

Détection de défauts de surface sur le bois par capteur tactile capacitif

par

Jean-Simon LAVERTU

MÉMOIRE PRÉSENTÉ À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
COMME EXIGENCE PARTIELLE À L'OBTENTION DE LA MAÎTRISE
AVEC MÉMOIRE EN GÉNIE DE LA PRODUCTION AUTOMATISÉE
M. Sc. A.

MONTRÉAL, LE 5 JANVIER 2023

ÉCOLE DE TECHNOLOGIE SUPÉRIEURE
UNIVERSITÉ DU QUÉBEC



Jean-Simon Lavertu, 2023



Cette licence Creative Commons signifie qu'il est permis de diffuser, d'imprimer ou de sauvegarder sur un autre support une partie ou la totalité de cette oeuvre à condition de mentionner l'auteur, que ces utilisations soient faites à des fins non commerciales et que le contenu de l'oeuvre n'ait pas été modifié.

PRÉSENTATION DU JURY

CE MÉMOIRE A ÉTÉ ÉVALUÉ

PAR UN JURY COMPOSÉ DE:

M. Vincent Duchaine, directeur de mémoire
Département de génie des systèmes, École de technologie supérieure

M. Christian Desrosiers, président du jury
Département de génie logiciel et des TI, École de technologie supérieure

M. Jean-Philippe Roberge, membre du jury
Département de génie des systèmes, École de technologie supérieure

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

LE 19 DÉCEMBRE 2022

À L'ÉCOLE DE TECHNOLOGIE SUPÉRIEURE

REMERCIEMENTS

L'achèvement de ce mémoire de maîtrise représente pour moi la réalisation d'un objectif de longue date, mais aussi d'une étape majeure de ma vie. En cours de route, j'ai rencontré des gens extraordinaires et je suis reconnaissant pour tout ce qu'ils ont fait pour moi.

J'aimerais commencer par remercier Vincent Duchaine pour l'aide et le soutien qu'il m'a apporté tout au long de mon parcours. Merci de m'avoir offert l'occasion de faire de la recherche lors de mon baccalauréat, de m'avoir soutenu durant mon passage au Centech et de m'avoir accompagné dans la réalisation de ce projet.

Merci à tous les collègues que j'ai eu le plaisir de côtoyer lors de mes études : Alexandre, Chandra, Étienne, Guillaume, Jean-Christophe, Jean-Philippe, Jennifer, Sébastien, ainsi que tous les autres membres du CoRo. Votre présence et votre amitié ont fait du laboratoire un endroit où il fait bon travailler.

Merci à ma compagne et meilleure amie, Marie-Ève, ainsi qu'à toute ma famille (Carl, Bob, Maxime, Julien et tous les autres qui sauront se reconnaître) d'avoir toujours cru en moi et de m'avoir soutenu, même lorsque la tâche me paraissait insurmontable.

Merci à Emile, Francis, Louis-Maxime, Mathieu, Maxime et Samuel. Votre amitié fidèle m'apporte un grand bonheur depuis plus d'une décennie déjà.

Merci à mes co-fondateurs chez Denovogen : Alex, Andrei et Khizer. Fonder une compagnie à vos côtés a été un grand honneur.

Merci à Noixsette, Douceur, Apollo et Nyx. Leurs ronronnements incessants et leurs manigances n'ont jamais manqué de me faire sourire.

Finalement, je tiens à remercier particulièrement Carole, ma mère. Sans son soutien inconditionnel et ses encouragements constants, je ne serais pas où je suis aujourd'hui.

Détection de défauts de surface sur le bois par capteur tactile capacitif

Jean-Simon LAVERTU

RÉSUMÉ

La montée en popularité des robots collaboratifs crée, pour plusieurs petites et moyennes entreprises, de nouvelles possibilités d'automatisation qui n'étaient pas auparavant viables. C'est notamment le cas pour l'inspection de tâches de sablage et de polissage de produits en bois. Or, afin de pouvoir réaliser cette inspection, le robot doit être équipé de capteurs permettant de percevoir les détails de leur surface. Dans ce mémoire, nous avons exploré la possibilité d'utiliser un capteur tactile capacitif pour détecter la présence de défauts de surface sur le bois.

Dans un premier temps, nous avons utilisé les quatre modalités du capteur tactile CoRo pour entraîner une variété de réseaux de neurones artificiels à détecter la présence de trois types de défauts de surface, soit les rayures, les indentations et les arrachements. Aucune des modalités n'a permis de détecter la présence de rayures étant donné leurs très petites dimensions. Cela dit, la modalité statique, qui mesure le motif de pression sur la surface du capteur, a obtenu les meilleurs résultats pour les indentations et les arrachements.

Nous avons ensuite testé si la fusion des modalités permet de mieux détecter la présence de défauts. Contrairement à ce que nous avons anticipé, les résultats obtenus montrent que la fusion ne permet pas nécessairement d'obtenir une meilleure performance que l'utilisation de modalités individuelles. Néanmoins, nous avons confirmé que la modalité statique, utilisée seule ou en combinaison avec la modalité dynamique, est la plus intéressante.

En somme, nous avons démontré que le capteur tactile capacitif CoRo représente une solution prometteuse pour la détection de défauts de surface dans le bois. Toutefois, sa conception devrait être repensée en fonction de cette tâche pour atteindre le maximum de performance.

Mots-clés: Capteurs tactiles, Inspection de surface, Détection de défaut, Apprentissage profond

Wood Surface Defect Detection Using a Capacitive Tactile Sensor

Jean-Simon LAVERTU

ABSTRACT

The rise in popularity of collaborative robots is creating new automation opportunities that were not previously viable for many small and medium-sized businesses. This is the case for the inspection of sanding and polishing tasks on wood products. In order to perform this inspection, a robot must be equipped with sensors that allow it to feel the surface for defects. In this thesis, we explored the possibility of using a capacitive tactile sensor to detect the presence of surface defects on wood.

Initially, we used the four modalities of the CoRo tactile sensor to train a variety of artificial neural networks to detect the presence of three types of surface defects : scratches, indentations, and tearouts. None of the modalities were able to detect the presence of scratches given their very small dimensions. That being said, the static modality, which measures the pressure pattern on the sensor's surface, performed best for indentations and tearouts.

We then tested whether the fusion of modalities improves the detection of defects. Contrary to what we had anticipated, the results show that modality fusion does not necessarily lead to better performance than using the individual modalities. Nevertheless, we confirmed that the static modality, used alone or in combination with the dynamic modality, is the most useful.

In sum, we have demonstrated that the CoRo capacitive tactile sensor represents a promising solution for the detection of surface defects in wood. However, it should be redesigned with this task in mind to achieve maximum performance.

Keywords: Tactile sensors, Surface inspection, Defect detection, Deep learning

TABLE DES MATIÈRES

	Page
INTRODUCTION	1
CHAPITRE 1 REVUE DE LITTÉRATURE	5
1.1 Qu'est-ce qu'une texture de surface ?	5
1.2 Défauts de surface dans le bois	6
1.2.1 Qu'est-ce qu'un défaut de surface ?	6
1.2.2 Types de défauts de surface	7
1.2.3 Axes de recherche sur les défauts de surface	9
1.3 Méthodes de détection de défauts de surface	10
1.3.1 Sens du toucher humain	10
1.3.2 Méthodes non applicables	13
1.3.3 Méthodes basées sur la vision artificielle	13
1.3.4 Méthodes par capteurs tactiles	15
CHAPITRE 2 MONTAGE EXPÉRIMENTAL	23
2.1 Plaques échantillons	23
2.1.1 Choix de l'essence de bois	23
2.1.2 Choix des défauts	24
2.1.3 Préparation des plaques échantillons	26
2.2 Système d'acquisition de données	29
2.2.1 Composantes physiques	30
2.2.2 Composantes logicielles	31
2.2.3 Capteur tactile capacitif CoRo	33
2.3 Création de l'ensemble de données	36
2.3.1 Processus d'acquisition	36
2.3.2 Préparation des données	38
CHAPITRE 3 PREUVE DE CONCEPT	43
3.1 Méthodologie	43
3.2 Résultats	43
3.3 Discussion	47
CHAPITRE 4 EXPLORATION DES MODALITÉS	49
4.1 Méthodologie générale	49
4.1.1 Seuil de classification	49
4.1.2 Métriques	51
4.1.3 Traitement des données	53
4.1.4 Méthodologie d'entraînement et de test	55
4.2 Modalité statique	55
4.2.1 Architectures de réseaux considérées	56

4.2.2	Résultats	63
4.2.2.1	Distribution des erreurs pour chaque type de défaut	65
4.2.3	Discussion	71
4.3	Accéléromètre	72
4.3.1	Architectures de réseaux considérées	72
4.3.2	Résultats	80
4.3.2.1	Distribution des erreurs pour chaque type de défaut	83
4.3.3	Discussion	86
4.4	Gyroscope	87
4.4.1	Architectures de réseaux considérées	87
4.4.2	Résultats	88
4.4.2.1	Distribution des erreurs pour chaque type de défaut	89
4.4.3	Discussion	93
4.5	Modalité dynamique	93
4.5.1	Architectures de réseaux considérées	93
4.5.2	Résultats	94
4.5.2.1	Distribution des erreurs pour chaque type de défaut	97
4.5.3	Discussion	100
4.6	Résultats généraux	101
4.7	Discussion	103
CHAPITRE 5 FUSION DES MODALITÉS		105
5.1	Méthodologie générale	105
5.1.1	Méthodes de fusion de modalités	105
5.2	Combinaisons de modalités considérées	107
5.3	Résultats	110
5.3.1	Comparaison avec les modalités individuelles	113
5.4	Discussion	114
CONCLUSION ET RECOMMANDATIONS		117
BIBLIOGRAPHIE		120

LISTE DES TABLEAUX

	Page
Tableau 1.1 Méchanorécepteurs et leurs caractéristiques	11
Tableau 2.1 Plaques échantillons	28
Tableau 3.1 Performance du capteur avec normalisation	46
Tableau 4.1 Performance de la modalité statique sur l'ensemble de validation	63
Tableau 4.2 Performance de la modalité statique sur l'ensemble de test	63
Tableau 4.3 Performance de la modalité statique sur l'ensemble de validation (sans rayures)	67
Tableau 4.4 Performance de la modalité statique sur l'ensemble de test (sans rayures)	68
Tableau 4.5 Changements de performance de la modalité statique lorsque les rayures sont éliminées	68
Tableau 4.6 Performance de l'accéléromètre sur l'ensemble de validation	81
Tableau 4.7 Performance de l'accéléromètre sur l'ensemble de test	81
Tableau 4.8 Performance de l'accéléromètre sur l'ensemble de validation (sans rayures)	83
Tableau 4.9 Performance de l'accéléromètre sur l'ensemble de test (sans rayures)	84
Tableau 4.10 Changements de performance de l'accéléromètre lorsque les rayures sont éliminées	84
Tableau 4.11 Performance du gyroscope sur l'ensemble de validation	88
Tableau 4.12 Performance du gyroscope sur l'ensemble de test	88
Tableau 4.13 Performance du gyroscope sur l'ensemble de validation (sans rayures)	90
Tableau 4.14 Performance du gyroscope sur l'ensemble de test (sans rayures)	90

Tableau 4.15	Changements de performance du gyroscope lorsque les rayures sont éliminées	91
Tableau 4.16	Performance de la modalité dynamique sur l'ensemble de validation	95
Tableau 4.17	Performance de la modalité dynamique sur l'ensemble de test	95
Tableau 4.18	Performance de la modalité dynamique sur l'ensemble de validation (sans rayures)	97
Tableau 4.19	Performance de la modalité dynamique sur l'ensemble de test (sans rayures)	97
Tableau 4.20	Changements de performance de la modalité dynamique lorsque les rayures sont éliminées	98
Tableau 4.21	Meilleure performance de chaque modalité sur l'ensemble de validation (sans rayures)	102
Tableau 4.22	Meilleure performance de chaque modalité sur l'ensemble de test (sans rayures)	102
Tableau 5.1	Performance de chaque combinaison sur l'ensemble de validation (sans rayures)	110
Tableau 5.2	Performance de chaque combinaison sur l'ensemble de test (sans rayures)	110
Tableau 5.3	Performance de chaque modalité individuelle et combinaisons de modalités sur l'ensemble de test (sans rayures)	113

LISTE DES FIGURES

	Page
Figure 1.1 Exemples de défauts de surface sur le bois	8
Figure 2.1 Échantillon d'érable blanc	24
Figure 2.2 Types de défauts considérés	25
Figure 2.3 Étapes de préparation d'une plaque échantillon	28
Figure 2.4 Système d'acquisition de données	29
Figure 2.5 Organigramme du système d'acquisition de données	30
Figure 2.6 Chariot indexable en rotation	31
Figure 2.7 Diagramme de flux de l'automate fini	32
Figure 2.8 Diagramme de flux de la boucle d'acquisition	33
Figure 2.9 Capteur tactile capacitif CoRo	34
Figure 2.10 Diélectrique microstructuré	35
Figure 2.11 Diagramme de flux de la boucle de calibration	37
Figure 2.12 Diagramme de flux de l'acquisition et du traitement des données	39
Figure 2.13 Diagrammes de flux des sous-procédés d'acquisition et de traitement des données	41
Figure 2.14 Structure de l'ensemble de données	42
Figure 3.1 Matrice de confusion de la classification sur l'ensemble de test	44
Figure 3.2 Valeurs mesurées par les taxels statiques au repos	45
Figure 3.3 Matrice de confusion de la classification sur l'ensemble de test (avec normalisation)	46
Figure 4.1 Résultats possibles d'un système de détection	50
Figure 4.2 Mesure à vide du capteur avec et sans calibration	54
Figure 4.3 Représentation spatiale des taxels statiques	57

Figure 4.4	Effet de γ sur la sparsité et l'erreur de représentation	61
Figure 4.5	Dictionnaire utilisé pour l'encodage sparse	62
Figure 4.6	Distribution des étiquettes prédites par le réseau <i>LSTM Simple</i> sur l'ensemble de test	65
Figure 4.7	Distribution des étiquettes prédites avec et sans rayures par le réseau <i>LSTM Simple</i> sur l'ensemble de test	70
Figure 4.8	Distribution des étiquettes prédites par le réseau <i>CNN Temporel</i> sur l'ensemble de test (sans rayures)	70
Figure 4.9	Exemple de transformation d'un signal du domaine temporel vers le domaine fréquentiel	73
Figure 4.10	Spectrogramme du signal de l'axe X de l'accéléromètre	75
Figure 4.11	Effet du traitement du spectrogramme	76
Figure 4.12	Compromis entre la résolution temporelle et fréquentielle pour la STFT	77
Figure 4.13	Ondelette de Morlet	79
Figure 4.14	Résolution temporelle et fréquentielle de la transformée en ondelettes continue	80
Figure 4.15	Scalogramme du signal de l'axe X de l'accéléromètre	80
Figure 4.16	Distribution des étiquettes prédites par les réseaux <i>LSTM Simple</i> et <i>CNN Temporel</i> sur l'ensemble de test pour l'accéléromètre	82
Figure 4.17	Distribution des étiquettes prédites par le réseau <i>CNN Spectrogramme</i> sur l'ensemble de test pour l'accéléromètre	82
Figure 4.18	Distribution des étiquettes prédites par les réseaux <i>LSTM Simple</i> et <i>CNN Temporel</i> sur l'ensemble de test pour l'accéléromètre (sans rayures)	85
Figure 4.19	Distribution des étiquettes prédites par le réseau <i>CNN Scalogramme</i> sur l'ensemble de test pour l'accéléromètre (sans rayures)	86
Figure 4.20	Distribution des étiquettes prédites par le réseau <i>CNN Scalogramme</i> sur l'ensemble de test pour le gyroscope	89

Figure 4.21	Distribution des étiquettes prédites par les réseaux <i>LSTM Simple</i> et <i>CNN Temporel</i> sur l'ensemble de test pour le gyroscope (sans rayures)	92
Figure 4.22	Distribution des étiquettes prédites par le réseau <i>CNN Scalogramme</i> sur l'ensemble de test pour le gyroscope (sans rayures)	92
Figure 4.23	Distribution des étiquettes prédites par les réseaux <i>LSTM Simple</i> et <i>CNN Temporel</i> sur l'ensemble de test pour la modalité dynamique	95
Figure 4.24	Distribution des étiquettes prédites par le réseau <i>CNN Scalogramme</i> sur l'ensemble de test pour la modalité dynamique	96
Figure 4.25	Distribution des étiquettes prédites par les réseaux <i>LSTM Simple</i> et <i>CNN Temporel</i> sur l'ensemble de test pour la modalité dynamique (sans rayures)	99
Figure 4.26	Distribution des étiquettes prédites par le réseau <i>CNN Spectrogramme</i> sur l'ensemble de test pour la modalité dynamique (sans rayures)	100
Figure 4.27	Distribution des étiquettes prédites par le réseau <i>CNN Scalogramme</i> sur l'ensemble de test pour la modalité dynamique (sans rayures)	100
Figure 4.28	Distribution des étiquettes prédites par le meilleur réseau pour chaque modalité sur l'ensemble de test (sans rayures)	103
Figure 5.1	Distribution des étiquettes prédites par chaque combinaison de modalités sur l'ensemble de test (sans rayures)	111
Figure 5.1	Distribution des étiquettes prédites par chaque combinaison de modalités sur l'ensemble de test (sans rayures)	112
Figure 5.2	Distributions des étiquettes prédites par la modalité statique et la combinaison des modalités statique et dynamique sur l'ensemble de test (sans rayures)	114

LISTE DES ABRÉVIATIONS, SIGLES ET ACRONYMES

3D	Trois Dimensions
API	Application Programming Interface
CCD	Charged Coupled Device
CMOS	Complementary Metal Oxyde Semiconductor
CNN	Convolutional Neural Network
CoRo	Laboratoire de Commande et de Robotique à l'ÉTS
CSV	Comma Separated Values
CWT	Continuous Wavelet Transform
EQM	Erreur Quadratique Moyenne
ÉTS	École de Technologie Supérieure
FFT	Fast Fourier Transform
HDF5	Hierarchical Data Format (Version 5)
HDMI	High-Definition Multimedia Interface
IMU	Inertial Measurement Unit
LSTM	Long Short-Term Memory
MEMS	Microelectromechanical systems
PCB	Printed Circuit Board
STFT	Short-Term Fourier Transform
SVM	Support-Vector Machine

LISTE DES SYMBOLES ET UNITÉS DE MESURE

μm	Micromètre
mm	Millimètre
m	Mètre
mm ²	Millimètre carré
s	Seconde
ms	Milliseconde
mm/s	Millimètre par seconde
cm/s	Centimètre par seconde
g	Gramme
N	Newton
Hz	Hertz
kHz	Kilohertz
dB	Décibel
px	Pixel
deg	Degré

INTRODUCTION

Depuis quelques années, un nouveau type de robotique, la robotique dite "collaborative", engendre un changement de paradigme considérable dans le domaine manufacturier. Ces robots collaboratifs (aussi connus sous le diminutif "cobots"), étant plus abordables, sécuritaires et faciles à utiliser qu'un robot conventionnel, permettent aux petites et moyennes entreprises d'automatiser certaines de leurs opérations. Cette possibilité ne leur était pas économiquement accessible auparavant.

Or, cette nouvelle vague de tâches à automatiser au sein d'une multitude d'entreprises dans virtuellement tous les secteurs de l'industrie requiert un type d'automatisation beaucoup plus polyvalent. En effet, les tâches à accomplir sont généralement uniques, changeantes et effectuées en plus petit volume. Dans ce contexte, l'implantation d'un robot collaboratif est intéressante, puisque contrairement à un robot traditionnel, il ne requiert pas d'équipement de sécurité fixe et qu'il est relativement facile et rapide à programmer.

Toutefois, un robot collaboratif seul n'est pas toujours suffisant. Il est souvent nécessaire d'ajouter des capacités de perception au robot pour qu'il puisse s'adapter à l'environnement changeant dans lequel il est utilisé et aux variations des tâches à accomplir. Autrement dit, certaines tâches ne peuvent simplement pas être réalisées en répétant une série de mouvements prédéfinis. Pour obtenir le résultat désiré, le robot doit pouvoir ajuster son programme aux conditions réelles. Par exemple, la prise d'objets devient beaucoup plus difficile si les objets n'ont pas tous la même forme où qu'ils ne sont pas tous au même endroit. Dans un tel cas, sans pouvoir percevoir l'objet, la prise réussirait uniquement s'il était déjà placé correctement.

Dans ce mémoire, nous examinerons plus spécifiquement un de ces types de tâches : la finition de pièces de bois par sablage. Lors d'une opération de sablage, puisque la forme de l'objet et les variations dans le matériau (p. ex. un nœud ou une rayure) influencent la performance de

l'outil ¹, une répétition exacte de la même série de mouvements sur deux pièces différentes ne donnera pas nécessairement le même résultat. Sans pouvoir prendre en compte les particularités du matériau et le progrès du sablage, le travail du robot doit être vérifié et les imperfections restantes corrigées manuellement, limitant ainsi la productivité pouvant être atteinte.

Certaines technologies, comme la vision artificielle, permettent déjà aux robots collaboratifs de percevoir leur environnement, mais elles ne sont pas encore bien adaptées au problème du sablage de pièces en bois. Sans contact direct, il est difficile d'évaluer la texture d'un objet ou d'une surface. Même s'il est possible de créer un système de vision artificielle qui reconnaît des textures dans certains contextes, comme l'usage de la vision permet de percevoir uniquement l'information visuelle, cette approche est vulnérable aux variations de l'environnement. En effet, un changement de luminosité ou de matériau peut avoir un impact majeur sur ce qui est perçu par la caméra, même si la texture à évaluer reste identique. À titre d'exemple, une pièce en métal et une pièce en plastique ayant la même texture de surface vont réfléchir la lumière de manière très différente. Même une couche de poussière laissée par une opération de sablage peut avoir un impact négatif sur la performance d'un système de vision, puisque les particules qui la composent cachent les détails qui permettent de définir la texture. Puisque ces limites ne découlent pas de l'avancement de la technologie, mais bien du principe de fonctionnement même de la vision artificielle, toute amélioration est faite en dépit de limitations fondamentales qui ne peuvent pas être éliminées.

Or, il est pourtant facile pour l'humain d'évaluer l'avancement de la finition puisque le sens du toucher permet de percevoir la texture de la surface et ses imperfections de manière intuitive. Même lorsqu'utilisé de manière inconsciente, le sens du toucher permet de percevoir les caractéristiques de notre environnement de manière très détaillée. Cette capacité de discerner et d'identifier la texture d'un objet en le manipulant est d'une importance fondamentale pour la

¹ Généralement une sableuse de type orbitale.

réalisation de tâches diverses. Le sens du toucher permet à l'humain non seulement de reconnaître la forme et le matériau d'un objet, mais aussi d'y déceler des imperfections ou irrégularités, sans même devoir le regarder. Par exemple, lors de travaux de réparation de carrosserie sur une voiture, plutôt que d'effectuer une inspection visuelle, il est souvent plus efficace de glisser sa main sur la surface pour trouver les défauts restants. En effet, certaines imperfections sont invisibles avant que la couche finale de peinture soit appliquée, alors qu'elles peuvent être identifiées immédiatement par le sens du toucher.

De la même manière, l'ajout du sens du toucher (ou retour tactile) au robot permet d'étendre ses capacités aux tâches qui requièrent de reconnaître des textures. En effet, puisque le mécanisme par lequel le toucher perçoit l'environnement est complètement différent, les limitations inhérentes à la vision peuvent être contournées. Par exemple, avec l'ajout de retour tactile, il importe peu si l'apparence d'une pièce change en fonction de l'éclairage, puisque l'information perçue par le toucher n'est pas affectée par la lumière. De la même manière que l'humain peut reconnaître un objet les yeux fermés en le touchant, un système basé sur le retour tactile fonctionnerait aussi bien dans un environnement bien éclairé que dans le noir complet.

C'est donc dans cette optique de biomimétisme du sens du toucher humain que ce mémoire traitera de l'applicabilité de capteurs tactiles capacitifs à des tâches de détection de défauts pour le sablage et la finition de pièces de bois. Au chapitre 1, nous effectuerons une revue de la littérature existante concernant les défauts de surface et les méthodes permettant de les détecter. Par la suite, le chapitre 2 présentera le montage expérimental ainsi que les procédures d'acquisition et de traitement de données. Dans le chapitre 3, nous confirmerons la possibilité de détecter la présence de défauts à l'aide d'un capteur tactile capacitif. Au chapitre 4, nous étudierons les forces et faiblesses de chaque modalité du capteur ainsi que la capacité de différentes architectures de réseaux et méthodes de traitement données à extraire de l'information. Nous poursuivrons cette étude au chapitre 5 en fusionnant les modalités et architectures prometteuses pour réaliser un

réseau plus performant. Finalement, nous présenterons nos conclusions et nous identifierons des pistes de recherche additionnelles.

CHAPITRE 1

REVUE DE LITTÉRATURE

1.1 Qu'est-ce qu'une texture de surface ?

La surface d'un objet est le résultat de la superposition de plusieurs profils à différentes échelles de mesure (American Society of Mechanical Engineers, 2019). Le profil réel de la surface est composé du profil désiré auquel s'ajoutent le profil d'erreur de forme, le profil d'ondulation et le profil de rugosité (Goli, 2003). Myshkin, Grigoriev, Chizhik, Choi & Petrokovets (2003) présentent deux niveaux additionnels soit cinq niveaux majeurs de topographie pouvant composer une surface, soit : les erreurs de forme, l'ondulation, la rugosité (ou rugosité technologique), la sous-rugosité (ou relief physique) et la rugosité moléculaire et atomique. Il est important de noter que malgré la standardisation de ces niveaux, il n'existe pas de démarcation stricte entre eux (Myshkin *et al.*, 2003).

La texture d'une surface peut donc être vue comme la somme des déviations par rapport au plan désiré. Autrement dit, une surface réelle est la combinaison du profil "idéalisé" et de sa texture.

Plusieurs paramètres existent pour caractériser la rugosité d'une surface en deux dimensions. R_a , R_z et R_t ¹ sont quelques exemples de paramètres couramment utilisés (Gurau & Irle, 2017; Myshkin *et al.*, 2003). Cela dit, une analyse en deux dimensions ne permet pas de caractériser une surface dans son entièreté puisqu'elle capture uniquement l'information sur une ligne et que les caractéristiques de la texture peuvent varier selon la section qui est mesurée. À cette fin, des paramètres pouvant décrire une texture en trois dimensions existent aussi, notamment l'ensemble de 14 paramètres introduit par Dong, Sullivan & Stout (1994).

Bien que ces facteurs s'appliquent indépendamment du matériau considéré, le bois présente des complexités supplémentaires. En effet, son apparence et sa texture dépendent de plusieurs

¹ R_a , R_z et R_t sont la déviation moyenne, la hauteur de profil maximale et la hauteur de profil totale respectivement.

facteurs incluant l'anatomie du grain, sa densité, son taux d'humidité et la direction des fibres (Sandak & Tanaka, 2003). De plus, les propriétés de la surface sont aussi affectées par les étapes de traitement qui lui sont appliquées (sciage, sablage, etc.). Par exemple, un morceau de bois ayant été scié avec une scie à ruban aura des marques verticales dans le sens de la coupe tandis qu'un morceau sablé sera plus uniforme (Sinn, Sandak & Ramananantoandro, 2009).

Contrairement aux matériaux uniformes comme le métal, la nature irrégulière du bois rend la quantification de ses caractéristiques particulièrement difficile. Même lorsqu'une surface de bois est sablée adéquatement, elle présentera quand même des variations anatomiques, car la structure du grain contient des espaces vides. Les valeurs des paramètres objectifs (R_a , R_z , etc.) qui décrivent une surface ne sont donc pas nécessairement représentatives de la qualité réelle du fini (Gurau, Mansfield-Williams & Irle, 2011). Tel que rapporté par Thoma, Peri & Lato (2015), il n'existe pas de standards permettant de mesurer objectivement la surface du bois puisque les variations inhérentes du matériau et l'impact des étapes de traitement rendent leur application peu fiable. D'autre part, le bois est un matériau anisotropique, ce qui veut dire que ses caractéristiques varient en fonction de la direction considérée, compliquant encore plus la caractérisation.

