

ÉCOLE DOCTORALE MIPTIS

Thèse présentée par :

Oussama HADJERCI

soutenue le : **2017**

pour obtenir le grade de : **Docteur de l'Université d'Orléans**

Discipline : **Vision par ordinateur**

**Détection automatique du nerf dans les images
échographiques**

Thèse dirigée par :

Pierre VIEYRES

Professeur des universités, Université d'Orléans

Encadrée par :

Adel HAFIANE

Maître de conférences, INSA Centre Val-de-Loire

Co-Encadrée par :

Donattelo CONTE

Maître de conférences, Université de François Rabelais

RAPPORTEURS :

Didier VRAY

Professeur des universités, INSA Lyon

Isabelle BLOCH

Professeur des universités, Université Paris-Saclay

JURY :

Didier VRAY

Professeur, INSA Lyon

Isabelle BLOCH

Professeur, Université Paris-Saclay

Nicole VINCENT

Professeur, Université Paris Descartes

Alain DELBOS

Professeur, Clinique Médipole Gâronne

Adel HAFIANE

Maître de conférences, INSA-CVL de Bourges

Donatello CONTE

Maître de conférences, Université de François Rabelais

Pierre VIEYRES

Professeur, Université d'Orléans

Remerciements

Préface

L'anesthésie loco-régionale écho-guidée est une procédure en pleine expansion qui s'impose comme la technique de référence aujourd'hui, grâce à une visualisation en temps réel du nerf, de la progression de l'aiguille et de la distribution de l'anesthésique local autour du nerf. Cette technique est beaucoup plus précise que l'anesthésie loco-régionale par neurostimulation mais nécessite en contrepartie un apprentissage spécifique afin d'éviter des complications sévères liées à une erreur de localisation visuelle du nerf dans les images échographiques.

Dans cette thèse, nous proposons une méthode de détection des nerfs présents dans les images échographiques afin de faciliter le geste opératoire de l'anesthésie loco-régionale écho-guidée. La tâche d'identification est rendue particulièrement difficile à cause de la qualité visuelle des structures nerveuses qui souffre de la présence de faibles échos, d'artefacts et de frontières discontinues. L'objectif de cette thèse est de démontrer que le développement d'un algorithme à base de plusieurs caractéristiques comme la texture, la forme et la cohérence temporelle, permet tout en contournant les limitations liées à la structure nerveuse, de générer une segmentation robuste du nerf dans les images ultrasonores.

Dans le Chapitre 1, nous présentons deux études menées en préambule. La première concernent la bonne compréhension des limitations de la procédure de l'anesthésie loco-régionale écho-guidée telle que réalisée par un expert. La seconde, consiste à analyser la structure du nerf afin de proposer les caractéristiques représentatives du nerf les plus pertinentes pour l'objectif fixé.

Dans le Chapitre 2, nous présentons un survol de la littérature à base des méthodes de segmentation dans les images échographiques. L'objectif de ce chapitre est d'étudier les points forts et faibles des différentes méthodes existantes, en soulignant leurs avantages et inconvénients par rapport au sujet de cette thèse. Nous définissons une taxonomie des stratégies de segmentation qui permet d'abord de regrouper les algorithmes et leurs applications et finalement de choisir la stratégie à adopter pour la meilleure réponse à notre problème.

Dans le Chapitre 3, une méthode de détection assistée par ordinateur est proposée, celle-ci incorpore plusieurs étapes ; prétraitement, extraction et sélection de caractéristiques et classification. Dans ce chapitre, nous explorons deux nouvelles approches pour caractériser le nerf et sélectionner les caractéristiques les moins redondants et les plus pertinentes. Nous détaillons chaque étape de la

méthode de détection assistée par ordinateur. Chacune étant accompagnée par une large évaluation afin d'établir un système de détection automatique du nerf.

Dans le Chapitre 4, nous explorons la cohérence temporelle de la position, la forme et la confiance de classification afin d'assurer une méthode de détection robuste et capable de rectifier une mauvaise reconnaissance du nerf dans une séquence d'images échographique. Un paragraphe est dédié au modèle *on-line* à base de priorités de plusieurs caractéristiques que nous proposons, lequel permet de s'adapter aux différentes distributions des données du nerf dans une séquence d'images échographiques.

En guise de conclusion, un dernier chapitre reprend les principales contributions de cette thèse et propose des orientations futures envisagées dans la continuité de ce travail. En guise de fin, une liste des publications relatives à ce travail est proposée pour le lecteur qui serait intéressé à approfondir et comprendre certaines parties de ce travail.

Sommaire

Liste des figures	8
Liste des tables	11
1 Introduction	15
1.1 Anesthésie loco-régionale	15
1.1.1 Anatomie du nerf	16
1.1.2 Techniques d’anesthésie loco-régionale	18
1.2 Principes de l’ALR écho-guidée	19
1.2.1 La visualisation de l’image échographique	19
1.2.2 Techniques de localisation du nerf	26
1.2.3 Insertion de l’aiguille et injection de l’anesthésique local	30
1.3 Limitations de l’ALR écho-guidée	31
1.4 Objectif de la thèse	33
1.5 Validation des méthodes de la détection du nerf	35
2 Détection des régions d’intérêt dans les images échographiques : état de l’art	37
2.1 Introduction	37
2.2 Méthodes de segmentation des images échographiques	38
2.2.1 Segmentation guidée par atlas	40
2.2.2 Segmentation par graphe	41
2.2.3 Segmentation à base de frontière	43

2.2.4	Segmentation à base de modèle déformable	44
2.2.5	Modèles déformables paramétriques	45
2.2.6	Modèle déformable géométrique	48
2.2.7	Méthodes de segmentation basées sur la classification	50
2.2.8	Segmentation de classification à base des méthodes probabilistes	52
2.2.9	Segmentation à base des systèmes de détections aidées par ordinateurs	53
2.3	Évaluation des performances des méthodes de segmentation	54
2.4	Choix de la méthode de segmentation des nerfs dans les images échographiques	54
2.5	Conclusion	56
3	La détection du nerf assistée par ordinateur	57
3.1	Introduction	57
3.2	Système DAO proposé pour la détection du nerf	58
3.3	Pré-traitement	59
3.4	Filtre de dé-bruitage	60
3.4.1	Filtre linéaire	62
3.4.2	Filtre non-linéaire	63
3.4.3	Filtre fréquentiel	64
3.4.4	Autres Filtres	65
3.5	Extraction des caractéristiques	65
3.5.1	Méthodes statistiques	66
3.5.2	Famille de Motif Local Binaire	69
3.5.3	Fractal	71
3.6	Sélection des caractéristiques	71
3.6.1	Méthodes à base des filtres	72
3.6.2	Méthodes à base d'apprentissage	75
3.7	Localisation et segmentation	77

3.8	Méthodes proposées pour améliorer le système DAO	78
3.8.1	Descripteur dédié à la texture du nerf	79
3.8.2	Algorithme de sélection des caractéristiques	80
3.9	Résultats d'expérience	81
3.9.1	Évaluation des composantes du système	81
3.9.2	Évaluation de segmentation	86
3.9.3	Évaluation de la robustesse	86
3.10	Discussion	87
3.11	Contribution	90
3.12	Conclusion	90
4	Modèle adaptative d'apprentissage on-line via la cohérence temporelle pour la détection du nerf	93
4.1	Introduction	94
4.2	Principes de la méthode proposée	95
4.2.1	Cohérence temporelle	95
4.2.2	Apprentissage <i>on-line</i>	96
4.2.3	Concept	96
4.3	Méthode de la détection du nerf	99
4.3.1	Modèle de position dans le temps	99
4.3.2	Mesure de qualité de détection	104
4.4	Résultats	112
4.5	Contributions	114
4.6	Conclusion	115
5	Conclusion	117
5.1	Récapitulatif de la thèse	117
5.2	Contribution	118

5.3	Perspectives	119
5.3.1	Optimisation et amélioration de l'algorithme de segmentation	120
5.4	Ligne de recherches dérivées de cette thèse	120
5.5	Publications associées	121

Bibliographie	123
----------------------	------------

Liste des figures

1.1	Schéma montrant les principales divisions du système nerveux périphérique	16
1.2	Système nerveux périphérique (source : © QA International)	17
1.3	Schéma du nerf périphérique détaillé	17
1.4	Les principales étapes de la procédure d'ALR écho-guidée	20
1.5	Sonde linéaire (droite) et sonde curviligne (gauche)	21
1.6	L'interaction des ondes ultrasonores	22
1.7	Machines échographiques	24
1.8	Mode B	25
1.9	Mode Doppler	25
1.10	Modes de visualisation du nerf.	25
1.11	Maniement de la sonde échographique.	26
1.12	Image échographique du nerf médian	28
1.13	Une image échographique du nerf médian dans l'avant-bras. Illustration de la similarité de l'échogénicité entre le nerf et tendon	28
1.14	Une image échographique du nerf sciatique. Illustration de la similarité de l'échogénicité entre le nerf sciatique et les muscles	29
1.15	Une image échographique du nerf plexus brachial interscaléniques. Illustration de la similarité de l'hypoéchogénicité du nerf et les vaisseaux sanguins	29
1.16	Images échographiques du nerf médian. Le côté droit de la figure représente une situation où un mouvement de basculement brutal de la sonde provoque la dégradation de l'image. Le côté gauche de la figure représente la situation idéale pour obtenir l'image optimale.	30

1.17	Illustration de la complexité de l'anesthésie loco-régionale écho-guidée	33
1.18	Synthèse de l'objectif	34
2.1	Résultats des filtres gradients dans une image US du nerf médian	43
2.2	L'évolution de la courbe sur une image du nerf sciatique[97]	45
2.3	Trois trames d'une vidéo US à $t = 1, 50, 84$ annotée par un expert anesthésie (le nerf est représenté par la couleur verte).	55
3.1	Les étapes du système de détection du nerf dans les images US proposées	59
3.2	Indication des 3 lieux de visualisation du nerf médian dans l'avant-bras	59
3.3	Un exemple du pré-traitement, la région annotée avec la couleur jaune sur l'image représente la section du nerf. (a) l'image originale pré-segmentation par l'algorithme k-moyennes. (b) isolation des tissus anéchogènes (c) extraction des tissus de la peau. 60	
3.4	Schéma de classification et de segmentation	77
3.5	Exemple de détection du nerf. (a) Trois images annotées par un expert anesthésiste. (b) Localisation du nerf, le carré vert représente la zone du nerf. (c) Détection du contour nerf.	82
4.1	Exemple de trois trames d'une séquence d'images US à $t = \{1, 50, 84\}$ annotées par des experts anesthésistes (la région du nerf est marquée par la couleur verte). Cette figure montre le défi de la détection du nerf illustré comme suit : (a) Confusion d'apparence entre les tissus nerveux et les tendons. (b) la forme et la texture du nerf confondu avec la région de l'os (couleur rouge). (c) le faible écho de la région du nerf par rapport aux trames $t = 1$ et $t = 84$	94
4.2	Illustration de quatre courbes associées aux trois trames d'une séquence d'image US à $t = \{1, 50, 84\}$. Cette figure montre l'incohérence de la texture du nerf	94
4.3	Illustration de la méthode proposée pour détecter le nerf dans une séquence d'images sous forme de machine à états finis	97
4.4	Illustration d'un exemple des coordonnées de positions des régions générées par SVM pour une seule trame US. Les coordonnées de position (x_k^1, y_k^1) correspondent aux centroïdes des régions R_1^{SVMk} générées par k instance de SVM pour la trame 1. Par exemple la région R_1^{SVM5} est la région prédite dans la trame 1 par l'instance $SVM5$ avec un maximum de confiance de classification ayant le couple (x_5^1, y_5^1) comme coordonnées de position de cette région.	98

4.5	Exemple de cinq positions des régions générées par SVM (RC) du nerf dans le temps sélectionnées par l'étape 1 de la méthode proposée	100
4.6	Illustration des paramètres du modèle de positions (moyenne (μ^p), variance (σ^p) et précision du modèle (β^{pos})) dans le temps pour trois séquences d'images US. . . .	102
4.7	Processus de détection automatique des intervalles des valeurs des points de repère.	105
4.8	Les formes d'une GGD normalisée avec $\mu = 0$, $\sigma = 1$ et la valeur du paramètre de forme β	106
4.9	Illustration des paramètres du modèle de forme dans le temps pour trois séquences d'images.	108
4.10	Illustration de différents poids des IPRs dans le temps.	109
4.11	Illustration de différentes variations des IPRs dans le temps.	110
4.12	Filtrage de bruit du signal $Conf(t)$	111
4.13	Illustration des paramètres du modèle de confiance de classification pour trois séquences d'images.	112

Liste des tableaux

1.1	Image échographique des différents tissus	27
2.1	Revue sur les méthodes récentes de segmentation dans les images échographiques .	39
2.2	Évaluation de la méthode de segmentation du nerf dans les images échographiques .	55
3.1	Les réponses des méthode de dé-bruitages	61
3.2	Les méthode d'extractions de caractéristiques	66
3.3	Méthodes de sélections à base des filtres	72
3.4	Sélection des caractéristiques à base d'apprentissage	76
3.5	Résultat de classification pour différentes techniques implémentées dans l'approche proposée (filtre de dé-bruitage et extraction de caractéristiques).	83
3.6	Résultat de classification pour différentes technique implémentées dans l'approche proposée (Les filtres de dé-bruitage à base des méthodes fréquentielles).	83
3.7	Résultat de classification pour différents paramètres pour LGBP et MGBP	84
3.8	Résultat de classification pour différentes méthodes à base de LBP implémentées dans l'approche proposée.	84
3.9	Résultat de classification pour différentes techniques implémentées dans l'approche proposée (méthodes de sélection de caractéristiques).	85
3.10	Résultats de classification pour différentes techniques de machines d'apprentissages implémentées dans le système proposé.	86
3.11	Comparaison de notre système avec d'autres méthode	86
3.12	Les scores moyens de l'évaluation quantitative de la localisation et de la segmentation pour l'étude de la robustesse	87

4.1	Résultats de localisation et de segmentation pour différentes techniques.	112
4.2	Résultats de localisation et segmentation pour différents modèles de formes rajoutés à la méthode proposée.	113
4.3	Résultats de localisation et de segmentation obtenus expérimentalement dans le cadre de l'approche proposée pour différentes séquences d'images.	114

Chapitre 1

Introduction

Le domaine de l'analyse d'images médicales englobe toutes les techniques permettant de manipuler les images à caractère médical. Les techniques d'analyse et de traitement d'images se sont multipliées ces dernières années pour assister les médecins dans leurs interventions. Dans le domaine médical, ces techniques sont particulièrement mise en œuvre pour la localisation, la segmentation et le suivi d'une région d'intérêt ou d'un tissu anatomique.

La motivation de cette thèse consiste à développer un système efficace et robuste, de détection du nerf et d'autres régions d'intérêt dans les images échographiques. Ce système doit contourner certaines limites des ultrasons de manière à diminuer les complications lors d'une procédure d'anesthésie loco-régionale écho-guidée.

Dans cette thèse, nous détaillons le développement de deux méthodes dans le cadre d'une détection assistée par ordinateur, devant s'insérer de façon relativement aisée dans un échographe afin de répondre aux besoins des praticiens de l'anesthésie loco-régionale écho-guidée.

Dans ce chapitre d'introduction, nous justifions à la fois la motivation sous-jacente au développement d'un algorithme dédié à la détection des nerfs, et argumentons sur la contribution de cette thèse envers les communautés des anesthésistes et bio-informaticien.

1.1 Anesthésie loco-régionale

Une intervention chirurgicale est souvent accompagnée de douleurs et certaines complications post-chirurgicales, comme le stress et le syndrome de panne chronique. L'apparition de ces complications peut induire une augmentation du temps de rétablissement chez le patient avec pour conséquence un retour difficile à une vie normale. Cela est d'autant plus vrai si l'opération subie est lourde.

Depuis des décennies une recherche active dans ce domaine a permis d'introduire de nouvelles

méthodes pour réduire les risques et les douleurs post-opératoires. L'une d'entre elles, l'anesthésie loco-régionale (ALR) est devenue une voie incontournable pour la gestion des douleurs, elle permet de supprimer la sensibilité d'une partie du corps humain sur laquelle va pouvoir effectuer des actes chirurgicaux mineurs ou intermédiaires.

L'ALR est de plus en plus utilisée par les médecins anesthésistes du fait de la qualité analgésique (absence de douleur) qu'elle confère et de ses capacités à remplacer l'anesthésie générale. C'est une technique efficace et moins intrusive, qui offre aux patients un rétablissement plus rapide et une réduction importante de la durée de l'hospitalisation.

L'ALR est devenu un protocole standard dans de nombreux hôpitaux [150]. En France, chaque année, ce sont des centaines de milliers d'ALR qui sont réalisées sur 11 millions de procédures d'anesthésie effectuées. Dans l'étude [15], les accidents graves avec apparition des grandes lésions nerveuses ont atteint 3/10 000 des interventions d'ALR.

L'ALR est devenue une méthode très sollicitée pour les interventions chirurgicales, d'ailleurs de nombreux travaux ont été dédiés à l'étude de cette méthode [164, 52, 17, 121].

Cependant, l'ALR est une pratique complexe qui nécessite un long processus d'apprentissage pour le praticien et des années de pratique au bloc opératoire pour acquérir le bon geste opératoire. Parmi les problèmes majeurs de l'ALR, la plus importante et la plus difficile à réaliser, demeure la localisation des blocs nerveux dans les différentes parties du corps humain.

1.1.1 Anatomie du nerf

Une anesthésie loco-régionale peut être appliquée soit au niveau du système nerveux central ou périphérique [21, 174]. Le système nerveux central est constitué du cerveau et de la moelle épinière. Le cerveau émet et reçoit des informations vers/en provenance du corps humain via la moelle épinière. Précisons que, les blocs les plus fréquemment réalisés sont les blocs périphériques. La fonction principale du système nerveux périphérique est de faire circuler l'information entre plusieurs organes et le système nerveux central [9]. Comme illustré dans la Figure 1.1 le système




FIGURE 1.1 – Schéma montrant les principales divisions du système nerveux périphérique

nerveux périphérique est constitué du système nerveux somatique et autonome. Le système nerveux somatique transmet les informations sensorielles de la peau, des muscles et des articulations afin

de commander les contractions des muscles du squelette. Le système nerveux autonome dirige quant à lui les fonctions organiques internes. Ce système peut être divisé en deux types de nerfs appelés pour l'un afférent (qui va vers) et pour l'autre efférent (qui part de). Les nerfs afférents (sensitifs) transmettent l'information des récepteurs sensoriels jusqu'au système nerveux central contrairement aux nerfs efférents (moteurs), qui transmettent les informations du système nerveux central vers les muscles. La Figure 1.2 illustre les 43 blocs nerveux du système nerveux périphérique.




FIGURE 1.2 – Système nerveux périphérique (source : © QA International)

Chaque nerf est relié à une fonctionnalité précise. Par exemple, le nerf médian est une branche du plexus brachial innervant divers muscles de la partie antérieure de l'avant bras et une partie de la main. L'unité anatomique du nerf est composée de plusieurs fascicules, où chaque fascicule est composé d'un ensemble d'endonevres, eux mêmes structurés en groupe d'axones (voir Figure 1.3).

La structure anatomique du nerf joue un rôle majeur pour sa localisation pendant une procédure d'ALR, tant pour les membres supérieurs qu'aux membres inférieurs [220].




FIGURE 1.3 – Schéma du nerf périphérique détaillé

1.1.2 Techniques d'anesthésie loco-régionale

La procédure d'anesthésie loco-régionale consiste à localiser le nerf dans le but d'injecter dans sa périphérie un anesthésique local. Il existe deux méthodes pour localiser le nerf, la méthode basée sur la neuro-stimulation et celle basée sur le guidage par échographique [216].

ALR basée sur la neuro-stimulation

L'anesthésie loco-régionale basée sur la technique de neuro-stimulation, consiste à localiser les blocs nerveux en stimulant les fibres sensitives. Ce processus est lié au déclenchement de l'influx nerveux dans un nerf à l'aide d'une impulsion électrique. De même que cette impulsion électrique permet d'enclencher une réaction musculaire qui correspond au territoire d'intervention. Une fois le nerf localisé, une aiguille relié à un stimulateur et une seringue sont utilisés pour injecter le liquide anesthésique [190, 216]. La neurostimulation est une technique très connue dans le domaine de l'ALR, cette technique est utilisée depuis pour plusieurs années, et a été considérée comme la technique de référence pour l'ALR [240, 176]. Cependant, cette technique nécessite une connaissance précise de l'anatomie du corps humain afin de déposer l'anesthésique à proximité du bloc nerveux uniquement, afin d'éviter ainsi l'injection intra-neurale source de lésion et de séquelles nerveuses invalidants. Autre inconvénient, La neurostimulation est une méthode invasive qui présente le désavantage d'une recherche aveugle du nerf, dont la précision de repérage est liée aux bonnes connaissances anatomiques. De plus, la connaissance parfaite de l'anatomie est parfois insuffisante pour la précision de repérage, à cause des variations morphologiques inter-patients [52].

ALR écho-guidée

Les développements technologiques dans le domaine de l'imagerie échographique ont permis l'utilisation de cette technique non invasif pour localiser les nerfs, identifier l'aiguille et suivre l'injection d'anesthésique local en temps réel. Le plus grand avantage de cette technique est la possibilité d'avoir un retour visuel, en permettant la localisation direct des nerfs et des structures environnantes (i.e. muscles, vaisseaux sanguins, tendons, etc.). L'ultrasonographie donne d'une part la possibilité de choisir la trajectoire de l'aiguille la plus ad'hoc afin de réduire le risque de ponction vasculaire et d'injection intra-neurale accidentelle et d'une autre part, cette technique apporte un confort visuel permettant d'observer la diffusion de l'anesthésique local durant toute la procédure de l'ALR. Un contrôle précis est alors possible sur la qualité injectée réduisant ainsi considérablement les risques de neuropathie et toxicité [44].

Un grand nombre d'études ont montré l'intérêt de l'assistance de l'image échographique pour l'ALR, les résultats de ces travaux ont montré une baisse de complication neurologique [228]. Dans [189, 167], une comparaison entre l'approche par neuro-stimulation et l'écho-guidage a confirmé l'avantage de cette dernière par rapport au temps de latence à la faible dose d'anesthésique local

nécessaire et au risque moindre de perforation vasculaire, élément en faveur d'un meilleur confort pour le patient. Dans [230], 12688 patients ont été évalués pendant 8 ans ; les auteurs ont remarqué une faible incidence de toxicité (0.08/1000) et des symptômes neurologiques post-opératoires de 0.9/1000, 6 mois après avoir subi une ALR écho-guidée. Ce faible taux d'incidence de toxicité est plus bas que celui présenté par [11] qui présente des statistiques relatives à l'ALR neuro-stimulée. Dans leur travail, les auteurs ont effectué 16 études entre 1995 et 2005 durant lesquelles 22414 blocs périphériques ont été examinés, les résultats publiés font ressortir un taux d'incidence neurologique de 18 cas pour 1000 blocs opérés. Dans [193], une analyse de la procédure d'ALR effectuée par des anesthésistes en apprentissage pendant 44 mois a montré 6 cas de complications dans 9000 blocs basées sur la neuro-stimulation seule, tandis que pour l'ALR écho-guidée n'a donné aucune complication.

Pendant les dernières années, plusieurs travaux ont montré l'utilité des techniques d'imagerie ultrasonore pour l'ALR afin d'éviter des complications post-opératoires. Aujourd'hui des recommandations ont été émises par les services de santé de certains pays comme les États-Unis d'Amérique et le Royaume-Uni qui recommandent l'utilisation de l'image échographique pour la procédure d'ALR afin d'améliorer le taux de réussite et réduire le nombre de complications [228].

1.2 Principes de l'ALR écho-guidée

D'autres technologies d'imagerie telles que l'IRM ou le scanner permettent de mieux visualiser la structure nerveuse et l'aiguille, mais l'échographie reste privilégiée pour la pratique de l'ALR ; elle présente l'avantage de la portabilité, de la facilité d'installation, du faible coût et surtout de l'absence de radiations.

Dans le protocole de l'ALR écho-guidée, le praticien utilise une sonde ultrasonore à haute fréquence pour localiser le nerf, et pour cibler la zone sur laquelle va être injecté le liquide anesthésique rendant ainsi la partie du corps en aval insensible à la douleur [164, 17, 121].

Comme illustrée dans la Figure 1.4, la procédure d'ALR écho-guidée peut être décomposée en quatre étapes principales ; l'acquisition et visualisation de l'image, la localisation du nerf, puis l'insertion de l'aiguille pour finalement injecter l'anesthésique localement.

1.2.1 La visualisation de l'image échographique

L'utilisation du guidage échographique dans la pratique de l'ALR nécessite un équipement échographique de haute performance et une compréhension approfondie des structures anatomiques. Les praticiens de l'ALR ont besoin d'acquérir à la fois une base solide dans le domaine des ultrasons et acquérir les compétences pratiques nécessaires pour visualiser les structures nerveuses [203].

La visualisation des nerfs par des ultrasons nécessite l'utilisation de hautes fréquences offrant




FIGURE 1.4 – Les principales étapes de la procédure d'ALR écho-guidée

des images de haute résolution. Les vibrations mécaniques ultrasonores forment une onde ayant les propriétés d'une onde sonore. Ils ne peuvent se déplacer que dans les milieux gazeux, liquides et solides.

La fréquence des ultrasons exprime le nombre de vibrations par seconde et elle est exprimée en Hertz. La plupart des applications de localisation des blocs nerveux exigent des fréquences dans la gamme de 10-14 MHz [44]. Cependant, les fréquences plus élevées permettent d'exploiter des structures superficielles où la profondeur de pénétration est moins importante, comme la peau.

Chaque vibration ultrasonore se caractérise par une fréquence et une longueur d'onde spécifique. La longueur d'onde est une distance entre deux cycles de vibration consécutives. Elle dépend de la fréquence des ondes et la vitesse de propagation. Donc la vitesse de propagation dépend des tissus traversés, par exemple la vitesse de propagation de l'air est de 330 m/s, celle de l'os 3000 m/s et celle du muscle 1600 m/s [28, 221].

La longueur d'onde permet de définir la résolution spatiale :

$$R = \text{vitesse} / \text{fréquence des ultrasons}$$

où on déduit que plus la fréquence est élevée et plus la résolution est importante.

Les ondes ultrasonores sont produites par effet piézoélectrique. Les cristaux piézoélectriques qui constituent le cœur d'une sonde échographique agissent à la fois comme des générateurs et des récepteurs des signaux. La sonde est soumise à des charges électriques, où les cristaux piézoélectriques transforment l'onde électrique en vibration mécanique, afin de générer une onde ultrasonore. Après le passage des ondes dans les tissus, une partie du signal ultrasonore est réfléchi vers la sonde pour générer les trames échographiques. Une sonde agit comme un générateur d'ondes ultrasonore pour seulement 1% du temps et agit comme un microphone pour écouter les vibrations pour le reste du temps (99%) [28].

Les sondes échographiques

Plusieurs types de sondes sont disponibles pour la procédure d'ALR écho-guidée, elle sont de fréquences ultrasonores et de formes physiques (voire Figure 1.5). Une sonde contient essentielle-



FIGURE 1.5 – Sonde linéaire (droite) et sonde curviligne (gauche)

ment une couche d'amortissement, des cristaux piézo-électriques, un adaptateur d'impédance et une couche de protection. La couche d'amortissement est placée derrière les cristaux piézo-électriques. Cette couche influe sur la bande passante de la sonde et sur son rendement. La couche d'adaptation sert à la fois pour protéger les cristaux piézo-électrique et surtout elle permet d'éviter une grande réfraction de l'onde ultrasonore compte tenue de la forte différence d'impédance entre le cristal piézo-électrique et la peau.

Généralement deux types de sondes sont utilisées pour les procédures d'ALR [207] (Voir Figure 1.5). Les sondes à hautes fréquences ($8-12\text{ MHz}$) et faibles fréquences ($2-5\text{ MHz}$) [207, 221].

La majorité des blocs nerveux périphériques peut être effectuée avec une sonde linéaire à hautes fréquences.

Ce type de sonde est constitué d'un ensemble d'éléments piézo-électrique alignés de manière rectiligne structurée sous la forme d'une barrette. Dans cette configuration les US sont émis dans la même direction. Ces sondes fournissent une résolution optimale des structures superficielles ($3-4\text{ cm}$), telles que la plexus brachial, le nerf fémoral et poplitée [203, 207].

Par ailleurs, il existe une famille de sondes au volume réduit (micro-convexes) très utiles pour les ALR à destination des enfants principalement mais aussi des adultes pour accéder à certaines zones anatomiques spécifiques telles que celles du cou et de la cheville.

Un dernier type de sonde nommée "sondes curvilignes" est parfois utilisé pour localiser les blocs

nerveux périphériques. Dans ce cas, les ondes émises sont divergentes et ils sont généralement d'une fréquence plus basse, afin de visualiser les structures plus profondes ($> 4\text{ cm}$), telles que le nerf sciatique [207].

Interaction des ultrasons

Une fois que les ondes ultrasonores sont générées, elles passent à travers différentes structures tissulaires. Les ondes sont alors soumises à un certain nombre d'interactions, à savoir la réflexion, la réfraction et l'atténuation [114, 141].

Lorsque les ondes ultrasonores rencontrent un tissu, une partie de celle-ci sont réfléchies et d'autres sont transmises. Les orientations des ondes réfléchies et transmises sont fournies, respectivement par l'angle de réflexion (Θ_r) et l'angle de transmission (Θ_t) [114] (voir Figure 1.6).




FIGURE 1.6 – L'interaction des ondes ultrasonores

La réflexion d'une onde sonore est très similaire à celle observée pour la réflexion optique. Une partie de son énergie est renvoyée au milieu d'origine. Dans une véritable réflexion, l'angle de réflexion Θ_r doit être égal à l'angle d'incidence Θ_i . L'intensité de l'énergie réfléchie sur l'interface dépend de la différence entre les impédances acoustiques des deux milieux présents de part et d'autre de l'angle d'incidence.

La différence significative entre les impédances hautes et basses déterminent l'intensité de la réflexion (écho), autrement dit si les impédances hautes et basses sont égales, la réflexion est inexistante (sans écho).

Par exemple, l'interface entre les tissus mous et les os implique un changement considérable d'impédance acoustique, provoquant par conséquent l'apparition d'un écho de forte amplitude. Cette intensité de réflexion est également liée à l'angle d'onde incidente. Plus l'angle sera petit,

meilleure sera la visualisation de l'organe à localiser. Concrètement la sonde devra être placée perpendiculairement au nerf.

Un autre phénomène d'interaction ultrason-interface est connu sous le nom de réfraction [125]. La réfraction est causée par le changement de direction de l'onde émise lors du franchissement de la frontière entre deux différents milieux. Si la vitesse de propagation à travers le second milieu est plus lente que celle du premier milieu, alors l'angle de réfraction est plus petit que l'angle d'incidence. La réfraction peut provoquer des artefacts tels les erreurs de duplication.

L'atténuation se réfère à la perte d'énergie quand les ondes sonores se déplacent à travers une profondeur conséquente. Le phénomène d'atténuation est directement lié à la profondeur de pénétration des ondes, le type de tissu pénétré et la fréquence de l'onde.

En raison du phénomène de friction, une grande quantité d'énergie est perdue sous forme de chaleur. Les structures plus denses ont des coefficients d'atténuation plus élevés, ce qui veut dire que le mouvement oscillatoire produit par une onde US créera plus de friction et donc plus de chaleur [182]. Étant donné qu'une onde de haute fréquence est plus fortement atténuée qu'une onde de plus basse fréquence, on peut noter qu'une sonde haute fréquence ne peut être d'une grande aide pour la visualisation des structures plus profondes telles que le nerf sciatique.

Appareil échographique

Une localisation rapide et précise du nerf passe inmanquablement par une bonne prise en main de la sonde échographique et une connaissance approfondie du fonctionnement de l'échographe. Une visualisation optimale du nerf dans les images échographiques dépend à la fois des paramètres physiques de la sonde, de l'électronique et logiciels de l'échographe (Figure 1.7). Dans cette section nous allons parler des paramètres les plus importants d'une machine échographique : la résolution, le gain, la zone focale et fréquence de fonctionnement.

La paramètre de résolution décrit la capacité d'identifier séparément ou individuellement de deux structures très proches [85, 20].

Le paramètre de gain se réfère à l'intensité du signal. La luminosité de l'image est proportionnelle à l'intensité du signal reçu par la sonde [20].

Les ondes sonores convergent vers un point appelé la zone focale, puis divergent [114]. La divergence de ces ondes au-delà de la zone focale cause une perte des informations dans un plan horizontal. Pour minimiser cette perte, il est important de régler la zone focale au même niveau que la région d'intérêt.




FIGURE 1.7 – Machines échographiques

Formation de l'image échographique

La formation de l'image échographique est basée sur deux grandes étapes ;

1. La sonde émet des ondes ultrasonores puis les réceptionne en les transformant en signal électrique sous l'effet piezo-électrique. L'électronique de l'échographe se charge d'amplifier et de traiter ces signaux afin de les convertir en signal numérisé (radio-fréquence).
2. La transformation du signal numérique en image échographique est basée sur plusieurs étapes ; le signal reçu est échantillonné afin d'être stocké dans une matrice. A l'issue de cet échantillonnage, le contenu de la matrice comprend des valeurs codées de niveaux de gris obtenue selon selon l'intensité de l'écho en retour. L'opération de quantification est généralement basée sur une échelle de 256 niveaux de gris. Une interpolation à partir des valeurs des échos les plus proches est effectuée en second étape, finalement un lissage spatial est réalisé afin de remédier à l'effet d'interpolation.

La visualisation de l'image échographique pour la procédure d'ALR est obtenue à partir de deux modes d'acquisition différents. Le premier est appelé le mode Brightness (B) et le second le mode Doppeler (Figure 1.10).

Le mode B ou mode de Luminosité en français produit une image en niveaux de gris des tissus traversés par l'onde. Les ondes ultrasonores émises sont réfléchies par les tissus, ce qui donne une apparence sonographique (échogénicité ou luminosité) sur les images échographiques. La luminosité de chaque tissu sur l'image échographique est déterminée par l'intensité de l'écho qui est le résultat de la réflexion de l'onde incidente qui a subi une réflexion au moment du passable dans le tissu. Si l'onde réfléchie est de forte intensité, nous observons un phénomène dit hyperéchogène (obtention

de région fortement blanche) comme par exemple l'os. A contrario, si l'onde réfléchie est de faible amplitude, nous observons cette fois un effet hypoéchogène (région très sombre) comme c'est le cas pour certains nerfs périphériques. Autre cas particulier, qui se manifeste lorsqu'aucune onde n'est réfléchie et donc aucun écho n'est détecté donnant lieu au phénomène de zone anéchogène (zone totalement noire).

Le mode B est la forme adoptée pour visualiser le nerf pour la procédure d'ALR. Cependant, le mode Doppler, ou le mode temps/mouvement en français, est utilisé pour identifier les structure vasculaires et les distinguer des nerfs périphériques. Ce mode représente la distance entre la sonde et les tissus échogènes en fonction du temps.




FIGURE 1.8 – Mode B




FIGURE 1.9 – Mode Doppler

FIGURE 1.10 – Modes de visualisation du nerf.

Une bonne visualisation du nerf et de l'aiguille sont un gage du bon déroulement d'une ALR sans complication. Malheureusement la qualité de la vidéo est parfois entachée par les limitations liées aux réglages de l'échographe ainsi qu'à la sonde ce qui engendre une dégradation des images.

L'apparition des artefacts est un des problèmes majeurs dans l'interprétation du contenu d'une image ultrasonore. Ils dégradent les images échographique et modifient par conséquent la représentation anatomique. Cependant leur identification aide à surmonter cette difficulté [226]. Deux catégories d'artefacts sont connus dans l'ALR ; les artefacts acoustiques et anatomiques [227]. Les artefacts acoustiques rendent difficile toute visualisation des structures en profondeur. Ils en existent différentes formes :

- le phénomène d'ombre se produit lors de la recherche d'une cible se trouvant derrière une structure osseuse ;
- les phénomènes de renforcement surviennent souvent lorsque les ondes ultrasonores passent à travers les vaisseaux sanguins (coefficient d'atténuation faible). Ce phénomène est très connue lors de la localisation des nerfs périphériques associés à des gros vaisseaux sanguins ;
- Le phénomène de réverbération apparaissant lorsque deux interfaces très échogènes et parallèles sont situées sur le trajet de l'onde (par exemple la plèvre) ;

- le phénomène d'air provenant des bulles d'air piégées dans le produit anesthésique lors de d'une injection. Ce phénomène se produit souvent à la périphérie du bloc nerveux tibial ou du bloc nerveux ulnaire.

Les artefacts anatomiques sont une autre catégorie d'artefacts qui sont souvent rencontrés lors d'une procédure d'ALR. Les artefacts anatomiques sont des structures normales mais aberrantes qui peuvent ressembler au nerf recherché donnant l'illusion de sa présence. Effectivement la texture du tendons, muscles et vaisseaux sanguins peuvent ressembler respectivement à la texture du nerf médian, à la fosse poplitée et au plexus brachial.

Le bon déroulement d'une ALR dépend de plusieurs facteurs présents tout au long de la chaîne d'acquisition et de traitement, allant du contact de la sonde sur le corps humain, jusqu'à l'étape de visualisation. Il est important d'optimiser la fréquence de la sonde, la profondeur, la focalisation, le gain et aussi connaître les artefacts éventuels pour éviter des complications lors d'une intervention. Cependant, il est important pour le praticien de savoir orienter la sonde et de déterminer de quel côté elle doit être posée sur le patient. En effet, afin d'obtenir les visualisations optimales, les techniques de maniement de la sonde sont primordiales (Figure 1.11).




FIGURE 1.11 – Maniement de la sonde échographique.

Les glissements longitudinaux de la sonde sont souvent les plus régulièrement pratiqués afin de repérer l'introduction de la seringue et localiser les nerfs [227]. L'orientation de la sonde peut aussi améliorer la qualité de l'image en optimisant le contraste échographique entre le nerf et les tissus environnants. La rotation de la sonde s'avère aussi efficace pour bien visualiser la totalité de l'aiguille.

1.2.2 Techniques de localisation du nerf

La première étape dans la recherche des blocs nerveux guidée par les ultrasons est de pouvoir visualiser l'ensemble des structures anatomiques pour localiser la zone cible (nerf). Tous les réglables possibles, à savoir la profondeur de pénétration, les fréquences et la position de la sonde,

doivent être optimisés pour localiser la cible. La localisation du nerf est un pré-requis pour une procédure d'ALR réussie, mais la qualité de celle-ci est primordiale pour éviter d'endommager le nerf et ses structures environnantes. En règle générale, il est possible d'identifier presque tous les nerfs périphériques dans le corps humain, mais cela demande de la part du praticien un long entraînement et une pratique régulière du geste opératoire [238, 74].

Les images échographiques permettent la visualisation du nerf et les tissus environnants grâce au phénomène de réflexion plus au moins prononcé sur les tissus, selon leurs échogénités [45] (voir Table 1.1).

Tissu	Image
Veine	Anechogène (compressible)
Artère	Anéchogène (pulsatile)
Graisse	Hypoéchogène
Muscle	Hypoéchogène
Tendon	Hyperéchogène ou hypoéchogène
Os	Ligne hyperéchogène
Nerf	Hyperéchogène ou hypoéchogène
Fascia	hyperéchogène

TABLE 1.1 – Image échographique des différents tissus

Les nerfs périphériques sont généralement sous forme d'un triangle ou cercle avec une apparence hyperéchogène (structures lumineuses) ou hypoéchogène (structures sombres) en fonction de la taille du nerf, de la fréquence et de l'angle de l'onde [43, 233].

La plupart des blocs nerveux est détecté grâce à la technique de balayage transversale de la sonde, permettant ainsi d'obtenir une image en coupe transversale dans lesquelles les nerfs apparaissent en multiple zones hypoéchogènes ovales encerclées par un tissu hyperéchogène (voir Figure 1.12a). Ces structures hyperéchogènes sont les fascicules des nerfs, en revanche le fond hypoéchogène reflète le tissu conjonctif entre les structures nerveuses. Dans une vue longitudinale, chaque nerf apparaît comme une bande hyperéchogène caractérisée par de multiples bandes hypoéchogènes discontinues (Figure 1.12b).

Comme les faisceaux sont les principales caractéristiques échographiques des nerfs périphériques, leur apparence a été décrite comme un “motif fasciculaire” donnant un aspect de “nid d'abeille”, par opposition au “motif fibrillaire” des tendons, caractérisés par de multiples lignes continues hyperéchogènes [74, 207].

Le nombre de fascicules observées sur les images échographiques ne reflètent pas le nombre réel de fascicules à l'intérieur du nerf, en outre les plus petites fascicules ne peuvent pas être visualisées par échographie. L'aspect de nid d'abeille correspond typiquement aux grands nerfs périphériques (par exemple les nerfs médian, cubital et radial), cet aspect n'est pas observable pour les nerfs de petites tailles (par exemple le nerf pneumogastrique).




FIGURE 1.12 – Image échographique du nerf médian

Les nerfs peuvent faire partie d'un groupe neurovasculaire qui comprend les artères et les veines. Les artères sont pulsatives avec une structure hypoéchogène non compressible, tandis que les veines sont non pulsatives et facilement compressibles. Ces deux types de structures peuvent facilement se distinguer lorsque l'on utilise le mode Doppler [220].

