

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC

MÉMOIRE PRÉSENTÉ À
L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

COMME EXIGENCE PARTIELLE
À L'OBTENTION DE LA
MAÎTRISE EN GÉNIE ÉLECTRIQUE
M.Sc.A.

PAR
Samuel RISPAL

DISCRIMINATION DE TEXTURES ET QUANTIFICATION DE RUGOSITÉ PAR ALGORITHME
D'APPRENTISSAGE

MONTRÉAL, LE 2 OCTOBRE 2014

© Tous droits réservés, Samuel Rispal, 2014

© Tous droits réservés

Cette licence signifie qu'il est interdit de reproduire, d'enregistrer ou de diffuser en tout ou en partie, le présent document. Le lecteur qui désire imprimer ou conserver sur un autre media une partie importante de ce document, doit obligatoirement en demander l'autorisation à l'auteur.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE:

M. Vincent Duchaine, directeur de mémoire

Département de génie de la production automatisée, École de Technologie Supérieure (ÉTS)

M. Tony Wong, président du jury

Département de génie de la production automatisée, École de Technologie Supérieure (ÉTS)

M. Philippe Cardou, membre du jury

Département de génie mécanique, Université Laval

IL A FAIT L'OBJET D'UNE SOUTENANCE DEVANT JURY ET PUBLIC

LE 23 SEPTEMBRE 2014

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

Pour commencer ce mémoire, je tiens à remercier Vincent Duchaine, mon maître de mémoire qui m'a offert un bon encadrement, des idées innovantes et une grande motivation.

Je tiens aussi à remercier Jean-Philippe Roberge, professionnel de recherche du laboratoire CORO, qui a toujours été là pour soutenir mon projet tant techniquement que moralement.

Je tiens aussi à remercier Claire Florent et Geneviève-Kim Bouret qui m'ont aidé à retravailler mon mémoire pour en faire un document de qualité.

Je veux aussi dire un grand merci à toutes les personnes qui ont accepté de participer à mon expérience sur la quantification de la rugosité. Merci pour leur disponibilité et leur motivation.

Enfin, je remercie Axay, Reza, Jean-Baptiste et tous les autres membres du laboratoire CORO pour le milieu de travail exceptionnel dans lequel nous étudions. Je souligne aussi leur disponibilité, leur assistance technique et leurs idées pertinentes pour mon projet.

Pour terminer, il m'est important de remercier ma famille et mes amis, de France et du Canada, qui m'ont soutenu durant ces deux ans de maîtrise et grâce à qui j'ai trouvé l'énergie positive pour mon travail.

DISCRIMINATION DE TEXTURES ET QUANTIFICATION DE RUGOSITÉ PAR ALGORITHME D'APPRENTISSAGE

Samuel RISPAL

RÉSUMÉ

Alors que la recherche en robotique progresse sur la manipulation d'objets, nous nous sommes intéressés à trouver des informations qui pourraient permettre d'améliorer la dextérité du robot si ce dernier en avait connaissance avant la manipulation. Nous supposons que lorsqu'une personne observe un objet, elle intègre en même temps un certain nombre de ses caractéristiques (forme, texture, rugosité, fragilité, déformabilité...). Ces informations conditionnent son mouvement et lui permettent de mieux manipuler l'objet. En allant dans ce sens, nous cherchons à donner au toucher un moyen d'acquérir ce type d'informations. Pour cela, l'objectif de notre étude est de proposer un algorithme léger et utilisant des mouvements d'acquisition rapides pour permettre à un robot de distinguer des textures et d'estimer la rugosité. Cet algorithme a pour objectif de pouvoir être utilisé en temps réel.

Dans un premier temps, nous sommes repartis de différentes études sur la discrimination de textures. Nous avons réalisé trois études visant à reconnaître différentes textures malgré des vitesses, des forces ou une orientation d'acquisition différentes. Nous avons aussi fait une étude sur 10 textures fines visant à différencier des textures proches. Pour chaque simulation (RNA ou SVM), optimisée par algorithme génétique, la reconnaissance dépasse 90%. Nous avons noté l'intérêt d'utiliser des algorithmes génétiques pour optimiser la simulation. Néanmoins, ces algorithmes sont limités car il est nécessaire d'apprendre une texture avant de pouvoir la reconnaître.

Dans une seconde étude, nous avons cherché à estimer la rugosité d'un matériau en se basant sur une échelle humaine : nous avons demandé à 30 personnes de donner un indice de rugosité allant de 1 à 10 pour 25 textures. Ensuite, nous avons créé un algorithme cherchant à estimer la rugosité en étalonnant notre échelle avec les résultats de nos participants. Nous avons pu voir que l'homme a du mal à définir de manière précise la rugosité sur une échelle de 1 à 10. Malgré quatre propositions d'architecture et différents traitements, l'algorithme a aussi eu des difficultés à généraliser les résultats avec uniquement 25 textures. Une étude avec plus de textures serait nécessaire.

Mot-clés : capteur tactile, algorithme d'apprentissage, algorithme génétique

TITRE ORIGINAL

Samuel RISPAL

ABSTRACT

During the last years, the research on robotic object's manipulation made interesting progresses. In order to improve robot's dexterity, this essay proposes a new approach to find information about the robot's neighborhood using tactile sensors. We focus on two main properties : textures discrimination and roughness estimation.

We propose three experiments on textures discrimination : the first one discriminates 4 textures with different speeds and strengths between the sensor and the texture during the acquisition. The second one proposes a way to recognize a texture in spite of the initial orientation of the sensor on the texture. The last one discriminates 10 smooth textures showing the sensor's accuracy. For each experience, the simulations using ANN or SVM and optimized by genetic algorithm have results higher than 90% of recognition. The use of genetic algorithm has an interesting impact and allow to find the best value for different variables. The limit of this kind of algorithm is the necessity of learning each texture you need to recognize.

In our second study, we look for a scale to estimate any texture's roughness based on human roughness feeling. To create this scale we asked 30 people to classify 25 textures chosen from the smoothest to the roughest on a scale from 1 to 10. Then, we create an algorithm to estimate the roughness using these results. We conclude human roughness feeling have difficulties to estimate roughness with precision on a scale from 1 to 10. Despite using 4 different algorithms, we have troubles to generalize the algorithm on unknown textures. A new study with more textures should be necessary.

Keywords: Tactile sensing, learning algorithm, genetic algorithm

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 DE LA MAIN HUMAINE À LA MAIN ROBOTISÉE	5
1.1 La sensibilité humaine : 4 mécanorécepteurs différents travaillant en corrélation..	6
1.2 Des capteurs variés pour simuler les mécanorécepteurs humains	8
1.3 Un capteur multi-utilisation et ultra sensible	11
1.3.1 Information statique : une vision 3D des forces.....	12
1.3.1.1 Principe : Estimer la capacité pour retrouver les forces.....	12
1.3.1.2 Caractérisation : Etude de l'exactitude des informations mesurées	14
1.3.1.3 Conclusion : Forces et faiblesses.....	18
1.3.2 Information dynamique : Mieux connaître les interactions à haute fréquence	21
1.3.2.1 Principe : Estimer les écarts de capacité pour trouver les variations des forces	21
1.3.2.2 Caractérisation : Etude de l'exactitude des informations mesurées	23
1.3.2.3 Conclusion : Forces et faiblesses.....	25
CHAPITRE 2 RECONNAISSANCE DE TEXTURES À L'AIDE D'ALGORITHMES D'APPRENTISSAGE	27
2.1 Recherche documentaire	28
2.1.1 Qu'est ce qu'une texture ?.....	28
2.1.2 Les différentes méthodes pour reconnaître une texture	29
2.2 Approche	34
2.3 Principe de l'algorithme	35
2.3.1 Acquisition	35
2.3.2 Pré-traitements	37
2.3.3 Sélection des discriminants	37
2.3.4 Apprentissage	38
2.3.5 Optimisation par algorithme génétique	40
2.4 Mouvements de courts glissements linéaires (MCGL)	42
2.4.1 Protocole expérimental	42
2.4.2 Résultats.....	44
2.5 Mouvements d'exploration circulaire (MEC).....	48
2.5.1 Protocole expérimental	49
2.5.2 Résultats.....	51
2.6 Étude finale : différenciation de textures fines	53
2.6.1 Protocole expérimental	54
2.6.2 Résultats.....	54

2.7	Discussion	55
CHAPITRE 3 QUANTIFICATION DE LA RUGOSITÉ À L'ÉCHELLE HUMAINE .		59
3.1	Approche proposée	61
3.2	Étude de l'évaluation de la rugosité par l'être humain	62
3.2.1	Présentation de l'étude	62
3.2.2	Présentation des textures	63
3.2.3	Résultats de l'expérience	63
3.2.4	Hypothèse pour la simulation	66
3.3	Principe de l'algorithme	68
3.3.1	Acquisition	68
3.3.2	Pré-traitements	68
3.3.3	Sélection des discriminants	68
3.3.4	Apprentissage	69
3.3.5	Optimisation par l'algorithme génétique	70
3.4	Résultats	71
3.4.1	RNA unique	72
3.4.2	RNA3	72
3.4.3	SVM10	73
3.5	Discussion	74
CONCLUSION		77
BIBLIOGRAPHIE		79

LISTE DES TABLEAUX

	Page
Tableau 2.1	Matrice de confusion de MCGL avec des SVM 44
Tableau 2.2	Valeurs des variables de l'algorithme génétique pour les RNA 46
Tableau 2.3	Valeurs des variables de l'algorithme génétique pour les SVM 46
Tableau 2.4	Matrice de confusion de MCGL avec des SVM en vote majoritaire (5 votes) 47
Tableau 2.5	Valeurs des variables de l'algorithme génétique pour les RNA (vote majoritaire) 47
Tableau 2.6	Valeurs des variables de l'algorithme génétique pour les SVM (vote majoritaire) 48
Tableau 2.7	Matrice de confusion de MEC avec des SVM et un mouvement exploratoire rotatif 51
Tableau 2.8	Valeurs des variables de l'algorithme génétique pour les RNA (mouvement rotatif) 52
Tableau 2.9	Valeurs des variables de l'algorithme génétique pour les SVM (mouvement rotatif) 53
Tableau 2.10	Matrice de confusion des SVM sur 10 textures fines 55
Tableau 3.1	Tableau des textures d'apprentissage 67
Tableau 3.2	Tableau des textures de tests 67
Tableau 3.3	Résultats synthétiques des 4 architectures 71

LISTE DES FIGURES

	Page
Figure 1.1 Exemple de signaux des différents mécanorécepteurs de la main humaine lorsqu'elle effleure une surface Tirée de Vallbo et Johansson (1984)	6
Figure 1.2 Photo du capteur	11
Figure 1.3 Exemple de données statiques.....	12
Figure 1.4 Photo de la forme de la mousse utilisée entre les deux armatures du condensateur Tirée de Axaykumar et Vincent (2013)	13
Figure 1.5 Banc de mesure utilisé pour les expériences de caractérisation du capteur ..	15
Figure 1.6 Zones de pression testées pour caractériser la fonction statique du capteur .	16
Figure 1.7 Caractérisation de la fonction statique du capteur : Estimation de la force en fonction du nombre de comptes	16
Figure 1.8 Estimation de l'incertitude sur la mesure statique du capteur	17
Figure 1.9 Visualisation du mode hyper-sensibilité	18
Figure 1.10 Second exemple de l'influence de l'hystérésis	20
Figure 1.11 Premier exemple de l'influence de l'hystérésis.....	20
Figure 1.12 Illustration des effets de bord.....	21
Figure 1.13 Montage amplificateur de charge Tirée de Nelson et Davidson (2002)	22
Figure 1.14 Montage global du circuit dynamique du capteur	23
Figure 1.15 Photo de l'haptuator	24
Figure 1.16 Exemple de signal dynamique et sa transformée de Fourier	25
Figure 1.17 Exemple de signal dynamique et sa transformée de Fourier	26
Figure 2.1 Illustration des deux mouvements exploratoires utilisés	34
Figure 2.2 Banc d'acquisition des textures	36

Figure 2.3	Modèle du réseau de neurones utilisé	39
Figure 2.4	Textures pour l'expérience MCGL	43
Figure 2.5	Surface du capteur utilisé	43
Figure 2.6	FFT de deux acquisitions des textures 2 (à gauche) et 3 (à droite) à même vitesse et force moyenne	45
Figure 2.7	Illustration des deux mouvements exploratoires utilisés	50
Figure 2.8	Textures pour l'expérience MEC	50
Figure 2.9	Textures pour l'expérience de sensibilité	54
Figure 3.1	Présentation des différentes textures	64
Figure 3.2	Graphique des votes des participants	65
Figure 3.3	Ecart-type des textures	66
Figure 3.4	Erreur de l'algorithme RNA unique en fonction du set d'apprentissage et de test	72
Figure 3.5	Erreur de l'algorithme RNA3 en fonction du set d'apprentissage et de test	73
Figure 3.6	Erreur de l'algorithme SVM10 en fonction du set d'apprentissage et de test	74

LISTE DES SYMBOLES ET UNITÉS DE MESURE

C	Capacité d'un condensateur
e	Distance entre les deux armatures d'un condensateur
ϵ	Permittivité d'un diélectrique
F_a	Force appliquée sur le capteur
$f_e()$	Fonction donnant la distance entre deux armatures en fonction de la force appliquée sur le capteur.
L	Longueur du profil d'une surface
S	Surface des armatures du condensateur
y	Amplitude du profil d'une surface

INTRODUCTION

Avez-vous déjà imaginé l'importance de votre sens du toucher ? Il permet de sentir votre environnement, mais dans une finesse très intéressante. Il donne la possibilité de sentir le contact, la nature d'une texture, la forme d'un objet et les nombreuses propriétés des objets comme la fragilité, la rugosité, la déformabilité, l'adhérence. Il permet aussi une manipulation très habile de l'environnement : L'humain attrape les objets sans les abîmer, les déplace sans les échapper, et les relâche avec précision à l'endroit désiré. Il est capable de sentir un objet à travers un autre comme par exemple les aliments à travers les ustensils durant un repas. Enfin, il peut réaliser des actions demandant une grande précision (montage/démontage d'objets...). Pour appuyer cela, Robles-De-La-Torre (2006) présente le cas d'un homme ayant perdu le sens du toucher dans tout son corps. Au moment de l'accident, il ne pouvait plus rien faire, juste être dans son lit était terrifiant car il avait l'impression de flotter. Plusieurs mois ont été nécessaires pour réapprendre à marcher. La manipulation d'objets reste toujours un défi car il n'arrive pas à les saisir correctement, les presse trop fort ou les échappe. Il n'utilise que des objets non déformables afin de pouvoir appliquer une force plus importante que nécessaire sans détruire l'objet. Une année d'étude dans une école spécialisée a été nécessaire pour réapprendre à écrire.

Durant la manipulation d'un objet, l'information tactile renvoyée peut être séparée en deux catégories : l'information extéroceptive et proprioceptive. L'information extéroceptive concerne directement le toucher, c'est-à-dire le contact entre le corps humain et l'environnement extérieur : les textures, les glissements, les vibrations... Ces informations sont cruciales pour manipuler un objet sans l'échapper ou l'abîmer. L'information proprioceptive permet de situer notre corps, la position dans laquelle il se trouve sans avoir à le regarder. Atkins *et al.* (1996) ont effectué une étude auprès de 2477 amputés et montrent que leur plus grande difficulté reste le manque d'informations proprioceptives plus que celles extéroceptives : en effet, ils n'arrivent pas à localiser la position de leur prothèse sans la regarder. Pour conclure, De Vignemont *et al.* (2005) montrent que ces deux composantes du sens du toucher sont liées et nécessaires pour une bonne manipulation d'objets.

Aujourd'hui, les capteurs tactiles pour les mains robotisées commencent à émerger et répondent à un besoin de l'industrie ayant pour objectif de donner plus d'autonomie aux robots et de les rendre moins dangereux pour leur environnement. Il existe autant des capteurs proprioceptifs comme Carrozza *et al.* (2003) que extéroceptifs comme Howe et Cutkosky (1989). Dans notre étude, nous travaillerons uniquement sur les capteurs proprioceptifs car nous réalisons une recherche sur la caractérisation des textures de l'environnement de la main robotisée.

Souvent, des systèmes de vision ont été associés aux robots mais ils ne sont pas suffisants. Comme le montre Johansson et Flanagan (2009), le sens de la vision permet uniquement la planification du mouvement et non la manipulation. Malgré les récentes intégrations de capteurs tactiles aux mains robotisées, les signaux récupérés représentent la répartition des forces à la surface du capteur et sont encore très loin de l'intuitivité humaine.

C'est pourquoi depuis plus de 40 ans, les chercheurs explorent différentes manières de donner un sens du toucher plus intelligent aux robots. Aujourd'hui, les recherches ont fait des progrès et proposent divers modèles pour les mains robotisées principalement autour de la prise d'un objet et de l'analyse des vibrations transmises durant différents glissements. Différentes approches en temps réel ont été réalisées et divers projets industriels commencent à voir le jour.

Pour notre étude, nous partons d'un constat : quand l'être humain connaît un objet, il le manipule différemment suivant ses propriétés. Par exemple, Savelsbergh *et al.* (1996) ont montré qu'un objet fragile n'est pas manipulé de la même manière qu'un autre objet. Il semble donc intéressant de pouvoir obtenir de l'information sur l'objet avant la manipulation, comme sa rugosité, sa fragilité, son adhésion, sa déformabilité, sa forme... Cela peut permettre par la suite de créer des réflexes naturels pour le robot dans sa manipulation d'objets. On peut imaginer à moyen terme qu'il suffise de demander au robot d'attraper et déplacer un objet pour qu'il planifie son mouvement, l'attrape avec dextérité, le déplace sans l'échapper et le repose en douceur à l'endroit demandé. De même, on peut imaginer un robot réalisant des assemblages relativement complexes à une ou deux mains utilisant le retour tactile pour assembler correctement les objets sans les abîmer et vérifier que l'assemblage ait bien été réalisé.