1.2 Défauts de surface dans le bois

1.2.1 Qu'est-ce qu'un défaut de surface ?

Dans ce contexte, un défaut de surface est défini comme étant une déviation non désirée dans le profil de la surface. Cette définition est intrinsèquement arbitraire puisqu'un défaut n'existe que par rapport à un résultat désiré (Richter, 2015). Puisque la nature exacte de ce résultat dépend de plusieurs facteurs externes (matériau, utilisation prévue, aspect souhaité, etc.), une même déviation dans la texture d'une surface peut être considérée soit comme étant un défaut, soit comme étant normale. Par exemple, un panneau de copeaux ² est considéré comme étant

² Ces panneaux sont généralement connus sous le nom de "OSB" (Oriented Strand Board).

sans défauts s'il ne comporte pas de trous ou de variations majeures. Or, si un panneau de contre-plaqué de finition avait la même texture, sa surface serait entièrement couverte de défauts.

Malgré la subjectivité inhérente de ce qui constitue un défaut de surface, il est tout de même possible de créer des standards de qualité. Au meilleur de notre connaissance, certaines normes existent pour le bois (ASTM International, 2017; Architectural Woodwork Institute, 2022), mais la majorité d'entre elles ne sont pas universelles et varient selon les besoins de leurs utilisateurs (Huber, Ruddell & Mcmillin, 1990).

1.2.2 Types de défauts de surface

Il existe plusieurs types de défauts pouvant être présents sur une surface de bois. La figure 1.1 en présente quelques exemples. Deux catégories principales sont reconnues dans la littérature : les défauts naturels et les défauts de transformation (Goli, 2003). Dans le cadre de ce mémoire, nous présentons une troisième catégorie : les défauts ponctuels. Ces catégories sont définies dans les paragraphes suivants en fonction de leurs causes respectives.

Les **défauts naturels** sont créés lors de la croissance de l'arbre et sont grandement affectés par les conditions dans lesquelles il pousse. Selon Richter (2015), ils sont divisés en trois sous-catégories principales selon le phénomène responsable, soit : les facteurs inhérents à la croissance de l'arbre (nœuds, grain déformé, etc.), les facteurs biologiques (moisissures, trous d'insectes, etc.) et les facteurs non biologiques (brûlures, fissures causées par le vent, etc.). Bien que les conditions de croissance peuvent être influencées, elles contiennent une part de hasard inhérente qui rend ce type de défaut difficile à contrôler.

Les **défauts de transformation** sont causés par les différentes étapes de transformation qui sont appliquées pour produire du bois utilisable. On parle ici de fissures causées lors du séchage, de marques de scie, de brûlures de coupe, etc. Selon Goli (2003), les phénomènes en cause sont principalement déterministes et répétables, contrairement aux défauts naturels. De plus, l'auteur ajoute que leur importance peut être minimisée en ajustant les paramètres des procédés de transformation.



Figure 1.1 Exemples de défauts de surface sur le bois

Finalement, les **défauts ponctuels** sont le résultat d'événements accidentels. Puisque les causes de ce type de défaut sont variées et souvent aléatoires, les caractéristiques de ces défauts sont également variées. De manière générale, leur superficie est circonscrite, mais ils sont plus prononcés que les défauts de transformation. Ces défauts incluent, par exemple, une rayure sur un panneau de bois causée par un accrochage sur le coin d'un établi en le déplaçant, un arrachement des fibres du bois causé par un outil échappé, ou une indentation dans la surface

² Adaptée de <https://www.pxfuel.com/en/free-photo-oyzdm>

³ Les images sans attribution sont celles de l'auteur.

⁴ Adaptée de <https://www.pxfuel.com/en/free-photo-xxomz>

⁵ Adaptée de <https://www.pxfuel.com/en/free-photo-jvsrx>

⁶ Adaptée de <https://www.pxfuel.com/en/free-photo-exzot>

après avoir entreposé une planche sur du gravier. Ils sont généralement associés à de mauvaises manipulations par un être humain.

1.2.3 Axes de recherche sur les défauts de surface

La littérature consacrée aux défauts de surface dans le bois est orientée sur deux axes principaux : détecter la présence de défauts et effectuer leur caractérisation.

La **détection des défauts** consiste à automatiquement identifier leur présence à des fins d'assurance qualité. Pour effectuer cette détection, un grand nombre de méthodes peuvent être utilisées en fonction du contexte et des requis spécifiques. Un survol de ces méthodes sera présenté à la section 1.3. Bien que cet axe de recherche soit parfois appliqué aux défauts de transformation, il est principalement orienté vers les défauts naturels. En effet, puisque ceux-ci sont présents dans le matériau brut, ils ne peuvent pas être éliminés par un meilleur ajustement des procédés de transformation. La seule manière de les éliminer est donc de les détecter et de sélectionner les matériaux bruts en conséquence.

La **caractérisation des défauts** consiste à étudier les mécanismes qui mènent à leur formation et quantifier l'influence des différents paramètres de ces mécanismes sur la qualité de surface résultante. Cet axe de recherche est principalement orienté vers les défauts de transformation. En effet, puisque ceux-ci sont entièrement causés par les étapes de transformation et ne sont pas inhérents au matériau lui-même, une meilleure compréhension des causes permet d'ajuster l'équipement et les procédés pour réduire l'incidence des défauts à la source. Par exemple, Goli, Marchal & Uzielli (2004) ont démontré que l'angle de coupe par rapport au grain du bois a un impact significatif sur la qualité de surface. Yang, Xue & Liu (2012) ont étudié l'impact de différentes méthodes de traitement du bois sur la rugosité de surface. Ramanakoto, Andrianantenaina, Ramananantoandro & Eyma (2017) et Ramanakoto, Ramananantoandro, Eyma & Castanié (2019) ont étudié les relations entre les paramètres de surface et les préférences des consommateurs malgaches et français respectivement. Puisque ce mémoire s'intéresse uniquement à la détection de défauts, nous n'aborderons pas la caractérisation plus en profondeur.

Au meilleur de notre connaissance, aucune étude ne traite spécifiquement des défauts ponctuels. Nous posons l'hypothèse que ceci est dû aux contextes dans lesquels les défauts ponctuels sont problématiques. Pour la production à grande échelle, les procédés peuvent être suffisamment contrôlés et optimisés pour pratiquement éliminer les événements accidentels qui causent ce type de défaut. Au contraire, pour la production à petite échelle où l'automatisation n'est pas présente, l'inspection manuelle des pièces est suffisante pour détecter les défauts ponctuels lorsqu'ils se produisent. Dans les deux cas, les défauts ponctuels ne représentent pas un problème majeur, d'où, sans doute, le manque de recherche sur le sujet. Or, avec l'arrivée des robots collaboratifs, l'automatisation des procédés peut maintenant être utilisée pour la production à petite échelle. On voit donc apparaître des environnements où les défauts ponctuels se produisent, mais où l'inspection est automatisée. C'est dans ce contexte que s'inscrit l'objectif de ce mémoire, soit d'étudier la capacité de détecter automatiquement la présence de défauts ponctuels.

1.3 Méthodes de détection de défauts de surface

Il existe plusieurs méthodes et systèmes permettant d'effectuer la détection de défauts sur une surface de bois. Cette section présente les méthodes majeures ainsi que leurs avantages et leurs défauts par rapport à notre contexte.

1.3.1 Sens du toucher humain

Une des manières les plus simples de détecter la présence de défauts sur un objet est d'utiliser notre propre corps. En effet, le sens du toucher nous permet de percevoir notre environnement de manière inhérente et intuitive. En glissant notre main sur une surface, nous pouvons ressentir les variations de sa texture et ainsi percevoir les défauts. Comme il s'agit d'une fonction innée, l'inspection tactile de surfaces est utilisée presque universellement depuis le début de l'humanité.

Le sens du toucher est distribué sur l'entièreté du corps, mais sa sensibilité varie selon l'endroit (Dargahi & Najarian, 2004). Les mains sont particulièrement sensibles : le bout des doigts contient jusqu'à 241 récepteurs par cm^2 (Johansson & Vallbo, 1979) et peut différencier des

points aussi proches que 1 mm (Craig & Kisner, 1998). Le sens du toucher sur la peau glabre (sans poil) est engendré principalement par quatre types de mécanorécepteurs (Vallbo & Johansson, 1984). Selon Caldwell, Tsagarakis & Wardle (1997), ceux-ci sont divisés principalement selon leur vitesse d'adaptation à un stimulus statique et selon la taille de leur champ réceptif. Les récepteurs à action lente perçoivent les stimuli statiques tandis que les récepteurs à action rapide ne réagissent qu'aux variations de stimuli. Les récepteurs de type I possèdent un petit champ réceptif tandis que les récepteurs de type II perçoivent des stimuli sur une surface plus large. Le tableau 1.1 présente quelques-unes des caractéristiques de ces mécanorécepteurs.

Tableau 1.1 Mécanorécepteurs et leurs caractéristiques
Adapté de Caldwell *et al.* (1997)

Mécanorécepteur	Type	Champ Réceptif (mm ²)	Plage de fréquences (Hz)
Corpuscules de Meissner	FA I	1 - 100	10 - 200
Corpuscules de Pacini	FA II	10 - 1000	40 - 800
Disques de Merkel	SA I	2 - 100	0.4 - 100
Corpuscules de Ruffini	SA II	10 - 500	7

La perception de texture est engendrée par deux mécanismes différents qui agissent en fonction de sa rugosité. En effet, selon les travaux de Katz (1989) et de Hollins & Risner (2000), lorsque les variations d'une texture sont de l'ordre de moins de 100 µm, celle-ci est principalement perçue par les vibrations causées lors de mouvements exploratoires. Plus la taille des variations augmente au-dessus de 100 µm, plus la perception spatiale des caractéristiques géométriques de la texture prend le dessus. Il est intéressant de noter que ce mécanisme spatial fonctionne même de manière statique alors que le mécanisme vibratoire (et donc la perception de textures fines) requiert la présence de mouvement.

Les empreintes digitales jouent également un grand rôle dans le fonctionnement du mécanisme vibratoire. Selon Scheibert, Leurent, Prevost & Debrégeas (2009) et Wandersman, Candelier, Debrégeas & Prevost (2011), l'interaction entre les empreintes digitales et la texture d'une surface enrichit et amplifie le contenu fréquentiel des vibrations perçues par les mécanorécepteurs. À des vitesses d'exploration standard (≈10-15 cm/s), la distance entre les crêtes des empreintes

digitales ($\approx 500 \mu\text{m}$) génère un signal entre 200 et 300 Hz, ce qui correspond environ au pic de sensibilité des corpuscules de Pacini. On peut donc dire que les empreintes digitales traitent en quelque sorte le signal généré par l'interaction avec la texture afin qu'il soit mieux perçu par les mécanorécepteurs.

L'inspection de pièces par le toucher humain a fait l'objet de plusieurs travaux. Desai & Konz (1983) ont comparé la performance d'inspection tactile de tuyaux hydrauliques et ont découvert que l'utilisation de gants (de type latex) n'avait pas d'impact significatif. Kleiner, Drury & Christopher (1987) ont étudié l'inspection de cylindres en métal à l'aide de sondes manuelles et ont démontré qu'elle pouvait être réalisée en utilisant uniquement le sens du toucher. Aust, Mitrovic & Pons (2021) ont montré que l'inspection visuo tactile de pales de moteurs d'avion pour la présence de défauts est supérieure à l'utilisation de la vision uniquement. Cet ajout a aussi permis de mieux classer les types de défauts.

Comme mentionné précédemment, le sens du toucher est couramment utilisé pour inspecter des surfaces, incluant celles du bois. Pour une production artisanale ou de petite échelle, il s'agit d'une excellente méthode de détection de défauts puisqu'elle ne requiert aucun équipement et qu'elle est accessible à (presque) tout le monde. Or, bien qu'elle peut être très sensible (pouvant détecter des variations de l'ordre de $15 \mu\text{m}$ (Kishi, Hida, Nakajima & Matsumoto, 2016)), l'inspection par le toucher humain comporte plusieurs lacunes, tel que rapportées par Gurau & Irle (2017) et Sinn *et al.* (2009) : la capacité à percevoir et reconnaître des défauts est affectée par la subjectivité de la perception humaine et l'expérience de l'inspecteur. Selon Galley, Mothe & Boury (1998), elle est aussi plus sensible à l'anatomie et à l'angle du grain du bois que d'autres méthodes objectives. Finalement, l'inspection manuelle implique évidemment un coût non négligeable de main-d'oeuvre et ne peut pas être facilement étendue pour augmenter la production.

1.3.2 Méthodes non applicables

Les profilomètres à contact utilisent un stylet à pointe fine glissé sur une surface pour mesurer la position verticale de son profil. Cette méthode permet d'obtenir une excellente résolution de mesure, mais il s'agit d'un processus lent qui ne permet pas d'inspecter une grande surface puisqu'il mesure une ligne en deux dimensions seulement. De plus, le stylet peut endommager la surface, ce qui n'est pas acceptable dans un environnement de production. Il existe aussi des profilomètres sans contact qui permettent de mesurer le profil de la surface sans y toucher, ce qui a l'avantage de ne pas l'endommager (Creath, 1988; Poon & Bhushan, 1995). Or, ils doivent être placés très près de l'échantillon à mesurer et sont également limités en termes de surface couverte.

D'autres méthodes, comme la méthode pneumatique (Hiziroglu, 2005) et la méthode capacitive (Gurau & Irle, 2017) sont capables d'inspecter rapidement de grandes surfaces planes, mais elles ne peuvent mesurer que la rugosité moyenne sur l'ensemble de la zone de mesure. Cela est adéquat pour contrôler un processus grossier comme la fabrication de planches, mais l'incapacité à percevoir la présence de défauts individuels rendent ces méthodes inutilisables pour l'inspection de produits finis (Mothe, 1985). De plus, elles nécessitent de l'équipement sur mesure pour chaque application et n'ont donc pas la flexibilité requise par notre contexte.

1.3.3 Méthodes basées sur la vision artificielle

Le sens de la vue chez l'humain permet de percevoir l'environnement sans devoir être en contact physique. Ceci inclut la capacité de percevoir et d'identifier la texture d'un objet (Landy & Graham, 2004). Comme son nom l'indique, la vision artificielle est inspirée par le sens de la vue humain et fonctionne de manière équivalente.

Un système de vision artificielle comporte généralement trois éléments principaux : l'illumination de la surface, l'acquisition d'image et le traitement des données. Ren, Fang, Yan & Wu (2022) présentent les rôles respectifs de ces éléments :

- L'illumination consiste à éclairer la surface de manière à rendre les caractéristiques désirées plus visibles et à réduire l'impact de l'environnement en produisant une apparence constante. Les caractéristiques du système d'illumination doivent être choisies en fonction de l'application spécifique puisqu'ils jouent un rôle important dans la performance du système entier. Le nombre de sources de lumière, leur position par rapport à la caméra et le type de lumière utilisée (blanche, infrarouge, rayons X, etc.) sont quelques-uns de ces paramètres.
- L'acquisition d'image est réalisée par une ou plusieurs caméras. Celles-ci captent la surface illuminée et génèrent une image ou un flux vidéo. La majorité des caméras utilisent des capteurs CCD (*Charged coupled device*) ou CMOS (*Complementary metal oxide semiconductor*), mais il existe aussi des technologies plus avancées comme les caméras plénoptiques (qui permettent de capter une image 3D). De plus, tout comme les systèmes d'illumination, il existe des caméras pouvant opérer hors du spectre visible.
- Le traitement des données consiste à transformer et analyser les images acquises par les caméras pour en extraire de l'information permettant de prendre une décision. Pour commencer, des étapes de prétraitement peuvent être appliquées pour réduire le bruit et faciliter l'analyse (normalisation, filtres spatiaux et fréquentiels, etc.). Les images traitées sont ensuite analysées par un ou plusieurs algorithmes qui extraient des caractéristiques indiquant ou non la présence de défauts. Un trop grand nombre d'algorithmes existent pour être traités dans ce mémoire, mais il est tout de même pertinent de mentionner que l'apprentissage profond (*deep learning*) fait l'objet de la majorité de la recherche récente.

Pour le bois spécifiquement, plusieurs auteurs ont utilisé des méthodes basées sur l'usage de réseaux neuronaux convolutifs (CNN) pour détecter la présence de défauts naturels et de transformation sur des images de surfaces en bois (Fang, Guo, Chen, Zhou & Ye, 2021; He *et al.*, 2019; Shi, Li, Zhu, Wang & Ni, 2020; Yang, Zhou, Liu, Hu & Ding, 2020). Ces travaux obtiennent tous d'excellents taux de classification supérieurs à 90%. Cependant, ils ont tous été réalisés dans un contexte d'inspection de surfaces planes (principalement des planches) et leur applicabilité à des surfaces complexes n'a pas été étudiée. De plus, nous n'avons pas identifié de travaux traitant des défauts ponctuels spécifiquement.

Malgré ses avantages et sa performance intéressante, la vision artificielle présente deux limitations qui la rendent inappropriée pour notre application :

- Un système de vision suffisamment performant pour pouvoir détecter la présence de défauts implique un coût d'implantation élevé. En effet, la conception du système et l'installation de l'équipement requis peuvent rapidement rendre un projet non viable financièrement, spécialement dans le contexte d'une petite entreprise. De plus, ce problème n'est qu'amplifié si les surfaces à inspecter ne sont pas planes ou si leurs formes varient.
- La poussière engendrée par le sablage des pièces de bois crée un environnement difficile pour la vision artificielle. Les particules de poussière sur la surface de l'objet peuvent masquer les défauts, leur présence dans l'air peut interférer avec le système d'illumination et elles peuvent réduire la qualité d'image en se déposant sur la lentille de la caméra. Ces problèmes peuvent tous être réglés à l'aide d'équipement additionnel, mais cela implique une augmentation de la complexité du système et de son coût déjà élevé.

1.3.4 Méthodes par capteurs tactiles

Tout comme la vision artificielle est inspirée du sens de la vue, les capteurs tactiles sont inspirés du sens du toucher. Ils permettent de percevoir les caractéristiques d'une surface simplement en étant en contact avec celle-ci. Contrairement à la vision artificielle, les capteurs tactiles sont peu vulnérables aux variations de l'environnement (Fang *et al.*, 2020). Ils ne requièrent aucun système d'illumination et peuvent fonctionner dans l'obscurité totale. De plus, ils ne sont pas affectés par les caractéristiques visuelles de la surface (couleur, motifs, etc.) Ces capteurs peuvent être réalisés avec une large variété de technologies, chacune ayant ses propres forces et faiblesses. Dans cette sous-section, nous effectuerons un survol des plus importantes par rapport à notre contexte.

Capteurs piézorésistifs

Les capteurs piézorésistifs sont basés sur l'utilisation de matériaux dont la résistance électrique change lorsqu'une force leur est appliquée. Généralement, ils sont composés de particules

électriquement conductrices dispersées dans un matériau élastique. Il s'agit d'une technologie mature, relativement bon marché et facile à manufacturer (Kappasov, Corrales & Perdereau, 2015). Toutefois, selon Gao, Dai & Nathan (2022), les capteurs piézorésistifs sont limités par leur hystérésis élevée ⁸, ce qui veut dire qu'il y a un retard entre la force appliquée sur le capteur et la valeur mesurée par celui-ci. Toujours selon Gao *et al.* (2022), ils sont aussi affectés par les variations de température, ce qui peut causer des problèmes selon l'environnement dans lequel ils sont utilisés.

Les capteurs piézorésistifs ont été utilisés avec succès pour effectuer plusieurs tâches d'exploration de surfaces. Okatani *et al.* (2016) ont utilisé un capteur piézorésistif pour estimer le coefficient de friction statique lors de prises d'objets. Gupta *et al.* (2018) ont étudié la capacité de reconnaître des textures de surface et ont obtenu un taux de classification de 98% avec 5 textures et 5 angles d'exploration. Bien que les capteurs piézorésistifs permettent d'obtenir des résultats intéressants, nous n'avons pas recensé de travaux les appliquant à la détection de défauts.

Capteurs piézoélectriques

Les capteurs piézoélectriques sont basés sur l'utilisation de matériaux qui, lorsqu'ils sont déformés par une contrainte mécanique, génèrent des charges électriques sur leur surface. Ces charges sont ensuite mesurées, ce qui permet de quantifier la force appliquée sur le capteur. Puisque la génération de ces forces s'effectue extrêmement rapidement, ce mécanisme d'opération permet aux capteurs piézoélectriques de percevoir des variations de force à beaucoup plus haute fréquence (Wang, Dong, Peng & Pan, 2019). Par exemple, Goger, Gorges & Worn (2009) ont mesuré des signaux allant jusqu'à 7 kHz. Or, selon Gao (2017), puisque les charges électriques générées par le matériau sont facilement dissipées, ce type de capteur n'est pas adapté à mesurer les forces statiques. Ils doivent donc être combinés à d'autres capteurs si l'application nécessite ce type de mesure. De plus, selon Dahiya & Valle (2008), ils sont aussi sensibles aux changements de température.

⁸ Ceci est principalement causé par le fait que le matériau élastique ne reprend pas instantanément sa forme originale lors du déchargement.

Tout comme les capteurs piézorésistifs, les capteurs piézoélectriques ont aussi été utilisés avec succès effectuer la classification de textures. En effet, Drimus, Borlum Petersen & Bilberg (2012) ont obtenu une exactitude de 96.9% sur 7 textures courantes. Yi, Zhang & Peters (2017) ont classifié 8 surfaces ayant différents niveaux de rugosité avec un taux de classification de 82.6%. Dans le même ordre d'idées, Xin *et al.* (2021) ont atteint un taux de classification moyen de rugosité de surface de 94%. En revanche, nous n'avons ici aussi pas recensé de travaux traitant de la détection de défauts spécifiquement.

Capteurs optiques

Les capteurs optiques (parfois appelés capteurs visuo tactiles) utilisent une approche entièrement différente aux autres types de capteurs tactiles : de manière générale, ils transforment le problème de la perception tactile en un problème de perception visuelle (Yamaguchi & Atkeson, 2019). Ce changement d'approche permet d'exploiter les forces de la vision artificielle dans un contexte où, comme discuté précédemment, elle est normalement limitée.

Pour ce faire, les capteurs optiques sont généralement composés d'un système de vision et d'une couche de matériau flexible qui, lorsqu'elle est mise en contact avec une surface, subit un changement visible. Ces changements sont perçus par le système de vision et sont ensuite traités pour obtenir une "image tactile" de la surface. Les changements en question peuvent prendre plusieurs formes selon la nature spécifique du matériau. Shah, Muthusamy, Gan, Zweiri & Seneviratne (2021) en présentent plusieurs exemples, dont :

- Le mouvement de marqueurs de position (Ward-Cherrier *et al.*, 2018; Yamaguchi & Atkeson, 2016)
- La diffusion de rayons lumineux (Giannoccaro, Massaro, Spedicato & Lay-Ekuakille, 2015; Shimonomura & Nakashima, 2013)
- La réflexion de la lumière sur une membrane élastique (Cirillo, Cirillo, De Maria, Natale & Pirozzi, 2017; Dong, Yuan & Adelson, 2017; Lambeta *et al.*, 2020)

L'un des avantages majeurs des capteurs optiques par rapport aux autres types de capteurs tactiles est que, puisqu'ils utilisent des caméras ayant une résolution élevée ⁹, leurs signaux peuvent être traités comme des images normales. Comme expliqué par Shah *et al.* (2021), cela veut dire qu'il est possible d'utiliser des algorithmes et des réseaux de neurones puissants venant du domaine de la vision artificielle. Par exemple, Long, Fang, Zhang, Luo & Sun (2021) ont utilisé le réseau convolutif préentraîné *ImageNet* pour classifier leurs données. L'usage de caméras implique aussi un avantage en termes du câblage requis : pour les capteurs non optiques, augmenter la résolution implique généralement une augmentation du nombre de câbles qui doivent être utilisés pour transmettre les données (Kappasov *et al.*, 2015). Toutefois, selon Shimonomura (2019), les capteurs optiques peuvent facilement gérer plusieurs milliers (voir millions) de pixels à l'aide de câblage standard (HDMI ou autres), et ce à très haute vitesse.

Les capteurs optiques sont extrêmement prometteurs pour la détection de défauts et leur efficacité a été démontrée plusieurs fois. Giannoccaro *et al.* (2015) ont utilisé une fibre optique encastrée dans un matériau nanocomposite en or pour détecter la présence de rayures allant jusqu'à 1 mm sur une planche de bois. Elkington *et al.* (2021) ont détecté la présence d'une variété de défauts communs lors de la fabrication de matériaux composites à l'aide du capteur *TacTip*. Fang *et al.* (2020), Long *et al.* (2021) et Fang *et al.* (2022) ont utilisé un capteur similaire au capteur *Gelsight* pour détecter avec succès les défauts de surface sur plusieurs tissus d'apparences et de textures variées. À notre connaissance, la détection de défauts sur le bois spécifiquement a uniquement été traitée par Giannoccaro *et al.* (2015) et nous n'avons pas été en mesure d'identifier des travaux subséquents à cette étude.

Malgré ces excellents résultats, aucun des travaux que nous avons recensés n'offre d'indications quant à la durée de vie de ces capteurs dans un contexte d'inspection de surfaces en bois. Il semble toutefois logique de croire que le glissement du capteur (et donc de sa couche flexible) sur la surface rugueuse du bois pourrait mener à une diminution importante de sa durabilité. L'usage

⁹ Certain capteurs optiques ne disposent pas d'une haute résolution, mais la majorité des capteurs récents possèdent cette caractéristique.

de matériaux plus rigides pourrait potentiellement remédier à ce problème, mais l'impact que cela aurait sur la performance du capteur reste à déterminer.

Capteurs capacitifs

Les capteurs capacitifs sont basés sur la mesure de la variation de la capacitance lorsqu'une force est appliquée sur le capteur. Ils sont généralement composés de deux électrodes conductrices qui sont séparées par une couche de matériau diélectrique flexible. Lorsqu'une force est appliquée sur le capteur, la couche diélectrique est comprimée, ce qui réduit la distance entre les deux électrodes. Puisque la capacitance de l'assemblage est inversement proportionnelle à l'écart entre les deux électrodes, mesurer la capacitance permet de mesurer cet écart et donc d'inférer la force qui est appliquée sur le capteur. L'équation 1.1 montre cette relation :

$$C = \varepsilon_0 \varepsilon_r \frac{A}{d} \quad (1.1)$$

où C est la capacitance, ε_0 est la constante électrique, ε_r est la perméabilité relative du diélectrique, et A est la surface de superposition des électrodes. Enfin, d est la distance entre les deux électrodes, soit l'épaisseur de la couche diélectrique.

Selon Le, Maslyczyk, Roberge & Duchaine (2017), les capteurs capacitifs sont couramment utilisés étant donné leur simplicité et leur fabrication relativement simple. Ils offrent une bonne réponse fréquentielle permettant la perception statique et dynamique et leur résolution spatiale peut être élevée (Tiwana, Redmond & Lovell, 2012). De plus, en modifiant la structure de la couche diélectrique (avec de la mousse ou des microstructures, par exemple), il est possible d'augmenter significativement la sensibilité du capteur à de petites forces tout en maintenant une force maximale élevée (Wang *et al.*, 2019). Les capteurs capacitifs sont vulnérables à l'interférence électromagnétique (Gao *et al.*, 2022), mais il est toutefois possible d'ajouter un blindage pour en réduire l'impact (Le *et al.*, 2017). De plus, selon la conception de la couche diélectrique, ils peuvent être limités par leur hystérésis (Kappasov *et al.*, 2015).