Malgré la particularité de la structure du nerf qui lui permet d'être localisé, son apparence peut être confondue avec les structures qui l'entourent comme les vaisseaux sanguins, tendons et les muscles [227]. Par exemple l'apparence du nerf médian et le tendon peuvent être similaire lors d'une procédure d'ALR de l'avant bras. Les tendons apparaissent moins ovales en comparaison au nerf médian [225]. Cependant, dans certain cas les tendons fléchisseurs peuvent facilement être confondus avec le nerf médian comme représenté sur la Figure 1.13. Où encore, la texture du nerf




FIGURE 1.13 – Une image échographique du nerf médian dans l'avant-bras. Illustration de la similarité de l'échogénicité entre le nerf et tendon

sciatique peut être similaire avec la texture du muscle. Cependant les praticiens se basent sur les tissus adipeux pour contourner cette ambiguïté. Les tissus adipeux sont plus hypoéchogènes ce qui crée une zone sombre qui sépare le muscle du nerf sciatique [227]. Pourtant, les muscles peuvent tromper les performances de localisation d'un bloc nerveux guidé par ultrasons. La confusion se produit chez les athlètes lors d'une musculature développée où les tissus adipeux sont moindres (voir Figure 1.14).




FIGURE 1.14 – Une image échographique du nerf sciatique. Illustration de la similarité de l'écho-génicité entre le nerf sciatique et les muscles

Les vaisseaux sanguins généralement ne sont pas confondus avec les nerfs, car il y a plusieurs éléments d'identifications qui permet de les différencier. En général, les nerfs sont constitués par des tissus hyperéchogènes ou hypoéchogènes, tandis que les vaisseaux sanguins sont composés de tissus anéchogène. Par ailleurs, les artères ont un caractère pulsative et résiste à la compression. A l'inverse, les veines ne pulsent pas et sont facilement compressibles. Quand au nerf, ce dernier ne pulsent pas et ils résistent à la compression. Contrairement à la plupart des nerfs dans le corps, les racines du plexus brachial peuvent apparaître parfaitement rondes et anéchogènes. Une artère de petit calibre dans le cou peut être dangereusement confondu avec une racine nerveuse [227, 164], comme en témoigne la Figure1.15.



FIGURE 1.15 – Une image échographique du nerf plexus brachial interscaléniques. Illustration de la similarité de l'hypoéchogénicité du nerf et les vaisseaux sanguins

La difficulté de localiser le nerf ne se résume pas que sur l'ambiguïté entre l'apparence de celui-ci et d'autres structures. En effet, en manipulant la sonde afin d'optimiser la qualité de l'image, la visualisation du nerf peut disparaître de l'image échographique. Il y a deux explications à ce phénomène.

D'une part, les nerfs périphériques sont des structures très mobiles qui peuvent changer de position. Ce phénomène a été bien décrit par [209], ils ont démontré l'emplacement variable du

nerf médian par rapport à l'artère axillaire, en raison d'une légère pression appliquée par les sondes.

D'autre part, il y a la question de la réflexion et de la réfraction des ondes ultrasonores. La seule façon pour avoir une visualisation optimale des nerfs dans une image échographique est de faire en sorte que les ondes se réfléchissent sur un nerf. Si les conditions d'un taux de réflexion élevé ne sont pas respectées, la région du nerf dans l'image échographique sera soit dégradée soit complètement disparue. La Figure 1.16 montre comment l'optimisation de l'image échographique du nerf dépend de l'angulation de la sonde.




FIGURE 1.16 – Images échographiques du nerf médian. Le côté droit de la figure représente une situation où un mouvement de basculement brutal de la sonde provoque la dégradation de l'image. Le côté gauche de la figure représente la situation idéale pour obtenir l'image optimale.

1.2.3 Insertion de l'aiguille et injection de l'anesthésique local

Une fois que l'image de la cible est optimale, la position de la sonde doit rester relativement inchangée pour le reste de la procédure. Dans une seconde étape, l'aiguille est introduite pour injecter l'anesthésique local.

Insertion et identification de l'aiguille basée sur les images échographiques

L'aiguille doit toujours être portée au plan de la sonde, afin de garder la localisation du nerf et des structures environnantes. L'aiguille est identifiée uniquement lorsqu'elle traverse la zone insonifiées. L'aiguille est identifiée d'une part comme étant une structure hypoéchogène et d'une autre part elle est localisée à partir de l'ombre acoustique générée par elle même. De plus, l'aiguille est également identifiée par son mouvement et le déplacement des tissus l'entourant.

Généralement deux types d'approches sont utilisés pour l'insertion de l'aiguille par rapport à

la sonde ; l'approche hors du plan et dans le plan.

L'approche hors du plan consiste pour l'opérateur a insérer l'aiguille perpendiculairement au plan US de la sonde ce qui a pour résultat de faire apparaître une zone hyperéchogène. Cependant, l'inconvénient de cette méthode est l'imprécision dans la position de la pointe ; ce qui présente un risque du fait que la pointe de l'aiguille peut endommager le nerf provoquant dans le cas grave de trauma [203].

L'approche dans le plan consiste à insérer l'aiguille parallèlement au plan US de la sonde. L'objectif de cette méthode est de visualiser à la fois l'aiguille et sa pointe tout au long de la procédure. Cette approche est la plus appropriée pour les blocs nerveux superficiels comme le brachial plexus ou le bloc fémoral, en raison de l'angle de l'insertion de l'aiguille par rapport à la sonde, ce qui améliore la visualisation et facilite l'identification de l'aiguille. Cependant, la localisation de la pointe de l'aiguille demeure parmi les problèmes majeurs de l'ALR écho-guidée [203]. Plusieurs méthodes pour localiser l'aiguille et sa pointe ont été proposées dans la littérature (voir Section 1.3).

Injection de l'anesthésique local basée sur le guidage échographique

Une fois obtenue l'image échographique optimale de l'aiguille en place, l'anesthésique est administré localement sous visualisation échographique directe jusqu'à ce que les structures nerveuses soient intégralement entourées d'un anesthésique. Si l'anesthésique se propage dans la mauvaise direction, l'aiguille peut être repositionnée, afin d'assurer la propagation d'anesthésique adéquate. Cela offre des avantages de sécurité supplémentaires par rapport aux techniques de neurostimulation [199].

L'un des avantages le plus significatif de l'ALR écho-guidée est la capacité d'identifier en temps réel la propagation de l'anesthésique local autour des nerfs périphériques [207].

La possibilité de voir directement la distribution de l'anesthésique local par échographie minimise les doses à administrer pour les blocs nerveux, ce qui est particulièrement utile dans les procédures de séquences multiples [165].

1.3 Limitations de l'ALR écho-guidée

Malgré la valeur ajoutée par la technique de l'ALR écho-guidée pendant les dernières années, la visualisation échographique est toujours soumise à l'interprétation individuelle. Par conséquent, cette technique dépend de la compétence des praticiens de l'ALR [229]. En effet l'utilisation de l'image échographique pour l'ALR est une procédure délicate en raison du manque d'apprentissage, de la difficulté à localiser le nerf et à détecter la pointe de l'aiguille souvent causée par la variabilité anatomique observée d'un patient à l'autre (artefacts et confusion entre les structures entourant le nerf).

Les praticiens sont tenus de suivre une formation approfondie de l'ALR écho-guidée avant que leurs compétences soient jugées adéquates. Dans [4], ils ont montré que l'apprentissage prend une longue durée pour maîtriser cette technique. Ceci est due à la difficulté de localiser le nerf et l'aiguille dans une image échographique [184]. Dans [229] les auteurs ont identifié 398 erreurs commises par les novices pendant l'exécution de 520 procédures d'ALR écho-guidée. La plus part de ces erreurs consiste à identifier la pointe de l'aiguille, localiser le nerf et reconnaître une fausse distribution d'anesthésique pendant la procédure d'ALR basée sur l'approche "dans le plan" (voir Section 1.2.3).

Quant aux variations morphologiques, elles peuvent limiter la propagation de l'anesthésique local malgré la visualisation échographie [2]. Mais là encore, la difficulté de distinguer le nerf par rapport aux tendons, muscles et vaisseaux sanguins peuvent nuire à la qualité de visualisation du nerf (voir Section 1.2.2) et de l'aiguille (voir Section 1.2.3).

Cependant, l'utilisation de la neurostimulation combinée avec la méthode basée sur les ultrasons peut être une solution en cas d'incertitude sur l'apparence échographique des nerfs périphériques ou si le nerf se trouve à un endroit plus profond où la qualité de l'image est non-satisfaisante [51]. Mais cette technique demande de l'expertise sur les deux techniques d'ALR, ce qui nécessite de la part du praticien un temps d'apprentissage relativement long.

Toutefois, de nouvelles avancées technologies dans le domaine des ultrasons laisse entrevoir la possibilité de surmonter certaines de ces limitations techniques.

Plusieurs méthodes pour la détection de l'aiguille dans les images échographiques ont été proposées récemment dans la littérature. Certaines se concentrent sur les aspects logiciels en utilisant des techniques de traitement d'image [102] tandis que d'autres sont basées sur l'amélioration des propriétés physiques de l'aiguille pour améliorer la visualisation de l'aiguille en la rendant plus hyperéchogène [259]. Malgré ces propositions, la détection de l'aiguille reste parmi les problèmes majeurs de l'ALR écho-guidée. Rappelons qu'une erreur de détection de nerf peuvent entraîner accidentellement une injection intra-neurale qui peut conduire à des complications graves. Il existe très peu d'études qui mettent l'accent sur la détection des nerfs, soit à partir d'un logiciel ou d'un point de vue physique. Récemment, des méthodes d'imagerie photo-acoustique ont été proposées pour améliorer la visualisation des nerfs [274, 259, 260]. Dans [166, 260], les auteurs ont développé une technique d'imagerie photo-acoustique multi-spectral pour distinguer les tissus nerveux. Cependant, la limitation de ce type de système d'imagerie est principalement leur coût, ce qui la rend difficile à leur emploi pour l'ALR dans un proche avenir.

Par conséquent, cette thèse se concentre sur l'aspect logiciel en utilisant les techniques de traitement d'images pouvant aisément s'intégrer dans des appareils échographiques disponibles sur le marché. Le développement de telles techniques permettra la mise en œuvre à un faible coût de machine échographiques plus performantes. En outre, le développement d'un système d'imagerie

avec une meilleure visualisation du nerf pourra à la fois contourner certaines limites de l'ALR écho-guidée et augmenter le taux de réussite de ce mode opératoire.

1.4 Objectif de la thèse

D'un point de vue pratique, le protocole d'ALR est fortement expert-dépendant. Il est soumis à de fortes contraintes : lors de l'insertion de l'aiguille réalisée d'une main, l'anesthésiste doit maintenir la visibilité du nerf en orientant la sonde US avec l'autre main. Par conséquent, l'anesthésiste doit effectuer une coordination main-œil complexe pour garder à la fois l'aiguille et le nerf visibles dans le plan 2D de l'image ultrasonore (Figure 1.17).



FIGURE 1.17 – Illustration de la complexité de l'anesthésie loco-régionale écho-guidée

Depuis plusieurs années, il apparaît une demande croissante de cette technique en France et dans d'autres pays européens [121]. Cependant, les moyens humains ne sont pas suffisants pour généraliser cette pratique.

Le positionnement de la sonde ultrasonore sur le corps du patient est donc une étape très importante car cette action permet de cibler au mieux la région et la pointe de l'aiguille ; de plus la précision de la position de la sonde aide à mieux visualiser les éléments anatomiques sensibles et évitant des complications majeures liées à l'ALR écho-guidée (ex : injection intra-vasculaire). Cependant, même pour un expert en ALR, maintenir constamment la sonde dans la position optimale, tout en insérant l'aiguille, est une tâche délicate.

Il y a donc deux étapes critiques dans l'ALR écho-guidée : 1) la reconnaissance des structures anatomiques dans l'image échographique (ex : les nerfs, les structures vasculaires, etc.) et 2) le suivi de l'aiguille lors de l'insertion.

En routine hospitalière, ces étapes exigent un degré élevé de formation en analyse d'images ultrasonores et surtout des compétences pratiques régulières [52, 17].

En effet, l'échographie est aujourd'hui un moyen important dans la pratique de l'ALR car elle permet la visualisation directe des blocs nerveux et de l'aiguille d'anesthésie. En revanche, l'angle de la sonde, la qualité de l'image, la profondeur, l'aspect du nerf et du tissu conjonctif qu'il contient peuvent grandement changer l'image échographique du nerf. Ceci peut augmenter le risque des traumatismes nerveux (ponctions avec l'aiguille, injection d'anesthésique local dans le nerf) qui peuvent malheureusement avoir des conséquences désastreuses.

L'université d'Orléans, l'université de Tours, l'hôpital Médipôle Garonne (Toulouse) et Adecho-tech ont développé une collaboration autour du projet DANIEAL avec le concours financier de la région Centre Val-de-Loire. L'objectif du projet est de développer un outil permettant de diminuer les risques de la pratique de l'anesthésie loco-régionale en bloc opératoire et aider les praticiens anesthésistes dans leurs gestes médicaux. Cet outil consiste en un traitement de l'information provenant d'un échographe dans le but de détecter automatiquement les blocs nerveux à neutraliser et guider le praticien vers ce bloc afin qu'il puisse injecter le produit analgésique le plus précisément possible. Dans ce cadre, la réalisation de ce projet repose sur des méthodes du traitement d'images et de la robotique afin d'extraire les blocs nerveux et pour planifier la trajectoire de l'aiguille pour l'amener sans difficulté sur le nerf ciblé.

Le problème de la détection du nerf n'est pas simple à résoudre car il se présente au sein d'une image échographique comme des régions aux contours peu saillants et la nature bruitée de ce type d'images rend encore la tâche plus ardue.

Dans cette perspective, l'objectif de cette thèse est de développer une méthode de détection du nerf efficace et précis pour aider les praticiens lors d'une procédure d'anesthésie loco-régionale écho-guidée (Figure 1.18).




FIGURE 1.18 – Synthèse de l'objectif

Dans un premier temps nous avons étudié l'aspect spatial de la détection du nerf, cette étude nous a permis de proposer une méthode de détection de nerf basée sur des fenêtres coulissantes et la classification.

Cependant, les praticiens ont tendance à localiser le nerf en se basant à la fois sur l'information spatiale (anatomie du nerf) mais aussi l'information temporelle pour confirmer cette détection. De là nous avons élaboré une autre méthode de détection robuste en se basant sur l'information

spatio-temporelle. Cette méthode est basée sur plusieurs modalités ; d'une part nous localisons le nerf à l'aide d'un modèle probabiliste dynamique en-ligne. Ce modèle est réalisé à partir d'une estimation de la trajectoire du nerf dans une séquence d'images. D'autre part un module de mesure de qualité de détection est employé pour confirmer cette détection. Ce module a été développé en se basant sur la confiance de classification d'une part et d'autre part sur l'utilisation d'un modèle de déformation de la forme du nerf dans le temps.

1.5 Validation des méthodes de la détection du nerf

La détection des nerf dans les images échographiques nécessite une étude approfondie sur les techniques de détections les plus performants d'une part et d'autre part repose sur un ensemble de données assez large afin d'inclure les variations intra et inter patients. Ces étapes sont primordiales pour évaluer la robustesse des méthodes de détection du nerf dans les images US. Cependant, la localisation du nerf pour l'ALR est un sujet très délicat, en raison d'absence de données. À notre connaissance, aucune base de données des images échographiques des nerfs n'est publiée. De cette raison, une récolte des données est inévitable pour évaluer les performances des méthodes de détections du nerf.

Une visite de la salle d'opération et les discussions menées avec les différents praticiens de l'anesthésie locorégionale à la clinique Médipole Garonne Toulouse a permis de comprendre les étapes essentielles à prendre en considération pour réaliser les algorithmes de détection. Pendant ces journées, nous avons obtenu des vidéos avec une vérité terrain réalisée par des anesthésistes. D'autres visites à la clinique Médipole et réunions ont permis de cerner certains problèmes techniques et anatomique et avoir des réponses précises sur le plan médical, ainsi que des points de vues et perspectives du côté des praticiens.

Des vidéos échographiques du nerf médian ont été obtenues sur plusieurs patients volontaires dans des conditions réelles. Les données ont été acquises en deux différentes périodes à une année d'intervalle.

Les bases de données sont sous forme d'une vidéo pour chaque patient en format DICOM (convertit en format AVI pour une visualisation facile). Chaque vidéo contient dans les environs de 700 trames. Les images utilisées dans nos expériences sont de dimension 600×350 et 600×313 pixels. Les expériences de cette étude ont été menées à l'aide d'un ordinateur équipé de 32GB de RAM et un processeur Intel Xeon 3,70GHz $\times$ 8 CPU.

Très peu de travaux ont abordé la problématique de détection du nerf dans les images échographiques. Par conséquent, une évaluation des méthodes de segmentations est apodictique afin d'adopter une stratégie capable de résoudre le problème de localisation du nerf. Une fois cette stratégie aboutie, nous avons proposé des méthodes dédiées spécialement à la détection du nerf dans les

images échographiques sous les artefacts, les bruits et les variations morphologiques. Les résultats obtenus par ces méthodes ont été présentés régulièrement aux anesthésistes afin de recueillir leur retour et valider nos résultats. La vérité terrain validée par les anesthésistes a été comparée aux résultats obtenus par l'ordinateur. Cette comparaison a permis une mesure des performances des méthodes automatiques développées.

Chapitre 2

Détection des régions d'intérêt dans les images échographiques : état de l'art

La segmentation des nerfs dans les images échographiques est un sujet peu étudié. Dans un premier temps nous allons effectuer une brève revue des méthodes récentes de segmentation dans les images ultrasonores et lister les principales limites et inconvénients de celles-ci. L'analyse des points forts et faibles de chacune d'elles seront analysées permettant alors de faire émerger des propositions de nouveaux algorithmes plus adaptés pour répondre à la problématique qui nous intéresse ici à savoir la détection de nerfs. Cette démarche adoptée doit nous permettre tout naturellement de proposer une solution proche de la meilleure stratégie possible. En fin de chapitre, une discussion sur le choix de la stratégie proposée est donnée.

2.1 Introduction

Dans ce chapitre, une étude bibliographique est effectuée, afin de trouver la stratégie adéquate pour la meilleure détection du nerf dans les images US. Dans la littérature, trois types de taxonomies sont présentées afin de survoler les méthodes de segmentations des régions d'intérêts dans les images échographiques. La première se focalise sur l'organe, la seconde sur les approches théoriques et la dernière prend en compte les caractéristiques du système de traitement (automatique et semi-automatique).

Dans ce travail, nous avons regroupé ces méthodes en fonction de leurs approches théoriques et les types d'applications associées (Table 2.1). La taxonomie basée sur les approches théorique nous a permis d'avoir une estimation globale des performances des différentes méthodes. Cependant, chaque technique est directement liée à un type d'application. De cette raison, nous rapportons une taxonomie qui est à la fois basée sur les approches techniques mais aussi sur les différents types

d'applications. La taxonomie adoptée nous permet non seulement de comprendre le fondement de ces techniques mais aussi d'établir les points forts et faibles de ces méthodes par rapport à la détection du nerf dans les images US.

La taxonomie basée organes consiste à faire une synthèse d'une technique appliquée sur plusieurs organes. Par exemple dans le travail de [234], les auteurs ont présenté une étude sur la technique basée sur la transformée en ondelettes dans la phase de pré-traitement pour la segmentation et l'extraction des caractéristiques du cancer du sein, de la thyroïde, de l'ovaire et de la prostate dans les images US. Dans [110], les auteurs ont aussi présenté un travail de synthèse sur les algorithmes de multi-atlas appliqués sur une variété de problèmes biomédicaux.

Il existe aussi la taxonomie à base des méthodes théoriques. Cette synthèse consiste à cibler un organe et étudier les méthodes appliquées. Par exemple, dans [81], les auteurs ont présenté un survol sur les techniques de segmentation appliquées à la prostate dans les images US et l'imagerie par résonance magnétique. Dans une autre revue [67], un travail d'évaluation de plusieurs méthodes de segmentation appliquées sur la paroi de la carotide a été présenté.

Dans certaines revues, la taxonomie à base du type de système de traitement est utilisée. Comme dans [172], les auteurs ont testé les méthodes de segmentation appliquées au foie à l'aide des techniques automatiques et semi-automatiques. Les méthodes de segmentation semi-automatiques nécessitent une intervention limitée du praticien pour finaliser la segmentation. Par contre, les méthodes entièrement automatisées sont mises en œuvre sans aucune sorte d'intervention humaine.

L'objectif de ce chapitre est d'étudier les méthodes automatiques de segmentation pour différentes types d'organes. Dans ce travail, nous avons réalisé une synthèse qui cible les familles d'approches susceptibles d'être intéressantes pour notre problématique. Cependant pour les lecteurs intéressés par une taxonomie fondamentale sur les familles de méthodes de segmentation dans les image ultrasonores (US), la lecture des travaux de [168, 46, 76] pourront leur être d'un grand intérêt.

Dans la suite de ce chapitre, dans la Section 2.2 nous allons présenter l'état de l'art des méthodes de segmentation les plus récentes utilisées dans les images US. Ensuite, nous présentons dans la Section 2.3 les méthodes d'évaluation utilisées pour la segmentation des régions d'intérêts dans les images US. Finalement, une discussion sur la stratégie adoptée pour la segmentation du nerf est élaborée dans la Section 2.4.

2.2 Méthodes de segmentation des images échographiques

Les méthodes de segmentation dans les images ultrasonores présentées dans ce chapitre sont regroupées en quatre catégories :

1. **Méthodes de segmentations guidées par atlas :** Ces méthodes traitent la segmentation

TABLE 2.1 – Revue sur les méthodes récentes de segmentation dans les images échographiques

Approches	Organes													
	Cœur	Prostate	Sein	Carotide	Thyroïde	Peau	Fœtus	Vessie	Abdomen	Vaisseaux sanguins	Nerf sciatique	Foie	Utérus	Os
Atlas	[117, 247]	[188]												
Graphes		[279]	[104, 104, 105, 106, 86]	[73, 86]	[273]	[65, 64]								
Frontières	[270]	[148, 130, 270, 269]		[211, 212, 177]			[267]	[195]	[118]					
Modèles déformables	[83, 135, 275, 147, 49, 66, 108, 205]	[170, 78, 77, 80, 79, 113]	[213, 249, 253]	[111, 137]						[276, 146]	[97]	[132]	[183]	
Classification	[219, 277, 278, 250, 249, 99, 265]	[210, 271]	[143, 54, 275, 224]	[32]								[134, 173, 241, 218]		[14, 16]

comme un problème de recalage d'image, où la correspondance spatiale est établie entre les coordonnées de l'atlas et la nouvelle image. Le recalage implique des calculs de déformation afin de trouver la similarité entre l'atlas et la nouvelle image. La cartographie de similarité est ensuite utilisée pour étiqueter la nouvelle image. Toutefois, ces techniques sont très sensibles à la variation morphologique et présentent généralement un coût en temps de calcul très important.

2. **Méthodes de segmentations par graphe :** Ces méthodes peuvent représenter une image US à l'aide d'un graphe en associant un nœud du graphe à chaque pixel. Par la suite, en établissant des relations entre les nœuds correspondants à des pixels voisins dans l'image US, un graphe peut représenter la topologie d'attache aux données basées sur l'homogénéité des niveaux de gris. En présence de bruits dans les régions d'intérêt texturées (nerfs), le niveau de gris constitue une information trop bas niveau pour permettre une bonne identification de la classe d'appartenance de chaque pixel.
3. **Méthodes de segmentation à base de frontières :** Les techniques à base de frontières exploitent l'information des bords d'une région d'intérêt pour la segmentation. Les informations de bords sont souvent peu fiables dans les images US à cause du bruit et des artefacts. Des développements spécifiques sont souvent requis pour maîtriser ce problème.
4. **Méthodes de segmentation à base de modèles déformables :** Les modèles déformables font souvent référence à des courbes dans un domaine d'image à deux dimensions. Les courbes sont déformées sous l'influence de forces internes et externes. Les forces internes et externes associées à un modèle déformable sont combinées et incluses dans un cadre de minimisation de l'énergie pour segmenter des structures anatomiques. Cependant, l'évaluation de la courbe est complexe et souvent sensible au bruit dans les images US.
5. **Méthodes de segmentation basée sur la classification :** Ces méthodes utilisent différentes caractéristiques (intensité ou réponses de filtres) pour diviser et/ou classifier l'image en deux régions : la région d'intérêt et le fond. L'objectif de ces méthodes est de regrouper des objets semblables sur la base d'un vecteur de caractéristiques. Les différentes méthodes de classification seront classées en quatre groupe : Supervisée, non-supervisée, à base des méthodes probabilistes et les méthodes de détection assistées par ordinateur. Toutefois, le résultat de ces méthodes dépend principalement de la sélection des données d'apprentissages.

2.2.1 Segmentation guidée par atlas

Ce type d'approche est très utilisé pour la segmentation des images IRM du cerveau [256], plus récemment les images CT et IRM ont été aussi utilisées pour la segmentation de la prostate [168, 231, 248].

L'atlas anatomique est généré par un ensemble de segmentations manuelles des structures anatomiques. L'idée de la segmentation par atlas est d'utiliser l'atlas anatomique comme un cadre

de référence pour segmenter de nouvelles images. Cependant, la segmentation à base d’atlas est traitée comme un problème de recalage, étant donné que la segmentation est basée sur la recherche d’une transformation qui permet de mettre en correspondance l’atlas pré-segmenté avec la nouvelle image à analyser. Ces méthodes de segmentation sont bien adaptées pour les structures anatomiques stables comme le cerveau humain [110]. En revanche, ces techniques sont très peu utilisées pour les images US, en raison de la présence de fortes variations due à l’interaction des ultrason. Cependant, certains travaux ont proposé cette méthode sur les images US [117, 188, 247]. Dans [117], une méthode de segmentation des profils de vitesse du sang dans l’aorte (maladie cardiovasculaire) à partir d’images US en mode “Doppler” est présentée. La méthode proposée est basée sur le calibrage de l’image test à l’image pré-segmentée de l’atlas. Dans le processus de calibrage, l’information mutuelle est utilisée comme une mesure de similarité [157, 159], tandis que la maximisation de la mesure de similarité est effectuée en utilisant la méthode de remontée de gradient. Cependant, généralement, l’optimisation des métriques de similarité dans les images US n’indique pas une bonne correspondance de calibration. Ceci est dû aux artefacts et bruits dans les images US. Dans [247], les auteurs proposent un système de segmentation du cœur dans les images US basé sur la fusion des techniques de multi-atlas et une méthode de classification basée sur la fusion d’étiquetage de patches pour minimiser les erreurs de calibrage.

Durant ces dernières années, des techniques atlas-guidée ont été utilisées pour segmenter la prostate ou bien les tumeurs liées aux maladies cardiaques. Cependant, l’inconvénient de cette méthode dans les images US des nerfs est la sensibilité aux variations morphologiques.

2.2.2 Segmentation par graphe

Ces méthodes peuvent représenter une image à l’aide d’un graphe en associant un nœud du graphe à un groupe de pixels. En établissant des relations entre les nœuds d’un graphe, il est possible de représenter la topologie d’attache des données. Cette topologie informe de l’homogénéité des régions. Différents algorithmes basés graphe comme l’arbre de couverture minimale, les coupes minimales, la marche aléatoire et les algorithmes par régularisation peuvent être utilisés pour la segmentation des régions d’intérêts [63].

Dans [104], les auteurs ont proposé une méthode semi-automatique pour segmenter des tumeurs dans le cadre du cancer du sein. Cette méthode est basée sur deux étapes. Dans un premier temps, un filtre non-linéaire de diffusion anisotrope a été utilisé pour réduire le bruit. Dans la deuxième étape, une méthode de segmentation à base de graphes en utilisant des statistiques régionales est utilisée pour déterminer les sous-région connectées qui peuvent être fusionnées. En répétant cette procédure de fusion, l’image est segmentée en plusieurs sous-régions homogènes permettant ainsi de détecter la tumeur. La méthode proposée est robuste dans les images US. Cependant, deux paramètres de l’algorithme de segmentation ont été sélectionnés manuellement à plusieurs reprises pour obtenir un bon résultat. En continuité de ce travail, une étude sur la relation entre

les paramètres a été effectuée pour automatiser la méthode [105].

Houssem et al. [86] ont proposé une méthode semi-automatique de segmentation appliquée sur des images US de la carotide et des reins. Cette méthode nécessite deux étapes. Dans un premier temps, un contour est initialisé par l'expert pour sélectionner la région à segmenter, afin de réduire la taille du graphe. Dans un second temps ils ont appliqué deux méthodes de segmentation basées sur les algorithmes de GraphCuts à marche aléatoire. L'utilisateur initialise d'abord un contour de l'objet à segmenter. Ensuite l'image est partitionnée en fonction de la distance des pixels par rapport au contour initial. L'épaisseur de ces partitions est liée à la distance par rapport au contour selon la suite de Fibonacci. Une génération automatique de premier-plan et d'arrière-plan de l'image est obtenue selon une partition spécifiquement sélectionnée; tous les pixels au-delà de cette couche sont éliminés, ce qui limite la segmentation des régions proches du contour initial.

Dans [279], une autre méthode semi-supervisée a été proposée pour segmenter la prostate dans les images US, en se basant sur un schéma de partition de graphe. Dans un premier temps, l'utilisateur sélectionne manuellement quelques pixels représentant les nœuds, ainsi l'algorithme de partition de graphe sélectionne les nœuds connectés afin d'obtenir un contour de la prostate. Dans un second temps, le contour a été affiné par un descripteur de texture basée sur les statistiques pour déterminer l'appartenance d'un pixel à la région de la prostate.

Dans d'autres travaux, un algorithme basé graphe par régularisation a été proposé pour segmenter une lésion de la peau. Cette méthode [65] est basée sur les caractéristiques d'Haralick [101] pour représenter un pixel. D'autre part, les mêmes auteurs ont proposé une segmentation à base de graphe par régularisation qui relie le critère inspiré du travail de Chan and Vese [27] pour détecter la texture de la région d'intérêt. Cependant, la robustesse de cette méthode dépend de la sélection manuelle des caractéristiques. Dans ce contexte, les auteurs ont fusionné un classifieur supervisé (réseau de neurones) avec un algorithme à base de graphe par régularisation pour corriger les erreurs de segmentation [64].

Plusieurs méthodes de segmentation à base de graphe pour détecter une région d'intérêt dans les image US, passent par une étape de filtrage [104, 273, 106]. Dans [273], un filtre de diffusion anisotrope et un algorithme de coupe minimale ont été appliqués pour segmenter les nodules thyroïdiens dans les images US. Dans [106], ils ont proposé un système automatique pour détecter le cancer du sein dans une image US. Tout d'abord un filtre basé sur un modèle global de variation non-linéaire [215] est utilisé afin de réduire le bruit. Ensuite une méthode de segmentation à base de graphes (RGB) [104] est appliquée pour partitionner l'image en sous-régions. Puis, une méthode à base de classification utilisant les réseaux de neurones suivie d'une phase d'extraction et sélection des caractéristiques est utilisée pour reconnaître la tumeur.

Dans [73], les auteurs ont proposé une méthode automatique pour détecter les plaques carotidiennes, en se basant sur la segmentation d'une carte d'information mutuelle qui reflète la différence

de dépendance cinématique entre les plaques affectées et les normales. Cet algorithme repose sur le calibrage de l'image basée sur la méthode *group-wise* pour représenter le champ de déformation dans une séquence (déplacement vertical et horizontal), cette représentation est récupérée à partir des vecteurs de caractéristiques. Dans une deuxième étape chaque pixel est associé à un vecteur de caractéristiques à l'aide de l'algorithme d'analyse en composantes indépendantes pour identifier la classe du mouvement dominant et finalement représenter les dépendances cinématiques entre les pixels par une carte d'information mutuelle entre les pixels. Dans la dernière étape de cette méthode, la carte d'information mutuelle est segmentée en utilisant une méthode à base de chaînes de Markov.

En raison de la grande taille des image US du nerf, les méthodes de segmentations automatiques basées sur la théorie des graphes nécessitent un temps de calcul important. De plus, ces méthodes sont très sensibles aux déplacements visuels des structures anatomiques dans une séquence d'images US. Cependant, la combinaison de cette méthode avec d'autres peuvent contourner ces limitations.

2.2.3 Segmentation à base de frontière

Les méthodes à base de frontière sont souvent appliquées pour réduire le bruit et mettre en évidence les pixel appartenant à une frontière, par conséquent elles pourraient s'appliquer à la segmentation dans les images US afin de chercher les transitions entre plusieurs régions connexes.

Les méthodes les plus anciennes utilisent les filtres gradient comme Prewitt, Robert, Sobel, Castan et Canny pour extraire les informations des frontières (voir Figure 2.1). Cependant, avec la




FIGURE 2.1 – Résultats des filtres gradients dans une image US du nerf médian

présence du bruit, faible contraste, et des artefacts liés à l'image ultrasonore, ces méthodes génèrent souvent des erreurs de détection. Pour améliorer ces méthodes, des combinaisons de filtres gradients, l'information de la texture et l'intensité sont souvent nécessaires pour contourner les inconvénients de ces méthodes [153]. Les méthodes de segmentation basées sur l'information des frontières sont particulièrement difficiles dans les images US. Les filtres de gradients traditionnels ne parviennent pas à obtenir des bords précis en raison du faible contraste, du bruit et d'autres artefacts liés au ultrasons.

Pour surmonter ces problèmes, certaines approches visent à réduire le bruit dans l'image US.

Par exemple, dans [267], un nouveau noyau de diffusion anisotrope est proposé pour réduire le bruit et détecter les frontières de sacs embryonnaires dans les images US. Padmapriya et al. [195] ont proposé une méthode basée sur plusieurs étapes. Premièrement, un filtre passe-bas est appliqué pour réduire le bruit. Ensuite, le filtre de Sobel a été utilisé pour segmenter les frontières. Finalement, l'épaisseur de la paroi de la vessie permet la détection et l'analyse de divers anomalies dans les images US. Cependant un filtre passe-bas peut éliminer des frontières peu visibles de la région d'intérêt. Dans ce contexte, une méthode basée sur le coefficient de variation instantanée [270], la programmation dynamique et la classification floue [211] des frontières sont utilisées pour contourner les limites des filtres passe-bas [212]. Les mêmes auteurs ont proposé une méthode [177] automatique pour segmenter l'artère carotide dans une image US en utilisant la technique de flux de frontière [156] basée sur l'intensité et la texture.

D'autres approches utilisent l'information de la texture pour réduire les frontières parasites, afin de les détecter en appliquant les méthodes de segmentation à base de frontières. Kwoh et al. [130] ont utilisé des harmoniques de la transformée de Fourier pour réduire les frontières parasites de la segmentation de la prostate. Dans [118], les auteurs ont proposé un algorithme basée sur la transformation en ondelettes continue pour détecter les frontières de l'anévrisme de l'aorte abdominale dans les images US. [1] ont utilisé l'écart-type local pour identifier les régions homogènes et hétérogènes dans un cadre multi-résolution, afin de détecter la prostate.

Dans [148] les auteurs proposent une représentation radiale à bas-relief de la prostate qui implique la différence entre l'image originale et une image agrandie pour obtenir une carte de frontières. La carte est ensuite lissée et squelettisée pour générer les frontières raffinées. Dans le travail de [269], la méthode basée radial à bas-relief a été aussi utilisée pour initialiser le contour de la prostate et pour réduire les frontières erronées.

Les méthodes à base de frontières segmentent facilement les contours des régions d'intérêts. Cependant, les contours détectés sont souvent interrompus.

2.2.4 Segmentation à base de modèle déformable

Les modèles déformables sont des techniques basées sur la délimitation des frontières de région d'intérêt en utilisant des courbes fermées paramétriques ou des surfaces déformables sous l'influence de forces internes et externes. D'une part, l'énergie extérieure propage le modèle déformable vers la limite de l'objet à segmenter. D'autre part, l'énergie interne est utilisée pour préserver la douceur des contours lors d'une déformation. Les énergies internes et externes dans un modèle déformable sont combinées et minimisées pour segmenter une région d'intérêt (voir Figure 2.2).




FIGURE 2.2 – L'évolution de la courbe sur une image du nerf sciatique[97]

2.2.5 Modèles déformables paramétriques

Modèles de contours actifs

L'une des premières pratiques du modèle déformable paramétrique, appelé *snakes* ou contour actif, a été proposée par Kass et al. [119]. Un Modèle de Contour Actif (MCA) est une méthode variationnelle appliquée pour détecter les contours des objets dans les images. Il s'agit d'une méthode semi-automatique dans laquelle l'utilisateur dessine un premier contour au voisinage de la forme à segmenter. Ce premier contour va ensuite se déformer afin d'épouser la forme de l'objet dans l'image. La procédure de déformation est conduite par la minimisation de la fonction d'énergie, jusqu'à ce que le modèle de déformation atteigne le contour de l'objet. Supposons que $X(p)$ est la paramétrisation du contour C et I l'intensité de l'image. L'énergie de C est donnée par $\alpha \int |X'(p)|^2 + \beta \int |X''(p)|^2 - \lambda \int |\Delta I(X(p))|^2$. Les deux premiers termes représentent l'énergie interne et le troisième représente l'énergie externe. L'énergie interne est responsable du lissage (régularisation) du contour tandis que l'énergie externe est proportionnel à la distance entre le contour C et la limite de l'objet à segmenter. α , β et λ sont des paramètres libres. λ permet de contrôler la sensibilité au bruit. α et β empêchent la non-continuité et la rupture du contour au cours de la procédure d'optimisation itérative.

Étant donné le faible contraste dans les images échographiques, la localisation des frontières d'une structure anatomique est un véritable défi. Pour cette raison, l'énergie externe est souvent modifiée pour adapter le MCA aux modalités des tissus anatomiques. Différentes énergies comme la force de ballon [36], la force de distance potentielle [3] et le flux de vecteurs gradients [263] ont été proposés pour améliorer le modèle de contour actif.

Le modèle de ballon contour actif [36] ajoute une force de pression à l'MCA traditionnel, simulant un comportement similaire à un ballon, ce qui provoque le gonflement ou la rétraction (dégonflement) de la courbe en fonction de la position initiale du contour. La force de pression emmène le contour à surpasser les bruits isolés et les frontières à faibles contrastes afin de s'arrêter

au niveau des frontières à contraste élevé. Dans un travail récent [66], la force de ballon a été utilisée pour segmenter un ventricule cardiaque dans les images US. La contribution principale de cette méthode est l'énergie interne basée sur la force de ballon, qui minimise l'énergie de chaque point de la courbe en utilisant la topologie des points voisins, ainsi la courbe se déplace vers l'objet d'intérêt.

Les modèles de contour actif traditionnels et les MCAs basés force de ballon sont des méthodes semi-automatiques qui ne sont pas dépourvus d'inconvénients comme en particulier le manque de capacité à capturer des frontières. En raison de ces limitations, les Flux de Vecteurs Gradients (FVG) ont été développés. Le MCA à base de FVG est formé par un champ de vecteurs $V_{FVG}(x, y) = [u_{FVG}(x, y), v_{FVG}(x, y)]$ afin de remplacer l'énergie externe, où V_{FVG} est calculé à partir de la fusion des vecteurs de gradients.

[132] ont proposé une méthode basée sur des FVG généralisés pour la segmentation de la tumeur. Cette méthode est basée sur plusieurs étapes. Dans la première étape, le FVG généralisée [262] est utilisé pour obtenir un contour approximatif de la tumeur. Selon le contour approximatif, une nouvelle carte de distance est générée. Par la suite, une nouvelle carte directionnelle est créée par le calcul d'un produit scalaire des gradients de la carte des distances et l'image initiale. Dans ce processus, l'information du gradient directionnel et les informations de grandeur de la carte de distance sont utilisées pour atténuer les frontières indésirables et mettre en évidence les frontières réelles de la nouvelle carte directionnelle. Enfin, le champ de FVG généralisé est utilisé pour affiner le contour de la tumeur, en dirigeant le contour approximatif aux frontières. Dans le même contexte, une méthode basée sur un FGV modifié a été proposée pour évaluer les configurations locales du champ vectoriel pour attribuer à chaque point un score de direction. Ces caractéristiques ont été intégrées dans l'équation des FGV [213]. Dans [97], les auteurs proposent une méthode pour segmenter le nerf dans les images US. Cette méthode consiste à adopter le FGV comme un contour actif à base de frontière. L'analyse de la phase du signal monogénique est utilisée pour fournir des frontières fiables au FGV. Ensuite, un modèle probabiliste donne un nouveau champ de force externe pour attirer le contour actif vers la région d'intérêt.

Les méthodes à base des modèles de contours actifs agissent d'une manière intuitive et ils peuvent être facilement adaptées pour suivre des objets dynamiques. Cependant, ces méthodes représentent diverses limitations, comme la sensibilité au bruit et la dépendance à l'initialisation.

Modèles actifs de forme

Pour surmonter les limites des contours actifs dans les images US, les informations à priori de texture ont été étudiées afin de guider l'évolution du contour actif. D'autres chercheurs utilisent l'information de forme à priori pour éviter l'évolution du contour actif vers des fausses frontières [37, 242, 223, 103]. Parmi ces modèles, le modèle actif de forme (MAF) [242], a été largement appliquée dans la segmentation d'images médicales. Ce modèle comporte trois parties : (1) la construction

d'un Modèle Statistique de Forme (MSF) pour générer la forme à priori de l'objet d'intérêt à partir d'un ensemble de formes d'apprentissage; (2) construction d'un modèle d'observation de la région d'intérêt à partir de l'image afin de donner la confiance à la forme à priori (3) et finalement équilibrer l'énergie des deux modèles pour évaluer la courbe vers les frontières de la région d'intérêt.

Dans la partie de création de MSF, un modèle de distribution de points représente les frontières d'un objet en définissant interactivement une liste ordonnée de position de points correspondent aux mêmes positions de toutes les formes d'apprentissage. Ensuite, l'Analyse en Composantes Principales (ACP) [257] est utilisée pour réduire la dimensionnalité et la modélisation de la forme. Ce modèle représente la position moyenne des points et la déformation principale des formes.

