

Table des Matières

Introduction générale.....	1
----------------------------	---

Chapitre I : Etude de l'art sur l'imagerie micro-onde

I.1.Introduction.....	3
I.2.Imagerie Micro ondes.....	4
I.3.Techniques d'imagerie micro-ondes confocale.....	6
I.3.1.Les algorithmes de reconstruction.....	7
I.3.2.Technique adaptative Multistatique d'imagerie micro-ondes confocale.....	7
I.4.Technique d'imagerie micro ondes tomographique.....	8
I.4.1.Imagerie micro ondes tomographique par diffraction.....	10
I.4.2.Imagerie micro ondes tomographique itérative.....	10
I.4.3.Problème inverse.....	11
I.5.Paramètres électromagnétique du matériau.....	12
I.5.1.Champ de polarisation et permittivité.....	13
I.5.2.Aimantation et perméabilité.....	14
I.5.3.Diélectrique imparfait.....	14
I.6.Propriétés diélectriques des tissus humains.....	15
I.7.Propriétés diélectriques des tissus mammaires.....	17
I.8.Conclusion.....	18

Chapitre II : Théorie des approches SVM et SVR

II.1.Introduction.....	19
II.2. Support vector machine.....	19
II.2.1.Généralités.....	19
II.2.2. Mise en œuvre des SVM.....	20
II.3. Définition de base.....	20
II.3.1. Séparation linéaire (séparateur linéaire).....	20
II.3.2. Notion de marge.....	22
II.4. Machine a vecteurs supports linéaires.....	23
II.4.1. Cas des données séparables.....	23

II.5. Implémentation.....	25
II.6. Avantages et inconvénients.....	25
II.6.1. Avantage.....	25
II.6.2. Inconvénients.....	25
II.7. Régression par les machines à vecteurs supports SVR.....	26
II.7.1. Méthode standard.....	26
II.7.1.1. Idée de base : Cas linéaire.....	26
II.7.1.2. Cas non-linéaire.....	28
II.8 Modifications apportées aux SVR.....	29
II.8.1 Procédure itérative avec une marge adaptative.....	30
II.8.2 Pondération du SVR.....	31
II.9. Conclusion.....	33

Chapitre III: Applications des approches SVM et SVR pour la classification

III.1. Introduction.....	34
III.2 Modèle du sein pour la collection des données.....	34
III.2.1 Modèle de sein.....	34
III.2. Choix de l'antenne.....	36
III.3. Etapes de construction et de validation des SVM.....	38
III.3.1. Construction du SVM et SVR.....	39
III.3.2. Phase de pré-traitement des données.....	39
III.3.3. Phase d'apprentissage.....	40
III.3.4. Résultats de simulation et de test.....	40
III.4.-Conception du modèle de classification par approche SVR.....	42
III.5. Conclusion.....	44

Conclusion générale.....	45
--------------------------	----

Références Bibliographiques.....	46
----------------------------------	----

Annexe (A).....	54
-----------------	----

Introduction Générale



Introduction générale

Le cancer du sein est un problème de santé publique important. Ce type de cancer est le plus fréquent et le deuxième plus meurtrier chez les femmes. À ce jour, la méthode de prévention s'étant montrée la plus efficace est le dépistage au moyen de mammographies. Celles-ci sont obtenues à partir de mammographes à rayon X. Ces appareils sont munis de deux plaques qui compriment le sein. Une source de rayons X éclaire ce dernier et l'image est formée sur une pellicule sensible au rayonnement.

. Au cours de la dernière décennie, l'application de l'Imagerie Micro-ondes à la détection du cancer du sein a suscité un intérêt sans cesse grandissant. Cet intérêt est principalement justifié par les grands contrastes qui existent, aux fréquences microondes, entre les propriétés électriques des tissus sains et celles des tissus pathologiques

En effet, les contrastes rencontrés peuvent être supérieurs à 100% alors qu'en Imagerie à Rayons X, ils ne sont de l'ordre que de quelques pour-cent. Cette constatation suscite naturellement l'espoir de développer de nouveaux outils capables d'améliorer la précision des diagnostics. C'est dans cette perspective que s'inscrivent notre projet.

Dans notre travail, on s'intéresse à l'implémentation d'algorithmes de classification des tumeurs du cancer du sein, en vue d'intégration de ces outils dans un système d'imagerie Ultra Large Bande (ULB). Nous présentons dans ce mémoire de Master une nouvelle variante d'algorithmes de classification telle que les supports vector machine (SVM), qui représente une alternative intéressante dans le domaine de l'imagerie micro-ondes. Les SVM permettent non seulement d'établir des relations analytiques importantes pour la phase de classification, mais aussi une grande flexibilité, puisqu'il n'y a aucune restriction quant au nombre de paramètres du système en entrée et en sortie. La phase de classification des tumeurs devient alors possible grâce à la relation explicite donnée par les SVM. Pour cela, il est possible de construire les SVM durant la phase d'apprentissage en se basant sur un ensemble de solutions obtenues par simulation en utilisant le logiciel CST Studio

Ce Mémoire est structuré en trois chapitres.

Dans le premier chapitre, on présentera la technique d'imagerie micro ondes confocale ou radar et leur différentes approches à savoir mono, bi et multi-statiques, ainsi que les algorithmes de reconstruction et les méthodes d'imagerie micro ondes tomographique.

Le chapitre 2 sera consacré à une présentation des approches SVM et SVR, les plus couramment rencontrées, et aux méthodes d'apprentissage afin de mettre en évidence à la fois leurs applications potentielles et possibilités de fonctions multiples.

Le troisième chapitre s'intéresse à l'application des SVM et SVR dans la classification des tumeurs du cancer du sein. Une étude comparative en utilisant les réseaux de neurones artificiels (RNA) sera faite dans le but de valider les approches utilisées.

Nous achèverons notre manuscrit par une conclusion générale sur la classification par imagerie micro-ondes, ainsi que sur les perspectives prometteuses existantes dans ce domaine de recherche.

Chapitre I



Etude de l'art sur l'imagerie micro-onde

I.1.Introduction

L'imagerie micro-ondes, comme l'imagerie optique, obtient des images en mesurant l'influence de l'onde appliquée sur un objet. Selon le type d'ondes utilisé pour la reconstruction d'image, on a deux sorte d'images : l'image optique et l'image micro ondes. En utilisant les ondes optiques, la densité d'onde est imagée, alors que dans le cas des micro-ondes les propriétés diélectriques sont imagés.

Dans le cas d'imagerie optique, la longueur d'onde est très petite par rapport à la taille de l'objet, une hypothèse linéaire de propagation est valide. Mais, une onde électromagnétique dans le spectre micro-ondes, a une longueur d'onde dans la même gamme que la taille de l'objet. Ainsi, les effets de diffraction ne peuvent pas être négligés, comme le montre la figure (I. 1). Par exemple, pour produire une image tomographique d'un objet, un problème de diffusion inverse doit être résolu, où les propriétés diélectriques de l'objet sont déduites à partir du champ mesuré, dispersé ou rayonné par l'objet, avec un champ incident connu, comme le montre la figure (I. 1). En raison de multi-trajets, une relation non linéaire est établie entre le champ diffusé et les propriétés diélectriques de l'objet ^[1].




Figure I. 1 : Effet de multi-trajets de diffusion dans l'imagerie micro ondes

L'imagerie micro-ondes consiste à reconstruire des objets inconnus à partir des mesures du champ dispersé ou réfléchi qui résultent de leur interaction avec une onde incidente connues. Les deux approches d'imagerie micro ondes utilisées sont : la technique

confocale ou radar et la tomographique micro-ondes ; pour la première technique les signaux réfléchis sont mesurés et pour la deuxième méthode c'est le cas de la tomographique micro-ondes où les signaux diffusés qui sont mesurés.

Dans les systèmes de détection ou de localisation à base d'image micro onde, on distingue généralement quatre catégories :

- ❖ les systèmes dimension zéro (0-D), ce sont des systèmes qui ne font qu'informer de la présence d'objets ou d'individus et ne donnent ni le nombre ni la position ;
- ❖ les systèmes dimension un (1-D), ce sont des systèmes qui en plus différencient les objets ou les individus les plus proches des plus éloignés ;
- ❖ les systèmes dimension deux (2-D), ce sont des systèmes qui identifient la position des objets ou des individus et également leur nombre ;
- ❖ les systèmes dimension trois (3-D), ce sont des systèmes qui identifient la position des objets ou des individus et qui en plus informent sur leur hauteur.

Dans le premier chapitre, on présentera la technique d'imagerie micro ondes confocale ou radar et leur différentes approches à savoir mono, bi et multi-statiques, ainsi que les algorithmes de reconstruction et les méthodes d'imagerie micro ondes tomographique.

I.2.Imagerie Micro ondes

Depuis les premières propositions de systèmes d'imagerie par micro-ondes ^{[2] - [3] - [4]}, l'imagerie micro-ondes a été considérée comme ayant un fort potentiel pour différentes applications. Récemment, l'imagerie micro-ondes a reçu un intérêt considérable par rapport à d'autres techniques d'imagerie. Un grand nombre d'études s'appuient sur micro onde comme un outil puissant électromagnétiques pour récupérer les propriétés physiques et électriques des objets pénétrables et impénétrables.

Les systèmes d'imagerie micro-ondes sont généralement des systèmes actifs, qui signifient que le signal d'éclairage est généré par le système de mesure. Les systèmes passifs ne sont pas largement utilisés car il n'y a qu'un faible rayonnement dans la gamme de fréquence micro ondes de la plupart des objets.

Les fréquences utilisées dans l'imagerie micro-ondes actives sont comprises entre moins de 1 GHz à 40 GHz. On sait que les basses fréquences réduisent l'effet du problème de la non-linéarité et la stabilisation de l'algorithme, tandis que les hautes fréquences augmentent la

résolution de l'image. La plupart des applications fonctionnent dans la gamme de **2 GHz à 8 GHz**. Cette gamme est prévue pour donner un bon compromis entre la résolution spatiale (des fréquences plus élevées) et la pénétration (basses fréquences) ^[1].

L'objectif de l'imagerie micro-ondes est la reconstruction d'un objet ou plus précisément, déduire les paramètres physiques d'un objet à partir de mesure des champs électromagnétiques dispersés ou réfléchi qui se produit lorsque l'objet est éclairé par une incidence micro ondes connue. Un système typique de l'imagerie active à micro-ondes est représenté sur la figure (I. 2). L'émetteur génère un signal micro-ondes (la génération du champ d'éclairage) qui sera diffusé par l'objet, le champ diffracté ou réfléchi est mesuré par les récepteurs.




Figure I. 2 : Système actif d'imagerie micro-ondes

Parmi les méthodes actives d'imagerie micro-ondes signalées dans la littérature, On peut distinguer deux types de méthodes : la tomographie à micro-ondes et les techniques radars UWB, qui cherchent à exploiter le contraste diélectrique. La reconstruction de l'image tomographique vise principalement à récupérer les propriétés diélectriques ou voir le profil d'objet à partir des signaux micro-ondes diffusés, en résolvant un problème non linéaire de diffusion inverse ^{[5] – [6] – [7]}.

D'autre part, les techniques radars à ultra large bande (UWB) ne tentent pas de reconstruire le profil complet diélectrique, au contraire elles cherchent à localiser et de détecter les objets par leurs signaux rétrodiffusés. Les approches radar sont abordées par une étude récente publié par Hagness^{[8] – [9] – [10]}.

I.3. Techniques d'imagerie micro-ondes confocale

L'approche générale dans de tels systèmes est de concentrer un signal micro-ondes d'éclairage à un point particulier dans le volume d'analyse, puis de recentrer le signal réfléchi vers le point d'éclairage. En balayant systématiquement le point focal dans un ensemble de voxels (un pixel en 3D) présélectionnés dans tout le volume d'objet, une image 3D peut être construite.

Selon la façon dont les données sont acquises, il existe trois approches d'imagerie micro-ondes confocale (CMI) qui sont : les mono-statiques ^[11], bi-statiques ^[12] et multi-statiques ^[13]. Dans l'approche mono-statique, l'émetteur est utilisé comme un récepteur et se déplace pour former une synthèse d'ouverture. Pour l'approche bi-statique, une antenne de transmission et une autre de réception sont utilisées. Pour multistatique CMI, une large ouverture réelle (figure I. 3) est utilisée pour la collecte des données. Chaque antenne dans le tableau se relaye pour transmettre une impulsion de sondage, et toutes les antennes (dans certains cas, tous sauf l'antenne de transmission) sont utilisées pour recevoir les signaux rétrodiffusés. Multistatique CMI peut être considérée comme un cas particulier de la large bande multi-entrées multi-sorties (MIMO) radar ^{[14] - [15]} avec les multiples formes d'ondes transmises étant soit des impulsions UWB ou des zéros.




Figure I. 3 : Configuration de réseau d'antennes.

I.3.1. Les algorithmes de reconstruction

Le défi à l'imagerie CMI est de concevoir des algorithmes de traitement du signal pour améliorer la résolution et de supprimer les fortes interférences. Les Algorithmes de traitement du signal peuvent être classés en deux méthodes des données dépendantes (données-adaptative) et des données indépendantes.