Nous n'avons pas pu recenser de travaux dans lesquels les capteurs capacitifs ont été utilisés pour la détection de défauts de surface spécifiquement. Néanmoins, ils ont été utilisés avec succès pour effectuer la reconnaissance de textures. Muhammad *et al.* (2011) ont utilisé un capteur capacitif MEMS (*Microelectromechanical systems*) pour identifier cinq textures artificielles et 2 tissus. Rispal, Rana & Duchaine (2017) ont utilisé un capteur capacitif capable de capter des signaux statiques et dynamiques pour classifier cinq textures artificielles et dix textures de la vie courante avec un taux d'exactitude de 96%. Taunyazov, Koh, Wu, Cai & Soh (2019) ont utilisé un robot humanoïde équipé de 60 taxels sur l'avant-bras pour classifier 23 textures de la vie courante et ont obtenu un taux de classification de 98% en combinant un mouvement de glissement et un de toucher.

Autres types de capteurs tactiles

En plus de ceux mentionnés dans les sections précédentes, il existe d'autres technologies permettant d'implémenter un capteur tactile. À des fins de brévit  , nous ne les traiterons pas en d  tail, mais nous incluons tout de m  me quelques r  f  rences o   elles ont   t   utilis  es :

- Capteurs barom  triques (Tenzer, Jentoft & Howe, 2014; Wettels, Fishel & Loeb, 2014)
- Capteurs magn  tiques (Wattanasarn, Noda, Matsumoto & Shimoyama, 2012; Yan, Hu, Shen & Pan, 2022)
- Capteurs    tomographie par imp  dance   lectrique (Russo, Assaf, Carbonaro & Tognetti, 2019; Silvera-Tawil, Rye, Soleimani & Velonaki, 2015)
- Capteurs tribo  lectriques (Tao *et al.*, 2019; Wang & Wang, 2019)
- Capteurs ultrasoniques (Ando & Shinoda, 1995)

Finalement, il est possible de combiner plusieurs technologies afin de cr  er des capteurs tactiles multimodaux. Tout comme le toucher humain est d      plusieurs types de corpuscules qui se conjuguent pour percevoir une large gamme de stimuli (comme la pression, les vibrations, la temp  rature, etc.), la combinaison de plusieurs technologies permet d'  largir les capacit  s d'un capteur tactile. Le capteur *BioTac*, qui combine la perception de pression, de vibrations et de

température, est un excellent exemple de ce principe (Fishel & Loeb, 2012b). Le capteur utilisé dans le cadre de ce mémoire, développé par Le *et al.* (2017), en est un bon exemple puisqu'il peut simultanément percevoir la pression statique et les vibrations, en plus de contenir une centrale inertielle (IMU) qui perçoit son orientation et sa position.

CHAPITRE 2

MONTAGE EXPÉRIMENTAL

Dans ce chapitre, les éléments qui composent le montage expérimental seront présentés. Nous commencerons par présenter les plaques échantillons à partir desquelles les données ont été obtenues. Nous présenterons ensuite le système permettant de les acquérir, puis finalement, nous expliquerons les procédures suivies pour la création de l'ensemble de données.

2.1 Plaques échantillons

Afin d'obtenir des données fiables et répétables, nous avons créé une série de plaques échantillons représentant une variété de surfaces. Les données ont été acquises en glissant le capteur tactile sur la surface de ces plaques.

2.1.1 Choix de l'essence de bois

Il existe une multitude d'espèces de bois qui sont utilisées couramment dans la fabrication de produits. Elles peuvent être divisées principalement en termes de dureté et de l'apparence du grain.

La dureté du bois est définie par le type d'arbre dont il provient. Bien qu'il existe des exceptions, les arbres feuillus produisent du bois dur tandis que les conifères produisent du bois tendre. Un bois dur sera généralement plus dur et dense qu'un bois tendre. Le bois dur a aussi généralement meilleure apparence qu'un bois tendre. Par exemple, le pin blanc est souvent utilisé pour la fabrication de bois d'œuvre, mais rarement pour du mobilier puisqu'il est facilement endommagé et qu'il comporte beaucoup d'imperfections. La majorité des produits de consommation (mobilier, jouets, etc.) seront donc fabriqués en bois dur.

L'apparence du grain réfère au degré de visibilité de la texture inhérente aux fibres du bois. Par exemple, la surface du chêne rouge est texturée et présente un grain très apparent. Comme son nom l'indique, l'apparence du grain est un facteur plus subjectif que la dureté.

Pour la création des plaques échantillons, nous avons choisi d'utiliser une seule espèce de bois comme référence, soit l'érable blanc, qui est couramment utilisé pour la fabrication de produits et de meubles. La figure 2.1 montre une image de la surface d'une planche d'érable blanc.



Figure 2.1 Échantillon
d'érable blanc

Nous avons choisi d'utiliser l'érable blanc puisqu'il s'agit d'un bois dur dont le grain est peu apparent. Ces caractéristiques nous permettent de concentrer nos efforts sur la détection des défauts ponctuels en minimisant l'impact de la structure du grain et le risque de créer d'autres défauts accidentellement (par une mauvaise manipulation des plaques ou par usure).

Le bois brut ayant servi à la fabrication des plaques échantillons a été obtenu dans le commerce (Langevin Forest).

2.1.2 Choix des défauts

Nous avons choisi d'étudier trois types de défauts ponctuels relativement communs, soit les rayures, les indentations et les arrachements. La figure 2.2 montre un exemple de chaque type de défaut dans l'érable blanc.

Le premier type de défaut considéré est les **rayures**. Des rayures sont produites lorsqu'un objet pointu est glissé sur la surface (ou vice-versa). Selon la force appliquée, les fibres du bois sur le chemin de l'objet seront déformées, allant même jusqu'à être arrachées. Une mauvaise manipulation du matériau peut causer des rayures facilement. Par exemple, si une planche entre en contact avec le coin d'un objet lorsqu'elle est déplacée. L'apparence et la profondeur d'une rayure dépendent non seulement de la force appliquée et de l'objet en contact, mais aussi de la direction du mouvement. En effet, si le mouvement est dans la direction des fibres, le dommage sera limité puisque les fibres auront tendance à se séparer. Au contraire, si le mouvement est perpendiculaire au grain du bois, les fibres seront déchirées et le dommage sera très évident. Pour prendre ceci en compte, nous avons décidé de considérer des rayures à différents angles par rapport au grain du bois, soit 0° , 45° et 90° .




Figure 2.2 Types de défauts considérés

Le deuxième type de défaut considéré est les **indentations**. Celles-ci sont produites lorsqu'un objet est enfoncé dans la surface du bois. Cela peut se produire de manière statique (p. ex. déposer une planche sur du gravier) ou dynamique (p. ex. un outil échappé de haut sur un meuble). Le dommage résultant sera une indentation plus ou moins profonde dépendant de la force de l'impact, de l'objet qui l'a causé et de l'essence du bois.

Le dernier type de défaut considéré est les **arrachements**. Un arrachement est produit lorsque le bois est déchiré dans le sens des fibres. Cela se produit principalement lorsqu'un outil ne parvient pas à couper proprement les fibres. Celles-ci sont agrippées par la lame et la force les détache de la surface, laissant une surface irrégulière (Goli *et al.*, 2004). L'angle des fibres du bois joue un rôle majeur dans la forme de l'entaille.

Ces catégories de défauts ne sont pas mutuellement exclusives et un certain chevauchement existe. Par exemple, un impact causant une indentation peut aussi causer de l'arrachement des fibres sur les côtés. Afin de simplifier l'analyse, nous ne considérerons pas ces variations dans le cadre de ce projet. De plus, comme mentionné dans le chapitre précédent, d'autres types de défauts existent, mais ne seront pas traités, car ils peuvent déjà être détectés avec des méthodes existantes.

2.1.3 Préparation des plaques échantillons

Les plaques échantillons ont été préparées en plusieurs étapes.

D'abord, les planches brutes ont été planées afin de rendre les deux faces parallèles et uniformes. Certaines des planches n'étaient pas assez larges, elles ont donc été jointes côte à côte pour obtenir la largeur désirée. Elles ont ensuite été sciées pour obtenir des plaques carrées d'environ 180 mm de largeur. Les plaques brutes ont été sablées à l'aide d'une ponceuse orbitale jusqu'à ce qu'une inspection visuelle et tactile ne révèle plus aucun défaut de surface.

Chaque face des plaques a été identifiée et assignée soit à une catégorie de défaut ou comme contrôle. Les plaques contrôles ont été laissées intactes. Les rayures ont été faites en traînant un tournevis plat appuyé fermement sur la surface. Les indentations ont été faites en donnant des coups de marteau sur les plaques. Finalement, puisqu'il aurait été dangereux d'utiliser incorrectement des outils de coupe pour créer des arrachements, ceux-ci ont été simulés en coupant le bois en diagonale avec un couteau à lame rétractable et en arrachant les fibres ainsi séparées à l'aide d'une pince. Nous avons tenté au meilleur de notre capacité d'espacer les défauts sur les plaques afin de pouvoir capturer la différence entre la surface normale et le défaut.

Pour éviter d'endommager involontairement la face opposée des plaques, elles ont été déposées sur une surface de caoutchouc lors des manipulations.

Chaque face a ensuite été photographiée de haut et de loin pour minimiser les effets de perspective, puis les déformations restantes ont été corrigées à l'aide d'un outil de correction de la perspective. Les photos ont ensuite été redimensionnées à une échelle de 20 px : 1 mm. Chaque image a été étiquetée en colorant manuellement les défauts de surface de couleur bleue (RGB 0,0,255). Afin de nous assurer de la validité de l'étiquetage, nous avons utilisé les plaques elles-mêmes pour vérifier la position et la forme des défauts. La couleur bleue a été choisie, car elle contraste énormément avec la couleur des plaques et ne peut donc pas être confondue. Toutes ces étapes ont été réalisées dans le logiciel d'édition d'images GIMP. Finalement, afin de réduire le temps de calcul lors du traitement des données, une image en noir et blanc pouvant être utilisée comme un masque binaire a été générée pour chaque image étiquetée (où les défauts sont représentés par du blanc).

Afin de s'assurer qu'il n'y ait pas de fuites d'information entre les ensembles d'entraînement et de test, les plaques sont assignées exclusivement à l'un ou l'autre des ensembles.

La figure 2.3 présente une série de photos représentant les étapes de préparation des plaques et le tableau 2.1 présente les plaques échantillons ayant été utilisées dans le cadre de ce mémoire.




Figure 2.3 Étapes de préparation d’une plaque échantillon

Tableau 2.1 Plaques échantillons

No.	Espèce	Type	Angle (deg)
11	Érable Blanc	Rayures	0°
12		Contrôle	N/A
13	Érable Blanc	Indentations	N/A
14		Arrachements	N/A
39	Érable Blanc	Contrôle	N/A
40		N/A	N/A
41	Érable Blanc	Rayures	45°
42		Rayures	90°
51*	<i>Érable Blanc</i>	<i>Rayures</i>	<i>0°</i>
52		<i>Contrôle</i>	<i>N/A</i>
53	<i>Érable Blanc</i>	<i>Indentations</i>	<i>N/A</i>
54		<i>Arrachements</i>	<i>N/A</i>

* L’ensemble de test est composé des plaques 51 à 54 (mises en italique).

2.2 Système d'acquisition de données

Afin de faciliter la prise de données en grande quantité, nous avons conçu et fabriqué un banc de test dédié à cette tâche. Collecter manuellement les données a été exclu, car cette méthode ne permet pas de contrôler les conditions expérimentales de façon suffisamment précise. La vitesse du mouvement, la pression exercée sur le capteur et l'angle de contact seraient tous variables et pourraient donc induire des erreurs.

Un banc de test dédié permet de faire la prise de données dans un environnement contrôlé, répétable et constant. La figure 2.4 montre une photo du banc de test et la figure 2.5 présente un organigramme de ses composantes majeures. Il aurait également été possible de collecter les données en utilisant un robot collaboratif, mais nous avons décidé de ne pas choisir cette option en raison du nombre limité de ces robots au laboratoire et de leur utilisation fréquente pour plusieurs projets.




Figure 2.4 Système d'acquisition de données




Figure 2.5 Organigramme du système d'acquisition de données

2.2.1 Composantes physiques

Nous avons choisi de déplacer la plaque sous le capteur plutôt que le capteur sur la plaque. Cela permet d'obtenir un système plus rigide et simple, car de cette manière les deux degrés de liberté de mouvement (avant/arrière et bas/haut) sont mécaniquement indépendants. Le capteur est maintenu en contact sur la plaque par un rail permettant uniquement le mouvement de bas en haut. Des poids peuvent être ajoutés sur le dessus du rail pour appliquer une pression constante.

Les différentes plaques échantillons sont placées sur le chariot mobile. La surface du chariot peut être pivotée jusqu'à 90° par incréments de 5° afin de changer la direction du mouvement de la plaque par rapport au capteur. Les plaques sont localisées par trois goupilles de positionnement et maintenues en place par un bras de verrouillage. Une photo du chariot est présentée à la figure 2.6. Le tout est fixé à un encodeur linéaire de 520 mm (MSA373.55-2P, RSF Electronik). Cet encodeur agit comme rail rigide et guide le chariot, en plus de mesurer sa position avec une précision de $\pm 5\mu\text{m}$. La sortie de l'encodeur est en cycles de quadrature et est convertie en distances par un lecteur de quadrature (ENC1000_0, Phidgets Inc.).

Un moteur stepper NEMA 23 fixé au châssis du banc de test permet de déplacer le chariot à l'aide d'une vis sans fin. Le moteur est contrôlé par un contrôleur de moteur (STC1004_0, Phidgets Inc.) et l'alimentation électrique provient d'une alimentation de laboratoire. Deux

interrupteurs de fin de course sont placés aux extrémités du châssis et sont utilisés comme points de référence pour la calibration et comme arrêt d'urgence en cas de défaillance.

Le contrôleur de moteur, le lecteur de quadrature et les interrupteurs de fin de course sont connectés au logiciel via une interface USB (HUB0000_0, Phidgets Inc.). Nous avons choisi d'utiliser ces composantes, car l'API (*Application programming interface*) fourni par la compagnie facilite significativement le développement du logiciel de contrôle et minimise le temps requis pour la mise en place.




Figure 2.6 Chariot indexable en rotation

2.2.2 Composantes logicielles

Le logiciel de contrôle du banc de test est basé sur l'interface *CoRoSensorUI* développée au laboratoire CoRo. Cette interface permet de visualiser et d'enregistrer les données mesurées par le capteur en temps réel. Elle a été développée en C++ dans l'environnement Qt (Qt Group).

Notre logiciel de contrôle est composé de quatre composantes principales :

- Le module d'acquisition de données est largement identique à la version originale. Les données reçues du capteur sont stockées temporairement dans un tampon circulaire et peuvent être sauvegardées en mémoire sous la forme de fichiers CSV.
- Le module de contrôle de position gère la communication avec le moteur, l'encodeur linéaire et les interrupteurs de fin de course. Il permet d'obtenir la position du chariot en temps réel et transmet les commandes au contrôleur du moteur. Le moteur peut être contrôlé soit en position ou en vitesse.
- L'automate fini (*Finite state machine*) est le cœur du logiciel et gère l'opération du banc de test. Les figures 2.7 et 2.8 présentent les diagrammes de flux du banc de test en général et de la boucle d'acquisition, respectivement.
- L'interface utilisateur est dérivée de l'interface originale et permet de contrôler les fonctions du banc de test, d'entrer les paramètres d'acquisition, ainsi que de surveiller son état en temps réel.




Figure 2.7 Diagramme de flux de l'automate fini




Figure 2.8 Diagramme de flux de la boucle d'acquisition

2.2.3 Capteur tactile capacitif CoRo

Le cœur du système d'acquisition de données est le capteur tactile capacitif développé au laboratoire CoRo par Rana, Roberge & Duchaine (2016) et Le *et al.* (2017). La figure 2.9 montre une image du capteur tactile installé sur le doigt d'un robot.

Le capteur tactile CoRo mesure $43 \times 28 \times 11$ mm. Il comporte quatre modalités de mesure, soit la modalité dynamique, la modalité statique, un accéléromètre trois-axes et un gyroscope trois-axes. Le fonctionnement des deux premières est basé sur l'usage d'une couche diélectrique microstructurée et de capteurs de capacitance qui permettent de mesurer les forces de contact sur une grande plage de valeurs (0-50 N).

Lorsqu'une force est appliquée sur le capteur, la pression comprime la couche diélectrique ce qui change la valeur de capacitance entre les électrodes selon l'équation 2.1. En mesurant la

capacitance, le capteur peut donc mesurer l'épaisseur de la couche diélectrique, et ainsi mesurer la pression appliquée.

$$C = \varepsilon_0 \varepsilon_r \frac{A}{d} \quad (2.1)$$

où C est la capacitance, ε_0 est la constante électrique, ε_r est la perméabilité relative du diélectrique, et A est la surface de superposition des électrodes. Enfin, d est la distance entre les deux électrodes, soit l'épaisseur de la couche diélectrique.



Figure 2.9 Capteur tactile capacitif CoRo

En utilisant un matériau mou, il est possible d'augmenter la sensibilité du capteur puisqu'une petite variation de force causera une déformation significative. Or cela réduit la capacité maximale du capteur puisque la couche diélectrique est plus facilement saturée. Inversement, un matériau plus dur augmentera la capacité maximale aux dépens de la sensibilité. Une couche plus épaisse de matériau mou permet d'augmenter la capacité maximale, mais augmente la taille du capteur.

Afin d'augmenter la sensibilité tout en maintenant un format intéressant, le capteur utilise une couche diélectrique microstructurée. Sa surface inférieure (en contact avec le PCB (*Printed circuit board*)) est recouverte de petites pyramides. Lorsque la pression appliquée est faible, celles-ci se déforment facilement et la déformation résultante est significative. Lorsque les

pyramides sont suffisamment déformées pour remplir entièrement l'espace vide entre elles, la couche diélectrique agit comme si elle était uniforme et peut soutenir une pression élevée. Cette déformation en deux phases permet d'obtenir une bonne sensibilité à basse pression, sans sacrifier l'épaisseur du capteur ou sa capacité maximale. La figure 2.10 montre une photo du dessous de la couche diélectrique.

La modalité statique est constituée d'une matrice de 28 taxels de 3.625×3.625 mm disposés sur une grille de 22×37 mm. Chaque taxel mesure indépendamment la pression appliquée sur sa surface. L'ensemble des taxels permettent donc d'obtenir une vue détaillée du motif de pression appliqué sur l'ensemble du capteur. La modalité statique peut mesurer des forces de 0 à 50 N à une fréquence de 60 Hz. Elle joue un rôle similaire aux mécanorécepteurs à action lente du système somato-sensoriel humain (corpuscules de Ruffini et disques de Merkel), soit de percevoir la pression de contact et la forme des objets.




Figure 2.10 Diélectrique microstructuré
Tirée de Le *et al.* (2017)

La modalité dynamique est composée d'un seul taxel distribué sur la surface du capteur entre les taxels de la modalité statique. Contrairement à la modalité statique, elle ne mesure pas directement la capacitance, mais plutôt la variation de capacitance à l'aide d'un amplificateur transimpédance. Elle mesure donc les variations de pression appliquée sur le capteur. Elle est acquise à une fréquence de 1 kHz et peut donc mesurer des signaux allant jusqu'à 500 Hz¹. On

¹ Selon le théorème d'échantillonnage de Nyquist-Shannon.

peut y voir un équivalent aux mécanorécepteurs à action rapide du système somatosensoriel humain (Corpuscules de Pacini et corpuscules de Meissner). Son rôle est donc de percevoir les vibrations et la texture des surfaces.

De plus, le capteur inclut une centrale inertielle, généralement connue sous le nom de IMU (*Inertial measurement unit*). Celle-ci permet d'ajouter deux modalités supplémentaires : un accéléromètre et un gyroscope. L'accéléromètre permet de percevoir des vibrations, les mouvements du système, ainsi que des perturbations externes dans trois axes. En combinaison avec la modalité dynamique, le capteur peut donc faire la différence entre des vibrations causées par l'objet en contact et une perturbation externe, comme le mouvement du robot. Le gyroscope permet de mesurer la rotation dans trois axes et donc de percevoir l'orientation du capteur dans l'espace. Les signaux de la centrale inertielle sont également acquis à une fréquence de 1 kHz. En mesurant l'accélération et l'orientation du capteur, ces deux modalités forment un équivalent de la proprioception humaine, soit la capacité à percevoir la position des différentes parties du corps.

Finalement, la surface externe du capteur est recouverte d'une couche de caoutchouc de silicone texturé afin de protéger le capteur et d'augmenter la friction de contact.

2.3 Création de l'ensemble de données

2.3.1 Processus d'acquisition

Le processus d'acquisition des données commence par fixer les paramètres à utiliser :

- Plaque échantillon
- Angle d'orientation de la plaque
- Poids appliqué sur le capteur
- Vitesse de déplacement

La surface du chariot est ensuite réglée à l'angle désiré, puis la plaque échantillon est appuyée sur les trois goupilles de positionnement et sécurisée en place par le bras de verrouillage. Le poids désiré est placé sur le rail du capteur tactile.

Afin de s'assurer que les données de position sont valides et répétables, une calibration du système est effectuée lors du démarrage et répétée en cas de dérive excessive. Pour ce faire, le chariot est déplacé en X- jusqu'à ce qu'il active l'interrupteur de fin de course. L'encodeur linéaire et le contrôleur du moteur sont mis à zéro à ce point. Ensuite, le chariot est déplacé en X+ jusqu'à ce qu'il active l'autre interrupteur de fin de course, où la position maximale est obtenue. La position de l'index de l'encodeur (un point fixe au centre de l'encodeur) est aussi enregistrée afin de vérifier la dérive du système. Si lors de l'acquisition, la position de l'index mesurée diverge de celle obtenue lors de la calibration, le système s'arrête automatiquement et l'utilisateur doit refaire une calibration avant de continuer. Le diagramme de flux de la boucle de calibration est présenté à la figure 2.11.




Figure 2.11 Diagramme de flux de la boucle de calibration

Une fois la calibration effectuée, le nombre d'acquisitions à réaliser est spécifié et la prise de données commence. Le capteur est déplacé sur la surface de la plaque échantillon pendant que le système enregistre les données. Une fois les acquisitions terminées, le chariot est ramené au point de départ puis le système se met en attente. Ce processus est répété pour chaque combinaison de paramètres.

Les paramètres suivants ont été utilisés pour acquérir les données :

- Angles d'orientation de la plaque : 0° , 45° , 90°
- Poids appliqué sur le capteur : 100 g, 200 g, 300 g
- Vitesse de déplacement ² : 30 mm/s

Chaque acquisition est sauvegardée dans un fichier CSV. À l'intérieur de chaque fichier, chaque ligne représente un point de données individuel. En plus des valeurs de chaque modalité (soit une pour la modalité dynamique, 28 pour les taxels statiques et 6 pour l'IMU), un horodatage (*timestamp*) et la position du capteur sur la plaque sont enregistrés. La fréquence d'enregistrement est de 1 kHz, soit la même que celle du capteur dynamique et de l'IMU. Puisque la modalité statique est échantillonnée à 60 Hz mais enregistrée à 1 kHz, les données sont répétées entre chaque mise à jour.

Les paramètres de l'acquisition ainsi que la date et l'heure sont enregistrés dans le nom du fichier afin d'identifier la source de chaque acquisition.

2.3.2 Préparation des données

Une fois les données brutes acquises, plusieurs étapes de traitement doivent être effectuées afin qu'elles puissent être utilisées pour entraîner un réseau de neurones. Les figures 2.12 et 2.13 présentent ces étapes de traitement.

Premièrement, afin de s'assurer que les données proviennent toutes d'un contexte équivalent, seulement les données où le capteur est déplacé à vitesse constante sont conservées. Puisque

² Cette vitesse a été sélectionnée selon les travaux de Fishel & Loeb (2012a).

le chariot accélère et décélère au début et à la fin du mouvement, le début et la fin de chaque acquisition sont tronqués jusqu'à ce qu'elle contienne uniquement les points où la vitesse correspond à la vitesse cible désirée. Une marge d'erreur est tolérée afin d'éviter d'éliminer des points où un retard sur la mise à jour de la position réelle changerait la vitesse calculée. De plus, afin de s'assurer que le capteur est entièrement en contact avec la plaque tout au long de l'acquisition, les données où le capteur dépasse de la plaque sont aussi tronquées.




Figure 2.12 Diagramme de flux de l'acquisition et du traitement des données

Deuxièmement, les données sont étiquetées afin d'identifier si elles contiennent un défaut ou non. Chaque acquisition est traitée séquentiellement. Pour ce faire, le masque binaire de la plaque correspondante est chargé en mémoire et orienté selon l'angle de la plaque lors de l'acquisition.

Ensuite, pour chaque point de données, la position du capteur mesurée par l'encodeur linéaire est utilisée pour extraire la région du masque binaire correspondante à la région de contact entre le capteur et la plaque à cet instant. Si la région extraite contient un défaut, ce point de données est étiqueté comme étant un défaut. Si ce n'est pas le cas, le point est étiqueté comme normal. Ce processus est répété pour tous les points de données. Les données ainsi que leurs étiquettes sont enregistrées dans de nouveaux fichiers CSV afin de les distinguer des données brutes. La sous-figure 2.13a présente le diagramme de flux de l'étiquetage.

Lorsque la région de contact entre le capteur et la plaque contient un défaut, le point de donnée est étiqueté comme défaut peu importe la "quantité" de défauts présents. Cela est particulièrement significatif lorsque le capteur entre en contact avec la bordure d'un défaut (ou lorsqu'il cesse d'être en contact). Dans ce cas, la grande majorité du capteur est en contact avec une surface normale, mais puisque le bord touche à un défaut, l'entièreté du point de données est considérée comme un défaut. Il y a donc un risque d'obtenir des échantillons étiquetés comme défauts alors qu'ils s'apparentent plus à un échantillon normal. Puisque nous utilisons des classes binaires qui ne peuvent pas refléter la proportion de défauts sur la surface, il est possible que le système soit parfois mis en erreur.

Une fois les données étiquetées, elles sont combinées sous la forme d'un ensemble de données en format HDF5. Ce format permet de stocker des données de manière structurée et d'y accéder et de les manipuler facilement. À l'intérieur du fichier HDF5, les données étiquetées provenant des fichiers CSV sont organisées par combinaisons de paramètres. Les paramètres utilisés sont sauvegardés comme attributs.

Afin d'obtenir un ensemble de données prêt à être utilisé, chaque acquisition est séparée en fenêtres de longueur n avec un chevauchement de 50%. Pour nos expériences, nous avons sélectionné une longueur n de 500 ms. Afin d'éviter que la position des fenêtres soit répétée entre les acquisitions, une valeur de décalage aléatoire entre 0 et n est utilisée comme point de départ. Le chevauchement permet d'augmenter significativement la quantité de données disponibles en plus de faire varier la position temporelle des défauts. À ce point, une ou des

étapes de prétraitement des données peuvent optionnellement être appliquées sur les fenêtres (par exemple : une étape de normalisation). Les fenêtres sont ensuite séparées en trois parties : les données, leurs étiquettes et leurs métadonnées (soit les paramètres de l'acquisition et la position du capteur). Finalement, les données, les étiquettes et les métadonnées sont séparées en ensembles d'entraînement et de test en fonction de leurs plaques correspondantes (voir le tableau 2.1). La sous-figure 2.13b présente le diagramme de flux de la séparation en fenêtres.




Figure 2.13 Diagrammes de flux des sous-procédés d'acquisition et de traitement des données

La figure 2.14 présente la structure de l'ensemble de données final.

Dans ce chapitre, nous avons présenté le système et les procédures qui ont été utilisés pour acquérir et préparer l'ensemble de données à partir de plaques échantillons. Dans les chapitres suivants, nous utiliserons cet ensemble de données pour déterminer si le capteur tactile capacitif CoRo permet de détecter la présence de défauts de surface dans le bois et, si oui, dans quelle mesure et dans quelles conditions.