Cependant, le MAF a les inconvénients suivant : (1) l'alignement des points de repère prend un temps considérable; (2) l'ACP est robuste seulement dans le cas où les formes d'apprentissage sont approximatives (linéaires) car l'ACP gère que les distributions linéaires; Si cette hypothèse n'est pas respectée, il y a un grand risque de perdre d'importantes informations, ce qui peut influencer considérablement la précision de l'estimation de forme; (3) l'information à priori de la forme doit être manuellement localisées proche de la région d'intérêt, le cas échéant, il peut conduire à des résultats de segmentation incorrectes.

Pour surmonter les limitations de l'ACP, plusieurs méthodes à base d'apprentissage multiple ont été utilisées pour créer un modèle de forme à priori dans un espace non-linéaire [236, 60]. La similitude des régions d'intérêts dans les images US a été utilisée pour modéliser l'information à priori afin de limiter l'évolution de la courbe pour segmenter la canine (cardiologie) et tumeur de sein [275, 249]. Dans d'autres travaux [108, 205] plusieurs modèles actifs de formes à base de dictionnaires d'apprentissage et de représentations parcimonies sont appliqués pour détecter la lésion dans le ventricule (cardiologie) dans les vidéos US. Récemment dans [183], les auteurs ont proposé un modèle statistique de forme basé sur l'aspect dynamique afin d'estimer la forme à priori, dans le but d'une segmentation plus précise des fibromes utérins dans les images US. Afin d'éviter l'opération d'alignement des données d'apprentissage, un nouveau modèle de représentation de forme paramétrique basé sur des caractéristiques radiales de l'information dynamique est proposé pour raffiner la segmentation.

L'inconvénient de ce type de modèle dans les images US sont les formes inattendues. Ce type de modèle gère que la détection des formes qui font partie de l'ensemble d'apprentissage. A l'opposé, il est robuste par rapport au bruit et les artefacts présents dans les images US.

Modèles actifs d'apparence

Les modèles actifs d'apparence [38] étendent les modèles actifs de forme en tenant compte à la fois de la forme du modèle, mais également d'autres propriétés de l'image, comme l'intensité ou la texture. Un modèle d'apparence peut représenter à la fois la variabilité de la forme et de

la texture observée dans un ensemble d'apprentissage. Ainsi, il diffère du modèle actif de forme, car au lieu de chercher localement chaque point du modèle, il vise à minimiser la différence entre une nouvelle image et une image synthétisée par le modèle d'apparence [39]. L'avantage du modèle actif d'apparence par rapport aux modèles actifs de forme est que ce dernier utilise uniquement des contraintes de forme et ne profite pas de toutes les informations du niveau de gris disponible dans un objet.

Les Modèles Actifs d'Apparences (MAA) sont souvent utilisés pour segmenter la prostate dans les images US, en raison de l'information de forme et d'apparence de la prostate [170, 78, 77, 80, 79]. Les MAA ont aussi été utilisés pour segmenter le ventricule dans des séquences d'images US [135]

Dans [170, 78, 77, 80], les auteurs ont utilisé le MAA comme le corps d'un algorithme de segmentation, cet algorithme combine le contour et l'information de la texture. La principale contribution de ces travaux est l'utilisation des caractéristiques pour définir l'information de la texture comme par exemple les ondelettes [78] et les motifs locaux binaires [77]. Cependant, dans le travail de [80], un modèle Bayésien a été utilisé pour obtenir la probabilité *a posteriori* du pixel ; cette probabilité remplace l'information traditionnelle d'intensité pour construire un MAA.

À son tour, deux des principaux inconvénients des modèles d'apparence actifs sont la difficulté de définir un ensemble d'apprentissage qui représente de manière fiable l'objet à segmenter, comme dans les modèles de forme actifs, et le coût supplémentaire impliqué dans la gestion d'un modèle plus complexe qui gère plus d'informations.

2.2.6 Modèle déformable géométrique

Les modèles déformables géométriques sont proposés dans [160, 23]. Ils fournissent une solution distinguée pour répondre aux principales limitations des modèles déformables paramétriques. Ces modèles sont basés sur la théorie de l'évolution de la courbe [122] et la méthode d'ensembles de niveaux (*LevelSets*) [194]. Les techniques d'ensembles de niveaux sont très populaires dans le domaine de la segmentation des images médicales [133, 171]. Dans la mesure où l'avantage de ces méthodes consiste à la prise en compte des changements de topologie automatique. Les méthodes *level-sets* existantes peuvent être regroupées en deux catégories : basées frontière et basées région [243, 244].

Les modèles des ensembles de niveaux à base de frontières utilisent l'information local des frontières pour conduire le contour vers les bords de l'objet. Cependant, ces méthodes sont très sensibles aux paramètres initiaux et les frontières peu visibles [24]. Les méthodes d'ensembles de niveaux à base des régions visent à identifier chaque région d'intérêt en utilisant certains descripteurs pour guider l'évaluation du contour [139]. Cependant, définir un descripteur de région est difficile dans une image avec la présence de bruit et de faibles bords.

Des efforts ont été faits pour automatiser la segmentation à base de modèles d'ensembles de niveaux dans les images US. Dans [137, 113], les auteurs ont proposé des méthodes à base de classification floue pour fournir une estimation approximative du contour avec l'intégration du modèle des ensembles de niveaux pour segmenter l'artère carotide et la prostate dans les images US. Cependant, des opérations sont encore nécessaires pour ajouter les paramètres d'un modèle d'ensembles de niveaux efficace et robuste. Une méthode améliorée de flou c-moyenne (*fuzzy c-mean* en anglais) avec l'information spatiale a été proposée pour initialiser la fonction de level-set [113]. Une distance de régularisation de l'évaluation des level-sets est également apparue comme une technique puissante pour la segmentation des images US, compte tenu de sa performance. Mais elle n'a pas été en mesure de suivre les frontières faibles dans les images US [140]. Récemment, quelques travaux visent à segmenter automatiquement des régions d'intérêt dans les images US sans initialisation de paramètres pour l'évaluation de la courbe. Par exemple, dans [146] un modèle d'ensemble de niveau automatique (sans contour initial) est proposé pour la segmentation des vaisseaux sanguins dans les images US. La contribution de cet article se manifeste principalement en trois points. Premièrement, ils proposent une méthode de classification basée sur un algorithme de *mean shift* adaptatif, cet algorithme est basé sur l'information globale pour évaluer l'ensemble de niveaux. Deuxièmement, le résultat de la classification de l'image est utilisé pour estimer les paramètres de contrôle de l'évaluation du contour.

L'un des principaux avantages des méthodes d'ensemble de niveaux est la capacité naturelle d'une surface unique à se diviser et fusionner sans perdre son identité. D'autre part, l'un des principaux inconvénients réside dans l'exigence d'un effort considérable pour concevoir des fonctions de vitesse appropriées à la fonction d'ensemble de niveau.

D'une autre part, les contours actifs géodésiques [24] ont été présentés comme la fusion entre les modèles déformables géométriques et paramétriques. Cette méthode est basée sur la relation entre les contours actifs et les distances géodésiques, reliant les modèles de contours actifs basés sur la minimisation de l'énergie et les contours actifs géométriques afin d'évaluer la courbe. Cette technique est basée sur les contours actifs qui se déforment dans le temps en fonction des mesures géométriques dans une image. Les contours se divisent et se fusionnent naturellement pendant le processus, ce qui permet de détecter simultanément plusieurs objets. Les contours actifs géodésiques ont été utilisés pour segmenter les régions d'intérêt dans les images échographiques. Par exemple, dans [206] les auteurs ont proposé une méthode à base d'un modèle de régions actives géodésiques pour segmenter du thrombus dans une image US veineuse. L'image est d'abord lissée par un filtre Gaussien puis des caractéristiques statistiques des frontières et régions ont été calculées pour former un modèle de distribution de niveaux de gris de la région et une méthode level-set à partir d'une courbe initiale a été appliquée. Récemment, dans [253] une méthode à base d'un filtre de diffusion anisotrope et un contour actif géodésique ont été appliqués dans les images US pour segmenter le cancer du sein. Dans ce travail, ils ont montré que les méthodes de contour actif géodésique sont efficaces seulement si un filtre a été appliqué sur les images US afin de réduire le bruit. Cependant,

dans un cas général les filtres réduisent à la fois le bruit dans l'image US et perdent de l'information utile comme les frontières de la région d'intérêt.

En général, les modèles déformables géométriques présentent en particulier une sensibilité au réglage des paramètres de contrôle pour l'évaluation de la courbe.

2.2.7 Méthodes de segmentation basées sur la classification

Les méthodes de segmentation par classification sont des techniques de reconnaissance de motifs dans une image. Ces techniques sont basées sur la distinction d'une région d'intérêt par rapport à d'autres (e.g. arrière plan) à l'aide des caractéristiques. Les techniques basées classification visent à obtenir une partition de l'espace des caractéristiques dans un ensemble de différentes régions étiquetées. Ces techniques peuvent être groupées en quatre familles ; supervisée, non-supervisée, à base de méthodes probabilistes et les méthodes de détection assistée par ordinateur.

Les techniques de classification supervisées sont basées sur l'apprentissage des données manuellement étiquetées. Ces données sont utilisées comme un modèle pour segmenter automatiquement les nouvelles données. En revanche, le but des méthodes de classification non-supervisée est d'identifier des régions similaires dans une image sans l'utilisation des données d'apprentissage. Des mesures de proximité sont utilisées pour regrouper les données en classes de type similaire. De plus, les techniques de classification à base des méthodes probabilistes sont souvent utilisées pour caractériser le bruit dans les images US. Ces méthodes sont basées sur des modèles probabilistes pour représenter l'échogénicité d'une région d'intérêt dans une image US. D'autre part, les techniques de détection assistée par ordinateur sont souvent liées à la classification pour segmenter une région dans une image. Ces méthodes nécessite plusieurs étapes de calcul ; du pré-traitement jusqu'à la segmentation, en se basant sur des techniques d'analyses d'images et d'apprentissage automatique.

Segmentation par classification supervisée

La segmentation par classification supervisée est un problème d'apprentissage et de prédiction. L'ensemble des données d'apprentissage est associé avec un vecteur de caractéristiques et d'une étiquette de classe. Ces données d'apprentissage sont utilisées pour construire un modèle prédictif, afin d'assigner une classe à chaque objet à segmenter.

La segmentation basée sur la classification supervisée a été beaucoup utilisée pour la détection des régions d'intérêts dans les images US. Le principe de base de ces méthodes est l'extraction des caractéristiques pour représenter les tissus à segmenter et finalement la classification afin d'attribuer à chaque pixel une étiquette correspondante à une classe. Par exemple, les auteurs dans [173, 241] ont proposé une méthode de segmentation à base de classification supervisée pour le détection du foie dans les images US. Dans [173] les caractéristiques ont été calculées à partir de la texture dyna-

mique [56], puis la méthode de k-plus proche voisins a été utilisée comme classificateur. Dans [241], une transformée en ondelettes continue a été utilisée pour caractériser les tissus du foie et un séparateur à vaste marge pour classer les pixels dans une image US. Dans un autre travail [129], les auteurs ont proposé une méthode à base de transformée en cosinus discrète [5] comme vecteur de caractéristique et un réseau de neurones incrémental comme classificateur pour la segmentation de vessie dans les images US. Récemment dans [275], les auteurs ont étudié la segmentation du cancer du sein dans les images US, en se basant sur le principe des techniques de segmentation à base de classification. Les auteurs ont utilisé d'une part, la transformée de shearlet [88] pour caractériser la texture des tissus cancéreuses et d'autre part, un séparateur à vaste marge a été utilisé pour grouper les pixels correspondant aux tissus cancéreux. La segmentation de l'artère carotide aussi a été étudiée en utilisant ce type de méthode, notamment un histogramme de niveaux de gris a été élaboré comme un vecteur de caractéristiques et un classificateur flou à base de réseaux de neurones [32].

la variabilité de l'échogénicité des pixels, les artefacts ultrasonores et l'incertitude des caractéristiques de texture posent souvent un défi lors d'une classification dans une images US. Cependant, plusieurs auteurs ont proposé des combinaisons de caractéristiques de texture et de classificateurs pour contourner la difficulté de segmentation dans les images US. Par exemple, dans [143], les auteurs ont proposé une méthode de segmentation du cancer du sein en se basant sur un séparateur à vaste marge et 16 caractéristiques calculées à partir d'une matrice de co-occurrence, de la moyenne et de la variance de l'intensité de groupes de pixels dans l'image. Dans [271], les auteurs ont aussi utilisé une fusion de caractéristiques, dont l'entropie, l'énergie de symétrie et le second ordre des coefficients d'ondelettes [75] afin de segmenter la prostate dans les images US. Récemment dans [16], les auteurs ont proposés une méthode de segmentation pour détecter le spinos process, l'ombre acoustique et les autres tissus dans la colonne vertébrale. Cette méthode de segmentation est basée à la fois sur la fusion du gradient de l'image, la carte de probabilité d'os [70], la phase de symétrie [92], le motif local binaire et le filtre de Gabor comme caractéristique et l'analyse discriminante linéaire comme classificateur [169]. Par exemple, dans [54] une méthode à base de caractéristique d'Haralick et la fusion de plusieurs classificateurs de séparateurs à vaste marge ont été utilisées pour segmenter une tumeur dans les images US de sein. Dans un autre travail récent, une combinaison de caractéristiques et de classificateurs a été utilisée comme méthode de segmentation. la méthode proposée est basée sur la combinaison d'une part, de plusieurs classificateurs comme, le séparateurs à vaste marge, le réseaux de neurones artificiels, le naïve Bayésien, le k-plus proche voisin et l'arbre de décision. D'autre part, 357 caractéristiques ont été utilisées pour segmenter un foie malade dans une image US [218]

Les méthodes d'apprentissage de séparateur à vaste marge sont très utilisées pour la segmentation à base de classification dans les image US. Les méthodes d'apprentissage en profondeur sont devenues récemment des techniques très en vogue pendant ces dernières années, en raison de leur robustesse. Cependant, ces méthodes souffrent généralement du problème de la petite taille de

l'échantillon d'apprentissage. Les ensembles de données ultrasonores sont généralement trop petits pour pouvoir utiliser ces techniques.

Segmentation par classification non-supervisée

Le but d'une telle méthode est de segmenter une image en se basant sur des mesures de distances, sans besoin des données étiquetées. Ces mesures de distance sont appliquées sur des vecteurs de caractéristiques afin de regrouper et classer les régions similaires. L'inconvénient de cette méthode est le choix du nombre initial de groupes.

Ces méthodes sont souvent employées sur les images par résonance. Cependant, quelque travail propose ces méthodes pour la segmentation des images US. Par exemple, dans [210], les auteurs ont proposé une méthode de segmentation de la prostate. Ils ont utilisé l'algorithme de *mean shift* dans l'espace des textures pour déterminer la matrice de covariance pour chaque *cluster*. Une étiquette probabiliste a été attribuée à chaque pixel pour déterminer l'appartenance d'un pixel par rapport à chaque *cluster*. Dans [134] les auteurs ont utilisé la décomposition spatiale et fréquentielle et la géométrie fractale comme vecteur de caractéristiques puis l'algorithme de k-moyenne est utilisé pour déterminer les pixels appartenant aux tissus d'un foie malade dans une image US. Une fusion de caractéristiques comme la matrice de co-occurrence, banque de filtre de Gabor et les coefficients de transformée en cosinus discrète a été introduite dans un algorithme de k-moyenne pour une segmentation non-supervisée d'os dans une image US [14].

2.2.8 Segmentation de classification à base des méthodes probabilistes

Une grande variété de modèles basés région a été présentée au cours des dernières années. Parmi ces méthodes, les approches probabilistes sont de plus en plus répandues [41]. Ces approches sont utilisées pour définir les motifs hyperéchogènes afin de caractériser différents types de tissus dans les images US. Généralement les modèles probabilistes sont utilisés pour segmenter chaque région selon un ensemble de paramètres. De cette façon, on peut distinguer la région d'intérêt des autres. Ces modèles sont basés sur la distribution gaussienne [175], la distribution Gamma, la distribution de Weibull [235], la distribution de Wishart [12], la distribution de Rayleigh [219] et la distribution de Fisher-Tippett [59]. Ces modèles sont principalement élaborés à travers la maximisation d'une estimation de vraisemblance ou d'une probabilité a posteriori.

Plusieurs travaux ont mis l'accent sur la modélisation du bruit des images US en tant que partie intégrante du modèle de segmentation [186, 187]. Dans [278], des densités d'un mélange de Nakagami sont utilisées pour modéliser la distribution du sang et de l'arrière plan pour détecter la déformation cardiaque dans les images US. Dans le même contexte, un mélange de distribution de Rayleigh est utilisé pour segmenter le myocarde dans les images US [277]. Dans [196] la distribution exponentielle est utilisée pour modéliser les tissus du ventricule gauche.

De nombreux travaux récents utilisent un mélange de plusieurs distributions pour segmenter une région d'intérêt dans les images US. Par exemple dans [99], les auteurs ont utilisé un mélange de Gamma, Nakagami, Rayleigh, Log-Normal et Fisher-Tippett distributions pour modéliser la distribution de la position de l'endocarde dans une vidéo de cardiographie.

Les méthodes probabilistes basées distributions peuvent aussi être utilisées pour minimiser les fonctions d'énergies dans des modèles à base de contours actifs. Dans [219], la probabilité de distribution de Rayleigh a été utilisé afin de représenter l'intensité de l'image dans un modèle déformable géométrique. Dans des récents travaux [250, 249, 265], une distribution Gaussienne a été utilisée pour minimiser la fonction d'énergie du modèle de contour actif afin de segmenter le ventricule dans les images US.

Les méthodes probabilistes sont souvent appliquées pour détecter le dysfonctionnement cardiaque dans les vidéo US. Ceci dit, les modèles de distributions sont adaptés à ce type d'application, en raison du rythme cardiaque dans les vidéo US ce qui génère une distribution périodique. Cependant, dans une vidéo US du nerf, la dynamique de la distribution est variée, ce qui rend ces méthodes moins efficaces.

2.2.9 Segmentation à base des systèmes de détections aidées par ordinateurs

Au cours des dernières décennies, il y a eu un intérêt croissant pour ces systèmes dans différentes applications médicales [33, 112, 68]. La méthode de Détection Aidée par Ordinateur (DAO) est généralement décomposé en pré-traitement, extraction et/ou sélection des caractéristiques et finalement l'étape de classification. Par exemple, dans [158], un grand nombre de caractéristiques ont été extraites, puis un algorithme à base d'informations mutuelles est utilisée pour sélectionner les meilleurs caractéristiques. Finalement, un classificateur non-linéaire est utilisé pour détecter le cancer du sein dans les images US. Le classificateur non-linéaire a aussi été utilisé avec des caractéristiques extraites par les ondelette afin de détecter la prostate [61]. Récemment, [124] ont proposé un système de DAO à base de caractéristiques et un classificateur k-plus proche voisin afin de modéliser le spina bifida dans une image US. Dans [126], les auteurs ont proposé un système DAO automatique pour segmenter le rein dans une image US. Une étape de pré-traitement est utilisée pour dé-bruiter l'image, puis les caractéristiques de Haralick et un histogramme d'intensité sont calculé et finalement une classification à base de SVM est utilisé pour détecter la présence de pierres dans le rein. Les méthodes de DAO sont souvent utilisées pour segmenter les régions d'intérêts dans les images US. Cependant, la robustesse de ces méthodes se basent principalement sur le choix des techniques utilisées dans chaque étape du système. Par ailleurs, les systèmes DAO existants dans la littérature sont souvent basés sur la classification des pixels. Toutefois, ces méthodes ne sont pas adaptées à la segmentation du nerf, en raison de la vraisemblance des pixel du nerf et d'autre région dans l'images US.

2.3 Évaluation des performances des méthodes de segmentation

La performance des algorithmes de segmentation dans les images US est généralement évaluée en comparant le résultat de la méthode proposée avec une vérité terrain obtenu à partir d'une annotation manuel de la région d'intérêt faite par des experts. Habituellement, la moyenne des segmentations manuelles de différents experts à différents moments est utilisée pour réduire la variation d'annotation.

Dans la littérature, les mesures d'évaluations peuvent être classées en mesures qualitatives et quantitatives. Dans une évaluation qualitative, la région segmentée est visuellement comparé avec la vérité terrain. En revanche, pour l'évaluation quantitative, l'erreur entre la segmentation obtenue et la vérité terrain est numériquement calculée. En règle générale, ces mesures d'erreurs peuvent être classés en mesure de similarité, mesure de distance et mesure standard [204]. Cependant, l'évaluation des méthodes de segmentation est souvent lié à la métrique à base de contour et à base de région. Les métriques à base de contours reposent sur le calcul de la proximité de la vérité terrain et les contours obtenues. Les métriques à base des contours les plus utilisées pour la segmentation dans les images US sont la distance d'Hausdorff [97, 16, 183], la distance moyenne [99, 269], la distance moyenne absolue [99, 269] et l'erreur quadratique moyenne [265]. Les métriques à base de région sont basées sur le calcul de chevauchement de la vérité de terrain et la zone obtenue après segmentation. L'erreur de chevauchement est souvent calculée par la métrique de Dice [97, 269, 113, 250, 265, 16, 73], l'erreur de consistance globale [265], la sensibilité [99, 265, 32, 224, 73, 106, 183], la spécificité [265, 32, 224, 73, 106, 183], le f-score [86, 32, 224, 73, 106, 183], la courbe ROC [86], la courbe de précision-rappel [99, 106], l'erreur de surface [99] et la zone de recouvrement [269, 73].

Dans ce travail, la sensibilité, la spécificité et le f-score seront utilisées pour déterminer le score de localisation. Ensuite, pour analyser le résultat de segmentation, les mesures de Dice et Hausdorff sont utilisées (voir Table 2.2).

2.4 Choix de la méthode de segmentation des nerfs dans les images échographiques

Dans cette section nous avons discuté les points forts et faibles de chaque méthodes abordées dans la section précédente, afin d'adopter la stratégie la plus appropriée aux modalités du nerf dans les images échographiques.

L'obstacle de la segmentation des images US des nerfs par les méthodes à base d'atlas est la sensibilité au variation morphologique. Par ailleurs, les méthodes basées sur la théorie des graphes est aussi moins adaptées pour ce type d'application, en raison des temps de calculs importants. De plus les méthodes à base de frontières détectent souvent des contours coupés, ce qui rend ce

type de méthode incohérente avec notre objectif. Quand aux méthodes de segmentation à base de modèles déformables, elle sont sensibles au bruit et ils exigent une initialisation des paramètres pour minimiser les fonctions d'énergies ce qui rend cette méthode pas complètement automatique. A son tour, La segmentation par classification est souvent utilisée dans les images US. Cependant, l'intensité et la texture peu fiable du nerf est un défi pour le développement d'un système de classification supervisée et non-supervisée. Les principales limitations de chacune de ces techniques est souvent lié aux artefacts, aux bruits et les variations morphologiques dans les images US (voir Figure 2.3). Par conséquent, des méthodes hybrides ont été utilisées pour contourner ces limites. Ces




FIGURE 2.3 – Trois trames d'une vidéo US à $t = 1, 50, 84$ annotée par un expert anesthésie (le nerf est représenté par la couleur verte).

méthodes combinent l'information à priori élaborée par des méthodes à base d'atlas, de graphes, de frontières, des modèles déformables et par classification pour améliorer la segmentation. Par exemple la classification peut être utilisée pour la segmentation initiale ensuite les informations obtenues sont utilisé pour la propagation d'un modèle déformable afin de produire la segmentation finale [97]. Dans [91], le résultat obtenu d'une classification non-supervisée est utilisé pour initialiser un modèle déformable. Dans [214], deux méthodes hybrides ont été proposées. Le premier algorithme est basé sur la classification non-supervisée floue et les réseaux neuronaux cellulaires. Dans le deuxième algorithme un réseau de neurones artificiels et un algorithme de level-set ont été utilisés pour segmenter une tumeur de sein.

Une autre solution prometteuse pour contourner les limites des méthodes de segmentations mono-modèle est la détection assistée par ordinateur (DAO) dans les images US. Toutefois, la

TABLE 2.2 – Évaluation de la méthode de segmentation du nerf dans les images échographiques

Métrique	Paramètre	Équation	Utilisé par
Distance d'Hausdorff	Un ensemble de points $A = a_1, \dots, a_n$ et $B = b_1, \dots, b_m$	$HD(A, B) = \max(h(A, B), h(B, A))$ où $h(A, B) = \max_{a \in A}(\min_{b \in B} a - b)$	[97, 16, 183]
Dice	R_{VT} : vérité de terrain, R_{Seg} : région segmentée	$DC(R_{VT}, R_{Seg}) = \frac{2R_{VT} \cap R_{Seg}}{R_{VT} + R_{Seg}}$	[97, 269, 113, 250, 265, 16, 73]
Sensibilité Spécificité F-score	VP : vrais positive VN : vrais négative FP : faux positive FN : faux négative	$SN = \frac{VP}{VP+FN}, SP = \frac{VN}{VN+FP},$ $Fscore = \frac{2VP}{2VP+FN+FP}$	[99, 265, 32, 86, 224, 73, 106, 183]

segmentation du nerf dans les images US doit impérativement utiliser l'information spatiale, la texture et les priorités physiques de l'ultrason afin d'avoir une détection robuste. En effet, les

méthodes hybride ont montré leur robustesse pour la segmentation dans les images US. C'est pourquoi, nous utiliserons ce concept afin de localiser le nerf puis le segmenter en se basant sur un modèle déformable. Cependant, la structure du nerf ne peut être différenciée des autres tissus que par une représentation basée région. En conséquence, nous adoptons la stratégie des méthodes de DAO, afin de localiser la région du nerf.

2.5 Conclusion

Dans ce chapitre nous avons examiné les méthodes récentes de segmentation des régions d'intérêts dans les images ultrasonores. Premièrement, les avantages et les limites de ces méthodologies ont été discutés, ensuite un bref survole sur les méthodes d'évaluation a été proposé. Finalement, une réflexion sur le choix d'une méthode de segmentation du nerf appropriée est donnée. Il a été mis en évidence que les techniques de segmentation du nerf devraient utiliser les méthodes hybrides. En initialisant la segmentation par un système de détection assistée par ordinateur, puis obtenir la détection finale par un modèle déformable. Les stratégie hybrides et DAO ont été utilisées pour améliorer la précision de détection. Dans le chapitre suivant, nous allons élaborer ces deux stratégies pour confirmer le faisabilité d'une méthode de détection robuste et efficace.

Chapitre 3

La détection du nerf assistée par ordinateur

La segmentation automatique ou semi-automatique dans les images échographiques est une tâche délicate. Non seulement, le bruit, le faible contraste et les artefacts d'images ultrasonores affectent considérablement la performance de segmentation. Mais encore, la distribution hétérogène et la déformation de la région du nerf due à la manipulation de la sonde et à la variation anatomique inter-patient rendent la segmentation du nerf un défi. Ainsi, l'apparence du nerf est confondue avec d'autres tissus anatomiques comme le tendon, le muscle et les vaisseaux sanguins. Pour faire face aux défis de la segmentation du nerf, nous proposons une méthode hybride basée sur la localisation et la segmentation. L'étape de localisation est dérivée d'un nouveau système de détection assistée par ordinateur et l'étape de segmentation est basée sur un modèle déformable paramétrique.

3.1 Introduction

Plusieurs études ont rapporté des améliorations significatives dans la pratique médicale et l'efficacité lors de l'utilisation d'un système DAO [50, 208, 179, 136]. Par ailleurs, la stratégie de DAO peut fournir un outil de détection automatique des nerfs pour les anesthésistes. Cependant, les modalités d'imageries US associées aux propriétés visuelles du nerf rendent la localisation automatique difficile et présentent un vrai défi. Très peu d'études dans la littérature ont traité cette problématique [237, 96]. Dans [237, 96], les auteurs ont proposé une méthode à base de modèle déformable pour détecter le nerf sciatique dans les images US. D'une part, [237] ont utilisé un contour actif basé sur le flux de vecteurs gradients (GVF). D'autre part, dans [96] une méthode basée sur la combinaison d'un signal monogénique et un contour actif probabiliste a été proposée pour détecter le nerf sciatique. Toutefois, ces études ne fournissent pas une vue d'ensemble ou une évaluation approfondie des techniques utilisés dans les images US afin de détecter les nerfs. Cela soulève par conséquent les questions suivantes : (1) comment les techniques issues de l'état de l'art

peuvent être utilisées pour la détection du nerf destinées plus particulièrement aux interventions de type ALR? (2) Quel type de méthode à chaque étape du système DAO proposé peut conduire à une meilleure performance?

Un certain nombre d'auteurs ont examiné des méthodes de la vision par ordinateur et de l'apprentissage automatique dans les images US pour diverses applications médicales. Dans [34], les auteurs ont fait un état de l'art des étapes d'un système de DAO destiné au diagnostic du cancer du sein. Ils ont effectué une étude approfondie de la littérature et ont discuté de leurs avantages et leurs limites. Toutefois, l'étude n'a pas tenu compte de l'évaluation des performances des méthodes, qui est une étape essentielle pour mesurer les limites d'une méthode de manière efficace dans une application donnée. Il existe, d'ailleurs, des travaux qui ont tenté de réaliser des études comparatives des techniques de détections dans les images US. Par exemple, dans [29], une étude comparative de détection d'infarctus a été effectuée. Dans [239], les auteurs ont rapporté une analyse comparative des techniques à base d'ondelettes. Dans [152], les auteurs ont comparé les techniques de dé-bruitages. La plupart de ces études comparatives se concentrent sur une seule étape d'un système DAO. La principale faiblesse de ces études comparatives est que l'on ne peut tirer aucune conclusion effective de la performance de l'ensemble du système DAO. Pour cette raison, nous étudions les performances de chaque étapes du système DAO afin de trouver l'ensemble performant.

Dans ce travail, nous proposons dans un premier temps un nouveau système DAO afin de segmenter le nerf médian dans les images US. Ensuite, nous consolidons cette proposition par une étude comparative des performances de chaque composante de ce système. Dans un travail antérieur, nous avons mené une étude afin de sélectionner les paramètres optimaux pour chaque techniques de ce système afin de présenter uniquement les méthodes ayant les meilleurs résultats. Mais encore, nous intégrons dans ce système DAO un nouveau descripteur et un nouveau algorithme de sélection de caractéristiques afin de présenter et sélectionner au mieux les caractéristiques du nerf dans les images US. Ce chapitre est organisé comme suit : la méthode de détection du nerf est présentée progressivement à partir de la Section 3.2 jusqu'à la Section 3.7. Ensuite, dans la Section 3.8, nous détaillons le descripteur et l'algorithme de sélection proposés. Finalement, Dans la Section 3.9, la validation et l'évaluation du système sont fournies, suivie d'une discussion dans la section 3.10.

3.2 Système DAO proposé pour la détection du nerf

Dans la section actuel nous présentons le système général de détection du nerf. La Figure 3.1 illustre l'ensemble de la chaîne de traitement, qui est composée de plusieurs techniques de traitement d'image et d'apprentissage.

Tout d'abord, nous avons appliqué les techniques de pré-traitement afin de réduire l'effet du




FIGURE 3.1 – Les étapes du système de détection du nerf dans les images US proposées

bruit et d'améliorer les propriétés visuelles des tissus anatomiques. Après l'étape de pré-traitement, l'extraction de caractéristiques a été réalisée pour représenter la texture des régions d'intérêts. Ensuite, la sélection des caractéristiques a également été effectuée pour obtenir un sous-ensemble des caractéristiques les plus discriminantes. Le sous-ensemble optimal choisi a été utilisé avec un algorithme de Séparateur à Vaste Marge (SVM) pour la phase d'apprentissage et de test. Un seul modèle SVM est utilisé pour avoir plusieurs instances. En effet, le nerf médian change de structure tout au long de l'avant bras (coude, proximale et distale, et le poignet), comme illustré dans la Figure 3.2. Pour cette raison, différentes instances SVM ont été utilisées pour représenter les différentes structures du nerf médian dans l'avant bras. Par conséquent, différentes régions




FIGURE 3.2 – Indication des 3 lieux de visualisation du nerf médian dans l'avant-bras

candidates ont été générés par ces instances. Une mesure de confiance a été appliquée sur ces régions candidates pour sélectionner la meilleure cible qui représente le nerf. Après la localisation de la région du nerf, un contour actif a été appliqué pour segmenter les frontières du nerf.

3.3 Pré-traitement

La phase de pré-traitement comprend deux étapes. Dans un premier temps, l'algorithme k-moyennes est appliqué avec $k = 2$, afin de classer chaque pixel selon l'intensité, et ainsi extraire les tissus à tendance hyperéchogènes. La Figure 3.3 (b) montre un exemple du résultat obtenu permettant l'isolation des tissus anéchogènes présents dans l'image originale de la Figure 3.3 (a). Dans la deuxième étape, on extrait la région de la peau, afin de réduire l'ambiguïté entre les















FIGURE 3.3 – Un exemple du pré-traitement, la région annotée avec la couleur jaune sur l'image représente la section du nerf. (a) l'image originale pré-segmentation par l'algorithme k-moyennes. (b) isolation des tissus anéchogènes (c) extraction des tissus de la peau.

structures nerveuses et les tissus de la peau. Après l'extraction des tissus hyperéchogènes, nous avons soustrait les tissus de la peau (épiderme et derme) à l'aide d'un algorithme de squelettisation, une opération de morphologie et de propriétés anatomiques. Dans un premier temps, l'algorithme de Thomé est appliqué pour supprimer les pixel inessentiels, ensuite une opération d'érosion est utilisée afin d'améliorer les propriétés géométriques des tissus anatomiques. L'information anatomique quant à elle aide à éliminer certaines de ces régions. En effet, on sait que la région de l'épiderme et du derme se situent toujours vers le bord du haut de l'image avec une profondeur de plusieurs millimètres (dizaine de pixels) [71]. Ceci permet d'éliminer cette structure dans l'image. Ce pré-traitement est important car il réduit les erreurs de détection et le temps de recherche du nerf. Un exemple de cette opération est illustrée dans Figure 3.3 (c), où le cadre rouge indique la zone éliminée par cette opération.

3.4 Filtre de dé-bruitage

Le bruit corrompt l'aspect visuel de la région du nerf, ce qui le rend difficile à détecter. Le filtrage du bruit est une opération essentielle pour améliorer la qualité visuelle et permettre une meilleure analyse de la région du nerf. Une abondante littérature est apparue récemment sur les opérations de dé-bruitages utilisant le filtrage linéaire, filtrage non linéaire, et le filtrage fréquentiel [115, 72, 107, 200, 22, 232, 7, 151, 55]. Dans ce chapitre nous fournissons une comparaison et une évaluation de la performance des 11 filtres de dé-bruitages afin de déterminer quelle méthode est la mieux adaptée au bruit dans une image US de nerf. La table 3.1 résume les techniques de suppression du bruit utilisées dans cette étude. Ces filtres sont présentés plus en détail dans les sous-sections suivantes.

TABLE 3.1 – Les réponses des méthode de dé-bruitages

Méthode de dé-bruitage	Images filtrées	Méthode de dé-bruitage	Images filtrées
Images US originale		Filtre Géométrique (GF) [22]	
Filtre de Lee (FL) [115]		Filtre Homomorphique (HF) [232]	
Filtre d'Index d'Homogénéité (MSIHM) [151]		Filtre de Diffusion Anisotrope (ADF) [200]	
Filtre de Frost (FF) [72]		Filtre Maximum de Vraisemblance Rayleigh (RMLF) [10]	
Filtre Médian (MF) [107]		Filtre d'Ondelette (WavF) Biorthogonal [55]	
Filtre d'Homogénéité Maximale (MHPN) [7]		Filtre de Gabor (GaborF) [48]	

3.4.1 Filtre linéaire

Filtres de Lee, Kuan et Frost

Des techniques populaires de filtrages de bruits utilisent des statistiques locales dans le voisinage d'un pixel, comme les filtres de Lee [115], Frost [72], et Kuan [128]. Le filtre de Frost est un filtre adaptatif basé sur les coefficients de variations. Dans une image, le pixel centre est remplacé par une somme pondérée des valeurs de pixels voisins dans une fenêtre coulissante. Le filtre de Lee est basé sur un modèle de bruit multiplicatif et des statistiques locales afin de préserver les bord dans une image filtrée, où le lissage est appliqué seulement dans les régions avec des variances élevées. Le filtre de Kuan transforme le bruit multiplicatif en un bruit additif sur lequel il applique le critère du minimum de l'erreur quadratique moyenne. Le filtre obtenu est un filtre qui à la même forme que le filtre proposé par Lee, mais avec une fonction de pondération différente. Dans cette étude, seuls les filtres de Frost et Lee ont été étudiés avec un masque de 5×5 . Les filtres basés sur les statistiques locales donnent le même résultat que celui du filtre moyen dans les régions uniformes. De plus ces filtres maintiennent la valeur d'intensité dans les zones de frontière.

Filtre d'index d'homogénéité

Dans ce filtre [180], deux fenêtres sont utilisées. D'une part, la plus grande est consacrée à la définition du voisinage d'un pixel. D'autre part, une sous-fenêtre plus petite se déplaçant dans la fenêtre principale permet l'estimation du niveau d'homogénéité lors de son déplacement. L'homogénéité est mesurée par $C = \sigma^2 / \bar{M}$ où σ^2 et $\bar{M}$ sont, respectivement la variance et la moyenne locale dans la sous-fenêtre. Ensuite, le pixel central est remplacé par la plus petite valeur de C . Dans cette étude, la taille de la fenêtre mobile pour ce filtre est de 5×5 et le nombre d'itérations a été fixé à deux pour chaque image.

Filtre d'homogénéité Maximale

Ce filtre [7] estime aussi l'homogénéité locale. Dans ce filtre nous considérons un voisinage de 5×5 autour de chaque pixel $P_{x,y}$. Ce pixel est remplacé par la valeur d'homogénéité C la plus élevée, L'équation de la réponse de filtre est donnée comme suite :

$$R_{x,y} = \frac{C_{x,y} P_{x,y}}{\sum_{x,y} P_{x,y}} \quad (3.1)$$

Avec

$$\begin{cases} C_{x,y} = 1 & \text{si } (1 - 2\sigma_n)\bar{P} \leq P_{x,y} \leq (1 + 2\sigma_n)\bar{P} \\ C_{x,y} = 0 & \text{sinon} \end{cases}$$

3.4.2 Filtre non-linéaire

Filtre médian

Le filtre médian [107] est une opération non-linéaire qui remplace chaque pixel dans une image par la valeur médiane de son voisinage. Dans ce travail, la taille du voisinage est de 5×5 pixels. Son application a été réitérée deux fois pour réduire efficacement le bruit.

Filtre géométrique

Les filtres géométriques sont basés sur un algorithme itératif non linéaire qui incrémente ou décrément les intensités de voisinages de chaque pixel en fonction de leurs valeurs relatives. Dans ce travail, nous avons étudié le filtre géométrique introduit dans [22]. Ce filtre compare l'intensité du pixel central avec ses huit voisins. Il incrémente ou décrément la valeur du pixel central (y) en utilisant la règle géométrique suivante sur un voisinage vertical de x, y, z :

$$si \left. \begin{array}{l} x \geq y + 2 \\ x > y \leq z \\ z > y \leq x \\ z \geq y + 2 \end{array} \right\} \rightarrow y = y + 1 \quad \text{et} \quad si \left. \begin{array}{l} x \leq y - 2 \\ x < y \geq z \\ z < y \geq x \\ z \leq y - 2 \end{array} \right\} \rightarrow y = y - 1$$

Filtre homomorphique

Un filtre homomorphique est utilisé simultanément pour normaliser la luminosité à travers une image et augmenter le contraste. Le filtrage homomorphe [232] est effectué dans le domaine fréquentiel de l'image logarithmique compressée. La fonction homomorphique $H(\cdot)$ est réalisée en utilisant le filtre passe haut de Butterworth :

$$H(u, v) = \frac{1}{1 + [D(u, v)/D_0]^2} \quad (3.2)$$

Où

$$D(u, v) = [(u - X/2)^2 + (v - Y/2)^2]^{1/2} \quad (3.3)$$

D_0 est la fréquence de coupure du filtre, u, v sont les variables du plan fréquentiel de Fourier de l'image, et X, Y sont la taille de l'image dans l'espace de Fourier. L'inverse de FFT de l'image est ensuite réalisée pour former l'image filtrée $R_{i,j}$. La taille de la fenêtre mobile pour ce filtre dans cette étude est de 5×5 et deux itérations sont appliquées à chaque image..

