les ensembles d'observations sont extraites du Bscan de la façon suivante. Chaque vecteur x_a est constitué d'un Ascan (i.e. une colonne d'un Bscan). A chaque position horizontale l (ainsi $a \equiv l$), deux ensembles d'observations \mathbf{x}_1 et \mathbf{x}_2 constitués respectivement de m_1 et m_2 Ascans sont construits. On peut noter que l'algorithme KCD peut être implémenté en ligne suivant la coordonnée spatiale l . En d'autres termes, il n'est pas nécessaire d'avoir la donnée Bscan entière pour chercher les ruptures suivant l . La mesure du contraste $I_1(l)$ est calculée par la méthode décrite dans le paragraphe 3.3.6.2. Les ruptures spatiales sont détectées chaque fois que l'indice $I_1(l)$ est plus grand que le seuil η_l qui est déterminé de manière expérimentale. Ceci signifie que les deux ensembles d'observations diffèrent significativement et qu'il peut y avoir un objet enfoui ou une mine antipersonnel. Une fois que $I_1(l)$ est calculé, les ensembles d'observations \mathbf{x}_1 et \mathbf{x}_2 sont mis à jour à la coordonnée spatiale $l + 1$ en incorporant l'Ascan suivant dans \mathbf{x}_2 et en retirant le plus ancien Ascan de \mathbf{x}_1 , et ainsi de suite. L'algorithme 2 résume la procédure de détection des positions horizontales d'un objet sur une donnée Bscan.

Un objet enfoui est caractérisé par deux ruptures proches suivant l qui indiquent les limites de l'objet dans le Bscan et par conséquent les positions horizontales où il se situe. Il est ensuite important de noter que l'étape 2 de la méthode de détection n'est appliquée que si au moins un objet enfoui a été détecté dans le Bscan à l'étape 1.

Algorithme 2 : Algorithme de détection des positions horizontales d'un objet enfoui.

Etape 0 : Extraction des observations d'un Bscan

- Soit $\mathcal{Y}_1 = \{x_1, \dots, x_N\}$ un Bscan constitué de N Ascans où x_i est un Ascan.
- Chaque observation x_l extraite de \mathcal{Y}_1 est constitué d'un Ascan.

Etape 1 : Initialisation

- Choisir la taille des ensembles d'apprentissage m_1, m_2 , le paramètre de régularisation ν et la valeur du seuil η_l .
- Choisir $k(\cdot, \cdot)$ un noyau gaussien et régler le paramètre de dispersion σ .
- Prendre $l \leftarrow m_1 + 1$.

Etape 2 : Détection des ruptures suivant l

- Les supports des densités de probabilité de l'ensemble du passé immédiat $\mathbf{x}_1 = \{x_{l-m_1}, \dots, x_{l-1}\}$ et de celui du futur immédiat $\mathbf{x}_2 = \{x_l, \dots, x_{l+m_2-1}\}$ pour la position l sont estimés indépendamment grâce à des estimateurs SV de support de densité. Les paramètres $(f_1(\cdot), b_1)$ et $(f_2(\cdot), b_2)$ sont obtenus.
 - Calculer l'indice de décision $I_1(l) = \mathcal{D}_{\mathcal{H}}(\mathbf{x}_1, \mathbf{x}_2)$ définie par (3.24).
 - Selon $I_1(l)$ décider :
 - si $I_1(l) \geq \eta_l$ alors un objet est détecté à la position l .
 - si $I_1(l) < \eta_l$ alors il n'y a pas d'objet détecté à la position l .
 - Incrémenter $l \leftarrow l + 1$ et retourner à l'Étape 2.
-

3.4.2 Etape 2 : Détection des temps de réponse

Dans un premier temps le Bscan est prétraité par le filtre numérique conçu pour la réduction de clutter (voir section 2.2.3). En fonction du nombre d'objets détectés dans le Bscan à l'étape 1, la donnée Bscan filtrée est divisée en sous-Bscans de sorte que chaque sous-Bscan ne contient la réponse que d'un seul objet, voir figure 3.7. On sélectionne ensuite un tel sous-Bscan.

Des données utilisées pour former les ensembles d'observations pour l'algorithme KCD sont extraites du sous-Bscan prétraité. Chaque vecteur x_a est constitué d'une ligne du sous-Bscan. A chaque instant t (ainsi $a \equiv t$), deux ensembles d'observations $\mathbf{x}_1, \mathbf{x}_2$ constitués respectivement de m_1 et m_2 lignes du sous-Bscan sont construits. La mesure du contraste $I_2(t)$ est calculée par l'algorithme KCD. Les ruptures temporelles sont détectées chaque fois que l'indice $I_2(t)$ est plus grand qu'un seuil η_t , déterminé expérimentalement. Une fois $I_2(t)$ calculé, les deux ensembles d'observations sont mis à jour à l'instant $t + 1$.

Les multiples réflexions qui se produisent entre les objets enfouis et les antennes du GPR ainsi que les résidus du clutter peuvent être à l'origine de nombreuses ruptures. Par conséquent, il peut être difficile de déterminer automatiquement les temps de réponse des objets enfouis. C'est la raison pour laquelle la mesure du contraste $I_2(t)$ est remplacée par une nouvelle mesure $\tilde{I}_2(t)$ afin d'introduire un poids sur chacune des ruptures.