Figure 2.14 Structure de l'ensemble de données

CHAPITRE 3

PREUVE DE CONCEPT

Dans ce chapitre, nous présenterons un système rudimentaire de détection de défauts. À l'aide de ce système, nous vérifierons s'il est possible de détecter la présence de défauts sur une surface de bois à l'aide du capteur tactile CoRo. Nous utiliserons une approche naïve, qui consiste à fournir les données brutes à un algorithme d'apprentissage machine, sans effectuer de traitement ou d'optimisation prématurée.

3.1 Méthodologie

Puisque les données acquises par le capteur sont fondamentalement de nature temporelle, nous utiliserons un réseau de neurones récurrent de type *Long Short-Term Memory (LSTM)*. Le réseau est composé d'une seule couche *LSTM* de 128 unités et de la couche de sortie. Le nombre d'unités (128) a été choisi arbitrairement. Toutes les modalités du capteur sont concaténées et fournies au réseau simultanément. Le réseau de neurones a été entraîné avec une validation croisée (*k-fold*) de cinq.

3.2 Résultats

La performance obtenue par le réseau sur l'ensemble de données non traité est médiocre. La figure 3.1 présente la matrice de confusion des prédictions faites par le réseau sur l'ensemble de test. On peut voir que le réseau classifie tous les échantillons comme étant des défauts. Ceci est dû au fait que lorsque le réseau est incapable d'apprendre une représentation utile des données, le taux de classification peut être maximisé en classifiant toutes les données dans une seule classe. Le réseau obtient un taux de classification de 45.6% sur l'ensemble de test, ce qui correspond exactement au pourcentage de défauts dans cet ensemble. L'exactitude moyenne sur l'ensemble de validation est de $58.53 \pm 0.04\%$




Figure 3.1 Matrice de confusion de la classification sur l'ensemble de test

Ce résultat était toutefois attendu. En effet, puisque les données sont fournies à l'état brut, il est difficile d'entraîner un réseau adéquatement. Chaque élément du capteur possède un biais différent que le réseau doit apprendre, mais qui n'offre pas d'information sur la surface. Considérons la modalité statique par exemple : les 28 taxels ne sont pas calibrés pour fournir la même valeur lorsque soumis à une même pression. La figure 3.2 montre la valeur moyenne (en nombre de comptes) mesurée par les taxels lorsqu'aucune force n'est appliquée sur le capteur. On peut y voir que les valeurs de taxels adjacents peuvent varier énormément. De plus, puisque les données ont été acquises avec différents niveaux de force appliqués sur le capteur, la valeur moyenne des taxels de la modalité statique varie aussi entre les acquisitions.

Lors de l'entraînement, le réseau doit donc apprendre à faire la différence entre le biais inhérent des taxels, la variation causée par la force appliquée sur le capteur et la variation causée par la présence de défauts. Or, pour la détection de défauts, seulement cette dernière contient de l'information pertinente.

15566	12544	16784	10512
21431	15590	10731	10869
26201	9902	10086	10197
35819	9868	9827	10056
35608	10957	13538	15772
11150	35378	10857	15418
35510	10999	10326	16192

Figure 3.2 Valeurs mesurées par les taxels statiques au repos

Pour gérer ce problème, nous appliquons une étape simple de normalisation à l'ensemble de données. Pour ce faire, les *features* de chaque échantillon sont translatées et mises à l'échelle individuellement de telle manière à ce que leurs données soient distribuées sur l'intervalle $[-1 : 1]$ (selon l'équation 3.1). Cette opération de normalisation est effectuée à l'aide de la fonction *minmax_scale* de la librairie *Scikit-learn*. En théorie, cette transformation permet d'éliminer l'impact du biais inhérent du capteur, ainsi que celui de la pression appliquée sur le capteur. Les variations causées par les défauts devraient donc être plus faciles à discerner.

$$X_{norm} = scale \cdot X + b - X_{min} \cdot scale \quad (3.1a)$$

$$scale = \frac{a - b}{X_{max} - X_{min}} \quad (3.1b)$$

Où X sont les données à traiter, X_{max} et X_{min} sont les valeurs maximale et minimale de X respectivement, a et b sont les limites supérieure et inférieure de l'intervalle désiré respectivement, et X_{norm} sont les données normalisées.

Avec ce nouvel ensemble de données normalisé, un nouveau réseau est entraîné et testé. La figure 3.3 et le tableau 3.1 en présentent les résultats. La performance obtenue reste médiocre, mais contrairement au réseau précédent, le réseau parvient à apprendre une certaine représentation qui s’applique aussi à de nouvelles données. On remarque aussi que la performance sur l’ensemble de test est significativement plus basse que lors de l’entraînement et donc que la représentation apprise par le réseau n’est pas nécessairement valide pour de nouvelles données.




Figure 3.3 Matrice de confusion de la classification sur l’ensemble de test (avec normalisation)

Tableau 3.1 Performance du capteur avec normalisation

Itération	1	2	3	4	5	Test
Exactitude	0.66	0.67	0.67	0.67	0.69	0.58
Précision	0.70	0.70	0.71	0.72	0.73	0.54
Rappel	0.72	0.73	0.75	0.73	0.73	0.58

3.3 Discussion

Il est évident qu'un taux de classification de moins de 60% est loin d'être suffisant pour être utilisé dans un contexte réel, mais il indique tout de même que les données perçues par le capteur tactile contiennent un certain niveau d'information sur la présence de défauts de surface.

Nous pouvons donc conclure que l'utilisation du capteur tactile CoRo pour la détection de défauts de surface a du potentiel et mérite d'être étudiée plus en profondeur.

CHAPITRE 4

EXPLORATION DES MODALITÉS

Dans ce chapitre, nous étudierons la capacité de chaque modalité du capteur à détecter la présence de défauts. Les quatre modalités du capteur seront testées et optimisées séparément, puis les résultats seront analysés pour comprendre leurs forces et leurs limitations individuelles. Pour ce faire, nous considérerons différentes architectures de réseau, mais aussi différentes méthodes de représentation des données.

4.1 Méthodologie générale

Dans cette section, les éléments de méthodologie communs à chacune des modalités du capteur tactile seront présentés. Nous détaillerons le choix du seuil de classification et des métriques d'évaluation, les étapes de traitement des données et finalement la méthodologie d'entraînement.

4.1.1 Seuil de classification

Une prédiction produite par un classificateur binaire est un nombre réel entre zéro et un, dépendant du niveau de certitude du réseau. Puisque nous désirons une classification binaire (soit l'une ou l'autre des classes exclusivement), un seuil doit être établi pour séparer les classes. À cet effet, les données au-dessus de ce seuil sont considérées comme étant positives (1), et celles en dessous sont considérées comme négatives (0). Plus un résultat est aux extrémités, plus le réseau est certain que la classification est correcte. Par exemple, une prédiction de 0.99 indique que le réseau est presque certain qu'il s'agit d'un positif, tandis qu'une prédiction de 0.51 est aussi considérée comme un positif, mais avec peu de certitude. Plus le seuil est élevé, moins il y aura de faux positifs, mais plus il y aura de faux négatifs. Naturellement, l'inverse se produit si le seuil est bas. Couramment, le seuil est fixé au centre de la plage de valeurs, soit 0.5.

Or, le choix de ce seuil doit être effectué en fonction du rôle concret du classificateur et des conséquences de la classification, et non pas simplement en minimisant le nombre de faux positifs/négatifs.

Considérons une entreprise produisant des meubles de luxe qui désire effectuer l'assurance qualité à l'aide d'un système automatisé de détection de défauts. Si une pièce contenant un défaut est ignorée et qu'elle est vendue à un client, la réputation de la compagnie pourrait en souffrir considérablement. Au contraire, si une pièce intacte est identifiée comme non conforme, une inspection manuelle supplémentaire est nécessaire pour confirmer la qualité de la pièce, ce qui ne représente pas un coût significatif en comparaison. Les résultats possibles du système de détection sont présentés à la figure 4.1.

		<i>Classification réelle</i>	
		Non-Conforme	Conforme
<i>Classification du système</i>	Non-Conforme	Pièce non-conforme rejetée	Inspection manuelle inutile (Faux Positif)
	Conforme	Pièce non-conforme acceptée (Faux Négatif)	Pièce conforme acceptée

Figure 4.1 Résultats possibles d'un système de détection de défauts

Dans ce cas, obtenir un faux négatif est clairement plus grave qu'un faux positif. Le seuil de décision du système devrait donc être faible pour s'assurer que les pièces non conformes soient détectées. Par le fait même, il est possible que plus de pièces conformes soient identifiées comme non conformes (faux positifs), mais le coût de laisser passer des défauts est plus important que le coût de la main-d'œuvre associée aux inspections manuelles supplémentaires.

Or, si le même classificateur est utilisé dans un contexte différent, un seuil faible n'est pas nécessairement approprié. Par exemple, si la compagnie produit plutôt des pièces bon marché en grand volume, réduire le coût associé à l'inspection manuelle des pièces serait beaucoup plus important que de s'assurer que toutes les pièces sont conformes. Dans ce cas, le seuil de détection devrait être élevé pour que le nombre de pièces devant être inspectées manuellement soit réduit, même si quelques pièces non conformes sont ignorées.

Il est important de noter que les facteurs qui influencent le choix du seuil de classification sont indépendants du système de détection lui-même. Une entreprise désirant utiliser un tel système doit analyser s'il est préférable de minimiser le nombre de pièces non conformes, le temps d'inspection manuelle, ou un entre-deux ; et ce, en fonction de ses standards de qualité et du coût de sa main-d'œuvre.

Puisque cette analyse dépend du contexte spécifique d'une entreprise réelle, elle est hors du contexte de ce mémoire. Un seuil est toutefois nécessaire pour le fonctionnement du système, donc nous utiliserons simplement la valeur moyenne entre les deux classes, soit 0.5.

4.1.2 Métriques

Afin d'analyser correctement la performance d'un système, il est nécessaire de choisir des métriques appropriées. En effet, bien qu'il existe une grande variété de métriques pouvant être appliquées à la classification de données, les informations qu'elles fournissent sur le système ne sont pas toutes pertinentes au contexte et à l'objectif de l'analyse. Dans le cadre de ce mémoire, nous avons choisi d'utiliser les métriques suivantes : l'exactitude, la précision, le rappel et l'erreur quadratique moyenne. De plus, nous utilisons aussi un outil qualitatif, soit la distribution des étiquettes prédites. Les raisons justifiant ces choix sont présentées dans les paragraphes suivants.

L'**exactitude** représente simplement le taux de données classifiées correctement. Il s'agit d'une mesure simple et facile à comprendre qui est couramment utilisée dans la recherche. Elle permet d'obtenir une idée générale de la performance d'un classificateur.

$$Exactitude = \frac{VP + VN}{P + N} \quad (4.1)$$

où, pour les équations 4.1 à 4.3, P et N sont les échantillons positifs et négatifs, VP et FP sont les vrais et faux positifs, et VN et FN sont les vrais et faux négatifs.

La **précision** représente le taux de vrais positifs parmi les échantillons ayant été classifiés comme positifs. On peut y voir un indicateur de la fiabilité de la classification d'un échantillon comme positif. Dans le contexte de ce mémoire, la précision nous donne une idée de la fréquence à laquelle le classificateur a raison lorsqu'il détecte un défaut. Une précision élevée indique que le classificateur produit peu de fausses alarmes.

$$Précision = \frac{VP}{VP + FP} \quad (4.2)$$

Le **rappel** représente le taux de vrais positifs parmi tous les échantillons positifs. Il s'agit d'un indicateur de la capacité du classificateur à bien identifier les échantillons positifs. Pour la détection de défauts de surface, il permet d'évaluer à quel point le système laisse passer des défauts. Un rappel élevé indique que le classificateur détecte presque tous les défauts.

$$Rappel = \frac{VP}{VP + FN} \quad (4.3)$$

L'**erreur quadratique moyenne** (EQM), comme son nom l'indique, représente l'erreur moyenne au carré entre les étiquettes prédites et leurs valeurs réelles. L'avantage principal de l'EQM est qu'il s'agit d'une métrique qui ne prend pas en compte le seuil de classification binaire. Les trois métriques précédentes considèrent les prédictions après qu'elles aient été discrétisées ce qui veut dire que le niveau de certitude du classificateur n'est pas pris en compte : des prédictions de

0.51 et 0.99 sont considérées comme identiques, alors que des prédictions de 0.49 et 0.51 sont classifiées différemment. Puisque l'EQM est calculée à partir des prédictions brutes, elle permet d'évaluer la performance du classificateur de manière plus nuancée. Une EQM faible indique que les étiquettes prédites par le classificateur sont proches des étiquettes réelles. Toutefois, il est important de mentionner que l'EQM peut être trompeuse puisqu'elle punit les erreurs majeures beaucoup plus que les erreurs mineures. Par exemple, un classificateur qui prédit toujours des valeurs un peu erronées pourrait avoir une EQM plus faible qu'un classificateur qui ne commet que quelques erreurs majeures.

$$EQM = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (4.4)$$

Où n est le nombre d'échantillons, Y sont les étiquettes réelles des échantillons, et $\hat{Y}$ sont les étiquettes prédites par le classificateur.

Finalement, nous considérons aussi la **distribution des étiquettes prédites**. Comme mentionné dans la section précédente, une prédiction effectuée par un classificateur binaire est un nombre réel entre zéro et un qui est ensuite discrétisé entre les deux classes. Toutefois, la valeur réelle de la prédiction donne de l'information sur le niveau de confiance du classificateur. En représentant la distribution des étiquettes réelles pour chaque classe dans un histogramme, il est possible de déceler des tendances relatives à comment le classificateur se comporte. Plus spécifiquement, on obtient une vue d'ensemble sur la manière dont le classificateur perçoit chaque classe. Il s'agit évidemment d'une analyse comportant un certain niveau de subjectivité, mais qui permet tout de même d'obtenir des indications pertinentes.

4.1.3 Traitement des données

En raison de la nature des composantes électroniques qui compose la modalité statique du capteur, les taxels ne sont pas parfaitement identiques les uns aux autres. Lorsqu'aucune force n'est appliquée sur le capteur, on pourrait s'attendre à voir la même valeur sur tous les taxels, mais ce n'est pas le cas : les taxels produisent des valeurs sur une plage d'environ 10000 à 35000.

Techniquement, cela ne devrait pas être un problème puisque les algorithmes que nous utilisons peuvent apprendre et annuler un biais. Par contre, c'est un élément de plus à apprendre pour représenter adéquatement les données, ce qui rend l'apprentissage plus difficile. Puisqu'il est facile de mesurer le biais des taxels, il est pertinent de prétraiter les données pour soustraire ce biais directement. Pour ce faire, nous avons enregistré plusieurs points de mesure sans appliquer de force sur le capteur et en avons pris la moyenne pour chaque taxel individuellement. Les valeurs résultantes représentent le biais du capteur et sont soustraites de chaque point de mesure pour l'ensemble des données. La figure 4.2 présente un exemple d'un signal brut de la modalité statique avec et sans calibration.




Figure 4.2 Mesure à vide du capteur avec et sans calibration

Il est possible de simplement soustraire les valeurs de biais, car les taxels varient de manière similaire par rapport à la même variation de force : une force qui fait augmenter un taxel d'une certaine valeur absolue, fera varier un autre taxel d'environ la même valeur absolue. Par exemple, si l'on applique une force faisant passer un taxel de 10000 (à vide) à 15000, un autre taxel ayant un biais de 20000 passera à environ 25000 lorsque soumis à la même force. La variation absolue (+5000) est similaire, même si le taux est différent (+50% vs +25%).

Il est important de mentionner qu'il ne s'agit bien d'une étape de calibration et non pas de normalisation. Une étape de normalisation permettrait aussi de retirer le biais du capteur, mais

elle transformerait également les données et leur distribution. Au contraire, la calibration permet d'éliminer le biais sans affecter le signal. De cette manière, il est par la suite possible de normaliser les données avec une méthode appropriée à chaque expérience.

4.1.4 Méthodologie d'entraînement et de test

Afin d'éviter que les hyperparamètres des réseaux correspondent à un minimum local, nous utilisons l'algorithme de *Bayesian Optimization* fourni par la librairie *Keras-Tuner* (O'Malley *et al.*, 2019). Cet algorithme permet d'optimiser une fonction dont les paramètres sont inconnus. Pour ce faire, l'algorithme commence par évaluer la fonction pour une série de points aléatoires et se sert des résultats pour définir une distribution a priori de son comportement. À partir de cette distribution, l'algorithme sélectionne le point où l'amélioration attendue est maximale comme prochain point à évaluer. Le résultat de cette évaluation est utilisé pour mettre à jour la distribution et obtenir une distribution a posteriori qui représente mieux le comportement de la fonction. À chaque fois que ce processus est répété, la distribution représente de mieux en mieux le comportement réel de la fonction et le maximum global peut être déterminé. Dans notre cas, la fonction à optimiser donne la performance attendue du réseau en fonction de ses hyperparamètres. Chaque évaluation de la fonction est effectuée trois fois afin de réduire l'impact de la variance de l'entraînement.

Une fois que l'algorithme se stabilise, la meilleure configuration d'hyperparamètres est sélectionnée et le modèle résultant est entraîné à l'aide d'une validation croisée (*k-fold*) de 5 sur l'ensemble d'entraînement puis évalué sur l'ensemble de test pour obtenir les résultats.

4.2 Modalité statique

Nous commençons par considérer la modalité statique du capteur tactile.

4.2.1 Architectures de réseaux considérées

LSTM Simple

Afin d'obtenir un résultat pouvant servir de référence, nous commençons par utiliser un réseau simple constitué d'une couche *LSTM* suivie de deux couches denses. Les données sont fournies sous la forme d'une matrice de deux dimensions (temps $\times$ taxels). Afin de minimiser le surentraînement du réseau, une valeur de *dropout* de 0.5 est appliquée sur les couches denses du réseau (Srivastava, Hinton, Krizhevsky, Sutskever & Salakhutdinov, 2014) et nous utilisons le *early stopping* pour arrêter l'entraînement lorsque la fonction objectif commence à augmenter sur l'ensemble de validation. De plus, une couche de *BatchNormalization* est ajoutée après la couche *LSTM* afin de s'assurer que la moyenne et la variance de ses valeurs de sortie restent près de zéro et de un respectivement (Laurent, Pereyra, Brakel, Zhang & Bengio, 2016). Dans cette section, ce réseau est identifié comme *LSTM Simple*.

Représentation spatiale des données

Par la suite, nous considérons l'impact d'utiliser une représentation spatiale des données. Les taxels qui composent le capteur statique sont physiquement disposés séquentiellement dans une matrice de 4×7 , or les données brutes sont sous la forme d'un vecteur unidimensionnel de 28 éléments. Lorsqu'elles sont sous cette forme, il est difficile de visualiser ce qui est perçu par le capteur, puisque deux éléments adjacents dans le vecteur ne proviennent pas nécessairement de taxels réellement adjacents (et donc que les relations spatiales entre éléments sont partiellement perdues).

Plutôt que de présenter les données sous la forme d'une matrice (temps $\times$ taxels), nous les réorganisons sous la forme d'une matrice (temps $\times$ 4 taxels $\times$ 7 taxels). De cette façon, la disposition des données reflète la manière dont les taxels sont réellement disposés sur le capteur. Nous pouvons donc traiter les données comme une série d'"images de pression", tel que mentionné par Kappasov *et al.* (2015) et présenté dans les travaux de Bekiroglu, Detry & Kragic

(2011a), Bekiroglu, Laaksonen, Jorgensen, Kyrki & Kragic (2011b) et Taunyazov *et al.* (2019). La figure 4.3 présente un exemple de l'avantage d'une telle transformation pour des données artificielles : le vecteur unidimensionnel ne semble pas contenir de motif significatif, or lorsque les mêmes données sont réorganisées en matrice, le chiffre "1" est clairement visible.




Figure 4.3 Représentation spatiale des taxels statiques

Cette manière de représenter les données nous permet d'utiliser des techniques qui peuvent extraire de l'information provenant de taxels adjacents. Nous faisons l'hypothèse que ces techniques permettront de mieux représenter les données et donc obtenir une meilleure classification.

CNN LSTM

Le deuxième réseau considéré est composé d'une seule couche de convolution dont le noyau de convolution est de la même dimension que l'image (4×7). Une activation *ReLU* est appliquée à la sortie des noyaux ainsi qu'une couche de *BatchNorm*. Afin de traiter la dimension temporelle des données, la couche de convolution et celle de *BatchNorm* sont contenues dans une couche *TimeDistributed* qui les répète sur chaque pas de temps. De cette manière, les mêmes convolutions

sont appliquées sur toute la durée de l'échantillon. Les *features maps* extraites de cette manière sont ensuite passées dans une couche *LSTM* suivie de deux couches denses. Ce deuxième réseau sera identifié comme *CNN LSTM*.

CNN Upscaled

Le troisième réseau considéré est composé de deux couches de convolution avec des noyaux 3×3 et une activation *ReLU*, chacune suivie d'une couche de *MaxPooling* et de *BatchNorm*. Ces couches sont ici aussi contenues dans une couche *TimeDistributed* et suivies d'une couche *LSTM* et de deux couches denses. Puisque la résolution initiale des données ne permet pas d'utiliser un réseau profond, les images de pression sont agrandies jusqu'à une taille de 20×35 par interpolation bicubique (soit un facteur de cinq) (Keys, 1981). Le facteur de cinq a été choisi afin de maximiser la taille de l'image sans dépasser les limites de mémoire vive de l'ordinateur. Ce réseau plus représentatif d'un réseau convolutif "classique" est désigné comme *CNN Upscaled*.

CNN Temporel

Le quatrième réseau considéré est basé sur l'usage de couches de convolution pour extraire des *features* dans la dimension temporelle, comme l'ont fait Roberge & Duchaine (2017). Pour ce faire, nous utilisons deux couches de convolution avec des noyaux de taille $3 \times 1 \times 1$ et une troisième avec un noyau de taille $5 \times 1 \times 1$. Ces dimensions correspondent à la dimension temporelle et aux deux dimensions spatiales respectivement (temps $\times$ largeur $\times$ hauteur). De cette manière, le réseau considère les variations de pression dans le temps sur chaque taxel indépendamment. Chaque couche de convolution est suivie d'une couche de *MaxPooling* et d'une couche *BatchNorm*. Les couches de convolution sont ensuite suivies de deux couches denses. Ce réseau est identifié comme *CNN Temporel*.

Encodage sparse

Finalement, nous considérons deux méthodes qui utilisent l'encodage sparse (*sparse coding*) pour obtenir une représentation de plus haut niveau des données. Cockburn, Roberge, Le, Maslyczyk & Duchaine (2017) ont précédemment utilisé l'encodage sparse pour encoder l'information provenant de la modalité statique du capteur et ainsi détecter la qualité d'une prise d'objet.

Pour ce faire, un dictionnaire de vecteurs de base est préalablement généré à l'aide des données non étiquetées. Ces vecteurs de base représentent des *features* de haut-niveau de l'ensemble de données et sont obtenus en effectuant une double minimisation de l'erreur de représentation (la capacité du dictionnaire à bien représenter les données) et de la sparsité de la reconstruction (le nombre de vecteurs de base utilisés pour reconstruire un échantillon). Le niveau de sparsité du dictionnaire est contrôlé par une pénalité de sparsité *EpsilonL1* (β).

Une fois la double minimisation terminée, le dictionnaire peut être utilisé pour encoder de nouveaux échantillons sous la forme d'une combinaison linéaire de ses éléments. À cet effet, l'algorithme fixe les coefficients de chaque vecteur de base en minimisant l'erreur de représentation et la sparsité de la reconstruction résultante. Le niveau de sparsité est ici contrôlé par une pénalité de sparsité *L1* (γ) plutôt que celle utilisée pour la création du dictionnaire, afin de contrôler le niveau de sparsité de chaque étape indépendamment. L'échantillon encodé prend la forme d'un vecteur composé des coefficients des vecteurs de base du dictionnaire.

Les paramètres que nous avons utilisés comme point de départ sont tirés de Cockburn *et al.* (2017), soit 29 vecteurs de base, $\beta = 1000$ et $\gamma = 950$. Tous les échantillons ont été utilisés pour la création du dictionnaire initial.

En ce qui a trait au nombre de vecteurs de base, les résultats présentés par Cockburn *et al.* (2017) montrent que la performance augmente considérablement jusqu'à environ 11, puis reste relativement stable au-delà de cette valeur. Nous avons donc choisi de conserver le même nombre

de vecteurs de base. Pour la pénalité de sparsité β , nos tests n'ont pas révélé d'effet significatif sur le dictionnaire résultant, nous avons donc choisi de conserver la valeur originale, soit $\beta = 1000$.

Nous avons ensuite testé l'impact du choix des échantillons utilisés lors de la création du dictionnaire. En excluant les échantillons normaux (sans défauts) et ceux comprenant des rayures, nous avons pu améliorer la sparsité et l'erreur de représentation moyenne. Ceci est potentiellement dû au fait que la surface de ces échantillons est moins complexe que celle des indentations et des arrachements et donc plus facile à représenter. En générant le dictionnaire uniquement avec les échantillons plus complexes, les vecteurs de base de celui-ci peuvent en quelque sorte être focalisés sur la représentation des irrégularités et ainsi mener à une meilleure performance générale.

Nous avons également remarqué que γ avait un effet significatif sur l'erreur de reconstruction et la sparsité. En effet, avec $\gamma = 950$, la sparsité moyenne est excellente (93%), mais l'erreur de reconstruction moyenne est très élevée (53%). Ceci est dû au fait que pour beaucoup d'échantillons, la pénalité associée au terme de sparsité excède largement celle associée au terme de l'erreur de représentation. Dans ces cas, la fonction objectif est minimisée avec un encodage extrêmement sparse (99%) qui représente très mal l'échantillon (95% d'erreur). Pour ces échantillons l'encodage résultant est peu utile pour la classification puisque presque toute l'information est perdue.

Nous avons testé plusieurs valeurs de γ afin de trouver une valeur appropriée. La figure 4.4 présente l'erreur de représentation moyenne et la sparsité moyenne pour les échantillons de chaque acquisition selon la valeur de γ utilisée lors de l'encodage.

Nous avons choisi d'utiliser $\gamma = 250$ puisque nous obtenons un bon niveau de sparsité moyen (79%) sans sacrifier l'erreur de représentation moyenne (12%). L'usage d'une pénalité de sparsité plus basse que celle de Cockburn *et al.* (2017) semble indiquer que notre ensemble de données est plus "complexe" à représenter. En effet, contrairement à une tâche de préhension d'objets où les images de pression sont généralement claires et définies en plus d'être statiques dans le temps, la détection de défauts de surface implique que le capteur est entièrement en contact avec

la surface en plus d'être en mouvement par rapport à celle-ci. L'information résultante nécessite ainsi plusieurs vecteurs de base actifs pour être encodée correctement.

Les paramètres que nous avons utilisés pour la création du dictionnaire sont donc : 29 vecteurs de base, $\beta = 1000$ et $\gamma = 250$. Les échantillons correspondants aux indentations et aux arrachements ont été sélectionnés pour la réalisation du dictionnaire. La figure 4.5 illustre les 29 vecteurs de base qui composent le dictionnaire. À la sous-figure 4.5b, un filtre bicubique est appliqué sur les vecteurs de base pour visualiser leur équivalent "réel".




Figure 4.4 Effet de γ sur la sparsité et l'erreur de représentation
Les points en gras représentent la moyenne pour chaque valeur de γ .

Sparse Coding (SVM)

La première méthode que nous avons testée est basée sur l'usage de machines à vecteur de support (SVM), comme l'ont fait Cockburn *et al.* (2017). Puisque les SVM acceptent uniquement des

vecteurs unidimensionnels et que nos données sont sous la forme de matrices (*temps* $\times$ *features*), nous devons transformer nos données. Pour ce faire, nous utilisons une combinaison de deux SVM en série. Le premier reçoit les échantillons encodés avec le dictionnaire et classifie chaque pas de temps individuellement, produisant ainsi un vecteur unidimensionnel dans le temps. Le deuxième prend ce vecteur et le classifie pour obtenir une étiquette correspondant à l'entièreté de la fenêtre. Cette méthode est identifiée par *Sparse Coding (SVM)*.