Filtre de diffusion anisotrope

Le filtre de diffusion est une technique non linéaire efficace, qui réduit à la fois l'effet du bruit et conserve les informations de bord. L'équation de la diffusion anisotrope est définie dans [200] :

$$\frac{\partial I(x, y, t)}{\partial t} = \text{div}[g(|\nabla I(x, y, t)|)\nabla I(x, y, t)] \quad (3.4)$$

Où t est le paramètre du temps, $I(x, y, 0)$ est l'image originale, $\nabla I(x, y, t)$ est le gradient de l'image au moment t et $g(\cdot)$ est la fonction de conductance. Cette fonction doit satisfaire deux critères ; $\lim_{f \rightarrow 0} g(f) = 1$ de sorte que la diffusion soit maximale dans une région uniforme, et $\lim_{f \rightarrow \infty} g(f) = 0$ de sorte que la diffusion soit interrompue à travers les bords. Deux coefficients de diffusion sont proposés dans [200]. Le coefficient de diffusion suggéré dans ce travail est le suivant :

$$g(f) = \frac{1}{1 + (f/k)^2} \quad (3.5)$$

où k est le paramètre de seuil de magnitude du gradient. Il est utilisé pour contrôler le taux de diffusion et en tant que seuil pour établir la distinction entre les gradients d'image des bords et ceux du bruit. Dans le cas discret, l'équation de diffusion anisotrope donné en 3.4 est définie comme suit :

$$\begin{aligned} \frac{\partial I(x, y, t)}{\partial t} = & \frac{\lambda}{|\eta_s|} (d_{x+1, y, t} [I_{x+1, y} - I_{x, y}] + d_{x-1, y, t} [I_{x-1, y} - I_{x, y}] \\ & + d_{x, y+1, t} [I_{x, y+1} - I_{x, y}] + d_{x, y-1, t} [I_{x, y-1} - I_{x, y}]) \end{aligned} \quad (3.6)$$

où $d_{x+1, y, t}$, $d_{x-1, y, t}$, $d_{x, y+1, t}$ et $d_{x, y-1, t}$ sont les coefficients de diffusion respectivement, pour la gauche, droite, haut, et le bas de la direction des pixels. La constante $0 < \lambda < 1/4$ détermine le taux de diffusion, et $|\eta_s|$ désigne le nombre de voisinage. La réponse de l'image filtrée est donnée par une équation linéaire de diffusion isotrope :

$$R_{x, y} = I_{x, y} + \frac{\partial I(x, y, t)}{\partial t} \quad (3.7)$$

Les paramètres du filtre de diffusion anisotrope utilisés dans cette étude est $\lambda = 0.20$, $\eta = 8$ et $K = 30$.

Filtre maximum de vraisemblance de Rayleigh

Dans [10], les auteurs ont d'abord obtenu les observations statistiques de Rayleigh et ils ont utilisé l'approche robuste du maximum de vraisemblance pour estimer les informations souhaitées.

3.4.3 Filtre fréquentiel

Filtre d'ondelettes

La réduction du bruit dans le domaine des ondelettes est basée sur différentes familles d'ondelettes [55]. Le choix d'une famille d'ondelettes dépend du type d'applications et d'informations à extraire, et affecte les performances d'extraction de caractéristiques et de classifications. Dans cette étude, nous avons étudié quatre familles d'ondelettes : biorthogonale, Daubechie, Haar et Symmlet. Le processus de filtrage mis en œuvre dans cette étude est basé sur quatre étapes, qui sont : (1) calculer la variance de bruit σ_n^2 à partir de la transformée logarithmique de l'image avec

l'équation suivante : $\sigma_n^2 = \sum_{i=1}^p \frac{\sigma_p^2}{\bar{g}_p}$ où σ_p^2 et $\bar{g}_p$ sont la variance et la moyenne de l'image dans la fenêtre sélectionnée, et p est l'index de la fenêtre courante dans l'image, (2) calculer la transformée discrète d'ondelette (TDO) pour quatre échelles, (3) appliquer le seuillage des coefficients de détail pour chaque sous-bande, et finalement (4) inverser la décomposition TDO pour générer l'image filtrée.

Filtre de Gabor

Le filtre Gabor est un filtre qui peut maintenir une fréquence spatiale spécifique liée à des motifs de texture avec une orientation et une échelle spécifique, en modulant une enveloppe gaussienne avec une fonction sinusoïdale. La fonction du noyau utilisée pour ce filtre dans cette étude est exprimée par l'équation suivante :

$$g(x, y) = \exp\left[-\frac{1}{2}\left(\frac{x'^2}{\sigma_x^2} + \frac{y'^2}{\sigma_y^2}\right)\right] \cos(2\pi f x') \quad (3.8)$$

où $x' = x \cos \phi + y \sin \phi$, $y' = -x \sin \phi + y \cos \phi$, ϕ est le filtre de direction, σ est l'écart type de l'enveloppe gaussienne et f est la fréquence de l'onde sinusoïdale. Dans cette étude nous utilisons la magnitude du filtre de gabor comme réponse du filtrage de bruit, qui est $f(x, y) = |I(x, y) * g(x, y)|$. Les valeurs des paramètres suivantes $\sigma = 13$, $\phi = \pi/2$ et $f = 1$ ont été utilisées pour obtenir les meilleurs résultats.

3.4.4 Autres Filtres

Au cours des dernières années, de nombreuses méthodes basées sur les techniques de filtrage ont été proposées pour les images US. Dans [53], une nouvelle méthode pour réduire le bruit dans les images US a été proposée. Cette approche est basée sur l'hypothèse d'une distribution de Rayleigh de bruit. Un filtre Rayleigh est d'abord appliqué pour supprimer le bruit primaire. Ensuite, la diffusion anisotrope est appliquée pour réduire davantage de bruit, tout en améliorant l'aspect visuel des structures dans l'image originale. Dans [87], une carte d'homogénéité a été générée selon les statistiques locales d'une fenêtre choisie pour chaque pixel de l'image afin de réduire le bruit dans une image US. Dans [47], les auteurs ont proposé une banque de filtres de Gabor, en mélangeant les réponses de filtre. Le bruit a été réduit et l'information des frontières a été renforcée.

3.5 Extraction des caractéristiques

L'extraction des caractéristiques est l'une des étapes essentielles pour détecter le nerf dans une image US. Cette étape consiste à extraire des informations significatives à partir des ROIs. Cette section commence par une description des six techniques statistiques qui ont été étudiées. Cette description est suivie par une présentation de plusieurs méthodes utilisées à base de motif local binaire ainsi que de la méthode fractale.

3.5.1 Méthodes statistiques

Les méthodes statistiques analysent d'abord la distribution spatiale des caractéristiques locales présentes dans des régions d'intérêts et extraient ensuite un ensemble de données statistiques issues de ces distributions. La Table 3.2 présente pour chaque méthode les caractéristiques extraites pour décrire les propriétés de la texture.

TABLE 3.2 – Les méthode d'extractions de caractéristiques

Méthode	Caractéristiques
Statistiques du Premier Ordre (FOS)	Moyenne, médian, variance, skewness, kurtosis et indice de bruit.
Différence Statistique de Niveau de Gris (GLDS) [255]	Entropie, contraste, moyenne et second moment angulaire.
Matrice de Différence de Voisinage Niveau de Gris (NGTDM) [8]	Rudesse, contraste, busyness, complexité et force
Matrice de dépendances spatiales de niveaux de gris (SGLDM) [100]	Second moment angulaire, contraste, corrélation, somme des carrés, variance, moment de différence inverse, somme moyenne, somme variance, somme entropie, entropie, différence de variance et mesures d'information de corrélation
Matrice de Caractéristique Statistique (SFM) [35]	Rudesse, contraste, périodicité et rugosité
Loi des Mesures de l'Énergies de la Texture (TEM) [222]	énergie de la texture calculé à partir du noyaux LL , EE , SS , LE , ES et LS .

Statistiques de premier ordre

Supposons que I est une variable aléatoire représentant les intensités d'une ROI dans une image. Sur la base d'un histogramme de premier ordre $P(I)$, la moyenne m_1 et le moment centré μ_k de I sont données par :

$$m_1 = E[I^1] = \sum_{I=0}^{N_g-1} I^1 P(I), \quad (3.9)$$

et

$$\mu_k = E[(I - E[I])^k] = \sum_{I=0}^{N_g-1} (I - m_1)^k P(I), \quad (3.10)$$

où N_g est le nombre des valeurs de niveau de gris possibles. Les moments centrés utilisés comme caractéristiques dans cette méthode sont :

- Moyenne de l'histogramme (m_1).
- Médian de l'histogramme $P(I)$ (m_1).

- Variance de l'histogramme $P(I)$ (μ_2).
- Skweness mesure le degré d'asymétrie de l'histogramme $P(I)$ autour de la moyenne ($\mu_3/(\mu_2)^{3/2}$).
- Kurtosis mesure l'aspect de l'histogramme $P(I)$ (μ_4/μ_2^2).
- Indice de bruit de l'histogramme $P(I)$ (μ_2/m_1).

Différence statistique de niveau de gris

Soit $I(x, y)$ la désignation du niveau de gris d'un pixel (x, y) présent dans une image, pour tout déplacement donné $\delta = (\Delta x, \Delta y)$, la dissemblance est définie par :

$$I_\delta(x, y) = |I(x, y) - I(x + \Delta x, y + \Delta y)|, \quad (3.11)$$

Finalement la densité de probabilité (p_δ) calcule le nombre de répétition des valeurs de $I_\delta(x, y)$, où $p_\delta(i)$ représente la probabilité d'une valeur i dans $I_\delta(x, y)$, où p_δ est une matrice à n éléments. Les caractéristiques obtenues ont été calculées pour les déplacements $\delta = (0, 1), (1, 1), (1, 0), (1, -1)$.

Ces caractéristiques sont :

- le contraste représente le second moment de p_δ ($\sum_{i=1}^n i^2 p_\delta(i)$).
- le second moment angulaire représente la concentration des valeurs dans une région, par exemple la second moment angulaire est petit lorsque les valeurs de $p_\delta(i)$ sont presque égaux ($\sum_{i=1}^n p_\delta(i)^2$).
- l'entropie a une grande valeur lorsque $p_\delta(i)$ sont presque égaux ($-\sum_{i=1}^n p_\delta(i) \log(p_\delta(i))$).
- la moyenne ($(1/m) \sum_{i=1}^n i^2 p_\delta(i)$) où m est le nombre de niveau de gris dans I .

Matrice de différences de niveaux de gris dans un voisinage

Cette matrice est basée sur la différence entre la valeur du niveau de gris d'un pixel et de la moyenne de son voisinage. Soit $I(x, y)$ la valeur d'intensité d'une image dans une position (x, y) . L'intensité moyenne dans une fenêtre centrée au point (x, y) est donnée par :

$$f_i = f(x, y) = \frac{1}{W-1} \sum_{m=-K}^K \sum_{n=-K}^K I(x+m, y+n), \quad (3.12)$$

où K est la taille d'une fenêtre et $W = (2K+1)^2$. Dans cette étude $K = 4$. L' i^{me} élément de cette matrice est calculé par :

$$s(i) = \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} |i - f_i|, \quad (3.13)$$

Différentes caractéristiques ont été dérivées de la matrice s de n éléments :

- La rudesse est définie par les primitive de la texture (coarseness= $(\epsilon + \sum_{i=1}^n p_i s(i))^{-1}$), où ϵ permet d'éviter des valeurs de coarseness infini, p_i est la probabilité estimée de l'occurrence d'une intensité i .
- Le contraste, qui est dépendant de la différence d'intensité entre les pixels voisins ($\frac{1}{N_t(N_t-1)} \sum_{i=1}^n \sum_{j=1}^n p_i p_j (i-j)^2 \frac{1}{n} \sum_{i=1}^n s(i)$), où n est le nombre total des pixel dans une fenêtre et N_t est le nombre total des différents niveau de gris présents dans une image.

- Busyness est décrite par la fréquence spatiale des changements d'intensité ($\frac{\sum_{i=1}^n \sum_{j=1}^n p_i s(i)}{\sum_{i=1}^n \sum_{j=1}^n |ip_i - jp_j|}$).
- La complexité dépend du nombre de différentes primitives et moyennes d'intensités ($\sum_{i=1}^n \sum_{j=1}^n \frac{|i-j|}{n^2(p_i+p_j)} [p_i s(i) + p_j s(j)]$).
- Force de la texture est définie par la clarté et la visibilité de la texture ($\frac{\sum_{i=1}^n \sum_{j=1}^n (p_i+p_j)(i-j)^2}{\epsilon + \sum_{i=1}^n s(i)}$).

Matrice de dépendances spatiales de niveaux de gris

Cette méthode mesure le second ordre des caractéristiques de la texture $p(i, j) = g(i, j, d, \theta)$, où chaque élément de la matrice $p(i, j)$ représente la probabilité d'occurrence du niveau d'intensité avec une certaine distance d et angle θ . Dans ce travail $d = 4$ et $\theta = (0^\circ, 45^\circ, 90^\circ, 135^\circ)$. Les formules utilisées pour les caractéristiques de la matrice de dépendance spatiale de niveaux de gris sont :

- Contraste, représente le moment d'inertie de la matrice autour de sa diagonale ($\sum_i \sum_j (i - j)^2 p(i, j)$).
- Second moment angulaire a une valeur petit lorsque les valeurs de $p(i, j)$ sont presque égaux ($\sum_i \sum_j p(i, j)^2$).
- Entropie de la matrice $p(i, j)$ ($-\sum_i \sum_j p(i, j) \log p(i, j)$).
- Corrélation mesure le degré de ressemblance de lignes ou de colonnes de la matrice $p(i, j)$ ($\sum_i \sum_j \frac{ijp(i, j) - \mu_x \mu_y}{\sigma_x \sigma_y}$), où μ_x et σ_y sont la moyenne et la écart type des sommes de la lignes de la matrice $p(i, j)$.

Dans notre travail, nous avons utilisé d'autre caractéristiques dérivées de ceux qui ont été listées, comme la somme des carrés, le moment de différence inverse, la somme moyenne, la somme variance, la somme entropie, la différence de variance, et la mesure d'information de corrélation.

Matrice de caractéristiques statistiques

Cette méthode calcule les statistique de second ordre selon un vecteur de distance $\delta = (\Delta x, \Delta y)$ sur l'axe x et y (dans cette étude, nous avons choisi la distance 3). La plupart des caractéristiques des statistiques de second ordre sont le contrats, la covariance et la dissimilarité calculées à partir des équations suivantes : δ -contrats ($Con = E\{[I(x, y) - I(x + \Delta x, y + \Delta y)]^2\}$), δ -covariance ($COV = E\{[I(x, y) - \eta][I(x + \Delta x, y + \Delta y) - \eta]\}$) et δ -dissimilarité ($DSS = E\{|I(x, y) - I(x + \Delta x, y + \Delta y) - \eta|\}$), où $I(x, y)$ est l'intensité d'un pixel à la position (x, y) , $E\{.\}$ représente l'espérance et η est la moyenne du niveau de gris de I . À partir de δ -contraste, δ -covariance et δ -dissimilarité, des caractéristiques de texture comme la rudesse, le contraste, la périodicité et la rugosité sont calculées comme suite :

- La rudesse permet d'exprimer la différence entre le niveau de gris d'un pixel et son voisinage ($c * n / \sum_{(i, j) \in N_r} DSS(i, j)$), où c est un facteur de normalisation, n est le nombre d'élément et N_r est l'ensemble des éléments du vecteur de déplacement δ .

- Le contraste mesure la netteté des frontières $([\sum_{(i,j) \in N_r} CON(i,j)/4]^{1/2})$.
- La périodicité permet d'évaluer la matrice de dissimilarité d'une image $((\bar{DSS} - DSS(vallee))/\bar{DSS})$, où $\bar{DSS}$ est la moyenne de tout les éléments de la matrice DSS et $DSS(vallee)$ représente la vallée la plus profonde de la matrice DSS .
- La rugosité mesure la dimension fractale $((D_f^{(h)} + D_f^{(v)})/2)$, où $D_f^{(h)}$ et $D_f^{(v)}$ sont les dimensions horizontal et vertical estimées. D_f est obtenue de l'équation $D_f = 3 - H$, où H est estimé à partir de l'équation $E|\Delta I| = C||\delta||^H$ avec C comme constante.

Loi des mesures de l'énergie de la texture

Cette approche consiste à mesurer la quantité de variations dans un voisinage d'un pixel. Tout d'abord, un ensemble de masques de convolution est utilisé pour calculer l'énergie de la texture. Les masques sont calculés à partir des noyaux de convolutions d'une seule dimension : $L_5 = [1 \ 4 \ 6 \ 4 \ 1]$, $E_5 = [-1 \ -2 \ 0 \ 2 \ 1]$, $S_5 = [-1 \ 0 \ 2 \ 0 \ -1]$, $W_5 = [-1 \ 2 \ 0 \ -2 \ 1]$ et $R_5 = [1 \ -4 \ 6 \ -4 \ 1]$. Chaque noyau détecte des caractéristiques spécifiques. L_5 fournit la moyenne du niveau de gris, E_5 extrait les caractéristiques de bords, S_5 détecte les motifs répétitif, W_5 détecte les ondes et R_5 détecte des ondulations. La convolution entre ces noyaux (vertical noyau avec un horizontal noyau) génère un noyau de convolution à deux dimensions. Par exemple, le noyau LL est calculé à partir de $L^T \times L$. Dans ce travail 6 noyaux ont été appliqués (LL , EE , SS , LE , ES , LS) sur une image. Puis le résultat de cette convolution est utilisée pour calculer l'énergie de la texture.

3.5.2 Famille de Motif Local Binaire

Pour étudier la performance de la famille des descripteurs basés Motif Local Binaire (LBP), quatre méthodes basées LBP ont été étudiées : (1) LBP, (2) *Shifted* LBP (SLBP), (3) Motif Médian Binaire (MBP) et (4) Adaptative MBP (AMBP). Les méthodes de famille LBP utilise un voisinage circulaire autour de chaque pixel avec un rayon R et N points autour d'un pixel τ . Ces descripteurs utilisent une interpolation bilinéaire pour calculer les valeurs g_p dans un schéma circulaire. Il est définie par l'équation suivante :

$$L_{N,R}(x, y) = \sum_{p=0}^{N-1} s(g_p - \tau) 2^p \quad (3.14)$$

où

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & \text{sinon} \end{cases}$$

et τ représente le pixel central pour LBP, la médiane pour MBP etc.

Motif local binaire

LBP est un descripteur très populaire pour l'analyse de la texture en raison de sa simplicité et de sa grande performance [191]. LBP utilise un pixel central $\tau = g_c$ pour calculer le voisinage.

Dans ce travail, $R = 2$ et $N = 16$ obtiennent le meilleur score.

Motif local binaire décalé

SLBP [201] est similaire à LBP sur deux aspects, il intègre le paramètre k dans l'équation de seuillage (i.e. $(g_p - \tau - k)$), où k varie dans un intervalle défini par une limite d'intensité l . Contrairement à LBP, SLBP peut générer différents motifs binaires en fonction de la valeur donnée à k . Chaque code de motif est ajouté à l'histogramme des motifs binaires. Le nombre de motifs générés, K , pour une seule position d'un pixel est égale à $2l + 1$. Une valeur de $k = 3$ a été utilisé dans cette étude.

Motif médian binaire

AMBP [95] utilise la même stratégie que LBP. Cependant la valeur médiane d'un voisinage est utilisée au lieu du centre de ce voisinage ($\tau = g_{med}$, où $g_{med} = median(g_0, ..., g_{N-1}, g_c)$). La fonction s est définie comme dans LBP. Les paramètres optimaux sont $R = 1$ et $N = 8$.

Adaptative motif médian binaire

AMBP [94] utilise le principe du filtrage de la moyenne adaptative pour préserver les détails de l'image. Atout non négligeable lorsque l'on fait varier la taille de la fenêtre locale générant dans ce cas une augmentation du niveau du bruit. AMBP modifie de manière adaptative la taille de la fenêtre d'analyse afin d'obtenir un meilleur seuil en fonction du contexte local. De plus, AMBP peut choisir entre le pixel central ou la médiane comme valeur de seuillage. Dans le premier cas AMBP donne LBP alors que dans le second cas on obtient MBP. En fait, l'histogramme d'AMBP peut combiner LBP et MBP en fonction des structures et des bruits locaux.

Autres familles de LBP

Au cours de ces dernières années, de nombreuses méthodes basées LBP ont été proposées pour représenter les informations d'une texture donnée. Cependant, très peu de ces descripteurs ont été utilisés pour représenter les régions dans une image US. Dans ce contexte, nous avons étudié les méthodes basées LBP les plus connues. D'une part, LBP, SLBP, MBP et AMBP ont été détaillés dans les sections précédentes. D'une autre part, pour compléter l'investigation sur les descripteurs appartenant à la famille LBP, nous avons évalué d'autres méthodes comme : LBP Complet (CLBP) [90], Quantification de Phase Local (LPQ) [192], Histogramme de Fourier LBP (HFLBP) [6] et Motif de Configuration Local (LCP) [89].

3.5.3 Fractal

Dans [161], les auteurs ont proposé le modèle de mouvement Brownien fractionnaire pour décrire la rugosité de la texture dans une image. La dimension fractale D_f a été estimée par l'équation suivante :

$$E(\delta I^2) = c(\delta r)^{6-2D_f} \quad (3.15)$$

où $E(.)$ désigne l'opérateur d'espérance, $\delta I = I(x_2, y_2) - I(x_1, y_1)$ représente la variation d'intensité, c est considéré comme une constante et $\delta r = \|(x_2, y_2) - (x_1, y_1)\|$ est une distance spatiale. Dans [258], les auteurs ont proposé une méthode pour estimer le paramètre H et la dimension fractale peut être facilement calculé à partir de l'équation suivante :

$$D_f = 3 - H \quad (3.16)$$

La dimension fractale D_f indique la rugosité d'une surface; pour les surfaces lisses D_f affiche de petites valeurs.

3.6 Sélection des caractéristiques

Cette section présente brièvement quelques méthodes bien connues utilisées pour la sélection des caractéristiques. Ces méthodes aident l'extraction des informations essentielles à partir d'un ensemble de données contribuant à la fois à l'amélioration des performances de classification et à la réduction du temps de calcul.

Dans cette étude, les techniques de sélection des caractéristiques ont été classées en deux groupes : le premier est basé sur les modèles de filtre et le second est basé sur l'apprentissage.

Les méthodes de sélection à base de filtres sont meilleures en terme de temps de calcul et mieux adaptées à des ensembles de données de grandes dimensions, mais en général, ils sont moins performants que les méthodes à base d'apprentissage.

Les méthodes de sélection à base d'apprentissage fournissent de meilleurs résultats, en raison de l'optimisation de la sélection des caractéristiques pour un classificateur spécifique [123]. L'inconvénient majeur de ces méthodes est leur coût de calcul, en particulier pour les grands ensembles de données, du fait que chaque sous ensemble des caractéristiques doit être évalué, ce qui ralentit le processus de sélection. Récemment, une autre méthode de sélection appelée hybride a été utilisée. Cette méthode est basée sur les avantages des deux méthodes (filtre et apprentissage). Les auteurs dans [42] ont proposé une méthode hybride dans le contexte de la prédiction de série temporelle; ils ont défini un filtre neuronal itératif pour l'évaluation des caractéristiques, qui a été ensuite incorporée dans une série d'apprentissage pour la construction et la transformation des caractéristiques.

Dans [18], les auteurs ont proposé une méthode à deux étapes ; dans la première étape *BW ratio* [58] a été utilisé comme une méthode de sélection à base de filtre pour le classement individuel des caractéristiques, ensuite dans la deuxième étape l'analyse discriminante linéaire et un algorithme génétique ont été utilisés comme une méthode de sélection à base d'apprentissage.

3.6.1 Méthodes à base des filtres

Ces méthode agissent comme un pré-traitement pour ranger les caractéristiques afin de sélectionner que les meilleurs d'entre eux. Les méthodes de sélections à base de filtres sont rapides et simples à implémenter. Cependant, le principal inconvénient est qu'ils ne prennent pas en considération l'évaluation du classificateur. Ces méthodes peuvent être catégorisées en deux groupes : (1) sélection à base des caractéristiques pondérées et (2) sélection à base d'un algorithme de recherche.

Méthode de pondération de caractéristiques

Ces méthodes pèsent chaque caractéristique et les classe en fonction de leurs pertinences [268]. Les algorithmes à base de pondération de caractéristiques les plus utilisés sont présentés dans Table 3.3.

TABLE 3.3 – Méthodes de sélections à base des filtres

Algorithme de pondération des caractéristiques	Algorithme de recherche d'ensembles de caractéristiques
Score de Fisher [57]	Sélection des caractéristiques basées corrélation [149]
Indice de Gini [84]	
Gain d'information [40]	Minimum redondance maximum pertinence [197]
Kruskal-Wallis [254]	
ReliefF [144]	Corrélation rapide basée filtre [268]
Score de t-test [178]	
Score de Chi-carré [145]	

Score de Fisher : Cet indice donne une mesure des caractéristiques capable de distinguer entre différentes classes d'échantillons. Soit C une classe (ensemble), le score de Fisher d'une caractéristique f peut être formulée comme :

$$fs(f_i) = \frac{\sum_{j=1}^c n_j (\mu_{i,j} - \mu_i)^2}{\sum_{j=1}^c n_j \sigma_{i,j}^2} \quad (3.17)$$

où μ_i est la moyenne des valeurs d'échantillonnage d'une caractéristique f_i , n_j est le nombre d'échantillons dans la classe j^{th} , $\mu_{i,j}$ et $\sigma_{i,j}$ sont respectivement la moyenne et la variance de f_i .

Indice de Gini : L'indice de Gini est une mesure de quantification de capacité d'une caractéristique de faire la distinction entre des classes d'échantillons. Soit une classe C , l'indice de Gini d'une caractéristique f peut être calculé comme :

$$GI(f) = 1 - \sum_{i=1} C p(i/f)^2 \quad (3.18)$$

Les principales caractéristiques sont sélectionnées selon le plus petit indice de Gini.

Gain d'information : Le gain d'information évalue la dépendance entre les caractéristiques et les classes étiquetées. Soit une caractéristique X et la classe Y , le gain d'information est exprimé en :

$$IG(X, Y) = H(X) - H(X/Y), \quad (3.19)$$

où

$$H(X) = - \sum_i P(x_i) \log_2(P(x_i)), \quad (3.20)$$

$$H(X/Y) = - \sum_j P(y_j) \sum_i P(x_i/y_j) \log_2(P(x_i/y_j)) \quad (3.21)$$

$H(X)$ et $H(X/Y)$ sont respectivement, l'entropie de X , et l'entropie de X après l'observation Y . Un gain d'information élevé exprime la pertinence d'une caractéristique donnée.

Kruskal-Wallis : L'algorithme Kruskal-Wallis est basé sur les rangs pour comparer la popularité des médianes de caractéristiques parmi différentes classes. Il retourne une valeur ρ pour l'hypothèse nulle que tous les échantillons appartiennent à la même population. Si $\rho \simeq 0$ alors l'indice de caractéristique est sélectionné.

ReliefF : Supposons que p est le nombre d'échantillons, le critère d'évaluation de l'algorithme de ReliefF est défini comme :

$$rf(f_i) = \frac{1}{2} \sum_{t=1}^p d(f_i(x_t) - f_i^{NM}(x_t)) - d(f_i(x_t) - f_i^{NH}(x_t)), \quad (3.22)$$

où $f_i(x_t)$ représente la valeur de l'instance x_t de caractéristique f_i , $f_i^{NH}(x_t)$ et $f_i^{NM}(x_t)$ désignent la valeur de la i^{eme} caractéristique du plus proche point de x_t , respectivement avec la même et différente classe étiquetée, et $d(\cdot)$ est une mesure de distance euclidienne.

Score de t-test : L'approche de t-test mesure la signification statistique entre la moyenne de deux classes. T-test calcule le ratio entre la différence de moyennes et de variances de deux classes.

Score de Chi-carré : Chi-carré est utilisé comme un test pour mesurer l'indépendance entre une caractéristique particulière et une classe étiquetée. Soit r le nombre de caractéristiques et C

le nombre de classe, le score Chi-carré peut être formulé comme suit :

$$X^2 = \sum_{i=1}^r \sum_{j=1}^C \frac{(n_{ij} - \mu_{ij})^2}{\mu_{ij}}, \quad (3.23)$$

où $\mu_{ij} = \frac{n_{*j}n_{i*}}{n}$, n_{i*} est le nombre de l'échantillon de la i^{eme} valeur d'une caractéristique particulière, n_{*j} est le nombre d'échantillons dans une classe j et n est le nombre totale d'échantillons.

Méthodes de recherche de sous-ensembles de caractéristiques

Le but d'un algorithme de recherche de sous-ensembles [268] est d'extraire les meilleurs sous-ensembles de caractéristiques qui ont des propriétés élevée de discrimination. Cet algorithme utilise une mesure d'évaluation pour capturer la qualité de chaque sous-ensemble. Les algorithmes de recherche de sous-ensembles les plus utilisés pour la sélection des caractéristiques sont les suivants.

Sélection des caractéristiques basée sur la corrélation : Cet algorithme classifie un sous-ensemble de caractéristiques en utilisant la fonction de corrélation basée sur l'évaluation heuristique :

$$H = \frac{k\bar{r}_{cf}}{\sqrt{k + k(k-1)\bar{r}_{ff}}}, \quad (3.24)$$

où H est l'heuristique d'un sous-ensemble de caractéristique S contenant k caractéristiques, $\bar{r}_{cf}$ désigne la moyenne de corrélation entre une caractéristique et une classe, et $\bar{r}_{ff}$ désigne la moyenne d'inter-corrélation entre caractéristiques. D'une part, la corrélation $\bar{r}_{cf}$ est une indication de la facilité de prédiction d'une classe à partir des caractéristiques. D'autre part, la corrélation $\bar{r}_{ff}$ inter-caractéristiques mesure le niveau de redondance entre elles. L'algorithme à base de corrélation pour la sélection des caractéristiques estime la pertinence des caractéristiques en considérant la capacité de prédiction et le degré de corrélation.

Corrélation rapide basée filtre : L'algorithme de corrélation rapide à base de filtres pour la sélection des caractéristiques est utilisé pour sélectionner les caractéristiques en se basant sur la corrélation entre deux variables aléatoires. Il existe deux approches de mesure de corrélation. L'une est basée sur la corrélation linéaire et l'autre est basée sur la théorie de l'information. Dans cette étude nous optons pour la mesure de corrélation basée sur la théorie de l'information. Cet algorithme trouve un ensemble de caractéristiques les plus prédominant f_{best} . Cette méthode comprend deux étapes essentielles. La première calcule l'incertitude symétrique (SU) en tant que mesure d'efficacité de chaque caractéristique, SU est définie comme suit :

$$SU(X, Y) = 2\left[\frac{IG(X/Y)}{H(X) + H(Y)}\right], \quad (3.25)$$

où $IG(X/Y)$, $H(X)$ et $H(X/Y)$ sont définis dans l'Eq. 3.20 et Eq. 3.21. Ensuite, il sélectionne les caractéristiques pertinentes à l'aide d'un seuil prédéfini δ , et les classe selon la valeur de SU .

Dans la deuxième étape, il garde les plus prédominantes parmi tous les caractéristiques pertinentes sélectionnées (i.e. une caractéristique f_i est appelée prédominante pour la classe c si $SU_{i,c} \geq \delta$). Cependant, s'il existe une caractéristique f_j telle que $SU_{j,i} \geq SU_{i,c}$, alors f_j sera considérée comme un élément redondant de f_i . Puis, cet ensemble de caractéristiques redondantes sera désigné comme $S_{\bar{p}_i}$, qui sera encore divisé en $S_{\bar{p}_i}^+$ et $S_{\bar{p}_i}^-$ contenant les caractéristiques redondantes à f_i respectivement avec $SU_{j,c} > SU_{i,c}$ et $SU_{j,c} \leq SU_{i,c}$. Finalement, l'algorithme applique trois heuristiques sur S_{p_i} , $S_{\bar{p}_i}^-$, et $S_{\bar{p}_i}^+$ pour supprimer les caractéristiques redondantes et garder les plus pertinentes pour une classe donnée.

Minimum redondance maximum pertinence (MRMR) : MRMR sélectionne les caractéristiques qui présentent une grande différence d'information mutuelle. L'information mutuelle entre deux variables x et y est définie comme :

$$I(x; y) = \int \int p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy, \quad (3.26)$$

où $p(x)$ et $p(y)$ sont les fonctions de densités de probabilités marginales des variables x et y , et $p(x, y)$ est leur distribution de probabilité conjointe. $I(x; y) = 0$, signifie que x et y sont statistiquement indépendants. La méthode multivariée de MRMR vise à optimiser deux critères simultanément :

1. Le critère de pertinence maximale D tout d'abord, obtenu en maximisant la moyenne de l'information mutuelle $I(x_i; y)$ entre chaque caractéristique x_i et le vecteur cible y .
2. le critère de redondance minimum R ensuite, obtenu en minimisant cette fois la moyenne d'information mutuelle $I(x_i; x_j)$ entre deux caractéristiques.

Étant donné un ensemble de caractéristiques S_k de k , une caractéristique est sélectionnée en maximisant les critères $D - R$:

$$\max_{x_i \in X - S_k} [I(x_i; y) - \frac{1}{k} \sum_{x_j \in S_k} I(x_i; x_j)] \quad (3.27)$$

3.6.2 Méthodes à base d'apprentissage

Les méthodes de sélection des caractéristiques à base d'apprentissage tiennent compte de la performance d'un prédicteur, à savoir le retour de prédicteur est incorporé dans un algorithme de recherche pour obtenir le sous-ensemble de caractéristiques optimal. Ce sous-ensemble est celui qui produit le rendement prédictif le plus élevé. Bien que ces méthodes comprennent l'intersection entre la recherche de sous-ensemble de caractéristiques, la sélection du modèle et les dépendance des caractéristiques, ils ont un risque plus élevé à la fois de sur-apprentissage et de temps de calcul par rapport aux techniques de sélection de caractéristiques à base des filtres Dans cette étude, nous avons investigué les algorithmes à base d'apprentissages les plus utilisés (voire Table 3.4).

TABLE 3.4 – Sélection des caractéristiques à base d'apprentissage

Algorithmes basés apprentissage
La régression logistique multinomiale [25]
Sélection séquentielle vers l'avant [163]
Sélection séquentielle vers l'arrière [162]

La régression logistique multinomiale (SMLR) : L'algorithme SMLR effectue un apprentissage d'un classificateur multi-classe en se basant sur une régression logistique multinomiale. Soit un modèle de régression définie comme suit :

$$M = E_D + \lambda E_\alpha, \quad (3.28)$$

où $E_\alpha = \sum_{i=1}^k \sum_{j=1}^d |\alpha_{i,j}|$, $E_D = \sum_{i=1}^l \log 1 + \exp(-y_i + f(x_i))$, $f(x_i)$ est la régression linéaire donnée par $\sum_{j=1}^d \alpha_j x_{ij} + \alpha_0$, α est le paramètre du modèle de régression logistique et d est la dimensionnalité de la base de données. SMLR minimise l'équation 3.28 par rapport au paramètre du modèle α comme suit :

$$\begin{aligned} \left| \frac{\partial E_D}{\partial \alpha_{i,j}} \right| &= \lambda & \text{si } |\alpha_{i,j}| > 0 \\ \left| \frac{\partial E_D}{\partial \alpha_{i,j}} \right| &< \lambda & \text{si } |\alpha_{i,j}| = 0 \end{aligned} \quad (3.29)$$

$\alpha_{i,j} < \lambda$, signifie que la caractéristique correspondante sera exclue, étant donné que le paramètre est égal à zéro. Notez que nous avons utilisé que la première et deuxième dérivées partielles de E_D par rapport à $\alpha_{i,j}$:

$$\left| \frac{\partial E_D}{\partial \alpha_{i,j}} \right| = \sum_{n=1}^l y_i^n x_j^n - \sum_{n=1}^l t_i^n x_j^n, \quad (3.30)$$

$$\left| \frac{\partial^2 E_D}{\partial \alpha_{i,j}} \right| = \sum_{n=1}^l y_i^n (1 - y_i^n) [x_j^n]^2. \quad (3.31)$$

où y_i^n est la probabilité de $w^n \in t_i$. RLM adopte un algorithme d'apprentissage simplifié à base de composantes [25], ce qui évite l'utilisation de la matrice de Hessian pour la phase d'apprentissage.

Sélection séquentielle vers l'avant (SFS) : L'algorithme SFS est plus performant lorsque le sous-ensemble de caractéristiques optimal a un petit nombre de caractéristiques. Le principal inconvénient de cet algorithme est l'incapacité de supprimer les caractéristiques qui deviennent obsolètes après l'ajout de nouvelles caractéristiques.

Sélection séquentielle vers l'arrière (SBE) : Contrairement à l'algorithme SFS, SBE est meilleur quand le sous-ensemble de caractéristiques optimal a un grand nombre de caractéristiques. Similaire au SFS, le principal inconvénient est l'incapacité d'évaluer la pertinence des caractéristiques ajoutées après la sélection du sous-ensemble optimal.

3.7 Localisation et segmentation

Les propriétés visuelles des tissus nerveux dans les images échographiques peuvent varier d'un patient à un autre. De plus, la position de la sonde peut affecter considérablement ces propriétés. Pour faire face à une telle situation, nous utilisons plusieurs modèles d'apprentissage. Comme illustré dans la Figure 3.4, plusieurs images US ont été utilisées comme un ensemble d'apprentissage $\{N_1, \dots, N_m\}$, afin de représenter différents aspects du nerf médian. Pour détecter le nerf, le modèle




FIGURE 3.4 – Schéma de classification et de segmentation

SVM a été utilisé pour comparer les fenêtres coulissantes dans l'image en entrée (test) et les m modèles. Nous avons calculé la distance entre un échantillon x_i et l'hyperplan SVM pour chaque modèle de SVM. L'échantillon avec la plus grande distance de l'hyperplan du modèle est attribué au degré de confiance le plus élevé. La procédure de classification génère m positions de régions candidates pour chaque nerf. À partir de ces positions, nous ne gardons que les régions où le degré de confiance est le plus élevé comme le montre la Figure 3.4. La segmentation du nerf a besoin d'une autre étape pour obtenir les frontières du nerf. C'est pourquoi nous utilisons une méthode de contour actif probabiliste (PGVF) pour segmenter le nerf [96], car il fournit de meilleurs résultats pour la segmentation du nerf par rapport aux méthodes classiques à base de modèles déformables, où la zone de la délimitation de l'étape de localisation est utilisée comme un contour initial. Cette méthode utilise le contour actif paramétrique avec une fonction de l'énergie basée sur le GVF [264] modifiée. Le contour actif est composé de forces interne et externe pour manipuler l'évaluation de

la courbe $\mathbf{x}(c) = [x(c), y(c)]$, $c \in [0, 1]$ avec l'équation de *snack* bien connue [120].

$$E_{AC} = \frac{1}{2} \int_0^1 \alpha |\mathbf{x}'(c)|^2 + \beta |\mathbf{x}''(c)|^2 ds + \int_0^1 \varepsilon(\mathbf{x}(c)) ds \quad (3.32)$$

où α et β sont des paramètres de pondération. Le premier terme est appelé l'énergie interne et il contrôle la régularité de la courbe x , tandis que le seconde terme, appelé énergie externe, attire la courbe x vers les bords de l'objet. Le GVF utilise le processus de diffusion pour obtenir la force externe. Il est définie comme un champ vectoriel $V[v(x, y), u(x, y)]$ utilisé pour minimiser la fonction de l'énergie suivante :

$$\varepsilon = \iint \mu |\nabla V|^2 + |\nabla g|^2 |V - \nabla g|^2 \quad (3.33)$$

La performance de l'algorithme GVF est basée sur la fiabilité de la détection des frontières. Cependant, en présence de bruit dans les images US, les techniques standards de détection de bords ont plusieurs limites. Pour garder uniquement les frontières du nerf dans une image US, l'information de texture et l'approche probabiliste sont utilisés. Il s'avère qu'il est plus avantageux de combiner les caractéristiques de texture avec l'information de phase local en utilisant l'approche probabiliste. La fonction de PGVF est basée sur la combinaison de la méthode d'apprentissage probabiliste et l'information locale de phase. Cette fonction modifie l'équation d'énergie externe du GVF, qui est comme suite :

$$\varepsilon = \iint \mu |\nabla V|^2 + |\nabla pf_{FA}|^2 |V - \nabla pf_{FA}|^2 \quad (3.34)$$

La solution dérivée de l'Eq. 3.34 est obtenue en utilisant l'équation d'Euler Lagrange,

$$V_t = \mu \nabla V^2 - (V - \nabla pf_{FA}) |\nabla pf_{FA}|^2 \quad (3.35)$$

où $p(x, y)$ est une fonction du poids du champ de vecteurs de gradient. Cette fonction guide le contour actif vers les frontières avec une forte probabilité d'appartenance à la région d'intérêt. f_{FA} est une fonction de mesure d'asymétrie de caractéristiques basée sur le signal monogénique. $p(x, y)$ est obtenue à partir des données d'apprentissage à l'aide du Modèle de Mélange Gaussien (GMM). Soit $\chi(x, y)$ un vecteur de caractéristiques représentant la réponse du filtre de Gabor à l'emplacement (x, y) et $p(x, y)$ la fonction de vraisemblance à cet emplacement, donnée par $p(x, y) = P(\chi/\Theta)$ pour générer la carte de probabilité $p(x, y)$, GMM est utilisé pour sélectionner le modèle statistique et pour estimer ces paramètres. Le GMM est défini par $p(\chi/\Theta) = \sum_{k=1}^K w_k p(x/\theta_k)$, où w_k est le poids de chaque Gaussienne et θ_k est le vecteur de paramètres de la k^{eme} Gaussienne. Ce vecteur contient la moyenne et la matrice de covariance.

3.8 Méthodes proposées pour améliorer le système DAO

Dans cette section, nous présentons les améliorations apportées au système DAO. Dans un premier temps, nous avons commencé par proposer un descripteur basée sur la fusion entre deux méthodes d'extraction de caractéristiques (le filtre de Gabor et le motif médian binaire). D'autre

part, nous avons aussi proposé une nouvelle méthode hybride de sélection de caractéristiques. Cette méthode est basée sur le résultat de plusieurs méthodes de sélection à base de filtres et une méthode à base d'apprentissage afin de réduire et de trouver les caractéristiques les plus pertinentes.