Cette étude a pour objectif d'introduire ce sujet en proposant des méthodes pour quantifier certaines caractéristiques des textures. La première partie de ce travail porte sur la différenciation de textures et cherche aussi à définir différents mouvements d'exploration. La seconde partie propose une méthode pour classer les textures sur une échelle de rugosité de 1 à 10. Ces deux études ont pour objectif de caractériser les textures par des informations utiles permettant diverses applications. Par exemple, on peut imaginer des algorithmes de reconnaissances d'objets utilisant la discrimination de textures. De même, la connaissance de la rugosité pourrait permettre une meilleure manipulation des objets grâce à une connaissance accrue de la texture. Enfin, ces données peuvent contribuer à la résolution d'un problème non résolu de la robotique : distinguer le glissement d'un objet en mouvement dans la main à celui de l'objet frottant avec une autre surface.

Le mémoire est séparé en trois parties. Dans un premier temps, le domaine de la robotique tactile est introduit. Nous nous intéressons au fonctionnement de la main humaine, aux différents capteurs tactiles existants et nous terminons en présentant notre capteur et sa caractérisation.

La seconde partie s'intéresse à la discrimination de textures. Avec différents sets de textures, nous nous intéressons à les différencier en étant indépendant de la vitesse et de la force appliquée durant l'acquisition. Nous cherchons aussi une invariance en rotation sur les textures ayant des particularités géométriques (stries, quadrillages, cercles...). Pour terminer cette partie, une étude sur des textures fines conclue en montrant les discriminations possibles sur des textures peu différenciables par l'être humain.

Enfin, la dernière partie présente une expérience d'évaluation de la rugosité des textures. L'objectif est d'estimer la rugosité des textures sur une échelle de 1 à 10 à la manière dont l'être humain pourrait les classer naturellement. Pour calibrer l'échelle, il a été demandé à 30 personnes de classer 25 textures sur une échelle de 1 à 10. Cela nous permet ensuite, en repartant de l'algorithme de la partie précédente, de réaliser cette échelle sur le capteur tactile.

CHAPITRE 1

DE LA MAIN HUMAINE À LA MAIN ROBOTISÉE

Ce premier chapitre a pour objectif d'introduire le lecteur au domaine de la sensibilité tactile. Comme la robotique s'inspire souvent du fonctionnement de l'être humain, une première section introduit au fonctionnement des mécanorécepteurs de la main humaine permettant de ressentir le toucher. Cela permet dans un second temps de faire un parallèle avec les capteurs tactiles existants. Ensuite, une présentation détaillée du capteur utilisé dans ce mémoire est effectuée avec une caractérisation complète. Enfin, la quatrième et dernière section propose une brève revue de littérature sur les frottements : les capteurs donnent des informations sur l'interaction des objets en contact avec leur surface. Il est donc important de comprendre ce domaine.

1.1 La sensibilité humaine : 4 mécanorécepteurs différents travaillant en corrélation

La main humaine est composée de quatre mécanorécepteurs. De nombreuses recherches ont lieu depuis longtemps, comme cette étude de Sato (1961) identifiant la réponse fréquentielle des corpuscules de Pacinian. Parmi les pionniers de l'identification des mécanorécepteurs se trouvent Vallbo et Hagbarth (1968) et Johansson et Vallbo (1979) qui ont beaucoup fait avancer la recherche sur la différenciation des mécanorécepteurs à travers leurs articles. Vallbo et Johansson (1984) identifient une distinction en deux catégories des mécanorécepteurs : certains sont sensibles aux charges statiques alors que d'autres réagissent uniquement aux charges dynamiques, c'est-à-dire aux variations d'effort. Pourtant, la plupart des chercheurs négligent ces derniers alors qu'il a été montré qu'ils représentent plus de 50% des mécanorécepteurs de la main et jouent un rôle important dans la manipulation d'objets grâce à leur contenu haute-fréquence permettant d'acquiescer les vibrations et les glissements. La figure 1.1 présente de manière intéressante la distinction entre ces deux types d'information (FA : dynamique, SA : statique).




Figure 1.1 Exemple de signaux des différents mécanorécepteurs de la main humaine lorsqu'elle effleure une surface
Tirée de Vallbo et Johansson (1984)

Johnson (2001) a rassemblé les recherches sur les mécanorécepteurs afin de proposer un compte-rendu de chacun de ces récepteurs :

Disques de Merkel (SA1) : Ces capteurs sont très nombreux dans la peau (environ 100 par cm^2). Ils sont très sensibles aux points, aux angles et aux courbes. Un capteur détecte des détails de l'ordre de 0.5mm dans un champ de 2-3mm. Ils sont principalement responsables de la détection des textures. Ces capteurs renvoient au cerveau une image tactile de l'objet touché.

Corpuscules de Meissner (RA ou FA1) : Ces récepteurs sont plus nombreux (150 par cm^2) dans la main humaine. Ils sont insensibles au ressenti statique de la main mais sont très sensibles aux déformations dynamiques sur un rayon de 3 à 5mm. Ils permettent de détecter les glissements dans un objet dans une main et les premiers contacts. En général, ils fournissent les informations permettant de contrôler la saisie d'un objet.

Corpuscules de Pacinian (PC ou FA2) : Ces récepteurs sont ultrasensibles. Ils répondent à un déplacement de 10nm ou moins à une fréquence de 200Hz. Ils permettent essentiellement de comprendre l'univers qui nous entoure à travers un objet dans notre main. Par exemple, sentir le type de sable se trouvant sur une pelle.

Terminaisons de Ruffini (SA2) : Ces récepteurs sont beaucoup plus gros et moins nombreux que les autres. Ils ont aussi été moins étudiés. Néanmoins, deux utilités leur sont attribuées : déterminer le sens du glissement d'un objet dans une main. Ils permettent aussi de connaître la position des doigts en fonction de la manière dont la main est étirée. Nous n'approfondirons pas notre étude sur ces récepteurs n'ayant aucun impact sur les textures.

La figure 1.1 montre un exemple des signaux reçus par le cerveau durant l'effleurement d'une texture. Pour le même signal, cette figure montre à travers les tirets verticaux les acquisitions de chaque mécanorécepteurs.

Blake *et al.* (1997) se sont spécialement intéressés au fonctionnement de la perception de la rugosité des surfaces. Ils montrent qu'il existe une certaine corrélation entre les signaux, même si la perception est essentiellement due aux variations spatiales détectées par le récepteur SA1.

1.2 Des capteurs variés pour simuler les mécanorécepteurs humains

Afin de simuler les mécanorécepteurs humains, les scientifiques ont développé de nombreux capteurs basés sur des principes physiques différents et mesurant des grandeurs différentes. La plupart des capteurs tactiles sont des capteurs statiques donnant l'image de la répartition des pressions à sa surface à une fréquence d'acquisition assez faible.

Du côté des capteurs dynamiques, le premier capteur tactile dynamique a été réalisé par Howe et Cutkosky (1989) en 1989. Ils utilisent un matériel piézoélectrique qui leur permet d'obtenir un capteur relativement performant. Ce capteur a une fréquence d'acquisition de 1000hz. Dans un second article en 93, Howe et Cutkosky (1993) propose une étude expliquant la méthode de test du capteur en fréquence.

Suite à cette première étude, de nombreux capteurs statiques, dynamiques, combinant les deux, ont été créés. Néanmoins, Siciliano et Khatib (2008) affirment qu'actuellement aucun capteur tactile n'est équivalent aux mécanorécepteurs humains. Dans un article plus récent, Dahiya *et al.* (2010) présente l'ensemble des technologies utilisées pour réaliser des capteurs tactiles. Voici un bref résumé distinguant le type de capteur (S : statique, D : dynamique) pouvant être fabriqué avec chaque technologie :

Les capteurs piézo-résistifs (S) : Ces capteurs font varier la valeur d'une résistance en fonction du point d'application de la force et de l'amplitude de cette force. Le phénomène de piézorésistance, consistant à faire varier une résistance en fonction de la pression appliquée sur une surface, est réalisé avec des MEMS (Microelectromechanical systems), des microsystèmes électromécaniques. Ils sont souvent utilisés pour leur coût faible, leur bonne précision et leur faible bruit. Leur inconvénient majeur est leur importante consommation de courant. Par exemple, Wisitsoraat *et al.* (2006) propose un capteur piézoélectrique à base de MEMS permettant de mesurer des efforts très faibles ($< 300\mu$). Afin de réduire les coûts de fabrication, un substitut à l'utilisation du silicium est proposé.

Les capteurs à effet tunnel (S) : Cette technologie datant du début des années 2000 utilise des matériaux composites à tunnels quantiques (QTC : Quantum tunnelling composite). Ces

matériaux ont la propriété de pouvoir passer d'isolant parfait à des métaux conducteurs en fonction de la pression qui est exercée à leur surface. Ces capteurs, développés très récemment, bien que prometteurs, sont encore assez complexes à intégrer à un robot. Bien que des premiers capteurs utilisant cette technologie aient été créés (Stiehl et Breaeal (2006)), aucun test poussé ou application n'ont été réalisés avec eux. Par contre, Lantada *et al.* (2010) propose récemment une caractérisation plus précise pour des capteurs futurs.

Les capteurs capacitifs (S et D) : Ces capteurs mesurent la capacité C selon l'équation 1.1 :

$$C = \epsilon_0 \epsilon \frac{A}{d} \quad (1.1)$$

Avec ϵ la perméabilité du diélectrique situé entre les deux armatures du capteur, ϵ_0 la perméabilité du vide, A la surface d'une armature et, d la distance entre les deux armatures. En sélectionnant avec précaution le diélectrique, la distance entre les deux armatures dépend de la force appliquée sur le capteur. Cela signifie que la capacité varie en fonction de cette force. Notre capteur fonctionne sur ce principe, nous détaillerons donc ce procédé dans la partie suivante. Lee *et al.* (2006) propose un capteur capacitif de 16x16 taxels. Un taxel, en analogie avec les pixels des photos, représente la force sur une petite partie du capteur. Ce capteur est flexible et peut s'interconnecter à d'autres capteurs similaires afin de former un capteur plus grand. Des applications pour des peaux tactiles sont envisagées. Les capteurs capacitifs sont aussi utilisés dans les écrans tactiles.

Les capteurs optiques (S) : Ces capteurs utilisent la variation de l'intensité lumineuse pour mesurer la pression appliquée sur le capteur. Ohmura *et al.* (2006) propose un capteur optique à base de LED permettant de réaliser des peaux flexibles. Ce capteur a aussi l'avantage de ne pas utiliser de fibre optique ce qui permet de ne pas avoir d'atténuation du signal.

Les capteurs ultrasoniques (S et D) : Plusieurs chercheurs ont utilisé des microphones à ultrasons pour calculer la pression appliquée sur un capteur. Ils permettent de mesurer le bruit à la surface du capteur pendant un frottement. Omata *et al.* (2004) propose un capteur ultrasonic

dédié au biomédical. C'est un capteur dynamique permettant d'atteindre une fréquence de 400Hz.

Les capteurs piézoélectriques (D) : Les matériaux piézoélectriques génèrent une différence de tension variant en fonction de la pression appliquée. Ces capteurs sont particulièrement sensibles aux hautes fréquences (100-500hz) et sont donc de bons capteurs de faibles interactions (frottement avec une texture, objet glissant des doigts...). Néanmoins, ils restent trop sensibles aux variations de température. Dargahi (2000) propose un capteur de ce type. Ils utilisent un système assez poussé de triangulation mais ont peu poussé les tests du capteur.

Les capteurs magnétiques (S) : Le principe de ces capteurs est de mesurer une variation de flux magnétique. Ces capteurs ont beaucoup d'avantages : haute sensibilité, fréquence d'échantillonnage élevée, hystérésis négligeable... Néanmoins ils ne fonctionnent que dans un environnement ne contenant aucun champ magnétique. Takenawa (2009) propose un capteur magnétique permettant à la fois d'estimer les forces en trois dimensions et en même temps à détecter les frottements avec une fréquence d'acquisition de 10kHz.

Ce bref état de l'art des capteurs permettra par la suite de mieux comprendre les articles qui sont cités mais aussi de comprendre le fonctionnement du capteur développé au laboratoire Coro. Ce dernier est le sujet de la prochaine sous-section.

1.3 Un capteur multi-utilisation et ultra sensible

Le capteur utilisé est développé au laboratoire CoRo de l'École de Technologie Supérieure (ÉTS) à Montréal. Il est commercialisé par la société Kinova.




Figure 1.2 Photo du capteur

Ce capteur (voir figure 1.2) est un capteur capacitif donnant deux types d'informations :

Des informations statiques : Le capteur retourne des valeurs permettant de reconstruire l'image de la pression appliquée sur le capteur. La limite de ces mesures est la fréquence d'acquisition qui atteint environ 20hz.

Des informations dynamiques : Le capteur retourne aussi une valeur liée à la variation de pression appliquée sur le capteur. Cette méthode utilise un circuit complètement indépendant de celui utilisé pour la partie statique. La fréquence d'acquisition de ces informations est limité uniquement par le port d'acquisition (dans notre cas : 1000 hz). Cela permet de mieux sentir les vibrations donnant de l'information sur les glissements et les textures.

Dans cette partie, nous allons présenter pour chacune des mesures, son principe physique, une caractérisation et nous concluerons avec ses forces et ses faiblesses.

1.3.1 Information statique : une vision 3D des forces

Notre capteur comporte 12 taxels. Un taxel est nommé ainsi par analogie au pixel. Il donne la force appliquée sur une petite surface du capteur. L'ensemble des taxels permet de connaître la répartition de la pression sur l'ensemble du capteur et de construire une “image de la pression” pouvant ressembler à la figure 1.3. La numérotation des axes horizontaux représente le nombre de taxels. L'axe vertical, numéroté en comptes, représente le nombre de comptes du système d'évaluation de la capacité.




Figure 1.3 Exemple de données statiques

Dans cette partie, la première section présente le principe physique utilisé pour mesurer la force de chaque taxel. Ensuite, une caractérisation réelle de ce capteur est proposée avec plusieurs expériences. Cela permet de conclure avec un bilan des forces et faiblesses des taxels statiques.

1.3.1.1 Principe : Estimer la capacité pour retrouver les forces

Comme présenté dans Axaykumar et Vincent (2013), le principe des capteurs capacitifs consiste à mesurer la capacité qui dépend directement de la distance entre les deux armatures du condensateur selon l'équation 1.2 :

$$C = \epsilon_0 \epsilon \frac{A}{d(f)} \quad (1.2)$$

Avec ϵ la perméabilité du diélectrique situé entre les deux armatures du capteur, ϵ_0 la perméabilité du vide, A la surface d'une armature, d la distance entre les deux armatures et f la force appliquée sur le capteur.

Comme la compression du matériau se trouvant entre les armatures est connue et que sa perméabilité est constante quand il est soumis à la compression, on peut noter que la capacité dépend directement de la force appliquée sur le capteur.

Pour notre capteur, le matériau utilisé entre les armatures comporte deux innovations permettant d'obtenir une meilleure précision :

Une microstructure en double cône : Afin d'accroître la précision dans les petites forces, la forme réalisée pour le diélectrique ressemble à la figure 1.4




Figure 1.4 Photo de la forme de la mousse utilisée entre les deux armatures du condensateur
Tirée de Axaykumar et Vincent (2013)

En appuyant sur la mousse, les petits cônes s'écrasent en premier créant un fort écart de distance entre les deux armatures pour un faible écart de force. Ensuite, les grands cônes se compriment à leur tour. Mais cela nécessite plus d'effort que lors de la première étape. Ce système de doubles cônes permet d'être précis pour mesurer des petits efforts mais en même temps garder une large plage de forces mesurables. Nous quantifierons cette gamme de forces dans la partie suivante.

Une mousse en silicone avec des nanoparticules : Lors de la compression des pics, la densité de silicone par rapport à l'air augmente. En ajoutant des nanoparticules à forte valeur diélectrique, c'est la constante diélectrique du matériau qui augmente de manière significative durant l'application d'une force sur le capteur. Cela permet d'augmenter l'accroissement de la capacité et donc la précision. L'équation de la capacité devient 1.3 :

$$C = \epsilon(f)\epsilon_0 \frac{A}{d(f)} \quad (1.3)$$

Avec ϵ la perméabilité du diélectrique situé entre les deux armatures du capteur, ϵ_0 la perméabilité du vide, A la surface d'une armature, f la force appliquée sur le capteur et $d()$ une fonction connue donnant la distance entre les deux armatures en fonction de la force appliquée sur le capteur.

Nous allons étudier les résultats de ces différentes innovations dans la partie suivante.

1.3.1.2 Caractérisation : Etude de l'exactitude des informations mesurées

Cette caractérisation est partagée en deux parties : dans un premier temps, le mode image tactile visant à obtenir une image des efforts appliqués sur le capteur est étudié. Il cherche à déterminer le nombre de comptes (représentant la mesure de capacité) en fonction de la force appliquée. Dans un second temps, le mode hyper sensibilité est présenté : en travaillant uniquement avec les deux taxels centraux, il permet de mesurer des efforts très faibles.

a. Mode image tactile

Dans ce mode, nous pouvons estimer la force appliquée sur chaque taxel. Le capteur mesure un nombre de comptes qui est proportionnelle à la valeur de la capacité. Comme nous avons pu voir dans la formule 1.3, la capacité n'est par contre pas proportionnelle à la force appliquée. Nous avons donc, dans un premier temps, estimé la courbe de la force en fonction du nombre de comptes. Pour cela, le banc de la figure 1.5 est utilisé. Il est composé d'une jauge de force Mark-10 (modèle : M4-10) fixé à un banc de la même marque. Cette jauge permet de mesurer

des forces de 0.5N à 50N avec une précision de 0.2% de la valeur mesurée. Pour mesurer le déplacement vertical du banc (en mm), nous utilisons un indicateur de position Mitutoyo (modèle : ID S112T) permettant d'estimer des déplacements entre 0 et 12mm avec une erreur de $1\mu\text{m}$.



Figure 1.5 Banc de mesure utilisé pour les expériences de caractérisation du capteur

Afin d'étudier le capteur, quatre courbes ont été réalisées : la première en appuyant uniquement sur un seul taxel, la seconde en appuyant sur tous les taxels, et les deux autres en appuyant sur la moitié droite et la moitié gauche des taxels (6 taxels à chaque fois). La figure 1.6 illustre les zones d'appui (la partie 3 illustre à la fois chacune des deux moitiés).

En faisant varier la force appliquée de 0.01N/taxel à 10N/taxel, nous obtenons la courbe 1.7.