Pour les mono et bi-statique à ultralarge bande CMI, les algorithmes de formation d'image sont DAS (Delay-And-Sum) ^{[11] - [13]} et le MIST (Microwave Imaging Space-Time) ^[16], deux algorithmes de la méthode des données indépendantes. Par contre la méthode des données adaptatives utilise le RCB ^[12] (Robust Capon Beamforming) et l'APES (Amplitude and Phase EStimation) ^[12] algorithmes pour la formation des images. Les méthodes d'adaptation des données en général sont plus performantes que leurs homologues de données indépendantes. Pour le cas multistatique ultra-large bande CMI, les méthodes DAS ^[13] et RCB-adaptative ^[17] ont été envisagées.

Il est bien connu que l'imagerie radar UWB classique ne parvient pas à atteindre la résolution désirée due à la limité d'ouverture d'antenne ^[18]. Cette limitation peut être surmontée en utilisant la technique de retournement temporel, car elle offre une meilleure résolution focale ^{[18] - [19]} en augmentant l'ouverture d'antenne virtuellement. La méthode de retournement temporel a été largement utilisé dans de nombreuses applications qui utilisent la propriété de recentrage pour détecter et localiser une cible au moyen de la simulation numérique ou virtuelle imagerie ^[18].

I.3.2. Technique adaptative Multistatique d'imagerie micro-ondes confocale

La technique adaptative Multistatique d'imagerie micro-ondes (MAMI) est une méthode qui permet de former des images à travers l'énergie rétrodiffusée captée par un réseau d'antennes. Une étude comparative entre les différentes techniques montre que la méthode MAMI a une résolution meilleure et une grand capacité de rejeté les interférences et les bruits que les autres méthodes ^[20].

Pour un endroit d'intérêt (ou point focal), les données complètes multistatique enregistrées peuvent être représentées par un cube, comme le montre la figure (I. 4). MAMI emploie les données adaptatives d'algorithme RCB ^[21] en deux stades. Au premier, MAMI-1 coupe le cube des données correspondant à chaque indice de temps, et traite la tranche des

données par le formateur de faisceau robuste Capon (RCB) ^{[21] - [22]}; pour obtenir des estimations de forme d'onde rétrodiffusées à chaque instant. Selon ces estimations, à l'étape II une forme scalaire d'onde est récupérée au moyen du même l'algorithme, l'énergie est utilisée comme une estimation de l'énergie rétrodiffusée du point focal.




Figure I. 4 : Multistatique CMI modèle cube des données.

Une autre façon de découper le cube des données dans le stade I avant d'appliquer l'algorithme RCB est de sélectionner une tranche correspondant à chaque indice d'antenne d'émission figure (I. 4). L'approche ainsi obtenu est dénommé MAMI-2.

« Jian Li et Petre Stoica » ^[23] montrent que MAMI-2 tend à produire de meilleures images que MAMI-1 pour un fort rapport signal d'entrée sur interférence et bruit (SINR), mais des mauvaises images pour un faible (SINR), et ils montrent aussi que la combinaison de MAMI-1 et MAMI-2 donne de bonnes performances dans tous les cas de SINR.

I.4. Technique d'imagerie micro ondes tomographique

Le contraste entre les propriétés diélectriques de l'objet crée la diffusion multiple de l'onde dans l'objet, cela pose un problème non linéaire de diffusion inverse. Les méthodes tomographiques sont basées sur la résolution de ce problème, et ils sont divisés en deux groupes différents. Premièrement, la tomographie par diffraction, une approche linéaire, qui utilise l'approximation de Born ou Rytov, est une méthode de calcul très efficace pour obtenir

des quasis imageries en temps réel ^{[24] - [25] - [26]}, et dans les situations des objets à faibles pertes et à faible contraste. Dans les situations des objets à contraste élevé, des méthodes non linéaires sont nécessaires.

Le deuxième groupe, est une approche non linéaire déterministe introduite par « Joachimowicz » et « Chew » dans le début des années 90 ^{[6] - [27]}. De plus, « Caorsi » a contribué très tôt dans ce domaine ^[28]. La méthode est basée sur une optimisation itérative d'une fonction d'objet pour résoudre le problème inverse d'imagerie micro ondes. En raison de la non-linéarité du problème de diffusion inverse Eq (I.1), un algorithme de reconstruction itératif dans lequel une fonction de coût est réduite au minimum est nécessaire. Le champ diffusé dépend de deux types d'inconnues, la permittivité complexe et la totalité du champ à l'intérieur de l'objet, qui sont liés par une contrainte de domaine d'intégration de l'équation. En ce qui concerne ces inconnues, la plupart des méthodes de reconstruction peut être divisé en deux catégories.

$$e_s(\vec{r}) = \iint_S G(\vec{r}, \vec{r}') C(\vec{r}') e(\vec{r}') dr' \quad (I. 1)$$

Où G est la fonction de Green.

$$\text{Avec} \quad C(\vec{r}) = k^2(\vec{r}) - k_1^2 \quad (I. 2)$$

où k_1 et $k(\vec{r})$ sont les constantes de propagation dans un milieu homogène et inhomogène respectivement.

Dans la première approche (cas classique), l'inconnu (champ total) est éliminé du problème ce qu'on l'appelle "le Problème directe ", de telle sorte que la fonction de coût Eq (I.1) ne dépend que de la permittivité complexe ^[29]. Les algorithmes de calcul sont très lourds, par conséquence l'imagerie en deux dimensions (2D) est généralement utilisée. Dans la second approche (modification du gradient), la contrainte domaine d'intégration de l'équation est ajoutée comme un second terme à la fonction de coût, qui est ensuite réduite au minimum pour les deux types d'inconnues en utilisant un schéma d'optimisation du gradient conjugué ^{[30] - [31]}.

Récemment, pour éviter les minima locaux, des systèmes alternatifs de l'optimisation ont été rapportés, tel que l'inversion de régularisation multiplicative de contraste source

(Multiplicative Regularization Contrast Source inversion), ce qui donne un calcul efficace en particulier pour les solutions de situation 3D qui été introduite par « Abubakar »^{[32] – [33]}, on trouve aussi les méthodes d'optimisation globale qui utilise les réseaux de neurones et les algorithmes génétiques présentés par « Caorsi »^{[34] – [35] – [36]}. Ces méthodes évitent les minima locaux, toutefois par un ralentissement de la convergence et un temps de calcul plus élevé.

Il est connu que les basses fréquences réduisent l'influence de la non linéarité de phase et stabilisation de l'algorithme, alors que les fréquences les plus élevées augmentent la résolution, une combinaison va probablement améliorer la reconstruction. Cependant, inclure la dépendance de fréquence de la permittivité dans l'algorithme de reconstruction est une tâche difficile, selon les études de « Q. Fang, P. M. Meaney » et « K. D. Paulsen » dans^[37]. Les Futurs efforts de recherche sont vraisemblablement orientés dans cette direction.

I.4.1.Imagerie micro ondes tomographique par diffraction

La tomographie par diffraction a été la première tentative de créer des images quantitatives utilisant les micro-ondes. La méthode tente de reconstituer les courants induits, J , qui génèrent le champ mesuré dispersés, en se rapprochant le champ l'intérieur de l'objet au champ incident. Cette approximation est appelée l'approximation de Born^[24]:

$$\text{avec} \quad J(\vec{r}) = C(\vec{r})e(\vec{r}) \quad (\text{I. 3})$$

$$\text{Où} \quad e(\vec{r}) = e_i(\vec{r}) + e_s(\vec{r}) \quad \text{est le champ total dans l'objet} \quad (\text{I. 4})$$

I.4.2.Imagerie micro ondes tomographique itérative

Dans cette approche le problème non linéaire de diffusion inverse résolu en deux parties, problème direct et problème inverse. La méthode est basée sur un processus itératif d'optimisation d'une fonction de coût Eq (I. 1), ce qui représente la différence entre le champ dispersé mesuré et simulé.

I.4.2.1.Problème direct

Problème direct dans notre domaine de recherche correspond au calcul du champ électrique $E_{\text{disp}}(\vec{r})$ qui est dispersé à partir d'une distribution connue de permittivité complexe

$\varepsilon(r)$ dans un domaine d'investigation 'D' quand un champ incident connu $E_{inc}(r)$ empiète dans ce domaine figure (I. 5).




Figure I. 5 : La configuration 3D dispersion.

On peut supposer que le problème direct peut toujours être résolu en utilisant des méthodes numériques comme la méthode des Moments ^{[6] - [28]}, la méthode des éléments finis (FEM) en hybride avec les éléments de frontière (BE) ^[38], ou dans certains cas les méthodes des différences finies (FDM) ^[39]. L'avancement des machines de calculs et le développement des algorithmes avancés FDTD (*Finite Difference Time Domain*) permettent de donner une solution exacte du problème direct dans un schéma itératif ^{[40] - [41]}. C'est pour quoi l'utilisation des modèles simplistes pour la solution du problème direct peut être évitée.

I.4.3.Problème inverse

Le problème de diffusion inverse consiste à récupérer la distribution de la permittivité complexe d'un objet, à partir d'un champ électromagnétique incident connu et le champ diffusé mesuré autour de l'objet. En général multi-vue est nécessaire, afin de recueillir suffisamment de données indépendantes. En outre, la répartition des points de réception, par exemple le long d'une ligne ou un cercle figure (I. 6), a un impact sur la reconstruction d'image. Toutefois, plusieurs études de comparaison ^{[42] - [43]} entre différentes configurations d'antennes de réception; montrent qu'une configuration circulaire a généralement plus d'avantage qu'une configuration plane, car des informations plus importantes peuvent être perçues.




Figure I. 6 : Trois différentes configurations multi-vues. (a) caméra planaire. (b) Scanner demi-circulaire (HCS) (c) Scanner circulaire (FCS).

Le champ diffusé est une fonction non-linéaire de la permittivité. En conséquence, le problème de diffusion inverse est résolu de manière itérative ^{[5] - [6]}. Il est formulé comme un problème d'optimisation dans lequel les variables d'optimisations sont les valeurs de la permittivité complexe $\epsilon(r)$ figure (I. 7).




Figure I. 7 : Reconstruction d'une image micro ondes

I.5.Paramètres électromagnétique du matériau

Lorsqu'on utilise les micro-ondes pour la formation d'imagerie, la distribution des paramètres électromagnétique de l'objet est utilisée pour la formation d'image. Il s'agit de la permittivité, la perméabilité et la conductivité.

I.5.1. Champ de polarisation et permittivité

Lorsqu'on applique un champ électrique $\vec{E}$ à un objet, les dipôles permanents qu'il contient s'alignent dans la direction du champ appliqué. D'autre part les charges liées positives et négatives des molécules neutres se déplacent légèrement et en sens opposé le long du champ appliqué, par suite des forces électriques provoquées : le champ appliqué fait apparaître dès lors des dipôles induits. Tous ces dipôles sont caractérisés par un moment électrique dipolaire, dont l'amplitude est le produit de la charge par la distance séparant les charges. Le champ de polarisation $\vec{P}$ est défini comme étant la densité volumique des moments dipolaires lorsque l'élément de volume devient très petit.

L'effet du champ électrique $\vec{E}$ est alors représenté par le déplacement (ou induction) électrique $\vec{D}$ Défini par :

$$\vec{D} = \epsilon_0 \vec{E} + \vec{P} \quad \text{En (A. s/m}^2\text{)} \quad (\text{I. 5})$$

Où ϵ_0 est la permittivité absolue du vide

$$\epsilon_0 = \frac{10^{-9}}{36\pi} = 8,854.10^{-12} \quad \text{En (A. s/V. m) ou (F/m).} \quad (\text{I. 6})$$

Dans un diélectrique dit linéaire, le champ de polarisation $\vec{P}$ est proportionnel au champ électrique $\vec{E}$ selon la relation :

$$\vec{P} = \epsilon_0 \chi \vec{E} \quad (\text{I. 7})$$

Ainsi, dans ce type de milieu, on peut écrire :

$$\vec{D} = \epsilon_0 \vec{E} + \epsilon_0 \chi \vec{E} = \epsilon \vec{E} \quad \text{Ou } \epsilon = \epsilon_0 (1 + \chi) = \epsilon_0 \epsilon_r$$

Avec ϵ_r : est la permittivité relative des matériaux.

Finalement, dans un milieu linéaire, on peut écrire $\vec{D} = \epsilon \vec{E} = \epsilon_0 \epsilon_r \vec{E}$ en (A.s/m²). Dans le vide (l'air), la polarisation $\vec{P}$ est nulle. Il en résulte $\vec{D} = \epsilon_0 \vec{E}$ et $\epsilon_r = 1$

On appelle milieu linéaire isotrope, un milieu linéaire dans lequel la permittivité ϵ est un scalaire. Dans ce type de milieu $\vec{D}$ et $\vec{E}$ sont colinéaires.