3.8.1 Descripteur dédié à la texture du nerf

Comme nous traitons des images bruitées, un descripteur non sensible à l'effet du bruit est primordiale pour une détection robuste. Le descripteur de Gabor peut aider à réduire le bruit car il est basé sur un processus de filtrage passe-bande [48]. Cependant les méthodes fréquentielles utilisant le filtre de Gabor ne sont pas suffisantes pour caractériser la structure du nerf, il est plus intéressant d'ajouter des informations additionnelles. Les méthodes à base de LBP sont parmi les meilleures techniques pour l'analyse de la texture et ils peuvent être combinées avec les descripteurs de Gabor pour obtenir de meilleures performances comme montré dans [272]. La méthode appelée Local Gabor Binary Pattern (LGBP) a démontré une certaine robustesse par rapport au bruit dans les images multimédias, tout en produisant de bonnes performances de reconnaissance. Cependant, LGBP est moins adapté pour caractériser la texture nerveuse en raison de l'importance du bruit dans l'image US. Cependant, MBP a des propriétés plus intéressantes pour caractériser une texture bruitée. MBP incorpore le processus de filtrage par la médiane, ce qui contribue à la réduction du bruit. Afin de représenter la texture du nerf selon plusieurs aspects, nous proposons la combinaison de MBP et le filtre de Gabor pour produire un nouveau descripteur appelé Motif Gabor Médian Binaire (MGBP). Pour calculer sa valeur pour une position (x,y) dans une image I, celle-ci est convoluée avec noyau de Gabor, exprimée par l'équation suivante :

$$g(x, y) = \exp\left[-\frac{1}{2}\left(\frac{x'^2}{\sigma_x^2} + \frac{y'^2}{\sigma_y^2}\right)\right] \cos(2\pi f x') \quad (3.36)$$

où $x' = x \cos \phi + y \sin \phi$, $y' = -x \sin \phi + y \cos \phi$, ϕ est le filtre de direction, σ est l'écart type de l'enveloppe gaussienne et f est la fréquence de l'onde cosinus. Nous utilisons la magnitude de la réponse du filtre de Gabor ($z(x, y) = |I(x, y) * g(x, y)|$). Le MGBP est déterminé par la correspondance de la réponse $z(x, y)$ au motif binaire localisé, ainsi le voisinage de chaque pixel est seuillé par la valeur médiane. Le MGBP au pixel (x, y) est définie comme suit :

$$MGBP_{P,R} = \sum_{p=0}^{P-1} \delta(z_p - z_m) 2^p \quad \delta = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.37)$$

Nous avons adopté la même stratégie que LBP et MBP [191, 95], où P est le nombre de voisins et R est le rayon du voisinage circulaire, z_p est la valeur du pixel et z_m est la valeur médiane dans le voisinage R . La rotation invariante et uniforme (RIU) est définie comme suit :

$$MGBP_{P,R}^{riu2} = \begin{cases} \sum_{p=0}^{P-1} \delta(z_p - z_m) & \text{si } U(MGBP_{P,R}^U) \leq 2 \\ P + 1 & \text{sinon} \end{cases} \quad (3.38)$$

où

$$(MGBP_{P,R}^U) = |\delta(z_{p-1} - z_m) - \delta(z_0 - z_m)| + \sum_{p=0}^{P-1} |\delta(z_p - z_m) - \delta(z_{p-1} - z_m)| \quad (3.39)$$

Après l'obtention du motif local, nous calculons l'histogramme de MGBP à chaque pixel dans un patch centré $N \times N$. Cet histogramme fournit le descripteur de MGBP.

3.8.2 Algorithme de sélection des caractéristiques

Un algorithme de sélection de caractéristiques appelé Sélection Aléatoire des Caractéristiques (SAC) a été proposé pour réduire les caractéristiques redondantes et sélectionner les caractéristiques pertinentes. Comme illustré dans l'Algorithme 2; d'abord les données d'apprentissage (R^{Train}, Y^{Train}) et les données de validation (R^{Val}, Y^{Val}) sont extraites de façon aléatoire (ligne 6). L'importance des caractéristiques pour (R^{Train}, Y^{Train}) est évaluée par l'information mutuelle,

Algorithm 1: Algorithme de sélections aléatoires de caractéristiques

Input: Ensemble de donnée de la ROI du nerf et les autres tissus R
 Ensemble d'étiquettes $Y = \{-1, +1\}$
 Critère d'arrêt γ (Fonction booléenne)
Output: S_k

- 1 Initialisation :
- 2 nbF ; Nombre de sous-ensembles
- 3 $Fscore = 0$; Score de classification
- 4 FS ; Sous-ensemble sélectionné
- 5 **repeat**
- 6 $[(R^{Train}, Y^{Train}), (R^{Val}, Y^{Val})] = RandomSelected(R, Y)$;
- 7 MI^{List} Générer la liste de rang avec (R^{Train}, Y^{Train})
- 8 RfF^{List} Générer la liste de rang avec (R^{Train}, Y^{Train})
- 9 IG^{List} Générer la liste de rang avec (R^{Train}, Y^{Train})
- 10 CS^{List} Générer la liste de rang avec (R^{Train}, Y^{Train})
- 11 $FS^{List} = Intersection([MI, RfF, IG, CS]^{List})$;
- 12 $\bar{FS}^{List} = CFS(FS^{List})$; Générer la liste de classement
- 13 $[Fscore] = Classification(\bar{FS}^{List}, (R^{Test}, Y^{Test}))$;
- 14 **if** $(Fscore^t > Fscore^{t-1})$ **then**
- 15 $S = FS^{list}$
- 16 **until** γ^t est vrai;
- 17 **return** S

Relief, gain d'information et score de Chi-carré (lignes 7-10). Les caractéristiques sont classées individuellement dans l'ordre décroissant, afin d'obtenir quatre listes de rangs : la liste d'information mutuelle MI^{List} , la liste de Relief RfF^{List} , la liste de gain d'information IG^{List} , et la liste de Chi-carré CS^{List} .

Ensuite, les intersections des caractéristiques dans les listes ordonnées sont conservées pour former FS^{List} (ligne 11). Dans une autre étape, l'algorithme de CFS (voire Section 3.6) utilise le processus de classement précédent pour sélectionner les caractéristiques les plus corrélées (ligne 12). La liste de rangs finale est obtenue en sélectionnant les caractéristiques qui sont présents dans les résultats des méthodes de sélection par pondération et de la méthode de sélection par corrélation.

L'ensemble des caractéristiques optimale est utilisé afin d'entraîner un classifieur SVM pour la classification des données de validation (R^{Val}, Y^{Val}) . Ensuite le sous-ensemble de caractéristiques optimal S est enregistré si le score de la classification $fscore^t$ est plus élevé que $fscore^{t-1}$ obtenu avec le sous-ensemble des caractéristiques optimal dans l'itération précédente (*lignes 13-15*).

L'algorithme est répété avec de nouvelles données d'apprentissages obtenues aléatoirement, et le résultat de $(\bar{F}S^{list}, fscore^t)$ est enregistré s'il est meilleur qu'à l'itération précédente. Cette procédure est répétée jusqu'à ce que le critère d'arrêt soit vrai (*ligne 16*). Dans cette étude le critère d'arrêt est vrai lorsque le score de classification est stable ($|fscore^t - fscore^{t-1}| < \epsilon$) ou que le nombre maximum d'itérations est atteint.

3.9 Résultats d'expérience

Des vidéos sonographiques du nerf médian ont été obtenues à partir de 19 patients (voir Section 1.5 pour plus de détails). Dans ces expériences, nous avons utilisé deux bases de données (DB1 et DB2) acquises au cours de plusieurs périodes. DB1 contient les données de 8 patients et DB2 contient les données de 11 patients. Environ 100 trames ont été extraites automatiquement de chaque video par un algorithme basée sur l'estimation de mouvement [62]. Cette étape permet de sélectionner les trames clés dans une vidéo dans lesquelles des changements importants ont eu lieu, ce qui permet d'éviter de biaiser les résultats. Les expériences ont été conduites selon deux étapes principales. Premièrement, l'évaluation a été effectuée sur DB1 avec la sélection aléatoire de l'ensemble des données d'apprentissage et de test. La seconde expérience vise à étudier la robustesse du système de détection sur les données acquises après une certaine période de temps, sans changer les méthodes, les paramètres ou les modèles d'apprentissage. DB1 a été considérée comme l'ensemble d'apprentissage et DB2 (acquise une année après DB1) a été considérée comme l'ensemble de test. Cette expérience permet d'évaluer la fiabilité d'une méthode donnée, indépendamment des conditions d'apprentissage.

3.9.1 Évaluation des composantes du système

L'objectif de cette expérience est d'évaluer chaque étape du système DAO proposé dans le but d'étudier le rôle et l'impact de chaque étape sur la localisation et segmentation du nerf. Le système proposé fonctionne en deux étapes (la localisation et la segmentation) tel décrit dans la Section 3.7. La Figure 3.5 illustre un exemple de localisation et de segmentation du nerf en utilisant trois images échographiques obtenues à partir de trois patients différents. La localisation du nerf est une étape essentielle pour permettre une convergence précise des contours actifs vers la région d'intérêt. La performance de chaque étape de localisation du nerf a été évaluée par la spécificité, transitivité et l'index de f-score (voir Chapitre 1 Section 2.4). Une région détectée est considérée comme un "vrai positif" si la surface d'intersection entre deux carrés (vérité terrain et la région détectée) divisée par




FIGURE 3.5 – Exemple de détection du nerf. (a) Trois images annotées par un expert anesthésiste. (b) Localisation du nerf, le carré vert représente la zone du nerf. (c) Détection du contour nerf.

leur union est supérieure à 50%. sinon, la région détectée est considérée comme un “faux positif”. Le faux négatif est incrémenté quand la réponse positive est inexistante, bien que la vérité terrain montre l’existence d’une région de nerf. Cinq principales étapes ont été évaluées pour la localisation du nerf : le dé-bruitage, l’extraction des caractéristiques, la sélection de caractéristiques et pour finir l’étape de classification. À noter que le classificateur SVM a été adopté dans les expériences suivantes, sauf lors de la comparaison des algorithmes de classifications.

Filtrage et extraction de caractéristiques

Dans cette expérience, nous avons étudié l’influence des différentes méthodes de dé-bruitages décrites dans la Section 3.4. Chaque filtre de dé-bruitage est associé à plusieurs caractéristiques statistiques pour représenter la région d’intérêt (voir Section 3.5). Table 3.5 et Table 3.6 présente la précision de localisation en termes de moyenne et d’écart type (i.e. $\mu \pm \sigma$) sur tout les f-scores obtenues. On peut constater que les performances d’un filtre de dé-bruitage donné dépend des caractéristiques choisies. Par exemple, le filtre MHPN fonctionne mieux avec les caractéristiques de FOS, tandis que les filtres FF, GaborF et WavF BIOR donnent de meilleurs résultats respectivement, avec TDM, SGLDM et GLDS. Cependant, la méthode de filtrage MSIHM offre un meilleur compromis, étant donné que les résultats sont cohérents pour la plupart des caractéristiques. Afin de mesurer la performance du descripteur MGBP, 173 images US extraites de 3 vidéos ont été utilisées. Cette expérience est accompagnée par un ensemble de paramètres comme montré dans

TABLE 3.5 – Résultat de classification pour différentes techniques implémentées dans l'approche proposée (filtre de dé-bruitage et extraction de caractéristiques).

Desc	DF	GF	MHPN	LF	MSIHM
FOS	0.26 ± 0.22	0.55 ± 0.32	0.67 ± 0.03	0.46 ± 0.09	0.59 ± 0.24
SGLDM	0.28 ± 0.06	0.15 ± 0.08	0.24 ± 0.53	0.36 ± 0.08	0.61 ± 0.54
GLDS	0.43 ± 0.34	0.62 ± 0.32	0.61 ± 0.12	0.54 ± 0.23	0.63 ± 0.21
NGTDM	0.40 ± 0.21	0.65 ± 0.05	0.44 ± 0.23	0.43 ± 0.21	0.63 ± 0.26
SFM	0.56 ± 0.08	0.51 ± 0.13	0.54 ± 0.54	0.52 ± 0.28	0.57 ± 0.43
TEM	0.42 ± 0.29	0.49 ± 0.43	0.33 ± 0.21	0.39 ± 0.27	0.58 ± 0.05
Fractal	0.22 ± 0.17	0.28 ± 0.36	0.43 ± 0.05	0.51 ± 0.23	0.61 ± 0.14

Desc	FF	HF	MF	RMLF
FOS	0.37 ± 0.12	0.41 ± 0.05	0.43 ± 0.08	0.42 ± 0.23
SGLDM	0.32 ± 0.17	0.27 ± 0.23	0.34 ± 0.31	0.31 ± 0.34
GLDS	0.56 ± 0.12	0.37 ± 0.06	0.60 ± 0.12	0.42 ± 0.13
NGTDM	0.73 ± 0.13	0.23 ± 0.18	0.64 ± 0.13	0.43 ± 0.22
SFM	0.49 ± 0.29	0.51 ± 0.43	0.51 ± 0.06	0.45 ± 0.26
TEM	0.46 ± 0.30	0.43 ± 0.13	0.47 ± 0.08	0.48 ± 0.15
Fractal	0.41 ± 0.24	0.17 ± 0.18	0.39 ± 0.21	0.32 ± 0.19

TABLE 3.6 – Résultat de classification pour différentes technique implémentées dans l'approche proposée (Les filtres de dé-bruitage à base des méthodes fréquentielles).

Desc	WavF Bior	WavF Daubechies	WavF Haar	WavF Symlets	GaborF
FOS	0.46 ± 0.02	0.18 ± 0.20	0.30 ± 0.02	0.43 ± 0.13	0.25 ± 0.35
SGLDM	0.60 ± 0.25	0.46 ± 0.32	0.18 ± 0.12	0.42 ± 0.07	0.73 ± 0.16
GLDS	0.50 ± 0.03	0.63 ± 0.32	0.45 ± 0.18	0.73 ± 0.16	0.47 ± 0.02
NGTDM	0.63 ± 0.02	0.46 ± 0.03	0.18 ± 0.01	0.43 ± 0.08	0.58 ± 0.43
SFM	0.46 ± 0.18	0.20 ± 0.03	0.28 ± 0.31	0.31 ± 0.22	0.19 ± 0.25
TEM	0.51 ± 0.09	0.37 ± 0.42	0.30 ± 0.27	0.60 ± 0.18	0.40 ± 0.32
Fractal	0.47 ± 0.23	0.50 ± 0.14	0.32 ± 0.09	0.12 ± 0.06	0.37 ± 0.02

Table 3.7. De plus MGBP a été comparé à LGBP, où on peut observer que MGBP est plus performant que LGBP avec une précision moyenne de 71.34%. Dans une autre expérience (voir Table 3.8), nous avons comparé plusieurs méthodes à base de LBP. Nous pouvons observer que ABMP réalise le meilleur score par rapport aux autres méthodes basées sur LBP. Cependant, AMBP est moins stable que MGBP.

Sélection des caractéristiques

Comme mentionné dans la section précédente, MSIHM offre un bon compromis entre les méthodes de filtrage et les techniques d'extraction de caractéristiques. Pour augmenter les performances, 37 caractéristiques ont été concaténées comme un seul vecteur de caractéristiques en utilisant toutes celles décrites dans la table 3.2. Les résultats obtenus ont montré une diminution des performances comme présenté dans la Table 3.5. Par conséquent, seul un sous-ensemble de caractéristiques fonctionne mieux ce qui conduit à un problème de sélection des caractéristiques

TABLE 3.7 – Résultat de classification pour différents paramètres pour LGBP et MGBP

Params(riu2)		LGBP			MGBP		
R	P	Acc	Sn	Sp	Acc	Sn	Sp
1	8	61,99	70.97	53.02	71.34	82.38	60.30
2	16	62.55	44.42	80.68	57.01	50.29	63.73
3	24	60.54	35.54	89.54	61,15	34.61	87.69
1-2	8-16	61.14	68.97	53.31	68,20	77.39	59.01
1-3	8-24	61.82	66.63	57.01	63,72	74.01	53.43
2-3	16-24	60.12	46.63	74.17	60,42	40.39	80.45
1-2-3	8-16-24	66.99	70.97	53.02	66.48	70.05	62.45

TABLE 3.8 – Résultat de classification pour différentes méthodes à base de LBP implémentées dans l'approche proposée.

Desc	Recall	Precision	F-score
LBP	0.78 ± 0.01	0.42 ± 0.03	0.61 ± 0.03
CLBP	0.29 ± 0.12	0.35 ± 0.22	0.32 ± 0.10
LPQ	0.11 ± 0.15	0.19 ± 0.14	0.15 ± 0.14
LCP	0.12 ± 0.43	0.24 ± 0.14	0.24 ± 0.18
MBP	0.80 ± 0.07	0.45 ± 0.10	0.63 ± 0.09
AMBP	0.82 ± 0.03	0.64 ± 0.41	0.72 ± 0.10
SLBP	0.39 ± 0.06	0.46 ± 0.13	0.44 ± 0.12
HFLBP	0.23 ± 0.09	0.37 ± 0.03	0.30 ± 0.21
GMBP	0.46 ± 0.03	0.88 ± 0.01	0.65 ± 0.02

(voir Section 3.6).

Pour évaluer l'étape de la sélection de caractéristiques, Nous avons comparé les méthodes à base de filtres les plus utilisées : t-test, ReliefF, Kruskal-Wallis, gain d'information, indice de gini, score de Fisher, sélection des caractéristiques à base de corrélation (CFS), score de Chi-carré, corrélation rapide basée filtre (FCBF), test de Wilcoxon, analyse en composantes principales (PCA), Minimum redondance maximum pertinence (MRMR) et la sélection aléatoire des caractéristiques (SAC). Nous avons également comparé les approches de sélection de caractéristiques à base d'apprentissage : sélection séquentielle vers l'arrière (SFS), sélection séquentielle vers l'avant (SBE) et la régression logistique multinomiale (SMLR).

La Table 3.9 montre généralement que les méthodes à base d'apprentissage donnent de meilleurs résultats que les méthodes à base de filtres en termes de précision. Cependant, les méthodes de sélection à base d'apprentissage exigent beaucoup plus de temps de calcul que les méthodes à base de filtres, ceci est principalement dû à la dépendance de la boucle fermée pour la sélection des caractéristiques accordée à la sortie du classificateur. En ce qui concerne le nombre de caractéristiques sélectionnées, le t-test et le Fisher score ont respectivement 23 et 25 caractéristiques, ce qui représente les nombres fournis les plus élevés parmi toutes les méthodes.

Les algorithmes de SAC et MRMR donnent les plus petits nombres de caractéristiques avec

TABLE 3.9 – Résultat de classification pour différentes techniques implémentées dans l'approche proposée (méthodes de sélection de caractéristiques).

Algo	number of features	Recall	Precision	F-score
CFS	10	0.70 ± 0.55	0.83 ± 0.15	0.77 ± 0.32
Chi-square	11	0.71 ± 0.02	0.77 ± 0.29	0.74 ± 0.09
FCBF	3	0.60 ± 0.20	0.68 ± 0.21	0.65 ± 0.22
Fisher score	23	0.51 ± 0.01	0.60 ± 0.46	0.56 ± 0.13
gain index	12	0.65 ± 0.54	0.77 ± 0.23	0.72 ± 0.52
information gain	8	0.70 ± 0.01	0.79 ± 0.42	0.75 ± 0.11
Kruskal-Wallis	13	0.76 ± 0.17	0.72 ± 0.15	0.74 ± 0.18
MRMR	7	0.80 ± 0.08	0.83 ± 0.10	0.82 ± 0.09
PCA	12	0.74 ± 0.03	0.72 ± 0.11	0.74 ± 0.13
ReliefF	11	0.65 ± 0.21	0.73 ± 0.24	0.71 ± 0.14
SMLR	21	0.59 ± 0.32	0.45 ± 0.36	0.52 ± 0.23
T-test	25	0.46 ± 0.50	0.53 ± 0.44	0.50 ± 0.36
Wilcoxon test	10	0.77 ± 0.04	0.69 ± 0.08	0.73 ± 0.06
SFS	7	0.85 ± 0.28	0.76 ± 0.22	0.81 ± 0.37
SBE	13	0.74 ± 0.17	0.79 ± 0.25	0.78 ± 0.04
SAC	6	0.82 ± 0.13	0.85 ± 0.05	0.83 ± 0.11

les meilleures performances en termes de f-score. Cependant, l'algorithme SAC est très coûteux en terme de temps de calcul par rapport à MRMR. Les caractéristiques extraites de l'algorithme SAC sont : l'homogénéité, l'entropie, et l'énergie dérivée de GLDM, la force et le busyness dérivés de NGTDM et enfin la rudesse extraites de SFM.

Comparaison des classificateurs

Dans cette section, nous comparons les performances de plusieurs algorithmes de machines d'apprentissage couramment utilisés pour la classification dans les images US, i.e. la machine à vecteurs de support (SVM), l'arbre de décision (DCT), le k-plus proches voisins (KNN), le réseau de neurone (MLP) et enfin le naïve bayésienne (NB). L'objectif de cette expérience est de déterminer le modèle d'apprentissage qui produit la meilleure performance pour un petit ensemble de données d'apprentissage. Dans ce contexte, nous avons utilisé le filtre de dé-bruitage MSIHM et l'algorithme de sélection de caractéristiques MRMR, étant donné qu'il est indépendant du classificateur. Dans cette expérience nous avons gardé les meilleurs paramètres de chaque algorithme d'apprentissage automatique. L'algorithme de SVM est utilisé avec un noyau RBF et pour lequel $\sigma = 0.25$ et $C = 0.7$. Rappelons que le paramètre C contrôle le compromis entre les erreurs du SVM sur les données d'apprentissages et de la marge de maximisation. MLP, KNN et NB exigent un seul paramètre pour chaque algorithme. Concernant les réseaux de neurones, une seule couche cachée de 5 neurones a été utilisée pour l'algorithme de MLP, pour le KNN la taille de voisinage a été portée à 3 et l'expérience montre que la distribution normale est plus appropriée pour l'algorithme de NB. La prédiction de chaque algorithme de machine d'apprentissage est indiquée par la probabilité qu'une étiquette provient d'une classe particulière. Table 3.10 montre que l'algorithme SVM atteint

le meilleur résultat.

TABLE 3.10 – Résultats de classification pour différentes techniques de machines d'apprentissages implémentées dans le système proposé.

Classifier	<i>DTree</i>	<i>Knn</i>	<i>MLP</i>	<i>SVM</i>	<i>NBayes</i>
$f - score$	0.71 ± 0.19	0.67 ± 0.23	0.45 ± 0.31	0.82 ± 0.09	0.36 ± 0.28

3.9.2 Évaluation de segmentation

La localisation est une étape importante pour une segmentation performante d'une région d'intérêt, particulièrement quand on utilise un algorithme de contour actif. Nous avons évalué le processus de segmentation avec et sans l'étape de localisation, en utilisant des méthodes à base de modèles déformables et celles qui sont dédiées à la détection du nerf. Dans Table 3.11, nous avons comparé notre méthode avec plusieurs algorithmes i.e. CV [26], DRLS [138] et PGVF [96]. Les résultats ont montré que, PGVF est meilleur que DRLS et CV pour l'étape de segmentation. Cependant, notre méthode de localisation a systématiquement améliorée la segmentation à base

TABLE 3.11 – Comparaison de notre système avec d'autres méthode

Method	Dice metric	Hausdorff metric
[26] (CV)	0.09 ± 0.13	350 ± 19.8
[138] (DRLS)	0.13 ± 0.03	267 ± 11.2
[96] (PGVF)	0.75 ± 0.15	23.9 ± 25.9
Localization + CV	0.69 ± 0.11	37.02 ± 30.9
Localization + DRLS	0.71 ± 0.18	27.12 ± 17.73
Localization + PGVF	0.81 ± 0.10	12.06 ± 2.81

des méthodes de contour actifs. La combinaison de PGVF et le système de localisation donne le meilleur résultat avec 81% et 12.06 respectivement pour Dice et Hausdorff. Ces résultats montrent que la méthodologie adoptée peut détecter avec succès les ROIs dans les images bruitées, ce qui est important pour parvenir à une délimitation réussie du contour du nerf. Des résultats qualitatifs sont montrés dans la Figure 3.5, où l'on peut voir que le nerf a été détecté avec succès par rapport à la vérité terrain.

3.9.3 Évaluation de la robustesse

Dans les expériences précédentes, nous avons utilisé des données acquises dans la même période de temps. Une question intéressante se pose concernant la fiabilité du système proposé au fil du temps. En d'autres termes, peut-on détecter les structures nerveuses, en utilisant différentes données, acquises après une longue période avec la même machine d'échographie? Pour cela, nous avons utilisé la première base de données (DB1) pour calculer les modèles d'apprentissage et la

seconde (DB2) acquis un an plus tard, en tant que données de test. Dans cette expérience, nous avons utilisé les méthodes qui ont obtenu les meilleurs résultats et qui ont été validées dans les premières expériences, à savoir, le filtre MSIHM, l'algorithme de sélection de caractéristiques MRMR et le classificateur SVM pour la localisation du nerf. Ensuite, un contour actif a été adopté pour la segmentation finale. Table 3.12 représente les résultats de la localisation et de la segmentation.

TABLE 3.12 – Les scores moyens de l'évaluation quantitative de la localisation et de la segmentation pour l'étude de la robustesse

F-score	Recall	Precision	Dice metric	Hausdorff metric
0.70 ± 0.37	0.69 ± 0.54	0.73 ± 0.19	0.78 ± 0.43	12.51 ± 5.79

On observe pour la localisation un résultat de 70% pour f-score et concernant la précision de segmentation, nous affichons des valeurs de 78% et 12.51, obtenues respectivement pour les métriques de Dice et Hausdorff.

3.10 Discussion

Le but de cette étude a été de proposer des outils performants pour répondre au besoin de détection et de segmentation des nerfs dans les images échographiques. Nous avons introduit une nouvelle approche impliquant une vaste étude comparative pour traiter différents problèmes liés à l'identification des nerfs. À notre connaissance, cette étude est la première à proposer des comparatifs sur l'efficacité des différentes techniques de traitement d'image et de machines d'apprentissages appliquées aux images US. Il était important que la proposition d'un nouveau système de DAO soit précédé par une étude comparative exhaustive des techniques disponibles aujourd'hui. Il était essentiel de réaliser ce travail afin de trouver l'approche appropriée pour une localisation et une segmentation robuste. L'approche proposée combine à la fois une méthode d'apprentissage automatique et un algorithme de contour actif pour détecter les régions nerveuses. La performance des systèmes DAO pour les images US, en général, dépend de cinq grandes phases : le filtrage, l'extraction de caractéristiques, la sélection de caractéristiques et enfin la classification. Chacune de ces phases ont reçu une attention particulière au cours des dernières décennies et il a été montré que chaque méthode a ses propres spécificités, selon le type d'application [34, 69]. Par conséquent, il nous a semblé nécessaire d'établir un état de l'art des méthodes susceptibles de répondre à l'approche de DAO souhaitée. Ce travail a permis de sélectionner les méthodes spécifiques conduisant aux meilleurs résultats. Cette approche méthodologique a été fastidieuse mais elle a portée ses fruits dans le contexte qui nous intéresse ici.

Dans la section précédente, nous avons évalué chaque étape de la chaîne de traitement pour mesurer leur influence sur la localisation du nerf. Cependant, la localisation dépend des propriétés des caractéristiques discriminantes obtenues. Les propriétés de la modalité imagerie ultrasonores sont souvent dégradées. Par conséquent, la phase de dé-bruitage est nécessaire pour réduire le

bruit et améliorer ainsi la qualité des caractéristiques. La comparaison entre différentes méthodes de dé-bruitage et d'extraction de caractéristiques a donné un aperçu de la méthode de filtrage qui fonctionne le mieux avec les méthode d'extraction de caractéristiques (voir Table 3.5 et Table 3.8). Parmi les filtres considérés ici, MSIHM a donné les meilleurs résultats dans la plupart des cas, ce qui en fait une bonne méthode pour la caractérisation du nerf. Ces résultats sont en parfait accord avec une étude menée sur les images échographiques de l'artère carotide [152], où MSIHM, GF et HF ont fourni les meilleurs scores en utilisant le classificateur k-NN. Néanmoins, les ondelettes et les filtres tels que MHPN et FF ont donné des scores intéressants mais seulement pour certaines caractéristiques, ce qui les rend moins adapté à l'objectif de la méthode proposée. Cependant, ces méthodes de filtrages peuvent améliorer les performances, en particulier les méthodes d'ondelettes comme démontrée par une étude comparative pour caractériser les tissus athéromateuse par les ondelettes [239].

Les caractéristiques de texture à base de LBP ont démontré aussi des performances élevées dans d'autres modalités d'imagerie médicale [109, 181]. Cependant, le cas est différent pour les images US, principalement en raison de leur sensibilité au bruit. Néanmoins, des descripteurs tels que MGBP et AMBP prennent en compte l'effet du bruit local, ce qui explique pourquoi les performances sont meilleures que les autres méthodes basées LBP comme indiquées dans Table 3.8. Cependant, comme MGBP et AMBP sont basées sur le filtrage médian, ils ne peuvent pas traiter complètement le bruit dans l'image US.

La sélection des caractéristiques est souvent sous-estimée dans les études appliquées à l'imagerie médicale par ultrasons, bien qu'elle soit une étape cruciale pour améliorer les performances car la redondance dans l'espace des caractéristiques augmente l'erreur de classification. Comme on peut le voir dans Table 3.9, les algorithmes de sélection des caractéristiques, généralement augmentent de façon significative la performance de détection. Cependant, comme pour l'étape de filtrage et de l'étape d'extraction, nous avons établie une étude comparative des méthodes de sélection afin de trouver la mieux adaptée pour l'application ALR. Cette étude comparative a identifiée la méthode SAC proposée comme la meilleure technique de sélection des caractéristiques. Toutefois, MRMR ne nécessite pas d'une étape d'apprentissage, ce qui le rend intéressant et moins sensible à l'étape de classification.

Le quatrième composant majeur du système DAO proposé est le classificateur. SVM a montré les meilleurs résultats par rapport à k-NN, MLP, l'arbre de décision et le Naïve Bayésien. Le noyau RBF fournit les meilleurs résultats pour SVM. Ces résultats sont cohérents avec l'étude comparative sur le diagnostic du myocarde basée sur l'imagerie ultrasonores [245]. De nombreuses études pour les applications d'imagerie US ont indiqué que SVM fonctionne mieux que d'autres classificateurs. Selon [30], SVM est mieux adapté que les méthodes de réseaux neuronaux : MLP, réseau PCA, réseau RBF et réseau SOFM. La haute performance de SVM peut être expliquée par sa robustesse à la séparation correcte des classes. Alors que SVM prend beaucoup de temps dans

la phase d'apprentissage afin de construire le modèle de classification, il est rapide dans la phase de classification. Ceci présente un avantage pour les applications en temps réel, étant donné que la phase d'apprentissage peut être effectué hors ligne.

Il est important de tester l'effet d'un faible pourcentage d'échantillons d'apprentissage, ce qui correspond aux conditions hospitalières réelles. Cet ensemble d'apprentissage représente un faible pourcentage au regard du grand nombre de nouveaux arrivants, pour lesquels la détection de nerf doit être faite en temps réel dans la salle d'opération. Les résultats observés (Table 3.12) ont montré une certaine diminution de la performance quand un petit ensemble d'apprentissage est utilisé mais ils montrent toutefois un haut niveau de performance et de cohérence. Il est également intéressant de souligner que l'inter-variabilité entre l'anatomie des patients impacte l'aspect visuel du nerf médian dans les images US. Cette variabilité doit être prise en compte lors de la formation de l'ensemble d'apprentissage. De plus, les paramètres de réglages des machines échographiques ont changé après une période d'un an entre les deux acquisitions (DB1 et DB2). Comme l'apprentissage a été réalisée uniquement sur les premières données (DB1), ce qui peut expliquer les scores plus faibles de la localisation et de la segmentation obtenue à partir du second ensemble de données (DB2) (voir Table 3.12).

Comme indiqué précédemment, la localisation de la ROI est très importante pour obtenir une bonne segmentation du nerf, puisqu'un contour initial correspondant permet une convergence rapide et précise du contour actif dans la région d'intérêt. De nombreuses études dans les images échographiques [185] utilisent des algorithmes de segmentation, comme les contour actif, graph cuts, etc. Souvent, ces méthodes sont assistées par un opérateur humain, qui sélectionne manuellement la ROI [98, 127]. Cependant, la combinaison entre les machines d'apprentissages et les techniques de segmentation montrent de bonnes performances [261, 30]. Dans des travaux antérieurs [96], les auteurs ont démontré l'efficacité d'une telle approche pour segmenter le nerf sciatique. Cependant, cette méthode a donné des scores plus faibles pour le nerf médian. En effet, l'initialisation du contour actif par notre méthode de localisation proposée montre de bonnes performances en termes de mesures de Dice et de Hausdorff (comme on peut le voir dans (Table 3.11)). Cela est dû à l'espace de recherche réduit et le contour initial approprié.

L'impact médicale de la méthode proposée sera très intéressant pour les anesthésistes. Le développement d'un système d'assistance facilitera la procédure d'ALR et de l'enrichir avec des informations pertinentes. On peut envisager une machine échographique avec une interface interactif qui fournit à des anesthésistes un outil capable de détecter les nerfs en temps réel. Jusqu'à présent, dans ce travail, nous avons pas mis l'accent sur le traitement en temps réel. L'objectif était d'abord d'étudier divers aspects pour trouver un système performant. Dans l'approche proposée, le processus d'apprentissage est l'étape la plus consommatrice de temps d'exécution, mais comme cette procédure se fait hors ligne, il ne devrait pas être un problème pour les applications en temps réel. La plupart des procédure de détection, tels que le dé-bruitage, l'extraction de caractéristiques,

etc., peuvent être optimisés en temps réel. L'algorithme de contour actif est également rapide, car il fonctionne à proximité de la région souhaitée. Par ailleurs, il est possible de paralléliser la méthode proposée en utilisant, par exemple, un processeur graphique GPU.

3.11 Contribution

Les principales contributions de ce chapitre sont les suivantes :

- (1) Méthode hybride : une approche basée sur une technique de localisation et de segmentation a été proposée pour détecter le nerf dans les images échographiques. D'une part, la localisation est assurée par une méthode de détection assistée par ordinateur, cette méthode incorpore plusieurs étapes; prétraitement, extraction et sélection de caractéristiques et classification. Dans ce chapitre, nous avons détaillé chaque étape de la méthode de détection assistée par ordinateur accompagnée par une large évaluation afin d'établir un système de détection automatique du nerf. D'autre part, une méthode de contour actif probabiliste est utilisée pour assurer la segmentation du nerf après localisation.
- (2) Descripteur dédié à la texture du nerf : afin de représenter la texture du nerf selon plusieurs aspects, nous proposons la combinaison de *median binary pattern* et le filtre de Gabor pour produire un nouveau descripteur appelé Motif Gabor Médian Binaire. En effet, un descripteur non sensible à l'effet du bruit et capable de caractériser la structure du nerf, est primordiale pour une détection robuste. Pour cette raison, nous combinons le filtre Gabor pour réduire le bruit et la méthode *median binary pattern* pour caractériser la texture du nerf.
- (3) Algorithme de sélection de caractéristique : un algorithme de sélection de caractéristiques appelé Sélection Aléatoire des Caractéristiques a été proposé pour réduire les caractéristiques redondantes et sélectionner les caractéristiques pertinentes. Tout d'abord la méthode à base des filtres a été utilisée pour évaluer l'importance des caractéristiques. Ensuite les méthodes à base d'apprentissage sont appliquées pour sélectionner les caractéristiques les plus optimales.

3.12 Conclusion

Une nouvelle méthode hybride basée sur la localisation et la segmentation du nerf dans les images échographiques a été proposée, d'une part. L'étape de localisation est dérivée d'un nouveau système de Détection Assistée par Ordinateur (DAO) et l'étape de segmentation est basée sur un modèle déformable paramétrique. D'autre part, nous avons étudié les performances de chaque composantes de la méthode DAO proposée. L'étude comparative a été réalisée sous l'aspect de fiabilité, efficacité et cohérence de chaque composantes de la méthode DAO. Les résultats obtenus indiquent la validité de l'approche proposée. En résumé, le système proposé est efficace par rapport aux méthodes existantes pour la segmentation du nerf dans des images US. Toutefois, certaines faiblesses demeurent. L'information seule de la texture n'est pas tout à fait suffisante pour détecter

3.12. CONCLUSION

le nerf dans toute situations ; la forme et l'information temporelle complèteront le manque de propriétés discriminantes.

3.12. CONCLUSION

Chapitre 4

Modèle adaptative d'apprentissage on-line via la cohérence temporelle pour la détection du nerf

Dans ce chapitre, une étude est menée sur la détection du nerf dans une séquence d'images extraite d'une vidéo échographique. En effet, La localisation automatique du nerf dans une séquence d'images US est souvent entravée par les variations morphologiques des structures nerveuses. Citons pour exemple la perte d'information d'apparence, la déformation de la forme, le changement de rotation et d'échelle des tissus anatomiques et les artefacts au cours du temps. Pour ces raisons, une méthode à base d'information spatio-temporelle est nécessaire pour contourner ces limitations. D'une part, nous nous sommes intéressés à la cohérence temporelle de plusieurs caractéristiques comme la position, la confiance de classification et la forme du nerf pour une localisation automatique et performante. D'autre part, nous avons élaboré plusieurs techniques afin de transformer l'information indistincte de la variation de la structure du nerf en une information ordonnée et utile pour créer une représentation du nerf dans le temps.

Premièrement, pour agencer l'information temporelle du nerf, nous avons utilisé l'apprentissage *on-line* afin de construire un modèle capable de s'adapter aux différentes variations structurelles du nerf dans le temps. Deuxièmement, dans une séquence d'images US consécutives, le nerf peut changer significativement d'apparence et de forme. Pour cette raison, dans ce travail, le nerf est représenté par différentes caractéristiques, chacune complétant les autres. Effectivement, une combinaison de plusieurs informations comme la position, la confiance de classification et la forme sont primordiales pour capter l'information nécessaire du nerf dans le temps. Finalement, nous avons remarqué qu'un modèle de forme traditionnel à base de valeurs de point de repère est inefficace pour représenter la variation de la forme du nerf dans le temps. Par conséquent, nous avons proposé un modèle de forme à base d'intervalle des valeurs des points de repère capable de rajouter une certaine incertitude utile au modèle afin de prendre en considération la variation de la forme dans le temps.




FIGURE 4.1 – Exemple de trois trames d’une séquence d’images US à $t = \{1, 50, 84\}$ annotées par des experts anesthésistes (la région du nerf est marquée par la couleur verte). Cette figure montre le défi de la détection du nerf illustré comme suit : (a) Confusion d’apparence entre les tissus nerveux et les tendons. (b) la forme et la texture du nerf confondu avec la région de l’os (couleur rouge). (c) le faible écho de la région du nerf par rapport aux trames $t = 1$ et $t = 84$.




FIGURE 4.2 – Illustration de quatre courbes associées aux trois trames d’une séquence d’image US à $t = \{1, 50, 84\}$. Cette figure montre l’incohérence de la texture du nerf

4.1 Introduction

La similitude d’intensité entre la région du nerf et les autres tissus anatomiques rend la modélisation du nerf une tâche très difficile car une seule modalité d’information est incapable de fournir une représentation complète de la structure du nerf dans une séquence d’images US. Les Figure 4.1 et 4.2 montrent les principales difficultés à détecter le nerf dans une séquence d’images US, à partir des variations de forme et de texture (contraste, corrélation, énergie ...) dans le temps. Durant une procédure d’ALR écho-guidée, le praticien se base à la fois sur l’aspect spatial pour trouver la texture du nerf et aussi sur l’aspect dynamique en analysant l’évolution visuelle des tissus anatomiques dans le temps afin de localiser les régions d’intérêts. Cet aspect dynamique est lié à un apprentissage visuel en temps réel de la cohérence de la forme et de la texture du nerf dans un intervalle de trames successives. Pour cette raison, nous avons réfléchi à un modèle d’apprentissage *on-line* par ordinateur capable de gérer la cohérence temporelle de la structure

du nerf automatiquement afin d'assurer une localisation correcte dans le temps. En effet, la cohérence temporelle représente une information relativement stable dans le temps, par exemple la forme et la position du nerf dans une séquence d'images US contiennent une certaine information répétitive. Cette répétition définit la cohérence temporelle. Cependant, pour trouver l'information cohérente dans un intervalle de trames successives, nous utilisons un apprentissage *on-line*, capable de modéliser la cohérence temporelle en s'adaptant aux différentes situations de cette cohérence.

Une fois les problématiques de cohérence temporelle et d'apprentissage *on-line* définies, nous avons mené une étude sur ces problématiques afin de trouver la modélisation adéquate à l'aspect spatial et dynamique du nerf dans une séquence d'images US.

Dans ce chapitre, nous commençons par montrer les principes de la méthode proposée dans la Section 4.2, d'une part. D'autre part, la méthode proposée est présentée et analysée dans la Section 4.3. Ensuite dans la Section 4.4, une comparaison quantitative est donnée pour prouver la performance de notre méthode. Finalement, le document se termine par quelques conclusions dans la Section 4.6.