Figure 4.5 Dictionnaire utilisé pour l'encodage sparse

Sparse Coding (LSTM)

La deuxième méthode consiste à utiliser un réseau équivalent au réseau *LSTM Simple* introduit précédemment (soit une couche *LSTM* suivie de deux couches denses) pour classer directement les données encodées avec le dictionnaire. Cette méthode est identifiée par *Sparse Coding (LSTM)*.

4.2.2 Résultats

Les tableaux 4.1 et 4.2 présentent les résultats obtenus par chaque méthode sur les ensembles de validation et de test respectivement.

Tableau 4.1 Performance de la modalité statique sur l'ensemble de validation

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.76±0.01	0.79±0.02	0.71±0.04	0.16±0.01
CNN LSTM	0.75±0.01	0.77±0.02	0.70±0.05	0.17±0.00
CNN Upscaled	0.73±0.01	0.75±0.04	0.69±0.07	0.18±0.00
CNN Temporel	0.63±0.01	0.66±0.04	0.55±0.05	0.22±0.00
Sparse Coding (SVM)	0.61±0.01	0.60±0.01	0.68±0.02	0.39±0.01
Sparse Coding (LSTM)	0.67±0.01	0.66±0.02	0.72±0.02	0.20±0.00

Tableau 4.2 Performance de la modalité statique sur l'ensemble de test

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.70	0.51	0.69	0.20
CNN LSTM	0.68	0.49	0.70	0.23
CNN Upscaled	0.63	0.44	0.72	0.24
CNN Temporel	0.73	0.57	0.56	0.19
Sparse Coding (SVM)	0.50	0.34	0.66	0.50
Sparse Coding (LSTM)	0.47	0.32	0.66	0.29

On peut voir que le réseau *LSTM Simple* obtient une performance supérieure à toutes les autres méthodes avec une exactitude de 76% sur l'ensemble de validation. Cette performance diminue sur l'ensemble de test mais reste dans le même ordre de grandeur pour toutes les métriques

sauf la précision qui chute de 28%. Cette baisse est probablement causée par la distribution des classes de l'ensemble de test. En effet, contrairement à l'ensemble d'entraînement qui contient environ autant de défauts que de normaux, l'ensemble de test contient environ 69% d'échantillons normaux. Cette augmentation de la proportion d'échantillons normaux cause donc une augmentation du nombre de faux positifs et donc une diminution de la précision.

Les réseaux *CNN LSTM* et *CNN Upscaled* obtiennent une performance inférieure, mais globalement similaire au réseau *LSTM Simple*.

Le réseau *CNN Temporel* obtient une bonne performance sur l'ensemble de test avec 73% d'exactitude. Or, cette performance est supérieure à celle obtenue sur l'ensemble de validation. En observant la distribution des étiquettes prédites par le réseau, on voit que ses prédictions sont biaisées vers les normaux. Puisque l'ensemble de test est déséquilibré en faveur des échantillons normaux, il est normal que la performance de ce réseau soit meilleure. La performance obtenue sur l'ensemble de validation semble indiquer que le réseau n'est pas aussi performant de manière globale.

La méthode *Sparse Coding SVM* obtient seulement 61% d'exactitude sur l'ensemble de validation et 50% sur l'ensemble de test. Contrairement aux travaux de Cockburn *et al.* (2017) où de bons résultats ont été obtenus pour la classification de données statiques, nous tentons ici de classer des données temporelles. L'usage de SVM dans ce contexte ne semble pas être approprié.

Le réseau *Sparse Coding LSTM* obtient également une performance décevante sur les ensembles de test et de validation. Il obtient la meilleure performance sur l'ensemble de validation en termes de rappel, mais en observant la distribution des étiquettes prédites, on voit que les prédictions du réseau sont incohérentes et ne représentent pas un apprentissage réel.

Ces deux derniers résultats semblent indiquer que le *sparse coding* est peu intéressant dans notre contexte. Il est possible que nos données ne soient pas bien adaptées à être représentées adéquatement par le *sparse coding*.

Contrairement à notre hypothèse qu’une représentation spatiale des données améliorerait la performance en permettant d’extraire de l’information additionnelle, les réseaux basés sur cette représentation ne semblent pas offrir d’amélioration majeure par rapport au réseau *LSTM Simple*. Il est possible que la résolution faible du capteur limite la quantité d’information pouvant être acquise et donc qu’un réseau simplifié permette de bien classifier les données sans être susceptible au surentraînement.

4.2.2.1 Distribution des erreurs pour chaque type de défaut

Toutefois, les résultats présentés aux tableaux 4.1 et 4.2 ne donnent pas une vue complète de la situation. En effet, les trois types de défauts (rayures, indentations et arrachements) sont combinés en une seule classe, mais la performance du réseau n’est pas équivalente pour chacun. La figure 4.6 présente la distribution des étiquettes prédites par le réseau *LSTM Simple* sur l’ensemble de test avec chaque type de défaut affiché séparément. Pour une classification parfaite, la distribution devrait correspondre à un seul pic contenant 100% des échantillons à 1 pour les défauts et 0 pour les normaux.




Figure 4.6 Distribution des étiquettes prédites par le réseau *LSTM Simple* sur l’ensemble de test

Pour les indentations et arrachements (en vert et bleu respectivement), on peut voir un grand pic de densité pour les étiquettes près de 1, ce qui signifie qu'une bonne fraction des échantillons ont été classifiés correctement avec beaucoup de certitude. Au contraire, la distribution pour les rayures (en rouge) ne présente non seulement pas de pic près de 1, mais elle est presque identique à la distribution des échantillons normaux (en gris). Ceci indique que le réseau n'est pas capable de faire la différence entre une rayure et la surface normale et donc que ces échantillons sont essentiellement classifiés aléatoirement.

Il est possible de penser que ce phénomène est causé par l'architecture utilisée ; or, toutes les autres architectures testées présentent le même problème. Le facteur commun est l'utilisation de la modalité statique. En effet, la manière dont cette dernière est implémentée dans le capteur crée deux désavantages qui limitent sa capacité à capter les détails fins, comme les rayures.

D'abord, la résolution de la modalité statique est intrinsèquement limitée par la taille et la disposition des taxels sur le capteur. Même s'il est possible d'utiliser des techniques de traitement pour "augmenter" artificiellement la résolution, le capteur comporte uniquement 28 taxels et chaque taxel mesure 3.625×3.625 mm. De la même manière que la résolution d'une image limite le niveau de détail visuel qu'elle peut contenir, la résolution spatiale du capteur limite le niveau de détail qu'il peut capter.

De plus, la présence de la couche diélectrique qui permet au capteur de mesurer la pression signifie que les taxels ne sont pas indépendants les uns des autres. Puisqu'il est composé d'une seule couche uniforme de polyuréthane qui n'est pas parfaitement flexible, la pression appliquée à un point unique sur la surface externe du capteur est diffusée sur une plus grande surface lorsqu'elle atteint les taxels. Le motif de pression qui est perçu par le capteur est donc en fait une version floue du motif de pression réel. La rigidité du diélectrique limite aussi la capacité du capteur à se conformer précisément à la surface mesurée. Si un défaut est trop petit, le matériau ne peut pas se déformer assez pour épouser son contour.

Pour la majorité des indentations et des arrachements, ces désavantages n'ont pas d'effets majeurs puisque le défaut couvre assez de surface pour causer une variation de pression pouvant être

perçue par les taxels. Par contre, puisque les rayures sont fines et peu profondes, le motif de pression qui leur correspond est masqué par la structure du capteur et le bruit inhérent au signal et elles ne peuvent donc pas être perçues.

Puisque les résultats obtenus aux tableaux 4.1 et 4.2 sont affectés de manière significative par l'incapacité de la modalité statique à détecter la présence de rayures, il n'est pas possible de voir clairement la performance pouvant être obtenue sur les autres types de défauts. Nous avons donc répété les mêmes essais en excluant entièrement les rayures. Les données acquises sur les plaques contenant des rayures (soit les plaques 11, 41, 42 et 51) ont été retirées de l'ensemble de données. Puis, chaque réseau a été réentraîné entièrement et retesté selon la procédure établie précédemment.

Les tableaux 4.3 et 4.4 présentent les résultats obtenus sans les rayures. Afin de faciliter la comparaison, le tableau 4.5 présente les changements de performance entre les deux expériences ¹.

Tableau 4.3 Performance de la modalité statique sur l'ensemble de validation (sans rayures)

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.93±0.01	0.93±0.01	0.89±0.02	0.06±0.00
CNN LSTM	0.93±0.01	0.93±0.02	0.91±0.02	0.05±0.01
CNN Upscaled	0.92±0.01	0.93±0.02	0.87±0.03	0.06±0.08
CNN Temporel	0.81±0.01	0.79±0.02	0.72±0.04	0.14±0.01
Sparse Coding (SVM)	0.67±0.00	0.69±0.01	0.35±0.01	0.33±0.00
Sparse Coding (LSTM)	0.77±0.01	0.82±0.06	0.57±0.10	0.14±0.00

On peut voir que l'élimination des rayures a entraîné une augmentation majeure de la performance obtenue sur presque toutes les métriques pour tous les modèles.

Sur l'ensemble de validation, les réseaux *LSTM Simple*, *CNN LSTM* et *CNN Upscaled* obtiennent tous une excellente performance, presque identique sur toutes les métriques. En éliminant les rayures, ces réseaux deviennent capables de distinguer les défauts des normaux avec beaucoup plus de certitude.

¹ Soit la variation entre les résultats des tableaux 4.1 et 4.2 et ceux des tableaux 4.3 et 4.4.

Tableau 4.4 Performance de la modalité statique sur l'ensemble de test (sans rayures)

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.86	0.76	0.68	0.12
CNN LSTM	0.83	0.69	0.70	0.14
CNN Upscaled	0.85	0.70	0.77	0.12
CNN Temporel	0.84	0.70	0.73	0.12
Sparse Coding (SVM)	0.81	0.83	0.37	0.19
Sparse Coding (LSTM)	0.75	0.55	0.53	0.19

Tableau 4.5 Changements de performance de la modalité statique lorsque les rayures sont éliminées

Modèles	Δ Exactitude	Δ Précision	Δ Rappel	Δ EQM
LSTM Simple	+0.17 (+0.15)*	+0.14 (+0.25)	+0.18 (+0.01)	-0.11 (-0.08)
CNN LSTM	+0.19 (+0.15)	+0.15 (+0.20)	+0.21 (+0.00)	-0.12 (-0.09)
CNN Upscaled	+0.19 (+0.21)	+0.18 (+0.26)	+0.18 (+0.05)	-0.12 (-0.12)
CNN Temporel	+0.18 (+0.11)	+0.13 (+0.13)	+0.17 (+0.17)	-0.09 (-0.07)
Sparse Coding (SVM)	+0.06 (+0.31)	+0.09 (+0.50)	-0.33 (-0.29)	-0.06 (-0.31)
Sparse Coding (LSTM)	+0.10 (+0.28)	+0.16 (+0.23)	-0.15 (-0.13)	-0.06 (-0.10)

* Les valeurs sans parenthèses indiquent la variation entre les résultats obtenus avec les rayures et ceux obtenus sans les rayures sur l'ensemble de validation, alors que celles entre parenthèses indiquent la variation sur l'ensemble de test.

Une amélioration majeure est aussi présente sur l'ensemble de test pour toutes les métriques excepté le rappel, qui reste presque identique. En observant la distribution des étiquettes prédites par ces réseaux, on voit que cette discordance est causée par la mauvaise classification de certains défauts. En effet, lorsque les rayures sont présentes, les réseaux ont beaucoup de difficulté à séparer les échantillons contenant des défauts minimes (soit les échantillons contenant des rayures et ceux contenant les extrémités des indentations et des arrachements) des échantillons

normaux. Les étiquettes prédites pour ces deux types d'échantillons sont donc distribuées relativement uniformément entre les deux classes. Lorsque les rayures sont éliminées, les réseaux deviennent capables de différencier les deux classes puisqu'il y a moins de chevauchement entre elles.

Or, puisque les échantillons qui contiennent des défauts minimes sont très similaires aux échantillons normaux, ceux-ci sont maintenant classifiés comme normaux avec beaucoup de certitude. Ce phénomène est visible dans la figure 4.7 qui montre les distributions des étiquettes prédites par le réseau *LSTM Simple* sur l'ensemble de test avec et sans les rayures. Dans la sous-figure 4.7b, on voit qu'une partie des indentations et arrachements est classifiée comme des échantillons normaux avec certitude (soit une étiquette prédite de 0), ce qui n'est pas le cas lorsque les rayures sont présentes (sous-figure 4.7a). Pour ces deux types de défauts, le taux de rappel obtenu reste similaire, mais on voit tout de même un gain dans le niveau de certitude de la classification.

On peut aussi remarquer une légère variation réciproque entre la précision et le rappel. Plus le réseau est biaisé vers les défauts, plus la précision diminue et le rappel augmente.

Sur l'ensemble de validation, le réseau *CNN Temporel* obtient une moins bonne performance que les trois réseaux précédents (*LSTM Simple*, *CNN LSTM* et *CNN Upscaled*), mais on voit quand même une amélioration majeure en éliminant les rayures. La performance sur l'ensemble de test est également meilleure que sur l'ensemble de validation ce qui indique que ce réseau est biaisé envers les échantillons normaux. De plus, la distribution des étiquettes prédites (voir figure 4.8) montre que les prédictions sont faites avec moins de certitude. En effet, le réseau classifie les arrachements avec certitude, mais les indentations et les échantillons normaux sont répartis sur une plage beaucoup plus large (plutôt que d'être concentrées à 0 et 1 comme pour les trois réseaux précédents).

² Pour les figures qui présentent la distribution des valeurs prédites, il est important de noter que la densité maximale affichée peut varier.




Figure 4.7 Distribution des étiquettes prédites avec et sans rayures par le réseau *LSTM Simple* sur l'ensemble de test ²




Figure 4.8 Distribution des étiquettes prédites par le réseau *CNN Temporel* sur l'ensemble de test (sans rayures)

Tout comme précédemment, le réseau *Sparse Coding (LSTM)* et la méthode *Sparse Coding (SVM)* obtiennent une performance médiocre sur les ensembles de validation et de test. On voit

une amélioration pour l'exactitude, la précision et l'erreur quadratique moyenne, mais le rappel souffre considérablement.

4.2.3 Discussion

Dans cette section, nous avons démontré que la modalité statique du capteur tactile peut être utilisée pour détecter la présence de défauts sur une surface de bois. Elle est particulièrement adaptée à la détection de défauts majeurs comme les indentations et les arrachements. Par contre, dû à la manière dont elle est implémentée, elle est incapable de percevoir des défauts mineurs comme les rayures.

L'usage de couches *LSTM* semble être suffisant pour traiter les données de la modalité statique. En effet, le réseau *LSTM Simple* obtient une performance intéressante en classifiant de nouvelles données avec 86% d'exactitude.

Contrairement à notre hypothèse, le fait de représenter les données de manière spatiale ne semble pas avoir d'effet significatif sur la performance. Effectivement, les réseaux utilisant les couches de convolution spatiales (*CNN LSTM* et *CNN Upscaled*) obtiennent une bonne performance, mais ne semblent pas être supérieurs au réseau *LSTM Simple*.

Les méthodes basées sur le *sparse coding* (*Sparse Coding (SVM)* et *Sparse Coding (LSTM)*) ne démontrent pas d'apprentissage et ne sont donc pas appropriées pour ce contexte.

Finalement, l'utilisation de couches de convolution dans la dimension temporelle par le réseau *CNN Temporel* permet de détecter la présence de défauts relativement bien, mais n'est pas aussi performante que les réseaux basés sur la couche *LSTM*.

À la lumière de ces résultats, les limitations de la modalité statique du capteur tactile à détecter les défauts de surface semblent être beaucoup plus liées à sa conception mécanique et électrique, plutôt qu'à l'architecture de réseau utilisée et aux méthodes de traitement des données.

4.3 Accéléromètre

Dans cette section, nous traitons de l'accéléromètre intégré au capteur tactile.

4.3.1 Architectures de réseaux considérées

LSTM Simple

Nous commençons ici aussi par considérer un réseau simple comme référence. Il s'agit de la même architecture que celle utilisée pour la modalité statique, soit une couche *LSTM* suivie de deux couches pleinement connectées. Une couche de *BatchNorm* est ajoutée après la couche *LSTM* ainsi qu'un *dropout* de 0.5 sur les couches pleinement connectées. Ce réseau est identifié comme *LSTM Simple*.

CNN Temporel

Le deuxième réseau considéré est l'équivalent du réseau *CNN Temporel* utilisé pour la modalité statique. Il utilise deux couches de convolution avec des noyaux de taille $3 \times 1 \times 1$ et une troisième avec un noyau de taille $5 \times 1 \times 1$ afin d'extraire de l'information dans la dimension temporelle. Chaque couche de convolution est suivie d'une couche de *MaxPooling* et d'une couche *BatchNorm*. Les couches de convolution sont ensuite suivies de deux couches denses. Ce réseau est identifié comme *CNN Temporel*.

Domaine fréquentiel

Les réseaux suivants considèrent les données dans le domaine fréquentiel plutôt que dans le domaine temporel.

Bien que le domaine temporel peut être compris de manière intuitive et utilisé pour extraire de l'information utile, il n'est pas toujours le plus approprié. Beaucoup de signaux naturels (sons, lumière, etc.) sont en fait composés d'une superposition de plusieurs signaux à différentes

fréquences. Dans le domaine temporel, puisque chaque composante du signal varie en même temps que les autres, il est difficile de percevoir cette superposition et de les isoler.

Au contraire, lorsqu'un signal est présenté dans le domaine fréquentiel, ses composantes sont séparées et peuvent donc être étudiées de manière indépendante. La figure 4.9 montre un exemple d'un signal et de sa transformée de Fourier (obtenue par la transformée de Fourier rapide (FFT)). Dans le domaine temporel, le signal varie continuellement et il est difficile d'identifier ses composantes, alors que dans le domaine fréquentiel, on voit facilement que le signal est en fait la sommation de trois sinus d'amplitude décroissante à 37 Hz, 125 Hz et 175 Hz.




Figure 4.9 Exemple de transformation d'un signal du domaine temporel vers le domaine fréquentiel

Lorsque le capteur tactile est déplacé sur une surface, l'interaction entre les deux cause des vibrations qui peuvent être mesurées. Les caractéristiques de la surface, plus particulièrement sa texture (incluant les défauts), influencent directement la composition fréquentielle de ces vibrations (Hollins & Risner, 2000). En transformant les signaux dans le domaine fréquentiel, nous pouvons isoler les fréquences qui les composent et ainsi obtenir de l'information sur les

caractéristiques de la surface. Nous faisons l'hypothèse que représenter les données dans le domaine fréquentiel permettra d'améliorer la performance du système.

CNN Spectrogramme

La première approche que nous considérons est basée sur l'usage de spectrogrammes.

Un spectrogramme permet de contourner une des principales limites de la transformée de Fourier. En effet, puisque celle-ci utilise des sinusoides complexes parfaitement localisées en fréquence et infinies dans le temps, elle transforme le signal dans le domaine fréquentiel, mais ne peut pas fournir d'information sur la localisation temporelle de ses composantes. Ceci n'est pas un problème lorsque le signal est stationnaire (ce qui veut dire que ses propriétés ne varient pas dans le temps), mais s'il ne l'est pas, la localisation temporelle des variations est perdue. Puisque les défauts que nous étudions sont des discontinuités dans la surface, ce qui implique implicitement des signaux non stationnaires, la FFT ne peut pas être utilisée directement. Pour remédier à ce problème, la transformée de Fourier à court terme (*Short-Term Fourier Transform (STFT)*) est utilisée pour créer un spectrogramme du signal. La STFT consiste essentiellement à diviser dans le temps le signal original en plusieurs fenêtres et à effectuer la FFT sur chacune d'elles. De cette manière, la localisation temporelle est perdue à l'intérieur de chaque fenêtre individuellement, mais une partie en est conservée pour le signal entier puisque les fenêtres sont elles-mêmes distribuées dans le temps. Le spectrogramme est ainsi une représentation du contenu fréquentiel du signal dans le temps. Pour obtenir une meilleure résolution temporelle et réduire les effets de frontière, les fenêtres peuvent être chevauchées.

Chaque canal de l'accéléromètre a été traité avec la STFT pour générer des spectrogrammes de forme (temps $\times$ fréquences) où les coefficients indiquent l'intensité des bandes de fréquences dans chaque fenêtre. Les spectrogrammes ont été générés avec une longueur de fenêtre de 128 échantillons, 50% de chevauchement et une fenêtre de Hanning.

La figure 4.10 présente un exemple du spectrogramme du signal acquis par l'axe X de l'accéléromètre.




Figure 4.10 Spectrogramme du signal de l'axe X de l'accéléromètre

On peut voir que le spectrogramme est dominé par une bande très élevée à environ 250 Hz (correspondant aux vibrations causées par le moteur du montage expérimental) qui masque la présence de motifs à plus basse intensité. Afin de réduire l'impact des valeurs élevées, nous effectuons les étapes de traitement présentées aux équations 4.5a et 4.5b.

$$X = X + 1 \quad (4.5a)$$

$$X_{Norm} = 10 * \log_{10}(X) \quad (4.5b)$$

où X représente les coefficients bruts et X_{Norm} , les coefficients traités.

En prenant 10 fois le logarithme en base 10 des valeurs du spectrogramme, nous obtenons des valeurs en décibel (par rapport à une valeur arbitraire de 1). L'équation 4.5a assure que le spectrogramme normalisé contient uniquement des valeurs positives en ajoutant 1 à tous les coefficients (puisque le logarithme en base 10 est positif pour $X > 1$). La figure 4.11 montre le même spectrogramme avant et après le traitement des données. Après le traitement des données, on peut voir des motifs qui n'étaient pas apparents précédemment.




Figure 4.11 Effet du traitement du spectrogramme

Les spectrogrammes traités sont ensuite séparés en fenêtres pour obtenir l'ensemble de données. Celui-ci est utilisé pour entraîner un réseau CNN composé de trois couches de convolution (chacune suivie d'une couche de *BatchNorm* et une de *Max pooling*) et de deux couches denses. Ce réseau est identifié comme *CNN Spectrogramme*.

CNN Scalogramme

La deuxième approche que nous considérons est basée sur l'usage de scalogrammes réalisés avec la transformée en ondelettes continue (*Continuous Wavelet Transform (CWT)*).

Bien que les spectrogrammes permettent de visualiser les variations du contenu fréquentiel d'un signal dans le temps, ils comportent tout de même une lacune majeure. En effet, le fait de séparer le signal en fenêtres pour améliorer la résolution temporelle cause une réduction proportionnelle de la résolution fréquentielle. Ceci est dû au principe d'incertitude de Gabor (voir équation 4.6) qui impose fondamentalement une limite minimale aux incertitudes fréquentielles et temporelles pouvant être atteintes simultanément (Hall, 2014).

$$\sigma_t \cdot \sigma_f \geq \frac{1}{4\pi} \quad (4.6)$$

où σ_t et σ_f sont les écarts types des estimations de temps et de fréquence respectivement.

Ce principe implique que plus la précision temporelle est augmentée en réduisant la taille des fenêtres, plus la précision fréquentielle est réduite (et inversement en augmentant la taille des fenêtres). Puisqu'il s'agit d'une propriété fondamentale des signaux, cette limite ne peut pas être contournée. La figure 4.12 illustre ce compromis.

Cette limite veut dire que la STFT n'est pas bien adaptée pour analyser des signaux contenant des composantes transitoires. En effet, puisque celles-ci sont généralement de courte durée, il est nécessaire d'utiliser une largeur de fenêtre courte pour les localiser dans le temps. Par le fait même, la résolution en fréquence est diminuée pour l'entièreté de la plage. Or, pour beaucoup de signaux naturels, les composantes à haute fréquence sont généralement de courte durée et les composantes à basse fréquence sont de longue durée (Polikar, 1996). Il serait donc préférable d'utiliser une largeur de fenêtre adaptée à chaque bande de fréquence pour obtenir la meilleure résolution sur toute la plage de fréquences.




Figure 4.12 Compromis entre la résolution temporelle et fréquentielle pour la STFT

C'est ce que la CWT permet d'effectuer en analysant le signal à différentes résolutions simultanément. Plutôt que d'utiliser des sinusoides complexes avec une largeur de fenêtre fixe, celle-ci utilise une oscillation limitée dans le temps appelée ondelette qui est simultanément dilatée (pour couvrir le domaine fréquentiel) et translatée (pour couvrir le domaine temporel). La transformée en ondelettes continue est donnée par l'équation 4.7 tirée de Polikar (1996).

$$CWT_x^\psi(\tau, s) = \frac{1}{\sqrt{|s|}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t - \tau}{s} \right) dt \quad (4.7)$$

où τ et s sont les paramètres de translation et de dilatation respectivement et ψ^* est la conjuguée complexe de l'ondelette mère.

Cette dernière est la fonction qui est dilatée et translatée pour générer toutes les ondelettes utilisées par la transformée. La figure 4.13 montre un exemple d'ondelette, plus particulièrement l'ondelette de Morlet.

Puisque les ondelettes sont elles-mêmes localisées dans le temps, elles jouent un rôle équivalent aux fenêtres de la STFT en localisant les composantes du signal dans le temps. Cependant, contrairement à la STFT dont la largeur de fenêtre est fixe, la dilatation de l'ondelette mère entraîne non seulement son élargissement dans le temps, mais aussi une diminution simultanée de sa fréquence. La largeur de l'ondelette est donc liée à la fréquence du signal qu'elle couvre, offrant ainsi de petites fenêtres pour les hautes fréquences et de grandes fenêtres pour les basses fréquences.

Le principe d'incertitude de Gabor s'applique ici aussi, mais les résolutions temporelles et fréquentielles varient en fonction du facteur de dilatation s . La figure 4.14 montre comment la CWT permet de localiser simultanément les composantes d'un signal dans les domaines temporel et fréquentiel pour les hautes et basses fréquences respectivement.

Wang, Qi, Wu & Hou (2007) ont démontré le potentiel de la transformée en ondelettes en l'appliquant à la détection de défauts dans le bois à l'aide d'un capteur ultrasonique.




Figure 4.13 Ondelette de Morlet
Tiré du domaine public, <https://commons.wikimedia.org/w/index.php?curid=225627>

En effectuant la transformée en ondelette continue sur chaque canal de l'accéléromètre, nous obtenons des scalogrammes de forme (temps $\times$ dilatation³), où les coefficients indiquent l'intensité du signal dans le temps et en fréquence. Les scalogrammes ont été générés à l'aide de la librairie *Ssqueezepy* (Muradeli, 2020) avec une ondelette de Morse généralisée et 16 valeurs de dilatation par octave (soit les paramètres par défaut de la librairie). Puisque les scalogrammes générés sont de très haute résolution, ils ont été réduits par un facteur de 4 afin de maximiser leur taille sans dépasser les limites de mémoire vive de l'ordinateur.

La figure 4.15 présente un exemple du scalogramme du signal acquis par l'axe X de l'accéléromètre.

³ Les scalogrammes sont représentés en termes du facteur de dilatation s plutôt que de la fréquence, mais on peut y voir un équivalent.




Figure 4.14 Résolution temporelle et fréquentielle de la transformée en ondelettes continue




Figure 4.15 Scalogramme du signal de l'axe X de l'accéléromètre

Comme pour la méthode précédente, ils ont ensuite été séparés en fenêtres afin de former l'ensemble de données. Celui-ci a été utilisé pour entraîner un réseau CNN composé de quatre couches de convolution (chacune suivie d'une couche de *BatchNorm* et une de *Max pooling*) et de deux couches denses. Ce réseau est identifié comme *CNN Scalogramme*.

4.3.2 Résultats

Les tableaux 4.6 et 4.7 présentent les résultats obtenus par chaque méthode sur les ensembles de validation et de test respectivement.