Il existe d'autres milieux diélectriques linéaires dits anisotropes dans lesquels la permittivité diélectrique n'est plus un scalaire mais un tenseur. Dans un repère tridimensionnel, la relation qui lie le déplacement électrique au champ électrique s'écrit :

$$\begin{pmatrix} D_x \\ D_y \\ D_z \end{pmatrix} = \begin{pmatrix} \epsilon_{xx} & \epsilon_{xy} & \epsilon_{xz} \\ \epsilon_{yx} & \epsilon_{yy} & \epsilon_{yz} \\ \epsilon_{zx} & \epsilon_{zy} & \epsilon_{zz} \end{pmatrix} \times \begin{pmatrix} E_x \\ E_y \\ E_z \end{pmatrix} \quad (\text{I. 8})$$

I.5.2. Aimantation et perméabilité

Les propriétés magnétiques des matériaux sont dues à une propriété quantique de l'électron et que l'on appelle le moment magnétique de spin (L'électron effectue un mouvement de rotation autour de lui-même). En présence d'une inductance $\vec{B}$ les moments magnétiques s'alignent sur le champ appliqué. Dans la plus part des matériaux, les atomes possèdent le même nombre d'électrons à moment magnétique de spin positif et d'électron à moment magnétique de spin négatif.

Dans le cas contraire là où les atomes possèdent des nombres différents d'électrons à moment magnétique de spin positif et d'électrons à moment magnétique négative, il apparaît une aimantation $\vec{M}$ provoquée par ce déséquilibre. Cette aimantation $\vec{M}$ est définie par la densité volumique des moments magnétiques résultants et est mesurée en (A/m). Le champ magnétique $\vec{H}$ est défini à partir de l'induction magnétique $\vec{B}$ et de l'aimantation $\vec{M}$, par la relation :

$$\vec{H} = \left(\left(\frac{\vec{B}}{\mu_0} \right) - \vec{M} \right) \quad \text{En (H/m)} \quad \text{ou} \quad \vec{B} = \mu_0 (\vec{H} + \vec{M}) \quad (\text{I. 9})$$

Avec $\mu_0 = 4 \pi 10^{-7}$ (V.s/m) ou (H/m) est la perméabilité absolue dans le vide. Dans un matériau linéaire, l'induction et Champ magnétique sont proportionnelle à l'aimantation, et on peut écrire : $\vec{B} = \mu \vec{H}$ en (T) ou μ est la perméabilité de matériau. Les matériaux non ferromagnétiques possèdent une aimantation nulle et leur perméabilité est égale à μ .

I.5.3. Diélectrique imparfait

Un diélectrique parfait est caractérisé par une conductivité nulle. Dans un diélectrique imparfait, on ne peut négliger la conductivité et, en régime sinusoïdale, l'équation qui s'écrit pour un diélectrique parfait :

$$\vec{\text{rot}}\vec{H} = j \omega \epsilon \vec{E} \quad (\text{I. 10})$$

Devient pour un diélectrique imparfait :

$$\vec{\text{rot}}\vec{H} = j \omega \epsilon \vec{E} + \sigma \vec{E} = j \omega \left(\epsilon + \frac{\sigma}{j \omega} \right) \vec{E} \quad (\text{I. 11})$$

En faisant l'analogie entre ces deux dernières équations, on peut dire que pour le diélectrique imparfait, tout se passe comme si la constante diélectrique était complexe.

$$\text{On pose : } \epsilon_c = \epsilon + \frac{\sigma}{j \omega} = \epsilon_0 \epsilon_r + \frac{\sigma}{j \omega} = \epsilon_0 \left(\epsilon_r - j \frac{\sigma}{\omega \epsilon_0} \right) = \epsilon_0 (\epsilon_r' - j \epsilon_r'') \text{ avec } \epsilon_r' = \epsilon_r$$

On caractérise souvent un diélectrique imparfait par la tangente de pertes :

$$\text{tg} \delta = \frac{\epsilon_r''}{\epsilon_r'} = \frac{\sigma}{\omega \epsilon}; \text{ avec } \epsilon = \epsilon_0 \epsilon_r \quad (\text{I. 12})$$

I.6. Propriétés diélectriques des tissus humains

Les tissus biologiques sont supposés être non magnétiques et se caractérisent principalement par sa teneur en eau, comme il sera montré par la suite.

Dans l'imagerie micro ondes quantitative, les propriétés diélectriques de l'objet sont imagées où on trouve une variation significative de la permittivité complexe, défini par l'équation (I. 1) :

$$\epsilon^* = \epsilon' + j \epsilon'' \quad (\text{I. 13})$$

où ϵ' est la permittivité relative qui décrit les effets de polarisation des particules chargées dans le tissu et ϵ'' décrit les pertes de phase dues aux courants de déplacement générés par le champ électromagnétique appliqué. Les pertes sont souvent décrites par la conduction ' σ ', tel que défini dans l'équation (II. 2), ^[44] :

$$\sigma = 2 \pi f \epsilon_0 \epsilon'' \quad (\text{I. 14})$$

Depuis le début du 20ème siècle, plusieurs chercheurs ont été intéressés par les propriétés électriques du corps humain et le domaine de l'interaction physique entre les champs électromagnétiques et les propriétés diélectriques des tissus humain. « Foster » et

« Schwan » a publié une étude critique sur les mécanismes physiques à l'origine de la dispersion des tissus biologiques, (dépendance de fréquence) et les propriétés diélectriques des tissus humain ^[44].

Les tissus humain sont très dispersive due à la relaxation cellulaire et moléculaire, générés par les différentes parties du tissu à des fréquences différentes. Pour une incidente micro ondes, la relaxation dominant est la relaxation dipolaire des molécules d'eau libre. Par conséquent, les propriétés diélectriques des tissus biologiques dans la région de micro-ondes sont fortement liées à la teneur en eau.

Plus récemment, « Gabriel » a fait une révision approfondit des mesures des propriétés électriques des tissus humains, avec l'objectif de développement des modèles physique des tissus humain pour des fréquences entre 10 Hz à 100 GHz ^{[45] - [46] - [47]}. Le modèle de Debye est un modèle bien connu standard pour la dispersion des tissus biologiques, et qui est donné par l'expression suivante ^[47]:

$$\varepsilon^*(f) = \varepsilon_{\infty} + \frac{\varepsilon_s - \varepsilon_{\infty}}{1 + j2\pi f \tau} \quad (\text{I. 15})$$

Où ε_{∞} est la permittivité à des fréquences ' $2\pi f \tau \gg 1$ ', ε_s est la permittivité à des fréquences ' $2\pi f \tau \ll 1$ ', et τ est la constante de temps du mécanisme de relaxation dans les tissus. Pour développé un modèle des propriétés électrique à une bande plus large, la constante de temps peut être divisé en plusieurs régions pour correspondre à différents types de relaxation ^[48].

$$\varepsilon^*(f) = \varepsilon_{\infty} + \frac{\varepsilon_s - \varepsilon_{\infty}}{1 + j2\pi f \tau_1} + \frac{\varepsilon_2 - \varepsilon_{\infty}}{1 + j2\pi f \tau_2} \quad (\text{I. 16})$$

Les permittivités ε_{∞} et ε_s doivent également être divisés dans les mêmes régions en ajoutant les valeurs intermédiaires. Toutefois, en raison de la complexité de la structure et la composition des tissus biologiques, « Gabriel » a utilisé l'expression étendue de Cole-Cole, défini dans l'équation (I. 17), ^[47].

$$\varepsilon^*(f) = \varepsilon_{\infty} + \sum_n \frac{\Delta\varepsilon_n}{1 + (j2\pi f \tau_n)^{1-\alpha_n}} + \frac{\sigma_i}{j2\pi f \varepsilon_0} \quad (\text{I. 17})$$

Avec σ_i est la conductivité statiques

L'équation (I. 17) a été utilisée avec succès dans une bande de fréquence très large entre 10 Hz-100 GHz par un choix individuel des paramètres des différents tissus ^[47].

I.7. Propriétés diélectriques des tissus mammaires

Les tissus mammaires des femmes ont également été étudiés, avec un accent sur la détection de cancer de sein. Mesure Ex vivo (tests biologiques mis en place en dehors de l'organisme) des tissus mammaires humains malignes et normales a été réalisée par plusieurs groupes, depuis le début des années 80. « Chaudhary » entre 3 MHz-3 GHz ^[49], « Surowiec » 20 kHz à 100 MHz ^[50], « Campbell » à 3,2 GHz ^[51] et « Joines » entre 50 MHz-900 MHz ^[52]. La conclusion de ces mesures est qu'il y a un contraste significatif entre les tissus mammaires malins et normaux, dans la gamme des fréquences de micro-ondes. Toutefois, les valeurs mesurées diffèrent beaucoup en raison principalement de la complexité de la structure tissulaire des tissus fibroglandulaires et gras. Les valeurs sont résumées dans le tableau (I.1). Par ailleurs, il a été démontré que le contraste entre les tumeurs et les tissus normaux est légèrement surestimée lors des mesures ex vivo. Cela pourrait être que les propriétés diélectriques des tissus sont changées quand ils sont enlevés, en raison de changements dans la circulation sanguine, teneur en eau et l'interruption du métabolisme ^[44].

Tissus	ϵ'	σ (S/m)
Tissus normaux	10 – 25	0.35 - 1.05
Graisse	4 - 4.5	0.11 - 0.14
Tumeur (maligne)	45 – 60	3.0 - 4.0
Tumeur (bénigne)	10 – 50	1.0 - 4.0

Tableau I.1 : Propriétés diélectriques de sein féminin mesuré en ex vivo (2 – 3.2 GHz).

Récemment « Lazebnik » a publié la nécessité d'une caractérisation à grande échelle des propriétés diélectriques de seins féminins ^{[53] - [54]}. Grâce aux efforts de collaboration entre l'Université de Wisconsin-Madison et l'Université de Calgary une étude à large bande en ex vivo des tissus mammaires a été lancée et publiée en 2007. La conclusion de cette étude était que les tissus mammaires normaux peuvent être classés en trois groupes différents selon le contenu adipeux, (0-34 adipeux%), (35-84 adipeux%) et (84 à 100% tissu adipeux). En utilisant cette classification, ils ont obtenu des résultats beaucoup plus stables en développant le modèle de Cole-Cole pour chacun des trois groupes de tissus et des tissus cancéreux. Ces

résultats représentent la plate-forme importante des caractéristiques des tissus mammaires pour les micro-ondes. Dans la figure (I.8), les résultats des modèles de Cole-Cole sont représentés, entre 300 MHz et 5 GHz. Cependant, il est notable que la partie imaginaire est légèrement surestimée pour les fréquences inférieures à 1 GHz dans le modèle de Cole-Cole pour les tissus mammaires peu adipeux.




Figure I.8 : Permittivité complexe des tissus mammaires cancéreux et normaux avec différent contenu adipeux du modèle de Cole-Cole [92, 93], (a) la partie réelle, (b) la partie imaginaire.

I.8.Conclusion

Dans cette partie, une revue des différentes techniques d'imagerie micro ondes dans les systèmes modernes de détection et de localisation des objets sont présentées. Un état d'art et les challenges des diverses algorithmes adaptés pour de telles applications ont été alors énumérés. Ensuite, nous avons présenté la technique d'imagerie micro ondes confocal ou radar et leur différentes approches à savoir mono, bi et multi-statiques, ainsi que les algorithmes de reconstruction et les méthodes d'imagerie micro ondes tomographique.

Chapitre II



Théorie des approches SVM et SVR

II.1.Introduction

Ces dernières années, il a soufflé comme un vent de révolution en apprentissage artificiel. Du côté des applications, on s'est tourné vers la fouille de très grandes bases de données réelles, avec les défis attenants en termes de complexité en calcul et en espace, de prétraitement nécessaire des données, et de présentation des résultats aux utilisateurs. Avec aussi de nouveaux besoins d'interactivité entre utilisateurs et outils d'apprentissage. Mais le bouleversement n'a pas semblé Moindre du côté conceptuel. Depuis 1995, nul n'est sensé ignorer les enseignements de Vapnik, et il est devenu quasiment impossible de ne pas essayer les SVMs ou le boosting sur un nouveau problème d'apprentissage. De quoi s'agit-il ?

Nous nous intéressons ici aux SVM. Étant donnée leur extraordinaire fortune, qui dépasse les cercles de la communauté de l'apprentissage artificiel, ce chapitre a pour objectif de les présenter de manière simple, mais assez complète. Une remarque préalable : SVM et SVR est l'acronyme de Support Vector Machines et support vector regression en anglais, méthodes et terme inventés par Vapnik principalement. Nous traduisons ici ce terme par Séparateurs à Vaste Marge^[55].

II.2. Support vector machine

II.2.1.Généralités

Les machines à vecteurs de support ou séparateurs à vaste marge (en anglais Support Vector Machine, SVM) sont un ensemble de techniques d'apprentissage supervisé destinées à résoudre des problèmes de discrimination. Les SVM sont une généralisation des classifieurs linéaires.

Les SVM ont été développés dans les années 1990 à partir des considérations théoriques de Vladimir Vapnik sur le développement d'une théorie statistique de l'apprentissage : la Théorie de Vapnik-Chervonenkis^[56]. Les SVM ont rapidement été adoptés pour leur capacité à travailler avec des données de grandes dimensions, le faible nombre d'hyper paramètre, leurs garanties théoriques, et leurs bons résultats en pratique.