La figure 1.7 montre que la fonction entre la force appliquée et le nombre de comptes de chaque taxel est légèrement différente suivant le nombre de taxels pris en compte. Le procédé




Figure 1.6 Zones de pression testées pour caractériser la fonction statique du capteur




Figure 1.7 Caractérisation de la fonction statique du capteur : Estimation de la force en fonction du nombre de comptes

de fabrication engendre une erreur relativement importante (elle sera quantifiée par la suite) entre chaque taxel. Les différences entre les courbes sont aussi dues au bruit interne du capteur, à son hystérésis et à des effets de bord. Nous reviendrons sur ces effets dans la partie suivante. L'incertitude créée par ces différents facteurs est estimée dans la figure 1.8. L'erreur relative

au nombre de comptes est calculé par la différence entre la courbe moyenne de la force en fonction du nombre de capteur et la valeur quand on appuie sur un taxel unique. L'erreur sur la force ajoute l'imprécision de mesure entre la valeur obtenue par le capteur et la force affichée sur le banc de test.




Figure 1.8 Estimation de l'incertitude sur la mesure statique du capteur

D'après la courbe de l'incertitude de mesure, nous pouvons voir que l'erreur est importante dans les petites mesures. Ceci est dû au bruit interne du capteur qui est important face à la valeur mesurée. Dans les forces élevées, c'est l'hystérésis du capteur qui fausse la mesure car la force de réaction de la mousse entre les deux armatures varie dans le temps. Dans la bande passante variant entre 0.4N/taxel et 7N/taxel, l'erreur reste par contre de l'ordre de 5%.

Globalement, pour connaître la force à partir du nombre de comptes, il faudrait connaître la caractéristique de chaque taxel. Sur une main équipée de 7 capteurs, cela représente 84 taxels. L'option souvent prise sera de faire différentes mesures de caractéristiques puis d'utiliser une moyenne pour estimer la force. La courbe d'incertitude de la force (mesure + calcul) estime l'erreur total d'un tel procédé. Nous pouvons voir que globalement, cela ajoute 5 %.

b. Mode hyper-sensibilité

Le mode hyper-sensibilité utilise uniquement les deux taxels centraux. En utilisant ces deux taxels, qui sont souvent les plus utilisés, on évite de prendre en compte tous les taxels, ce qui aurait tendance à faire diminuer la moyenne et réduire la précision. De plus, grâce à leur localisation, ils sont légèrement plus sensibles que les autres. En utilisant un moyennage et un filtre passe-bas sur les 20 dernières valeurs, le capteur est capable, avec un peu de délai due au moyennage, d'être beaucoup plus sensible. Il est capable de détecter une force d'environ 10^{-3}N et de mesurer une force d'environ 10^{-2}N . Si on ajoute un autre moyennage d'environ 1s, le capteur détecte des forces d'un ordre de grandeur de 10^{-4}N et mesure des forces d'environ 10^{-3}N . Ces expériences ont été réalisées en utilisant des petits objets de masses connues.

La figure 1.9 montre la visualisation du mode hyper sensibilité. On arrive à mesurer entre 0 et 300 comptes, ce qui représente des forces inférieures à 10^{-2}N .




Figure 1.9 Visualisation du mode hyper-sensibilité

1.3.1.3 Conclusion : Forces et faiblesses

En conclusion, le capteur statique a de nombreux avantages : il dispose d'une importante gamme de mesure pouvant varier de 10^{-4}N à 10N par taxel. La fréquence d'acquisition de 20hz permet un suivi relativement correct en temps réel. Malgré que cette fréquence soit plus faible dans des forces faibles, le dynamique permet de contrebalancer cet inconvénient. De plus, le

capteur utilise des matériaux simples et des procédés de fabrication courants lui permettant d'avoir un prix très compétitif.

Malgré cela, il comporte trois sources de bruit réduisant les performances :

Le bruit interne : Il représente environ 40 comptes (les comptes peuvent monter jusqu'à 10000) soit de 1% à 30% de la valeur mesurée. Il est généralement constant dans la plage de variation du capteur.

L'hystérésis : En raison de son comportement viscoélastique, lorsque le diélectrique se trouvant entre les deux armatures se déforme, un temps d'adaptation lui est nécessaire. Lors de la compression du capteur, cela engendre une détente de la mousse et une légère réduction de la force qu'elle oppose. A l'inverse, au relâchement, le capteur a un délai avant de redescendre à 0. Comme présenté dans Schneider *et al.* (2008), le modèle mécanique du silicone peut être comparé avec le modèle de Burger. Ce modèle inclut un amortisseur pouvant ralentir considérablement la dynamique du matériau. La microstructure du capteur permet de minimiser cet effet.

En effet, les figures 1.10 et 1.11 appuient cela avec deux cas concrets : dans le graphique 1.10, on passe d'un coup de 0 à 35 ou 50N. On s'aperçoit d'une perte de force d'environ 10% à chaque fois. Dans la figure 1.11, on relâche le capteur suite à différents appuis (plus ou moins longs et plus ou moins forts). Il faut plusieurs minutes pour redescendre à 0 mais la valeur au relâchement représente moins de 1% de la force initiale. On s'aperçoit aussi que la durée de la pression a un impact sur l'erreur au relâchement.

Les effets de bord : L'appui sur un taxel a une influence sur les taxels autour de lui en créant une ondulation. Il est assez compliqué d'évaluer l'importance de ces effets. Néanmoins ils ont une influence dans les variations des courbes entre la force appliquée et le nombre de comptes. La figure 1.12 illustre cet effet. On peut voir des creux négatifs autour du pic de force. Cela correspondrait à une force négative (impossible !). Il s'agit en réalité d'une déformation du silicone se trouvant entre les plaques du condensateur.




Figure 1.10 Second exemple de l'influence de l'hystérésis




Figure 1.11 Premier exemple de l'influence de l'hystérésis

En conclusion, le capteur statique permet de précisément connaître la répartition des forces appliquées sur le doigt. Cette information donne un portrait fidèle seulement pour les stimuli à bas contenu fréquentiel. Pour des stimuli à haute fréquence, il sera nécessaire d'utiliser la fonction dynamique que nous allons présenter dans la partie suivante.




Figure 1.12 Illustration des effets de bord

1.3.2 Information dynamique : Mieux connaître les interactions à haute fréquence

Le capteur dynamique permet d'obtenir très rapidement une information sur l'interaction immédiate du capteur avec son environnement. Ce n'est pas la force appliquée sur le capteur qui est mesurée mais la dérivée de cette force. Néanmoins, il reste possible en connaissant la force à un moment précis d'intégrer le signal pour retrouver la force. Le grand avantage des informations dynamiques est leur fréquence d'échantillonnage d'environ 1000hz et une sensibilité élevée permettant d'acquérir les vibrations de faible amplitude.

Dans cette partie, nous allons présenter le principe permettant de mesurer ces stimuli, quelques informations sur les performances mesurées du capteur et nous concluerons avec les avantages et inconvénients de ce signal.

1.3.2.1 Principe : Estimer les écarts de capacité pour trouver les variations des forces

Le principe du dynamique est inspiré d'un bruit interne des condensateurs : les vibrations extérieures ont tendance à déplacer les composantes internes des condensateurs. Cela engendre une légère variation de la capacité du condensateur qui parasite parfois le circuit. Une analogie entre ce bruit et le signal de notre capteur peut être réalisée : en effet, notre capteur mesure la

force en fonction d'une variation de capacité. Nelson et Davidson (2002) présente cet effet et l'observe grâce à différents circuits.

Il présente le circuit de la figure 1.13 servant à amplifier les variations d'une capacité et donc dans son cas, amplifier le bruit. Ce montage est appelé *amplificateur de charge*. Nous l'utilisons pour passer d'une variation de capacité à une variation de tension.




Figure 1.13 Montage amplificateur de charge
Tirée de Nelson et Davidson (2002)

Ce montage permet d'amplifier les variations de la capacité selon l'équation 1.4.

$$V_{out} = R_f \Delta C E \quad (1.4)$$

Dans cette équation, V_{out} représente la tension en sortie du montage, E la tension entre les bornes du condensateur, R_f la résistance de résistance du montage et ΔC les variations de la capacité.

Il faut noter que E est très faible car il s'agit aussi de la tension entre les deux bornes de l'amplificateur opérationnel qui est approximée à 0 dans l'AOP parfait. Pour compenser cela, nous avons mis la résistance la plus élevée possible, c'est à dire $1\text{M}\Omega$. Si on augmente plus cette résistance, elle entrera en conflit avec la résistance interne des entrées de l'AOP, approximée à l'infini, mais qui en réalité sont de l'ordre de grandeur de $10\text{M}\Omega$. Comme le signal reste assez faible, nous devons ajouter ensuite un amplificateur de tension. Le signal est ensuite acquis à 1000hz (limite possible avec le matériel utilisé). Un filtre passe-bas à 2000hz est inclus afin d'enlever les fréquences supérieures qui pourrait parasiter le signal. Le montage global est illustré sur la figure 1.14.




Figure 1.14 Montage global du circuit dynamique du capteur

Au final, nous obtenons une variation de tension directement liée aux variations de l'effort appliqué sur le capteur. Grâce à la fréquence d'acquisition élevée, nous pouvons détecter les vibrations comme nous allons le voir dans la partie suivante.

1.3.2.2 Caractérisation : Etude de l'exactitude des informations mesurées

Caractériser le signal dynamique est assez complexe. Pour cela, nous avons utilisé un transducteur vibrotactile commercialisé par TactileLabs sous le nom de Haptuator (site web : <http://www.tactilelabs.com/products/haptics/haptuator/>). Contrairement aux transducteurs communément utilisés, c'est-à-dire des moteurs à masse excentrique où l'amplitude de la vibration est couplée à la fréquence, l'Haptuator permet de contrôler la fréquence et l'amplitude grâce à un

aimant stimulé magnétiquement comme le présentent Yao et Hayward (2010). Il permet donc de créer des vibration de 50hz à 500hz. La figure 1.15 est une photo de ce dispositif.




Figure 1.15 Photo de l'haptuator

En le posant sur le capteur, celui-ci obtient le type de signal de la figure 1.16. Sa transformée de Fourier, également montrée sur la figure 1.16, est particulièrement intéressante à voir. On peut voir la réaction du capteur pour deux fréquences (réglées sur un générateur basse fréquence). La fréquence est fidèlement redonnée par le capteur. Il y a peu de bruit et d'harmoniques.

Suite à divers tests, on s'aperçoit que la sensibilité du capteur est supérieure à celle de l'être humain en fréquence et en intensité. En fréquence, comme Vallbo et Johansson (1984) l'indiquent, l'humain est limité à détecter des pics de fréquence entre 200 et 300hz alors que le capteur détecte des signaux jusqu'à 500hz. En intensité, nous avons réalisé une petite expérience : en réglant l'Haptuator de manière à ce que l'être humain ne ressente pas la vibration, le capteur arrive encore aisément à l'identifier. La figure 1.17 montre le signal obtenu par le capteur avec une intensité non détectable par la main humaine.

Il est donc possible de détecter des signaux de 0 à 500hz même avec une intensité très faible. Néanmoins il reste complexe d'évaluer la réponse à chaque fréquence car l'intensité de l'Haptuator varie en fonction la fréquence.




Figure 1.16 Exemple de signal dynamique et sa transformée de Fourier

1.3.2.3 Conclusion : Forces et faiblesses

Le signal dynamique permet d'obtenir de l'information à une fréquence beaucoup plus élevée (1000Hz) et avec une sensibilité supérieure à celle de l'être humain. Son principal défaut, au-delà de la complexité à caractériser précisément sa réponse, est la récupération de ce signal dans un cadre multicapteurs. La limite à 1000Hz est donnée par le protocole de communication donc lorsque nous avons par exemple deux capteurs à scruter en simultanément, la fréquence d'acquisition pour chacun est réduite à 500Hz. Cela nécessite une évolution de la stratégie de communication dans une prochaine version du capteur.




Figure 1.17 Exemple de signal dynamique et sa transformée de Fourier

CHAPITRE 2

RECONNAISSANCE DE TEXTURES À L'AIDE D'ALGORITHMES D'APPRENTISSAGE

La reconnaissance de textures est utile dans des domaines divers et variés : imagerie médicale, télédétection, géologie, robotique... Connaître la texture d'une surface permet d'anticiper un certain nombre de propriétés de celle-ci.

Dans cette partie, nous nous intéressons à la discrimination de textures. Plusieurs études ont déjà été réalisées sur ce sujet. Dans notre cas, nous travaillons trois éléments : tout d'abord, nous approfondissons deux mouvements d'exploration différents : un mouvement court unidirectionnel qui permet d'estimer la texture durant la manipulation d'un objet et un mouvement circulaire qui permet d'explorer une surface plus précisément. Nous cherchons aussi à devenir indépendants de la vitesse et de la force appliquée durant l'acquisition. Ensuite, nous proposons l'utilisation d'algorithmes génétiques pour optimiser les nombreux paramètres dont dépendent l'algorithme d'apprentissage. Cela allonge considérablement les temps de simulation mais permet d'optimiser de manière intéressante les résultats. Enfin, nous testons notre algorithme sur des textures fines pour voir la sensibilité du capteur et la précision de notre algorithme.

Pour réaliser cela, nous réalisons trois expériences différentes. La première expérience consiste avec le mouvement d'exploration unidirectionnel à chercher comment être indépendant de la vitesse et la force appliquées par le capteur durant l'acquisition. La seconde expérience a pour objectif de permettre au mouvement d'exploration circulaire d'être indépendant de la position initiale de l'objet en rotation. Enfin, la dernière expérience a pour mission, avec le premier mouvement d'exploration, de différencier dix textures fines.

Pour présenter cette partie, nous commençons par introduire une revue de littérature des études réalisées dans ce domaine. Nous continuons par une présentation de l'algorithme utilisé puis nous présentons les expériences et leur résultat une par une. Nous terminons cette partie par une discussion autour des résultats obtenus et des perspectives futures.

2.1 Recherche documentaire

2.1.1 Qu'est ce qu'une texture ?

Dans différents domaines (métallurgie, médical...), la nature de la surface est importante. On parle souvent de la rugosité de la surface. Néanmoins, il est relativement complexe de quantifier ce qu'est une texture, spécialement par la sensation du toucher humain. Les scientifiques ont proposé différents indices pour caractériser des textures dépendamment des domaines d'étude. L'indice le plus utilisé est celui de l'équation 2.1. Il s'agit de R_q , la moyenne quadratique des déplacements verticaux sur les déplacements horizontaux :

$$R_q = \frac{1}{L} \sqrt{\int_{x=0}^{x=L} y^2 dx} \quad (2.1)$$

Avec L longueur du profil et y l'amplitude du profil.

Ce premier indice nous donne une idée de la quantité de distance verticale sur la distance horizontale sur un profil 2D de la texture.

Pour compléter cet indice, Myers (1962) propose trois autres indices complémentaires :

$$R_1 = \frac{1}{L} \sqrt{\int_{x=0}^{x=L} \left(\frac{dy}{dx} \right)^2 dx} \quad (2.2)$$

L'équation 2.2 représente la moyenne quadratique de la dérivée première de l'amplitude du profil. Cet indice nous donne de l'information sur la raideur des pentes du profil.

$$R_2 = \frac{1}{L} \sqrt{\int_{x=0}^{x=L} \left(\frac{d^2y}{dx^2} \right)^2 dx} \quad (2.3)$$

L'équation 2.3 représente la moyenne quadratique de la dérivée seconde de l'amplitude du profil. Cet indice nous donne de l'information sur les profils qui varient beaucoup ou se ressemblent.

$$R_3 = \frac{\sum(\Delta x_i)_p - \sum(\Delta x_i)_n}{L} \quad (2.4)$$

Avec p pente positive, n pente négative et x_i élément de L .

L'équation 2.4 permet de connaître l'orientation du profil. Au fil du temps, de nombreux autres indices ont été introduits afin de caractériser la rugosité de manière plus précise comme par exemple par les études de Thomas (1981) et Gadelmawla *et al.* (2002). Dans le cas de la reconnaissance tactile, les capteurs ne sont pas assez précis pour calculer ces indices, nous n'approfondirons donc pas la recherche.

2.1.2 Les différentes méthodes pour reconnaître une texture

a. Utilisation de la vision

Les capteurs tactiles performants sont assez récents. Les premières approches ont donc été réalisées à l'aide de caméra. Mais dans ce cas, "texture" a un sens plus large. C'est un ensemble de pixels non uniformes représentant la surface d'un objet. Par exemple, en considérant une photo d'une maison avec son jardin, l'herbe sera une texture, le mur de briques une deuxième et le toit de tuiles une troisième. Cela permet de différencier différentes formes sur l'image mais aussi d'essayer d'en tirer les propriétés de ces surfaces. Avant de traiter le signal, l'importance d'uniformiser au maximum l'image a été montrée. Un certain nombre de prétraitements permet de réduire l'impact d'effets extérieurs (luminosité, résolution de l'appareil...). Deux types d'approches ont principalement été utilisés : des approches statistiques ou en fonction de certains critères, on donne une probabilité à chaque texture d'être celle recherchée et une approche structurelle. Cette dernière cherche à retrouver des primitives et à retrouver des patterns caractéristiques de la texture. Cette approche fonctionne mal sur des textures non régulières ou aléatoires.