Tableau 4.6 Performance de l'accéléromètre sur l'ensemble de validation

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.51±0.01	0.51±0.02	0.63±0.30	0.25±0.00
CNN Temporel	0.71±0.01	0.69±0.01	0.74±0.02	0.19±0.00
CNN Spectrogramme	0.80±0.01	0.82±0.02	0.86±0.01	0.14±0.01
CNN Scalogramme	0.76±0.02	0.78±0.04	0.88±0.05	0.16±0.01

Tableau 4.7 Performance de l'accéléromètre sur l'ensemble de test

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.51	0.33	0.59	0.25
CNN Temporel	0.62	0.40	0.48	0.24
CNN Spectrogramme	0.60	0.52	0.42	0.28
CNN Scalogramme	0.52	0.47	0.83	0.31

En observant la distribution des étiquettes prédites sur l'ensemble de test par les réseaux *LSTM Simple* et *CNN Temporel* (montrées à la figure 4.16), on peut voir qu'ils n'ont pas appris de représentation utile des données. Ces deux architectures ne semblent donc pas être appropriées pour l'accéléromètre.

Le réseau *CNN Spectrogramme* obtient une bien meilleure performance sur l'ensemble de validation avec 80% d'exactitude. Par contre, cette performance diminue considérablement sur l'ensemble de test. Cette baisse est probablement causée par le surentraînement du réseau et la présence de rayures. En effet, la précision de 82% et le taux de rappel de 86% indique que les défauts sont classifiés assez bien. Or, lorsque l'on regarde la distribution des étiquettes prédites sur l'ensemble de test (voir figure 4.17), on voit que les rayures sont majoritairement classifiées comme étant des échantillons normaux. Le réseau a donc sans doute appris à reconnaître les échantillons contenant des rayures dans l'ensemble de validation, mais cette représentation est trop spécifique et n'est pas applicable à de nouveaux échantillons. Toutefois, il est intéressant de noter que les échantillons normaux et les arrachements montrent un pic d'échantillons classifiés correctement.




Figure 4.16 Distribution des étiquettes prédites par les réseaux *LSTM Simple* et *CNN Temporel* sur l'ensemble de test pour l'accéléromètre




Figure 4.17 Distribution des étiquettes prédites par le réseau *CNN Spectrogramme* sur l'ensemble de test pour l'accéléromètre

Le réseau *CNN Scalogramme* obtient des résultats moins bons que *CNN Spectrogramme*, mais tout de même meilleurs que *LSTM Simple* et *CNN Temporel*. Le fait que le taux de rappel reste

élevé sur l'ensemble de test (83%) alors que l'exactitude et la précision chutent indiquant que le réseau est biaisé et qu'il classifie une partie des échantillons normaux comme étant des défauts.

4.3.2.1 Distribution des erreurs pour chaque type de défaut

Tout comme pour la modalité statique, toutes les architectures que nous avons testées sont influencées négativement par la présence de rayures. Ceci est probablement dû à la conception mécanique du capteur. En effet, puisque l'accéléromètre ne perçoit pas directement la surface, mais plutôt les vibrations causées par l'interaction du capteur avec la surface de l'objet, la nature de ces interactions affecte directement ce qui est perçu. Dans ce contexte, la surface relativement lisse du capteur est une limitation puisqu'elle ne produit pas autant de vibrations qu'une surface texturée (comme les empreintes digitales). Il est plausible que le capteur n'interagisse tout simplement pas assez avec les rayures pour produire un signal mesurable par l'accéléromètre.

Afin d'évaluer la performance de l'accéléromètre sur les autres types de défauts, nous avons répété les mêmes essais en excluant les plaques contenant des rayures (soit les plaques 11, 41, 42 et 51). Les tableaux 4.8 et 4.9 présentent les résultats sur les ensembles de validation et de test respectivement. Le tableau 4.10 présente les variations entre les deux expériences afin de faciliter la comparaison.

Tableau 4.8 Performance de l'accéléromètre sur l'ensemble de validation (sans rayures)

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.64±0.03	0.60±0.05	0.34±0.14	0.22±0.01
CNN Temporel	0.84±0.01	0.79±0.03	0.82±0.05	0.11±0.01
CNN Spectrogramme	0.87±0.01	0.84±0.03	0.85±0.03	0.10±0.00
CNN Scalogramme	0.96±0.00	0.96±0.01	0.95±0.02	0.03±0.00

Tableau 4.9 Performance de l'accéléromètre sur l'ensemble de test (sans rayures)

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.62	0.33	0.38	0.24
CNN Temporel	0.65	0.37	0.42	0.28
CNN Spectrogramme	0.66	0.56	0.37	0.29
CNN Scalogramme	0.72	0.67	0.62	0.24

Tableau 4.10 Changements de performance de l'accéléromètre lorsque les rayures sont éliminées

Modèles	Δ Exactitude	Δ Précision	Δ Rappel	Δ EQM
LSTM Simple	+0.13 (+0.11)*	+0.08 (-0.00)	-0.29 (-0.21)	-0.03 (-0.01)
CNN Temporel	+0.13 (+0.03)	+0.10 (-0.02)	+0.08 (-0.06)	-0.08 (+0.03)
CNN Spectrogramme	+0.07 (+0.06)	+0.02 (+0.04)	-0.01 (-0.05)	-0.04 (+0.02)
CNN Scalogramme	+0.20 (+0.21)	+0.18 (+0.19)	+0.07 (-0.21)	-0.13 (-0.07)

* Les valeurs sans parenthèses indiquent la variation entre les résultats obtenus avec les rayures et ceux obtenus sans les rayures sur l'ensemble de validation, alors que celles entre parenthèses indiquent la variation sur l'ensemble de test.

Même avec le retrait des rayures, les réseaux *LSTM Simple* et *CNN Temporel* ne sont pas capables d'apprendre une représentation utile des données, comme on peut voir au tableau 4.9. Ceci semble confirmer que ces méthodes ne sont pas appropriées pour l'accéléromètre. La figure 4.18 montre la distribution de leurs prédictions sur l'ensemble de test sans rayures. On peut y voir que le réseau *LSTM Simple* classe tous les types d'échantillons environ de la même manière et que le réseau *CNN Temporel* est complètement biaisé envers les échantillons normaux.




Figure 4.18 Distribution des étiquettes prédites par les réseaux *LSTM Simple* et *CNN Temporel* sur l'ensemble de test pour l'accéléromètre (sans rayures)

Alors que le réseau *CNN Spectrogramme* était précédemment capable de classifier les arrachements avec un certain niveau de succès, l'élimination des rayures semble avoir biaisé le réseau envers les échantillons normaux. Sur l'ensemble de test, la performance obtenue par le réseau est médiocre avec une diminution du taux de rappel de 0.05 et une augmentation de l'EQM de 0.02 (Voir tableau 4.10).

Pour le réseau *CNN Scalogramme*, le retrait des rayures entraîne une amélioration majeure pour toutes les métriques, excepté le taux de rappel sur l'ensemble de test (Voir tableau 4.10). Or, le taux de rappel élevé obtenu précédemment était en partie causé par un biais envers les défauts. Sans ce biais, une partie des défauts sont classifiés incorrectement et le taux de rappel est réduit en conséquence. Pour la même raison, on voit que la précision est augmentée puisque les échantillons normaux ne sont plus classifiés comme des défauts. De plus, une partie de la diminution est causée par le fait que le réseau peut séparer les classes avec plus de confiance. Puisque la présence de rayures causait de la confusion entre les deux classes, les échantillons

contenant des défauts minimes étaient distribués relativement uniformément entre celles-ci. Sans les rayures, ces échantillons sont maintenant classifiés comme étant normaux. La distribution des étiquettes prédites est présentée à la figure 4.19. On peut y voir que les échantillons normaux et les arrachements sont très bien classifiés alors que les indentations ne le sont pas. Ceci s'explique par le fait que la transformée en ondelettes est particulièrement bien adaptée à détecter les signaux transitoires. Contrairement aux arrachements, les indentations ont des contours plus lisses et sont par conséquent moins susceptibles de générer des signaux transitoires. Ce type de défaut est donc difficile à distinguer des échantillons normaux.




Figure 4.19 Distribution des étiquettes prédites par le réseau *CNN Scalogramme* sur l'ensemble de test pour l'accéléromètre (sans rayures)

4.3.3 Discussion

Dans cette section, nous avons démontré que l'accéléromètre du capteur Tactile CoRo peut être utilisé pour la détection de défauts de surface.

Cependant, sa capacité à percevoir les défauts de manière fiable semble être limitée aux arrachements. L'accéléromètre ne peut pas être utilisé pour détecter la présence de rayures et sa capacité à détecter les indentations est limitée.

Les réseaux qui traitent les signaux de l'accéléromètre dans le domaine temporel (*LSTM Simple* et *CNN Temporel*) n'ont pas permis de détecter la présence de défauts, ils ne peuvent donc pas être utilisés pour cette application.

Conformément à notre hypothèse, la représentation des signaux dans le domaine fréquentiel est prometteuse. Cependant, il est nécessaire d'utiliser une méthode spécifiquement adaptée pour les signaux transitoires, comme le réseau *CNN Scalogramme*. En effet, le réseau *CNN Spectrogramme* n'a pas été capable de classifier les échantillons correctement. Ceci indique que l'information utile dans les signaux de l'accéléromètre est principalement contenue sous la forme de variations transitoires créées par l'interaction entre la surface du capteur et les défauts. De plus, la puissance de ces deux réseaux les rend vulnérables au surentraînement, il est donc nécessaire d'y porter une attention particulière.

À la lumière de ces résultats, il apparaît que l'accéléromètre peut être utilisé pour détecter la présence d'arrachements, mais il est autrement limité par la conception mécanique du capteur tactile.

4.4 Gyroscope

Dans cette section, nous traitons du gyroscope intégré au capteur tactile.

4.4.1 Architectures de réseaux considérées

Dans la littérature existante, l'accéléromètre et le gyroscope sont généralement utilisés simultanément, car ils sont le plus souvent implémentés par un seul IMU qui acquiert les données des deux modalités à la même fréquence (tel que présenté à la section 2.2.3). Pour ce faire, les trois axes de l'accéléromètre peuvent être concaténés aux trois axes du gyroscope pour former un seul vecteur de données.

Lima, da Fonseca, de Oliveira, Zhu & Petriu (2020) ont démontré ce principe en combinant les signaux d'un IMU et d'un baromètre pour classifier différentes textures de surfaces avec

succès. Kwiatkowski, Cockburn & Duchaine (2017) ont utilisé une approche similaire pour évaluer la qualité de prises d'objets. Puisque les données concaténées de l'accéléromètre et du gyroscope peuvent être traitées par un seul réseau, il semble raisonnable de croire que les mêmes architectures de réseaux devraient être applicables même lorsqu'ils sont considérés séparément.

Nous avons donc décidé d'utiliser les mêmes architectures de réseaux pour le gyroscope que celles qui ont été utilisées pour l'accéléromètre. Les détails de ces architectures sont présentés à la section 4.3.1.

4.4.2 Résultats

Les tableaux 4.11 et 4.12 présentent les résultats obtenus par chaque méthode sur les ensembles de validation et de test respectivement.

Tableau 4.11 Performance du gyroscope sur l'ensemble de validation

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.55±0.00	0.58±0.01	0.38±0.13	0.24±0.00
CNN Temporel	0.65±0.01	0.67±0.04	0.61±0.09	0.22±0.00
CNN Spectrogramme	0.74±0.00	0.78±0.03	0.80±0.05	0.17±0.00
CNN Scalogramme	0.86±0.01	0.87±0.02	0.92±0.01	0.10±0.01

Tableau 4.12 Performance du gyroscope sur l'ensemble de test

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.66	0.42	0.31	0.24
CNN Temporel	0.69	0.50	0.54	0.20
CNN Spectrogramme	0.57	0.48	0.63	0.28
CNN Scalogramme	0.59	0.53	0.74	0.31

Comme pour l'accéléromètre précédemment, les réseaux *LSTM Simple* et *CNN Temporel* ne réussissent pas à apprendre une représentation utile des données et ne semblent donc pas pouvoir être utilisés pour le gyroscope.

Le réseau *CNN Spectrogramme* obtient une assez bonne performance avec une exactitude de 74% sur l'ensemble de validation. Or, cette performance chute considérablement sur l'ensemble

de test. Tout comme pour l'accéléromètre, ceci indique un certain niveau de surentraînement du réseau. De plus, la précision de 48% et le taux de rappel de 63% indiquent que le réseau est légèrement biaisé envers les défauts.

Le réseau *CNN Scalogramme* obtient la meilleure performance sur l'ensemble de validation avec 86% d'exactitude. Cette performance diminue considérablement sur l'ensemble de test, mais le taux de rappel reste assez élevé à 74%. La distribution des étiquettes prédites (voir figure 4.20) montre que les rayures et les échantillons normaux ne peuvent pas être distingués. Au contraire, les indentations et les arrachements ont un pic majeur d'échantillons classifiés correctement.




Figure 4.20 Distribution des étiquettes prédites par le réseau *CNN Scalogramme* sur l'ensemble de test pour le gyroscope

4.4.2.1 Distribution des erreurs pour chaque type de défaut

Tout comme la modalité statique et l'accéléromètre, la présence de rayures affecte aussi le gyroscope. Aucune des méthodes que nous avons testées n'a permis de différencier les rayures des échantillons normaux.

Ceci est probablement causé par la conception mécanique du capteur et du montage expérimental. Tout comme l'accéléromètre, le gyroscope ne perçoit pas directement la surface, mais plutôt les rotations causées par l'interaction du capteur avec la surface de l'objet. Dans ce contexte, la surface lisse du capteur limite à quel point le capteur peut interagir avec la surface. De plus, puisque le capteur est maintenu en place par une monture rigide en rotation, son amplitude de mouvement (et sa capacité à percevoir les rotations) est limitée. Il est donc plausible que le capteur ne puisse tout simplement pas interagir suffisamment avec les rayures pour produire des rotations pouvant être détectées.

Afin d'évaluer la performance du gyroscope sur les autres types de défauts, nous avons répété les mêmes essais en excluant les plaques contenant des rayures (soit les plaques 11, 41, 42 et 51). Les tableaux 4.13 et 4.14 présentent les résultats sur les ensembles de validation et de test respectivement. Le tableau 4.15 présente les variations entre les deux expériences afin de faciliter la comparaison.

Tableau 4.13 Performance du gyroscope sur l'ensemble de validation
(sans rayures)

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.66±0.02	0.67±0.03	0.34±0.10	0.22±0.01
CNN Temporel	0.73±0.01	0.70±0.03	0.61±0.06	0.18±0.00
CNN Spectrogramme	0.81±0.01	0.80±0.04	0.75±0.05	0.13±0.01
CNN Scalogramme	0.98±0.00	0.97±0.00	0.97±0.01	0.02±0.00

Tableau 4.14 Performance du gyroscope sur l'ensemble
de test (sans rayures)

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.76	0.56	0.52	0.18
CNN Temporel	0.73	0.51	0.57	0.18
CNN Spectrogramme	0.63	0.50	0.54	0.26
CNN Scalogramme	0.75	0.70	0.64	0.22

Tableau 4.15 Changements de performance du gyroscope lorsque les rayures sont éliminées

Modèles	Δ Exactitude	Δ Précision	Δ Rappel	Δ EQM
LSTM Simple	+0.11 (+0.10)*	+0.09 (+0.14)	-0.04 (+0.22)	-0.03 (-0.06)
CNN Temporel	+0.08 (+0.04)	+0.02 (+0.01)	-0.01 (+0.04)	-0.04 (-0.02)
CNN Spectrogramme	+0.07 (+0.07)	+0.02 (+0.02)	-0.05 (-0.10)	-0.04 (-0.03)
CNN Scalogramme	+0.12 (+0.15)	+0.10 (+0.17)	+0.06 (-0.10)	-0.08 (-0.08)

* Les valeurs sans parenthèses indiquent la variation entre les résultats obtenus avec les rayures et ceux obtenus sans les rayures sur l'ensemble de validation, alors que celles entre parenthèses indiquent la variation sur l'ensemble de test.

Bien que le retrait des rayures améliore la performance obtenue par les réseaux *LSTM Simple* et *CNN Temporel*, (particulièrement pour les échantillons normaux), la performance sur les défauts reste médiocre. Ces deux réseaux ne sont donc pas appropriés pour le gyroscope. La figure 4.21 montre la distribution de leurs prédictions sur l'ensemble de test sans rayures.

Alors que le réseau *CNN Spectrogramme* obtient une performance acceptable sur l'ensemble de validation, sa performance sur l'ensemble de test est médiocre avec une précision de 50% et un taux de rappel de 54%. Ces résultats indiquent que le réseau n'est pas approprié pour traiter les données obtenues par le gyroscope.

Tout comme pour l'accéléromètre, le réseau *CNN Scalogramme* voit une amélioration majeure pour toutes les métriques excepté le taux de rappel sur l'ensemble de test. Ceci est dû au fait que la présence de rayures causait de la confusion entre les deux classes. Les échantillons contenant des défauts minimes étaient distribués relativement uniformément entre celles-ci. Sans les rayures, ces échantillons sont maintenant classifiés comme étant normaux ce qui réduit le taux de rappel. La distribution des étiquettes prédites est présentée à la figure 4.22. On peut y voir que les échantillons normaux et les arrachements sont très bien classifiés alors que les

indentations ne le sont pas. Comme expliqué pour l'accéléromètre, ceci est probablement dû au fait que la transformée en ondelettes est mieux adaptée à détecter les signaux transitoires.




Figure 4.21 Distribution des étiquettes prédites par les réseaux *LSTM Simple* et *CNN Temporel* sur l'ensemble de test pour le gyroscope (sans rayures)




Figure 4.22 Distribution des étiquettes prédites par le réseau *CNN Scalogramme* sur l'ensemble de test pour le gyroscope (sans rayures)

4.4.3 Discussion

Dans cette section, nous avons démontré que le gyroscope du capteur tactile CoRo peut être utilisé pour la détection de défauts de surface.

Le gyroscope permet d'obtenir une performance très similaire à l'accéléromètre et beaucoup des mêmes conclusions peuvent être tirées. En effet, sa capacité à percevoir les défauts de manière fiable semble être limitée aux arrachements. Il ne peut pas être utilisé pour détecter la présence de rayures et sa capacité à détecter les indentations est limitée.

Les réseaux qui traitent les signaux dans le domaine temporel (*LSTM Simple* et *CNN Temporel*) n'ont pas permis de détecter la présence de défauts. Ils ne peuvent donc pas être utilisés pour cette application.

Le réseau *CNN Scalogramme* a obtenu les meilleurs résultats, alors que le réseau *CNN Spectrogramme* n'a pas réussi à classifier correctement les données. On peut en conclure que l'information utile contenue dans les signaux du gyroscope est sous la forme de variations transitoires. Malgré cette performance intéressante, la possibilité de surentraînement doit être prise en compte étant donnée la puissance de ces réseaux.

À la lumière de ces résultats, le gyroscope peut être utilisé pour détecter la présence d'arrachements, mais il est autrement limité par la conception mécanique du capteur tactile et du montage expérimental.

4.5 Modalité dynamique

Dans cette section, nous traitons la modalité dynamique du capteur tactile.

4.5.1 Architectures de réseaux considérées

Tout comme le gyroscope précédemment, nous avons décidé d'utiliser les mêmes architectures de réseaux que l'accéléromètre.

En effet, la modalité dynamique du capteur tactile et l'accéléromètre fournissent tous deux un signal de nature similaire. Ceci est dû au fait que les deux modalités utilisent la variation de capacitance pour percevoir leur cible :

- L'accéléromètre mesure le déplacement d'une masse en réaction aux accélérations en mesurant la variation de capacitance entre celle-ci et deux électrodes fixes.
- La modalité dynamique mesure la variation de pression appliquée sur le capteur en mesurant la variation de capacitance causée par la déformation de la couche diélectrique.

Dans les deux cas, le signal capté est de nature dynamique (plutôt que statique). De plus, ils sont tous deux acquis à la même fréquence d'échantillonnage, soit 1 kHz.

En raison de ces similarités, nous avons décidé d'utiliser les mêmes architectures de réseaux pour la modalité dynamique que celles qui ont été utilisées pour l'accéléromètre. Les détails de ces architectures sont présentés à la section 4.3.1.

4.5.2 Résultats

Les tableaux 4.16 et 4.17 présentent les résultats obtenus par chaque méthode sur les ensembles de validation et de test respectivement.

Les réseaux *LSTM Simple* et *CNN Temporel* obtiennent une performance médiocre sur l'ensemble de validation avec une exactitude de 54% et de 58% respectivement. Sur l'ensemble de test, leur performance reste médiocre. On voit une diminution et une augmentation majeure de la précision et du rappel respectivement, ce qui indique que les réseaux sont biaisés envers les défauts lorsque de nouvelles données sont présentées. Or, si l'on regarde les distributions des étiquettes prédites à la figure 4.23, on voit qu'une bonne partie des arrachements et des indentations sont classifiés avec succès, indiquant que les réseaux sont partiellement capables de détecter la présence de ces types de défauts.

Tableau 4.16 Performance de la modalité dynamique sur l'ensemble de validation

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.54±0.01	0.55±0.02	0.54±0.13	0.25±0.00
CNN Temporel	0.58±0.01	0.62±0.01	0.43±0.04	0.24±0.00
CNN Spectrogramme	0.62±0.01	0.62±0.01	0.96±0.03	0.23±0.00
CNN Scalogramme	0.74±0.01	0.79±0.02	0.80±0.03	0.17±0.01

Tableau 4.17 Performance de la modalité dynamique sur l'ensemble de test

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.54	0.38	0.80	0.25
CNN Temporel	0.67	0.47	0.64	0.23
CNN Spectrogramme	0.43	0.42	0.98	0.27
CNN Scalogramme	0.60	0.53	0.81	0.28




Figure 4.23 Distribution des étiquettes prédites par les réseaux *LSTM Simple* et *CNN Temporel* sur l'ensemble de test pour la modalité dynamique

Le réseau *CNN Spectrogramme* obtient une performance légèrement meilleure que les deux réseaux précédents avec une exactitude de 62% sur l'ensemble de validation. Toutefois, le taux de rappel extrêmement élevé de 96% indique que le réseau est déjà biaisé envers les défauts. Sur l'ensemble de test, on voit que c'est le cas puisque le taux de rappel atteint 98% alors que l'exactitude et la précision diminuent.

Finalement, le réseau *CNN Scalogramme* obtient la meilleure performance sur l'ensemble de validation avec une exactitude de 74%, une précision de 79% et un rappel de 80%. Sur l'ensemble de test, cette performance est réduite considérablement, mais le taux de rappel reste élevé à 81%. Ceci est en partie dû au biais du réseau, mais la distribution des étiquettes prédites (présentée à la figure 4.24) montre que le réseau est tout de même capable d'une bonne classification pour les arrachements et les indentations.




Figure 4.24 Distribution des étiquettes prédites par le réseau *CNN Scalogramme* sur l'ensemble de test pour la modalité dynamique

4.5.2.1 Distribution des erreurs pour chaque type de défaut

Comme pour les modalités précédentes, la présence de rayures affecte la modalité dynamique et aucune des méthodes que nous avons testées n'a permis de différencier les rayures des échantillons normaux.

Tout comme pour la modalité statique, ceci est probablement causé par la rigidité de la couche diélectrique du capteur tactile. En effet, celle-ci ne peut pas épouser suffisamment les contours des défauts mineurs (comme les rayures) pour causer une variation de capacitance mesurable. De plus, puisque la modalité dynamique mesure les variations de pression sur l'ensemble de la surface du capteur, une variation localisée causée par un défaut mineur aura un impact limité.

Afin d'évaluer la performance de la modalité dynamique sur les autres types de défauts, nous avons répété les mêmes essais en excluant les plaques contenant des rayures (soit les plaques 11, 41, 42 et 51). Les tableaux 4.18 et 4.19 présentent les résultats sur les ensembles de validation et de test respectivement. Le tableau 4.20 présente les variations entre les deux expériences afin de faciliter la comparaison.

Tableau 4.18 Performance de la modalité dynamique sur l'ensemble de validation (sans rayures)

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.71±0.01	0.68±0.03	0.55±0.06	0.19±0.00
CNN Temporel	0.70±0.01	0.70±0.03	0.47±0.05	0.20±0.00
CNN Spectrogramme	0.71±0.01	0.73±0.05	0.51±0.04	0.19±0.00
CNN Scalogramme	0.90±0.01	0.89±0.02	0.88±0.01	0.07±0.00

Tableau 4.19 Performance de la modalité dynamique sur l'ensemble de test (sans rayures)

Modèles	Exactitude	Précision	Rappel	EQM
LSTM Simple	0.82	0.66	0.72	0.14
CNN Temporel	0.80	0.63	0.64	0.15
CNN Spectrogramme	0.77	0.76	0.56	0.17
CNN Scalogramme	0.77	0.71	0.73	0.18

Tableau 4.20 Changements de performance de la modalité dynamique lorsque les rayures sont éliminées

Modèles	Δ Exactitude	Δ Précision	Δ Rappel	Δ EQM
LSTM Simple	+0.17 (+0.28)*	+0.13 (+0.28)	+0.01 (-0.07)	-0.05 (-0.11)
CNN Temporel	+0.12 (+0.13)	+0.08 (+0.16)	+0.04 (+0.00)	-0.04 (-0.08)
CNN Spectrogramme	+0.09 (+0.34)	+0.11 (+0.34)	-0.45 (-0.42)	-0.03 (-0.10)
CNN Scalogramme	+0.16 (+0.17)	+0.10 (+0.17)	+0.08 (-0.08)	-0.09 (-0.10)

* Les valeurs sans parenthèses indiquent la variation entre les résultats obtenus avec les rayures et ceux obtenus sans les rayures sur l'ensemble de validation, alors que celles entre parenthèses indiquent la variation sur l'ensemble de test.

Avec le retrait des rayures, les réseaux *LSTM Simple* et *CNN Temporel* voient une amélioration de performance sur l'ensemble de validation pour toutes les métriques avec une exactitude de 71% et 70% respectivement. Toutefois, l'augmentation du taux de rappel est plus faible (1% et 4% respectivement), ce qui s'explique par le fait que les réseaux étaient précédemment biaisés envers les défauts. Sur l'ensemble de test, on observe un comportement similaire avec une amélioration de performance pour toutes les métriques hormis le rappel. Les distributions des étiquettes prédites (présentées à la figure 4.25) montrent que les deux réseaux ont une certaine capacité à séparer les arrachements des échantillons normaux, mais qu'ils sont très limités en ce qui concerne les indentations.

Le réseau *CNN Spectrogramme* obtient de bien meilleurs résultats lorsque les rayures sont retirées. Sur les ensembles de validation et de test, toutes les métriques hormis le rappel sont améliorées avec une exactitude de 71% et 77% respectivement. En effet, alors que précédemment le réseau était complètement biaisé envers les défauts, ce qui aboutissait à un rappel très élevé, il

est maintenant capable de mieux séparer les défauts des échantillons normaux. En observant la distribution des étiquettes prédites présentée à la figure 4.26, on voit que (comme les deux réseaux précédents) les arrachements et les échantillons normaux sont relativement bien classifiés alors que les indentations ne le sont pas.




Figure 4.25 Distribution des étiquettes prédites par les réseaux *LSTM Simple* et *CNN Temporel* sur l'ensemble de test pour la modalité dynamique (sans rayures)

Sur l'ensemble de validation, le réseau *CNN Scalogramme* obtient de très bons résultats avec une exactitude de 90%, une précision de 89% et un rappel de 88%. Sur l'ensemble de test, cette performance est diminuée indiquant un certain niveau de surentraînement, mais reste relativement élevée pour toutes les métriques. De plus, la distribution des étiquettes prédites (voir la figure 4.27) montre que le réseau parvient à classifier les échantillons normaux et les arrachements avec beaucoup de certitude, mais qu'il a de la difficulté avec les indentations. Toutefois, contrairement à l'accéléromètre et au gyroscope, on n'observe pas de pic d'indentations classifiées comme échantillons normaux avec certitude, ce qui pourrait indiquer une meilleure perception de ce type de défaut.