A chaque instant t , $\tilde{I}_2(t)$ s'exprime en tant que produit de la mesure du contraste $I_2(t)$ par la fonction de poids $I_m(t)$, i.e. :

$$\forall t \in [0, \dots, (N-1)T_s], \quad \tilde{I}_2(t) = I_2(t)I_m(t) \quad (3.31)$$

avec T_s la période d'échantillonnage et N le nombre d'échantillons. La fonction de poids $I_m(t)$ est construite de la façon suivante. Dans un premier temps, un seuillage sur l'amplitude du sous-Bscan prétraité est réalisé. On note que le seuillage est une technique couramment utilisée en traitement d'image afin de supprimer le bruit lorsque le rapport signal sur bruit est grand. Après une bonne réduction du clutter, les signaux provenant des objets enfouis sont souvent prédominants dans le Bscan, le seuillage permet donc d'éliminer certains résidus de clutter ainsi que les réponses provenant des réflexions multiples du pulse émis par le GPR sur l'objet, dont l'amplitude est faible. Ainsi, les amplitudes des échantillons du sous-Bscan suivant l et t en dessous du seuil S choisi sont mises à zéro. Soit $A_l(t)$ la donnée Ascan du sous-Bscan, enregistrée à la position l , on a :

$$\forall t \in [0, \dots, (N-1)T_s], \quad A_l(t) = 0 \quad \text{si} \quad A_l(t) < S \quad (3.32)$$

Ensuite, la dérivée temporelle d'ordre 1 de chaque Ascan du sous-Bscan est calculée. Les données Ascans étant échantillonnées suivant t , la dérivée temporelle d'ordre 1 de l'Ascan enregistré à la position l , est approximée de la façon suivante :

$$\frac{\partial A_l(t)}{\partial t} \simeq \frac{A_l(t) - A_l(t - T_s)}{T_s}, \quad t \in [0, \dots, (N-1)T_s] \quad (3.33)$$

Enfin, la fonction de poids, dénotée $I_m(t)$, est égale à la moyenne des valeurs absolues des dérivées temporelles des Ascans.

$$\forall t \in [0, \dots, (N-1)T_s], \quad I_m(t) = \frac{1}{N_l} \sum_{l=1}^{N_l} \left| \frac{A_l(t) - A_l(t - T_s)}{T_s} \right| \quad (3.34)$$

avec N_l le nombre de Ascans constituant le sous-Bscan. $I_m(t)$ indique les variations de l'amplitude du signal en fonction du temps. Par conséquent, en multipliant $I_2(t)$ par $I_m(t)$ à chaque instant t , ceci conduit à augmenter significativement l'amplitude des ruptures provenant de la réponse d'un objet en comparaison de celle provenant des résidus de clutter et des réponses engendrées par les réflexions multiples du pulse émis par le GPR sur l'objet. L'algorithme 3 résume la procédure de détection des temps de réponse des objets enfouis.

Algorithme 3 : Algorithme de détection des temps de réponse d'un objet enfoui.

Etape 0 : Prétraitement de la donnée Bscan

- La donnée Bscan est prétraitée par le filtre numérique adapté défini dans la section 2.2.3 afin d'éliminer les bandes du clutter.

Etape 1 : Sélection d'un sous-Bscan

- Sélection d'un sous-Bscan \mathcal{Y}_2 contenant la réponse d'un seul objet détecté dans la donnée Bscan \mathcal{Y}_1 par l'algorithme 2.

Etape 2 : Extraction des observations d'un sous-Bscan

- Soit $\mathcal{Y}_2 = \{x_1, \dots, x_M\}$ un sous-Bscan constitué de M lignes où x_i dénote une ligne d'un Bscan.
- Chaque observation x_t extraite est constituée d'une ligne de \mathcal{Y}_2 .

Etape 3 : Initialisation

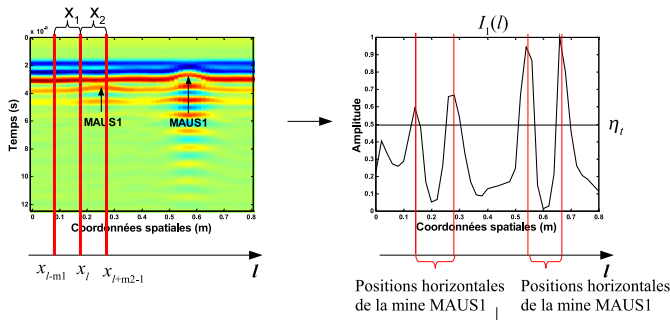
- Choisir la taille des ensembles d'apprentissage m_1, m_2 , le paramètre de régularisation ν et la valeur du seuil η_t .
- Choisir $k(\cdot, \cdot)$ un noyau gaussien et régler le paramètre de dispersion σ .
- Prendre $t \leftarrow m_1 + 1$.

Etape 4 : Détection des ruptures suivant t

- Les supports des densités de probabilité de l'ensemble du passé immédiat $\mathbf{x}_1 = \{x_{t-m_1}, \dots, x_{t-1}\}$ et de celui du futur immédiat $\mathbf{x}_2 = \{x_t, \dots, x_{t+m_2-1}\}$ pour l'instant t sont estimés indépendamment grâce à des estimateurs SV de support de densité. Les paramètres $(f_1(\cdot), b_1)$ et $(f_2(\cdot), b_2)$ sont obtenus.
- Calculer l'indice de décision $I_2(t) = \mathcal{D}_{\mathcal{H}}(\mathbf{x}_1, \mathbf{x}_2)$ définie par (3.24).
- Calculer la nouvelle mesure du contraste $\tilde{I}_2(t) = I_m(t)I_2(t)$
- Selon $\tilde{I}_2(t)$ décider :
 - si $\tilde{I}_2(t) \geq \eta_t$, le temps de réponse d'un objet est détecté à l'instant t .
 - si $\tilde{I}_2(t) < \eta_t$, il n'y a pas d'objet détecté à l'instant t .
- Incrémenter $t \leftarrow t + 1$ et retourner à l'Étape 4.