En 1987, Khotanzad et Kashyap (1987) partent de la logique selon laquelle la texture est propriété du voisinage pour proposer un algorithme SAR "simultaneous autoregressive". Ce type d'algorithme cherche à définir la valeur de chaque pixel en une combinaison de la valeur des pixels voisins multipliés par des coefficients et en ajoutant un peu de bruit. En choisissant ces coefficients, on détermine une image synthétisée. Suivant la ressemblance avec l'image d'origine, on peut déterminer des caractéristiques de la texture. Cette première étude permet une re-

connaissance à 97% sur 144 images de 64x64 pixels. Picard *et al.* (1993) remettent en question les études trop conditionnées à des images découpées sur peu de photos car elles ne permettent pas une bonne globalisation. Ils proposent donc une étude comparant deux algorithmes : un SAR et un algorithme de reconnaissance des composantes principales. Il est important de mentionner que ces algorithmes sont rendus peu sensibles à la rotation et aux variations d'échelles. Cette étude a été réalisée sur plus de 1 000 images venant de plus de 100 photos de la base d'image Brodatz, une des bases de photos de textures les plus utilisées. En conclusion l'algorithme SAR est beaucoup plus performant (91% contre 78%). De nombreuses études se sont aussi intéressées au filtre de Gabor. Ces filtres visent à être peu sensibles à l'orientation et l'échelle de l'image. Néanmoins leur théorie est peu expliquée et assez complexe. Les résultats sont par contre intéressants : Jain et Healey (1998) montrent l'intérêt d'utiliser une image multi-bandes. Il propose un algorithme utilisant différents descripteurs issu d'une image polychromatique filtrée avec un filtre de Gabor. En testant cet algorithme sur une base de plus de 2500 photos, il montre que cet algorithme a de meilleures performances que si on travaille uniquement avec une image en nuances de gris. Shi et Healey (2003) poursuivent ce travail en cherchant les descripteurs les plus efficaces. Il est intéressant de voir que ceux-ci ont beaucoup d'influence, les résultats varient de 35% à plus de 90% suivant le nombre de caractéristiques sélectionnées et du nombre de bandes spectrales. Néanmoins, ces méthodes utilisent des algorithmes lourds. Paschos (2000) propose une méthode beaucoup plus légère en utilisant les moments chromatiques. Cette approche consiste à calculer un indice pour chaque pixel dépendant des valeurs RGB de celui-ci. En faisant varier les moments, les résultats varient de 56 à 99% sur des sets de photos de marbres et granits.

b. Utilisation de capteurs tactiles

Mayol-Cuevas *et al.* (1998) ont réalisé une des premières expériences destinées à discriminer des textures. Le capteur utilisé est un microphone moulé dans un support ressemblant à un doigt (moulé à partir d'un vrai doigt). Ils récupèrent les informations à 44khz sur 2s. La classification sur 18 textures du quotidien est réalisée en découpant chaque acquisition en échantillons de 47ms. Ensuite, la transformée de Fourier est traitée (traitement non spécifié) et un classifica-

teur LVQ (learning vector quantization (réseau de neurones avec des règles particulières)) est appliqué. Ce traitement fonctionne à plus de 93%. Edwards *et al.* (2008) utilisent un système similaire avec une bande passante de 50hz-10khz. Quarante acquisitions d'une seconde ont été réalisées pour chacune des 22 textures simples. Le signal est converti en fréquence par une FFT et moyenné par une moyenne point par point. Une approche par analyse des composantes principales est proposée. La classification est faite par K nearest neighbors (KNN) et atteint 97%.

Plusieurs études ont aussi été réalisées avec un capteur à base d'un MEMS. Kim *et al.* (2005) présentent un capteur de force à base de MEMS dans un polymère et le teste sur des textures très simples à l'aide d'un réseau de neurones. Le taux de succès ne dépasse pas les 68%. De Boissieu *et al.* (2009) présentent un second capteur à base d'un MEMS piézoélectrique. Il s'agit d'un capteur de force en 3D. Leur expérience consiste à discriminer 10 types de papier en réalisant 50 acquisitions par texture dans une seule direction (4cm/acquisition à une vitesse de 3.8 mm/s et une fréquence d'acquisition de 1khz). 3 grandeurs d'entrée sont utilisées : un coefficient de friction (défini par la moyenne du signal), la variance du signal (représente la rugosité du matériau) et le coefficient d'aplatissement du signal. Deux algorithmes ont été utilisés pour caractériser différentes feuilles de papier : la distance minimale entre les moyennes de chaque texture et une approche par réseau de neurones MLP. Les meilleurs résultats atteignent environ 75% en entraînement et 60% en test.

Takamuku *et al.* (2007) utilisent un capteur haptique qui récupère les informations de manière dynamique à 1.6khz. Ses tests explorent uniquement deux manières de faire l'acquisition sans discrimination : presser l'objet et le taper.

Mazid et Ali (2008) utilisent un capteur opto-tactile. En fonction de comment une tige de métal se déplace sur la texture, la déviation d'une LED est modifiée. Cette variation permet de reconstruire un profil de la surface. Ils ont utilisé différents algorithmes d'apprentissage : des SVM, des Decision Tree (DT) et des Naive Bayes (NB). Les résultats atteignent environ 75%.

Sukhoy *et al.* (1989) utilisent un ongle artificiel connecté à un accéléromètre tactile. La fréquence d'acquisition est de 400hz. L'étude consiste en 10 acquisitions sur 20 surfaces. Chaque acquisition est composée de 5 mouvements (3 latéraux et 2 médians). L'étude utilise les SVM et atteint 80% de reconnaissance (peu d'informations sur le traitement).

Une des études les plus poussées est celle de Jamali et Sammut (2010) et Jamali et Sammut (2011) Ils utilisent un doigt qui contient plusieurs capteurs (statiques et dynamiques) placés aléatoirement. La fréquence d'acquisition est de 2.5khz. Le signal subit plusieurs prétraitements : les morceaux où la vitesse n'est pas constante sont coupés, la moyenne dynamique est mise à zéro et le signal est filtré à 500 hz (maximum détectable par la main humaine). Après avoir moyenné la transformée de Fourier, les données extraites sont les 3 premières composantes fréquentielles pour chaque capteur dynamique et la moyenne de l'effort statique appliqué. 50 acquisitions pour chacune des 8 textures et à 3 vitesses différentes (41mm/s, 51mm/s et 62mm/s) sont réalisées avec 1 translation dans deux sens différents. Les résultats sont donnés en fonction du nombre de composantes de Fourier utilisées et suivant la réalisation d'un vote majoritaire sur 3 acquisitions. Les résultats dépassent globalement les 90% et de grandes discussions sont ouvertes pour améliorer l'expérience.

Fishel et Loeb (2012) utilisent les inférences bayésiennes, une méthode statistique permettant d'avoir peu de données d'apprentissage. Néanmoins, pour confirmer une texture, 5 mouvements sont nécessaires. Ils utilisent le capteur BioTac contenant des capteurs statiques et dynamiques (à 2200hz). Les données extraites sont le courant du moteur, la puissance moyenne dynamique et la fréquence centrale. Les résultats dépassent 95% de reconnaissance sur 117 textures.

Chathuranga *et al.* (2013) utilisent des accéléromètres en MEMS (acquisition à 1,2khz) et des capteurs de force. Une expérience de discrimination est réalisée sur 7 textures avec 100 échantillons par texture. Les coefficients de Fourier inférieurs à 300hz sont utilisés en entrée d'un réseau de neurones pour une discrimination de 65%.

Xiaojing *et al.* (2012) proposent un nouveau modèle pour trouver des coefficients de friction : le modèle LuGre. Il permet d'approximer 8 coefficients de friction durant un frottement entre deux surfaces. Il est combiné avec une méthode de Newton-Raphson. Ces coefficients sont utilisés en entrée d'un algorithme probabiliste de type naïves bayésiennes. Les acquisitions mesurent les forces à une fréquence de 100hz sur 9 textures différentes. Les acquisitions sont faites à accélération constante et la force appliquée est constante aussi. La discrimination fonctionne à plus de 90%. Drimus *et al.* (2012) proposent un nouveau capteur à base de matériaux piézoélectriques et d'électrodes tactiles. L'expérience réalisée s'intéresse à la texture d'objets (des fruits principalement). Un mouvement de palpation est réalisé par le robot. Le capteur acquiert une image (8x8 taxels) toutes les 10ms (100hz). Les vecteurs d'entrées sont : la moyenne d'une image, l'écart-type d'une image. L'algorithme de classification utilisé est un KNN voisin. Les résultats sont autour de 90% de reconnaissance.

En conclusion, la notion de rugosité des textures est assez compliquée à définir. De nombreux coefficients ont été développés pour cela, néanmoins il faut choisir les plus appropriés en fonction de la nature des informations recherchées et du moyen de mesure. Le corps humain reconnaît les textures en combinant les informations de différents mécanorécepteurs lui donnant des informations sur la définition géométrique de la texture et des vibrations. Le cerveau compare ces informations à d'autres pour évaluer la rugosité du matériau. De nombreuses approches ont été proposées pour choisir les données à extraire qui pourront discriminer les textures : pics de fréquence, fréquence moyenne, indice de rugosité, image de taxels... Enfin la plupart des études utilise des algorithmes probabilistes ou des réseaux de neurones permettant un apprentissage adapté. Les premiers permettent moins d'apprentissage mais nécessitent plus d'informations. La plupart des études sont réalisées sur une surface plane et dans une seule direction. Elles nécessitent souvent des acquisitions assez longues, parfois plusieurs gestes, et un cadre de travail spécifique pour donner de bonnes performances. Notre objectif sera en partie de chercher à trouver des mouvements simples mais permettant un travail dans un maximum de conditions afin de rendre ce type d'algorithme utilisable par des robots au quotidien.

2.2 Approche

Notre étude se positionne légèrement différemment par rapport aux précédentes : nous proposons des acquisitions faciles à réaliser qui pourraient être utilisées par un robot durant une manipulation. Pour cela, nous avons retenu deux mouvements exploratoires : un “mouvement de courts glissements linéaires” dans une seule direction visant à pouvoir être réalisé en appliquant n’importe quelle force et n’importe quelle vitesse. Ce mouvement pourrait ressembler à un mouvement du pouce glissant sur un objet tenu dans la main. Le second mouvement est un “mouvement d’exploration circulaire” visant à identifier une surface plane. Il s’agit d’un cercle à vitesse constante et force constante. Ce mouvement ressemble au mouvement qu’un être humain pourrait faire avec l’index et le majeur sur une surface pour étudier sa rugosité. La figure 2.1 illustre ces deux mouvements.




Figure 2.1 Illustration des deux mouvements exploratoires utilisés

En lisant les articles d’autres études, nous avons pu constater le nombre important de paramètres dont dépendent les performances d’une détection de texture. La plupart des auteurs ont déterminé ces paramètres de manière expérimentale. Nous allons essayer de les optimiser par algorithmie génétique. Cela allonge de manière considérable les simulations mais permet

d’avoir de meilleurs résultats. Néanmoins, après l’apprentissage, il est envisageable d’utiliser les algorithmes d’intelligence artificielle pour détecter les texture en temps réel.

2.3 Principe de l’algorithme

Comme nous avons pu le voir précédemment, nos expérimentations sont réalisées à partir de deux types de mouvements exploratoires : des “mouvements de courts glissements linéaires” qui sont dans une seule direction mais ont comme défi de pouvoir gérer différentes vitesses et forces appliquées et des “mouvements d’exploration circulaires” qui ont une vitesse moyenne et une force appliquée constantes mais qui doivent gérer une acquisition en deux dimensions. Malgré quelques différences, la philosophie de l’algorithme reste la même et nous allons donc le présenter une seule fois en spécifiant les différences entre les deux algorithmes. L’algorithme fonctionne en quatre étapes que nous allons détailler : l’acquisition, les pré-traitements, la sélection des discriminants et l’apprentissage. Dans une cinquième partie, nous présenterons l’optimisation par algorithme génétique.

2.3.1 Acquisition

L’acquisition est très importante dans la réalisation de l’algorithme de détection de texture car elle va souvent déterminer les limites de l’algorithme et ses applications : peut-il fonctionner à toute vitesse ou force statique appliquée ? Est-il insensible aux rotations ? Est-ce qu’il fonctionne sur des textures souples ou non homogènes ?

Plusieurs études se sont interrogées sur quels mouvements exploratoires utiliser pour une bonne détection de textures. Plusieurs ont choisi des mouvements linéaires en deux dimensions comme Jamali et Sammut (2011) et Chathuranga *et al.* (2013). Takamuku *et al.* (2007) propose un mouvement différent en tapant l’objet. Enfin, une étude approfondie des mouvements de reconnaissance de textures de l’humain a été réalisée par Fishel et Loeb (2012). Ceux-ci ont sélectionné trois mouvements (non décrits dans l’étude) pour leur étude permettant de discriminer les textures avec moins de données d’apprentissage et un taux de réussite très élevé.

Pour réaliser notre expérience, nous utilisons le banc d'essai de la figure 2.2. Les textures sont frottées manuellement sur le capteur selon le mouvement exploratoire de l'expérience. Afin de contrôler la vitesse, nous utilisons un métronome permettant à l'opérateur de contrôler la vitesse moyenne des acquisitions. Le dynamomètre électronique permet de contrôler la force appliquée moyenne.



Figure 2.2 Banc d'acquisition des textures

Nous réalisons entre 200 et 500 acquisitions par texture suivant les expériences (avec une seconde de pause entre chaque acquisition). Les textures sont acquises à la suite sur le même enregistrement et sont enregistrées dans un fichier .csv. Un algorithme les extrait dans matlab.

2.3.2 Pré-traitements

Inspiré de l'article de Jamali Jamali et Sammut (2011), deux pré-traitements sont appliqués avant d'extraire les discriminants. Premièrement, nous rendons la moyenne du signal nulle afin de ne pas avoir de composante fréquentielle nulle sur la transformée de Fourier. Ensuite, nous calculons la FFT (Fast Fourier Transform) qui permettra d'extraire des discriminants. La FFT est calculée dans Matlab en post-traitement en utilisant la fonction *fft*. Le signal d'entrée a une durée variant entre 450ms et 600ms. La transformée de Fourier est calculée sur 1024 valeurs réparties équitablement entre 0hz et 500hz.

2.3.3 Sélection des discriminants

La plupart des études utilisant des capteurs capacitifs ou à base de microphones s'est inspirée du traitement du son et a utilisé les composantes principales de la transformée de Fourier en utilisant des algorithmes de détection de maximums. Plusieurs études ont aussi pris en compte la force et la vitesse appliquées par le robot comme une donnée d'entrée. Dans notre cas, nous allons étudier l'impact de plusieurs discriminants en laissant le choix à l'algorithme génétique de les utiliser ou non et de faire varier leurs paramètres. Nous allons prendre le temps dans cette partie de présenter chacun des discriminants et leurs caractéristiques :

les composantes principales de la transformée de Fourier : à partir de la transformée de Fourier d'une acquisition, ces composantes montrent les fréquences prédominantes dans le matériau. Ces fréquences ont un lien direct avec les propriétés de surface du matériau (lignes, quadrillage...) et gardent une certaine corrélation avec la vitesse de l'acquisition. Notre algorithme détecte les maximums de la transformée de Fourier. Une marge de tolérance impose un écart minimal entre les maximums. Le nombre de maximums détectés est choisi par l'utilisateur (ou l'algorithme génétique) et le code utilise la fréquence et l'amplitude de ces pics comme discriminants de l'algorithme d'apprentissage.

La vitesse moyenne de l'acquisition : intégrer une estimation de la vitesse moyenne de l'acquisition dans l'algorithme d'apprentissage permet de mieux anticiper les variations des pics de fréquence de la transformée de Fourier.

La force moyenne de l'acquisition : de la même manière, la force appliquée sur le capteur influence l'amplitude des différents pics de la transformée de Fourier.

L'intégrale de la valeur absolue du signal i : elle est calculée par la formule 2.5.

$$i = \int_0^T |s(t)|^2 dt \quad (2.5)$$

avec T la durée du signal et $s(t)$ les valeurs du signal. Cette valeur permet de mieux connaître le signal et peut être mise en adéquation avec la force moyenne. Elle devrait permettre de différencier deux signaux ayant des variations d'intensité et peu de variations fréquentielles.

la longueur du signal l : elle est calculée par l'équation 2.6.

$$l = \sum_{k=1}^T \sqrt{(t_{k+1} - t_k)^2 + (s_{k+1} - s_k)^2} \quad (2.6)$$

Ce dernier indice donne aussi de l'information à la fois sur l'amplitude du signal et sa fréquence.

2.3.4 Apprentissage

Les discriminants sont ensuite envoyés dans un algorithme d'apprentissage. Nous avons sélectionné uniquement deux types d'algorithmes d'apprentissage parmi les plus populaires : les Réseaux de Neurones Artificiels (RNA) et les Machines à Vecteurs de Support (SVM). Pour les RNA, nous utilisons un perceptron multicouche semblable au modèle proposé sur la figure 2.3. Le nombre d'entrées et le nombre de neurones sur la couche cachée dépendent de l'algorithme génétique. La fonction de transfert des neurones de la couche cachée est une fonction sigmoïde et celle du neurone de sortie est une fonction linéaire. A sa suite, une fonction arrondi permet d'obtenir une sortie booléenne. Les SVM permettent un apprentissage plus rapide et souvent aussi performants mais ont tendance à faire du surapprentissage. Dans les deux algorithmes la sortie est un booléen indiquant si l'échantillon d'entrée provient plus d'une texture a ou b. Pour différencier plus de deux textures, nous utilisons donc un ensemble de RNA (ou SVM) repré-

sentant chacun la différenciation entre deux textures. La texture de sortie d'un tel ensemble de RNA (ou SVM) est celle qui a été détectée par le plus grand nombre de RNA (ou SVM). Si le résultat est une égalité entre deux textures, la sortie est considérée comme non classée.




Figure 2.3 Modèle du réseau de neurones utilisé

Pour chaque combinaison de 2 textures, nous créons un réseau de neurones ou SVM pour les différencier. Cela implique de créer un nombre important de réseaux de neurones (2 parmi n , avec n le nombre de textures). Par exemple, pour différencier 4 textures, il faut 6 RNA ou SVM et pour en différencier 10, il faut 45 RNA ou SVM. Le fait d'utiliser un RNA ou SVM pour comparer les textures deux à deux permet de mieux comprendre les difficultés à différencier deux textures et d'adapter l'algorithme d'apprentissage en fonction des textures (avec l'algo-

gorithme génétique). Néanmoins, cela peut être très contraignant si on veut l'implémenter sur un trop grand nombre de textures.

Ensuite, nous avons deux manières de réaliser l'apprentissage : la première solution consiste à prendre l'intégralité de l'acquisition pour extraire les discriminants et être soumis à l'algorithme d'apprentissage. La seconde solution est un vote majoritaire : cela consiste à diviser cette acquisition en 5 échantillons et à extraire les discriminants et réaliser l'apprentissage de manière indépendante pour chaque échantillon. Pour déterminer la texture, un vote est fait en fonction des 5 réponses. Ce type d'algorithme permet d'améliorer les performances de l'algorithme et a souvent été utilisé comme par exemple par Jamali et Sammut (2011) et Fishel et Loeb (2012). Mais dans notre cas, le fait d'avoir des échantillons plus courts pourrait avoir un impact négatif important.