Les SVM ont été appliqués à de très nombreux domaines (bioinformatique, recherche d'information, vision par ordinateur, finance...). Selon les données, la performance des

machines à vecteurs de support est de même ordre, ou même supérieure, à celle d'un réseau de neurones ou d'un modèle de mixture gaussienne ^[57].

II.2.2. Mise en œuvre des SVM

La réalisation d'un programme d'apprentissage par SVM se ramène essentiellement à résoudre un problème d'optimisation impliquant un système de résolution de programmation quadratique dans un espace de dimension conséquente. C'est pourquoi ces programmes utilisent des méthodes spéciales pour y parvenir de manière efficace et il n'est pas recommandé de chercher à réaliser soi-même un tel programme ^[58].

L'utilisation de ces programmes revient surtout à sélectionner une bonne famille de fonctions noyau et à régler les paramètres de ces fonctions (par exemple l'exposant pour les fonctions noyau polynomiale, ou bien l'écart type pour les fonctions à base radiale). Ces choix sont le plus souvent faits par une technique de validation croisée, dans laquelle on estime la performance du système en la mesurant empiriquement sur des exemples n'ayant pas été utilisés en cours d'apprentissage. L'idée est de chercher les paramètres permettant d'obtenir la performance maximale.

II.3. Définition de base

II.3.1. Séparation linéaire (séparateur linéaire)

Dans le cas de la discrimination biclassée, nous supposons que les données sont des couples $(x_i, y_i)_{1 \leq i \leq n} \in X \times Y$, où X désigne l'espace des variables explicatives souvent pris dans $\mathbb{R}^d$. $Y = \{-1, +1\}$ et n étant la taille de l'échantillon. L'appartenance d'une observation x_i à une classe ou à une autre est matérialisée ici par la valeur -1 ou $+1$ de son étiquette y_i .

L'échantillon d'apprentissage S est ainsi une collection de réalisations c-à-dire du couple aléatoire (x, y) dont la distribution P est fixe mais inconnue. Cet ensemble est souvent noté par : $S = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\} \subseteq (X \times Y)^n$

Une fonction séparatrice entre les classes C_1 et C_2 est une fonction de décision f définie de $\mathbb{R}^d$ dans $\mathbb{R}$ telle que toute observation x_i est affectée à la classe qui correspond au signe de $f(x_i)$ si :

$-f(x_i) \geq 0$, x_i est affectée à la classe positive $(+1)$.

$-f(x_i) \leq 0$, x_i est affectée à la classe négative (-1) .

Cette fonction peut être de nature variée. Si f est linéaire, on parle d'une séparatrice linéaire ou bien d'un hyperplan séparateur, elle prend la forme générale suivante :

$$\begin{aligned} f(x) &= \langle w, x \rangle + b \quad \text{avec} \quad (w, b) \in \mathbb{R}^2 * \mathbb{R} \\ &= \sum_{i=1}^n w_i x_i + b \end{aligned} \quad (\text{II.1})$$

Où w et b sont des paramètres, et $x \in \mathbb{R}$ est une variable.

La méthodologie d'apprentissage implique la recherche des paramètres w et b séparant le mieux possible les données d'apprentissage des classes C_1 et C_2 dans l'espace $\mathbb{R}^d$.

La fonction signe ($f(x)$) est appelée classifieur linéaire.

Géométriquement, cela revient à considérer un hyperplan qui est le lieu des points x satisfaisant $\langle w, x \rangle + b = 0$. En orientant l'hyperplan, la règle de décision correspond à observer de quel côté de l'hyperplan se trouve l'exemple x_i . La figure II. 1 représente la situation dans $\mathbb{R}^2$.

On voit que le vecteur w définit la pente de l'hyperplan : w est perpendiculaire à l'hyperplan. Le terme b quant à lui permet de translater parallèlement à lui-même.




Figure II. 1 : l'hyperplan correspondant à la fonction de décision d'un classifieur linéaire dans $\mathbb{R}^2$

II.3.2. Notion de marge

a. Marge d'une observation

La marge d'une observation $(x, y) \in S$ relativement à la fonction f est définie par :

$$\gamma_i = y_i f(x_i) \quad (\text{II.2})$$

Cette marge peut prendre une valeur négative. Elle dépend de la fonction f et non du classifieur signe $(f(x_i))$. Si g est un multiple de f , les classifieurs pour ces deux fonctions sont les mêmes mais pas leurs marges.

L'observation (x_i, y_i) est bien classée par le classifieur f si et seulement si $\gamma_i > 0$.

La valeur absolue de γ_i est proportionnelle à la distance (marge) euclidienne $d_i(w, x, b)$ séparant le point x_i de l'hyperplan $H(w, b)$ associé à f . La marge euclidienne est donnée par :

$$d_i(w, x, b) = \frac{w \cdot x_i + b}{\|w\|} \quad (\text{II.3})$$

Ces deux quantités ne coïncident que lorsque $\|w\| = 1$, dans ce cas nous parlons de la marge euclidienne. Ainsi, c'est la métrique euclidienne que nous utilisons en calculant les marges plus tard.

b. Distribution de marge d'un hyperplan

La distribution de marge d'un hyperplan $H(w, b)$ par rapport à l'échantillon d'apprentissage S est définie par :

$$D_m(H_{(w,b)}) = \{\gamma_i ; i = 1, 2, \dots, n\} \quad (\text{II.4})$$

c. Marge d'un hyperplan :

La marge d'un hyperplan $H(w, b)$ par rapport à l'échantillon d'apprentissage S est définie par :

$$M(H_{(w,b)}) = \min_{1 \leq i \leq n} D_m(H_{(w,b)}) \quad (\text{II.5})$$

II.4. Machine à vecteurs supports linéaires

II.4.1. Cas des données séparables

Dans le cas de données séparables, il existe une infinité d'hyperplans permettant de séparer les deux classes, comme l'illustre la figure II.2.




Figure II.2 : Exemple d'hyperplans séparateurs dans $\mathbb{R}^2$

La séparabilité des données implique que la contrainte suivante est remplie pour chaque exemple

$$\begin{cases} W \cdot X_i + b \geq 1 \text{ si } y_i = 1 \\ W \cdot X_i + b \leq -1 \text{ si } y_i = -1 \end{cases}$$

Ce qui équivaut à :

$$y_i(w \cdot x_i + b) \geq 1 \text{ pour } i=1 \dots n \quad (\text{II.6})$$

Nous n'allons plus nous contenter d'en trouver un hyperplan séparateur. Mais nous allons en plus chercher parmi ceux-ci l'hyperplan optimal ^[56].

L'hyperplan optimal est celui qui maximise la marge $M(H)$ (figure II.3). Comme on cherche à maximiser cette marge, on parlera de méthode des séparateurs à vaste marge.




Figure II.3 : Hyperplan optimal et marge géométrique associée dans $\mathbb{R}^2$.

Maximiser la marge M est équivalent à maximiser la somme des distances euclidiennes des deux classes par rapport à l'hyperplan. Ainsi, la marge a l'expression mathématique suivante :

$$\begin{aligned}
 M(w,b) &= \min_{x_i, y_i = -1} d(w, b, x) + \min_{x_i, y_i = 1} d(w, b, x) \\
 &= \min_{(x_i, y_i = -1)} \frac{|w \cdot x_i + b|}{\|w\|} + \min_{(x_i, y_i = 1)} \frac{|w \cdot x_i + b|}{\|w\|} \\
 &= \frac{1}{\|w\|} [\min_{(x_i, y_i = -1)} |w \cdot x_i + b| + \min_{(x_i, y_i = 1)} |w \cdot x_i + b|] \\
 &= \frac{1}{\|w\|} [1 + 1] \\
 &= \frac{2}{\|w\|} \tag{II.7}
 \end{aligned}$$

Trouver l'hyperplan optimal revient donc à maximiser $2/\|w\|$.

II.5. Implémentation

Pour effectuer l'apprentissage d'un SVM la manière la plus simple est de résoudre le problème de programmation quadratique formulé à l'aide d'un Solver de programmation quadratique, comme étant un problème standard de la théorie d'optimisation, une variété de ressources logicielles existe pour la Programmation Quadratique (QP) (exemple : le QUADPROG de MATLAB).

D'autres méthodes proposent la décomposition du problème en plusieurs sous-problèmes afin de faire face à la limite des machines en calcul pour des exemples très vastes (Quadprog devient déficient pour un problème de 100,000 instances d'exemple).

II.6. Avantages et inconvénients

II.6.1. Avantages

- Absence d'optimum local.
- contrôle explicite du compromis entre la complexité du classifieur et l'erreur.
- Possibilité d'utilisation de structure de données comme les chaînes de caractères et arbres comme des entrées.
- traitement des données à grandes dimensions.

II.6.2. Inconvénients

- Demande des données négatives & positives en même temps.
- Besoin d'une bonne fonction Kernel.
- Problèmes de stabilité des calculs dans la résolution de certains programmes quadratiques à contraintes.

II.7. Régression par les machines à vecteurs supports SVR

La régression par les machines à vecteurs supports (SVR pour Support Vector Régression) est une extension des machines à vecteurs supports développées par l'équipe de VAPNIK ^[56].

Le but de cette approche est de déterminer l'hyperplan optimal représentant le jeu de données. Cet hyperplan doit interpoler les observations avec une certaine marge ε , marge définie par la fonction perte d'insensibilité ε . Les principaux avantages de cette approche sont: sa robustesse contre le bruit et les erreurs, ainsi que la possibilité de son utilisation dans les cas non-linéaires grâce aux fonctions noyaux.

II.7.1. Méthode standard

Par soucis de familiarité avec le formalisme des machines à vecteurs supports, nous allons en adopter les notations. Cela induit quelques changements avec les notations utilisées précédemment dans ce manuscrit. Le produit scalaire sera noté $\langle \dots, \rangle$ et les paramètres du mouvement ω à la place de θ .

II.7.1.1. Idée de base : Cas linéaire

Soit un ensemble de données $\{(x_1, y_1), \dots, (x_n, y_n)\} \subset X$, où X représente l'espace des données. Dans la régression par vecteurs supports, notre objectif est de trouver la fonction $f(x)$ qui possède, au plus, une déviation de ε par rapport aux cibles y_i de toutes les données de l'ensemble, et dans le même temps, qui soit aussi "plate" que possible. En d'autres termes, nous ne ferons pas attention aux erreurs tant que celles-ci seront inférieures à ε , mais nous n'accepterons aucune déviation qui lui soit supérieure.

Nous commencerons par décrire le cas des fonctions linéaires f , prises sous la forme :

$$f(x) = \langle \omega, x \rangle + b \text{ avec } \omega \in X, b \in \mathbb{R} \quad (\text{II.8})$$

Où $\langle \cdot, \cdot \rangle$ représente le produit scalaire dans X . La platitude dans le cas linéaire signifie que l'on cherche le plus petit ω . La façon la plus simple de s'en assurer est d'utiliser la norme Euclidienne au carré, c'est à dire $\|\omega\|^2$. Formellement, nous pouvons écrire ce problème comme un problème d'optimisation convexe présenté ci-dessous dans sa forme primale :

$$\text{Minimiser} \quad \frac{1}{2} \|\omega\|^2$$

Sous les contraintes
$$\begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon \\ y_i - \langle w, x_i \rangle - b \geq -\varepsilon \end{cases} \quad (\text{II.9})$$

Cependant, une hypothèse tacitement admise dans cette équation est qu'il existe une fonction f qui approxime tous les couples de données (x_i, y_i) avec une précision ε , ou en d'autres termes, que le problème d'optimisation convexe possède une solution. Mais, bien souvent, ceci n'est pas le cas et nous devons donc nous résoudre à autoriser quelques erreurs. De façon analogue aux machines à vecteurs supports, nous pouvons utiliser la fonction perte linéaire d'insensibilité " et ainsi introduire les variables ressorts (ou variables de relâchement) ξ_i, ξ_i^* pour gérer les contraintes irréalisables du problème d'optimisation convexe, ce qui est appelé la marge douce (soft margin). La fonction perte linéaire d'insensibilité " est représentée sur la figure 1.1 et s'écrit sous la forme :

$$l(\xi)\varepsilon = \begin{cases} 0 & \text{si } |\xi| \leq \varepsilon \\ |\xi| - \varepsilon & \text{sinon} \end{cases} \quad (\text{II.10})$$





Figure II.4– Illustration de la fonction perte

Nous devons résoudre un problème d'optimisation convexe sous contraintes dont voici-la



II.5– Représentation de la marge douce

formulation primale :

$$\min L(\omega, \xi_i, \xi_i^*) = \frac{1}{2} \|\omega\|^2 + C \cdot \sum_{i=1}^n (\xi_i + \xi_i^*) \quad (\text{II.11})$$

Sous les contraintes :

$$\begin{cases} y_i - \langle w, x_i \rangle - b \leq \varepsilon + \xi_i \\ \langle w, x_i \rangle + b - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad \forall i \in \{1, \dots, n\} \quad (\text{II.12})$$

La constante C détermine le compromis entre la "platitude" de f et l'attache aux données, c'est à dire qu'elle donne plus ou moins d'importance (de poids) aux erreurs ξ_i, ξ_i^* par rapport à la solution régulière $\frac{1}{2} \|\omega\|^2$. Pour faire un parallèle avec les notions de risque, minimiser (II.11) revient à minimiser le risque empirique régularisé.