4.2 Principes de la méthode proposée

4.2.1 Cohérence temporelle

La cohérence temporelle a été utilisée pour différentes problématiques comme le traitement d'images, l'évaluation de performance et la détection d'objet par suivi. Par contre, la cohérence temporelle a été moins utilisée pour résoudre les problèmes de traitement d'images US. Cependant, il existe quelques travaux traitant de la cohérence temporelle pour améliorer les images US, par exemple dans [19], un algorithme basé sur la régularité temporelle a été proposé pour filtrer et améliorer les séquences d'images multimédia qui souffrent de tremblements visuels. D'autre part, la cohérence temporelle a été appliquée pour l'évaluation de la qualité de détection par suivi sans recours à la vérité terrain. Ces méthodes se basent souvent sur des propriétés d'estimation de trajectoire comme la cohérence de zone [31], l'erreur dynamique de spectre [198] ou leurs combinaisons [116, 217]. Pour ce qui concerne la détection d'objet par suivi basée sur la cohérence temporelle, il est souvent lié à la cohérence de mouvement [142, 155]. Dans [142], les auteurs ont proposé une approche basée sur la classification de chaque paire de trames successives selon la cohérence du mouvement de l'objet associé. Une autre méthode de détection d'objet par suivi à base des positions cohérentes dans le temps a été proposée dans [155], en exploitant aussi la cohérence de mouvement. Autrement, la plupart des travaux sur les méthodes de détection d'objet par suivi basées sur la cohérence temporelle utilisent l'estimation de mouvement pour analyser la cohérence entre les trames dans une séquence d'images. Toutefois, ces techniques sont moins efficaces dans les séquences d'images US. Néanmoins, dans [154], les auteurs ont étudié les algorithmes de détection basés sur la cohérence temporelle du mouvement à grande échelle dans des séquences d'images US

afin de gérer les problèmes cardiaques et respiratoires. il en ressort que ces méthodes sont insuffisantes pour la détection du nerf dans une séquence d'images US, à cause de leur sensibilité aux bruits et leur dépendance à l'initialisation manuelle.

4.2.2 Apprentissage *on-line*

Le principal défi de détection des nerfs dans une séquences d'images US est souvent lié à la qualité visuelle des structures nerveuses ; le bruit, le faible écho, les artéfacts et les frontières discontinues, rendant la tâche d'identification particulièrement difficile. Pour contourner ces écueils, plusieurs travaux à base de connaissances préalables de la forme et de l'apparence ont été proposés. Tous utilisent un modèle d'apprentissage. Certains s'appuient sur une approche Bayésienne [99]. D'autres sur la modélisation de la forme avec priorité de la texture [82, 205] et quelques uns proposent l'usage des contours actifs à base d'apprentissage [96]. Ces travaux ont montré l'utilité de la multimodalité pour représenter des ROIs dans les images US. Cependant, l'apprentissage *on-line* a été moins abordée pour la détection dans les séquences d'images US. Or, ce dernier peut apporter des informations utiles liées aux variations morphologiques dans les séquences d'images US. Par exemple dans [252], un modèle d'apprentissage *DeepBoost on-line* a été utilisé afin de rectifier les erreurs de détection dans des scènes multimédias. Dans [131], les auteurs ont proposé un modèle *on-line* capable d'identifier l'arrière plan pour faciliter la détection des objets dans des images aériennes. Les modèles d'apprentissage *on-line* sont aussi utilisés pour détecter les erreurs de diagnostic. Par exemple dans [266], un modèle de Markov caché adaptatif basé sur un apprentissage *on-line* a été proposé pour détecter le changement dynamique des machines durant leur durée de vie.

4.2.3 Concept

Dans notre travail, une analyse sur la cohérence temporelle est mise en œuvre afin de construire un modèle dynamique capable à la fois de prendre en compte les variations morphologiques de la structure du nerf dans les séquences d'images US et d'estimer la qualité de détection pour corriger une fausse détection. Notre modélisation du nerf dans une séquence d'images US est représentée par une machine à états finis, comme illustrée dans la Figure 4.3. Une séquence d'images est donnée en entrée, où chaque trame est passée par l'étape "régions générées par SVM" afin de sélectionner les coordonnées de positions (voir la figure 4.4), les confiances de classifications et les formes associées aux régions prédites.

Notez que dans ce travail, les coordonnées de positions de n trames t ($t = 1 \dots n$), sont sélectionnées à partir d'un ensemble de régions $S = \{\mathcal{U}^1, \dots, \mathcal{U}^n\}$ prédit par m instances de SVM. Chaque $\mathcal{U}^t$ correspond aux régions candidates (R_t^{SVMk}) générées par les k instance de SVM pour la trame t , où $k = \{1, \dots, m\}$ et $\mathcal{U}^t = \{R_t^{SVM1}, \dots, R_t^{SVMm}\}$. Les centroïdes des régions R_t^{SVMk} pour




FIGURE 4.3 – Illustration de la méthode proposée pour détecter le nerf dans une séquence d'images sous forme de machine à états finis

la trame t et l'instance SVM k sont utilisés comme coordonnées de positions (x_k^t, y_k^t) . La position (x_k^t, y_k^t) est représentée par une direction et une amplitude, où un vecteur $\overrightarrow{AB}$ avec $A = (0, 0)$ et $B = (x_k^t, y_k^t)$, est utilisé pour calculer sa norme (direction) et son angle (amplitude) de la région R_t^{SVMk} . Un ensemble des régions candidates $(S = \{\mathcal{U}^1, \mathcal{U}^2, \dots, \mathcal{U}^t\})$ appartenant aux premières trames est utilisé pour construire le modèle de position, où il est sélectionné selon un seuil de stabilité de leurs coordonnées de position dans le temps $(C^{pos} > \tau)$. Une fois le modèle calculé $(C^M = 1)$, les régions candidates sont passées directement à l'étape de prédiction, afin de calculer la probabilité de position des nouvelles régions candidates. Ensuite, si la probabilité d'une de ces régions candidates est supérieure à 70% alors une étape de mesure de qualité de détection est lancée pour confirmer la détection du nerf. La machine à états finis est représentée par 3 états principaux, définis comme suit :

- (1) Régions générées par SVM : cette étape génère les régions candidates en utilisant le système de détection basé sur l'information spatiale. Elle fournit les positions (x_k^t, y_k^t) de l'ensemble des régions candidates $\mathcal{U}^t$ obtenu pour t trames, accompagnées par leurs mesures de confiance de classification (*Conf*) (i.e. distance entre l'hyperplan SVM et le vecteur de caractéristiques de cette région candidate) et de leurs formes (*Shp*) (i.e. segmentation de la région candidate à partir de l'algorithme PGVF). Cette méthode est décrite en détail dans le Chapitre précédent (cf. Section 3.7).
- (2) Le modèle de position : dans cette phase, nous recueillons les coordonnées des régions prédites par SVM en respectant la condition de cohérence de zone $(C^{pos} > \tau)$ afin de construire le modèle d'apprentissage *on-line*, où les positions des régions candidates (*pos*) sont représentées par les directions (ϕ) et les amplitudes (η). Une fois que le modèle est construit, la probabilité




FIGURE 4.4 – Illustration d'un exemple des coordonnées de positions des régions générées par SVM pour une seule trame US. Les coordonnées de position (x_k^1, y_k^1) correspondent aux centroïdes des régions R_1^{SVMk} générées par k instance de SVM pour la trame 1. Par exemple la région R_1^{SVM5} est la région prédite dans la trame 1 par l'instance $SVM5$ avec un maximum de confiance de classification ayant le couple (x_5^1, y_5^1) comme coordonnées de position de cette région.

a posteriori de la cohérence d'une nouvelle position est calculée afin de prédire l'appartenance d'une région d'intérêt au modèle du nerf. Si celle-ci dépasse les 70% ($\prod_{pos} P_t^{pos} > 0.7$) alors la forme et la confiance de classification de cette région sont utilisées pour mesurer la qualité de détection. Cependant, le modèle *on-line* de position est recalculé dans le cas où les positions des régions candidates sont incohérentes ($C^{pos} < \tau$).

- (3) La mesure de qualité de détection : une fois que la région du nerf est trouvée en utilisant le modèle de position, un modèle bayésien naïf est utilisé pour mesurer la qualité de la détection. Ce modèle est basé sur la connaissance préalable pour représenter deux caractéristiques indépendamment : la confiance de classification (*conf*) et la forme (*Shp*). Ce modèle permet de calculer la probabilité de cohérence de la forme et de la confiance de classification. Toutefois, si la probabilité est inférieure à un seuil ($\prod P_t^{Conf} P_t^{Shp} < 0.7$) alors tout le processus est redémarré ($C^M = 0$) pour reconstruire à nouveau le modèle de position avec une nouvelle série de régions candidates.

L'objectif principal de notre méthode est d'exploiter l'évolution temporelle de la structure du nerf dans une séquence d'images US. La méthode proposée est basée sur l'analyse de la cohérence temporelle de position, la forme et la confiance de classification afin de construire un modèle adaptatif *on-line*. Cette méthode est capable de gérer la variation d'un environnement anatomique du nerf dans une séquence d'images US.

4.3 Méthode de la détection du nerf

Dans ce travail, nous proposons une méthode de détection du nerf trame par trame dans une séquence d'images US successives, en se basant sur l'apprentissage *on-line* et la mesure de qualité de détection. Les étapes formulant le processus adopté sont les suivantes :

- Régions générées par SVM : calculer les informations reliées aux régions prédites en se basant sur l'aspect spatial, ces informations sont :
 1. La mesure de confiance de classification : cette mesure est calculée à partir de la distance entre l'hyperplan H du classificateur SVM et le vecteur de caractéristiques d'une région v .
 2. L'amplitude (η^t) et la direction (ϕ^t) sont calculées à partir des coordonnées (x_t, y_t) des régions candidates R_t^{SVM} dans la trame t .
 3. Un vecteur de points (Shp) représentant le contour de la forme du nerf. L'algorithme de PGVF est appliqué pour segmenter le contour des régions candidates.
- Le modèle position : le modèle de Gaussienne Généralisée (GG) *on-line* est calculé à partir du moment où une cohérence des positions des régions candidates est trouvée, en calculant les éléments suivants :
 1. La moyenne d'amplitude ($\hat{\eta}$) et sa variance (σ_η).
 2. La moyenne de direction ($\hat{\phi}$) et sa variance (σ_ϕ).
 3. Le paramètre de forme de la GG.
- La mesure de qualité de détection : Cette mesure est calculée à partir d'un modèle *a priori* basé sur les caractéristiques de la forme et de la confiance de classification de la région candidate sélectionnée par l'étape précédente, cette procédure est basée sur deux principes :
 1. Mesurer la qualité de la détection en utilisant le modèle bayésien naïf :

$$P(L^t) = \prod_q P^q \quad (4.1)$$

où $L^t = \{L^1 \dots L^n\}$ sont les régions candidates pour la trame t , calculées à partir de l'étape 1, P^q avec $q = \{Shp, conf\}$ représente les probabilités de la forme (Shp) et de la confiance de classification ($conf$) de la région L^t .

2. Reconstruire le modèle *on-line* dans le cas où $P(L^t) < 0.7$.

4.3.1 Modèle de position dans le temps

Les experts anesthésistes utilisent le mappage visuel de l'anatomie pour localiser le nerf lors d'une procédure d'ALR écho-guidée. La relation entre l'aspect visuel des tissus anatomiques et leurs formes géométriques dans une séquence d'images US est souvent utilisée pour obtenir une localisation visuelle confiante du nerf. Le principe de notre méthode est basé sur la prise en compte

du comportement des experts anesthésistes pour localiser le nerf lors d’une exécution d’ALR écho-guidée. Ainsi, nous avons adopté ce concept en vue d’accroître la fiabilité et la précision de la détection, en nous intéressant à la cohérence dynamique des tissus nerveux au cours du temps.

Dans la pratique d’ALR écho-guidée, la position du nerf dans toute une séquence d’images varie visuellement selon la manipulation de la sonde. Par exemple, la Figure 4.5 montre un exemple de variation des positions de trois régions candidates obtenues lors de l’étape de la région candidate.

Toutefois, la position du nerf dans un petit intervalle de trames successives respecte une certaine trajectoire moins variée, comme on peut voir dans la Figure 4.5, où les intervalles de trames $20 - > 76$, $128 - > 166$ et $241 - > 259$ offre des positions du nerf plus ou moins stables.




FIGURE 4.5 – Exemple de cinq positions des régions générées par SVM (RC) du nerf dans le temps sélectionnées par l’étape 1 de la méthode proposée

De plus, dans la Figure 4.5 nous pouvons observer que les régions générées par SVM R^{SVM2} , R^{SVM3} , R^{SVM4} sont plus stables par rapport au R^{SVM1} et R^{SVM5} , ce qui permet de conclure que la région correspondante au R^{SVM1} et R^{SVM5} ne représente pas les tissus nerveux avec une grande fiabilité.

Afin de trouver cette stabilité de position dans un intervalle de trames successives, nous utilisons l’algorithme 2. Cet algorithme a pour but de détecter les régions candidates de positions cohérentes dans une séquence d’images US, la direction (η_k^t) et l’amplitude (ϕ_k^t) pour les k instances de SVM et les trames t sont calculées pour chaque position des régions candidates (x_k^t, y_k^t) .

Ensuite, dans le cas où la cohérence de position n'a pas atteint le seuil souhaité ($\sigma(\eta^1 \dots \eta^n, \phi^1 \dots \phi^n) > \epsilon$) alors le nombre de trames est augmenté pour récupérer plus de régions candidates. Cet algorithme s'arrête quand la cohérence souhaitée est trouvée.

Algorithm 2: L'algorithme utilisé pour trouver l'ensemble des positions cohérentes

```

1  $N = 10$ ; le nombre initial de trames pour construire un modèle dynamique
2 while  $t < N$  do
3   1- Calculer la norme  $\eta_k^t$  et l'angle  $\phi_k^t$  des position des régions candidates  $(x_k^t, y_k^t)$ .
4   2- Charger la confiance de classification ( $Conf_t^k$ ) et la forme ( $Shp_t^k$ ) appropriée à la
      position  $(x_k^t, y_k^t)$  associée à la trame  $t$  et l'instance SVM  $k$ .
5    $t++$ ;
6   if  $t > N$  et  $(\sigma(\eta^1 \dots \eta^n, \phi^1 \dots \phi^n)) < \epsilon$  then
7     | Sélectionner l'ensemble des positions cohérentes pour générer le modèle on-line.
8   if  $t > N$  et  $(\sigma(\eta^1 \dots \eta^n, \phi^1 \dots \phi^n)) > \epsilon$  then
9     |  $N++$ 

```

Une fois la cohérence de position atteint son seuil de stabilité, nous sélectionnons seulement les coordonnées des régions avec une certaine cohérence dans le temps. Cette sélection est basée sur l'intersection spatio-temporelle des régions candidates comme illustré dans l'équation suivante :

$$\bigcap_{t=1}^T \left(\bigcap_{k=1}^N L(t, k) \right), \quad (4.2)$$

où $L(t, k)$ représente l'emplacement d'une région par rapport à l'instance SVM k et la trame t .

Une fois les positions sélectionnées, le modèle *online* est construit, en calculant les paramètres du modèle gaussien généralisé. Ensuite ce modèle est utilisé pour prédire la région du nerf. Cette prédiction est basée sur la probabilité d'appartenance des régions candidates à ce modèle de position.

Le modèle de position au cours du temps est basé sur trois paramètres; la moyenne μ^p , la variance σ^p et le paramètre de forme β^{pos} . Nous avons analysé l'évolution de chaque paramètre des modèles sur 300 trames afin de montrer l'apport de la proposition du modèle *on-line* et adaptatif adopté dans ce travail (voir Figure 4.6).

Les Figures 4.6a, 4.6b, 4.6c illustrent le résultat de la première étape (recherche des régions candidates) de notre méthode sur trois séquences d'images US. Dans ces figures, nous constatons que certaines positions des régions candidates suivent des trajectoires données, dans un intervalle de temps donné. Cependant, dans une seule séquence d'images, plusieurs distributions peuvent être adaptées à ces données. Afin de trouver les différentes distributions dans une séquence d'images, nous avons proposé un modèle de position adaptatif capable de s'adapter à plusieurs distributions dans une seule séquence d'images où la mesure de cohérence est utilisée comme déclencheur de la construction du modèle. Le modèle gaussien généralisé est utilisé pour représenter les différentes distributions d'ensembles de mesures de directions (η^t) et d'amplitudes (ϕ_k^t). Ce modèle est utilisé




FIGURE 4.6 – Illustration des paramètres du modèle de positions (moyenne (μ^p), variance (σ^p) et précision du modèle (β^{pos})) dans le temps pour trois séquences d'images US.

pour sa capacité à couvrir une grande variété de comportements statistiques. L'expression analytique de la Distribution GG (GGD) considérée dans notre approche pour modéliser la direction ($P^{pos}(\phi)$) et l'amplitude ($P^{pos}(\eta)$) est donnée comme suit :

$$P^{pos}(X) = \frac{\beta^{pos}}{2\alpha\Gamma(\frac{1}{\beta^{pos}})} \times \exp\left(-\frac{|X - \mu|}{\alpha}\right)^{\beta^{pos}} \quad (4.3)$$

où $X = \{\eta \text{ ou } \phi\}$, $\Gamma(\cdot)$ est la fonction gamma ($\Gamma(z) = \int_0^\infty e^{-t} t^{z-1} dt$), le terme μ , α et β^{pos} sont respectivement, la moyenne, l'échelle et le paramètre de forme de la distribution pour l'amplitude (η) et la direction (ϕ), et $\alpha = \sigma \sqrt{\Gamma(1/\beta^{pos})/\Gamma(3/\beta^{pos})}$. la moyenne (μ) et la variance (σ) peuvent être obtenues par la moyenne et la variance des mesures η et ϕ dans le temps. Le paramètre de forme β^{pos} détermine le type de distribution en se basant sur les distances entre les n positions les plus compactes (l_c^n) choisies par l'algorithme 2 par rapport à leur centroïde U_c . Par ailleurs comme β^{pos} manipule la forme de la distribution, il est considéré comme un paramètre de précision. β^{pos} mesure la densité de compactage des positions choisies par l'équation suivante :

$$\beta^{pos} = \frac{1}{2 \times \hat{d}(U_c, l_c^n)} \quad (4.4)$$

où $\hat{d}$ est la moyenne des distances entre U_c et n positions (l_c).

En effet, le modèle de position est représenté par trois paramètres (i.e $\mu^p, \sigma^p, \beta^{pos}$). Comme montré dans les Figure 4.6d, 4.6g, 4.6j, μ^p, σ^p et β^{pos} sont calculés sur plusieurs intervalles de temps. Par exemple dans la première séquence d'images ($v1$), le modèle a été reconstruit 5 fois (i.e. modèle : trames 1 $\rightarrow$ 10 || détection : trames 11 $\rightarrow$ 179, modèle : trames 180 $\rightarrow$ 210 || détection : trames 211 $\rightarrow$ 224 ...). Dans la Figure 4.6a, l'intervalle constituant les trames 1 $\rightarrow$ 10, nous remarquons une certaine cohérence de position dans le temps, ce qui implique les calculs des paramètres μ^p et σ^p (voir la figure 4.6d et la figure 4.6g). D'autre part, β^{pos} représente la précision attribuée au modèle de position selon la cohérence de la position dans le temps. Dans les Figures 4.6j, 4.6k, 4.6l, la valeur de β^{pos} dépendent de la cohérence des positions des régions candidates dans les séquences d'images (voir les Figures 4.6a, 4.6b, 4.6c). Plus les positions sont compactes plus la précision du modèle (β^{pos}) est élevée. Ceci dit pour la séquence d'images 3 ($v3$), il est très difficile d'observer une quelconque trajectoire dans le temps (voir Figure 4.6c). Pour cette raison, le modèle a été construit 13 fois dans une seule séquence d'images (voir les Figures 4.6f, 4.6i, 4.6l). D'après notre observation, le modèle que nous avons proposé est capable de s'adapter à n'importe quel scénario dans une séquence d'images US du nerf.

Le modèle de position est représenté par les paramètres μ , α et β^{pos} . Une fois ces paramètres calculés, le modèle est ensuite utilisé pour prédire les régions candidates du nerf dans les trames à venir. À chaque fois que le modèle de position est calculé, l'équation 4.3 est utilisée pour calculer la probabilité d'appartenance ($P^{pos}(X)$) de chaque région candidate k du nerf (voir Figures 4.6m, 4.6n, 4.6o). Une fois que $P_k(\phi)$ et $P_k(\eta)$ sont obtenues, la probabilité de localisation finale du nerf est calculée à partir du produit entre les deux probabilités ($\prod P_k(\phi)P_k(\eta)$), ensuite le maximum de la probabilité est utilisé pour prédire la région candidate k qui correspond au

$\text{nerf}(\text{argmax}_{k=1}^n (\prod P_k(\phi)P_k(\eta)))$. Cependant, une fois que toutes les régions candidates deviennent incohérentes dans le temps ($\prod P_k(\phi)P_k(\eta) < 0.7$), l'algorithme reconstruit un nouveau modèle en collectant de nouvelles régions candidates.

4.3.2 Mesure de qualité de détection

La détection du nerf dans les séquences d'images US pour l'ALR écho-guidée est un problème complexe en raison de la sensibilité de cette procédure. La mauvaise détection du nerf peut entraîner des complications graves lors de l'ALR. Pour cette raison une étape de confirmation de détection est essentiel pour une détection performante et sans risque. Dans ce sens, nous proposons une méthode de mesure de performance de détection au fil du temps, afin de fournir à la fois une détection précise et une correction de la détection après une dérive. Cette étape est basée non seulement sur la cohérence de la forme, mais aussi sur la cohérence de la confiance de classification dans le temps, toutes les deux associées aux régions candidates sélectionnées.

Dans l'étape de régions générées par SVM de la méthode proposée, les positions sélectionnées (x^t, y^t) dans le temps sont accompagnées par leurs confiances de classification (rappel : les valeurs les plus élevées des confiances de classification dans une image sont sélectionnées) et formes, ensuite le modèle de position est utilisé pour prédire la région candidate correspondant au nerf. Une fois la région R_t^{SVMk} est prédite pour la trame t , ça k -ième instance SVM est sélectionnée, afin de récupérer les formes et confiance de classification de l'ensemble des régions associé à l'instance SVM k pour les trames précédentes. Ensuite, un modèle avec une connaissance préalable des informations de la forme et de la confiance de classification au cours du temps est utilisé pour mesurer la qualité de détection de la région candidate. Toutefois, la combinaison brute entre la confiance de classification et la forme peut fournir une mauvaise interprétation. En d'autres termes, dans une séquence d'images US du nerf, ce dernier peut être caractérisé par la cohérence de confiance de classification, par la cohérence de forme ou bien par les deux au même instant. La combinaison de ces deux informations peut être confondue avec d'autres régions dans une image US. Sur la base de cette situation, les fonctions de pondération ont été reformulées pour indiquer l'importance de chaque caractéristiques (confiance de classification et forme) dans le temps. Pour cette raison, le modèle bayésien naïf est utilisé pour mesurer la qualité de détection en se basant sur les deux caractéristiques avec une connaissance *a priori*, l'expression analytique est comme suit :

$$P(L^t) = (\prod_q P^q) \quad (4.5)$$

où la mesure de qualité de détection est basée sur la relation entre les réponses des modèles de forme et de confiance de classification (" $q = \{Shp, conf\}$ ").

Modèle de forme

Les données de forme (*Shp*) sont utilisées pour créer le modèle dynamique de forme. Comme illustré dans la Figure 4.7, plusieurs étapes sont nécessaires pour construire ce modèle de forme. D'abord, l'algorithme PGVF [96] est appliqué à la région candidate pour générer les contours.




FIGURE 4.7 – Processus de détection automatique des intervalles des valeurs des points de repère.

Ensuite, les points de repère sont déterminés automatiquement par un modèle de distribution de points [38]. Dans la troisième étape, les caractéristiques de *shape context* [13] ont été utilisées pour sélectionner uniquement les points de repère qui se correspondent, ensuite ils sont alignés pour diminuer les bruits de rotations et d'échelles des formes.

À notre connaissance, les modèles de forme existants jusqu'à aujourd'hui sont basés sur une valeur numérique pour représenter les points de repère d'un contour. Cependant, étant donné la complexité et la variabilité de la forme dans une séquence d'images US, il est nécessaire de représenter le contour par un intervalle des valeurs des points de repère, afin d'inclure l'incertitude dans la phase de modélisation, ce qui rend le modèle robuste aux variations dans l'étape de reconnaissance. La sélection d'Intervalle des valeurs des Points de Repère (IPR) est dérivée des points de repère élaborés dans l'étape trois de la Figure 4.7, ces valeurs représentent le centre du nouveau IPR. Les extremums de cet intervalle (x_{inf} , x_{sup}) sont représentés par 10% de chaque côté du lien reliant deux centres d'IPR voisins.

Traditionnellement, la distribution des points de repère dans un contour est supposée être une gaussienne. A partir de cette hypothèse, l'analyse en composantes principales (ACP) est l'outil le plus adapté pour construire le modèle de forme, car l'ACP traite seulement les données qui suivent une distribution gaussienne. Néanmoins, une répartition gaussienne est inappropriée pour

approximer les IPRs, due à leurs diversités de distributions dans le temps. Dans ce cas, l'ACP perd énormément d'information de forme dans le temps. Afin d'améliorer la reconnaissance de la forme du nerf dans une séquence d'images US, il nous est apparu plus judicieux de proposer un modèle paramétrique plus général qui serait plus capable de décrire le comportement de la déformation de la forme au cours du temps. C'est pour cette raison que, nous avons considéré dans cette troisième étape un modèle alternatif, capable de couvrir une grande variété de situations. La GGD est particulièrement intéressante, car elle peut gérer une grande variété de distributions, par exemple : Laplacienne, gaussienne et uniforme comme illustré sur la figure 4.8. L'expression




FIGURE 4.8 – Les formes d'une GGD normalisée avec $\mu = 0$, $\sigma = 1$ et la valeur du paramètre de forme β .

analytique de GGD prise en compte dans notre approche pour la modélisation de la forme du nerf dans le temps est la suivante :

$$P^{shp}(Seg) = \frac{\beta^{Shp}}{2\alpha\Gamma(\frac{1}{\beta^{Shp}})} \times \exp\left(-\left|\frac{Seg - \mu}{\alpha}\right|^{\beta^{Shp}}\right) \quad (4.6)$$

où $Seg = (x_{inf}, x_{sup})$ est l'IPR, $\Gamma(\cdot)$ est la fonction gamma, les termes μ , α et β^{Shp} sont respectivement la moyenne, l'échelle et le paramètre de forme de Seg . Dans une GGD, trois paramètres à estimer sont nécessaires : la moyenne (μ), la variance (σ) et le paramètre de forme (β^{Shp}). Soit n points de IPR pour une forme donnée. Cette forme est représentée par deux vecteurs X_{inf} et X_{sup} , où $X_{inf} = (x_{inf}^1, \dots, x_{inf}^n, y_{inf}^1, \dots, y_{inf}^n)^T$, et $X_{sup} = (x_{sup}^1, \dots, x_{sup}^n, y_{sup}^1, \dots, y_{sup}^n)^T$. La moyenne ($\mu = \{\mu_{inf}, \mu_{sup}\}$) est donnée par la moyenne de X_{inf} et X_{sup} . Afin de capturer la variation totale dans un IPR, nous avons calculé la covariance S de la même façon que dans ce

travail [251] :

$$S = \begin{pmatrix} \frac{1}{n} \langle X_1, X_1 \rangle & \frac{1}{n} \langle X_1, X_2 \rangle & \dots & \frac{1}{n} \langle X_1, X_m \rangle \\ \frac{1}{n} \langle X_2, X_1 \rangle & \frac{1}{n} \langle X_2, X_2 \rangle & \dots & \frac{1}{n} \langle X_2, X_m \rangle \\ \vdots & \vdots & \ddots & \vdots \\ \frac{1}{n} \langle X_p, X_1 \rangle & \frac{1}{n} \langle X_p, X_2 \rangle & \dots & \frac{1}{n} \langle X_p, X_m \rangle \end{pmatrix} \quad (4.7)$$

où

$$\begin{cases} X_j = ([X_{inf}^{1j}, X_{sup}^{1j}], [X_{inf}^{2j}, X_{sup}^{2j}], \dots, [X_{inf}^{nj}, X_{sup}^{nj}])^T \\ X_o = ([X_{inf}^{1k}, X_{sup}^{1k}], [X_{inf}^{2k}, X_{sup}^{2k}], \dots, [X_{inf}^{nk}, X_{sup}^{nk}])^T \\ \langle x_{ij}, x_{io} \rangle = \frac{1}{4}(x_{inf}^{ij} + x_{sup}^{ij})(x_{inf}^{io} + x_{sup}^{io}), (j \neq o) \\ \langle x_{ij}, x_{ij} \rangle = \frac{1}{3}((x_{inf}^{ij})^2 + x_{inf}^{ij}x_{sup}^{ij} + (x_{sup}^{ij})^2) \end{cases} \quad (4.8)$$

Les vecteurs propres b_f et les valeurs propres λ_f sont calculées à partir de S , afin de déterminer la variance σ à partir de l'équation $\sigma = b\sqrt{(\lambda_{max})}$.

Dans ce travail nous avons pris un taux de 98% de λ_f et b_f . Le paramètre β^{Shp} est utilisé comme paramètre de précision de la GGD, ce paramètre permet de gérer la précision du modèle de forme. La *GGD* peut représenter différents types de distribution. Par exemple, le GGD forme une distribution Laplacienne lorsque $\beta^{Shp} = 1$, la distribution Gaussienne quand $\beta^{Shp} = 2$ et la distribution Uniforme quand $\beta^{Shp} \rightarrow \infty$. β^{Shp} est estimé selon la cohérence temporelle de la forme selon l'équation suivante :

$$\beta^{Shp} = \frac{1}{\hat{D}_{shape}} \quad (4.9)$$

où $\hat{D}_{shape}$ est la moyenne des distances entre chaque paire de forme successivement dans le temps, où $D_{shape} = \{d_1 \dots d_n\}$. d_t est calculé comme suit :

$$d_t = \frac{1}{3}((x_{inf}^t - \mu_{inf})^2 + (x_{inf}^t - \mu_{inf})(x_{sup}^t - \mu_{sup}) + (x_{sup}^t - \mu_{sup})^2)$$

où d_t est la distance entre chaque IPR de la forme de la trame t et sa moyenne μ .

En effet, Le modèle de la forme contient les paramètres de la moyenne (μ^{Shp}), de la variance (σ^{Shp}) et le paramètre de précision (β^{Shp}). Une fois les paramètres calculés sur un ensemble de formes des régions candidates sélectionnées dans un ensemble de trames successives, la probabilité de reconnaissance de la forme est calculée sur les formes des régions candidates tests pour chaque IPR à partir de l'Equation 4.6 (voir Figure 4.9a, 4.9b, 4.9c).

Dans la Figure 4.9d, 4.9e, 4.9f, plusieurs moyennes de forme ont été calculées automatiquement dans chacune des trois séquences d'images afin de gérer la déformation de la forme du nerf dans le temps. En revanche, l'information de la forme n'est pas omniprésente dans une séquence d'images US. C'est pour cette raison que nous rajoutons les paramètres de précision (β^{Shp}) et de variance (σ^{Shp}) pour chaque IPR du modèle de forme. Les paramètres β^{Shp} et σ^{Shp} sont liés à la cohérence des IPRs dans le temps. En d'autres termes, les deux paramètres contrôlent la déformation de la forme dans le temps. Dans la Figure 4.10 et la Figure 4.11, β^{Shp} et σ^{Shp} associées aux quelques IPRs




FIGURE 4.9 – Illustration des paramètres du modèle de forme dans le temps pour trois séquences d'images.

sont illustrés. La précision (β^{Shp}) ajoutée au modèle permet de contrôler à la fois la puissance du modèle dans le temps mais aussi de sélectionner l'ensemble d'IPR essentielle, par exemple comme illustré dans la Figure 4.10, la précision pour l'IPR numéro 101 de la séquence d'images 1 ($\beta_{v1,Seg101}^{Shp}$) est plus importante que celui des autres. Par conséquent la probabilité de l'IPR 101 est moins négligée que les autres probabilités d'IPRs.

Cohérence de la confiance de prédiction

Le modèle de forme est un atout pour une bonne détection dans une séquence d'images US. Cependant, l'instabilité de l'information de la forme du nerf peut fausser la mesure de la qualité de détection dans le temps. Pour cette raison, la cohérence temporelle de confiance de classification peut renforcer le modèle de forme. Effectivement, une seule caractéristique n'est pas suffisante pour caractériser le nerf dans une séquence d'images US. Le nerf peut être représenté par une ou plusieurs caractéristiques dans une seule séquence d'images US. Pour contourner ces limitations, un modèle à plusieurs caractéristiques peut être robuste à la détection du nerf dans une séquence d'images US. L'objectif d'un tel modèle est de prendre en compte cette variabilité temporelle.

Dans cette étude, les scores de confiance de classification sont obtenus en utilisant la distance entre l'hyperplan H_k appris par le classificateur SVM et les vecteurs des caractéristiques v_k^t . Les scores sont obtenus dans chaque fenêtre coulissante par rapport à l'instance SVM k dans l'étape de régions générées par SVM. Ensuite, nous utilisons la méthode proposée par [246, 202] pour calculer la probabilité qu'une donnée v_k^t appartienne à une classe particulière. Fondamentalement,




FIGURE 4.10 – Illustration de différents poids des IPRs dans le temps.





FIGURE 4.11 – Illustration de différentes variations des IPRs dans le temps.

FIGURE 4.12 – Filtrage de bruit du signal $Conf(t)$

[246, 202] suggèrent d'utiliser une forme paramétrique d'une sigmoïde pour calculer la probabilité *a posteriori* de la confiance de classification :

$$P^{Conf}(X) = \frac{\omega^{conf}}{1+e^{-(X)}} \quad \text{avec} \quad X = Conf(L) \quad (4.10)$$

Ici, $P^{Conf}(X)$ est la probabilité d'appartenance d'une région (L) à la classe nerf, et $Conf(L)$ est la distance entre les caractéristiques de L et l'hyperplan du SVM appris H'' . ω^{conf} est le poids attribué à ce modèle au cours du temps, en calculant le gradient moyen de la confiance de classification dans le temps ($Conf(L_t)$) (voir Equation 4.11).

$$\omega^{conf} = \frac{1}{T} \sum_{t=1}^T \nabla LPConf(L_t), \quad (4.11)$$

où $LPConf(L_t)$ est le $Conf(L_t)$ débruité. Afin de supprimer le bruit de la courbe $Conf(L_t)$, nous avons appliqué un filtre passe-bas en utilisant la transformée de Fourier, la Figure 4.12 montre la courbe de $Conf(L_t)$ et la courbe après filtrage $LPConf(L_t)$. La qualité de la détection est calculée à partir de la combinaison de deux modèles ; celui de la forme et celui de la confiance de classification, sachant que le modèle bayésien naïf permet de combiner ces deux caractéristiques. Cependant, comme pour le modèle de la forme, un poids ω^{conf} est rajouté au modèle de confiance de classification afin d'augmenter ou diminuer l'importance de ce modèle par rapport au modèle de la forme (voir Figure 4.13). Par exemple dans la séquence d'images 1 ($v1$) le poids du modèle de confiance de classification est moins important que celui de la forme (voir Figure 4.13d). Dans un autre cas, le nerf est plus représenté par la forme que par la confiance de classification, ceci est montré dans la Figure 4.13e à partir de la trame 80 jusqu'à la trame 160. Le modèle que nous proposons est capable de s'adapter aux différentes représentations du nerf que ce soit la forme ou la confiance de classification.




FIGURE 4.13 – Illustration des paramètres du modèle de confiance de classification pour trois séquences d'images.

4.4 Résultats

Des séquences d'images sonographiques du nerf médian ont été obtenues de 20 patients (voir Section 1.5 pour plus de détails). Dans ces expériences, environ 700 trames ont été extraites à partir de chaque séquence d'images. Ces expériences visent à étudier la robustesse de notre méthode de détection, en évaluant sa fiabilité, et à la comparer avec les méthodes existantes dans la littérature. Nous avons utilisé le F-score pour déterminer le taux de détection dans une séquence d'images et les métriques de Dice et Hausdorff pour l'évaluation de la segmentation.

Pour avoir une estimation quantitative globale de notre méthode, nous avons étudié l'influence de chaque partie de la méthode proposée (i.e région candidat cible (CC), CC + modèle de position (MP), CC + MP + mesure de qualité de détection (méthode proposée). Nous avons aussi comparé la méthode proposée avec les travaux connus sur la détection du nerf dans les images US [96] (voir Table 4.1). La Table 4.1 présente la précision de localisation en termes de moyenne et d'écart type (i.e. $\mu \pm \sigma$) sur tous les f-scores obtenues.

TABLE 4.1 – Résultats de localisation et de segmentation pour différentes techniques.

Méthodes	F-score	Dice	Hausdorff
[96]	0.74±0.25	0.72±0.30	31.90± 29.65
CC	0.76±0.17	0.78±0.08	27.06±12.98
CC+MP	0.81±0.05	0.76±0.02	34.06±32.81
CC+MP+forme	0.86±0.05	0.83±0.07	28.12±23.46
Méthode proposée	0.90±0.07	0.81±0.09	29.38±12.94

Quantitativement, la méthode proposée dans [96] produit un résultat de 74% de f-score. Cependant, la méthode CC proposée dans [93] donne un résultat meilleur avec 76% de f-score. Dans cette méthode, le vote effectué sur les régions candidates est basé sur la valeur de confiance de classification.

En revanche, la détection basée sur le modèle de position améliore nettement le résultat avec f-score de 81% tandis que l'ajout d'une étape de mesure de qualité de détection assure à la fois le contrôle permanent de la localisation et une détection robuste dans une séquence d'images US avec un résultat de f-score de 90%.

Grâce aux poids attribués aux modèles de forme et de confiance de classification selon leurs cohérence temporelle, les caractéristiques essentielles sont captés malgré la variation morphologique de la structure du nerf dans une séquence d'images US. Ainsi la différence de f-score entre CC+MP+forme et la méthode proposée en prenant en compte la combinaison des caractéristiques de forme et de confiance de classification est de 4%.

TABLE 4.2 – Résultats de localisation et segmentation pour différents modèles de formes rajoutés à la méthode proposée.

Méthodes	F-score
PR+ACP	0.83±0.04
IPR+GGD	0.90±0.07

Le résultat de la détection est lié aussi au choix du modèle de forme basé sur un intervalle des valeurs des points de repère (IPR) et un modèle à base de GGD. En effet, nous observons dans la Table 4.2, les erreurs de reconnaissance de forme, dues sans doute à la représentation des contours par des points de repères, incapable de gérer la variation morphologique de la forme dans les séquences d'images US. De plus, le modèle ACP ne s'adapte pas entièrement à la distribution des données constituant la déformation de la forme dans le temps (PR+ACP → 83%). Pour cette raison, nous avons utilisé des IPRs pour rajouter l'incertitude au modèle afin de gérer la variation de la forme dans un environnement bruité. D'ailleurs le modèle de forme basée GGD est utilisé pour s'adapter non seulement aux données représentant la forme dans le temps mais encore pour prendre en considération l'incertitude rajoutée par les IPRs, où le modèle est capable de trouver ces incertitudes dans l'étape de reconnaissance (IPR+GGD → 90%).

Ces expériences ont montré que la combinaison des modèles de position, de forme et de confiance de classification produit de bien meilleurs résultats de localisation. Cependant, dans certaines séquences d'images comme la 11 et 13 dans Table 4.3, le résultat est peu convaincant. Ce mauvais résultat est dû à l'attachement du nerf aux tissus de dermi (la peau) dans les premières trames, c'est pourquoi notre méthode est incapable de différencier les textures des tissus nerveux et de dermis.

TABLE 4.3 – Résultats de localisation et de segmentation obtenus expérimentalement dans le cadre de l’approche proposée pour différentes séquences d’images.

Séquences d’images	F-score	Dice	Hausdorff
1	0.98±0.02	0.79± 0.09	38.06±14.46
2	0.97±0.06	0.90±0.04	17.13± 8.40
3	0.99±0.04	0.86±0.06	23.67±10.26
4	0.93±0.05	0.78± 0.15	30.92± 10.38
5	0.88±0.05	0.78± 0.11	40.04± 20.37
6	0.96±0.01	0.75± 0.12	35.41± 20.61
7	0.87±0.08	0.85±0.074	25.12±13.74
8	0.98±0.07	0.76± 0.13	32.05±13.42
9	0.98±0.01	0.79± 0.14	32.12± 18.59
10	1±0	0.93±0.03	14.03±8.36
11	0.75±0.23	0.83±0.06	32.64±13.11
12	0.99±0.05	0.65±0.19	33.76±11.79
13	0.76±0.12	0.80±0.14	36.74± 11.34
14	0.83±0.09	0.93±0.04	17.31±6.46
15	0.78±0.18	0.84±0.06	32.84± 12.82

4.5 Contributions

La méthode présentée dans ce chapitre permet d’avoir une détection fiable et robuste du nerf dans une séquence d’images US. Les principales contributions de cette méthode sont les suivantes :

- (1) Modèle adaptative *on-line* : Généralement, un ensemble de donnée fixe est utilisé comme un ensemble d’apprentissage. Cependant, les informations du nerf comme la texture, la forme, l’échelle et la rotation varient d’une façon considérable dans une séquence d’images US à une autre, dû aux conditions d’interaction des ultrasons. Par conséquent, une stratégie de modélisation adaptative est nécessaire pour des données variables dans le temps. Compte tenu de cette hypothèse, ce travail accorde une importance à la création d’un modèle *on-line* capable de détecter le nerf dans un environnement non-stable.
- (2) Les paramètres estimés en fonction de la cohérence temporelle : traditionnellement dans la littérature les données utilisées pour la détection d’objet dans les images médicales sont supposées suivre une distribution gaussienne dans le temps. En revanche, cette supposition n’est pas entièrement juste, car la distribution gaussienne est une approximation du comportement des données dans une séquence d’images. Cette situation peut entraîner une perte considérable d’information, particulièrement dans les images US, où les pixels peuvent suivre différentes distributions dans le temps. Pour remédier à cette problématique, la GGD peut être employée afin de caractériser le comportement des données variables. Effectivement, la GGD peut estimer les différentes distribution que ce soit une gaussienne, laplacienne ou uniforme. Dans ce sens, la GGD a été utilisée pour représenter le modèle de position et de forme, où la cohérence temporelle est utilisée pour estimer les paramètres de ces modèles.
- (3) Intervalle des valeurs des points de repère pour le modèle dynamique de forme : le modèle

de forme est souvent utilisé soit comme un outil d'analyse des données de forme ou pour la construction de modèle prédictive. Le modèle de forme est généralement basé sur des valeurs de points de repères pour représenter un contour et l'analyse des composantes principales (ACP) pour générer un modèle de forme. Cependant, la forme du nerf a différents aspects visuels dans le temps, en raison de la manipulation de la sonde. L'utilisation points de repères peut brouiller la représentation d'une forme dans les images US. Ainsi nous proposons un intervalle (segment) de points de repères pour libérer la contrainte de forme statique. L'intervalle des valeurs des points de repère rajoute une incertitude pour éviter la dégénération de la phase d'apprentissage *on-line*. Afin de réaliser ce modèle de forme en fonction des intervalles des valeurs des points de repères, nous utilisons la GGD pour inclure l'incertitude dans le modèle de forme.