2.3.5 Optimisation par algorithme génétique

De nombreuses variables de l'algorithme sont à optimiser pour avoir un résultat optimal (configuration des RNA/SVM, nombre de composantes principales de la FFT, choix des discriminants...). Pour cela, nous allons utiliser un algorithme génétique (AG) standard avec 20 individus et 30 générations.

Pour chaque individu, l'algorithme sépare la base de données en deux parties égales : une partie d'apprentissage, une partie de test (permettant de limiter le surapprentissage). L'algorithme réalise 20 apprentissages différents qui sont testés ensuite avec la banque de données de test. La fonction de fitness retourne la moyenne de la somme des résultats d'apprentissage et de test.

L'AG permet de déterminer un ensemble de variables pour chacun des algorithmes liés aux mouvements exploratoires "mouvements de courts glissements linéaires" (MCGL) et "mouvements d'exploration circulaire"(MEC). Voici une liste de ces variables :

- a. **Le nombre de pics de fréquence (MCGL/MEC) :** varie entre 2 et 15 et permet de connaître le nombre de pics pertinants pour décrire la texture.

- b. **La fréquence minimale entre chaque pic (MCGL/MEC)** : varie entre 5 et 50 hz. Cette distance a pour objectif de filtrer le bruit créant parfois plusieurs pics proches mais sans impacter les pics rapprochés importants.
- c. **Le classement par fréquence ou intensité (MCGL/MEC)** : cette variable détermine si le classement des pics doit se faire par intensité ou par fréquence avant d'entrer dans l'algorithme d'apprentissage.
- d. **L'intégration de la vitesse moyenne du capteur sur la texture (MCGL)** : cette variable propose trois options : la non-intégration de la vitesse moyenne du capteur sur la texture, son intégration en tant que variable de l'algorithme d'apprentissage ou son intégration sous forme d'un étirement temporel permettant de ramener toutes les acquisitions à la même vitesse (1s à 1m/s devient 0.5s à 2m/s).
- e. **L'intégration de la force moyenne appliquée par le capteur sur la texture (MCGL)** : cette variable choisit si la force doit être ou non intégrée comme variable d'entrée de l'algorithme d'apprentissage.
- f. **La longueur du signal (MCGL/MEC)** : cette variable choisit si la force doit être ou non intégrée comme variable d'entrée de l'algorithme d'apprentissage.
- g. **L'intégrale du signal(MCGL/MEC)** : cette variable choisit si l'intégrale du signal doit être ou non utilisée comme variable d'entrée de l'algorithme d'apprentissage.
- h. **La décomposition en éléments de rotation (MEC)** : comme le mouvement d'exploration est en rotation, l'acquisition peut être découpée entre 1 et 6 parties pour extraire les pics de Fourier de chacune des sous-acquisitions.

Les trois dernières variables sont des variables des algorithmes d'apprentissage :

- i. **Le nombre de neurones sur la couche cachée du RNA (MCGL/MEC)** : varie entre 5 et 50.

- j. **BoxConstraint (SVM)** : varie entre 10^{-2} et 10. Cette valeur permet de limiter la taille de certains coefficients des vecteurs des SVM et donc d'obtenir des frontières différentes.
- k. **KernelScale (SVM)** : varie entre 10^{-5} et 10^5 . Cette variable modifie l'échelle de la fonction de Kernel permettant les transformations non-linéaires.

Pour la variation des deux derniers paramètres, nous suivons les recommandations de l'aide de Matlab.

2.4 Mouvements de courts glissements linéaires (MCGL)

Dans cette première expérience, nous allons étudier des petits mouvements dans une seule direction reproduisant le mouvement exploratoire humain montré sur la figure 2.1. Les acquisitions sont fait à des vitesses et forces d'acquisition différentes afin de chercher à s'affranchir de ces facteurs. Dans cette partie, nous détaillons le protocole expérimental et montrons les résultats de l'expérience.

2.4.1 Protocole expérimental

Dans cette première étude, nous nous intéressons à la discrimination des quatre textures de la figure 2.4. Voici un descriptif détaillé de ces textures :

- a. Cette texture contient des stries creusées de $400\mu\text{m}$ de large par $200\mu\text{m}$.
- b. Cette texture contient des stries creusées de $300\mu\text{m}$ de large par $200\mu\text{m}$.
- c. Cette texture contient des stries creusées de $300\mu\text{m}$ de large par $200\mu\text{m}$. Les stries sont deux fois plus profondes que la texture b).
- d. Cette texture contient un quadrillage creusé avec des stries de $400\mu\text{m}$ de large formant des carrés de $200\mu\text{m}$ de longueur.

Les textures sont frottées à la surface du capteur illustrée par la figure 2.5. La surface formée d'un ensemble de cercle a été étudiée pour donner une bonne saisie d'objets, plus que pour




Figure 2.4 Textures pour l'expérience MCGL

permettre une bonne exploration de l'environnement. Le matériau utilisé est un silicone de dureté 40A sur l'échelle de Shore.




Figure 2.5 Surface du capteur utilisé

Nous réalisons des acquisitions à trois vitesses différentes et trois forces différentes. 50 acquisitions sont réalisées par textures, par vitesse et par force. Cela représente 450 échantillons par texture soit une base de données de 1800 échantillons. Les acquisitions durent 500ms. Ce choix a été stimulé par le fait qu'il s'agit du temps nécessaire pour parcourir les 10cm de la texture à la vitesse la plus rapide. Les vitesses moyennes choisies sont 0.1m/s, 0.15m/s et 0.2m/s et les forces sont 1N, 2.5N et 5N.

2.4.2 Résultats

La simulation dure 8h. Le taux de reconnaissance sur 4 textures est de 82.2% (avec un taux de rejet de 8.5%) pour les RNA et de 85.3% (avec un taux de rejet de 7.8%) pour les SVM. Deux à deux, les textures sont différenciées avec un taux variant entre 85.7% et 93.8% pour les RNA (set d'apprentissage : 87.8%-96.2%, set de test : 81.8%-93.5%). Pour les SVM, ce même taux varie entre 86.4% et 94.8% (set d'apprentissage : 87.1%-100%, set de test : 77.6%-94%). Le tableau 2.1 donne la matrice de confusion des 4 textures pour les SVM. On notera que les données éronnées sont relativement bien réparties, même si la texture 4 est moins bien reconnue que les autres alors que c'est la plus différente vu qu'elle comporte un quadrillage et non des stries. Le défi de l'optimisation de ce RNA a été de réussir à bien différencier les textures 2 et 3 qui se ressemblent beaucoup. En demandant à cinq personnes différentes dans le laboratoire de déceler si les deux textures étaient différentes, uniquement une personne a trouvé la bonne réponse. La figure 2.6 illustre cela en montrant la transformée de Fourier de deux acquisitions de ces deux textures. Les acquisitions ont été réalisées avec la même vitesse et force moyenne du déplacement entre le capteur et la texture.

	a_c	b_c	c_c	d_c	nc
a_r	381	19	8	14	28
b_r	2	364	14	25	45
c_r	8	37	347	30	28
d_r	23	34	30	324	39

r : réel c : classé nc : non classé

Tableau 2.1 Matrice de confusion de MCGL avec des SVM

Il est aussi intéressant d'examiner les résultats de l'algorithme génétique donnant les valeurs des variables optimisées pour un bon résultat en globalisation. Afin de bien comprendre ces résultats, il est important de répreciser le fonctionnement de l'algorithme global. Dans ce problème, nous avons optimisé 6 RNA/SVM différents. Chacun est spécialisé dans la discrimination de deux textures précises. Par exemple, le premier compare la texture 1 et la texture 2. La texture résultante est celle détectée par le plus grand nombre de RNA/SVM. En cas d'égalité,




Figure 2.6 FFT de deux acquisitions des textures 2 (à gauche) et 3 (à droite) à même vitesse et force moyenne

le résultat est considéré comme non classé. Le tableau 2.2 présente les valeurs des variables pour l'optimisation des 6 RNA et le tableau 2.3 pour les 6 SVM. Pour la prise en compte de la vitesse, 0 signifie que la vitesse n'est pas prise en compte, 1 qu'elle a été prise en compte comme valeur d'entrée de l'algorithme d'apprentissage (RNA ou SVM) et 2 qu'elle a servi à faire un élargissement temporel directement sur le signal (1s à 1m/s devient 0.5s à 2m/s). Les valeurs de boxconstraint KernelScale pour les SVM sont directement celles utilisées par matlab. Le classement des composantes principales se fait toujours par amplitude. Nous avons donc choisi de l'enlever des tableaux pour faciliter leur lecture.

On peut noter que les variables résultant de l'algorithme génétique sont séparées en deux groupes. Certaines varient considérablement et d'autres non. Par exemple, pour les réseaux de neurones, le nombre de pics de la transformée de Fourier nécessaire pour différencier deux textures varie entre 3 et 15 dépendamment des deux matériaux à différencier. De même, le nombre de neurones sur la couche cachée varie globalement beaucoup. De plus, il est intéressant de noter que la vitesse, l'intégrale et la longueur du signal sont beaucoup utilisées alors que

Textures comparées	1-2	1-3	1-4	2-3	2-4	3-4
Nombre de composantes principales (CP)	15	15	15	7	3	11
Distance minimale entre les CP (en hz)	20	25	30	40	45	20
Prise en compte de la vitesse moyenne	2	0	1	2	1	2
Prise en compte de la force moyenne	0	0	1	0	1	1
Prise en compte de l'intégrale du signal	1	1	0	1	0	1
Prise en compte de la longueur du signal	1	1	1	1	0	1
Nombre de neurones sur la couche cachée	25	5	5	30	5	40

Tableau 2.2 Valeurs des variables de l'algorithme génétique pour les RNA

Textures comparées	1-2	1-3	1-4	2-3	2-4	3-4
Nombre de composantes principales (CP)	11	14	11	7	11	12
Distance minimale entre les CP (en hz)	30	20	25	35	20	20
Prise en compte de la vitesse moyenne	2	1	2	2	1	2
Prise en compte de la force moyenne	0	1	1	1	0	0
Prise en compte de l'intégrale du signal	1	1	0	0	1	0
Prise en compte de la longueur du signal	0	1	1	1	0	0
Kernel Scale	1	10	1	1	10	1
Box constraint	10	10	10	10	10	1

Tableau 2.3 Valeurs des variables de l'algorithme génétique pour les SVM

la force l'est finalement moins (50% des cas). Enfin, la vitesse est plus souvent utilisée pour détendre le temps que directement comme entrée du RNA. Dans le cas des SVM, le nombre de pics varient moins. La vitesse moyenne est toujours utilisée mais par contre, la force, l'intégrale et la longueur du signal le sont moins.

Un second mode incluant un vote majoritaire a été réalisé. Il sépare en 5 parties de 100ms les acquisitions de 500ms. Chaque mini-acquisition est soumise aux RNA ou SVM optimisés. La réponse ayant au moins trois voix détermine la réponse de l'acquisition. Dans ce cas, l'optimisation est beaucoup plus longue comme la base de données est beaucoup plus importante. Pour diminuer le temps d'acquisition, nous faisons une petite optimisation de 10 individus sur 10 générations démarrant à partir du résultat de la simulation précédente. Dans ce mode, les RNA atteignent seulement 84.4% avec un taux de rejet de 5.9% (amélioration de 2.2%) alors que les SVM montent à 98.2% avec un taux de rejet de 0.9% (amélioration de 12.9%). Le ta-

bleau 2.4 montre la matrice de confusion des SVM. On notera que les deux éléments ayant le plus d'erreurs sont le second et le troisième. Néanmoins, la qualité des acquisitions peut aussi intervenir comme nous le verrons par la suite.

	a_c	b_c	c_c	d_c	nc
a_r	445	0	2	2	1
b_r	1	427	15	1	6
c_r	0	4	437	2	7
d_r	1	2	2	443	2

r : réel c : classé nc : non classé

Tableau 2.4 Matrice de confusion de MCGL avec des SVM en vote majoritaire (5 votes)

Dans le cas du vote majoritaire, les valeurs des variables optimisées par l'algorithme génétique sont disponibles dans le tableau 2.5 pour les RNA et 2.6 pour les SVM.

Textures comparées	1-2	1-3	1-4	2-3	2-4	3-4
Nombre de composantes principales (CP)	15	13	12	15	6	7
Distance minimale entre les CP (en hz)	20	25	25	5	20	5
Prise en compte de la vitesse moyenne	2	1	2	2	1	2
Prise en compte de la force moyenne	0	1	1	1	1	1
Prise en compte de l'intégrale du signal	1	1	0	1	1	1
Prise en compte de la longueur du signal	1	1	1	1	0	1
Nombre de neurones sur la couche cachée	10	15	50	50	10	50

Tableau 2.5 Valeurs des variables de l'algorithme génétique pour les RNA (vote majoritaire)

Pour les RNA, nous constatons que le nombre de composantes principales reste élevé. De plus, la vitesse, la force, l'intégrale du signal et sa longueur deviennent quasiment indispensables en étant utilisées dans plus de 5 cas sur 6. Nous remarquons aussi qu'un nombre plus important de neurones sur la couche cachée est nécessaire. Ces résultats sont cohérents car, comme les acquisitions sont plus courtes (100ms au lieu de 500ms), l'algorithme a besoin de plus d'informations pour être précis. Pour les SVM, les résultats se ressemblent beaucoup : un nombre de pics autour de 10, une tendance très importante à utiliser la vitesse (par élargissement temporel)

Textures comparées	1-2	1-3	1-4	2-3	2-4	3-4
Nombre de composantes principales (CP)	9	12	13	11	12	8
Distance minimale entre les CP (en hz)	30	25	25	20	20	25
Prise en compte de la vitesse moyenne	2	2	2	2	2	2
Prise en compte de la force moyenne	0	0	0	0	1	1
Prise en compte de l'intégrale du signal	0	0	0	0	0	1
Prise en compte de la longueur du signal	1	1	1	1	1	0
Kernel Scale	1	1	1	1	1	1
Box constraint	10	10	10	10	10	10

Tableau 2.6 Valeurs des variables de l'algorithme génétique pour les SVM (vote majoritaire)

et la longueur du signal. Seul les deux derniers SVM utilisent la force et/ou l'intégrale. Les valeurs des boxconstraint et du KernelScale sont aux valeurs maximales possibles. Nous n'avons pas pu élargir la plage de valeurs en raison de différentes erreurs de simulation nécessitant de réduire ces variables. Comme précédemment, le classement des composantes principales de la FFT se fait toujours par amplitude.

Nous pouvons conclure que cette première étude montre qu'il est possible de classer des textures avec des acquisitions à des vitesses et forces différentes. Par contre, on notera qu'il est important d'avoir une idée de l'ordre de grandeur de cette vitesse et de cette force. Pour être indépendant de ces deux éléments, il faudrait retravailler encore plus profondément l'algorithme et trouver sûrement de nouveaux discriminants. Il faut aussi noter que si on augmente le nombre de textures, on perdra considérablement en précision.

2.5 Mouvements d'exploration circulaire (MEC)

Cette première partie a montré qu'il est possible de discriminer avec de bons résultats des textures à des vitesses et des forces entre le capteurs et la textures variant. Dans cette seconde étude, nous nous intéressons à l'invariance de l'orientation de la texture au moment de l'acquisition. Dans un environnement réel, le robot ne pourra pas toujours passer son doigts dans le sens opposé des stries ou d'un quadrillage. Il est donc important qu'il soit capable de reconnaître une texture avec un mouvement exploratoire simple mais adapté à n'importe quelle

orientation. Pour cela, nous allons comparer deux mouvements exploratoire : un mouvement linéaire similaire à la partie précédente et un mouvement rotatif.

2.5.1 Protocole expérimental

Cette seconde étude a pour objectif d'obtenir une invariance à l'orientation de la texture au moment de l'acquisition. Nous cherchons à déterminer un mouvement d'acquisition et un algorithme permettant de reconnaître une texture même si l'acquisition se fait dans le sens des stries ou en diagonale d'un quadrillage. Pour cela, nous proposons de comparer les deux mouvements exploratoires de la figure 2.7. Voici une description de ses mouvements :

- a. Le premier mouvement est un geste linéaire unidirectionnel sur environ 5cm (vitesse et force moyennes constantes). Le mouvement est réalisé dans différentes orientations sur la texture : 0 degrés (à l'opposé des stries), 30 degrés, 45 degrés et 90 degrés (dans le sens des stries).
- b. Le second mouvement est un cercle sur la texture d'environ 2cm de rayon. Nous faisons varier le point de départ de l'acquisition : 0 degrés (l'acquisition commence dans le sens inverse des stries), 30 degrés, 45 degrés et 90 degrés (l'acquisition commence dans le sens des stries).

L'étude a porté sur 5 textures différentes illustrées sur la figure 2.8. Le descriptif ci-dessous détaille les paramètres de ces textures :

- a. Cette texture contient des stries creusées de 300 μ m de large par 200 μ m.
- b. Cette texture contient des stries creusées de 400 μ m de large par 200 μ m.
- c. Cette texture contient un quadrillage creusé avec des stries de 400 μ m de large formant des carrés sortants de 200 μ m de longueur.
- d. Cette texture contient un quadrillage creusé par des carrés de 200 μ m de large formant des stries sortantes de 300 μ m.




Figure 2.7 Illustration des deux mouvements exploratoires utilisés

- e. Cette texture contient des cercles concentriques d'une largeur de $300\mu\text{m}$ et espacés chacun de $300\mu\text{m}$. Cette dernière texture amène aussi une petite difficulté d'invariance spatiale.




Figure 2.8 Textures pour l'expérience MEC

Pour chaque mouvement exploratoire, 200 acquisitions ont été réalisées par texture. Pour le mouvement unidirectionnel, les acquisitions ont été séparées en 4 fois 50 acquisitions avec des orientations différentes (0 degré (sens des stries), 45, 90 et 30 degrés). Pour le mouvement circulaire, c'est le point de départ qui a changé. les 4 même angles ont servi de point de départ.