Afin de résoudre ce problème d'optimisation, nous utilisons sa formulation duale car il est beaucoup plus aisé d'y calculer la solution. De plus, la formulation duale apporte la clef d'une extension des machines à vecteurs supports aux fonctions non-linéaires. Pour obtenir cette formulation duale, nous utilisons une méthode standard de dualisation basée sur les coefficients du Lagrangien.

II.7.1.2. Cas non-linéaire

Certains noyaux, appelés noyaux de MERCER, ont la propriété suivante : il existe une transformation Φ telle que $k(x, z) = \langle \Phi(x), \Phi(z) \rangle$

Plus précisément, il existe un espace de Hilbert F muni d'un produit scalaire $\langle \cdot, \cdot \rangle$ tel que :

$$\Phi : \begin{matrix} X \rightarrow F \\ x \mapsto \Phi(x) \end{matrix} \quad (\text{II.13})$$

Et :

$$k(x, z) = \langle \Phi(x), \Phi(z) \rangle \quad \forall (x, z) \in X^2 \quad (\text{II.14})$$

Le problème traité est donc transformé dans un espace F de dimension supérieure à la dimension de X où il existe une solution linéaire.

II.8 Modifications apportées aux SVR

Souvent, les estimateurs robustes, développés en statistique, utilisent l'hypothèse qu'une structure dominante, constituée par les "bonnes" données, occupe une majorité absolue de l'ensemble des données. Cependant, l'implication qu'au moins 50% des données soient de "bonnes" données n'est pas toujours satisfaite. Comme nous l'avons vu précédemment, la méthode standard de la régression par les machines à vecteurs supports est peu robuste face aux outliers, surtout lorsque les outliers sont à effet levier (x-outliers). Sur la figure II.6, on voit que la solution est perturbée par les x-outliers, aussi bien le paramètre d'offset b que le paramètre de pente a .




Figure II.6– Exemple de la sensibilité du SVR face aux y-outliers.

Nous avons donc tenté de mettre en œuvre quelques solutions afin d'améliorer la robustesse de la méthode standard. Dans un premier temps, nous avons étudié une procédure itérative de la méthode standard, puis dans un second temps, nous proposons une pondération de la technique de régression par vecteurs supports qui s'avère tolérer plus de 50% de contamination du jeu de données.

II.8.1 Procédure itérative avec une marge adaptative

Cette méthode a été publiée par Weiyu Zhu et al. ^[59]. Il s'agit d'appliquer la méthode de régression par les machines à vecteurs supports de façon itérative. À la première itération, la valeur initiale de la marge γ est réglée avec une valeur importante, puis cette valeur sera diminuée à chaque itération afin d'affiner le résultat de l'estimation.

➤ Détection des outliers

Un des points clefs de la robustesse de la marge adaptative est que l'on a la possibilité de détecter les points aberrants et donc de les retirer du jeu de données. Un exemple en deux dimensions de la procédure de détection de ces points aberrants est donné sur la figure II.7. La ligne continue représente l'hyperplan optimal, elle est encadrée de 2 lignes pointillées qui représentent les limites de la marge d'insensibilité γ . Les points positionnés à l'extérieur de cette marge sont appelés les outliers-SVs et les points positionnés sur les limites de cette marge sont appelés les margin-SVs. Ces deux catégories de points représentent les vecteurs supports. Quant aux points à l'intérieur de la marge, ils sont nommés non-SVs ce qui signifie que ceux-ci ne sont pas des vecteurs supports, ils sont considérés comme les données correctes. Dans la dernière colonne du tableau II.1 sont rappelées les valeurs que prennent les variables duales pour chacune des catégories de points. On remarque que les points aberrants, c'est à dire les outliers-SVs, possèdent une des 2 variables égale au paramètre C . Ainsi, en effectuant un simple test sur les valeurs des variables duales, nous sommes capables de déterminer à quelles catégories appartiennent chacune de nos données. D'où l'idée d'utiliser cette information pour repérer et enlever les points aberrants du jeu de données afin de calculer, de nouveau, la régression par les machines à vecteurs supports sur les données conservées dans le but d'obtenir une estimation plus précise car moins perturbée. Il faut, bien sûr, diminuer la valeur γ de la marge car toutes les données conservées entrent dans la marge précédente. Cette procédure itérative se poursuit tant que 2 conditions sont respectées : la valeur de γ doit être supérieure à un seuil défini, et le taux des données conservées sur les données initiales doit être, lui aussi, supérieur à un seuil.

non-SVs	••	$\alpha_i = \alpha_i^* = 0$
margin-SVs	□□	$\alpha_i \in]0, C[\Rightarrow \alpha_i^* = 0$
Outlier-SVs	**	$\alpha_i = C \Rightarrow \alpha_i^* = 0$

Tableau. II.1. Détection des outliers




Figure II.7. Illustration 2D de la détection des outliers

II.8.2 Pondération du SVR

A fin d'augmenter les performances de la méthode standard de régression par les machines à vecteurs supports, il a été apporté différentes modifications soit d'un point de vue algorithmique soit directement dans la formulation du problème. Du point de vue algorithmique, Huang et Waegenan ont utilisé une procédure itérative qui diminue progressivement la largeur de la marge tout en éliminant du jeu de données les points considérés comme des outliers, ce qui est appelé la régression par les machines à vecteurs supports avec marge adaptative. Du point de vue mathématique, nous avons pondéré l'erreur commise sur un point par un poids soit binaire (0 ou 1) dans le cas d'une pondération dure, soit réel dans le cas d'une pondération douce. Le principe de la régression par les machines à vecteurs supports pondérée est d'assigner à chaque donnée un coefficient de pénalité en accord avec un critère prédéfini ^{[60] [61]}.

Soit $\beta_i^{(k)}$ qui représente le facteur poids associé au point (x_i, y_i) à l'itération k . Le principe de l'approche proposée consiste à affiner le vecteur de paramètre $\omega^{(k)}$ (estimé à l'itération k) avec la régression modifiée par les SVM, où chaque terme de pénalisation ξ_i^* dans la somme est pondéré par le poids $\beta_i^{(k)}$. Le problème d'optimisation sous contraintes de la régression pondérée par les SVM prend alors la forme suivante :

$$\text{Min } L(\omega^{(k)}, \xi_i, \xi_i^*) = \frac{1}{2} \|\omega^{(k)}\|^2 + C \cdot \sum_{i=1}^n \beta_i^{(k)} (\xi_i + \xi_i^*) \quad (\text{II.15})$$

Sous les contraintes :

$$\begin{cases} y_i - \langle \omega^{(k)}, x_i \rangle - b^{(k)} \leq \varepsilon + \xi_i \\ \langle \omega^{(k)}, x_i \rangle + b^{(k)} - y_i \leq \varepsilon + \xi_i^* \\ \xi_i, \xi_i^* \geq 0 \end{cases} \quad \forall i \in \{1, \dots, n\} \quad (\text{II.16})$$

Le Lagrangien de ce système s'écrit :

$$\begin{aligned} L(\omega^{(k)}, b^{(k)}, \xi_i, \xi_i^*, \alpha_i, \alpha_i^*, \eta_i, \eta_i^*) = & \frac{1}{2} \|\omega^{(k)}\|^2 + C \cdot \sum_{i=1}^n \beta_i^{(k)} (\xi_i + \xi_i^*) \dots \\ & - \sum_{i=1}^n \alpha_i (\varepsilon + \xi_i - y_i + \langle \omega^{(k)}, x_i \rangle + b^{(k)}) \dots \\ & - \sum_{i=1}^n \alpha_i^* (\varepsilon + \xi_i^* - y_i + \langle \omega^{(k)}, x_i \rangle + b^{(k)}) \quad (\text{II.17}) \\ & - \sum_{i=1}^n (\eta_i \xi_i + \eta_i^* \xi_i^*) \end{aligned}$$

Seule la dérivée suivant ξ_i^* sera différente par rapport à la régression standard des machines à vecteurs supports :

$$\frac{\partial L}{\partial \xi_i^*} = C \beta_i^{(k)} - \alpha_i^* - \eta_i^* \quad (\text{II.18})$$

La formulation duale de la régression pondérée sera la même que celle de la régression standard, c'est à dire :

$$\begin{aligned} \max L(\alpha_i, \alpha_i^*) = & -\frac{1}{2} \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) (\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \dots \\ & - \varepsilon \sum_{i=1}^n (\alpha_i + \alpha_i^*) + y_i \sum_{i,j=1}^n (\alpha_i - \alpha_i^*) \end{aligned} \quad (\text{II.19})$$

Avec une différence uniquement sur les contraintes :

$$\begin{cases} (\alpha_i^* - \alpha_i) - 0 \\ \alpha_i, \alpha_i^* \in [0, C \beta_i^{(k)}] \end{cases} \quad (\text{II.20})$$

En fait, seule la limite supérieure des coefficients de Lagrange α_i et α_i^* est modifiée de façon dynamique à chaque itération. Pour comprendre l'effet des facteurs poids sur la régression, nous devons analyser les propriétés des variables duales α_i et α_i^* ainsi que des variables ressorts associées ξ_i et ξ_i^* . D'après le tableau. II.1 accompagnant la figure II.7, il apparaît que seules les données sur ou à l'extérieur de la marge étaient des vecteurs supports et contribuaient au calcul de la solution. Les points à l'intérieur de la marge n'étant pas des vecteurs supports, ils n'y contribuaient pas. Ces propriétés étant définies par les valeurs des variables duales, nous avons eu l'idée de forcer ces valeurs à 0 pour un point jugé comme aberrant, ce qui permet de ne plus prendre en compte ce point pour le calcul de la solution.

II.9. Conclusion

Les SVMs présentent un alternatif utile aux différentes méthodes de classification classique, leurs principes de vaste marge et fonction Kernel les permettent de réaliser des taux de classification et de minimisation très importants.

La régression par machines à vecteurs supports a été présentée dans sa forme standard dans les cas de modèles linéaires et non-linéaires. Différentes améliorations ont été apportées à cette forme standard pour la rendre robuste : marge adaptative, pondérations adaptatives hard et soft. Ces techniques de pondération tentent de réduire progressivement l'influence des outliers en x et y sur l'estimation.

Chapitre III



Applications des approches SVM et SVR pour la classification

III.1. Introduction

Les recherches dans le domaine de la reconstruction d'objets à partir de champs électromagnétiques ont pris une ampleur considérable durant la dernière décennie, en raison de leurs diverses applications dans de nombreux domaines comme la médecine (détection du cancer), la biologie, géophysique et d'autres sciences ^[62].

Le cancer du sein est l'une des maladies les plus dangereuses dans le monde moderne avec une mortalité élevée ^[63]. On estime que dans l'Union européenne, toutes les 2,5 minutes, une femme reçoit un diagnostic de cancer du sein. Toutes les 7,5 minutes, une femme meurt de la maladie. L'Algérie a connu ces dix dernières années une évolution importante du nombre de cancers du sein, En 2008 on dénombre 5 000 à 7 000 nouveaux cas alors qu'en 2003 on en comptait 2 000 par an ^[64].

La détection précoce des petites tumeurs du sein est absolument nécessaire pour prévenir les métastases du cancer et pour l'obtention d'un bon pronostic du traitement du cancer. Par conséquent, il est très important de disposer des technologies et des algorithmes qui sont capables de structures image tumorale de quelques millilitres dans le sein non-invasive et avec un coût relativement faible.

Nous présentons dans ce chapitre une nouvelle approche stochastique basée sur supports vector machine capable de classifier les tumeurs du cancer du sien. Une étude comparative en utilisant les réseaux de neurones artificiels (RNA) sera faite dans le but de valider les approches utilisées.

III.2 Modèle du sien pour la collection des données

III.2.1Modèle de sien

Dans la littérature, plusieurs modèles du sein ont été utilisés à savoir : les modèles sphériques, cylindriques,... ^{[65] - [66] - [67]}. Le choix du modèle dépend de l'application visée. Dans notre application, nous avons utilisé un modèle donné par « S. A. AlShehri et S. Khatun », ayant la forme hémisphérique (figure III.1) et les dimensions données dans le tableau (III.1).

Partie de Modèle	Taille en (cm)
Diamètre du sein	10
Hauteur du sein	6
Epaisseur de la peau	0.2
Epaisseur de la poitrine	2

Tableau III. 1 : Dimension des paramètres du modèle




Figure III. 1 : Vue du modèle sous CST

Les propriétés diélectriques utilisées sont données dans le tableau (III.2) ^[67], où σ est la conductivité des tissus en (siemens / mètre) et ϵ_r est la permittivité relative.