La figure 3.7 illustre la méthode de détection de mines antipersonnel sur une donnée Bscan réelle de la campagne MACADAM dans son ensemble.

Etape 1: Détection des positions horizontales



Etape 2: Détection des temps de réponse

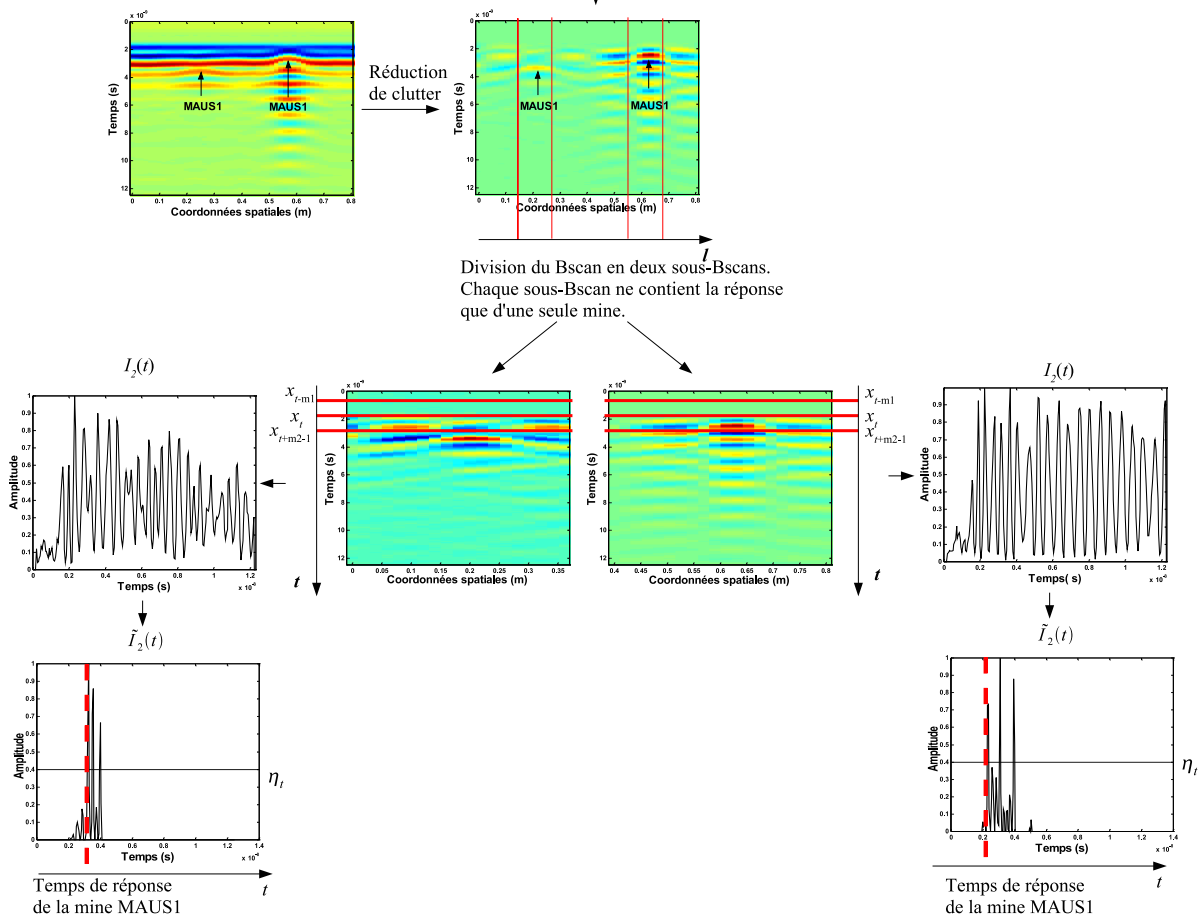


FIG. 3.7: Méthode de détection de mines antipersonnel. L'étape 1 consiste à détecter les positions horizontales des mines dans la donnée Bscan. L'étape 2 consiste à détecter les temps de réponses des mines détectées à l'étape 1.

3.4.3 Réglage des paramètres

Les paramètres des algorithmes 2 et 3 de la méthode de détection sont ν , m_1 , m_2 , ceux du noyau $k(\cdot, \cdot)$ (i.e. σ pour le noyau Gaussien), et les seuils de détection η_l et η_t .

Le réglage des tailles des ensembles d'apprentissage (m_1, m_2) , est généralement imposé par les dynamiques du signal considéré. De faibles valeurs de m_1 et m_2 permettent à l'algorithme KCD de détecter des changements fréquents tandis que de grandes valeurs de m_1 et m_2 permettent la détection de changements à long terme. Dans le cadre de la détection de mines antipersonnel, le pulse émis est de courte durée (quelques nanosecondes) par conséquent, si l'on veut détecter les temps de réponses des objets, il nous faut détecter les petits changements suivant t dans le signal réfléchi. Le diamètre des mines étant de l'ordre d'une dizaine de centimètres, la réponse d'une mine à un pulse émis par le GPR n'apparaît que sur un petit nombre de Ascans, il faut donc également détecter suivant l les changements à court terme. De ce fait, pour les algorithmes 2 et 3, m_1 et m_2 sont de petites tailles, on prend $m_1 = m_2 = 5$ pour les données Bscan réelles de la campagne MACADAM.