2.5.2 Résultats

L'apprentissage a été réalisé avec un algorithme génétique de 20 individus sur 30 générations. Il est intéressant de noter que dans le cas du premier mouvement, les RNA permettent une reconnaissance à 75.4% (avec 10.2% de rejet) et les SVM 87.0% (avec 7.8% de rejet). Les deux textures difficiles à différencier sont la (a) et la (b) ainsi que la (b) et la (d). Dans le cas de ces dernières, les composantes fréquentielles sont les mêmes. Seul le fait que l'une contienne des stries et l'autre un quadrillage les différencie. Il est intéressant de noter que ces résultats sont très corrects. La plus grande perte d'information a lieu lors de l'acquisition dans le sens des stries qui contient très peu de composantes fréquentielles.

Dans le cas du mouvement circulaire, l'algorithme découpe l'acquisition en plusieurs parties (variant entre 1,3,5,7 et 9) et les fait individuellement passer dans le RNA ou le SVM. Ensuite, un vote majoritaire est réalisé afin de déterminer la texture ayant le plus d'occurrence. Cela permet d'obtenir les résultats suivants.

Les RNA ont une reconnaissance de 85.7% avec un rejet de 3.1% et les SVM atteignent 93.0% avec un rejet de 3.4%. On observe une nette augmentation mais aussi une réduction intéressante du rejet. Il reste néanmoins compliqué de différencier les textures (a) et (b). La figure 2.7 montre la matrice de confusion pour un SVM.

	a_c	b_c	c_c	d_c	e_c	nc
a_r	157	30	0	0	2	11
b_r	28	162	0	1	6	0
c_r	2	0	192	1	0	5
d_r	1	0	0	190	1	8
e_r	1	0	0	1	197	1

r : réel c : classé nc : non classé

Tableau 2.7 Matrice de confusion de MEC avec des SVM
et un mouvement exploratoire rotatif

Le tableau 2.8 présente les valeurs des variables optimisées par l'algorithme génétique dans le cas des RNA et le tableau 2.9 pour les SVM.

Dans le cas du vote majoritaire, les valeurs des variables optimisées par l'algorithme génétique sont disponibles dans le tableau 2.5 pour les RNA et 2.6 pour les SVM.

Text-ures com-parées	Nombre de composantes principales	Distance minimale entre les composantes principales (en hz)	Nombre de découpes de l'acquisition	Prise en compte de l'intégrale du signal	Prise en compte de la longueur du signal	Nombre de neurones sur la couche cachée
1-2	10	5	9	1	1	10
1-3	9	35	9	1	1	5
1-4	14	25	9	1	1	10
1-5	7	35	9	0	0	5
2-3	15	20	9	1	1	25
2-4	4	20	9	1	0	15
2-5	14	10	7	0	1	40
3-4	4	20	9	0	1	50
3-5	15	25	9	0	1	5
4-5	11	5	9	1	0	20

Tableau 2.8 Valeurs des variables de l'algorithme génétique pour les RNA (mouvement rotatif)

Il est intéressant de noter que la tendance est de découper l'acquisition en 7 ou 9 dans presque tous les cas. Pour les RNA, l'intégrale du signal et sa longueur sont utilisées par 6-7 RNA sur 10. Le nombre de composantes principales de la FFT et de neurones sur la couche cachée est très variable. Pour les SVM, la tendance est d'utiliser au plus soit l'intégrale, soit la longueur du signal. Les coefficients des SVM (BoxConstraint et KernelScale) sont globalement constants et relativement élevés.

En conclusion, le mouvement circulaire permet une augmentation considérable de la reconnaissance par rapport à un mouvement linéaire classique. Ce mouvement pourrait être utilisé pour explorer des environnements et des surfaces planes relativement grandes (supérieures à 5x5cm). Néanmoins, il ne faut pas négliger le mouvement linéaire qui a aussi de nombreuses applications : il permet d'effleurer un objet tenu dans la main et peut se faire de manière discrète durant une manipulation. Le choix du mouvement pourra être réalisé en fonction du temps disponible

Text-ures com-parées	Nombre de compo-santes prin-cipales	Distance minimale entre les composantes principales (en hz)	Nombre de découpes de l'acqui-sition	Prise en compte de l'intégrale du signal	Prise en compte de la longueur du signal	Ker-nel Sca-le	Box con-straint
1-2	8	5	1	0	1	1	1
1-3	8	35	9	0	0	1	1
1-4	14	25	9	0	1	10	1
1-5	6	35	9	0	1	1	1
2-3	6	15	9	1	0	1	1
2-4	7	15	9	1	0	10	1
2-5	4	25	9	0	0	1	1
3-4	7	25	9	1	0	1	1
3-5	10	25	7	0	0	1	1
4-5	15	10	9	0	1	1	1

Tableau 2.9 Valeurs des variables de l'algorithme génétique pour les SVM (mouvement rotatif)

par le robot et du type de résultat désiré : le mouvement circulaire permet un meilleur résultat mais nécessite un temps dédié à l'exploration et le mouvement linéaire, bien que ses résultats soient plus incertains, est rapide et a plus d'applications.

2.6 Étude finale : différenciation de textures fines

Dans les deux études précédentes, nous avons travaillé avec des textures fabriquées artisanalement et relativement rugueuses. Avant d'entreprendre une étude plus approfondie sur des caractéristiques intrasèques du matériau, il est important de vérifier que le capteur peut travailler avec des textures fines. C'est pourquoi, nous proposons dans cette dernière étude de discriminer 10 textures différentes dont 4 très fines. Cette étude permettra aussi de voir comment notre algorithme réagit avec un nombre plus important de textures.

2.6.1 Protocole expérimental

Cette dernière expérience a pour objectif d'utiliser la grande sensibilité de notre capteur afin de différencier des textures très fines et proches. Dans cette expérience, nous travaillons sur dix textures fines de tous les jours décrites dans la figure 2.9.




Figure 2.9 Textures pour l'expérience de sensibilité

Pour chaque texture, nous réalisons 200 acquisitions ayant une vitesse et force moyennes constantes. Le capteur est frotté sur environ 10cm à 125mm/s avec une force d'environ 2N.

2.6.2 Résultats

L'architecture utilisée contient 45 RNA ou SVM différenciant les textures deux à deux. De la même manière que précédemment, la texture sélectionnée est celle ayant été reconnue par le plus grand nombre de RNA/SVM. En cas d'égalité, l'acquisition est considérée comme "non classée". Pour optimiser ces nombreux réseaux, nous utilisons un algorithme génétique de 10 générations de 13 individus. Chaque optimisation repart des résultats de l'expérience MCGL. Elle dure environ 8h. Cet algorithme ne comprend pas de vote majoritaire.

Les résultats sont très prometteurs : 95.1% pour les RNA (0.3% de rejet) et 96.1% pour les SVM (1.4% de rejet). Deux à deux, les résultats sont au minimum de 98.5% et la plupart différencie à 100% les textures. La figure 2.10 présente la matrice de confusion pour les SVM.

	a_c	b_c	c_c	d_c	e_c	f_c	g_c	h_c	i_c	j_c	nc
a_r) Feuille de métal	200	0	0	0	0	0	0	0	0	0	0
b_r) Plastique lisse	0	183	10	0	3	0	0	0	0	0	4
c_r) Feuille de papier	0	20	171	3	0	0	0	1	0	0	5
d_r) Papier cartonné	0	0	4	190	0	0	0	2	0	0	4
e_r) Bois composite	0	0	0	0	195	0	0	0	3	0	2
f_r) Plastique à CS*	0	2	0	0	0	180	15	0	0	0	3
g_r) Plastique à CE*	0	2	0	0	0	7	191	0	0	0	2
h_r) Cuir à motif	0	0	0	2	0	0	0	193	0	0	5
i_r) Plastique brossé	0	0	0	0	4	0	0	1	193	0	2
j_r) Plastique à MC*	0	0	0	0	0	0	0	0	0	200	0

r : réel c : classé nc : non classé

*CS : carreaux sortants, CE : carreaux entrants, MC : motifs coulés

Tableau 2.10 Matrice de confusion des SVM sur 10 textures fines

On peut voir que les deux sources principales d'erreurs sont le plastique lisse (b) et la feuille de papier (c) ainsi que le plastique à carreaux sortants (f) et le plastique carreaux entrants (g). Dans le premier cas, le capteur a eu tendance à coller au plastique lisse. Il est probable que cela ait faussé l'acquisition la rendant semblable au papier. Dans le second cas, les textures sont relativement proches et certaines acquisitions devaient être de qualité moyenne. Néanmoins, les erreurs restent inférieures à 10%.

2.7 Discussion

Les résultats de notre troisième étude qui a permis d'obtenir la classification de 10 textures fines à plus de 95% nous permet d'obtenir un résultat relativement similaire à celui de Mayol-Cuevas *et al.* (1998) et Edwards *et al.* (2008) qui avaient classifié une vingtaine de textures dans des conditions similaires et avec des résultats relativement semblables. Les éléments réellement novateurs de notre étude sont les deux premières études. La première est relativement comparable à celle de Jamali et Sammut (2011) qui a comparé trois vitesses entre le capteur

et la texture différentes (mais à force constante) et obtient des résultats atteignant 95%. Notre étude propose en plus de comparer trois forces d'acquisition différentes en simultané des trois vitesses d'acquisition. Elle propose aussi différents traitements pour ces vitesses. Une nouvelle proposition est réalisée aussi en découpant l'échantillon pour le vote majoritaire au lieu de prendre plusieurs échantillons différents. Cela permet d'atteindre des résultats à 98.2%. Enfin, notre seconde étude est actuellement unique. Toutes les études référencées ne se sont pas intéressées à l'impact de l'orientation de la texture. Nous ne pouvons pas comparer notre étude à d'autres mais nous pouvons conclure, appuyés par les résultats obtenus supérieurs à 93%, qu'il s'agit d'un facteur à prendre en compte et que l'exploration de nouveaux mouvements est une démarche intéressante. Enfin, nous pouvons espérer atteindre des résultats semblables à Fishel et Loeb (2012) qui discriminent 117 textures à plus de 97%.

Pour terminer, nous avons quatre points à proposer pour améliorer les études futures : les causes d'erreurs des expériences, l'impact de l'algorithme génétique, le vote majoritaire, et les limitations de l'étude.

Tout d'abord, plusieurs sources d'erreurs rendant les acquisitions imprécises ont été relevées. Premièrement, la surface du capteur est relativement épaisse et collante et a été conçue en priorité pour attraper les objets plus que pour les palper. Il serait pertinent d'étudier un nouveau matériau et une nouvelle forme pour cette surface. Il serait intéressant de tester les empreintes digitales à la manière de différentes études comme Chathuranga *et al.* (2013). Le matériau aurait besoin d'être moins collant et de mieux transmettre les vibrations. La seconde source d'imprécision notée est la réalisation des acquisitions : elles ont toutes été faites à la main. Malgré l'utilisation d'un métronome et d'un dynamomètre pour contrôler la vitesse et la force, cela reste approximatif. Le même problème se pose avec le mouvement circulaire qui était assez imprécis. Néanmoins, cela évite les vibrations internes du robot et pour certaines acquisitions, le fait de sentir la texture à travers le capteur permet de "mieux" réaliser l'acquisition. Au niveau de l'algorithme, nous n'utilisons sûrement qu'un nombre très faible d'informations du signal et de nouveaux discriminants pourraient être trouvés. Les algorithmes d'apprentissage

utilisés restent aussi basiques et une meilleur discrimination pourrait être envisagée avec des algorithmes plus poussés.

L'utilisation d'algorithme génétique pour optimiser l'apprentissage est une nouveauté dans ce domaine. Cela a permis de conclure sur la pertinence de certaines variables et de mieux les optimiser. L'outil est puissant et peut permettre beaucoup plus de tests différents. Néanmoins, cela allonge considérablement le temps des simulations.

Les essais réalisés avec le vote majoritaire sont concluants. Le fait de couper les acquisitions fait perdre un peu d'efficacité à l'algorithme de discrimination mais généralement, cela est largement compenser par le vote et permet d'améliorer certains résultats jusqu'à 13%. Les études de Fishel et Loeb (2012) et Jamali et Sammut (2011) avaient utilisées cela pour améliorer leurs résultats et nous confirmons l'efficacité de ce type d'algorithme et montrons qu'ils peuvent être réalisé en coupant l'acquisition.

Notre étude a malgré tout plusieurs limitations. Premièrement, comme nous comparons à chaque fois les textures deux à deux. Cela rendrait donc compliqué de différencier un grand nombre de textures car la durée de l'apprentissage serait considérablement allongée. Par exemple, rajouter une 11ème texture rajouterait 1h30 d'apprentissage (sur 8). Il faudrait penser à des algorithmes permettant de séparer les acquisitions en groupe afin de limiter le nombre de réseaux de neurones ou SVM. Cela nécessiterait d'approfondir les architectures d'algorithme intelligent. La seconde limitation est sur le capteur qui ne permet actuellement pas d'acquiesionner en même temps le statique et le dynamique. Cela permettrait d'avoir plus d'informations sur la texture et pourrait permettre une meilleur discrimination. Enfin, notre système d'acquisition a une limite sur les surfaces et objets pouvant être acquis : il n'est pas possible d'utiliser les objets trop petits, trop déformables ou avec des formes trop compliquées. Nous avons globalement travaillé avec des surfaces planes ou légèrement courbées de minimum 8x3cm. La dernière limite est que pour reconnaître une nouvelle texture, elle a besoin d'être apprise auparavant.

Pour terminer, nous pouvons nous interroger sur l'utilisation en robotique de ce type d'informations et la mise en pratique de ces algorithmes. A quel moment un robot pourrait-il réaliser

ces acquisitions durant la manipulation d'objets ? Ensuite, quelles informations pourrait-il en retirer et comment cela pourrait améliorer la manipulation des objets ?

CHAPITRE 3

QUANTIFICATION DE LA RUGOSITÉ À L'ÉCHELLE HUMAINE

La partie précédente vise à déterminer si, en utilisant le capteur développé au laboratoire CoRo de l'ÉTS, il est possible de déterminer un algorithme permettant la discrimination de textures. En plus de résultats intéressants, cette partie a aussi permis d'étudier les caractéristiques à extraire dans le signal (composantes principales de la FFT du signal, intégrale du signal...) et des configurations d'algorithme d'apprentissage optimisé par un algorithme génétique. Néanmoins, ce type d'algorithme a une limite : il ne peut pas être globalisé. En effet, il n'est pas possible d'identifier une texture qui n'a pas été apprise précédemment. C'est pourquoi, dans cette seconde partie, nous nous intéressons à quantifier la rugosité d'une texture à partir d'un frottement entre le capteur et la texture dans le but de pouvoir le généraliser à toutes les textures.

L'objectif est de proposer une échelle semblable à la manière de quantifier la rugosité de l'être humain. Nous avons fait ce choix car, en cherchant un sens scientifique à la rugosité, il aurait été nécessaire d'établir des critères sur la géométrie de la texture (profondeur, largeur des stries...) qui sont délicats à mesurer avec un capteur tactile et auraient généré une grande imprécision. De plus, ils ne resteraient pas complètement fiables car il est délicat d'établir des règles rigoureuses sur la rugosité. La perception humaine, bien que relative d'une personne à une autre, contribue à la bonne manipulation de l'environnement dont l'humain est capable. De plus, un être humain est capable d'estimer entre deux textures laquelle est la plus rugueuse uniquement avec le toucher. En attribuant un niveau de rugosité à chaque texture, nous obtenons un indice relatif mais facile d'utilisation et estimant la rugosité. Notre méthode de classement consiste à donner à chaque texture un indice variant entre 1 à 10 où 1 est la texture la plus lisse et 10 la texture la plus rugueuse.

Pour réaliser cette expérience, nous avons procédé en deux temps : l'initialisation de l'échelle puis des tests avec un algorithme d'apprentissage. Pour initialiser notre échelle, nous avons demandé à 30 personnes de quantifier la rugosité de 25 textures. Ensuite, nous nous sommes

servis de ces résultats pour simuler à travers plusieurs algorithmes d'apprentissage différents une estimation de la rugosité.

Dans cette partie, nous commençons par détailler l'approche proposée. Nous présentons ensuite notre expérience de calibration de l'échelle. L'algorithme utilisé est présenté par la suite avant de détailler les résultats de l'expérience. Nous terminons par une discussion des résultats afin de proposer des travaux futurs.

3.1 Approche proposée

Johansson et Flanagan (2009) montrent que le toucher humain est capable à lui seul de faire les manipulations d'un objet

sans besoin particulier de vision. La vision permet de conditionner la main avant d'attraper l'objet en préconcevant l'objet à l'avance (si on réfléchit, on sait souvent déjà à quoi s'attendre comme sensation avant de toucher un objet). Glover (2002) explique que si la vue donne de mauvaises informations, c'est uniquement la planification du mouvement qui est perturbée, la manipulation se passe bien. Cela implique que le toucher est suffisant pour manipuler et identifier un objet. Dans le cas de la rugosité, un seul glissement quelconque permet à l'être humain d'estimer la rugosité de l'objet, indépendamment du mouvement, de la vitesse, ou de la force appliquée.

Ce type d'information permet une meilleure manipulation des objets durant des réflexes. Bauer *et al.* (2010) définit un réflexe comme un mouvement que l'être humain réalise naturellement sans avoir besoin de réfléchir comme attraper un objet, ne pas le laisser tomber, ou ne pas blesser son environnement. L'objectif de ces réflexes est de donner au robot un comportement semblable à celui de l'être humain afin de lui permettre d'interagir dans un environnement vivant et dynamique.

La connaissance de la rugosité pourrait permettre une meilleure connaissance des forces nécessaires pour la préhension d'un objet et l'accomplissement d'une tâche avec celui-ci. Elle permettrait aussi d'améliorer les réflexes suivants : ne pas laisser un objet glisser de la main, manipuler un objet fragile, utiliser un objet en contact avec autre objet (ex : une éponge sur une table ou un fer à souder sur le matériau à souder)

D'après Meftah *et al.* (2000), la détection tactile de la rugosité est très fortement liée à la période spatiale du matériau. Cette même étude pense que la vitesse de l'acquisition n'a pas d'influence sur le résultat mais Cascio et Sathian (2001) ont montré plus tard que celle-ci contribuait à la sensation de rugosité. Smith *et al.* (2002) a appuyé ce résultat en montrant que le rapport entre la force normale et longitudinale a un impact important dans la quantification

de la rugosité. Le phénomène de la rugosité humaine est encore loin d'être clairement identifié et modélisé. Il est donc relativement compliqué de le reproduire.