	Conductivité σ (S/M)	Permittivité ϵ_r
Peau	1.49	37.9
Graisse	0.14	5.14
Poitrine	1.85	53.5
Tumeur	1.20	50

Tableau III. 2 : Propriétés diélectriques des paramètres du modèle

Dans la littérature ^{[68] - [69] - [70] - [71]}, le rayon de la tumeur varie de 0,2 cm à 1,5 cm. Dans notre cas, nous avons pris une tumeur ayant un rayon de 0,5 cm vue qu'elle est proche de la taille minimale.

III.2.Choix de l'antenne

Dans notre application, nous avons utilisé une antenne papillon (bow-tie) représenté par la figure (III.2) pour la transmission d'une impulsion gaussienne figure (III.3) dont la fréquence centrale est de 4GHz. Cette même antenne été utilisée pour la récupération du signal diffusé (figure III.4).




Figure III.2 : Vues de dessus et de côté d'antenne bow-tie UWB




Figure III. 3: Impulsion gaussienne Transmise

Ce type d'antenne est très utilisé dans notre domaine de recherche. On peut assimiler cette antenne à une antenne dipolaire dont on aurait élargi les fils dans l'optique d'augmenter la bande passante figure (III.2). Les antennes papillon présentent de nombreux avantages, tels que le faible profile, de haute efficacité de rayonnement et faciles pour la fabrication etc. Ils sont utilisés dans de nombreux domaines en raison des avantages mentionnés ci-dessus, tels que les radars à ondes pénétrantes ^{[72] - [73]} et d'impulsion des antennes ^{[74] - [75]}. Ces antennes ont une polarisation linéaire mais un gain et une directivité faible.

Dans ce travail, on a utilisé deux antennes papillon, dont l'une elle est utilisée pour la transmission d'impulsion gaussien et l'autre pour la récupération des données (figure III.4). Le transmetteur (Tx) et Récepteur (Rx) sont séparés par une distance de 10 cm (diamètre du sein).




Figure III.4: Représentation des antennes dans le modèle

Les caractéristiques de coefficient de réflexion et de transmission de l'antenne sont représentées dans la figure (III.5.).




Figure III.5 : Caractéristiques S_{11} et S_{21} d'une antenne en forme bow-tie

III.3. Étapes de construction et de validation des SVM

Généralement, les étapes de construction et de validation des SVM sont réparties en trois phases :

- ❖ Choix des entrées,
- ❖ Choix des sorties,
- ❖ Tests du modèle SVM ainsi construit sur de nouveaux exemples proches des exemples d'apprentissage.

Dans nos applications, nous avons fait appel au logiciel Matlab, " Bioinformatics toolbox" afin de réaliser ces étapes ^[76].

La figure (III.6) représente le schéma synoptique de la phase de test du modèle construit par les supports vector machine (SVM) et SVR.




Figure III.6 : Schéma synoptique de la phase de test du modèle par SVM et SVR

III.3.1. Construction du SVM et SVR

La construction des modèles SVM et SVR se fait par un processus itératif sur les échantillons d'une base de données construite préalablement. Cette base de données contient un ensemble de données (entrée/sortie) obtenues par simulation en utilisant le logiciel « CST ». Pour cela nous avons procédé de la manière suivante :

1. Placez une paire d'émetteur - récepteur à des cotés opposé du modèle du sien ;
2. Placez la tumeur dans une position fixée (dans notre cas au centre).
3. Transmettre une impulsion gaussienne d'une onde plane dans la direction de l'axe des abscisses ;
4. Recevoir le signal dans le point opposé ;
5. Changer la permittivité et la conductivité de la tumeur et répéter les étapes (3-4).

Cette procédure de génération de données a été réalisée pour 30 valeurs de permittivités et conductivités de la tumeur. En conséquence, deux groupes de signaux reçus ont été formés comme suit:

Groupe (1) : un ensemble de 20 signaux ont été utilisée pour l'apprentissage du SVM.

Groupe (2) : un ensemble de 10 signaux ont été utilisé pour la phase de test du SVM.

III.3.2. Phase de pré-traitement des données

Par ailleurs, nous avons remarqué que les signaux reçus par le récepteur contiennent un nombre d'échantillons qui peut aller de 4500 à 7200 échantillons (figure III.7). Afin de réduire ce nombre, nous avons pris uniquement un segment du signal la où la signature tumorale est prépondérante. Nous avons constaté qu'une signature tumorale peut être prise dans le segment (1,25 ns et 2,13ns), cependant le nombre d'échantillons varie d'un signal à l'autre. Dans le but de fixer un pas d'échantillonnage du signal, nous avons procédé à une interpolation cubique de Hermite permettant de générer un polynôme $P(x_i)$ tout en gardant la

même allure du signal (Annexe A). Le nombre d'échantillons obtenus après interpolation avec un pas de 0.01 dans le segment (1,25 ns et 2,13ns) est de 89.




Figure III. 7 : (a) signal transmis, (b) signal reçu

III.3.3. Phase d'apprentissage

L'apprentissage vise à découvrir les relations et motifs cachées dans des collections des données brutes. Il permet également de pallier les difficultés liées à l'acquisition de connaissances auprès d'experts du domaine. Un système d'apprentissage prend en entrée un ensemble d'exemples dont il cherche une définition. Dans notre cas, on cherche à apprendre le système à classifier les tumeurs (malignes ou bénignes) à partir des signaux fournis à son entrée. Ces signaux sont présentés sous forme de paramètre (éléments du vecteur d'entrée) qui représente les signaux diffusés par la tumeur. La sortie du modèle est la permittivité relative ϵ_r dans ce cas. En fait, si $\epsilon_r < 50$ on peut qualifier la tumeur de bénigne, sinon maligne^[77], ce qui fait correspondre deux classes à savoir (1 : maligne, 0 : bénigne).

III.3.4. Résultats de simulation et de test

Une fois la phase d'apprentissage achevée, nous avons testé les performances du SVM en utilisant le groupe 2 de test élaboré auparavant. Nous avons remarqué que le taux de classification obtenu est de 100% pour la phase de test (tableau III.3).

Groupes	Permittivité	Classe	type de la tumeur (B : bénigne, M : maligne)
Apprentissage	7.9	0	B
	9.6	0	B
	10.6	0	B
	11.6	0	B
	12.8	0	B
	15.5	0	B
	17.1	0	B
	18.9	0	B
	20.8	0	B
	22.9	0	B
	25.2	0	B
	30.5	0	B
	33.6	0	B
	45.5	0	B
	52	1	M
	54	1	M
	56	1	M
	58	1	M
	60	1	M
	62	1	M
Test	8.7	0	B
	27.7	0	B
	37.5	0	B
	7.2	0	B
	14.1	0	B
	47	0	B
	51	1	M
	53	1	M
	55	1	M
	57	1	M

Tableau III. 3 : Résultats de simulation pour la phase d'apprentissage et de test

III.4.-Conception du modèle de classification par approche SVR

Par ailleurs, nous avons utilisé l'approche SVR dans le but de construire un modèle permettant de générer pour chaque signal reçu de l'antenne, la permittivité relative et la conductivité de la tumeur. Pour cela, nous avons utilisé une toolbox disponible sur internet^[78] permettant de construire un modèle dans le cas de multi-sorties. Le modèle ainsi construit devra générer en sortie la permittivité relative et la conductivité de la tumeur. Nous avons construit deux groupes de signaux à savoir :

Groupe (1) : un ensemble de 17 signaux ont été utilisée pour l'apprentissage du SVR.

Groupe (2) : un ensemble de 7 signaux ont été utilisé pour la phase de test du SVR.

Les résultats de simulation sont résumés dans le tableau III.4. On remarque que les valeurs des permittivités et conductivités sont proches des valeurs réelles imposées sous « CST ». De même, une étude comparative à été faites en utilisant l'approche neuronale^[79]. On remarque que les réseaux de neurones sont plus précis que l'approche SVR, ceci est dû à l'utilisation de la méthode simplexe dans la phase d'apprentissage du SVR.

Groupes	Permittivité			Conductivité (S/m)			Type de Tumeur
	Sortie Réelle Sous « CST »	Sortie RNA	Sortie SVR	Sortie Réelle Sous « CST »	Sortie RNA	Sortie SVR	
Apprentissage	7,9	7.9169	8.4610	1,8	1.8278	1.8967	B
	9,6	9.6013	9.2927	2,2	2.2029	2.1198	B
	10,6	10.6009	10.1030	2,4	2.4124	2.3262	B
	11,6	11.6056	11.1304	2,7	2.6868	2.5878	B
	12,8	12.8025	12.4661	3,0	2.9987	2.9238	B
	15,5	15.5023	15.7338	3,7	3.6890	3.7399	B
	17,1	17.0989	17.6689	4,1	4.1165	4.2207	B
	18,9	18.8972	19.7347	4,5	4.5163	4.7328	B
	20,8	20.8036	21.8040	5,0	4.9797	5.2466	B
	22,9	22.9005	23.8795	5,5	5.4993	5.7612	B
	25,2	25.2064	25.9072	6,1	6.0980	6.2649	B
	30,5	30.5080	29.6759	7,4	7.4081	7.2010	B
	33,6	33.6106	31.3553	8,2	8.1912	7.6195	B
	45,5	45.5033	45.3691	10.7	10.7005	10.6714	B
	46.6	46.5987	46.5330	10.7	10.6994	10.6915	B
	48.2	48.2003	48.7611	10.9	10.9000	10.9626	B
	50	49.9797	49.4243	11.1	11.0921	11.0337	M
Test	8,7	8.0450	8.7509	2,0	1.8818	1.9778	B
	27,7	27.4427	27.8306	6,7	6.7865	6.7423	B
	37,5	37.2189	33.0752	9,0	9.0104	8.0475	B
	7,2	7.9123	8.3917	1,6	1.8233	1.8689	B
	14,1	13.9654	14.0096	3,3	3.2927	3.3088	B
	41.3	-	37.2023	9.9	-	8.9632	B
	47.5	49.4882	48.0268	10.8	11.0148	10.8780	B

Tableau III. 4 : Résultats de simulation pour la phase d'apprentissage et de test

III.5. Conclusion

Dans ce travail, deux approches SVM et SVR ont été utilisées pour la classification des tumeurs dans un modèle de sein. Les résultats de simulation sont très satisfaisants de point de vue taux de classification. Les signaux reçus ont été utilisés pour construire une base de données pour la phase d'apprentissage des modèles de classification.

A la différence des autres approches que nous avons citées (radar mono-statique) en premier chapitre, notre approche prend en considération la forme du signal représentant l'onde diffusée par le modèle de sein. Afin d'évaluer les performances de cette approche, nous avons effectué un nombre important de tests.

Conclusion Générale



Conclusion générale

Dans ce mémoire de Master, nous nous sommes intéressés à l'étude du problème de la classification des tumeurs du cancer du sein.

Une recherche bibliographique importante nous a permis de réaliser une description générale des différentes techniques et algorithmes réalisées jusqu'ici dans ce domaine de recherche ; en s'intéressant principalement à l'étude de l'imagerie micro onde tomographique dans les situations des objets à contraste élevé.

Dans une deuxième étape nous avons proposé une nouvelle variante d'algorithme de classification basée cette-fois-ci sur un formalisme mathématique de modélisation, en utilisant les SVM et SVR.

Les SVM et SVR permettent non seulement d'établir des relations analytiques importantes pour la phase de classification, mais aussi une grande flexibilité puisqu'il n'y a aucune restriction quant au nombre de paramètres du système en entrée et en sortie.

Les résultats obtenus montrent le bien fondé des approches utilisées de point de vue taux de classification. A la lumière de ce travail, l'approche SVR est la plus pratique et la meilleure du point de vue précision, quoi que le SVM reste toujours un moyen efficace auxiliaire à la présentation dans les cas spécifiquement douteux.

De nombreuses perspectives à ces travaux peuvent être envisagées à savoir :

- Classification des tumeurs par approche neuro-floue.
- Développement d'un système d'imagerie micro-ondes Ultra Large Bande.