Figure 4.26 Distribution des étiquettes prédites par le réseau *CNN Spectrogramme* sur l'ensemble de test pour la modalité dynamique (sans rayures)




Figure 4.27 Distribution des étiquettes prédites par le réseau *CNN Scalogramme* sur l'ensemble de test pour la modalité dynamique (sans rayures)

4.5.3 Discussion

Dans cette section, nous avons démontré que la modalité dynamique du capteur Tactile CoRo peut être utilisée pour la détection de défauts de surface.

Toutefois, comme l'accéléromètre et le gyroscope, cette capacité semble être limitée aux arrachements. La modalité dynamique n'a pas permis de détecter la présence de rayures. Quant aux indentations, elle a obtenu de meilleures performances que l'accéléromètre et le gyroscope, mais sa capacité à les détecter demeure limitée.

Tous les réseaux ayant été testés ont démontré une certaine capacité à percevoir la présence d'arrachements, alors que ce n'était pas le cas pour l'accéléromètre et le gyroscope. Ceci s'explique potentiellement par le fait que la modalité dynamique perçoit directement la surface en contact plutôt que l'interaction entre le capteur et la surface et qu'elle est ainsi moins susceptible d'être affectée par l'environnement et le bruit (Maslyczyk, 2016). Le signal résultant est donc assez simple pour être analysé dans le domaine temporel. C'est le réseau *CNN Scalogramme* qui obtient la meilleure performance, car il permet de bien extraire les variations transitoires associées aux défauts.

À la lumière de ces résultats, il est possible de conclure que la modalité dynamique permet de détecter la présence d'arrachements (et d'indentations dans une certaine mesure), mais qu'elle demeure limitée par la conception mécanique du capteur tactile.

4.6 Résultats généraux

Afin de faciliter la comparaison des différentes modalités du capteur tactile, cette section présente un récapitulatif des résultats présentés dans les sections précédentes. Les tableaux 4.21 et 4.22 rapportent, pour chaque modalité, la performance obtenue par le meilleur réseau sur les ensembles de validation et de test respectivement, sans les rayures. La figure 4.28 présente les distributions des étiquettes prédites par ces réseaux.

Sur l'ensemble de validation, on peut voir que le gyroscope obtient la meilleure performance sur toutes les métriques, suivi de près par l'accéléromètre. La modalité statique et la modalité dynamique les suivent toutefois de près. Toutes les modalités ont obtenu une exactitude d'au moins 90%.

Tableau 4.21 Meilleure performance de chaque modalité sur l'ensemble de validation (sans rayures)

Modalités	Modèles	Exactitude	Précision	Rappel	EQM
Statique	LSTM Simple	0.93±0.01	0.93±0.01	0.89±0.02	0.06±0.00
Accéléromètre	CNN Scalogramme	0.96±0.00	0.96±0.01	0.95±0.02	0.03±0.00
Gyroscope	CNN Scalogramme	0.98±0.00	0.97±0.00	0.97±0.01	0.02±0.00
Dynamique	CNN Scalogramme	0.90±0.01	0.89±0.02	0.88±0.01	0.07±0.00

Tableau 4.22 Meilleure performance de chaque modalité sur l'ensemble de test (sans rayures)

Modalités	Modèles	Exactitude	Précision	Rappel	EQM
Statique	LSTM Simple	0.86	0.76	0.68	0.12
Accéléromètre	CNN Scalogramme	0.72	0.67	0.62	0.24
Gyroscope	CNN Scalogramme	0.75	0.70	0.64	0.22
Dynamique	CNN Scalogramme	0.77	0.71	0.73	0.18

Sur l'ensemble de test, la modalité statique obtient la meilleure performance sur toutes les métriques hormis le rappel, avec une exactitude de 86%. La modalité dynamique obtient quant à elle le meilleur rappel et arrive deuxième pour les autres métriques. L'accéléromètre et le gyroscope montrent une diminution significative de performance probablement causée par du surentraînement.

La distribution des étiquettes prédites par les réseaux (voir figure 4.28) montre que tous les réseaux réussissent à détecter la présence d'arrachements, mais qu'ils sont limités en ce qui concerne les indentations. La modalité statique et la modalité dynamique montrent toutefois une meilleure capacité à détecter les indentations que l'accéléromètre et le gyroscope.




Figure 4.28 Distribution des étiquettes prédites par le meilleur réseau pour chaque modalité sur l'ensemble de test (sans rayures)

4.7 Discussion

Dans ce chapitre, nous avons étudié la capacité des quatre modalités du capteur tactile CoRo à détecter la présence de trois types de défauts de surface, soit les rayures, les indentations et les arrachements.

De manière globale, la modalité statique semble la plus efficace pour détecter les indentations et les arrachements. De plus, il n'est pas nécessaire de représenter les données dans le domaine fréquentiel ou spatial pour obtenir une performance intéressante.

L'accéléromètre et le gyroscope obtiennent une performance similaire entre eux, mais sont moins efficaces que la modalité statique à détecter les indentations et les arrachements. De plus, il est nécessaire de représenter les données dans le domaine fréquentiel pour ces deux modalités.

Quant à la modalité dynamique, elle est globalement plus efficace que l'accéléromètre et le gyroscope à détecter les indentations et les arrachements, en particulier pour le taux de rappel. Également, représenter les données dans le domaine fréquentiel permet ici aussi d'obtenir une meilleure performance.

Par ailleurs, trois remarques plus globales peuvent être formulées à partir des résultats obtenus :

Il apparaît d'abord évident que le capteur ne permet pas de détecter la présence de rayures. En effet, aucune des modalités n'a été capable de le faire, et ce, indépendamment du type de réseau utilisé pour les traiter.

Bien que les arrachements sont relativement bien détectés par toutes les modalités, ce n'est pas le cas des indentations. Les modalités statique et dynamique sont meilleures, mais elles restent limitées. Puisque les indentations ont des contours généralement plus lisses que les arrachements, on peut en conclure que plus un défaut est marqué, plus il sera facile à détecter.

Dans le même ordre d'idées, pour l'accéléromètre, le gyroscope et la modalité dynamique, l'utilisation de la CWT permet d'obtenir les meilleurs résultats, ce qui indique que l'information pertinente associée aux défauts existe principalement sous la forme de variations transitoires.

Ainsi, il est possible de conclure que les modalités du capteur tactile CoRo permettent de détecter certains défauts de surface dans le bois. Toutefois, celui-ci est limité par deux facteurs principaux, soit la rigidité de la couche diélectrique et sa surface lisse. Ces deux facteurs limitent sa capacité à interagir avec les défauts de la surface et donc à les percevoir.

CHAPITRE 5

FUSION DES MODALITÉS

Dans ce chapitre, nous étudierons la capacité du capteur tactile CoRo à détecter la présence de défauts en combinant ses différentes modalités. Cinq combinaisons de modalités seront testées, puis les résultats seront interprétés afin de mieux comprendre la manière dont les modalités interagissent entre elles. Finalement, nous identifierons les combinaisons qui permettent de mieux détecter la présence de défauts de surface.

5.1 Méthodologie générale

Puisqu’aucune des modalités n’a été capable de détecter la présence de rayures, et ce, indépendamment du réseau utilisé, nous ne considérerons pas la détection des rayures dans ce chapitre. Elles ont donc été retirées des ensembles d’entraînement et de test.

Hormis ce changement, les expériences de ce chapitre ont été réalisées selon la même méthodologie que celle utilisée dans le chapitre précédent (tel que décrite à la section 4.1). Ceci inclut les métriques d’évaluation, le traitement des données et la méthodologie d’entraînement et de test.

5.1.1 Méthodes de fusion de modalités

La fusion des modalités, comme son nom l’indique, consiste à utiliser deux (ou plus) modalités distinctes simultanément dans un même réseau. Puisque chaque modalité mesure des éléments différents de la surface, la combinaison de plusieurs modalités permet théoriquement à un réseau d’avoir une meilleure vue d’ensemble et donc de mieux classifier les données. Nous faisons donc l’hypothèse que la fusion des modalités du capteur tactile CoRo devrait mener à une meilleure performance pour la détection de défauts de surface.

Selon Boulahia, Amamra, Madi & Daikh (2021), il existe trois grandes catégories de méthodes permettant d'effectuer la fusion de modalités dans un réseau de neurones : la fusion précoce (*early fusion*), la fusion intermédiaire (*intermediate fusion*) et la fusion tardive (*late fusion*).

La **fusion précoce** consiste à combiner les données des modalités avant même de les fournir au réseau. De cette manière, elles sont essentiellement traitées comme si elles provenaient d'une seule modalité. Il s'agit d'une méthode intéressante lorsque les modalités à combiner sont de nature similaire, puisque les *features* que le réseau apprend sont applicables aux deux modalités simultanément et qu'il peut faire des liens entre elles dès le départ. Inversement, lorsque les modalités ne sont pas de nature similaire, le réseau doit simultanément apprendre deux groupes de *features* distincts, ce qui rend l'entraînement plus difficile. Kwiatkowski *et al.* (2017) ont utilisé cette méthode pour fusionner les données de l'accéléromètre et du gyroscope lors de l'évaluation de la qualité de prises d'objets.

La **fusion intermédiaire** consiste à utiliser une architecture de réseau en forme de "Y" dans lequel chaque branche correspond à une modalité. De cette manière, lors de l'entraînement, chaque branche devient "spécialisée" pour sa modalité respective. Le réseau peut donc extraire des *features* de haut niveau, spécifiques à chaque modalité, lesquelles sont ensuite combinées et passées dans les couches subséquentes du réseau. Cette méthode permet au réseau de faire des liens entre les modalités sans devoir extraire l'information des données simultanément. De plus, elle permet aussi d'utiliser des couches mutuellement non compatibles dans un même réseau. Pour la fusion précoce, les données doivent obligatoirement être du même format puisque le réseau ne contient qu'une seule branche. Avec la fusion intermédiaire, chaque branche peut utiliser des couches complètement différentes et ainsi traiter simultanément différents formats de données. Kwiatkowski *et al.* (2017) ont également utilisé cette technique pour fusionner les données du IMU et de la modalité statique.

Finalement, la **fusion tardive** consiste à utiliser deux (ou plus) réseaux distincts qui produisent chacun une classification préliminaire des échantillons ¹. Celles-ci sont par la suite combinées

¹ Généralement, ces classifications préliminaires ne sont pas discrétisées afin de préserver l'information sur le niveau de confiance des réseaux.

pour produire une classification finale. Bien que cette méthode représente la fusion la moins complète et qu'elle ne permet pas de faire des liens entre les modalités, elle permet d'utiliser des réseaux préexistants ou très spécialisés. Par exemple, Rispal (2014) a utilisé un ensemble de 45 classificateurs SVM pouvant individuellement discriminer une paire de textures pour effectuer la reconnaissance de 10 textures.

Dans le cadre de ce mémoire, nous utiliserons la fusion précoce et la fusion intermédiaire. Les détails et les justifications de leur utilisation sont présentés dans la section suivante.

5.2 Combinaisons de modalités considérées

Centrale inertielle (IMU)

La première combinaison que nous avons testée est celle de l'accéléromètre et du gyroscope.

Comme mentionné précédemment, l'accéléromètre et le gyroscope sont presque toujours intégrés sous la forme d'un seul IMU. Bien qu'il existe des accéléromètres et des gyroscopes indépendants, le faible coût et la taille réduite d'un IMU font qu'il est rarement pertinent de se priver de l'une ou l'autre des modalités. Elles sont donc souvent traitées comme étant équivalentes à une seule modalité permettant de mesurer les mouvements simultanément en translation et en rotation.

À la lumière des résultats obtenus dans le chapitre 4, il semble peu probable que cette combinaison permette d'obtenir une performance intéressante. Or, étant donné la simplicité et le faible coût d'un système qui utiliserait uniquement un IMU, il est tout de même pertinent d'en vérifier le potentiel.

Puisque ces deux modalités sont de nature très similaire, nous utilisons une fusion précoce (tel que décrite précédemment). Comme le réseau *CNN Scalogramme* a permis d'obtenir la meilleure performance pour l'accéléromètre et le gyroscope individuellement, tel que démontré aux sections 4.3 et 4.4, nous utilisons ce réseau.

Dynamique et IMU

La deuxième combinaison considérée est celle de la modalité dynamique et du IMU.

Bien que la modalité dynamique est similaire au IMU à bien des égards, elle est moins sensible aux perturbations externes. Combiner ces deux modalités pourrait donc permettre d'obtenir un capteur sensible aux vibrations, mais aussi capable de percevoir et de minimiser l'impact de l'environnement. De plus, la modalité dynamique est relativement simple à réaliser et donc un tel capteur resterait simple et peu coûteux.

Contrairement à la combinaison précédente, nous utilisons une fusion intermédiaire à l'aide d'un réseau en "Y" puisque la modalité dynamique est considérablement différente du IMU. Les données des deux modalités (sous la forme de scalogrammes) sont traitées par une série de trois couches de convolution. Les *feature maps* résultantes sont combinées et passées dans une dernière couche de convolution, puis dans deux couches denses. Tout comme le réseau *CNN Scalogramme*, présenté au chapitre 4, chaque couche de convolution est additionnée d'une couche de *BatchNorm* et une de *MaxPooling*.

Statique et IMU

La troisième combinaison considérée est celle de la modalité statique et du IMU.

Comme démontré dans le chapitre précédent, la modalité statique a obtenu la meilleure performance de toutes les modalités. Il semble donc plausible qu'elle permette aussi d'obtenir des résultats intéressants lorsque combinée à d'autres modalités. Or, la modalité statique n'a pas la capacité de percevoir le contenu vibratoire de l'interaction entre un défaut et la surface du capteur puisque sa fréquence d'acquisition est limitée à 60 Hz. Un IMU pourrait potentiellement fournir cette capacité sans augmenter significativement la complexité du capteur tactile.

Puisque les formats des deux modalités ne sont pas compatibles, nous considérons une fusion intermédiaire des données basée sur les meilleurs réseaux présentés au chapitre 4 (Soit *LSTM Simple* pour la modalité statique et *CNN Scalogramme* pour le IMU). Toutefois, alors que pour la

combinaison précédente la fusion était effectuée au niveau de la dernière couche de convolution, elle doit ici être effectuée au niveau de la première couche dense. En effet, puisque les sorties des deux branches du réseau sont de formats incompatibles (*feature maps* pour le IMU et "états cachés" pour la modalité statique), elles ne peuvent pas être combinées dans l'un ou l'autre de ces formats. Pour remédier à ce problème, leurs sorties respectives sont aplaties par une couche *Flatten*, concaténées ensemble, puis fournies à la première couche dense du réseau. Cette fusion est par conséquent moins complète puisqu'elle est effectuée une couche plus tard, mais elle devrait tout de même permettre au réseau de tirer parti des deux modalités.

Statique et dynamique

La quatrième combinaison considérée est celle des modalités statique et dynamique.

Bien que la modalité dynamique joue un rôle similaire au IMU (c'est-à-dire de percevoir les vibrations), les résultats obtenus dans le chapitre 4 indiquent qu'elle est meilleure à détecter la présence de défauts et qu'elle est moins sensible aux perturbations de l'environnement. Il est donc plausible que, lorsque combinée à la modalité statique, la modalité dynamique offre les mêmes avantages que le IMU, mais qu'elle permette d'obtenir une meilleure performance.

Puisque les formats de leurs données sont incompatibles, nous utilisons ici aussi une fusion intermédiaire basée sur les réseaux *LSTM Simple* pour la modalité statique et *CNN Scalogramme* pour la modalité dynamique. Hormis l'échange du IMU pour la modalité dynamique, la structure du réseau demeure la même.

Statique, dynamique et IMU

Finalement, nous considérons la combinaison de toutes les modalités du capteur tactile CoRo.

Tel qu'établi au chapitre 4, toutes les modalités ont démontré une certaine capacité à détecter la présence d'indentations et d'arrachements, ce qui veut dire qu'elles contiennent toutes de

l'information pertinente. En combinant toutes les modalités, le réseau a donc théoriquement accès au maximum d'information pour effectuer la classification des données.

Tout comme les deux combinaisons précédentes, nous utilisons une fusion intermédiaire des modalités. Plutôt qu'un réseau en forme de "Y", le réseau est ici en forme de "trident". Les trois modalités ² sont traitées par leurs branches respectives (*LSTM Simple* pour la modalité statique et *CNN Scalogramme* pour la modalité dynamique et le IMU), puis combinées avant d'être traitées par les couches denses du réseau.

5.3 Résultats

Les tableaux 5.1 et 5.2 présentent les résultats obtenus par chaque combinaison sur les ensembles de validation et de test respectivement. La figure 5.1 présente les distributions des étiquettes prédites par chacune des combinaisons.

Tableau 5.1 Performance de chaque combinaison sur l'ensemble de validation
(sans rayures)

Combinaisons	Exactitude	Précision	Rappel	EQM
IMU	0.99±0.00	0.98±0.01	0.99±0.01	0.01±0.00
Dynamique + IMU	0.98±0.00	0.98±0.01	0.98±0.01	0.01±0.00
Statique + IMU	0.99±0.00	0.98±0.00	0.99±0.00	0.01±0.00
Statique + Dynamique	0.95±0.01	0.94±0.02	0.95±0.02	0.04±0.01
Statique + Dynamique + IMU	0.98±0.00	0.98±0.01	0.98±0.01	0.01±0.00

Tableau 5.2 Performance de chaque combinaison sur l'ensemble de test
(sans rayures)

Combinaisons	Exactitude	Précision	Rappel	EQM
IMU	0.75	0.68	0.72	0.23
Dynamique + IMU	0.74	0.68	0.68	0.24
Statique + IMU	0.74	0.68	0.65	0.24
Statique + Dynamique	0.76	0.66	0.82	0.20
Statique + Dynamique + IMU	0.74	0.68	0.67	0.24

² Le IMU est ici considéré comme une seule modalité, bien qu'il consiste lui-même d'une combinaison de deux modalités.

Sur l'ensemble de validation, on note que toutes les combinaisons obtiennent une performance excellente pour toutes les métriques. Toutefois, la combinaison des modalités statique et dynamique est légèrement moins bonne avec une exactitude de 95%. La meilleure performance des autres combinaisons est probablement causée par le surentraînement associé à l'utilisation du IMU. En effet, puisque l'accéléromètre et le gyroscope sont susceptibles au surentraînement (voir section 4.6), il semble plausible que ce soit également le cas lorsqu'ils sont combinés et joints à d'autres modalités.




Figure 5.1 Distribution des étiquettes prédites par chaque combinaison de modalités sur l'ensemble de test (sans rayures) (suite à la page 112)

Sur l'ensemble de test, la combinaison des modalités statique et dynamique obtient la meilleure performance pour toutes les métriques, excepté la précision. L'exactitude et la précision qu'elle obtient sont relativement similaires aux autres combinaisons, mais son taux de rappel de 82% est nettement supérieur. Ceci est confirmé par la distribution des étiquettes prédites qui montre que, contrairement aux autres combinaisons, elle n'a pas de pic à 0 pour les indentations et les

arrachements (qui correspondrait à des défauts classifiés incorrectement). On y note également que les échantillons normaux sont classifiés avec moins de certitude.




Figure 5.1 Distribution des étiquettes prédites par chaque combinaison de modalités sur l'ensemble de test (sans rayures) (suite de la page 111)

Toujours sur l'ensemble de test, on remarque également dans le tableau 5.2 que lorsque le IMU est combiné à d'autres modalités, il entraîne une diminution de la performance du réseau, et ce, autant par rapport aux modalités statique et dynamique qu'à l'IMU seul.

5.3.1 Comparaison avec les modalités individuelles

Afin de faciliter la comparaison des modalités individuelles et des combinaisons de modalités du capteur tactile, le tableau 5.3 combine les résultats sur l'ensemble de test du chapitre 4 et ceux du présent chapitre. La figure 5.2 présente la distribution des étiquettes prédites par la modalité statique et la combinaison des modalités statique et dynamique sur l'ensemble de test.

Tableau 5.3 Performance de chaque modalité individuelle et combinaisons de modalités sur l'ensemble de test (sans rayures)

Modalités et combinaisons	Exactitude	Précision	Rappel	EQM
Statique	0.86	0.76	0.68	0.12
Accéléromètre	0.72	0.67	0.62	0.24
Gyroscope	0.75	0.70	0.64	0.22
Dynamique	0.77	0.71	0.73	0.18
IMU	0.75	0.68	0.72	0.23
Dynamique + IMU	0.74	0.68	0.68	0.24
Statique + IMU	0.74	0.68	0.65	0.24
Statique + Dynamique	0.76	0.66	0.82	0.20
Statique + Dynamique + IMU	0.74	0.68	0.67	0.24

Il est possible de noter que la modalité statique seule obtient la meilleure performance par une marge significative pour l'exactitude, la précision et l'EQM. Son exactitude de 86% est particulièrement au-dessus de ce que les autres réseaux obtiennent. Le meilleur taux de rappel de 82% est toutefois obtenu par la combinaison des modalités statique et dynamique.

À la figure 5.2, on peut noter que la modalité statique seule classifie correctement la majorité des échantillons avec beaucoup de certitude, mais que certains des défauts sont classifiés comme normaux, également avec beaucoup de certitude. Au contraire, les classifications de la combinaison des modalités statique et dynamique sont effectuées avec moins de certitude, mais elles ne contiennent pas de pic majeur d'échantillons mal classifiés.

Il est aussi intéressant de remarquer que, malgré quelques exceptions isolées, les autres combinaisons de modalités ne démontrent pas d'amélioration significative par rapport aux modalités seules.




Figure 5.2 Distributions des étiquettes prédites par la modalité statique et la combinaison des modalités statique et dynamique sur l'ensemble de test (sans rayures)

5.4 Discussion

Dans ce chapitre, nous avons étudié comment la fusion des différentes modalités du capteur tactile CoRo influence sa capacité à détecter la présence de défauts de surface.

Contrairement à notre hypothèse, il est clair que la fusion des modalités n'est pas une solution miracle pour améliorer la performance du système. Bien que la combinaison des modalités statique et dynamique ait obtenu le meilleur taux de rappel par une marge considérable, la modalité statique seule a été la plus performante en ce qui concerne l'exactitude, la précision et l'EQM. Il n'est donc pas nécessairement meilleur d'utiliser plusieurs modalités simultanément.

Cela dit, il est clair que la modalité statique, combinée à d'autres modalités ou non, est la mieux adaptée à détecter la présence de défauts de surface. Elle devrait donc être considérée comme essentielle pour cette tâche.

Il est également clair que si la capacité de percevoir les vibrations causées par l'interaction entre le capteur et la surface est désirée, la modalité dynamique est à préconiser. Celle-ci performe mieux que le IMU, que ce soit lorsqu'ils sont combinés à d'autres modalités ou utilisés individuellement.

Finalement, les résultats démontrent que le IMU performe mieux que l'accéléromètre et le gyroscope individuellement, en particulier sur le taux de rappel. Si ces modalités sont requises dans un capteur, il semble donc pertinent de les fusionner. Toutefois, lorsque le IMU est combiné aux autres modalités, une baisse de la performance obtenue est notée, potentiellement causée par sa vulnérabilité au surentraînement. Son utilisation pour la détection de défauts de surface semble donc peu intéressante.

CONCLUSION ET RECOMMANDATIONS

L'arrivée des robots collaboratifs engendre des changements majeurs dans certains milieux où l'automatisation n'était auparavant pas économiquement viable. C'est notamment le cas de certaines petites et moyennes entreprises qui manufacturent des produits en bois. L'automatisation de la fabrication de ces produits implique des tâches d'inspection de surface, ce dont il est question dans ce mémoire. Afin qu'un robot puisse réaliser ce type de tâche, il doit avant tout avoir la capacité de percevoir son environnement ; ce qui crée un besoin pour des capteurs capables de détecter les défauts de surface. L'objectif de ce mémoire était donc de vérifier la capacité du capteur tactile capacitif CoRo à détecter la présence de défauts de surface dans le bois.

Pour ce faire, le capteur CoRo, composé de quatre modalités différentes (statique, dynamique, accéléromètre et gyroscope) a été installé sur un banc d'essai permettant de recueillir des données de manière répétable à partir de 12 plaques échantillons en érable blanc, catégorisées selon qu'elles ne contenaient aucun défaut, une ou plusieurs rayures, indentations ou arrachements. Les données ont ensuite été utilisées pour entraîner des réseaux de neurones artificiels servant à les classer.

En premier lieu, à l'aide d'un réseau simple basé sur l'usage de couches *LSTM*, nous avons démontré que les signaux captés par le capteur tactile CoRo contiennent de l'information sur la présence de défauts de surface et que son utilisation mérite d'être étudiée.

Deuxièmement, chaque modalité a été testée séparément pour évaluer sa capacité à détecter les défauts de surface. Nous avons démontré qu'aucune des modalités du capteur n'est capable de percevoir la présence de rayures. Quant aux indentations, les modalités statique et dynamique semblent capables de les détecter dans une certaine mesure, sans être vraiment performantes à le faire, alors que l'accéléromètre et le gyroscope sont encore moins performants. Du côté des arrachements, les quatre modalités du capteur permettent relativement bien de détecter leur

présence. De manière générale, la modalité statique, suivie de la modalité dynamique, offre les meilleures performances de détection des indentations et des arrachements.

Finalement, nous nous sommes intéressés à l'impact que la fusion des modalités a sur la capacité à détecter les défauts. Contrairement à ce que nous avons anticipé et bien que les résultats ne soient pas entièrement concluants, la fusion des modalités ne semble pas constituer une avenue nécessairement meilleure que l'utilisation de modalités individuelles. Dans tous les cas, la modalité statique, utilisée seule ou combinée à la modalité dynamique, a fourni les résultats les plus prometteurs pour la détection des indentations et des arrachements. Quoiqu'il en soit, même si la performance du capteur tactile CoRo est prometteuse, elle nécessite plus de recherches et de développement, puisqu'elle demeure encore loin de la capacité du toucher humain à détecter des défauts de surface sur le bois.

Évidemment, l'expérimentation menée dans le cadre de cette étude comprend des limitations qu'il convient de mettre en lumière. Une de ses limitations majeures est que nous avons considéré une seule espèce de bois, soit l'érable blanc. Puisque la texture de surface de chaque essence de bois est différente, il reste à démontrer si les résultats que nous avons obtenus sont transférables à d'autres espèces. Cela dit, cette vérification pourrait sans doute être réalisée assez facilement en utilisant un ensemble de données contenant des échantillons de plusieurs espèces de bois pour réentraîner les réseaux présentés dans ce mémoire.

Une autre limite de l'étude provient du fait que nous avons traité chaque échantillon hors de son contexte d'origine et donc indépendamment des échantillons adjacents. Or, dans un contexte d'inspection réelle, le capteur est glissé sur la surface de manière continue ; ce qui signifie que les échantillons sont acquis dans l'ordre et qu'ils se chevauchent. Ainsi, chaque échantillon contient de l'information sur les échantillons adjacents. Puisque chaque défaut est couvert par plusieurs échantillons, il est possible qu'il ne soit pas nécessaire que chacun d'eux soit classifié parfaitement. En effet, un certain taux de mauvaises classifications pourrait être tolérable, pourvu

que suffisamment d'échantillons provenant d'un même défaut soient correctement classifiés, permettant ainsi de détecter sa présence. En considérant les échantillons qui le précèdent en plus de l'échantillon lui-même, il devrait être possible d'obtenir globalement une meilleure détection des défauts. Il serait pertinent de vérifier cette hypothèse dans des travaux futurs.

De plus, nous avons déterminé que l'une des plus grandes limitations du capteur tactile CoRo est liée à sa conception. En effet, il a été développé dans le but de fournir aux robots collaboratifs une capacité de perception tactile spécifiquement orientée pour la manipulation d'objets. Or, les caractéristiques nécessaires pour ce type de tâche sont différentes de celles requises pour la détection de défauts de surface. Afin de développer un système d'inspection tactile de surface réellement performant, la conception du capteur tactile CoRo devrait être repensée entièrement en tenant compte de cette tâche. Les éléments suivants représentent quelques changements qui semblent prometteurs pour améliorer sa performance :

- Utiliser une surface texturée inspirée par les empreintes digitales pour maximiser l'interaction avec les défauts ;
- Augmenter la résolution spatiale des modalités statique et dynamique pour pouvoir capter de plus petits défauts ;
- Réduire la rigidité de la couche diélectrique afin d'augmenter la sensibilité du capteur ;
- Agrandir l'aire de mesure du capteur pour couvrir plus de surface rapidement.