L'utilisation d'un noyau classique pour l'estimateur SV, tel que le noyau Gaussien, a suffi à obtenir de bons résultats pour la détection de ruptures sur une donnée Bscan. Pour un noyau Gaussien, le paramètre de dispersion σ détermine la localisation des images des observations sur l'hypersphère \mathcal{S} . Un choix heuristique courant pour σ est de le choisir d'un ordre de grandeur plus faible que la distance moyenne des $\|x - x'\|_{\mathcal{X}}$, voir [DDD05].

Le taux asymptotique d'observations anormales ν est réglé selon les critères de détection : pour la détection de mines antipersonnel, les performances obtenues à la détection varient peu pour des valeurs de ν comprises entre 0.2 et 0.8. Pour nos simulations, on choisit $\nu = 0.5$.

Le seuil S utilisé, pour construire la mesure du contraste $\tilde{I}_2(t)$, est choisi de sorte que les amplitudes des échantillons du sous-Bscan inférieures à 40% de la valeur maximale parmi les amplitudes des échantillons du sous-Bscan, soient mises à zéro.

Enfin, il n'y a pas de réglage automatique pour les seuils η_l et η_t . Pour la détection de mines antipersonnel, une analyse des résultats de simulation sur une donnée Bscan contenant la réponse d'une mine a été utilisée pour sélectionner η_l et η_t .

3.5 Simulations

3.5.1 Données synthétiques

La méthode décrite précédemment est appliquée à la donnée Bscan synthétique de la figure 3.8. La méthode split step 2D présentée dans [BG98] a été utilisée pour créer ce Bscan. Un pulse électromagnétique, modélisé par une fonction Gaussienne, a été envoyé à une hauteur de 12 cm au dessus d'un sol homogène dans lequel deux objets ont été enfouis. La fréquence centrale du spectre du pulse est de 900 MHz. Pour appliquer la méthode split step, la permittivité diélectrique (ε_r) et le facteur de qualité (Q) du sol et des objets doivent être connus. Le couplage entre les antennes émettrice et réceptrice du

GPR n'est pas pris en considération. Les paramètres de la simulation sont donnés dans le tableau 3.1.




FIG. 3.8: Donnée Bscan synthétique contenant les réponses de deux objets enfouis. L'un est situé aux positions horizontales $\{0.33, \dots, 0.63\}$ et à une profondeur de 7 cm. L'autre est situé aux positions horizontales $\{1.73, \dots, 2.03\}$ et à une profondeur de 2 cm.

TAB. 3.1: Paramètres de simulation

	Objet 1	Objet 2	sol
(ε_r, Q)	(5,500)	(5,500)	(9,100)
Coordonnées spatiales	$\{0.33, \dots, 0.63\}$	$\{1.73, \dots, 2.03\}$	-
Profondeur	7 cm	2 cm	-

Les positions des objets et les paramètres physiques du sol étant connus, il est possible de calculer le temps de réponse, dénoté t_r , de chacun des objets enfouis.

$$t_r = \frac{2h_r}{c} + \frac{2z_0\sqrt{\varepsilon_{rs}}}{c} \quad (3.35)$$

avec c la vitesse de propagation de l'onde électromagnétique dans l'air, h_r la hauteur du radar, z_0 la profondeur de l'objet et ε_{rs} la permittivité diélectrique relative du sol. Ainsi, les positions horizontales et les temps de réponse des mines sont connus et peuvent être comparés à ceux trouvés en appliquant la méthode de détection de mines antipersonnel proposée dans la section 3.4.

L'étape 1 de la méthode consiste à détecter les positions horizontales des objets enfouis. Des données Ascans sont extraites du Bscan afin de former les ensembles d'observation \mathbf{x}_1 et \mathbf{x}_2 . Ces ensembles sont de tailles respectives $m_1 = 7$ et $m_2 = 7$. Le paramètre de dispersion σ du noyau Gaussien est égal à 10 et le taux d'observations anormales ν est égale à 0.5. La figure 3.9 montre la mesure du contraste $I_1(l)$, calculée par l'intermédiaire de l'algorithme 2. En prenant le seuil de détection η_l égal à 0.5, les ruptures causées par les réponses des deux objets enfouis sont correctement détectées.

Le premier objet est situé entre les deux premières ruptures détectées, i.e. aux positions $l = \{0.38, \dots, 0.58\}$ du Bscan. Le second objet est situé entre les deux ruptures suivantes détectées, i.e. aux positions $l = \{1.75, \dots, 2\}$ du Bscan. Pour un seuil η_l inférieur à 0.5, d'autres ruptures sont susceptibles d'être détectées. Les ruptures aux positions $l = 1.18$ et $l = 1.4$ proviennent du croisement entre les branches des signatures hyperboliques des deux objets. Ainsi, pour un seuil de détection $\eta_l = 0.3$, un faux objet est détecté aux positions horizontales $l = \{1.18, \dots, 1.4\}$.