Référence Bibliographique



Références Bibliographiques

- [1] T. Henriksson, N. Joachimowicz, C. Conessa, and J.-Ch. Bolomey, ``Quantitative Microwave Imaging for Breast Cancer Detection Using a Planar 2.45 GHz System``. IEEE TRANSACTIONS ON INSTRUMENTATION AND MEASUREMENT, VOL. 59, NO. 10, OCTOBER 2010
- [2] N. Joachimowicz, C. Pichot, and J.P Hugonin, ``Inverse Scattering: An Iterative Numerical Method for Electromagnetic Imaging``. IEEE TRANSACTIONS ON ANTENNAS AND PROPAGATION, VOL. 39, NO. 12, DECEMBER 1991
- [3] L. E. Larsen and J. H. Jacobi. ``Microwave scattering parameter imagery of an isolated canine kidney``. Med. Phys., vol. 6, pp. 394–403, 1979.
- [4] J. C. Bolomey, A. Izadnegahdar, L. Jofre, C. Pichot, G. Perronet, and M. Soalaimani. ``Microwave diffraction tomography for biomedical applications``. IEEE Trans. MTT, vol. 30, pp. 1998–2000, November 1982.
- [5] A.K.KUNDU, B.BANDYOPADHYAY. ``Reconstruction Algorithm for Microwave Tomography Using Iterative Regularized Gauss-Newton Method`` International Conference on Computer and devices for Communication (CODEC 06), Kolkata, 2006
- [6] N. Joachimowicz, C. Pichot and J. -P. Hugonin. ``Inverse Scattering: An Iterative Numerical Method for Electromagnetic Imaging``. IEEE Trans. Antennas Propagation., vol. 39, pp. 1742–1752, Dec. 1991.
- [7] B.BANDYOPADHYAY, A.KUNDU, and A.N.DATTA. ``An Iterative Algorithm for Microwave Tomography Using Levenberg-Marquardt Regularization Technique``. nd J Pure & Appl Physics, 43, pp. 649 – 653, 2005
- [8] X. Li, E. J. Bond, B. D. van Veen and S. C. Hagness. ``An Overview of Ultra-Wideband Microwave Imaging via Space-Time Beamforming for Early-Stage Breast-Cancer Detection``, IEEE Antennas Propagation. Mag., vol. 47, pp. 19–34, Feb. 2005.
- [9] X. Li, S. K. Davis, S. C. Hagness, D. W. van der Weide, and B. D. V. Veen. ``Microwave imaging via spacetime beamforming: Experimental investigation of tumor detection in multilayer breast phantoms``. IEEE Trans. Microwave. Theory Tech., vol. 52, pp. 1856–1865, Aug. 2004.

- [10] **J. Bond, X. Li, and S. C. Hagness.** *``Numerical and experimental investigation of an ultrawideband ridged pyramidal horn antenna with curved launching plane for pulse radiation``*. vol. 2, pp. 259–262, 2003
- [11] **X. Li and S. C. Hagness.** *``A confocal microwave imaging algorithm for breast cancer detection``*. IEEE Microwave and Wireless Components Letters, vol. 11, pp. 130–132, March 2001.
- [12] **B. Guo, Y. Wang, J. Li, P. Stoica, and R. Wu.** *``Microwave imaging via adaptive beamforming methods for breast cancer detection``*. Progress in electromagnetics research symposium (PIERS), Hangzhou, China, August 2005.
- [13] **R. Nilavalan, A. Gbedemah, I. J. Craddock, X. Li, and S. C. Hagness.** *``Numerical investigation of breast tumour detection using multi-static radar``*. IEE Electronics Letters, vol. 39, December 2003.
- [14] **E. Fishler, A. Haimovich, R. Blum, D. Chizhik, L. Cimini, and R. Valenzuela.** *``MIMO radar: an idea whose time has come``*. in Proceedings of IEEE Radar Conference, pp. 71–78, Philadelphia, Pa, USA, April 2004.
- [15] **L. Xu, J. Li, and P. Stoica.** *``Radar Imaging via Adaptive MIMO Techniques``*. In Proceedings of 14th European Signal Processing Conference (EUSIPCO '06), Florence, Italy, September 2006.
- [16] **E. J. Bond, X. Li, S. C. Hagness, and B. D. Van Veen,** *``Microwave imaging via space-time beamforming for early detection of breast cancer``*. IEEE Transactions on Antennas and Propagation, vol. 51, pp. 1690–1705, August 2003.
- [17] **Y. Xie, B. Guo, L. Xu, J. Li, and P. Stoica.** *``Multi-static adaptive microwave imaging for early breast cancer detection``*. in Proceedings of 39th ASILOMAR Conference on Signals, Systems and Computers, Pacific Grove, Calif, USA, October 2005.
- [18] **Fred K. Gruber, Edwin A. Marengo and Anthony J. Devaney.** *``Time reversal imaging with multiple signal classification considering multiple scattering between the targets``*. J. Acoust. Soc. Am. vol. 115 (6), June 2004, pp. 3042–3047.

- [19] **Yifan Chen, E.Gunawan, Kay Soon Low, S.C.Wang, Yongmin Kim and C.B. Soh,** ``Pulse design for time reversal method as applied to UWB microwave breast cancer detection: a 2-D analysis``. IEEE Trans.on Ant. and Prop., vol. 55, no. 1, , pp. 194-204, Jan 2007.
- [20] **Yao Xie, Bin Guo, Luzhou et Xu. Dept.** `` Multi-Static Adaptive Microwave Imaging for Early Breast Cancer Detection``. University of Florida P. O. Box 116130, Gainesville, FL 32611, USA. 2005.
- [21] **J. Li, P. Stoica, and Z. Wang.** ``On robust Capon beamforming and diagonal loading``. IEEE Transactions on Signal Processing, vol. 51, pp. 1702–1715, July 2003.
- [22] **J. Li, P. Stoica, Eds John Wiley & Sons,.** ``Robust Adaptive Beamforming`` New York, NY, USA, 2005.
- [23] **Yao Xie, Bin Guo, Jian Li, and Petre Stoica.** `` Novel Multistatic Adaptive Microwave Imaging Methods for Early Breast Cancer Detection``. University of Florida, P.O. Box 116200, Gainesville, FL 32611-6200, USA. January 2006.
- [24] **L. Jofre, M. S. Hawley, A. Broquetas, E. De Los Reyes, M. Ferrando and A. R. Elias Fuste.** ``Medical Imaging with a Microwave Tomographic Scanner``. IEEE Trans. Biomed. Eng., vol. 37, pp. 303–311, Mar. 1990.
- [25] **C. Pichot, L. Jofre, G. Peronnet and J. -C. Bolomey.** ``Active Microwave Imaging of Inhomogeneous Bodies``. IEEE Trans. Antennas Propagation., vol. 33, pp. 416–423, Apr. 1985.
- [26] **S. X. Pan and A. C. Kak.** ``A Computational Study of Reconstruction Algorithms for Diffraction Tomography: Interpolation Versus Filtered Backpropagation``. IEEE Transactions on Acoustics, Speech and Signal Processing, vol. 31, pp. 1262–1275, Oct. 1983.
- [27] **N. Joachimowicz, C. Pichot, and J. P. Hugonin.** ``Inverse scattering: An iterative numerical method for electromagnetic imaging``. IEEE Trans. Antennas Propagation., vol. 39, no. 12, pp. 1742–1752, Dec. 1991.
- [28] **S. Caorosi, G. L. Gragnani and M. Pastorino.** ``Two-Dimensional Microwave Imaging by a Numerical Inverse Scattering Solution``. IEEE Trans. Microwave Theory Tech., vol. 38, pp. 981–989, Aug. 1990.

- [29] **A. Fhager.** *``Microwave Tomography``*. Ph.D. Thesis, Department of Signals and Systems, Chalmers , University of Technology, 2006.
- [30] **A. Abubakar, T.M. Habashy, P.M. van den Berg, D. Gisolf.** *``The Diagonalized Contrast Source Approach: an inversion method beyond the Born approximation``*. Inverse Problems, Vol. 21, No. 2, pp. 685-702, 2005
- [31] **Z.Q. Zhang, Q.H. Liu.** *``Three-Dimensional Nonlinear Image Reconstruction for Microwave Biomedical Imaging``*. IEEE Trans. Biomedical Engineering, Vol. 51, No. 3, pp. 544-548, 2004.
- [32] **A. Abubakar, P. M. van den Berg and S. Y. Semenov.** *``Two- and Three-Dimensional Algorithms for Microwave Imaging and Inverse Scattering``* Journal of Electromag. Waves and Applications., vol. 17, pp. 209–231, 2003.
- [33] **S. Y. Semenov, A. E. Bulyshev, A. Abubakar, V. G. Posukh, Y. E. Sizov, A. E. Souvorov, P. M. Van den Berg, and T. C. Williams.** *``Microwave Tomographic Imaging of the High Dielectric-Contrast Objects Using Different``*. IEEE Trans. Microwave Theory Tech, VOL. 53, NO. 7, JULY 2005.
- [34] **M. Pastorino, A. Massa, and S. Caorsi.** *``A Microwave Inverse Scattering Technique for Image Reconstruction Based on a Genetic Algorithm``*. IEEE Trans. Instrumen. Measure., vol. 49, pp. 573–578, June 2000.
- [35] **M. Pastorino, S. Caorsi, A. Massa, and A. Randazzo.** *``Reconstruction Algorithms for Electromagnetic Imaging``*. IEEE Trans. Instrumentation. Measure., vol. 53, pp. 692–699, June 2004.
- [36] **M. Pastorino, S. Caorsi, and A. Massa.** *``A Global Optimization Technique for Microwave Nondestructive Evaluation``*. IEEE Trans. Instrumentation. Measure, vol. 51, pp. 666– 673, Aug. 2002.
- [37] **Q. Fang, P. M. Meaney, and K. D. Paulsen.** *``Microwave image reconstruction of tissue property dispersion characteristics utilizing multiple-frequency information``*. IEEE Trans. Microwave. Theory Tech., vol. 52, pp. 1866–1875, Aug. 2004.

- [38] K. D. Paulsen, P. M. Meaney, M. J. Moskowitz and J. M. Sullivan. ``A Dual Mesh Scheme for Finite Element Based Reconstruction Algorithms``. IEEE Trans. Medical Imag., vol. 14, pp. 504–514, Mar. 1995.
- [39] P. M. Meaney, M. W. Fanning, D. Li, S. P. Poplack and K. D. Paulsen. ``A Clinical Prototype for Active Microwave Imaging of the Breast``. IEEE Trans. Microwave Theory Tech., vol. 48, pp. 1841/1853, Nov. 2000.
- [40] A. Franchois, A. Joisel, C. Pichot and J. -C. Bolomey. ``Quantitative Microwave Imaging with a 2.45-GHz Planar Microwave Camera``. IEEE Trans. Medical Imag., vol. 17, pp. 550–561, Aug. 1998.
- [41] A. Franchois, C. Pichot. ``Microwave Imaging–Complex Permittivity Reconstruction with a Levenberg-Marquardt Method``. IEEE Trans. Antennas Propagat., vol. 45, pp. 203–215, Feb. 1997.
- [42] A. Broquetas, J. Romeu, J. M. Rius, A. R. Elias-Fuste, A. Cardama, and L. Jofre. ``Cylindrical geometry: A further step in active microwave tomography``. IEEE Trans. Microw. Theory Tech., vol. 39, pp. 836–844, May 1991.
- [43] A. Franchois and C. Pichot. ``Microwave imaging–complex permittivity reconstruction with a levenberg-marquardt method``. IEEE Trans. Antennas Propagat., vol. 45, pp. 203– 215, Feb. 1997.
- [44] K. R. Foster and H. P. Schwan, “Dielectric properties of tissues and biological materials: A critical review,” Crit. Rev. Biomed. Eng., vol. 17, pp. 25–104, 1989.
- [45] C. Gabriel, S. Gabriel, and E. Corthout, “The dielectric properties of biological tissues: I. literature survey,” Phys. Med. Biol., vol. 41, pp. 2231–2249, 1996.
- [46] S. Gabriel, R. W. Lau, and C. Gabriel, “The dielectric properties of biological tissues: II. measurements on the frequency range 10 hz to 20 ghz,” Phys. Med. Biol., vol. 41, pp. 2251–2269, 1996.
- [47] S. Gabriel, R. W. Lau, and C. Gabriel, “The dielectric properties of biological tissues: III. parametric models for the dielectric spectrum of tissues,” Phys. Med. Biol., vol. 41, pp. 2271–2293, 1996.