Finalement, puisque l'objectif de ce mémoire consistait en une première exploration de la capacité du capteur tactile CoRo à détecter la présence de défauts de surface dans le bois, nous avons choisi d'utiliser des techniques d'apprentissage machine et de traitement de données établies. Il va sans dire qu'il serait pertinent de poursuivre les recherches sur ce sujet en augmentant la taille de l'ensemble de données et en ayant recours à des techniques plus avancées et spécialisées.

BIBLIOGRAPHIE

- American Society of Mechanical Engineers. (2019). *Surface Texture : Surface Roughness, Waviness and Lay*. Norme ASME B46.1-2019. Repéré à <https://webstore.ansi.org/Standards/ASME/ASMEB462019>.
- Ando, S. & Shinoda, H. (1995). Ultrasonic emission tactile sensing. *IEEE Control Systems*, 15(1), 61–69. doi : 10.1109/37.341866.
- Architectural Woodwork Institute. (2022). *Factory Finishing*. Norme ANSI/AWI 0400-2022. Repéré à <https://awiweb-cd.awinet.org/standards/factory-finishing>.
- ASTM International. (2017). *Standard Test Methods for Conducting Machining Tests of Wood and Wood-Base Panel Materials*. Norme ASTM D1666-17. Repéré à <https://www.astm.org/d1666-17.html>.
- Aust, J., Mitrovic, A. & Pons, D. (2021). Comparison of Visual and Visual–Tactile Inspection of Aircraft Engine Blades. *Aerospace*, 8(11), 313. doi : 10.3390/aerospace8110313.
- Bekiroglu, Y., Detry, R. & Kragic, D. (2011a). Learning tactile characterizations of object- and pose-specific grasps. *2011 IEEE/RSJ International Conference on Intelligent Robots and Systems*, pp. 1554-1560. doi : 10.1109/IROS.2011.6094878.
- Bekiroglu, Y., Laaksonen, J., Jorgensen, J. A., Kyrki, V. & Kragic, D. (2011b). Assessing Grasp Stability Based on Learning and Haptic Data. *IEEE Transactions on Robotics*, 27(3), 616–629. doi : 10.1109/TRO.2011.2132870.
- Boulahia, S. Y., Amamra, A., Madi, M. R. & Daikh, S. (2021). Early, intermediate and late fusion strategies for robust deep learning-based multimodal action recognition. *Machine Vision and Applications*, 32(6), 121. doi : 10.1007/s00138-021-01249-8.
- Caldwell, D., Tsagarakis, N. & Wardle, A. (1997). Mechano thermo and proprioceptor feedback for integrated haptic feedback. *Proceedings of International Conference on Robotics and Automation*, 3(April), 2491–2496. doi : 10.1109/ROBOT.1997.619335.
- Cirillo, A., Cirillo, P., De Maria, G., Natale, C. & Pirozzi, S. (2017). A Distributed Tactile Sensor for Intuitive Human-Robot Interfacing. *Journal of Sensors*, 1–14. doi : 10.1155/2017/1357061.
- Cockburn, D., Roberge, J.-P., Le, T.-H.-L., Masluczyk, A. & Duchaine, V. (2017, mai). Grasp stability assessment through unsupervised feature learning of tactile images. *2017 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 2238–2244. doi : 10.1109/ICRA.2017.7989257.

- Craig, J. C. & Kisner, J. M. (1998). Factors affecting tactile spatial acuity. *Somatosensory & Motor Research*, 15(1), 29–45. doi : 10.1080/08990229870934.
- Creath, K. (1988). Non-contact surface roughness measurements. *Proc. Biennial International Machine Tool Technology Conference*, pp. 235–245.
- Dahiya, R. S. & Valle. (2008). Tactile sensing for robotic applications. Dans Rocha, J. G. & Lanceros-Mendez, S. (Éds.), *Sensors : Focus on Tactile Force and Stress* (pp. 289–304). Londres, Royaume-Uni : IntechOpen. doi : 10.5772/103.
- Dargahi, J. & Najarian, S. (2004). Human tactile perception as a standard for artificial tactile sensing - a review. *International Journal of Medical Robotics and Computer Assisted Surgery*, 01(01), 23. doi : 10.1581/mrcas.2004.010109.
- Desai, S. & Konz, S. (1983). Tactile Inspection Performance with and without Gloves. *Proceedings of the Human Factors Society Annual Meeting*, 27(9), 782–785. doi : 10.1177/154193128302700906.
- Domaine Public. (2005). Wavelet - Morlet.png. Repéré le 2022-09-16 à <https://commons.wikimedia.org/w/index.php?curid=225627>.
- Dong, S., Yuan, W. & Adelson, E. H. (2017). Improved GelSight tactile sensor for measuring geometry and slip. *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 137–144. doi : 10.1109/IROS.2017.8202149.
- Dong, W., Sullivan, P. & Stout, K. (1994). Comprehensive study of parameters for characterising three-dimensional surface topography. *Wear*, 178(1-2), 45–60. doi : 10.1016/0043-1648(94)90128-7.
- Drimus, A., Borlum Petersen, M. & Bilberg, A. (2012, sep). Object texture recognition by dynamic tactile sensing using active exploration. *2012 IEEE RO-MAN : The 21st IEEE International Symposium on Robot and Human Interactive Communication*, pp. 277–283. doi : 10.1109/ROMAN.2012.6343766.
- Elkington, M., Almas, E., Ward-Cherrier, B., Pestell, N., Lloyd, J., Ward, C. & Lepora, N. (2021). Real time defect detection during composite layup via Tactile Shape Sensing. *Science and Engineering of Composite Materials*, 28(1), 1–10. doi : 10.1515/secm-2021-0001.
- Fang, B., Long, X., Zhang, Y., Luo, G., Sun, F. & Liu, H. (2020). Fabric defect detection using vision-based tactile sensor. *arXiv :2003.00839*. doi : 10.48550/arXiv.2003.00839.

- Fang, B., Long, X., Sun, F., Liu, H., Zhang, S. & Fang, C. (2022). Tactile-Based Fabric Defect Detection Using Convolutional Neural Network With Attention Mechanism. *IEEE Transactions on Instrumentation and Measurement*, 71, 1–9. doi : 10.1109/TIM.2022.3165254.
- Fang, Y., Guo, X., Chen, K., Zhou, Z. & Ye, Q. (2021). Accurate and automated detection of surface knots on sawn timbers using YOLO-V5 model. *BioResources*, 16(3), 5390–5406. doi : 10.15376/biores.16.3.5390-5406.
- Fishel, J. A. & Loeb, G. E. (2012a). Bayesian Exploration for Intelligent Identification of Textures. *Frontiers in Neurorobotics*, 6(JUNE), 1–20. doi : 10.3389/fnbot.2012.00004.
- Fishel, J. A. & Loeb, G. E. (2012b, juin). Sensing tactile microvibrations with the BioTac – Comparison with human sensitivity. *2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob)*, pp. 1122–1127. doi : 10.1109/BioRob.2012.6290741.
- Galley, C., Mothe, F. & Boury, S. (1998). Recherche de critères de rugosité adaptés à la qualification de chants usinés de LVL. *Annales des Sciences Forestières*, 55(5), 599–612. doi : 10.1051/forest:19980507.
- Gao, S. (2017). *A multi-functional touch panel for multi-dimensional sensing in interactive displays*. (Thèse de doctorat, University of Cambridge, Cambridge, Royaume-Uni). Repéré à <https://www.repository.cam.ac.uk/handle/1810/269846>.
- Gao, S., Dai, Y. & Nathan, A. (2022). Tactile and Vision Perception for Intelligent Humanoids. *Advanced Intelligent Systems*, 4(2), 2100074. doi : 10.1002/aisy.202100074.
- Giannoccaro, N. I., Massaro, A., Spedicato, L. & Lay-Ekuakille, A. (2015). Detection Analysis of Small Notches Damages Using a New Tactile Optical Device. *IEEE/ASME Transactions on Mechatronics*, 20(1), 313–320. doi : 10.1109/TMECH.2014.2301638.
- Goger, D., Gorges, N. & Worn, H. (2009, mai). Tactile sensing for an anthropomorphic robotic hand : Hardware and signal processing. *2009 IEEE International Conference on Robotics and Automation*, pp. 895–901. doi : 10.1109/ROBOT.2009.5152650.
- Goli, G. (2003). *Superficie del legno ottenuta mediante fresatura : studio delle meccaniche di formazione e dei relativi difetti - Surfaces de bois obtenues par defonçage : étude de la mécanique de formation et des défauts induits*. (Thèse de doctorat, Université de Florence & ENSAM Cluny). Repéré à <https://flore.unifi.it/handle/2158/1062033>.
- Goli, G., Marchal, R. & Uzielli, L. (2004). Classification of wood surface defects according to their mechanical formation during machining. *Proceedings of the 2nd International Symposium on Wood Machining*, pp. 315–324.

- Gupta, A. K., Ghosh, R., Swaminathan, A. N., Deverakonda, B., Ponraj, G., Soares, A. B. & Thakor, N. V. (2018, dec). A Neuromorphic Approach to Tactile Texture Recognition. *2018 IEEE International Conference on Robotics and Biomimetics (ROBIO)*, pp. 1322–1328. doi : 10.1109/ROBIO.2018.8665085.
- Gurau, L., Mansfield-Williams, H. & Irle, M. (2011). Evaluating the roughness of sanded wood surfaces. *Wood machining. ISTE-Wiley, London*, 217–267.
- Gurau, L. & Irle, M. (2017). Surface Roughness Evaluation Methods for Wood Products : a Review. *Current Forestry Reports*, 3(2), 119–131. doi : 10.1007/s40725-017-0053-4.
- Hall, M. (2014). What is the Gabor uncertainty principle ? Repéré à <https://agilescientific.com/blog/2014/1/15/what-is-the-gabor-uncertainty-principle.html>.
- He, T., Liu, Y., Xu, C., Zhou, X., Hu, Z. & Fan, J. (2019). A fully convolutional neural network for wood defect location and identification. *IEEE Access*, 7, 123453–123462. doi : 10.1109/ACCESS.2019.2937461.
- Hiziroglu, S. (2005). Surface roughness evaluation of medium density fiberboard (MDF) using stylus and pneumatic methods. *Holz als Roh- und Werkstoff*, 63(1), 81–82. doi : 10.1007/s00107-004-0538-2.
- Hollins, M. & Risner, S. R. (2000). Evidence for the duplex theory of tactile texture perception. *Perception & Psychophysics*, 62(4), 695–705. doi : 10.3758/BF03206916.
- Huber, H. A., Ruddell, S. & Mcmillin, C. W. (1990). Industry standards for recognition of marginal wood defects. *Forest Products Research Society*, 40(3), 30–34. Repéré à <https://www.fs.usda.gov/treearch/pubs/8073>.
- Johansson, R. S. & Vallbo, A. B. (1979). Tactile sensibility in the human hand : relative and absolute densities of four types of mechanoreceptive units in glabrous skin. *The Journal of Physiology*, 286(1), 283–300. doi : 10.1113/jphysiol.1979.sp012619.
- Kappasov, Z., Corrales, J.-A. & Perdereau, V. (2015). Tactile sensing in dexterous robot hands — Review. *Robotics and Autonomous Systems*, 74, 195–220. doi : 10.1016/j.robot.2015.07.015.
- Katz, D. (1989). *The world of touch*. New York City, NY : Psychology Press. doi : 10.4324/9780203771976.
- Keys, R. (1981). Cubic convolution interpolation for digital image processing. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 29(6), 1153–1160. doi : 10.1109/TASSP.1981.1163711.

- Kishi, K., Hida, T., Nakajima, R. & Matsumoto, T. (2016, dec). *Proposal of Tactile Inspection Conditions for Valid Defects Detection Focusing on Haptic Perception with Active Touch*. Communication présentée à The 17th Asia Pacific Industrial Engineering and Management Systems Conference, Taipei, Taiwan. Repéré à <https://www.conf.tw/site/userdata/1087/papers/0152.pdf>.
- Kleiner, B. M., Drury, C. G. & Christopher, G. L. (1987). Sensitivity of Human Tactile Inspection. *Human Factors : The Journal of the Human Factors and Ergonomics Society*, 29(1), 1–7. doi : 10.1177/001872088702900101.
- Kwiatkowski, J., Cockburn, D. & Duchaine, V. (2017, sep). Grasp stability assessment through the fusion of proprioception and tactile signals using convolutional neural networks. *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 286–292. doi : 10.1109/IROS.2017.8202170.
- Lambeta, M., Chou, P.-W., Tian, S., Yang, B., Maloon, B., Most, V. R., Stroud, D., Santos, R., Byagowi, A., Kammerer, G., Jayaraman, D. & Calandra, R. (2020). DIGIT : A Novel Design for a Low-Cost Compact High-Resolution Tactile Sensor With Application to In-Hand Manipulation. *IEEE Robotics and Automation Letters*, 5(3), 3838–3845. doi : 10.1109/LRA.2020.2977257.
- Landy, M. S. & Graham, N. (2004). Visual perception of texture. Dans Chalupa, L. M. & Werner, J. S. (Éds.), *The visual neurosciences* (pp. 1106–1118). Cambridge, MA : MIT Press Cambridge.
- Laurent, C., Pereyra, G., Brakel, P., Zhang, Y. & Bengio, Y. (2016). Batch normalized recurrent neural networks. *2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pp. 2657–2661. doi : 10.1109/ICASSP.2016.7472159.
- Le, T.-H.-L., Maslyczyk, A., Roberge, J.-P. & Duchaine, V. (2017, mai). A highly sensitive multimodal capacitive tactile sensor. *2017 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 407–412. doi : 10.1109/ICRA.2017.7989053.
- Lima, B. M. R., da Fonseca, V. P., de Oliveira, T. E. A., Zhu, Q. & Petriu, E. M. (2020, août). Dynamic Tactile Exploration for Texture Classification using a Miniaturized Multi-modal Tactile Sensor and Machine Learning. *2020 IEEE International Systems Conference (SysCon)*, pp. 1–7. doi : 10.1109/SysCon47679.2020.9275871.
- Long, X., Fang, B., Zhang, Y., Luo, G. & Sun, F. (2021, mai). Fabric defect detection using tactile information. *2021 IEEE International Conference on Robotics and Automation (ICRA)*, pp. 11169–11174. doi : 10.1109/ICRA48506.2021.9561092.

- Maslyczyk, A. (2016). *Développement d'un capteur tactile multimodal*. (Mémoire de maîtrise, École de Technologie Supérieure, Montréal, Québec). Repéré à <https://espace.etsmtl.ca/id/eprint/1789/>.
- Mothe, F. (1985). Essai et comparaison de trois méthodes de classement de surface de bois massif pour leur rugosité : méthodes pneumatique et sensorielles. *Annales des sciences forestières*, 42(4), 435–452. Repéré à https://www.afs-journal.org/articles/forest/pdf/1985/04/AFS_0003-4312_1985_42_4_ART0006.pdf.
- Muhammad, H., Recchiuto, C., Oddo, C., Beccai, L., Anthony, C., Adams, M., Carrozza, M. & Ward, M. (2011). A capacitive tactile sensor array for surface texture discrimination. *Microelectronic Engineering*, 88(8), 1811–1813. doi : 10.1016/j.mee.2011.01.045.
- Muradeli, J. (2020). Ssqueezeepy. Repéré à <https://github.com/OverLordGoldDragon/ssqueezeepy/>.
- Myshkin, N., Grigoriev, A., Chizhik, S., Choi, K. & Petrokovets, M. (2003). Surface roughness and texture analysis in microscale. *Wear*, 254(10), 1001–1009. doi : 10.1016/S0043-1648(03)00306-5.
- Okatani, T., Takahashi, H., Noda, K., Takahata, T., Matsumoto, K. & Shimoyama, I. (2016). A Tactile Sensor Using Piezoresistive Beams for Detection of the Coefficient of Static Friction. *Sensors*, 16(5), 718. doi : 10.3390/s16050718.
- O'Malley, T., Bursztein, E., Long, J., Chollet, F., Jin, H., Invernizzi, L. et al. (2019). KerasTuner. Repéré à <https://github.com/keras-team/keras-tuner>.
- Polikar, R. (1996). The Wavelet Tutorial. Repéré à <https://users.rowan.edu/~polikar/WTtutorial.html>.
- Poon, C. Y. & Bhushan, B. (1995). Comparison of surface roughness measurements by stylus profiler, AFM and non-contact optical profiler. *Wear*, 190(1), 76–88. doi : 10.1016/0043-1648(95)06697-7.
- Pxfuel. (2022a). Wood, Knot, Texture, Wooden, Hardwood, wood, knot, material, wood - Material, backgrounds, pattern. Repéré le 2022-09-16 à <https://www.pxfuel.com/en/free-photo-oyzdm>.
- Pxfuel. (2022b). bark beetles, pest, waldsterben, texture, wood, pattern, wood worm, structure, forestry, chip away. Repéré le 2022-09-16 à <https://www.pxfuel.com/en/free-photo-xxomz>.
- Pxfuel. (2022c). brown, wooden, table, top, wood, texture, pattern, tree, background, backgrounds. Repéré le 2022-09-16 à <https://www.pxfuel.com/en/free-photo-jvsrx>.

- Pxfuel. (2022d). Wood, Texture, Cracked, Material, Timber, hardwood, plank, grain, natural, backgrounds. Repéré le 2022-09-16 à <https://www.pxfuel.com/en/free-photo-exzot>.
- Ramanakoto, M. F., Ramananantoandro, T., Eyma, F. & Castanié, B. (2019). Visuo-tactile and topographic characterizations of finished wood surface quality by French consumers and industrials : acceptability thresholds for raised grain. *Annals of Forest Science*, 76(1), 26. doi : 10.1007/s13595-019-0807-1.
- Ramanakoto, M. F., Andrianantenaina, A. N., Ramananantoandro, T. & Eyma, F. (2017). Visual and visuo-tactile preferences of Malagasy consumers for machined wood surfaces for furniture : acceptability thresholds for surface parameters. *European Journal of Wood and Wood Products*, 75(5), 825–837. doi : 10.1007/s00107-016-1098-y.
- Rana, A., Roberge, J.-P. & Duchaine, V. (2016). An Improved Soft Dielectric for a Highly Sensitive Capacitive Tactile Sensor. *IEEE Sensors Journal*, 16(22), 7853–7863. doi : 10.1109/JSEN.2016.2605134.
- Ren, Z., Fang, F., Yan, N. & Wu, Y. (2022). State of the Art in Defect Detection Based on Machine Vision. *International Journal of Precision Engineering and Manufacturing-Green Technology*, 9(2), 661–691. doi : 10.1007/s40684-021-00343-6.
- Richter, C. (2015). *Wood Characteristics*. Suisse : Springer International Publishing. doi : 10.1007/978-3-319-07422-1.
- Rispal, S. (2014). *Discrimination de textures et quantification de rugosité par algorithme d'apprentissage*. (Mémoire de maîtrise, École de technologie supérieure). Repéré à <https://espace.etsmtl.ca/id/eprint/1401/>.
- Rispal, S., Rana, A. K. & Duchaine, V. (2017, avr). Textures recognition through tactile exploration for robotic applications. *2017 3rd International Conference on Control, Automation and Robotics (ICCAR)*, pp. 121–128. doi : 10.1109/ICCAR.2017.7942672.
- Roberge, É. & Duchaine, V. (2017, sep). Detecting insertion tasks using convolutional neural networks during robot teaching-by-demonstration. *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*, pp. 3210–3216. doi : 10.1109/IROS.2017.8206154.
- Russo, S., Assaf, R., Carbonaro, N. & Tognetti, A. (2019). Touch Position Detection in Electrical Tomography Tactile Sensors Through Quadratic Classifier. *IEEE Sensors Journal*, 19(2), 474–483. doi : 10.1109/JSEN.2018.2878774.

- Sandak, J. & Tanaka, C. (2003). Evaluation of surface smoothness by laser displacement sensor 1 : Effect of wood species. *Journal of Wood Science*, 49(4), 305–311. doi : 10.1007/s10086-002-0486-6.
- Scheibert, J., Leurent, S., Prevost, A. & Debrégeas, G. (2009). The role of fingerprints in the coding of tactile information probed with a biomimetic sensor. *Science*, 323(5920), 1503–1506. doi : 10.1126/science.1166467.
- Shah, U. H., Muthusamy, R., Gan, D., Zweiri, Y. & Seneviratne, L. (2021). On the Design and Development of Vision-based Tactile Sensors. *Journal of Intelligent & Robotic Systems*, 102(4), 82. doi : 10.1007/s10846-021-01431-0.
- Shi, J., Li, Z., Zhu, T., Wang, D. & Ni, C. (2020). Defect Detection of Industry Wood Veneer Based on NAS and Multi-Channel Mask R-CNN. *Sensors*, 20(16), 4398. doi : 10.3390/s20164398.
- Shimonomura, K. (2019). Tactile Image Sensors Employing Camera : A Review. *Sensors*, 19(18), 3933. doi : 10.3390/s19183933.
- Shimonomura, K. & Nakashima, H. (2013). A combined tactile and proximity sensing employing a compound-eye camera. *Proceedings of IEEE Sensors*, 4–5. doi : 10.1109/ICSENS.2013.6688497.
- Silvera-Tawil, D., Rye, D., Soleimani, M. & Velonaki, M. (2015). Electrical Impedance Tomography for Artificial Sensitive Robotic Skin : A Review. *IEEE Sensors Journal*, 15(4), 2001–2016. doi : 10.1109/JSEN.2014.2375346.
- Sinn, G., Sandak, J. & Ramanantoandro, T. (2009). Properties of wood surfaces – characterisation and measurement. A review COST Action E35 2004–2008 : Wood machining – micromechanics and fracture. *Holzforschung*, 63(2), 196–203. doi : 10.1515/HF.2009.016.
- Srivastava, N., Hinton, G., Krizhevsky, A., Sutskever, I. & Salakhutdinov, R. (2014). Dropout : a simple way to prevent neural networks from overfitting. *The journal of machine learning research*, 15(1), 1929–1958. Repéré à <https://dl.acm.org/doi/abs/10.5555/2627435.2670313>.
- Tao, J., Bao, R., Wang, X., Peng, Y., Li, J., Fu, S., Pan, C. & Wang, Z. L. (2019). Self-powered tactile sensor array systems based on the triboelectric effect. *Advanced Functional Materials*, 29(41), 1806379. doi : 10.1002/adfm.201806379.
- Taunyazov, T., Koh, H. F., Wu, Y., Cai, C. & Soh, H. (2019, mai). Towards Effective Tactile Identification of Textures using a Hybrid Touch Approach. *2019 International Conference on Robotics and Automation (ICRA)*, pp. 4269–4275. doi : 10.1109/ICRA.2019.8793967.

- Tenzer, Y., Jentoft, L. P. & Howe, R. D. (2014). The Feel of MEMS Barometers : Inexpensive and Easily Customized Tactile Array Sensors. *IEEE Robotics & Automation Magazine*, 21(3), 89–95. doi : 10.1109/MRA.2014.2310152.
- Thoma, H., Peri, L. & Lato, E. (2015). Evaluation of wood surface roughness depending on species characteristics. *Maderas. Ciencia y tecnología*, 17, 285-292. doi : 10.4067/S0718-221X2015005000027.
- Tiwana, M. I., Redmond, S. J. & Lovell, N. H. (2012). A review of tactile sensing technologies with applications in biomedical engineering. *Sensors and Actuators A : Physical*, 179, 17–31. doi : 10.1016/j.sna.2012.02.051.
- Vallbo, A. B. & Johansson, R. S. (1984). Properties of cutaneous mechanoreceptors in the human hand related to touch sensation. *Human neurobiology*, 3(1), 3–14. Repéré à <http://www.ncbi.nlm.nih.gov/pubmed/6330008>.
- Wandersman, E., Candelier, R., Debrégeas, G. & Prevost, A. (2011). Texture-Induced Modulations of Friction Force : The Fingerprint Effect. *Physical Review Letters*, 107(16), 164301. doi : 10.1103/PhysRevLett.107.164301.
- Wang, C., Dong, L., Peng, D. & Pan, C. (2019). Tactile Sensors for Advanced Intelligent Systems. *Advanced Intelligent Systems*, 1(8), 1900090. doi : 10.1002/aisy.201900090.
- Wang, L., Qi, W., Wu, J. & Hou, W. (2007, août). Recognizing the Patterns of Wood Inner Defects Based on Wavelet Neural Networks. *2007 IEEE International Conference on Automation and Logistics*, pp. 1719–1724. doi : 10.1109/ICAL.2007.4338850.
- Wang, Z. L. & Wang, A. C. (2019). On the origin of contact-electrification. *Materials Today*, 30, 34–51. doi : 10.1016/j.mattod.2019.05.016.
- Ward-Cherrier, B., Pestell, N., Cramphorn, L., Winstone, B., Giannaccini, M. E., Rossiter, J. & Lepora, N. F. (2018). The TacTip Family : Soft Optical Tactile Sensors with 3D-Printed Biomimetic Morphologies. *Soft Robotics*, 5(2), 216–227. doi : 10.1089/soro.2017.0052.
- Wattanasarn, S., Noda, K., Matsumoto, K. & Shimoyama, I. (2012, jan). 3D flexible tactile sensor using electromagnetic induction coils. *2012 IEEE 25th International Conference on Micro Electro Mechanical Systems (MEMS)*, pp. 488–491. doi : 10.1109/MEMSYS.2012.6170230.
- Wettels, N., Fishel, J. A. & Loeb, G. E. (2014). Multimodal tactile sensor. Dans Balasubramanian, R. & Santos, V. J. (Éds.), *The Human Hand as an Inspiration for Robot Hand Development* (pp. 405–429). Springer Cham. doi : 10.1007/978-3-319-03017-3_19.

- Xin, Y., Cui, M., Liu, C., Hou, T., Liu, L., Qian, C. & Yan, Y. (2021). A bionic piezoelectric tactile sensor for features recognition of object surface based on machine learning. *Review of Scientific Instruments*, 92(9), 095003. doi : 10.1063/5.0057236.
- Yamaguchi, A. & Atkeson, C. G. (2016, nov). Combining finger vision and optical tactile sensing : Reducing and handling errors while cutting vegetables. *2016 IEEE-RAS 16th International Conference on Humanoid Robots (Humanoids)*, pp. 1045–1051. doi : 10.1109/HUMANOIDS.2016.7803400.
- Yamaguchi, A. & Atkeson, C. G. (2019). Recent progress in tactile sensing and sensors for robotic manipulation : can we turn tactile sensing into vision ? *Advanced Robotics*, 33(14), 661–673. doi : 10.1080/01691864.2019.1632222.
- Yan, Y., Hu, Z., Shen, Y. & Pan, J. (2022). Surface Texture Recognition by Deep Learning-Enhanced Tactile Sensing. *Advanced Intelligent Systems*, 4(1), 2100076. doi : 10.1002/aisy.202100076.
- Yang, T., Xue, W. & Liu, Y. (2012). Influence of machining methods on wood surface roughness and adhesion strength. *Proceedings of 2012 International Conference on Biobase Material Science and Engineering*, pp. 284-287. doi : 10.1109/BMSE.2012.6466231.
- Yang, Y., Zhou, X., Liu, Y., Hu, Z. & Ding, F. (2020). Wood Defect Detection Based on Depth Extreme Learning Machine. *Applied Sciences*, 10(21), 7488. doi : 10.3390/app10217488.
- Yi, Z., Zhang, Y. & Peters, J. (2017). Bioinspired tactile sensor for surface roughness discrimination. *Sensors and Actuators A : Physical*, 255, 46–53. doi : 10.1016/j.sna.2016.12.021.