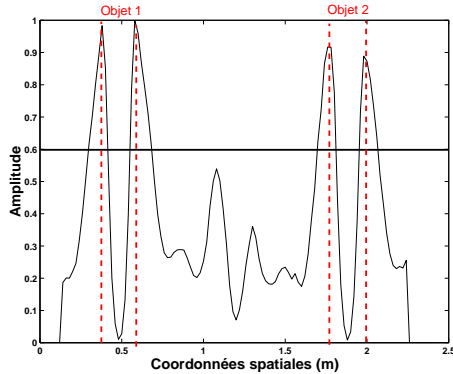


FIG. 3.9: Mesure du contraste $I_1(l)$ pour le Bscan de la figure 3.8. Deux objets enfouis ont été détectés. L'un est situé entre les positions horizontales $l = 0.38$ et $l = 0.58$ et l'autre entre $l = 1.75$ et $l = 2$.




FIG. 3.10: Sous-Bscan, prétraité par filtrage numérique, contenant la réponse de l'objet détecté aux positions horizontales $l = \{0.38, \dots, 0.58\}$.

L'étape 2 consiste à détecter les temps de réponse des objets enfouis. Pour ne pas détecter les ruptures provenant des bandes du clutter, il est nécessaire de prétraiter la donnée Bscan de façon à réduire le clutter. On choisit d'utiliser pour cela le filtre numérique proposé dans le chapitre 2. En effet, il a été montré précédemment que ce filtre permet de réduire significativement le clutter tout en préservant les signatures hyperboliques des mines. Les paramètres du filtre sont la fréquence d'échantillonnage spatiale $\nu_{xs} = 50 \text{ m}^{-1}$ et la largeur du Bscan $x_1 = 2.4 \text{ m}$. On s'intéresse dans un premier temps à la détection du temps de réponse de l'objet détecté aux positions horizontales $l = \{0.38, \dots, 0.58\}$. Par conséquent, l'algorithme 3 n'est pas appliqué à la donnée Bscan filtrée entière mais à un sous-Bscan constitué des données Ascan enregistrées aux positions $l = \{0, \dots, 1.2\}$, voir figure 3.10. Les données extraites du sous-Bscan afin de former les ensembles d'observation \mathbf{x}_1 et \mathbf{x}_2 sont constituées d'une ligne du sous-Bscan. Ces ensembles sont de tailles respectives $m_1 = 5$ et $m_2 = 5$. Les paramètres de l'algorithme σ et ν sont identiques à ceux de l'étape 1. La mesure du contraste $I_2(t)$ est représentée sur la figure 3.11. Les ruptures se produisant dans le sous-Bscan suivant t sont correctement identifiées. Les quatre premières ruptures détectées proviennent de la réponse de l'objet, tandis que les suivantes proviennent des branches de l'hyperbole caractérisant la réponse de l'objet 2. Ainsi, il est impossible de détecter automatiquement les ruptures provenant de la première réflexion sur l'objet 1. C'est la raison pour laquelle une nouvelle mesure du contraste $\tilde{I}_2(t)$ a été construite. La figure 3.12 représente $\tilde{I}_2(t)$ avec un seuil de détection

$\eta_t = 0.5$. Les deux ruptures détectées proviennent de la première réflexion du pulse GPR sur l'objet. Ainsi le temps de réponse de l'objet t_r est déterminé : $t_r = 2.16$ ns. Le temps de réponse théorique de l'objet étant de 2.13 ns, cela correspond à une erreur de 1.5 mm sur la profondeur de l'objet.




FIG. 3.11: Mesure du contraste normalisée $I_2(t)$ pour le sous-Bscan de la figure 3.10.




FIG. 3.12: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.10.

La même procédure est ensuite appliquée au sous-Bscan de la figure 3.13 pour déterminer le temps de réponse de l'objet 2 détecté aux positions $l = \{1.75, \dots, 2\}$. La mesure du contraste $\tilde{I}_2(t)$ calculée par l'algorithme 3 est représentée sur la figure 3.14. Les deux ruptures détectées correspondent à la réponse de l'objet 2 sur le sous-Bscan. La première rupture correspond à la réflexion du pulse GPR sur le sommet de l'objet. Ainsi, le temps de réponse de l'objet est détecté à l'instant $t_r = 1.08$ ns. Le temps de réponse théorique de l'objet étant de 1.13 ns, cela correspond à une erreur de 2.5 mm sur la profondeur de l'objet.

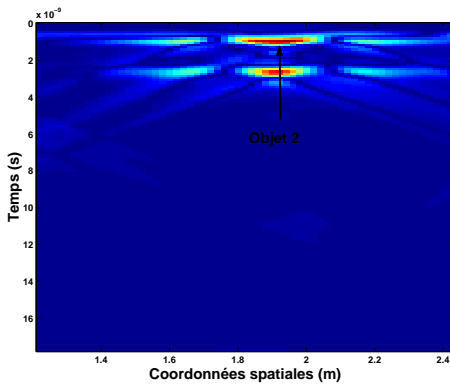


FIG. 3.13: Sous-Bscan, prétraité par filtrage numérique, contenant la réponse de l'objet détecté aux positions horizontales $l = \{1.75, \dots, 2\}$.




FIG. 3.14: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.13.

La méthode de détection proposée permet de détecter avec une bonne précision les temps de réponse des objets ainsi que leurs positions horizontales sur une donnée Bscan. Une autre donnée Bscan synthétique prenant en compte la rugosité de l'interface air-sol, représentée sur la figure 3.15, est utilisée pour tester la méthode. Pour créer cette donnée, un pulse électromagnétique, modélisé par une fonction Gaussienne, a été envoyé au dessus d'un sol homogène dans lequel deux objets ont été enfouis. La surface du sol est une variable aléatoire centrée en $z = 0$ est de variance égale à 5 cm. Les paramètres de simulations sont données dans le tableau 3.2.