- [48] **R. Buchner, J. Barthel, and J. Stauber**, “*The dielectric relaxation of water between 0°C and 35°C*,” Chem. Phys. Lett., vol. 306, pp. 57–63, 1999.
- [49] **S. S. Chaudhary, R. K. Mishra, A. Swarup, and J. M. Thomas**, “*Dielectric properties of normal and malignant human breast tissues at radiowave and microwave frequencies*,” Indian J. Biochem. Biophys., vol. 21, pp. 76–79, Feb. 1984.
- [50] **A. J. Surowiec, S. S. Stuchly, J. R. Barr, and A. Swarup**, “*Dielectric properties of breast carcinoma and the surrounding tissues*,” IEEE Trans. Biomed. Eng., vol. 35, pp. 257–263, Apr. 1988.
- [51] **A. M. Campbell and D. V. Land**, “*Dielectric properties of female human breast tissue measured in vitro at 3.2 ghz*,” Phys. Med. Biol., vol. 37, pp. 193–210, 1992.
- [52] **W. T. Joines, Y. Z. Dhenxing, and R. L. Jirtle**, “*The measured electrical properties of normal and malignant human tissues from 50 to 900 mhz*,” Med. Phys., vol. 21, pp. 547–550, Apr. 1994.
- [53] **M. Lazebnik, L. McCartney, D. Popovic, C. B. Watkins, M. J. Lindstrom, J. Harter, S. Sewall, A. Magliocco, J. H. Booske, M. Okoniewski, and S. C. Hagness**, “*A large-scale study of the ultrawideband microwave dielectric properties of normal breast tissue obtained from reduction surgeries*,” Phys. Med. Biol., vol. 52, p. 26372656, 2007.
- [54] **M. Lazebnik, D. Popovic, L. McCartney, C. B. Watkins, M. J. Lindstrom, J. Harter, S. Sewall, T. Ogilvie, A. Magliocco, T. M. Breslin, W. Temple, D. Mew, J. H. Booske, M. Okoniewski, and S. C. Hagness**, “*A large-scale study of the ultrawideband microwave dielectric properties of normal, benign and malignant breast tissues obtained from cancer surgeries*,” Phys. Med. Biol., vol. 52, pp. 6093-6115, 2007.
- [55] **<http://www.support-vector-machine.org/SVM.../howto.pdf>**
- [56] **V. Vapnik**, “*the nature of statistical learning*“, theory.spring-Verlag, New York, USA, 1995
- [57] **<http://www.dtrek.com/svm.htm>**
- [58] **<http://www.kernelmachines.org/>**

- [59] **W. Zhu, SongWang, R-Sung Lin, and S. Levinson.** "Tracking of Object with SVM Regression. Dans IEEE Computer Vision Pattern Recognition Conf., pages 240–245, 2001.
- [60] **H.P. Huang et Y.H. Liu.** *Fuzzy Support Vector Machines for Pattern Recognition and Data Mining. International Journal of Fuzzy Systems*, 4(3) :pp 826–835, 2002.
- [61] **W. Waegeman et L. Boullart.** *An ensemble of weighted support vector machines for ordinal regression. Transactions on Engineering, Computing and Technology*, 12 :71–75, 2006.
- [62] **R. Nilavalan, A. Gbedemah, I. J. Craddock, X. Li, and S. C. Hagness.** ``Numerical investigation of breast tumour detection using multi-static radar``. IEE Electronics Letters, vol. 39, December 2003.
- [63] **M.A. Fischler and R.C. Bolles.** ``Random sample consensus: A paradigm for model fitting with applications to image analysis and automated cartography``. CACM, 24(6):381–395, June 1981.
- [64] **S. Kyriakides,** ``The Beacon, Breast Cancer Network Australia's mag-azine``, vol. 29, p. 10, 2009.
- [65] **W. Shao, and B. Zhou,** "UWB microwave imaging for breast tumor detection in inhomogeneous tissue," Proceedings of the 2005 IEEE Engineering in Medicine and Biology, 27th Annual Conference, Shanghai, China, 1496–1499, 2005.
- [66] **E. C. Fear, and M. A. Stuchly,** "Microwave detection of breast cancer," IEEE Transactions on Microwave Theory and Techniques, Vol. 48, 1854–1863, 2000.
- [67] **Miyakawa, M., T. Ishida, and M. Wantanabe,** "Imaging capability of an early stage breast tumor by CP-MCT," Proceedings of the 26th Annual International Conference of the IEEE EMBS, Vol. 1, pp. 1427–1430, San Francisco, CA, USA, 2004.
- [68] **J. M. Sill, and E. C. Fear,** "Tissue sensing adaptive radar for breast cancer detection-experimental investigation of simple tumor models," IEEE Transactions on Microwave Theory and Techniques, Vol. 53, pp. 3312–3319, 2005.
- [69] **E. C. Fear, and M. A. Stuchly,** "Microwave detection of breast cancer," IEEE Transactions on Microwave Theory and Techniques, Vol. 48, pp. 1854–1863, 2000.

- [70] **M. Wang, S. Yang, S. Wu, and F. Luo**, “*A RBFNN approach for DoA estimation of ultra wideband antenna array*,” *Neurocomputing*, Vol. 71, pp. 631–640, 2008.
- [71] **S. K. Davis, H. Tandradinata, S. C. Hagness, and B. D. Veen**, “*Ultrawideband microwave breast cancer detection: A detectiontheoretic approach using the generalized likelihood ratio test*,” *IEEE Transactions on Biomedical Engineering*, Vol. 52, pp. 1237– 1250, 2005.
- [72] **D. Uduwawala, et al.**, “*A deep parametric study of resistor-loaded bow-tie antennas for ground penetrating radar applications using FDTD*,” *IEEE Trans. Geoscience and Remote Sensing*, Vol. 42, No. 4, pp. 732–742, Apr. 2004.
- [73] **M. Birch, and K. D. Palmer**, “*Optimized bow-tie antenna for pulsed low-frequency ground-penetrating radar*,” *Proceeding of SPIE*, Vol. 4758, 2002.
- [74] **A. Lestari, et al.**, “*RC-loaded bow-tie antenna for improved pulse radiation*,” *IEEE Trans. Antennas and Propagation.*, Vol. AP-52, No. 10, pp. 2555–2563, Oct. 2004.
- [75] **C. Waldschmidt, and K. D. Palmer**, “*Loaded wedge bow-tie antenna using linear profile*,” *Electron. Lett.*, Vol. 37, pp. 208–209, 2001.
- [76] <http://www.mathworks.com/access/helpdesk/help/toolbox/bioinfo>
- [77] **Alshehri, S. A., Khatun, S., Jantan, A. B., R. Raja Abdullah S. A., Mahmud, R., Awang, Z.**, “*3d Experimental Detection And Discrimination Of Malignant And Benign Breast Tumor Using NN-Based UWB Imaging System*,” *Progress In Electromagnetics Research*, Vol. 116, pp 221-237, 2011.
- [78] <http://www.esat.kuleuven.be/sista/lssvmlab>
- [79] **A. MIRAOU**, “*Implémentation de quelques algorithmes de détection et de localisation d’objets par imagerie micro-onde*”, thèse de magister en télécommunications, Université de Tlemcen, octobre 2011.

Annexa



Interpolation cubique de Hermite

Soient (x_i, y_i) , $i = 0, \dots, n, n+1$ couples de valeurs réelles. Le but de tout problème d'interpolation est de déterminer une fonction g simple, telle que :

$$g(x_i) = y_i, \quad \text{avec} \quad i = 0, \dots, n. \quad (\text{A. 1})$$

Les points (x_i, y_i) sont appelés les points d'interpolation. L'interpolation polynomiale consiste à chercher la fonction g sous la forme d'un polynôme.

On remplace la courbe de « f » par la droite passant par $(x_i, f(x_i))$ et $(x_{i+1}, f(x_{i+1}))$:

$$p(x) = f(x_i) + \frac{f(x_{i+1}) - f(x_i)}{x_{i+1} - x_i} (x - x_i) \quad (\text{A. 2})$$

Dans l'interpolation de Hermite on cherche un polynôme qui prenne non seulement ses valeurs en un certain nombre de points d'interpolation donnés mais dont le polynôme dérivé est aussi fixé en ces points. On cherche un polynôme « P » tel que :

$$P(x_i) = y_i, \quad i = 0, \dots, n$$

$$P'(x_i) = z_i, \quad i = 0, \dots, n.$$

On a $2(n+1) = 2n+2$ valeurs données, le polynôme sera de degré au plus $2n+1$.

Soient P et Q deux polynômes de degré inférieur ou égal à $2n+1$ tels que :

$$P(x_i) = Q(x_i) = y_i \text{ et } P'(x_i) = Q'(x_i) = z_i, \quad i = 0, \dots, n. \quad (\text{A. 3})$$

Notons $R = P - Q$, polynôme de degré inférieur ou égal à $2n+1$. Alors R possède au moins $n+1$ racines doubles (les x_i , $i = 0, \dots, n$ car P et P' s'annulent en x_i) soit $2n+2$ racines, ce qui signifie que R est le polynôme nul.

Soit $f \in C^{2n+1}([a, b])$, dérivable $(2n+2)$ fois sur $]a, b[$. Si $a \leq x_0 < x_1 < \dots < x_n \leq b$, alors :

$$f(x) - P(x) = \frac{(x - x_0)^2 (x - x_1)^2 \dots (x - x_n)^2}{(2n+2)!} f^{(2n+2)}(\xi) \quad (\text{A. 4})$$

Pour ξ tel que $a \leq \min(x, x_0) < \xi < \max(x, x_n) \leq b$.

On se donne une fonction f que l'on cherche à interpoler sur un intervalle $[a, b]$. Soient n points x_i dans cet intervalle tels que $a = x_1 < \dots < x_n = b$. On note $y_i = f(x_i)$, $i = 1, \dots, n$. Sur

chaque intervalle $[x_i, x_{i+1}]$, $i = 1, \dots, n-1$, on cherche un polynôme P_i , $i = 1, \dots, n-1$ de degré 3 tel que :

$$P_i(x_i) = y_i \text{ et } P_i(x_{i+1}) = y_{i+1}, i = 1, \dots, n-1$$

$$P'_i(x_i) = s_i \text{ et } P'_i(x_{i+1}) = s_{i+1}, i = 1, \dots, n-1$$

où s_i , $i = 1, \dots, n$ sont des paramètres libres que nous préciserons plus tard.

Pour connaître le polynôme P_i de degré 3, nous avons bien 4 équations pour 4 inconnues !

Alors, quel que soit le choix de s_i , $i = 1, \dots, n$, le polynôme P_i , qui restreint à chaque intervalle $[x_i, x_{i+1}]$, $i = 1, \dots, n-1$ vaut P_i , est une fonction de classe $C^1([a, b])$, continue et dérivable sur $[a, b]$, de dérivée continue sur $[a, b]$. On présente deux exemples de choix pour les paramètres s_i , $i = 1, \dots, n$, qui sont les plus utilisés et les plus intéressants du point de vue de l'approximation.

On choisit $s_i = f'(x_i)$, $i = 1, \dots, n$. On peut alors démontrer que sur chaque intervalle $[x_i, x_{i+1}]$, $i = 1, \dots, n-1$, on a :

$$|f(x) - p_i(x)| \leq \left(\frac{|x_{i+1} - x_i|}{2} \right)^4 \max_{x_i \leq x \leq x_{i+1}} \frac{|f^{(4)}(\xi)|}{4!}, \quad \xi \in]x_i, x_{i+1}[\quad (\text{A. 5})$$

et donc que si $f \in C^4([a, b])$, on a :

$$|f(x) - P(x)| \leq \frac{(b-a)^4}{384} \max_{a \leq x \leq b} |f^{(4)}(\xi)|, \quad \xi \in]a, b[\quad (\text{A. 6})$$

Les paramètres s_i sont déterminés par la condition : “ P doit être deux fois continument dérivable”.

Ce qui donne les conditions :

$$P''_i(x_i) = P''_{i+1}(x_i), \quad i = 2, \dots, n-1. \quad (\text{A. 7})$$

Ces conditions donnent un système tridiagonal de $n-2$ équations qui est à diagonale strictement dominante donc inversible. Ce système a donc une solution et une seule. Il manque encore deux conditions qu'on appelle les conditions de bord, à savoir le choix de s_1 et s_n .

Le choix le plus simple est la condition libre $s_1 = s_n = 0$ qui donne le spline naturel de f . Mais ce choix est mauvais du point de vue de l'approximation car cela provoque des erreurs au bord

de l'intervalle et diminue donc la qualité de l'approximation. Un autre choix naturel si f' est connue aux extrémités est $s_1 = f'(x_1)$ et $s_n = f'(x_n)$, ce qui donne le spline interpolant complet de f .

Résumé :

Ce mémoire développe des techniques de classification basées sur les SVM et SVR en vue de la distinction entre les tumeurs malignes et bénignes du cancer du sein.

Les SVM et SVR permettent non seulement d'établir des relations analytiques importantes pour la phase de classification, mais aussi une grande flexibilité, puisqu'il n'y a aucune restriction quant au nombre de paramètres du système en entrée et en sortie. La phase de classification des tumeurs devient alors possible grâce à la relation explicite donnée par les SVM et SVR.

Pour cela, il est possible de construire les SVM et SVR durant la phase d'apprentissage en se basant sur un ensemble de solutions obtenues par simulation en utilisant le logiciel « CST ».

Les résultats de simulation montrent le bien fondé de l'approche utilisée du point de vue taux de classification.

Mots clés : imagerie microndes, classification, antenne, cancer du sein, SVM, SVR.

ملخص :

تهدف هذه المذكرة الى تبيان تطور التقنيات المتعلقة بمعرفة الانواع المتمركزة و الخاصة ببرنامجي SVM و SVR بهدف اكتشاف الاختلاف الموجود بين الاورام الليفية السليمة و الخبيثة لسرطان الثدي. ان برنامجي SVM و SVR لا يقومان فقط على انشاء العلاقات التحليلية الهامة المتعلقة بالتصنيف و لكن ايضا يسهل الاكتشاف السريع للأورام،لذا فانه اصبح من الممكن تحديد الاورام الليفية و هذا من خلال الشرح المدقق الذي يقدمانه برنامجي SVM و SVR . من هنا يمكن القول بأنه من الممكن الارتكاز على SVM و SVR خلال فترة التعلم و التجربة و ذلك بالاهتمام بالحلول المحصل عليها عن طريق التجربة باستعمال الحبكة الاعلامية « CST ». من خلال ما سبق توضح لنا بان نتائج التجربة تبين الفوائد الرئيسية و الهامة للمنهج المستعمل من اجل تحديد تصنيف الاورام.

كلمات البحث

SVM, SVR سرطان الثدي, تصنيف هوائي , ميكروويف التصوير