Dans l'ensemble, ces contributions sont utilisées dans un cadre unifié pour la première fois dans la littérature, afin de relever le défi de détection du nerf dans une séquence d'images US.

4.6 Conclusion

Un nouveau schéma de détection du nerf dans une séquence d'images US basé sur la combinaison à base de connaissance préalable des modèles de positions dans le temps, de forme et de confiance de classification a été proposé. Notre méthode est plus robuste aux variations de la texture et de la forme présentes dans une séquence d'images US, par rapport aux travaux existants dans la littérature. La méthode proposée a montré des résultats prometteurs mais néanmoins l'algorithme de localisation doit être validé sur une base de données plus large. Par ailleurs, l'algorithme de segmentation devra être amélioré pour obtenir une segmentation après localisation plus robuste.

4.6. CONCLUSION

Chapitre 5

Conclusion

Dans ce dernier chapitre un résumé de la thèse est exposé. Nous présentons nos conclusions et nous donnons un aperçu des perspectives. D'autre part, une liste des publications liées à cette thèse est donnée.

5.1 Récapitulatif de la thèse

Le principal objectif de cette thèse est de fournir un algorithme robuste et efficace pour la détection du nerf dans les images échographiques. Ce travail prouve la faisabilité d'un système d'aide aux praticiens de l'anesthésie locorégionale écho-guidée. Les algorithmes développés pour la détection du nerf médian sont plus efficaces comparés aux travaux existants dans la littérature et les méthodes traditionnelles.

Dans cette thèse, une étude des méthodes de segmentation dans les images US a été réalisée. L'analyse de ces méthodes a révélé que les méthodes hybrides (localisation et segmentation) sont les mieux adaptées dans les images US. Pour la localisation, les méthodes de détection assistées par ordinateur proposent des solutions intéressantes à partir de la combinaison de plusieurs étapes : dé-bruitage, extraction et sélection des caractéristiques, classification. Cependant, l'efficacité de ces méthodes est fortement liée au choix des techniques mises en oeuvre à chaque étape de la chaîne de traitement. En conséquence, une étude approfondie des techniques utilisées a été élaborée. Ce travail a permis de proposer d'une part, un nouveau descripteur basé sur les motifs de texture et le filtre fréquentiel et d'autre part, un nouvel algorithme de sélection de caractéristiques basé sur la combinaison de méthodes à base de filtres et d'apprentissage. Précisons que la qualité de l'image US est affectée par le bruit et les artefacts. Pour faire face à ces inconvénients, nous avons proposé un descripteur de texture basé sur un filtre de Gabor appliqué sur les éléments obtenus à partir de la méthode dite Motif Médian Binaire (MBP). Cette proposition résulte des observations suivantes : nous avons constaté que le filtre de Gabor seul réduit efficacement le bruit. Néanmoins, les méthodes fréquentielles en général ne sont pas propices à caractériser la structure du nerf. C'est

pour cela que nous proposons d'utiliser conjointement le descripteur MBP et le filtre de Gabor, afin de contribuer plus efficacement à la réduction du bruit et à la préservation de la texture du nerf. Par ailleurs, pour réduire les caractéristiques de textures redondantes et sélectionner les plus pertinentes, nous proposons un nouvel algorithme de sélection de caractéristiques. Cet algorithme répond à la fois au besoin de réaliser une classification, en s'appuyant ici sur des méthodes à base de filtres et aussi à celui de performance dans le choix des classes, rendu possible ici grâce à l'évaluation des sous-ensembles de caractéristiques obtenus.

Dans le contexte très particulier des séquences US où les nerfs et les tissus anatomiques environnants présentent des variations morphologiques très variées, il nous a semblé essentiel de proposer un nouvel outil afin de faciliter et améliorer le processus de détection automatique. Pour cela, nous proposons un traitement se décomposant en deux étapes. Au cours de la première étape, nous ajoutons à la méthode décrite au paragraphe précédent, un modèle adaptative "on line" basé sur la connaissance de trajectoire du nerf dans le temps. Puis lors de la seconde étape, pour assurer une détection performante, nous prenons en compte une mesure de la qualité de détection obtenue sur la base de deux propriétés : la forme obtenue et la confiance de classification atteinte. Ce traitement supplémentaire est utile pour corriger la détection lorsqu'une erreur de reconnaissance apparaît. La combinaison de ces deux caractéristiques est établie par un modèle dit "naïve bayésien" avec une connaissance préalable. Une pondération étant affectée à chaque caractéristique, chaque poids est estimé selon la cohérence de la forme et la confiance de la classification au cours du temps. Sachant que les techniques plus anciennes comme le modèle de forme statistique, sont incapables de représenter la forme du nerf dans le temps en raison des déformations du nerf dans une vidéo US, nous avons proposé un nouveau modèle de forme basé sur un ensemble d'intervalles de points de repères représentant un contour afin de rajouter l'incertitude au modèle d'apprentissage. L'ajout de cette information permet de prendre en compte la variabilité de la forme dans le temps.

D'une manière générale, une distribution gaussienne est utilisée pour représenter une forme basée sur des valeurs de points de repères. D'ailleurs l'ACP est souvent consacrée pour calculer les paramètres de cette distribution. Cependant, l'ACP s'adapte seulement aux données qui suivent une distribution gaussienne. Dans notre cas de figure, la forme est basée sur un ensemble d'intervalles de points de repères. Pour cette raison, nous avons utilisé un modèle à base de gaussiennes généralisées, afin d'éviter la perte d'information, où les paramètres de ce modèle sont estimés à partir des méthodes adaptées aux données d'intervalles. L'avantage de ce type de modèle est qu'il prends en compte plus d'informations, ce qui nous permet finalement d'obtenir un modèle de forme capable de s'adapter aux déformations du nerf présent dans la vidéo US.

5.2 Contribution

Dans cette section, nous résumons la contribution de cette thèse :

- L'anesthésie locorégionale écho-guidée a été étudiée pour comprendre les problèmes rencontrés lors de la localisation visuelle du nerf par les praticiens. Ensuite une analyse sur la physique de l'ultrason et la structure anatomique du nerf a été effectuée pour découvrir les vrais défis de la détection du nerf dans les images échographiques.
- Une étude des méthodes de segmentation des régions d'intérêt dans les images échographiques a été effectuée. Une taxonomie sur les approches théoriques et leurs application, a été définie pour illustrer les avantages et inconvénients de chacune d'elles. Une discussion sur le choix de la stratégie de détection du nerf la plus appropriée est exposée. Nous avons pu conclure avec cette étude bibliographique que les méthodes hybrides basées sur une machine d'apprentissage et les modèles déformables sont les plus adaptées à la problématique de détection du nerf dans les images US.
- Suite à cela, nous avons pu proposer un nouveau système de détection assisté par ordinateur a été proposé pour la détection du nerf. Cette méthode est basée sur une chaîne de traitements constitués de 5 étapes principales : filtrage, extraction, sélection de caractéristiques, classification et segmentation. Une étude comparative de chaque étape du système nous a permis à la fois de déterminer les techniques les plus appropriées au bruit et artefact dans les images US du nerf et de proposer un descripteur et un algorithme de sélection mieux adaptés à la structure du nerf.
- Une nouvelle méthode basée sur des modèles en ligne et adaptatives a été proposée pour détecter le nerf dans une vidéo US. Trois modèles ont été élaborés (i.e position, forme et confiance de classification). Cette méthode est basée sur la cohérence temporelle pour déterminer la priorité du modèle pour représenter le nerf.
- Un nouveau modèle de forme basé sur un ensemble d'intervalles de points de repères a été proposé pour gérer la variation morphologique de la forme dans le temps.

5.3 Perspectives

Dans cette thèse, nous avons étudié diverses solutions qui ont été décrites en détail. Cependant, un nombre important d'idées demeurent non-exploitées et devront être analysées et étudiées en détail. Les orientations futures envisagées pour une suite possible peuvent se décliner selon les actions suivantes :

- Optimiser l'algorithme de segmentation pour diminuer le temps de calcul.
- Exploiter l'information spatio-temporelle en utilisant des algorithmes de suivi d'objets.
- Tirer profit des méthodes à base d'atlas pour générer une carte de distance entre les tissus nerveuse et les autres tissus.
- Collecter plusieurs bases de données de différents blocs nerveux.
- Se servir des résultats de la détection pour planifier l'asservissement de l'aiguille.

5.3.1 Optimisation et amélioration de l'algorithme de segmentation

Dans cette thèse, Nous avons adopté l'apprentissage supervisé sur les fenêtres coulissantes avec l'outil SVM pour une classification robuste de la région du nerf dans les images US. Cette étape est coûteuse en termes de temps et pénalise aujourd'hui son utilisation. Cependant, la parallélisation des algorithmes proposés sur plateforme GPU serait une réponse efficace pour voir émerger une solution acceptable pour un usage temps réel.

La problématique de la détection du nerf peut être traitée sous différentes approches. Effectivement, la problématique de suivi de contour et les méthodes à base d'atlas peuvent améliorer la précision de détection et diminuer considérablement le temps de calcul. D'une part, la détection du nerf par nos méthodes pourra être utilisée pour initialiser et rectifier la détection par les algorithmes de suivis de contours en utilisant les filtres particuliers, ce qui réduit le coût de calcul. D'autre part, les méthodes à base d'atlas peuvent être aussi utilisées pour sélectionner au départ la région d'intérêt du nerf en se basant sur une carte de distance entre les tissus nerveux, les vaisseaux sanguins et l'os.

5.4 Ligne de recherches dérivées de cette thèse

Le deuxième groupe de perspectives se concentre sur le développement de nouvelles directions de recherche dérivées de cette thèse. Nous pensons que l'orientation principale de cette recherche devrait être cadrée pour l'optimisation des algorithmes de segmentations du nerf dans les vidéos US et l'implémentation d'un système complet (robotique et traitement d'image) pour assister les praticiens durant l'ALR. De plus, le déploiement de notre algorithme dans les instituts hospitaliers va permettre de collecter une large base de données. En effet, nous nous attendons à ce que l'utilisation d'une plus grande base de données d'apprentissage, améliore considérablement les précisions de segmentation compte tenu de l'apprentissage préalable des paramètres d'apparence et de forme adoptés dans notre algorithme. Dans ce sens, notre équipe a commencé le développement d'une technique de génération de trajectoire pour guider l'aiguille lors de la procédure d'UGRA. Effectivement, en affichant la région du nerf et un chemin sûr de l'aiguille, l'anesthésiste se concentrera davantage sur la manipulation de l'aiguille au lieu de gérer la détection visuelle du nerf. Pour établir un tel système, on peut identifier deux étapes critiques ; premièrement, la reconnaissance des structures anatomiques établies par notre méthode afin de gérer la détection de la cible (nerfs) et les obstacles (vaisseaux sanguins) ; deuxièmement, l'algorithme de génération du chemin de l'aiguille établie par notre équipe pour atteindre en toute sécurité la cible afin d'administrer le liquide anesthésique.

5.5 Publications associées

Une liste de publication de l'équipe est donnée ci-dessous :

- [IJESA2016] Oussama Hadjerci, Adel Hafiane, Nicolas Morette, Cyril Novales, Pierre Vieyres, Alain Delbos, Assistive system based on nerve detection and needle navigation in ultrasound images for regional anesthesia, Expert Systems with Applications, Volume 61, 1 November 2016, Pages 64 – 77, ISSN 0957 – 4174, [http : //dx.doi.org/10.1016/j.eswa.2016.05.002](http://dx.doi.org/10.1016/j.eswa.2016.05.002).
- [IJIMU2016] Oussama Hadjerci, Adel Hafiane, Donatello Conte, Pascal Makris, Pierre Vieyres, Alain Delbos, Computer-aided detection system for nerve identification using ultrasound images : A comparative study, Informatics in Medicine Unlocked, Volume 3, 2016, Pages 29 – 43, ISSN 2352 – 9148, [http : //dx.doi.org/10.1016/j.imu.2016.06.003](http://dx.doi.org/10.1016/j.imu.2016.06.003).
- [ICIP2016] Oussama Hadjerci, Adel Hafiane, Pierre Vieyres, Donatello Conte, Pascal Makris and Alain Delbos, "On-line learning dynamic models for nerve detection in ultrasound videos," 2016 IEEE International Conference on Image Processing, Phoenix, AZ, USA, 2016, pp. 131 – 135, *doi* : 10.1109/ICIP.2016.7532333.
- [ICIP2015] Oussama Hadjerci, Adel Hafiane, Donatello Conte, Pascal Makris, Pierre Vieyres, Alain Delbos, "Ultrasound median nerve localization by classification based on despeckle filtering and feature selection," Image Processing, 2015 IEEE International Conference on, Quebec City, QC, 2015, pp. 4155 – 4159, *doi* : 10.1109/ICIP.2015.7351588.
- [ICIAP2015] Oussama Hadjerci, Adel Hafiane, Pascal Makris, Donatello Conte, Pierre Vieyres, Alain Delbos : Nerve Localization by Machine Learning Framework with New Feature Selection Algorithm. International Conference on Image Analysis and Processing (1) 2015 : 246-256.
- [ICIAR2014] Oussama Hadjerci, Adel Hafiane, Pascal Makris, Donatello Conte, Pierre Vieyres, Alain Delbos : Nerve Detection in Ultrasound Images Using Median Gabor Binary Pattern. International Conference on Image Analysis and Recognition (2) 2014 : 132-140.
- [SURGETICA2014] Nicolas Morette, C. Novles, A. Housni, O.Vieyers, O. Hadjerci, A. Hafiane, "Direct model based needle trajectory generation for ultrasound-guided regional anaesthesia", SURGETICA 2014.

Bibliographie

- [1] Rene G. Aarnink, Sayan Dev Pathak, Jean J.M.C.H. de la Rosette, Frans M.J. Debruyne, Yongmin Kim, and Hessel Wijkstra. Edge detection in prostatic ultrasound images using integrated edge map. *Ultrasonics*, 34 :635–642, 1998.
- [2] Matthew S. Abrahams, Oliver Panzer, Arthur Atchabahian, Jean-Louis Horn, and Anthony R. Brown. Case report : Limitation of local anesthetic spread during ultrasound-guided interscalene block. *Regional anesthesia and pain medicine*, 33(4) :357–359, 2008.
- [3] Scott T. Acton and Nilanjan Ray. *Biomedical Image Analysis : Tracking*. Morgan & Claypool, 2006.
- [4] Ronald S. Adler. The use of compact ultrasound in anesthesia : Friend or foe. *Anesthesia & Analgesia*, 105(6) :1530–1532, 2007.
- [5] N. Ahmed, T. Natarajan, and K. R. Rao. Discrete cosine transform. *IEEE Transactions on Computers*, C-23 :90–93, 1974.
- [6] Timo Ahonen, Jiří Matas, Chu He, and Matti Pietikäinen. Rotation invariant image description with local binary pattern histogram fourier features. In *Proceedings of the 16th Scandinavian Conference on Image Analysis*, pages 61–70, 2009.
- [7] S.M. Ali and R.E. Burge. New automatic techniques for smoothing and segmenting sar images. *Signal Process.*, 14 :335–346, 1988.
- [8] M. Amadasun and R. King. Textural features corresponding to textural properties. *IEEE Transactions on Systems, Man and Cybernetics*, 19 :1264–1274, 1989.
- [9] Ken W.S. Ashwell and Phil M.E. Waite. {CHAPTER} 4 - development of the peripheral nervous system. In GEORGE PAXINOS and JÜRGEN K. MAI, editors, *The Human Nervous System (Second Edition)*, pages 95 – 110. Academic Press, 2004.
- [10] T.C. Aysal and K.E. Barner. Rayleigh-maximum-likelihood filtering for speckle reduction of ultrasound images. *Medical Imaging, IEEE Transactions on*, 26(5) :712–727, May 2007.
- [11] Michael J. Barrington, Steve A. Watts, Samuel R. Gledhill, Rowan D. Thomas, Simone A. Said, Gabriel L. Snyder, Valerie S. Tay, and Konrad Jamrozik. Preliminary results of the australasian regional anaesthesia collaboration : A prospective audit of more than 7000 peripheral nerve and plexus blocks for neurologic and other complications. *Regional Anesthesia and Pain Medicine*, 34 :534–541, 2009.

- [12] J. M. Beaulieu and R. Touzi. Segmentation of textured polarimetric sar scenes by likelihood approximation. *IEEE Transactions on Geoscience and Remote Sensing*, 42(10) :2063–2072, 2004.
- [13] S. Belongie, J. Malik, and J. Puzicha. Shape matching and object recognition using shape contexts. *IEEE Trans. Pattern Anal. Mach. Intell.*, 24(4) :509–522, April 2002.
- [14] S. Benameur, M. Mignotte, and F. Lavoie. Unsupervised segmentation of ultrasound images by fusion of spatio-frequential textural features. *Proc. SPIE*, 7962 :796239–796239–9, 2011.
- [15] Dan Benhamou. Pain, epidural analgesia and late termination of pregnancy : a new challenge for obstetric anaesthesiologists. *Obstetric Anesthesia*, 16(4) :307–309, 2007.
- [16] Florian Berton, Farida Cheriet, Marie-Claude Miron, and Catherine Laporte. Segmentation of the spinous process and its acoustic shadow in vertebral ultrasound images. *Computer in Biology and Medicine*, 72 :201–211, 2016.
- [17] Sébastien Bloc, Olivier Rontes, Luc Mercadal, and Alain Delbos. Block success rate : A question of target and definition. *Regional Anesthesia*, 38(6) :553–554, 2013.
- [18] Edmundo Bonilla Huerta, J.Crispín Hernández Hernández, and L.Alberto Hernández Montiel. A new combined filter-wrapper framework for gene subset selection with specialized genetic operators. In *Advances in Pattern Recognition*, volume 6256 of *Lecture Notes in Computer Science*, pages 250–259. Springer Berlin Heidelberg, 2010.
- [19] Nicolas Bonneel, James Tompkin, Kalyan Sunkavalli, Deqing Sun, Sylvain Paris, and Hanspeter Pfister. Blind video temporal consistency. *ACM Trans. Graph.*, 34(6) :196 :1–196 :9, October 2015.
- [20] Richard Brull, Alan J.R. Macfarlane, and Cyrus C.H. Practical knobology for ultrasound-guided regional anesthesia. *Regional ane*, 35(2) :S68–S73, 2010.
- [21] Paolo Busoni. Central or peripheral blocks? *Techniques in Regional Anesthesia and Pain Management*, 6(3) :95–98, 2002.
- [22] L.J. Busse, T.R. Crimmins, and J.R. Fienup. A model based approach to improve the performance of the geometric filtering speckle reduction algorithm. In *Ultrasonics Symposium, 1995. Proceedings., 1995 IEEE*, volume 2, pages 1353–1356 vol.2, Nov 1995.
- [23] Vicent Caselles, Francine Catte, Tomeu Coll, and Francoise Dibos. A geometric model for active contours in image processing. *Numerische Mathematik*, 66(1) :1–31, 1993.
- [24] Vicent Caselles, Ron Kimmel, and Guillermo Sapiro. Geodesic active contours. *Computer Vision*, 22(1) :61–79, 1997.
- [25] G. Cawley, N. Talbot, and M. Girolami. Sparse multinomial logistic regression via bayesian l1 regularisation. *Advances in Neural Information Processing Systems*, 19 :41–42, 2007.
- [26] T. F. Chan and L. A. Vese. Active contours without edges. *IEEE Transactions on Image Processing*, 10(2) :266–277, 2001.

- [27] Tony F. Chan, B.Yezrielev Sandberg, and Luminita A. Vese. Active contours without edges for vector-valued images. *Visual Communication and Image Representation*, 11(2) :130–141, 2000.
- [28] Vincent Chan and Anahi Perlas. {CHAPTER} 2 - basics of ultrasound imaging. In S.N. Narouze, editor, *Atlas of Ultrasound-Guided Procedures in Interventional Pain Management*, pages 13–19. Springer science and Business media, 2011.
- [29] G. Chandrashekar and F. Sahin. A survey on feature selection methods. *Computer and Electrical Engineering*, 40 :16–28, 2014.
- [30] C.Y. Chang, S.J. Chen, and M. F. Tsai. Application of support-vector-machine-based method for feature selection and classification of thyroid nodules in ultrasound images. *Pattern Recognition*, 23 :3494–3506, 2010.
- [31] D. P. Chau, F. Bremond, and M. Thonnat. Online evaluation of tracking algorithm performance. In *Crime Detection and Prevention (ICDP 2009), 3rd International Conference on*, pages 1–6, Dec 2009.
- [32] Asmatullah Chaudhry, Mehdi Hassan, and Asifullah Khan. Robust segmentation and intelligent decision system for cerebrovascular disease. *Medical & Biological Engineering & Computing*, 2016.
- [33] H.D. Cheng, Juan Shan, Wen Ju, Yanhui Guo, and Ling Zhang. Automated breast cancer detection and classification using ultrasound images : A survey. *Pattern Recognition*, 43 :299–317, 2010.
- [34] H.D. Cheng, Juan Shan, Wen Ju, Yanhui Guo, and Ling Zhang. Automated breast cancer detection and classification using ultrasound images : A survey. *Pattern Recognition*, 43(1) :299 – 317, 2010.
- [35] W. Chung-Ming and C. Yung-Chang. Statistical feature matrix for texture analysis. *Graphical Models and Image*, 54 :407–419, 1992.
- [36] Laurent D. Cohen and Isaac Cohen. Finite-element methods for active contour models and balloons for 2-d and 3-d images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(11) :1131–1147, 1993.
- [37] T. F. Cootes and C. J. Taylor. Active shape models - 'smart snakes'. In *The British Machine Vision Conference*, pages 266–275, 1992.
- [38] T. F. Cootes and C. J. Taylor. Active appearance models. In *the European Conference on Computer Vision*, volume 2, pages 484–498, 1998.
- [39] T. F. Cootes and G. Edwards C. J. Taylor. Comparing active shape models with active appearance models. In *British Machine Vision Conference*, pages 173–182, 1999.
- [40] Thomas M. Cover and Joy A. Thomas. *Elements of Information Theory (Wiley Series in Telecommunications and Signal Processing)*. Wiley-Interscience, 2006.

- [41] Daniel Cremers, Mikael Rousson, and Rachid Deriche. A review of statistical approaches to level set segmentation : Integrating color, texture, motion and shape. *Computer Vision*, 72(2) :195–215, 2007.
- [42] Sven F. Crone and N. Kourentzes. Feature selection for time series prediction - a combined filter and wrapper approach for neural networks. *Neurocomputing*, 73 :1923–1936, 2010.
- [43] Diogo Brüggemann da Conceição, Pablo Escovedo Helayel, Francisco Amaral Egydio de Carvalho, Jaderson Wollmeister, and Getúlio Rodrigues de Oliveira Filho. Ultrasound images of the brachial plexus in the axillary region. *Revista Brasileira de Anestesiologia*, 57(6) :684–689, 2007.
- [44] Anna Dabu and Vincent WS Chan. *Guide pratique des blocs nerveux échoguidés*. Sauramps médical, 2006.
- [45] Nicole Dagon, Pierre Frossard, Marguerite Malik, and Nicole Richli Meystre. *TECHNIQUE ECHOGRAPHIQUE*. MFP CHUV Radiodiagnostic Lausanne, 2004.
- [46] Sonia Dahdouh. *Filtrage, segmentation et suivi d’images échographiques : applications cliniques*. PhD thesis, Université Paris Sud - Paris XI, 2011.
- [47] R.G. Dantas and E.T. Costa. Ultrasound speckle reduction using modified gabor filters. *Ultrasonics, Ferroelectrics, and Frequency Control, IEEE Transactions on*, 54(3) :530–538, March 2007.
- [48] John G. Daugman. Uncertainty relation for resolution in space, spatial frequency, and orientation optimized by two-dimensional visual cortical filters. *J. Opt. Soc. Am. A*, 2(7) :1160–1169, Jul 1985.
- [49] Auzuir Ripardo de Alexandria, Paulo César Cortez, Jessyca Almeida Bessaa, John Hebert da Silva Félix, José Sebastiao de Abreu, and Victor Hugo C. de Albuquerque. psnakes : A new radial active contour model and its application in the segmentation of the left ventricle from echocardiographic images. *Computer Methods and Programs in Biomedicine*, 116 :260–273, 2014.
- [50] Judy C. Dean and Christina C. Ilvent. Improved cancer detection using computer-aided detection with diagnostic and screening mammography : Prospective study of 104 cancers. *American Journal of Roentgenology*, 187 :20 – 28, 2006.
- [51] L. Delaunay and Sébastien Bloc. Couplage à la neurostimulation : Is nerve stimulation still necessary in ultrasound-guided regional anaesthesia. *Annales Françaises d’Anesthésie et de Réanimation*, 31 :e199–e201, 2012.
- [52] Alain Delbos and Lazar Bibin. L’échographie en alr. Technical report, Clinique du Cours Dillon, 1 rue Peyrolade - 31400Toulouse, 2008.
- [53] Yinhui Deng, Yuanyuan Wang, and Yuzhong Shen. Speckle reduction of ultrasound images based on rayleigh-trimmed anisotropic diffusion filter. *Pattern Recognition Letters*, 32(13) :1516 – 1525, 2011.

- [54] Jianrui Ding, H. D. Cheng, Jianhua Huang, Jiafeng Liu, and Yingtao Zhang. Breast ultrasound image classification based on multiple-instance learning. *Digital Imaging*, 25 :620–627, 2012.
- [55] Liwen Dong. Adaptive image denoising using wavelet thresholding. In *Information Science and Technology (ICIST), 2013 International Conference on*, pages 854–857, March 2013.
- [56] Gianfranci Doretto, Alessandro Chiuso, Ying Nian Wu, and Sterano Soatto. Dynamic textures. *Computer Vision*, 51(2) :91–109, 2003.
- [57] Richard O. Duda, Peter E. Hart, David G. Stork, R. O. Duda, P. E. Hart, and D. G. Stork. Pattern classification, 2nd ed, 2001.
- [58] S. Dudoit, J. Fridlyand, and T. Speed. Comparison of discrimination methods for the classification of tumors using gene expression data. *Journal of the American Statistical Association*, 97 :77–87, 2002.
- [59] Vinayak Dutt. *Statistical Analysis of Ultrasound Echo Envelope*. PhD thesis, The Mayo Graduate School, 1995.
- [60] Patrick Etyngier, Florent Segonne, and Renaud Keriven. Shape pprior using manifold learning techniques. In *IEEE International conference on computer vision*, pages 1–8, 2007.
- [61] Eli Gibson Amir Khojaste Mena Gaed Madeleine Moussa Farhad Imani, Purang Abolmaesumi, Jose A. Gomez, Cesare Romagnoli, Michael Leveridge, Silvia Chang, D. Robert Siemens, Aaron Fenster, Aaron D. Ward, and Parvin Mousavi. Computer-aided prostate cancer detection using ultrasound rf time series : In vivo feasibility study. *IEEE Transactions on Medical Electronics*, 34(11) :2248–2257, 2015.
- [62] G. Farnebäck. Two-frame motion estimation based on polynomial expansion. In *Proceedings of the 13th Scandinavian Conference on Image Analysis*, LNCS 2749, pages 363–370, Gothenburg, Sweden, June-July 2003.
- [63] Cyrille Fauchaux. *Segmentation supervisée d’images texturées par régularisation de graphes*. PhD thesis, Univeristé Francois Rabelais de Tours, 2013.
- [64] Cyrille Fauchaux, Julien Olivier, and Romuald Boné. Graph-based regularization of binary classifiers for texture segmentation. In *15th International Conference, Computer Analysis of Images and Patterns*, pages 310–318. Springer Berlin Heidelberg, 2013.
- [65] Cyrille Fauchaux, Julien Olivier, Romuald Boné, and Pascal Makris. Texture-based graph regularization procee for 2d and 3d ultrasound image segmentation. In *2012 19th IEEE International Conference on Image Processing*, pages 2333–2336. IEEE, 2012.
- [66] Pedro Pedrosa Reboucas Filho, Paulo César Cortez, Antônio Carlos da Silva Barros, and Victor Hugo C. de Albuquerque. Novel adaptive balloon active contour method based on internal force for image segmentation - a systematic evaluation on synthetic and real images. *Expert Systems with Application*, 41 :7707–7721, 2014.

- [67] Molinari Filippo, Zeng Guang, and S. Suri Jasjit. A state of the art review on intima-media thickness (imt) measurement and wall segmentation techniques for carotid ultrasound. *Computer methods and programs in biomedicine*, 100 :201–221, 2010.
- [68] Wilfrido Gomez Flores, Wagner Coelho de Albuquerque Pereira, and Antonio Fernando Castelli Infantosi. Improving classification performance of breast lesions on ultrasonography. *Pattern Recognition*, 48 :1125–1136, 2015.
- [69] Wilfrido Gómez Flores, Wagner Coelho de Albuquerque Pereira, and Antonio Fernando Castelli Infantosi. Improving classification performance of breast lesions on ultrasonography. *Pattern Recognition*, 48(4) :1125 – 1136, 2015.
- [70] Pezhman Foroughi, Emad Boctor, Michael J. Swartz, Russell H. Taylor, and Gabor Fichtinger. Ultrasound bone segmentation using dynamic programming. In *IEEE Ultrasonics Symposium*, pages 2523–2526, 2007.
- [71] O. Frenkel, K. Mansour, and J. W. Fischer. Ultrasound-guided femoral nerve block for pain control in an infant with a femur fracture due to nonaccidental trauma. *Pediatric emergency care*, 28 :183–184, 2012.
- [72] Victor S. Frost, Josephine Abbott Stiles, K.S. Shanmugan, and J. Holtzman. A model for radar images and its application to adaptive digital filtering of multiplicative noise. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, PAMI-4(2) :157–166, March 1982.
- [73] Aimilia Gastounioti, Aristeidis Sotiras, Konstantina S. Nikita, , and Nikos Paragios. Graph-based motion-driven segmentation of the carotid atherosclerotic plaque in 2d ultrasound sequences. In Nassir Navab, Joachim Hornegger, M. William Wells, and F. Alejandro Frangi, editors, *Medical Image Computing and Computer-Assisted Intervention*, pages 551–559. Springer International Publishing, 2015.
- [74] Ralf Gebhard, Admir Hadzic, and William Urmeý. *Dual Guidance A Multimodal Approach to Nerve Location*. B. Braun Melsungen AG, 2008.
- [75] Jeffrey S. Geronimo and Douglas P. Hardin. Fractal functions and wavelet expansions based on several scaling functions. *Approximation Theory*, 78 :373–401, 1994.
- [76] Soumya Ghose. *Robust Image Segmentation Applied to Magnetic Resonance and Ultrasound Images of the Prostate*. PhD thesis, Université de Bourgogne and Universitat de Girona, 2012.
- [77] Soumya Ghose, Arnau Oliver, Robert Martí, Xavier Llado, Jordi Freixenet, Joan C. Vilanova, and Fabrice Meriaudeau. Prostate segmentation with texture enhanced active appearance model. In *Sixth International Conference on Signal-Image Technology and Internet Based Systems*, pages 18–22, 2010.
- [78] Soumya Ghose, Arnau Oliver, Robert Martí, Xavier Llado, Jordi Freixenet, Joan C. Vilanova, and Fabrice Meriaudeau. Texture guided active appearance model propagation for prostate segmentation. In Anant Madabhushi, Jason Dowling, Pingkun Yan, Aaron Fenster, Purang Abolmaesumi, and Nobuhiko Hata, editors, *Prostate Cancer Imaging. Computer-Aided*

- Diagnosis, Prognosis, and Intervention : International Workshop, Held in Conjunction with MICCAI*, pages 111–120. Springer Berlin Heidelberg, 2010.
- [79] Soumya Ghose, Arnau Oliver, Robert Marti, Xavier Llado, Jordi Freixenet, J.C. Villanova, and Fabrice Meriaudeau. A probabilistic framework for automatic prostate segmentation with a statistical model of shape and appearance. In *18th IEEE International Conference on Image Processing*, pages 725–728, 2011.
- [80] Soumya Ghose, Arnau Oliver, Robert Marti, Xavier Llado, Jordi Freixenet, J.C. Villanova, and Fabrice Meriaudeau. Prostate segmentation with local binary patterns guided active appearance models. In *SPIE 7962, Medical Imaging*, 2011.
- [81] Soumya Ghose, Arnau Oliver, Robert Marti, Xavier Lladó, Joan C. Vilanova, Jordi Freixenet, Jhimli Mitra, Désiré Sidibé, and Fabrice Meriaudeau. A survey of prostate segmentation methodologies in ultrasound, magnetic resonance and computed tomography images. *Computer methods and programs in biomedicine*, 108 :262–287, 2012.
- [82] Soumya Ghose, Arnau Oliver, Jhimli Mitra, Robert Marti, Xavier Llado, Jordi Freixenet, Désiré Sidibé, Joan C. Vilanova, Josep Comet, and Fabrice Meriaudeau. A supervised learning framework of statistical shape and probability priors for automatic prostate segmentation in ultrasound images. *Medical Image Analysis*, 17(6) :587 – 600, 2013.
- [83] George D. Giannoglou, Yiannis S. Chatzizisis, Vassilis Koutkias, Ioannis Kompatsiaris, Maria Papadogiorgaki, Vasileios Mezaris, Eirini Parissi, Panagiotis Diamantopoulos, Michael G. Strintzis, Nicos Maglaveras, George E. Parcharidis, and George E. Louridas. A novel active contour model for fully automated segmentation of intravascular ultrasound images : In vivo validation in human coronary arteries. *Computers in Biology and Medicine*, 37 :1292–1302, 2007.
- [84] C. Gini and G. Ottaviani. *Memorie di metodologia statistica*. Number vol. 1 in *Memorie di metodologia statistica*. E.V. Veschi, 1955.
- [85] Robert Grent. *Applied Physics and Technology of Diagnostic Ultrasound*. Milner Publishing, 1997.
- [86] Housseem-Eddine Gueziri, Michael J. McGuffin, and Catherine Laporte. A generalized graph reduction framework for interactive segmentation of large images. *Computer Vision and Image Understanding*, 000 :1–14, 2016.
- [87] Murat Alparslan Gungor and Irfan Karagoz. The homogeneity map method for speckle reduction in diagnostic ultrasound images. *Measurement*, 68(0) :100 – 110, 2015.
- [88] Kanghui Guo and Demetrio Labate. Optimally sparse multidimensional representation using shearlets. *SIAM Journal on Mathematical Analysis*, 39(1) :298–318, 2007.
- [89] Yimo Guo, Guoying Zhao, and Matti Pietikainen. Texture classification using a linear configuration model based descriptor. In *Proceedings of the British Machine Vision Conference*, pages 119.1–119.10, 2011.

- [90] Zhenhua Guo, Lei Zhang, and David Zhang. A completed modeling of local binary pattern operator for texture classification. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, 19(6) :1657–1663, 2010.
- [91] Deep Gupta, R.S. Anand, and Barjeev Tyagi. A hybrid segmentation method based on gaussian kernel fuzzy clustering and region based active contour model for ultrasound medical images. *Biomedical Signal Processing and Control*, 16 :98–112, 2015.
- [92] Ilker Hacihaliloglu, Rafeef Abugharbieh, Antony J. Hodgson, and Robert N. Rohling. Bone surface localization in ultrasound using image phase-based features. *Ultrasound in Medicine & Biology*, 35(9) :1475–1487, 2009.
- [93] Oussama Hadjerci, Adel Hafiane, Donatello Conte, Pascal Makris, Pierre Vieyres, and Alain Delbos. Computer-aided detection system for nerve identification using ultrasound images : A comparative study. *Informatics in Medicine Unlocked*, 3 :29 – 43, 2016.
- [94] A. Hafiane, K. Palaniappan, and G. Seetharaman. Adaptive median binary patterns for texture classification. In *Pattern Recognition (ICPR), 2014 22nd International Conference on*, pages 1138–1143, Aug 2014.
- [95] A. Hafiane, G. Seetharaman, K. Palaniappan, and B. Zavidovique. Rotationally invariant hashing of median binary patterns for texture classification. *International conference on image analysis and recognition*, pages 619–629, 2008.
- [96] A. Hafiane, P. Vieyres, and A. Delbos. Phase-based probabilistic active contour for nerve detection in ultrasound images for regional anesthesia. *Computers in Biology and Medicine*, 52 :88–95, 2014.
- [97] Adel Hafiane, Pierre Vieyres, and Alain Delbos. Phase-based probabilistic active contour for nerve detection in ultrasound images for regional anesthesia. *Computers in Biology and Medicine*, 52 :88–95, 2014.
- [98] Yrjo Häme and Mika Pollari. Semi-automatic liver tumor segmentation with hidden markov measure field model and non-parametric distribution estimation. *Medical Image Analysis*, 16(1) :140 – 149, 2012.
- [99] Mattias Hansson, Sami S. Brandt, Johan Lindström, Petri Gudmundsson, Amra Jujic, Andreas Malmgren, and Yuanji Cheng. Segmentation of b-mode cardiac ultrasound data by bayesian probability maps. *Medical Image Analysis*, 18 :1184–1199, 2014.
- [100] R.M. Haralick, K. Shanmugam, and Its’Hak Dinstein. Textural features for image classification. *Systems, Man and Cybernetics, IEEE Transactions on*, SMC-3(6) :610–621, 1973.
- [101] Robert M. Haralick, K. Shanmugam, and Its’hak Dinstein. Texture features for image classification. *IEEE Transactions on Systems*, SMC-3(6) :610–621, 1973.
- [102] C.R. Hatt and V. Parthasarathy. Enhanced needle localization in ultrasound using beam steering and learning-based segmentation. *Computerized Medical Imaging and Graphics*, 41 :46–54, 2014.

- [103] Nawal Houhou, Alia Lemkaddem, Valerie Duay, Abdelkarim Allal, and Jean philippe Thiran. Shape prior based on statistical map for active contour segmentation. In *International Conference on Image Processing*, pages 2284–2287, 2008.
- [104] Qing-Hua Huang, Su-Ying Lee, Long-Zhong Liu, Min-Hua Lu, Lian-Wen Jin, and An-Hua Li. A robust graph-based segmentation method for breast tumors in ultrasound images. *Ultrasonics*, 52 :266–275, 2012.
- [105] Qinghua Huang, Xiao Bai, Yingguang Li, Lianwen Jin, and Xuelong Li. Optimized graph-based segmentation for ultrasound images. *Neurocomputing*, 129 :246–224, 2014.
- [106] Qinghua Huang, Feibin Yang, Longzhong Liu, and Xuelong Li. Automatic segmentation of breast lesions for interaction in ultrasonic computer-aided diagnosis. *Information Sciences*, 314 :293–310, 2015.
- [107] T. Huang, G. Yang, and G. Tang. A fast two-dimensional median filtering algorithm. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, 27(1) :13–18, Feb 1979.
- [108] Xiaojie Huang, Donald P. Dione, Colin B. Compas, Xenophon Papademetris, Ben A. Lin, Alda Bregasi, Albert J. Sinusas, Lawrence H. Staib, and James S. Duncan. Contour tracking in echocardiographic sequences via sparse representation and dictionary learning. *Medical Image Analysis*, 18 :253–271, 2014.
- [109] DimitrisK. Iakovidis, EystratiosG. Keramidas, and Dimitris Maroulis. Fuzzy local binary patterns for ultrasound texture characterization. In Aurélio Campilho and Mohamed Kamel, editors, *Image Analysis and Recognition*, volume 5112 of *Lecture Notes in Computer Science*, pages 750–759. Springer Berlin Heidelberg, 2008.
- [110] Juan Eugenio Iglesias and Mert R. Sabuncu. Multi-atlas segmentation of biomedical images : A survey. *Medical Image Analysis*, 24 :205–219, 2015.
- [111] J. L. Izquierdo-Zaragoza, M. C. Bastida-Jumilla, R. Verdû-Monedero, J. Morales-Sanchez, and R. Berenguer-Vidal. Segmentation of the carotid artery in ultrasound images using frequency-designed b-spline active contour. In *IEEE International Conference on Acoustics, Speech and Signal Processing*, pages 713–716. IEEE, 2011.
- [112] Afsaneh Jalalian, Syamsiah B.T. Mashohor, Hajjah Rozi Mahmud, M. Iqbal B. Saripan, Abdul Rahman B. Ramli, and Babak Karasfi. Computer-aided detection/diagnosis of breast cancer in mammography and ultrasound : a review. *Clinical Imaging*, 37 :420–426, 2013.
- [113] Xiao-Liang Jiang, Qiang Wang, Biao He, Shao-Jie Chen, and Bai-Lin Li. Robust level set image segmentation algorithm using local correntropy-based fuzzy c-means clustering with spatial constraints. *Neurocomputing*, x :xx–xx, 2016.
- [114] Lawrence J.P. Physics and instrumentation of ultrasound. *Critical care medicine*, 35(8) :314–336, 2007.
- [115] Lee JS. Digital image enhancement and noise filtering by use of local statistics. *IEEE Trans. Pattern Anal. Mach Intell*, 2 :165–168, 1980.