TAB. 3.2: Paramètres de simulation

	Objet 1	Objet 2	sol
(ε_r, Q)	(10,5000)	(10,5000)	(3,60)
Coordonnées spatiales	{1,...,1.2}	{2.45,...,2.65}	-
Profondeur	5 cm	10 cm	aléatoire




FIG. 3.15: Donnée Bscan synthétique contenant les réponses de deux objets enfouis. L'un est situé aux positions $l = \{1, \dots, 1.2\}$ et l'autre aux positions $l = \{2.45, \dots, 2.75\}$.

La surface du sol variant d'un point de mesure à l'autre, le clutter n'est plus représenté par une bande horizontale, voir figure 3.15. Ainsi, les variations du clutter suivant l peuvent engendrer des ruptures susceptibles d'être détectées. Le réglage des tailles des ensembles d'apprentissage (m_1, m_2) est alors important. En effet, de faibles valeurs de m_1 et m_2 permettent de détecter des changements fréquents dans les dynamiques du Bscan tandis que des valeurs plus grandes pour m_1 et m_2 permettent de détecter des changements à plus long terme. Sur la donnée Bscan synthétique considérée, les changements engendrés par les variations du clutter dans les dynamiques du Bscan sont plus fréquents que ceux engendrés par la présence d'objets. Ainsi, un choix approprié des paramètres m_1 et m_2 de l'algorithme 2, peut limiter le nombre de ruptures provenant des variations rapides du clutter. Pour illustrer ceci, la mesure du contraste $I_1(l)$ est calculée pour

$m_1 = m_2 = 5$ et $m_1 = m_2 = 7$. La mesure du contraste pour $m_1 = m_2 = 5$ est représentée sur la figure 3.16. Les ruptures, engendrées par la présence des deux objets dans le Bscan, sont correctement détectées cependant d'autres ruptures, engendrées par les variations du clutter, sont détectées. Il est ainsi difficile de déterminer automatiquement la position de chacune des mines. La mesure du contraste calculée pour $m_1 = m_2 = 7$ est représentée sur la figure 3.17. Pour un seuil de détection supérieur à 4.5, seules les ruptures provenant des réponses des mines sont détectées. Ainsi, les positions des objets sont identifiées.

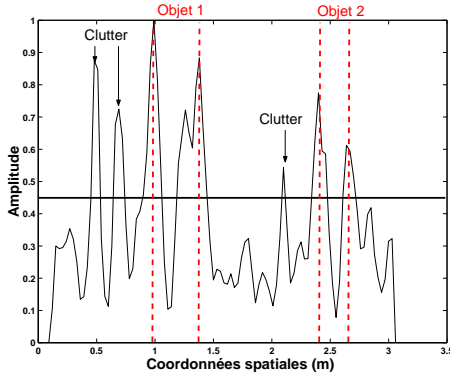


FIG. 3.16: Mesure du contraste $I_1(l)$ pour le Bscan de la figure 3.15 ($m_1 = m_2 = 5$). Plusieurs ruptures sont détectées. Certaines proviennent de la réponse des objets, d'autres proviennent des variations du clutter suivant l .




FIG. 3.17: Mesure du contraste $I_1(l)$ pour le Bscan de la figure 3.15 ($m_1 = m_2 = 7$). Deux objets enfouis ont été détectés. L'un est situé aux positions $l = \{0.99, \dots, 1.35\}$, et l'autre aux positions $l = \{2.4, \dots, 2.7\}$.

Les temps de réponses des deux objets sont déterminés en appliquant l'étape 2 de la méthode de détection. Les paramètres de la méthode sont donnés dans le tableau 3.3. Après filtrage, la donnée Bscan est divisée en deux sous-Bscans représentés respectivement sur les figures 3.18 et 3.20. Quelques résidus de clutter sont présents dans la donnée Bscan après filtrage. Un seuillage en amplitude est alors réalisé lors de la construction de l'indice $\tilde{I}_2(t)$ afin d'éliminer certains de ces résidus. Cela permet de limiter le nombre de ruptures suivant t en provenance des résidus de clutter. Les mesures du contraste pour chacun des deux sous-Bscans sont représentés sur les figures 3.19 et 3.21. Pour un seuil de détection η_t égal à 0.5, les réponses des deux objets suivant t sont correctement détectées.

TAB. 3.3: Paramètres de la méthode pour le Bscan de la figure 3.15

	m_1	m_2	σ	ν	η_l	x_1	ν_{xs}	η_t
Algorithme 2	7	7	10	0.5	0.45	-	-	-
Algorithme 3	5	5	10	0.5	-	3.2 m	33.3m^{-1}	0.5




FIG. 3.18: Sous-Bscan contenant la réponse de l'objet détecté aux positions horizontales $l = \{0.99, \dots, 1.35\}$.




FIG. 3.19: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.18.




FIG. 3.20: Sous-Bscan contenant la réponse de l'objet détecté aux positions horizontales $l = \{2.4, \dots, 2.7\}$.




FIG. 3.21: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.20.

La méthode de détection proposée permet de détecter de manière précise les positions horizontales des objets enfouis et leurs temps de réponse sur des données Bscan synthétiques. La méthode peut maintenant être appliquée sur les données Bscan réelles de la campagne MACADAM.