3.2 Étude de l'évaluation de la rugosité par l'être humain

Afin de pouvoir créer une échelle de rugosité à l'image humaine, nous avons utilisé les 25 textures de la figure 3.1. Nous avons demandé à trente personnes de classer ces textures sur une échelle de 1 à 10, 1 représentant les textures les plus lisses et 10 les textures les plus rugueuses. Dans cette partie, nous détaillons cette expérience de calibration de notre échelle.

3.2.1 Présentation de l'étude

Les trente sujets sont composés de 15 hommes et 15 femmes. 15 font partie de la tranche d'âge 18-25ans, 10 de la tranche d'âge 25-40 ans et les 5 derniers font partie de la tranche d'âge 40 et plus. 15 d'entre eux font des études ou travaillent dans un domaine scientifique. Parmi eux, 7 travaillent dans le domaine de la robotique tactile et 8 autres exercent en génie. Les 15 derniers sujets ont une profession dans divers domaines extérieurs à la science.

Les sujets ont été mis devant les 25 textures. L'objectif est expliqué ainsi : classer 25 textures sur une échelle de rugosité allant de 1 à 10. Après quelques consignes et une présentation des textures, ils ont le temps qu'ils considèrent nécessaire pour regarder, toucher et placer les textures sur l'échelle de rugosité. Les consignes données sont les suivantes :

- a. Chaque texture doit recevoir un indice de rugosité entre 1 et 10.
- b. Les textures doivent être réparties de manière homogène sur l'échelle (entre 2 et 3 textures par indice en moyenne).
- c. Il est important de bien distinguer collant et rugueux. On cherche uniquement à quantifier la rugosité.

Suite à l'expérience, il a été demandé aux participants quelle pourrait-être selon eux l'erreur entre leur réponse et la moyenne du sondage. Il leur a aussi été demandé comment il avait quantifié la rugosité.

3.2.2 Présentation des textures

Les textures sélectionnées ont été choisies de manière à représenter au mieux la diversité des textures présentes dans l'environnement humain. Néanmoins, elles sont toutes relativement rigides et peu déformables. Nous allons parcourir rapidement les textures sélectionnées.

La texture (a) est un bois composite comme on peut en trouver dans les tables et les meubles. Les plastiques (b), (c), (d), (i) et (j) sont des textures que l'on trouve sur divers objets (téléphones, imprimantes, boîtes...) pour leur donner une meilleure adhérence en main. Les papiers sablés (e), (f) et (g) sont souvent utilisés pour polir du bois ou d'autres matériaux souples. Le cuir à motifs (h) est un type de matériau utilisé souvent pour des housses de protection de téléphones ou tablettes tactiles. Les feuilles de papier (k), (l), (m) et (w) sont des papiers standard de la vie de tous les jours. Les plastiques (n), (o) et (p) représentent les plastiques lisses de la vie de tous les jours (ordinateur, matériel de cuisine...). La feuille de métal (q) correspond à des surfaces de produits métalliques brossés et la texture (r) donne la texture des miroirs. Le cuir tressé (s) représente différents objets design en cuir (trousse, sac...). La lime usée (t) représente son propre usage. Le tissu tressé (u) s'apparente aux matériaux utilisés pour des sacs synthétiques et le plastique tressé (v) aux tapis de bain anti-dérapant. La brosse de tableau (x) est une texture à la fois douce mais un peu agressive pour les doigts. Enfin le métal tressé (y) est une texture se trouvant sur les microphones ou les hauts-parleurs.

3.2.3 Résultats de l'expérience

En moyenne, les sujets ont mis entre 5 et 25 minutes à classer les textures avec des méthodes uniques à chacun. Certains triaient tous les matériaux en dix groupes sur la table, d'autres prenaient les textures une par une, donnait un indice puis faisaient trois ou quatre tours, d'autres encore trouvaient les extrema puis allaient doucement vers les textures centrales en cherchant les textures voisines aux précédentes. Les réponses données par les participants sur comment




Figure 3.1 Présentation des différentes textures

ils ont interprété la rugosité étaient variables : “Plus une texture est rugueuse, moins elle est agréable à toucher”, “La rugosité représente la quantité de vibrations induite dans le doigt en frottant l’objet”, “La rugosité peut être comparée à la complexité à déplacer son doigt sur la texture”. Mais globalement, les participants ont été surpris par la complexité de ce problème de classification et ont souvent dit que plusieurs classifications auraient été possibles. En moyenne, ils estiment quand même que leurs réponses ont un écart-type de 1 ou 2 de la moyenne des participants.

Les résultats sont donnés par la figure 3.2. Étant donné que quelques participants ont fait le test très rapidement ou n’avaient pas compris certaines subtilités de l’expérience, nous avons choisi de négliger les indices ayant reçu uniquement une ou deux voies par texture. En regardant les résultats, on peut voir que les extrêmes se détachent particulièrement. Ensuite, on constate que la plupart est évaluée sur 4 à 6 indices consécutifs. Certaines ont un indice qui ressort clairement alors que d’autres restent étalées.




Figure 3.2 Graphique des votes des participants

La figure 3.3 propose une autre visualisation des résultats. La boîte représente l'écart-type et les lignes montrent la largeur complète des résultats. On peut voir que dans les extrêmes, l'écart-type est proche de un. En se rapprochant du centre, l'écart-type augmente et les textures ayant les écart-types les plus importants dépassent trois. Nous pouvons donc voir que pour l'être humain, l'échelle de rugosité serait peut-être plus en trois classes : peu rugueux, normalement rugueux, très rugueux. Deux classes intermédiaires pourraient s'interposer. Il est important de noter aussi que l'un des commentaires qui est le plus ressorti suite à l'expérience est qu'il est compliqué de trier toutes les textures car beaucoup de touches ne sont pas plus ou

moins rugueux mais juste différents. Nous allons par la suite essayer de classer sur notre échelle des acquisitions réalisées avec un capteur tactile. En essayant de conserver le même ordre de grandeur que l'être humain, nous chercherons à obtenir une bonne globalisation, c'est-à-dire un fonctionnement de l'algorithme même si la texture n'a pas été apprise précédemment.




Figure 3.3 Ecart-type des textures

3.2.4 Hypothèse pour la simulation

Pour notre simulation, nous allons classer les textures en trois groupes : les textures d'apprentissage, celles de test, et les imprédictibles. Les textures d'apprentissage sont celles qui ont l'écart-type le plus faible et que l'on arrive le mieux à identifier à une valeur. Nous en avons choisi 10 qui correspondent chacune à une valeur de l'échelle de rugosité tel qu'illustrée dans le tableau 3.1. Les textures de test ont aussi été chacune affiliées à un indice de l'échelle de rugosité et vont servir à voir comment l'algorithme se comporte quand il doit généraliser le

problème à des textures qu'il ne connaît pas. Les indices attribués à chacune de ces textures est décrit dans le tableau 3.2.

indice	app
1	(r)
2	(n)
3	(l)
4	(i)
5	(w)
6	(t)
7	(j)
8	(v)
9	(g)
10	(e)

app : textures d'apprentissage

Tableau 3.1 Tableau des textures d'apprentissage

indice	test
1	(p)
1,5	(m)(q)
2	(k)
3,5	(a)(o)
4	(h)
4,5	(c)
6,5	(s)
7,5	(u)
9	(f)
10	(y)

test : textures de test

Tableau 3.2 Tableau des textures de tests

Enfin, les imprédictibles sont les textures ayant les écart-types les plus importants mais aussi des répartitions ne laissant pas de valeur centrale. Elles représentent les textures que les sujets ont eu le plus de mal à classer. Nous allons voir, sans leur attribuer d'indice, comment l'algorithme se comporte dans ces cas particuliers. Trois textures ont été jugées comme im-

prédictibles : le plastique strié (b), le plastique à carreaux sortants (d) et la brosse de tableau (x).

3.3 Principe de l'algorithme

L'algorithme utilisé pour quantifier la rugosité est inspiré par celui utilisé dans la partie précédente pour différencier les textures. En effet, nous avons pu voir dans la dernière expérience distinguant 10 textures que l'algorithme ne mélange pas les textures les plus rugueuses avec les plus douces. Les quatre étapes principales restent les mêmes. Nous allons les reprendre une par une et terminerons par présenter l'optimisation par algorithme génétique que nous réalisons.

3.3.1 Acquisition

L'acquisition est réalisée avec un mouvement unidirectionnel à vitesse et force constantes. Deux cents acquisitions sont réalisées par texture à une vitesse de 0.15m/s et une force de 2.5N. Pour cela, nous utilisons à nouveau un métronome pour la vitesse et un dynamomètre électronique.

3.3.2 Pré-traitements

Les deux mêmes pré-traitements sont appliqués sur les acquisitions. Premièrement, nous rendons la moyenne du signal égale à zéro afin de ne pas avoir de composante fréquentielle nulle sur la transformée de Fourier. Ensuite, nous calculons la FFT (Fast Fourier Transform) qui permettra d'extraire des discriminants.

3.3.3 Sélection des discriminants

Nous allons utiliser aussi une partie des discriminants de l'algorithme de détexion de textures :

Les composantes principales de la transformée de Fourier : à partir de la transformée de Fourier d'une acquisition, ces composantes montrent les fréquences prédominantes dans le matériau. Ces fréquences ont un lien direct avec les propriétés de surface du matériau (lignes, quadrillage...) et gardent une certaine corrélation avec la vitesse de l'acquisition. Notre algo-

rithme détecte les maximums de la transformée de Fourier. Une marge de tolérance impose un écart minimal entre les maximums. Le nombre de maximums détectés est choisi par l'utilisateur (ou l'algorithme génétique) et le code utilise la fréquence et l'amplitude de ces pics comme discriminants de l'algorithme d'apprentissage.

L'intégrale de la valeur absolue du signal i : elle est calculée par la formule 3.1.

$$i = \int_0^l |s(t)|^2 dt \quad (3.1)$$

avec l la longueur du signal et $s(t)$ les valeurs du signal. Cette valeur permet de mieux connaître le signal et peut être mise en adéquation avec la force moyenne. Elle devrait permettre de différencier deux signaux ayant des variations d'intensité et peu de variations fréquentielles.

la longueur du signal l : elle est calculée par l'équation 3.2.

$$l = \sum_{k=1}^l \sqrt{(t_{k+1} - t_k)^2 + (s_{k+1} - s_k)^2} \quad (3.2)$$

Ce dernier indice donne aussi de l'information à la fois sur l'amplitude du signal et sa fréquence.

3.3.4 Apprentissage

Le modèle d'apprentissage est néanmoins très différent. Nous allons comparer trois architectures différentes pour essayer de trouver celle qui permet la meilleure généralisation. Le défi de ce problème réside dans la globalisation : on cherche à ce que le modèle fonctionne par la suite sur toutes les textures sans nécessiter d'apprentissage.

Les trois architectures sont présentées ci-dessous :

Un réseau de neurones multi-couches unique (RNA unique) : il reçoit en entrée les discriminants et retourne directement une valeur entre 1 et 10. Il s'agit du système le plus simple.

Trois réseaux de neurones (RNA3) : chaque réseau représente une partie de l'échelle. Le premier vise à différencier les textures peu rugueuses (1 à 4), le second différencie les textures moyennement rugueuses (4 à 7) et le troisième, les textures rugueuses (7 à 10). Si plusieurs réseaux sont dans des valeurs intermédiaires, une moyenne des résultats est réalisée. Cette architecture a été proposée car les commentaires recueillis auprès des sujets lors de l'expérimentation laissent croire que l'humain différencie surtout les textures entre peu rugueux, moyennement rugueux et très rugueux.

Un SVM spécialisé pour chaque seuil de rugosité (SVM10) : chaque SVM de cet ensemble de 10 SVM permet de reconnaître uniquement les éléments d'un niveau. Si plusieurs indices sont détectés, la moyenne de ceux-ci est retournée.

3.3.5 Optimisation par l'algorithme génétique

Nous avons pu voir lors de notre première expérience que l'optimisation par AG permet une amélioration intéressante des résultats. Nous avons donc repris cette idée sur 8 variables dans ce problème :

- a. **Le nombre de pics de fréquence :** varie entre 2 et 15 et permet de connaître le nombre de pics pertinents pour décrire la texture.
- b. **La fréquence minimale entre chaque pic :** varie entre 5 et 50 Hz. Cette distance a pour objectif de filtrer le bruit créant parfois plusieurs pics proches mais sans impacter les pics rapprochés importants.
- c. **Le classement par fréquence ou intensité :** cette variable détermine si le classement des pics doit se faire par intensité ou par fréquence avant d'entrer dans l'algorithme d'apprentissage.
- d. **La longueur du signal :** cette variable est choisie si la force doit être ou non intégrée comme variable d'entrée de l'algorithme d'apprentissage.
- e. **L'intégrale du signal :** cette variable est choisie si l'intégrale du signal doit être ou non utilisée comme variable d'entrée de l'algorithme d'apprentissage.

Les trois dernières variables sont des variables des algorithmes d'apprentissage :

- f. **Le nombre de neurones sur la couche cachée du RNA** : varie entre 5 et 50.
- g. **BoxConstraint (SVM)** : varie entre 10^{-2} et 10. Cette valeur permet de limiter la taille de certains coefficients des vecteurs des SVM et donc d'obtenir des frontières différentes.
- h. **KernelScale (SVM)** : varie entre 10^{-5} et 10^5 . Modifie l'échelle de la fonction de Kernel permettant les transformations non-linéaires.

La variation des deux derniers paramètres est recommandée par Matlab.

Les paramètres de l'algorithme génétique varient suivant les modèles, ils seront donc spécifiés dans chacune des parties.

3.4 Résultats

A la fin de chaque simulation, nous obtenons un indice pour chacune des 200 acquisitions pour chaque texture soit 5000 résultats. Pour des fins de clareté de présentation, nous avons choisi de présenter les résultats pour chaque valeur de l'échelle et selon son type : information d'apprentissage ou de test. Les trois textures imprédictibles seront analysées et discutées par la suite. Le tableau 3.3 présente l'ensemble des résultats pour les trois expériences.

		RNA unique	RNA 3	SVM 10
apprentissage	moyenne	0.53	0.34	0.43
	écart-type	0.52	0.56	0.35
	minimum	0.00	0.00	0.00
	maximum	3.15	3.45	2.25
test	moyenne	1.83	1.65	1.61
	écart-type	1.49	1.25	1.06
	minimum	0.02	0.10	0.45
	maximum	6.18	5.50	5.05

Tableau 3.3 Résultats synthétiques des 4 architectures

Les éléments particulièrement importants sont les données du set de test car elles estiment la capacité de l'algorithme à généraliser. On peut voir que le RNA unique a l'écart-type le plus élevé avec une moyenne aussi importante. Il fait donc partie des moins pertinents avec le RNA10. Les deux algorithmes qui nous intéresseront le plus sont le RNA3 et le SVM10.

Dans les parties suivantes, nous détaillons les résultats de chacun des algorithmes et proposons différentes méthodes pour les améliorer.

3.4.1 RNA unique

La simulation dure un peu moins de trois heures. Les résultats sont illustrés par la figure 3.4. Il est intéressant de noter que l'apprentissage est homogène avec une erreur globalement inférieure à 1. Néanmoins, la globalisation est beaucoup moins précise. 4 textures ont en moyenne plus de deux indices d'erreurs. En moyenne, l'erreur est de 1.83 avec un écart type important de 1.49. L'indice 1 a une erreur particulièrement importante. Son cas sera étudié dans la discussion suivant les résultats. Les maximums sont aussi très élevés.




Figure 3.4 Erreur de l'algorithme RNA unique en fonction du set d'apprentissage et de test

3.4.2 RNA3

Ce réseau est le second plus intéressant après le SVM10, même si les résultats dans l'écart type sont en moyenne entre 0.4 et 2.9 indices de rugosité. Ses résultats sont présentés dans la figure 3.5. Il est intéressant de noter que l'algorithme fonctionne à l'inverse de la main humaine : les

extrémités ont du mal à être détectées à la bonne échelle alors que les valeurs centrales sont plus proches du résultat.

Pour optimiser ce réseau de neurone, nous avons envisagé de mettre les valeurs des réseaux non concernés à 0 (au lieu du minimum de la tranche) afin d'essayer de mieux isoler les valeurs non concernées par le réseaux de neurones. Cela fonctionne très mal car on perd beaucoup en précision dans la tranche de mesure.




Figure 3.5 Erreur de l'algorithme RNA3 en fonction du set d'apprentissage et de test

3.4.3 SVM10

Cet algorithme repose sur 10 SVM spécialisés individuellement dans un indice de l'échelle de rugosité. La réponse attendue est un seul SVM retournant 1 et tous les autres 0. Si plusieurs renvoient une réponse à 1, le résultat choisi est le moyenne de ceux-ci. De même, si tous les SVM renvoient 0, l'acquisition est rejetée.

Les résultats sont présentés dans la figure 3.6. L'algorithme a les meilleurs résultats actuels mais il a aussi une lacune importante : un taux de rejet de 20.4%. Ce taux est dû aux nombreuses acquisitions pour lesquels les dix SVM trouvent 0.

Afin d'améliorer cet algorithme, nous envisageons une solution : chaque SVM retourne un résultat entre 0 et 1. Actuellement, les valeurs supérieures à 0.5 sont seuillées à 1 et les autres à 0. En retravaillant cette fonction, il est possible d'améliorer le résultat. Trois solutions sont en-




Figure 3.6 Erreur de l'algorithme SVM10 en fonction du set d'apprentissage et de test

visageables : prendre la valeur la plus élevée des 10 SVM, calculer une moyenne coefficientée avec les valeurs de sortie ou combiner ensemble les trois fonctions.

Actuellement, ces études ne permettent pas d'améliorer l'algorithme car il manque de données d'apprentissage et de tests. En effet, chaque SVM apprend sur une seule texture et une seconde sert de test. Cela crée un surapprentissage : au lieu d'apprendre un niveau de l'échelle de rugosité, le SVM apprend une texture spécifique. Le résultat donne des erreurs similaires mais distribuées différemment. Néanmoins, l'idée est à garder pour une étude future avec plus de textures.

3.5 Discussion

Les résultats sont loin d'être performants en globalisation avec une erreur variant souvent entre 1 et 3 textures. Nous avons identifié au cours de l'expériences plusieurs sources menant à cette erreur.