- [116] Z. Kalal, K. Mikolajczyk, and J. Matas. Forward-backward error : Automatic detection of tracking failures. In *Pattern Recognition (ICPR), 2010 20th International Conference on*, pages 2756–2759, Aug 2010.
- [117] Hrvoje Kalinic, Sven Lončarić, Maja Čikeš, Davor Miličić, and Bart Bijnens. Image registration and atlas-based segmentation of cardiac outflow velocity profiles. *Computer Methods and Programs in Biomedicine*, 106 :188–200, 2012.
- [118] Jon Harald Kaspersena, Thomas Lango, and Frank Lindsetha. Wavelet-based edge detection in ultrasound images. *Ultrasound in Medicine & Biology*, 27(1) :89–99, 2001.
- [119] Michael Kass, Andrew Witkin, and Demetri Terzopoulos. Snakes : Active contour models. *Computer Vision*, 1(4) :321–331, 1988.
- [120] Michael Kass, Andrew Witkin, and Demetri Terzopoulos. Snakes : Active contour models. *INTERNATIONAL JOURNAL OF COMPUTER VISION*, 1(4) :321–331, 1988.
- [121] J. Kessler, P. Marhofer, P. M. Hopkins, and M. W. Hollmann. Peripheral regional anaesthesia and outcome : lessons learned from the last 10 years. *British Journal of Anaesthesia*, 114(5) :728–773, 2015.
- [122] Benjamin B. Kimia, Allen R. Tannenbaum, and Steven W. Zucker. Shapes, shocks, and deformations h the components of two-dimensional shape and the reaction-diffusion space. *Computer Vision*, 15 :189–224, 1995.
- [123] R. Kohavi and G. John. Wrappers for feature selection. *Artificial Intelligence*, 97(1-2) :273–324, 1997.
- [124] Umut Konur, Fikret S. Gurgun, Fusun Varol, and Lale Akarun. Computer aided detection of spina bifida using nearest neighbor classification with curvature scale space features of fetal skulls extracted from ultrasound images. *Knowledge-Based Systems*, 85 :80–95, 2015.
- [125] George Kossoff. Basic physics and imaging characteristics of ultrasound. *World Journal of Surgery*, 24(2) :134–142, 2000.
- [126] K. Divya Krishna, V. Akkala, R. Bharath, P. Rajalakshmi, A.M. Mohammed, S.N. Merchant, and U.B. Desai. Computer aided abnormality detection for kidney on fpga based iot enabled portable ultrasound imaging system. *IRBM*, pages 1959–0318, 2016.
- [127] Karl Krissian, Jose M. Carreira, Julio Esclarin, and Manuel Maynar. Semi-automatic segmentation and detection of aorta dissection wall in {MDCT} angiography. *Medical Image Analysis*, 18(1) :83 – 102, 2014.
- [128] Darwin T. Kuan, A. Sawchuk, Timothy C. Strand, and P. Chavel. Adaptive restoration of images with speckle. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, 35(3) :373–383, Mar 1987.
- [129] Mehmet Nadir Kurnaz, Zumray Dokur, and Tamer Olmez. An incremental neural network for tissue segmentation in ultrasound images. *Computer Methods and Programs in Biomedicine*, 85 :187–195, 2007.

- [130] C. K. Kwoh, M. Y. Teo, W. S. Ng, S. N. Tan, and L. M. Jones. Outlining the prostate boundary using the harmonics method. *Medical and Biological Engineering and Computing*, 36(6) :768–771, 1998.
- [131] Xiaosong Lan, S. Li, Chengfei Zhu, Feimo Li, and H. Chang. A dynamic online background modeling framework for moving object detection from airborne videos. In *2015 IEEE International Conference on Progress in Informatics and Computing (PIC)*, pages 168–172, 2015.
- [132] Yi Le, Xianze Xu, Zhongbing Li, Fengqiu Xu, and Wencheng Zhao. A multi-step directional generalized gradient vector flow snake for target tumor segmentation in us-guided high-intensity focused ultrasound ablation. *Biomedical Signal Processing and Control*, 8 :811–821, 2013.
- [133] Myungeun Lee, Wanhyun Cho, Sunworl Kim, Soonyoung Park, and Jong Hyo Kim. Segmentation of interest region in medical volume images using geometric deformable model. *Computer in Biology and Medicine*, 42 :523–537, 2012.
- [134] Wen-Li Lee, Yung-Chang Chen, Ying-Cheng Chen, and Kai-Sheng Hsieh. Unsupervised segmentation of ultrasonic liver images by multiresolution fractal feature vector. *Information Sciences*, 175(3) :177–199, 2005.
- [135] Boudewijn P.F. Lelieveldt, Steven C. Mitchell, Johan G. Bosch, Rob J. van der Geest, Milan Sonka, and Johan H.C. Reiber. Time-continuous segmentation of cardiac image sequences using active appearance motion models. In *Information Processing in Medical Imaging : 17th International Conference*, pages 18–22. Springer Berlin Heidelberg, 2001.
- [136] Guillaume Lemaître, Robert Marti, Jordi Freixenet, Joan C. Vilanova, Paul M. Walker, and Fabrice Meriaudeau. Computer-aided detection and diagnosis for prostate cancer based on mono and multi-parametric mri : A review. *Computers in Biology and Medicine*, 60 :8 – 31, 2015.
- [137] Bing Nan Li, Chee Kong Chui, Stephen Chang, and S.H. Ong. Integrating spatial fuzzy clustering with level set methods for automated medical image segmentation. *Computer in Biology and Medicine*, 41 :1–10, 2011.
- [138] C. Li, C. Xu, C. Gui, and M. D. Fox. Distance regularized level set evolution and its application to image segmentation. *IEEE Transactions on Image Processing*, 19(12) :3243–3254, 2010.
- [139] Chunming Li, Rui Huang, Zhaohua Ding, J. Chris Gatenby, Dimitris N. Metaxas, and John C. Gore. A level set method for image segmentation in the presence of intensity inhomogeneities with application to mri. *IEEE Transactions on Image Processing*, 20(7) :2007–2016, 2011.
- [140] Chunming Li, Chenyang Xu, Changfeng Gui, and Martin D. Fox. Distance regularized level set evolution and its application to image segmentation. *IEEE Transactions on Image Processing*, 19(12) :3243–3254, 2011.

- [141] David Lieu. Ultrasound physics and instrumentation for pathologists. *Archives of pathology and laboratory medicine*, 134(10) :1541–1597, 2010.
- [142] Cheng-Shian Lin and Jyh-Jong Tsay. A passive approach for effective detection and localization of region-level video forgery with spatio-temporal coherence analysis. *Digital Investigation*, 11(2) :120 – 140, 2014.
- [143] Bo Liu, H.D. Chenga, Jianhua Huang, Jiawei Tian, Xianglong Tang, and Jiafeng Liu. Fully automatic and segmentation-robust classification of breast tumors based on local texture analysis of ultrasound images. *Pattern Recognition*, 43 :280–298, 2010.
- [144] Huan Liu and Hiroshi Motoda. *Feature Selection for Knowledge Discovery and Data Mining*. Kluwer Academic Publishers, Norwell, MA, USA, 1998.
- [145] Huan Liu and R. Setiono. Chi2 : feature selection and discretization of numeric attributes. In *Tools with Artificial Intelligence, 1995. Proceedings., Seventh International Conference on*, pages 388–391, Nov 1995.
- [146] Qingyi Liu, Mingyan Jiang, Peirui Bai, and Guang Yang. A novel level set model with automated initialization and controlling parameters for medical image segmentation. *Computerized Medical Imaging and Graphics*, 48 :21–29, 2016.
- [147] Xin Liu, Yiu ming Cheung, Shu-Juan Peng, and Qinmu Peng. Automatic mitral valve leaflet tracking in echocardiography via constrained outlier pursuit and region-scalable active contours. *Neurocomputing*, 144 :47–57, 2014.
- [148] Y. J. Liu, W. S. Ng, M. Y. Teo, and H. C. Lim. Computerised prostate boundary estimation of ultrasound images using radial bas-relief method. *Medical and Biological Engineering and Computing*, 35(5) :445–454, 1997.
- [149] Mark Hall Lloyd. Feature selection for machine learning : Comparing a correlation-based filter approach to the wrapper, 1999.
- [150] Fernande Jane Lois and Marc De Kock. Does regional anesthesia improve long-term patient outcome? *Techniques in Regional Anesthesia and Pain Management*, 12(4) :203–208, 2008.
- [151] C. P. Loizou, C. S. Pattichis, C. I. Christodoulou, R. S. H. Istepanian, M. Pantziaris, and A. Nicolaides. Comparative evaluation of despeckle filtering in ultrasound imaging of the carotid artery. *IEEE Trans Ultrason*, 52 :1653–1669, 2005.
- [152] Christos P. Loizou and Constantinos S. Pattichis. *Despeckling*, chapter 7, pages 153–194. Springer Publishing Company, 2011.
- [153] Dzung L. Pham, Chenyang Xu, and Jerry L. Prince. Current methods in medical image segmentation. *annual Review of Biomedical engineering*, 2 :315 :317, 2000.
- [154] Valeria De Luca, Gábor Székely, and Christine Tanner. Estimation of large-scale organ motion in b-mode ultrasound image sequences : A survey. *Ultrasound in Medicine and Biology*, 41(12) :3044 – 3062, 2015.

- [155] Ye Luo, Junsong Yuan, and Jianwei Lu. Finding spatio-temporal salient paths for video objects discovery. *Journal of Visual Communication and Image Representation*, 38 :45 – 54, 2016.
- [156] W. Y. Ma and B. S. Manjunath. Edge flow : A framework of boudary detection and image segmenation. In *Computer Socity Conference on Computer Vision and Pattern*, pages 744–749. IEEE, 1997.
- [157] F. Maes, A. Collignon, D. Vandermeulen, G. Marchal, and P. Suetens. Multimodality image registration by maximization of mutual information. *IEEE Transactions on Medical Imaging*, 16(2) :187–198, 1997.
- [158] Simona Maggio, Alessandro Palladini, Luca De Marchi, Martino Alessandrini, Nicola Speciale, and Guido Masetti. Predictive deconvolution and hybrid feature selection for computer-aided detection of prostate cancer. *IEEE Transactions on Medical Imaging*, 29(2) :455–464, 2010.
- [159] T. Makela, P. Clarysse, O. Sipila, N. Pauna, Quoc Cuong Pham, T. Katila, and I. E. Magnin. A review of cardiac image registration methods. *IEEE Transactions on Medical Imaging*, 21(9) :1011–1021, 2002.
- [160] Ravikanth Malladi, James A. Sethian, and Baba C. Vemuri. Shape modeling with front propagation : a level set approach. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 17(2) :158–175, 1995.
- [161] Benoit B. Mandelbrot. *The fractal geometry of nature*. W.H. Freeman, 1 edition, August 1982.
- [162] K.Z. Mao. Orthogonal forward selection and backward elimination algorithms for feature subset selection. *Systems, Man, and Cybernetics, Part B : Cybernetics, IEEE Transactions on*, 34(1) :629–634, Feb 2004.
- [163] A. Marcano-Cedeno, J. Quintanilla-Dominguez, M. G. Cortina-Januchs, and D. Andina. Feature selection using sequential forward selection and classification applying artificial metaplasticity neural network. In *IECON 2010 - 36th Annual Conference on IEEE Industrial Electronics Society*, pages 2845–2850, Nov 2010.
- [164] Peter Marhofer and Vincent W. Chan. Ultrasound-guided regional anesthesia : current concepts and future trends. *Anesthesia and Analgesia*, 104(5) :1265–1269, 2007.
- [165] Peter Marhofer, Schrögender K, Andel H, Koining H, Grisch W, Kapral S, and Mayer N. Combined sciatic nerve-3 in 1 block in high risk patient. *Anaesthesiol Intensivmed Notfallmed Schmerzther*, 33(6) :399–401, 1998.
- [166] Jean Martial Mari, Wenfeng Xia, Simeon J. West, and Adrien E. Desjardins. Interventional multispectral photoacoustic imaging with a clinical ultrasound probe for discriminating nerves and tendons : an ex vivo pilot study. *Journal of Biomedical Optics*, 20(11), 2015.

- [167] Edward R. Mariano, Vanessa J. Loland, Richard H. Bellars, NavParkash S. Sandhu, Michael L. Bishop, Reid A. Abrams, Matthew J. Meunier, Rosalita C. Maldonado, Eliza J. Ferguson, and Brian M. Ilfeld. Ultrasound guidance versus electrical stimulation for infraclavicular brachial plexus perineural catheter insertion. *Ultrasound in medicine*, 28 :1211–1218, 2009.
- [168] Sébastien Martin. *Utilisation d’atlas anatomiques et de modèles déformables pour la segmentation de la prostate en IRM*. PhD thesis, Université Joseph-Fourier - Grenoble I, 2008.
- [169] Geoffrey J. McLachlan. *Discriminant Analysis and Statistical Pattern Recognition (Wiley Series in Probability and Statistics)*. Wiley-Interscience, 2004.
- [170] R. Medina, A. Bravo, P. Windyga, J. Toro, P. Yan, and G. Onik. A 2-d active appearance model for prostate segmentation in ultrasound images. In *IEEE Engineering in Medicine and Biology 27th Annual Conference*, pages 3363–3366, 2005.
- [171] Pablo Mesejo, Oscar Ibaner, Oscar Cordon, and Stefano Cagnoni. A survey on image segmentation using metaheuristic-based deformable models : state of the art and critical analysis. *Applied Soft Computing*, 44 :1–29, 2016.
- [172] Ahmed M. Mharib, Abdul Rahman Ramli, Syamsiah Mashohor, and Rozi Binti Mahmood. Survey on liver ct image segmentation methods. *Artificial intelligence review*, 37 :83–95, 2012.
- [173] Sergiy Milko, Eigil Samset, and Timor Kadir. Segmentation of the liver in ultrasound : a dynamic texture approach. *Computer Assisted Radiology and Surgery*, 3 :143–150, 2008.
- [174] Fabiola miller and Ronan O’rahilly. {CHAPTER} 2 - embryonic development of the central nervous system. In GEORGE PAXINOS and JÜRGEN K. MAI, editors, *The Human Nervous System (Second Edition)*, pages 22 – 48. Academic Press, 2004.
- [175] Amar Mitiche and Ismail Ben Ayed. *Variational and Level Set Methods in Image Segmentation*, volume 5. Springer Topics in Signal Processing, 2011.
- [176] Stephen M.Klein, M.Steve Melton, Warren M.Grill, and Karen Nielsen. Peripheral nerve stimulation in regional anesthesia. *Regional Anesthesia and Pain Medicine*, 37 :383–392, 2012.
- [177] Filippo Molinari, Kristen M. Meiburger, Guang Zeng, Andrew Nicolaides, and Jasjit S. Suri. Caudles-ef : Carotid automated ultrasound double line extraction system using edge flow. *Digital Imaging*, 24 :1059–1077, 2011.
- [178] Douglas C Montgomery, George C Runger, and Hubele. *Engineering statistics ; 2nd ed*. John Wiley and Sons, Hoboken, NJ, 2000.
- [179] Muthu Rama Krishnan Mookiah, U. Rajendra Acharya, Chua Kuang Chua, Choo Min Lim, E.Y.K. Ng, and Augustinus Laude. Computer-aided diagnosis of diabetic retinopathy : A review. *Computers in Biology and Medicine*, 43(12) :2136 – 2155, 2013.

- [180] M. Nagao and T. Matsuyama. Edge preserving smoothing. *Comput. Graph. Image Processing*, 9 :394–407, 1979.
- [181] Loris Nanni, Alessandra Lumini, and Sheryl Brahnham. Survey on {LBP} based texture descriptors for image classification. *Expert Systems with Applications*, 39(3) :3634 – 3641, 2012.
- [182] Samar N. Narouze. *Atlas of Ultrasound-Guided Procedures in Interventional Pain Management*. Springer New York, 2011.
- [183] Bo Nia, Fazhi Hea, and ZhiYong Yuan. Segmentation of uterine fibroid ultrasound images using a dynamic statistical shape model in hifu therapy. *Computerized Medical Imaging and Graphics*, 46 :302–314, 2015.
- [184] Denny NM and Harrop-Griffiths W. Location, location, location! ultrasound imaging in regional anaesthesia. *British journal of anaesthesia*, 94(1) :1–3, 2005.
- [185] A. Noble. Ultrasound image segmentation : A survey,. *IEEE Transactions on Medical Imaging*, 25(28) :987–1010, 2006.
- [186] J. A. Noble. Ultrasound image segmentation and tissue characterization. *Proceedings of the Institution of Mechanical Engineers*, 224 :307–316, 2010.
- [187] J. Alison Noble and Djamal Boukerroui. Ultrasound image segmentation : A survey. *IEEE TRANSACTIONS ON MEDICAL IMAGING*, 25(08) :987–1010, 2006.
- [188] Saman Nouranian, S. Sara Mahdavi, Ingrid Spadinger, William J. Morris, Septimiu E. Salcudean, and Purang Abolmaesumi. *An Automatic Multi-atlas Segmentation of the Prostate in Transrectal Ultrasound Images Using Pairwise Atlas Shape Similarity*, pages 173–180. Springer Berlin Heidelberg, 2013.
- [189] U. Oberndorfer, P. Marhofer, A. Bosenberg, H. Willschke, M. Felfernig, M. Weintraud, S. Kapral, and S. C. Kettner. Ultrasonographic guidance for sciatic and femoral nerve blocks in children. *British Journal of Anaesthesia*, 98(6) :797–801, 2007.
- [190] Ultrasound-Guided Interscalene Needle Placement Produces Successful Anesthesia Regardless of Motor Stimulation Above or Below 0.5 mA. Sanjay k sinha and jonathan h abrams and robert s weller. *Anesthesia and Analgesia*, 105(3) :848–900, 2007.
- [191] T. Ojala, M. Pietikainen, and T. Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(7) :971–987, Jul 2002.
- [192] Ville Ojansivu and Janne Heikkilä. Blur insensitive texture classification using local phase quantization. In *Image and Signal Processing : 3rd International Conference*, pages 236–243, 2008.
- [193] Steven L Orebaugh, Michael L Kentor, and Brian A Williams. Adverse outcomes associated with nerve stimulator-guided and ultrasound-guided peripheral nerve blocks by supervised

- trainees : update of a single-site database. *Regional anesthesia and pain medicine*, 37 :577–582, 2012.
- [194] Stanley Osher and James A. Sethian. Fronts propagating with curvature dependent speed : Algorithms based on hamilton-jacobi formulations. *Computation Physics*, 79 :12–49, 1988.
- [195] B. Padmapriya, T. Kesavamurthi, and H. Wassim Feroze. Edge based image segmentation technique for detection and estimation of the bladder wall thickness. *Procedia Engineering*, 30 :828–835, 2012.
- [196] Nikos Paragios, Marie-Pierre Jolly, Maxime Taron, and Rama Ramaraj. Active shape models and segmentation of the left ventricle in echocardiography. In *Scale Space and PDE Methods in Computer Vision*, pages 131–142, 2005.
- [197] H. Peng, Fulmi Long, and C. Ding. Feature selection based on mutual information criteria of max-dependency, max-relevance, and min-redundancy. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 27(8) :1226–1238, Aug 2005.
- [198] Wei-Shi Peng, Yang-Wang Fang, and Dong Chai. Enhanced dynamic error spectrum for estimation performance evaluation in target tracking. *Optik - International Journal for Light and Electron Optics*, 127(8) :3943 – 3949, 2016.
- [199] Anahi Perlas, Vincent W.S. Chan, and Martin Simons. Brachial plexus examination and localization using ultrasound and electrical stimulation. *Anesthesiology*, 99 :429–435, 2003.
- [200] P. Perona and J. Malik. Scale-space and edge detection using anisotropic diffusion. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 12(7) :629–639, Jul 1990.
- [201] M. Pietikäinen, T. Ojala, and Z. Xu. Rotation-invariant texture classification using feature distributions. *Pattern Recognition*, 33(1) :43–52, 2000.
- [202] John C. Platt. Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. In *ADVANCES IN LARGE MARGIN CLASSIFIERS*, pages 61–74. MIT Press, 1999.
- [203] Brian A. Pollard. *ultrasound guidance for vascular access and regional anesthesia*. Library and Archives Canada Cataloguing in Publication, 2012.
- [204] D. Surya Prabha and J. Satheesh Kumar. Performance evaluation of image segmentation using objective methods. *Indian Journal of Science and Technology*, 9(8), 2016.
- [205] Xianjing Qin, Yan Tian, and Pingkun Yan. Feature competition and partial sparse shape modeling for cardiac image sequences segmentation. *Neurocomputing*, 149 :904–913, 2015.
- [206] A. Rabhi, M. Adel, and S. Bourennane. Segmentation of ultrasound images using geodesic active contours. *ITBM-RBM*, 27(1) :8–18, 2006.
- [207] Pavan Kumar BC Raju and Calum RK Grant. Practical aspects of ultrasound-guided regional anaesthesia. *Anesthesia and intensive care medicine*, 14(4) :137–141, 2013.

- [208] Daniele Regge, Cesare Hassan, Perry J. Pickhardt, Andrea Laghi, Angelo Zullo, David H. Kim, Franco Iafrate, and Sergio Morini. Impact of computer-aided detection on the cost-effectiveness of ct colonography. *Radiology*, 250(2) :488–497, 2009.
- [209] Gerald Retzl, Stephan Kapral, Manfred Greher, and Walter Mauritz. Ultrasonographic findings of the axillary part of the brachial plexus. *Regional anesth*, 92 :1271–1275, 2001.
- [210] William D. Richard and Constance G. Keen. Automated texture-based segmentation of ultrasound images of the prostate. *Computerized Medical Imaging and Graphics*, 20(3) :131–140, 1996.
- [211] Rui Rocha, Jorge Silva, and Aurélio Campilho. Dynamic programming and fuzzy classification for the automatic segmentation of the carotid in ultrasound images. In *Conference on Machine Vision Applications*, pages 14–34. 2011.
- [212] Rui Rocha, Jorge Silva, and Aurélio Campilho. Automatic segmentation of carotid b-mode images using fuzzy classification. *Medical & Biological Engineering & Computing*, 50 :533–545, 2012.
- [213] Annupan Rodtook and Stanislav S. Makhnov. Multi-feature gradient vector flow snakes for adaptive segmentation of the ultrasound images of breast cancer. *Vision Communication and Image Representation*, 24 :1414–1430, 2013.
- [214] Rahimeh Rouhia and Mehdi Jafari. Classification of benign and malignant breast tumors based on hybrid level set segmentation. *Expert Systems with Application*, 46 :45–59, 2016.
- [215] Leonid I. Rudin, Stanley Osher, and Emad Fatemi. Nonlinear total variation based noise removal algorithms. *Physica D*, 60 :259–268, 1992.
- [216] Jorge Hernando Saez, Carlos Tornero Tornero, Vicente Roqués Escolar, Francisco Hernandez Meéndez, and Luis Aliaga Font. Development of complications in ultrasound-guided regional anesthesia vs neurostimulation. *Techniques*, 16 :152–157, 2012.
- [217] J. C. SanMiguel, A. Cavallaro, and J. M. Martinez. Adaptive online performance evaluation of video trackers. *IEEE Transactions on Image Processing*, 21(5) :2812–2823, May 2012.
- [218] Jaime Santos, Jose Silvestre Silva, Andreia Andrade Santos, and Pedro Belo-Soares. Detection of pathologic liver using ultrasound images. *Biomedical Signal Processing and Control*, 14 :248–255, 2014.
- [219] Alessandro Sarti, Cristiana Corsi, Elena Mazzini, and Claudio Lamberti. Maximum likelihood segmentation of ultrasound images with rayleigh distribution. *IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control*, 52(6) :947–960, 2005.
- [220] Luis Savastano and Lynda J.-S. Yang. Chapter 1 – anatomy of the median nerve and its branches. In R. Shane Tubbs, Elias Rizk, Mohammadali M. Shoja, Marios Loukas, Nicholas Barbaro, and Robert J. Spinner, editors, *Nerves and Nerve Injuries*, pages 553 – 562. Academic Press, 2015.

- [221] Harsha Shanthanna. Review of essential understanding of ultrasound physics and equipment operation. *World journal of anesthesiology*, 3(1) :12–17, 2014.
- [222] L.G. Shapiro and G.C. Stockman. *Computer Vision*. Prentice-Hall, 2001.
- [223] Dinggang Shen, Yiqiang Zhan, and C. Davatzikos. Segmentation of prostate boundaries from ultrasound images using statistical shape model. *IEEE Transactions on Medical Imaging*, 22(4) :539–551, 2003.
- [224] Jun Shi, Shichong Zhou, Xiao Liu, Qi Zhang, Minhua Lu, and Tianfu Wang. Stacked deep polynomial network based representation learning for tumor classification with small ultrasound image dataset. *Neurocomputing*, 194 :87–94, 2016.
- [225] E Silvestri, C Martinoli, L E Derchi, M Bertolotto, M Chiaramondia, and I Rosenberg. Echotexture of peripheral nerves : correlation between us and histologic findings and criteria to differentiate tendons. *Radiology*, 197(1) :291–269, 1995.
- [226] Brian D. Sites, Richard Brull, Vincent W. S. Chan, Brian C. Spence, John Gallagher, Michael L. Beach, Vincent R. Sites, Sherif Abbas, and Gregg S. Hartman. Artifacts and pitfall errors associated with ultrasound-guided regional anesthesia. part i : Understanding the basic principles of ultrasound physics and machine operations. *Regional anesthesia and pain medicine*, 32(5) :412–418, 2007.
- [227] Brian D. Sites, Richard Brull, Vincent W. S. Chan, Brian C. Spence, John Gallagher, Michael L. Beach, Vincent R. Sites, Sherif Abbas, and Gregg S. Hartman. Artifacts and pitfall errors associated with ultrasound-guided regional anesthesia. part ii : A pictorial approach to understanding and avoidance. *Regional anes*, 2007.
- [228] Brian D. Sites, Vincent W. Chan, Joseph M. Neal, Robert Weller, Thomas Grau, Zbigniew J. Koscielniak-Nielsen, and Giorgio Ivani. The american society of regional anesthesia and pain medicine, the european society of regional anaesthesia and pain therapy, and the asian australasian federation of pain societies joint committee recommendations for education and training in ultrasound-guided interventional pain procedures. *Regional Anesthesia*, 37 :657–664, 2012.
- [229] Brian D. Sites, Brian C. Spence, John D. Gallagher, Christopher W. Wiley, Marc L. Bertrand, and George T. Blike. Characterizing novice behavior associated with learning ultrasound-guided peripheral regional anesthesia. *Regional Anesthesia and Pain Medicine*, 32(2) :107 – 115, 2007.
- [230] Brian Daniel Sites, Andreas H Taenzer, Michael D Herrick, Constance Gilloon, John Antonakakis, Janeen Richins, and Michael L Beach. Incidence of local anesthetic systemic toxicity and postoperative neurologic symptoms associated with 12,668 ultrasound-guided nerve blocks : an analysis from a prospective clinical registry. *Regional Anesthesia and Pain Medicine*, 37 :478–482, 2012.

- [231] C. Sjöberg and A. Ahnesjö. Multi-atlas based segmentation using probabilistic label fusion with adaptive weighting of image similarity measures. *Computer Methods and Programs in Biomedicine*, 110 :308–319, 2013.
- [232] S. Solbo and T. Eltoft. Homomorphic wavelet-based statistical despeckling of sar images. *Geoscience and Remote Sensing, IEEE Transactions on*, 42(4) :711–721, 2004.
- [233] T. Steinfeldt, U. Schwemmer, T. Volk, M. Neuburger, T. Wiesmann, A.R. Heller, O. Vicent, A. Stanek, M. Franz, H. Wulf, and P. Kessler. Nerve localization for peripheral regional anesthesia. *Anesthesist*, 63 :597–602, 2014.
- [234] Vidya K Sudarshan, Muthu Rama Krishnan Mookiah, U Rajendra Acharya, Vinod Chandran, Filippo Molinari, Hamido Fujita, and Kwan Hoong. Application of wavelet techniques for cancer diagnosis using ultrasound images : A review. *Computers in Biology and Medicine*, 69 :97–111, 2016.
- [235] Z. Tao, H. D. Tagare, and J. D. Beaty. Evaluation of four probability distribution models for speckle in clinical cardiac ultrasound images. *IEEE Transactions on Medical Imaging*, 25(11) :1483–1491, 2006.
- [236] Joshua B. Tenenbaum, Vin de Silva, and John C. Langford. A global geometric framework for nonlinear dimensionality reduction. *Science*, 290 :2319–2323, 2000.
- [237] E. Thouin, A. Hafiane, P. Vieyres, N. Xylourgos, G. Triantafyllidis, and G. Papadourakis. Nerve region segmentation for ultrasound guided local regional anaesthesia (lra). In *Mediterranean Conference on Information Systems*, 2011.
- [238] Carlos Tornero Tornero and Luis Aliaga Font. Training on regional anesthesia—from neurostimulation to ultrasound. *Techniques in Regional Techniques and Pain Management*, 16 :131–125, 2012.
- [239] Nikolaos N. Tsiaparas, S. Golemati, I. Andreadis, J.S. Stoitsis, I. Valavanis, and K.S. Nikita. Comparison of multiresolution features for texture classification of carotid atherosclerosis from b-mode ultrasound. *Information Technology in Biomedicine, IEEE Transactions on*, 15(1) :130–137, Jan 2011.
- [240] Ban C.H. Tsui. Chapitre 2 - electrical nerve stimulation. In V. Chan, B. Finucane, Th. Grau, and A. Walji, editors, *Atlas of Ultrasound- and Nerve Stimulation-Guided Regional Anesthesia*, pages 9–18. 2008.
- [241] Fayyaz ul Amir Afsar Minhas, Durre Sabih, and Mutawarra Hussain. Automated classification of liver disorders using ultrasound images. *Medical Systems*, 36 :3163–3172, 2012.
- [242] Bram van Ginneken, Alejandro F. Frangi, Joes J. Staal, Bart M. ter Haar Romeny, and Max A. Viergever. Active shape model segmentation with optimal features. *IEEE Transactions on Medical Imaging*, 21(8) :924–933, 2002.
- [243] Alexander Vasilevskiy and Kaleem Siddiqi. Flux maximizing geometric flows. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(12) :1565–1578, 2002.

- [244] Luminita A. Vese and Tony F. Chan. A multiphase level set framework for image segmentation using the mumford and shah model. *Computer Vision*, 50(3) :271–293, 2002.
- [245] K. Sudarshan Vidya, E.Y.K Ng, U. Rajendra Acharya, Siaw Meng Chou, Ru San Tan, and Dhanjoo N. Ghista. Computer-aided diagnosis of myocardial infarction using ultrasound images with dwf, {GLCM} and {HOS} methods : A comparative study. *Computers in Biology and Medicine*, 62 :86 – 93, 2015.
- [246] Grace Wahba. Advances in kernel methods. chapter Support Vector Machines, Reproducing Kernel Hilbert Spaces, and Randomized GACV, pages 69–88. MIT Press, Cambridge, MA, USA, 1999.
- [247] Hongzhi Wang, Yu Cao, and Tanveer Syeda-Mahmood. *Multi-atlas Segmentation with Learning-Based Label Fusion*, pages 256–263. Springer International Publishing, 2014.
- [248] Hongzhi Wang, Jung W. Suh, Sandhitsu R. Das, John Pluta, Caryne Craige, and Paul A. Yushkevich. Multi-atlas segmentation with joint label fusion. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 35 :611–623, 2013.
- [249] Hui Wang, Ting-Zhu Huang, Zongben Xu, and Yilun Wang. An active contour model and its algorithms with local and global gaussian distribution fitting energies. *Information Sciences*, 263 :43–59, 2014.
- [250] Hui Wang, Ting-Zhu Huang, Zongben Xu, and Yilun Wang. A two-stage image segmentation via global and local region active contours. *Neurocomputing*, 205 :130–140, 2016.
- [251] Huiwen Wang, Rong Guan, and Junjie Wu. Cipca : Complete-information-based principal component analysis for interval-valued data. *Neurocomputing*, 86 :158 – 169, 2012.
- [252] Jun Wang and Yuehuan Wang. Multi-period visual tracking via online deepboost learning. *Neurocomputing*, pages 55–69, 2016.
- [253] Weiming Wang, Lei Zhu, Jing Qin, Yim-Pan Chui, Bing Nan Li, and Pheng-Ann Heng. Multiscale geodesic active contours for ultrasound image segmentation using speckle reducing anisotropic diffusion. *Optics and Lasers in Engineering*, 54 :105–116, 2014.
- [254] L. J. Wei. Asymptotic conservativeness and efficiency of kruskal-wallis test for k dependent samples. *Journal of the American Statistical Association*, 76(376) :1006–1009, December 1981.
- [255] J. C. Weszka, C. R. Dyer, and A. Rosenfield. A comparative study of texture measures for terrain classification. *IEEE Transactions on Systems, Man and Cybernetics*, SMC-6 :269–285, 1976.
- [256] David Wilson and Swamy Laxminarayan. *Handbook of Biomedical Image Analysis*, volume Volume 3 : Registration Models of *Topics in Biomedical Engineering. International Book Series*. Springer US, 1 edition, 2005.
- [257] Svante Wold. Principale component analysis. *Chemometrics and Intelligent Laboratory Systems*, 2 :37–52, 1987.

- [258] Chung-Ming Wu, Yung-Chang Chen, and Kai-Sheng Hsieh. Texture features for classification of ultrasonic liver images. *Medical Imaging, IEEE Transactions on*, 11(2) :141–152, Jun 1992.
- [259] Wenfeng Xia, Jean Martial Mari, Simeon J. West, Yuval Ginsberg, Anna L. David, Sebastien Ourselin, and Adrien E. Desjardins. In-plane ultrasonic needle tracking using a fiber-optic hydrophone. *Medical Physics*, 42 :5983 – 5991, 2015.
- [260] Wenfeng Xia, Simeon J. West, Daniil I. Nikitichev, Sebastien Ourselin, Paul C. Beard, and Adrien E. Desjardins. Interventional multispectral photoacoustic imaging with a clinical linear array ultrasound probe for guiding nerve blocks. volume 9708, pages 97080C–97080C–6, 2016.
- [261] M. Xian, Y. Zhang, and H.D. Cheng. A fully automatic segmentation method for breast ultrasound images. *Pattern Recognition*, 48 :485–497, 2015.
- [262] Chenyang Xu and Jerry L. Prince. Generalized gradient vector flow external forces for active contours. *Signal Processing*, 71 :131–139, 1998.
- [263] Chenyang Xu and Jerry L. Prince. Snakes, shapes, and gradient vector flow. *IEEE Transactions on Image Processing*, 7(3) :359–369, 1998.
- [264] Chenyang Xu and Jerry L. Prince. Snakes, shapes, and gradient vector flow. *IEEE TRANSACTIONS ON IMAGE PROCESSING*, 7(3) :359–369, 1998.
- [265] Haiyong Xu, Gangyi Jianga, Mei Yua, and Ting Luo. A local gaussian distribution fitting energy-based active contour model for image segmentation. *Computer and Electrical Engineering*, 000 :1–17, 2016.
- [266] Jianbo Yu. Adaptive hidden markov model-based online learning framework for bearing faulty detection and performance degradation monitoring. *Mechanical Systems and Signal Processing*, 2016.
- [267] Jinhua Yu, Yuanyuan Wang, and Yuzhong Shen. Noise reduction and edge detection via kernel anisotropic diffusion. *Pattern Recognition Letters*, 29 :1496–1503, 2008.
- [268] Lei Yu and Huan Liu. Feature selection for high-dimensional data : A fast correlation-based filter solution. pages 856–863, 2003.
- [269] Yanyan Yu, Yimin Chen, and Bernard Chiu. Fully automatic prostate segmentation from transrectal ultrasound images based on radial bas-relief initialization and slice-based propagation. *Computers in Biology and Medicine*, 74 :74–90, 2016.
- [270] Yongjian Yu and S. T. Acton. Edge detection in ultrasound imagery using the instantaneous coefficient of variation. *IEEE Transactions on Image Processing*, 13(12) :1640–1655, 2004.
- [271] Amjad Zaim, Taeil Yi, and Rick Keck. Feature-based classification of prostate ultrasound images using multiwavelet and kernel support vector machines. In *International Joint Conference on Neural Networks*, pages 278–281, 2007.
- [272] Wenchao Zhang, Shiguang Shan, Wen Gao, Xilin Chen, and Hongming Zhang. Local gabor binary pattern histogram sequence (lgbphs) : a novel non-statistical model for face represen-

- tation and recognition. In *IEEE International Conference on Computer Vision*, volume 1, pages 786–791, 2005.
- [273] Jie Zhao, Wei Zheng, Li Zhang, and Hua Tian. Segmentation of ultrasound images of thyroid nodule for assisting fine needle aspiration cytology. *Health Information Science and Systems*, 2012.
- [274] Y. Zhao, A. Bernard, C. Cachard, and H. Liebgott. Biopsy needle localization and tracking using roi-rk method. *Abstract and Applied Analysis*, in press, 2014.
- [275] Shichong Zhou, Jun Shi, Jie Zhu, Yin Cai, and Ruiling Wang. Shearlet-based texture feature extraction for classification of breast tumor in ultrasound image. *Biomedical Signal Processing and Control*, 8 :688–696, 2013.
- [276] Xinjian Zhu, Pengfei Zhang, Jinhua Shao, Yuanzhi Cheng, Yun Zhang, and Jing Bai. A snake-based method for segmentation of intravascular ultrasound images and its in vivo validation. *Ultrasonics*, 51 :181–189, 2011.
- [277] Yun Zhu, Xenophon Papademetris, Albert J. Sinusas, and James S. Duncan. Segmentation of myocardial volumes from real-time 3d echocardiography using an incompressibility constraint. In *Medical Image Computing and Computer-Assisted Intervention*, pages 44–51, 2007.
- [278] Yun Zhu, Xenophon Papademetris, Albert J. Sinusas, and James S. Duncan. A dynamical shape prior for lv segmentation from rt3d echocardiography. In *Medical Image Computing and Computer-Assisted Intervention*, pages 206–213, 2009.
- [279] Mehrnaz Zouqi and Jagath Samarabandu. Prostate segmentation from 2-d ultrasound images using graph cuts and domain knowledge. In *Canadian Conference on Computer and Robot Vision*, pages 359–362. IEEE, 2008.

[Oussama HADJERCI]
**Détection automatique du nerf dans les images
échographiques**

Résumé :

L'anesthésie loco-régionale présente une alternative intéressante à l'anesthésie générale dans de nombreuses interventions chirurgicales. L'atout majeur de cette technique est qu'elle réduit grandement les scores de douleurs et améliore par la même la mobilité post-opératoire. L'anesthésie locorégionale écho-guidée (UGRA) devient aujourd'hui, la méthode de référence dans le domaine de l'anesthésie, offrant de nombreux avantages par rapport aux autres méthodes comme la neurostimulation. Cependant, cette technique nécessite en contrepartie un apprentissage spécifique afin d'éviter des complications sévères liées à une erreur de localisation visuelle du nerf dans les images échographiques.

L'objectif de cette thèse est de faciliter et de sécuriser la pratique de l'anesthésie loco-régionale écho-guidée. Dans un premier temps, nous avons proposé une méthode de détection du nerf mettant en œuvre un algorithme qui suite à un prétraitement à partir de filtres fréquentielles, réalise une analyse de texture par apprentissage. Dans ce cadre, deux nouvelles approches ont été explorées : l'une concerne la caractérisation du nerf qui s'appuie sur la prise en compte du bruit présent dans une image ultrasonore, bruit ayant été au préalable atténué partiellement. L'autre propose une technique de sélection des caractéristiques mettant en avant celles qui sont les moins redondantes et les plus pertinentes.

Dans un second temps, après étude fine du comportement variable de la morphologie du nerf tout au long d'une séquence d'images ultrasonores, nous avons développé un modèle dynamique ayant comme paramètres des informations en lien avec la cohérence temporelle de la position, de la forme et la confiance de classification des ROI potentielles afin de générer une segmentation robuste. Il est proposé également dans cette partie, un nouveau modèle de forme prenant en compte un ensemble d'intervalles de points de repères du contour, permettant ainsi de s'adapter aux variations de la forme du nerf dans le temps.

Mots clés : anesthésie loco-régionale écho-guidée, détection du nerf, analyse de texture, apprentissage supervisé, modèle dynamique.

Automatic Nerve detection in ultrasound images

Abstract :

Regional anesthesia presents an interesting alternative or complementary act to general anesthesia in many surgical procedures. It reduces pain scores, improves postoperative mobility and facilitates earlier hospital discharge. Ultrasound-Guided Regional Anesthesia (UGRA) has been gaining importance in the last few years, offering numerous advantages over alternative methods of nerve localization (neurostimulation or paraesthesia). However, nerve detection is one of the most difficult tasks that anesthetists can encounter in the UGRA procedure.

The context of the present work is to provide practitioners with a method to facilitate and secure the practice of UGRA. However, automatic detection and segmentation in ultrasound images is still a challenging problem in many medical applications. This work addresses two main issues. The first one, we propose an algorithm for nerve detection and segmentation in ultrasound images, this method is composed of a pre-processing, texture analysis and machine learning steps. In this part of work, we explore two new approaches ; one to characterize the nerve and the second for selecting the minimum redundant and maximum relevant features. The second one, we studied the nerve detection in consecutive ultrasound frames. We have demonstrated that the development of an algorithm based on the temporal coherence of the position, the shape and the confidence measure of the classification, allows to generate a robust segmentation. In this work, we also propose a new model of shape based on a set of intervals landmarks able to adapt to the nerve shape under a morphological variations.

Keywords : ultrasound-guided regional anathesia , Nerve detection, texture analysis, machine learning, dynamic model.