3.5.2 Données réelles

Les données Bscan réelles de la campagne MACADAM, décrites dans l'annexe B, sont utilisées pour tester la méthode de détection proposée dans ce chapitre. Les trois données Bscan réelles sélectionnées, représentent les enregistrements d'un GPR au dessus de sols homogènes constitués de terre, dans lesquels différents types de mines antipersonnel ont été enfouies. Les paramètres de la méthode, pour ces trois Bscans, sont données dans le tableau 3.4.

TAB. 3.4: Paramètres de la méthode pour les données Bscans réelles.

	m_1	m_2	σ	ν	η_l	x_1	ν_{xs}	η_t
Algorithme 2	5	5	10	0.5	0.5	-	-	-
Algorithme 3	5	5	10	0.5	-	1 m	50 m ⁻¹	0.4

Dans un premier temps, la méthode de détection est testée sur la donnée Bscan de la figure 3.22. Sur cette image, les réponses de deux mines antipersonnel de type MAUS1 (contenu métallique) sont visibles. L'une provient d'une mine enfouie à 5 cm et l'autre d'une mine posée sur la surface du sol. La mesure du contraste $I_1(l)$ est représentée sur la figure 3.23.




FIG. 3.22: Donnée Bscan enregistrée au dessus d'une terre homogène. Les réponses de deux mines métalliques de type MAUS1 ont été enregistrées.




FIG. 3.23: Mesure du contraste $I_1(l)$ pour le Bscan de la figure 3.22. Deux objets enfouis ont été détectés. Le premier aux positions $l = \{0.14, \dots, 0.28\}$, et le second aux positions $l = \{0.54, \dots, 0.68\}$.

La présence des deux mines métalliques engendre de nettes ruptures suivant l qui délimitent les positions horizontales des deux mines. Après réduction du clutter par filtrage numérique, la donnée Bscan est divisée en deux sous-Bscans contenant chacun la réponse d'une mine. Sur la figure 3.24, quelques résidus de clutter sont présents. Leurs amplitudes sont cependant inférieures à celle de la réponse de la mine MAUS1. Ainsi, la pondération apportée à chaque rupture lors de la construction de la mesure du contraste $\tilde{I}_2(t)$ permet de donner plus de poids à la rupture provenant de la première réflexion sur la mine, voir figure 3.25. Le temps de réponse de la mine est correctement détecté. Sur le sous-Bscan de la figure 3.26, seules les réflexions multiples du pulse GPR sur la mine sont présentes. Grâce au seuillage en amplitude, effectué lors de la construction de l'indice $\tilde{I}_2(t)$ seules les ruptures correspondant aux trois premières réflexions du pulse GPR sur la mine sont détectées. La première rupture détectée permet de déterminer le temps de réponse de la mine MAUS1 posée sur le sol.




FIG. 3.24: Sous-Bscan contenant la réponse de l'objet détecté aux positions horizontales $l = \{0.14, \dots, 0.28\}$.




FIG. 3.25: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.24.




FIG. 3.26: Sous-Bscan contenant la réponse de l'objet détecté aux positions horizontales $l = \{0.54, \dots, 0.68\}$.

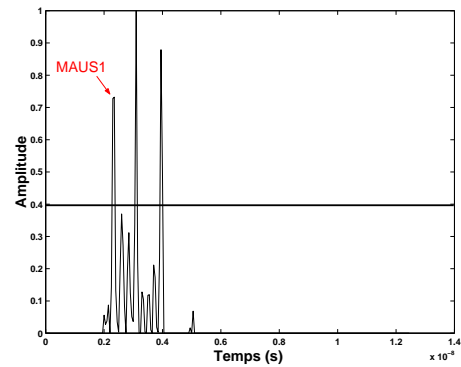


FIG. 3.27: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.26.

La méthode de détection est ensuite appliquée à la donnée Bscan représentée sur la figure 3.28. Les réponses de deux mines plastiques de type VSMK2 ont été enregistrées par le GPR. Cependant celles-ci sont difficilement visibles car leurs réponses sont noyées dans celle de l'interface air-sol. Bien que les réponses des mines VSMK2 n'apparaissent pas sous forme d'hyperbole dans l'image, leurs présences engendrent des modifications dans les premiers instants des données Ascans enregistrés par le GPR à proximité des mines. Ainsi, pour un seuil de détection supérieur à 0.5, les positions horizontales des deux mines sont détectées, voir figure 3.29. Après l'application du filtre numérique pour réduire le clutter sur la donnée Bscan, les signatures des deux mines VSMK2 apparaissent nettement sur les deux sous-Bscans des figures 3.30 et 3.32. Leurs temps de réponses sont correctement détectés, voir figures 3.31 et 3.33.




FIG. 3.28: Donnée Bscan enregistrée au dessus d'une terre homogène. Les réponses de deux mines plastiques de type VSMK2 ont été enregistrées.

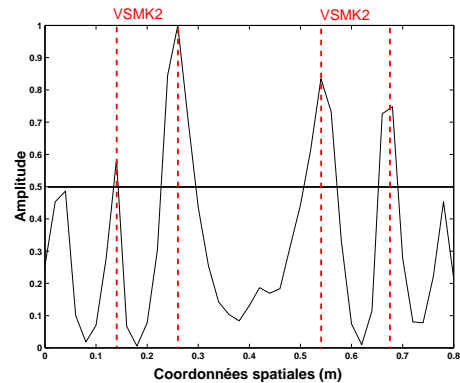


FIG. 3.29: Mesure du contraste $I_1(l)$ pour le Bscan de la figure 3.22. Deux objets enfouis ont été détectés. Le premier aux positions $l = \{0.14, \dots, 0.26\}$, et le second aux positions $l = \{0.54, \dots, 0.68\}$.