Premièrement, nous constatons un manque de textures : les apprentissages sont effectués uniquement avec une texture par niveau. Autant dans le cas du RNA unique et du RNA3, les niveaux influencent les résultats de leur voisins, autant dans le cas du SVM10, chaque SVM représente l'apprentissage d'une seule texture. Il serait donc intéressant d'élargir le problème à environ 50 textures afin d'avoir trois textures d'apprentissage par indice et 2 de tests. Il est important de noter que pour réaliser une expérience avec des individus et 50 textures, le mode de fonctionnement de l'expérience devra évoluer et être plus structuré afin que les participants ne

se perdent pas dans les nombreuses textures. Par exemple, il est possible de leur demander de diviser les objets en trois groupes puis de rediviser chaque groupe en trois autres sous-groupes. Nous obtenons ainsi une échelle de 1 à 9.

Nous notons aussi l'erreur particulièrement élevée de la texture de test de l'indice 1. Cette texture est le plastique lisse collant. Durant l'acquisition avec le capteur de cette texture, un problème important de friction s'est posé. Cela a eu tendance à faire accrocher le capteur sur la surface et donc créer un bruit parasite important. Nous pouvons à nouveau noter l'importance de retravailler le matériau et la forme de la surface du capteur afin d'optimiser le contact avec l'environnement. La peau humaine est un bel idéal car elle est suffisamment collante pour agripper les objets et en même temps, elle peut explorer son environnement avec précision.

Le troisième point est un peu plus philosophique. Est-ce que l'échelle sur 10 est trop large ? Nous avons observé dans l'expérience que l'être humain triait assez facilement les matériaux entre trois catégories : les matériaux non rugueux, moyennement rugueux et très rugueux. On pourrait donc imaginer une échelle sur 5 en rajoutant des entre-deux à ces trois catégories qui serait peut-être plus pertinent. Afin de déterminer cela, il semble important de voir les applications et d'approfondir cette expérience pour estimer la précision atteignable.

CONCLUSION

Dans notre étude, nous avons proposé un premier aperçu sur l'exploration de l'environnement d'un robot dans un but de trouver des informations permettant une meilleure manipulation par la suite. Nous sommes pour cela repartis de la détection de texture qui a été explorée dans diverses études et avons apporté des compléments en cherchant des invariances à la rotation, la vitesse et la force d'acquisition. Nous avons aussi montré la pertinence d'utiliser des algorithmes génétiques pour trouver les meilleurs paramètres possibles. Nous avons pour chaque expérience atteint des niveaux au-dessus de 90%. Nous avons aussi montré qu'à vitesse constante et force constante, il peut être facile de différencier des textures très proches les unes des autres.

Dans la seconde partie, nous nous sommes intéressés à l'estimation de la rugosité sur une échelle de 1 à 10. L'intérêt majeur est d'obtenir à la fin une grandeur caractéristique de la texture et non juste un nom qui seul, est inutile. Le défi de ce problème a été d'obtenir un algorithme généralisé, c'est-à-dire qui ne nécessite pas d'apprendre une nouvelle texture pour obtenir son résultat. L'étude que nous avons faite avec l'être humain a montré que celui-ci ne classe pas les textures de manière très précise et que certains touches sont difficiles à comparer. Les résultats de nos simulations restent loin des résultats recherchés, surtout en globalisation. Néanmoins, il semble possible de refaire une étude amenant de meilleurs résultats.

Pour des travaux futurs, je propose trois recommandations. Premièrement, il faudrait travailler la texture du capteur tactile afin de trouver un bon compromis pour garder à la fois une bonne capacité à manipuler des objets et en même temps une grande capacité d'exploration de l'environnement. Pour cela, il faut garder une grande sensibilité dans le doigt et en même temps que le matériau ne dérape pas sur des textures collantes.

Ma seconde recommandation serait de refaire une étude plus large sur la quantification de la rugosité en utilisant 50 textures. Pour la calibration de l'échelle, je propose une expérience en deux temps : dans un premier temps, il faudrait demander aux personnes de classer les textures en 3 catégories (très peu rugueuses, moyennement rugueuses et très rugueuses). Ensuite, dans ces trois catégories, il faudrait demander de séparer à nouveau cela en 2 ou 3 sous-catégories pour

obtenir une échelle sur 6 ou sur 9. Cela permettrait par la suite d'avoir au minimum trois textures d'apprentissage par indice de l'échelle et 2 de test. Cela devrait permettre une meilleure globalisation et de pouvoir mieux travailler les améliorations de l'algorithme final.

Enfin, suite à cette étude, ma recommandation serait de continuer ce type d'étude avec différentes autres données : fragilité de l'objet, collant ou glissant, déformabilité... Si avec quelques acquisitions le robot est capable de bien connaître l'objet à manipuler, il pourra améliorer sa dextérité.

Pour terminer ce mémoire, je veux conclure sur ce que ce travail de recherche m'a apporté. Tout d'abord, j'ai beaucoup appris sur la robotique et les capteurs tactiles et je me suis ouvert au domaine passionnant qu'est l'interaction homme-machine. J'ai aussi dû développer différentes compétences : l'autonomie, l'auto-motivation et la rigueur de recherche. Je crois que ces acquis me seront très utiles pour mes futurs travaux de recherche mais aussi dans ma vie en général. Enfin, ce projet m'a apporté un intérêt prononcé pour la recherche et beaucoup de plaisir. Je remercie encore une fois beaucoup Vincent Duchaine pour l'excellent maître de mémoire qu'il a été ainsi que toutes les personnes avec qui j'ai travaillé ou qui m'ont soutenu durant ce projet.

BIBLIOGRAPHIE

- Atkins, Diane J, Denise CY Heard, et William H Donovan. 1996. « Epidemiologic overview of individuals with upper-limb loss and their reported research priorities ». *JPO : Journal of Prosthetics and Orthotics*, vol. 8, n° 1, p. 2-11.
- Axaykumar, Rana et Duchaine Vincent. 2013. « Improved Soft Dielectric for Highly Sensitive Capacitive Tactile Sensor ». In *ICRA*.
- Bauer, Christian, Giulio Milighetti, Wenjie Yan, et Ralf Mikut. 2010. « Human-like reflexes for robotic manipulation using leaky integrate-and-fire neurons ». In *Intelligent Robots and Systems (IROS), 2010 IEEE/RSJ International Conference on*. p. 2572-2577. IEEE.
- Blake, David T, Steven S Hsiao, et Kenneth O Johnson. 1997. « Neural coding mechanisms in tactile pattern recognition : the relative contributions of slowly and rapidly adapting mechanoreceptors to perceived roughness ». *The Journal of neuroscience*, vol. 17, n° 19, p. 7480-7489.
- Carrozza, Maria Chiara, Fabrizio Vecchi, Fabrizio Sebastiani, Giovanni Cappiello, Stefano Roccella, Massimiliano Zecca, Roberto Lazzarini, et Paolo Dario. 2003. « Experimental analysis of an innovative prosthetic hand with proprioceptive sensors ». In *Robotics and Automation, 2003. Proceedings. ICRA'03. IEEE International Conference on*. p. 2230-2235. IEEE.
- Cascio, Carissa J et K Sathian. 2001. « Temporal cues contribute to tactile perception of roughness ». *The Journal of Neuroscience*, vol. 21, n° 14, p. 5289-5296.
- Chathuranga, Damith Suresh, Van Anh Ho, et Shinichi Hirai. 2013. « Investigation of a bio-mimetic fingertip's ability to discriminate fabrics based on surface textures ». In *Advanced Intelligent Mechatronics (AIM), 2013 IEEE/ASME International Conference on*. p. 1667-1674. IEEE.
- Dahiya, Ravinder S, Giorgio Metta, Maurizio Valle, et Giulio Sandini. 2010. « Tactile sensing—from humans to humanoids ». *Robotics, IEEE Transactions on*, vol. 26, n° 1, p. 1-20.
- Dargahi, J. 2000. « A piezoelectric tactile sensor with three sensing elements for robotic, endoscopic and prosthetic applications ». *Sensors and Actuators A : Physical*, vol. 80, n° 1, p. 23-30.
- De Boissieu, Florian, Christelle Godin, Bernard Guilhamat, Dominique David, Christine Serviere, et Daniel Baudois. 2009. « Tactile texture recognition with a 3-axial force MEMS integrated artificial finger ». In *Robotics : Science and Systems*.
- De Vignemont, Frédérique, Henrik H Ehrsson, et Patrick Haggard. 2005. « Bodily illusions modulate tactile perception ». *Current Biology*, vol. 15, n° 14, p. 1286-1290.

- Drimus, Alin, Gert Kootstra, Arne Bilberg, et Danica Kragic. 2012. « Design of a flexible tactile sensor for classification of rigid and deformable objects ». *Robotics and Autonomous Systems*.
- Edwards, J, J Lawry, J Rossiter, et C Melhuish. 2008. « Extracting textural features from tactile sensors ». *Bioinspiration & Biomimetics*, vol. 3, n° 3, p. 035002.
- Fishel, Jeremy A et Gerald E Loeb. 2012. « Bayesian exploration for intelligent identification of textures ». *Frontiers in Neurorobotics*, vol. 6.
- Gadelmawla, ES, MM Koura, TMA Maksoud, IM Elewa, et HH Soliman. 2002. « Roughness parameters ». *Journal of Materials Processing Technology*, vol. 123, n° 1, p. 133-145.
- Glover, Scott. 2002. « Visual illusions affect planning but not control ». *Trends in cognitive sciences*, vol. 6, n° 7, p. 288-292.
- Howe, Robert D et Mark R Cutkosky. 1989. « Sensing skin acceleration for slip and texture perception ». In *Robotics and Automation, 1989. Proceedings., 1989 IEEE International Conference on*. p. 145-150. IEEE.
- Howe, Robert D et Mark R Cutkosky. 1993. « Dynamic tactile sensing : Perception of fine surface features with stress rate sensing ». *Robotics and Automation, IEEE Transactions on*, vol. 9, n° 2, p. 140-151.
- Jain, Amit et Glenn Healey. 1998. « A multiscale representation including opponent color features for texture recognition ». *Image Processing, IEEE Transactions on*, vol. 7, n° 1, p. 124-128.
- Jamali, Nawid et Claude Sammut. 2010. « Material classification by tactile sensing using surface textures ». In *Robotics and Automation (ICRA), 2010 IEEE International Conference on*. p. 2336-2341. IEEE.
- Jamali, Nawid et Claude Sammut. 2011. « Majority voting : material classification by tactile sensing using surface texture ». *Robotics, IEEE Transactions on*, vol. 27, n° 3, p. 508-521.
- Johansson, Roland S et J Randall Flanagan. 2009. « Coding and use of tactile signals from the fingertips in object manipulation tasks ». *Nature Reviews Neuroscience*, vol. 10, n° 5, p. 345-359.
- Johansson, Roland S et Å B Vallbo. 1979. « Tactile sensibility in the human hand : relative and absolute densities of four types of mechanoreceptive units in glabrous skin ». *The Journal of physiology*, vol. 286, n° 1, p. 283-300.
- Johnson, Kenneth O. 2001. « The roles and functions of cutaneous mechanoreceptors ». *Current opinion in neurobiology*, vol. 11, n° 4, p. 455-461.

- Khotanzad, Alireza et Rangasami L Kashyap. 1987. « Feature selection for texture recognition based on image synthesis ». *Systems, Man and Cybernetics, IEEE Transactions on*, vol. 17, n° 6, p. 1087-1095.
- Kim, Sung-Hoon, Jonathan Engel, Chang Liu, et Douglas L Jones. 2005. « Texture classification using a polymer-based MEMS tactile sensor ». *Journal of micromechanics and Microengineering*, vol. 15, n° 5, p. 912.
- Lantada, Andrés Díaz, Pilar Lafont, José Luis Muñoz Sanz, Juan Manuel Munoz-Guijosa, et Javier Echavarri Otero. 2010. « Quantum tunnelling composites : Characterisation and modelling to promote their applications as sensors ». *Sensors and Actuators A : Physical*, vol. 164, n° 1, p. 46-57.
- Lee, Hyung-Kew, Sun-Il Chang, et Euisik Yoon. 2006. « A flexible polymer tactile sensor : fabrication and modular expandability for large area deployment ». *Microelectromechanical Systems, Journal of*, vol. 15, n° 6, p. 1681-1686.
- Mayol-Cuevas, WW, J Juarez-Guerrero, et S Munoz-Gutierrez. 1998. « A first approach to tactile texture recognition ». In *Systems, Man, and Cybernetics, 1998. 1998 IEEE International Conference on*. p. 4246-4250. IEEE.
- Mazid, Abdul Md et ABMS Ali. 2008. « Opto-tactile sensor for surface texture pattern identification using support vector machine ». In *Control, Automation, Robotics and Vision, 2008. ICARCV 2008. 10th International Conference on*. p. 1830-1835. IEEE.
- Meftah, El Mehdi, Loïc Belingard, et C Elaine Chapman. 2000. « Relative effects of the spatial and temporal characteristics of scanned surfaces on human perception of tactile roughness using passive touch ». *Experimental Brain Research*, vol. 132, n° 3, p. 351-361.
- Myers, NO. 1962. « Characterization of surface roughness ». *Wear*, vol. 5, n° 3, p. 182-189.
- Nelson, Robert et Lincoln Davidson. 2002. « Electrical noise generated from the microphonic effect in capacitors ». In *Electromagnetic Compatibility, 2002. EMC 2002. IEEE International Symposium on*. p. 855-860. IEEE.
- Ohmura, Yoshiyuki, Yasuo Kuniyoshi, et Akihiko Nagakubo. 2006. « Conformable and scalable tactile sensor skin for curved surfaces ». In *Robotics and Automation, 2006. ICRA 2006. Proceedings 2006 IEEE International Conference on*. p. 1348-1353. IEEE.
- Omata, Sadao, Yoshinobu Murayama, et Christos E Constantinou. 2004. « Real time robotic tactile sensor system for the determination of the physical properties of biomaterials ». *Sensors and Actuators A : Physical*, vol. 112, n° 2, p. 278-285.
- Paschos, George. 2000. « Fast color texture recognition using chromaticity moments ». *Pattern Recognition Letters*, vol. 21, n° 9, p. 837-841.

- Picard, Rosalind Wright, Tanweer Kabir, et Fang Liu. 1993. « Real-time recognition with the entire Brodatz texture database ». In *Computer Vision and Pattern Recognition, 1993. Proceedings CVPR'93., 1993 IEEE Computer Society Conference on*. p. 638-639. IEEE.
- Robles-De-La-Torre, Gabriel. 2006. « The importance of the sense of touch in virtual and real environments ». *Ieee Multimedia*, vol. 13, n° 3, p. 24-30.
- Sato, M. 1961. « Response of Pacinian corpuscles to sinusoidal vibration ». *The Journal of physiology*, vol. 159, n° 3, p. 391-409.
- Savelsbergh, GJP, B Steenbergen, et J Van der Kamp. 1996. « The role of fragility information in the guidance of the precision grip ». *Human Movement Science*, vol. 15, n° 1, p. 115-127.
- Schneider, F, T Fellner, J Wilde, et U Wallrabe. 2008. « Mechanical properties of silicones for MEMS ». *Journal of Micromechanics and Microengineering*, vol. 18, n° 6, p. 065008.
- Shi, Miaohong et Glenn Healey. 2003. « Hyperspectral texture recognition using a multiscale opponent representation ». *Geoscience and Remote Sensing, IEEE Transactions on*, vol. 41, n° 5, p. 1090-1095.
- Siciliano, Bruno et Oussama Khatib, 2008. *Springer handbook of robotics*. Springer.
- Smith, Allan M, C Elaine Chapman, Mélanie Deslandes, Jean-Sébastien Langlais, et Marie-Pierre Thibodeau. 2002. « Role of friction and tangential force variation in the subjective scaling of tactile roughness ». *Experimental Brain Research*, vol. 144, n° 2, p. 211-223.
- Stiehl, Walter Dan et C Breaeal. 2006. « A sensitive skin for robotic companions featuring temperature, force, and electric field sensors ». In *Intelligent Robots and Systems, 2006 IEEE/RSJ International Conference on*. p. 1952-1959. IEEE.
- Sukhoy, Vladimir, Ritika Sahai, Jivko Sinapov, et Alexander Stoytchev. 1989. « Vibrotactile recognition of surface textures by a humanoid robot ». In *IEEE International Conference on Robotics and Automation*. p. 145-150.
- Takamuku, Shinya, Gabriel Gomez, Koh Hosoda, et Rolf Pfeifer. 2007. « Haptic discrimination of material properties by a robotic hand ». In *Development and Learning, 2007. ICDL 2007. IEEE 6th International Conference on*. p. 1-6. IEEE.
- Takenawa, Satoru. 2009. « A magnetic type tactile sensor using a two-dimensional array of inductors ». In *Robotics and Automation, 2009. ICRA'09. IEEE International Conference on*. p. 3295-3300. IEEE.
- Thomas, TR. 1981. « Characterization of surface roughness ». *Precision Engineering*, vol. 3, n° 2, p. 97-104.
- Vallbo, Å B et RS Johansson. 1984. « Properties of cutaneous mechanoreceptors in the human hand related to touch sensation ». *Hum Neurobiol*, vol. 3, n° 1, p. 3-14.

- Vallbo, ÅB et K-E Hagbarth. 1968. « Activity from skin mechanoreceptors recorded percutaneously in awake human subjects ». *Experimental neurology*, vol. 21, n° 3, p. 270-289.
- Wisitsoraat, APVTAPN, V Patanasetagul, A Tuantranont, et N Poonnikorn. 2006. « Design and fabrication of non-silicon-based piezoresistive MEMS tactile sensor ». In *Sensors, 2006. 5th IEEE Conference on*. p. 1317-1320. IEEE.
- Xiaojing, Song, Liu Hongbin, Bimbo Joao, K. Althoefer, et Lakmal D. Seneviratne. 2012. « Object surface classification based on friction properties for intelligent robotic hands ». In *World Automation Congress (WAC), 2012*. p. 1-5.
- Yao, Hsin-Yun et Vincent Hayward. 2010. « Design and analysis of a recoil-type vibrotactile transducer ». *The Journal of the Acoustical Society of America*, vol. 128, n° 2, p. 619-627.