FIG. 3.30: Sous-Bscan contenant la réponse de l'objet détecté aux positions horizontales $l = \{0.14, \dots, 0.26\}$.

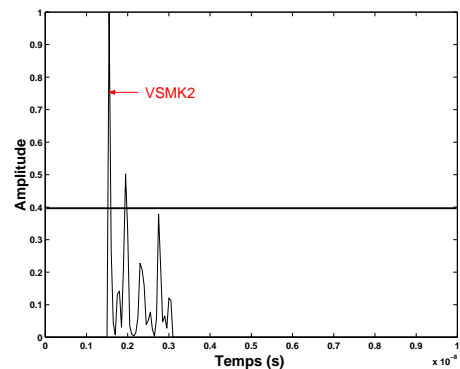


FIG. 3.31: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.30.

Enfin, la méthode est testée sur la donnée Bscan de la figure 3.34. Ce Bscan résulte des enregistrements d'un GPR au dessus d'une terre homogène recouverte d'herbe dans laquelle une mine plastique de type AUPS et une mine métallique de type MAUS1 ont été enfouies à une profondeur de 1 cm. La réponse de la mine AUPS n'est pas visible sur le Bscan cependant un choix approprié du seuil de détection, i.e. $\eta_l = [0.3, \dots, 0.5]$, permet de la détecter. On peut noter que l'amplitude des ruptures engendrées par la réponse de la mine plastique dans la donnée Bscan est nettement plus faible que celle des ruptures engendrées par la réponse de la mine métallique. Après l'étape de réduction du clutter, la signature de la mine AUPS apparaît sur le sous-Bscan de la figure 3.36. Sur cette donnée, l'amplitude des résidus de clutter est du même ordre que celle de la première réflexion du pulse GPR sur la cible. Ainsi, les ruptures provenant des résidus de clutter sont détectées avant celles provenant de la mine AUPS, voir figure 3.37. Le temps de réponse de cette




FIG. 3.32: Sous-Bscan contenant la réponse de l'objet détecté aux positions horizontales $l = \{0.54, \dots, 0.68\}$.




FIG. 3.33: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.32.




FIG. 3.34: Donnée Bscan enregistrée au-dessus d'une terre homogène recouverte d'herbe. Les réponses de d'une mine plastique de type AUPS et d'une mine métallique de type MAUS1 ont été enregistrées.




FIG. 3.35: Mesure du contraste $I_1(l)$ pour le Bscan de la figure 3.34. Deux objets enfouis ont été détectés. Le premier aux positions $l = \{0.04, \dots, 0.26\}$, et le second aux positions $l = \{0.52, \dots, 0.66\}$.

mine ne peut être déterminé automatiquement. En revanche, en ce qui concerne la mine MAUS1 les ruptures détectées correspondent bien aux réflexions du pulse GPR sur la mine, voir figure 3.39. La première rupture détectée permet de déterminer le temps de réponse de la mine.

3.6 Conclusion

L'algorithme de détection de ruptures est un outil prometteur dans le cadre de la détection de mines antipersonnel. Les différents résultats de simulations sur des données synthétiques ou réelles montrent ses capacités à détecter automatiquement les po-




FIG. 3.36: Sous-Bscan contenant la réponse de l'objet détecté aux positions horizontales $l = \{0.04, \dots, 0.26\}$.




FIG. 3.37: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.36.




FIG. 3.38: Sous-Bscan contenant la réponse de l'objet détecté aux positions horizontales $l = \{0.52, \dots, 0.66\}$.




FIG. 3.39: Mesure du contraste normalisée $\tilde{I}_2(t)$ pour le sous-Bscan de la figure 3.38.

sitions horizontales et les temps de réponse des objets enfouis dans les données Bscan. Les simulations sur les données réelles de la campagne MACADAM montrent que la méthode de détection proposée permet de détecter des mines antipersonnel enfouies à différentes profondeurs et dont le contenu métallique peut être faible. Cependant, les performances de l'algorithme de détection de ruptures suivant t sont liées à l'efficacité de la méthode de réduction de clutter utilisée puisque le rapport signal sur clutter doit être élevé. Le filtre numérique conçu dans le chapitre 2 se montre efficace puisqu'il permet de réduire significativement le clutter sans apporter de distorsions significatives aux signatures hyperboliques des objets enfouis. L'avantage de cette méthode de détection est qu'elle ne nécessite pas de modèle physique ou statistique du signal provenant d'une mine. De plus, cette méthode est robuste, puisque l'approche SVM pour l'estimation du support de densité, utilisée afin de construire la mesure du contraste $I(a)$, autorise la présence d'outliers dans les ensembles d'apprentissage x_1 et x_2 , voir section 3.3.5. L'inconvénient de cette méthode est que les objets sont détectés mais aucune information sur leurs natures n'est donnée. D'autres capteurs, tels que le détecteur de métal, les caméras infrarouges, peuvent aider à discriminer les objets détectés. Des méthodes de

fusion multicateurs pour la détection de mines antipersonnel telles que celles proposées dans [MB03] et [PDVB04] peuvent ensuite être utilisées.

Les performances de la méthode sont évaluées dans le chapitre 5 en terme de probabilité de détection et probabilité de fausse alarme à partir des différents scénarios de la campagne MACADAM.