



HAL
open science

Apprentissage profond multimodal appliqué à l'usinage

Cheick Abdoul Kadir Kounta

► **To cite this version:**

Cheick Abdoul Kadir Kounta. Apprentissage profond multimodal appliqué à l'usinage. Autre [cs.OH]. Institut National Polytechnique de Toulouse - INPT; Université des sciences, des techniques et des technologies de Bamako (Mali), 2022. Français. NNT : 2022INPT0076 . tel-04248258

HAL Id: tel-04248258

<https://theses.hal.science/tel-04248258>

Submitted on 18 Oct 2023

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.



Université
de Toulouse

THÈSE

En vue de l'obtention du

DOCTORAT DE L'UNIVERSITÉ DE TOULOUSE

Délivré par :

Institut National Polytechnique de Toulouse (Toulouse INP)

Discipline ou spécialité :

Informatique

Présentée et soutenue par :

M. CHEICK ABDOUL KADIR KOUNTA

le lundi 28 novembre 2022

Titre :

Apprentissage profond multimodal appliqué à l'usinage

Ecole doctorale :

Aéronautique-Astronautique (AA)

Unité de recherche :

Laboratoire de Génie de Productions de l'ENIT (E.N.I.T-L.G.P.)

Directeur(s) de Thèse :

M. BERNARD KAMU-FOGUEM

M. FANA TANGARA

Rapporteurs :

M. DENIS POMORSKI, Université de Lille

M. LUIZ ANGELO STEFFENEL, UNIVERSITE DE REIMS

Membre(s) du jury :

MME SYLVIE LE HEGARAT-MASCLE, UNIVERSITE PARIS-SACLAY, Président
M. BERNARD KAMU-FOGUEM, ECOLE NATIONALE D'INGENIEUR DE TARBES, Membre
M. FANA TANGARA, UNIV. DES SCIENCES TECH & TECHNO BAMAKO, Membre
M. FARID NOUREDDINE, ECOLE NATIONALE D'INGENIEUR DE TARBES, Membre
M. LIONEL ARNAUD, ECOLE NATIONALE D'INGENIEUR DE TARBES, Membre
MME LAURA LAGUNA SALVADO, ESTIA BIDART, Membre

Résumé

Les techniques axées sur les données ont offert à la technologie de fabrication intelligente des opportunités sans précédent pour assurer la transition vers une productivité basée sur l'industrie 4.0. L'apprentissage automatique et l'apprentissage profond occupent une place cruciale dans le développement de systèmes intelligents pour l'analyse descriptive, diagnostique et prédictive des machines-outils et la surveillance d'état des systèmes de fabrication industrielle. De nombreuses techniques d'apprentissage profond ont été testées sur les problèmes de surveillance d'état des machines-outils, de la détection du broutement, du diagnostic de défauts, de la sélection optimale des paramètres de coupe, etc.

Une étude bibliométrique est proposée pour retracer les techniques de détection du broutement, depuis les méthodes de traitement du signal temps-fréquence, la décomposition jusqu'à la combinaison avec des modèles d'apprentissage automatique ou d'apprentissage profond. Une analyse cartographique a été réalisée afin d'identifier les limites de ces différentes techniques et de proposer des axes de recherche pour détecter le broutement dans les processus d'usinage. Les données ont été collectées à partir du web of science (WoS 2022) en exploitant des requêtes particulières sur la détection du broutement. La plupart des documents recueillis présentent la détection du broutement à l'aide de techniques de transformation ou de décomposition. Ce travail a permis de détecter les articles les plus significatifs, les auteurs les plus cités, la collaboration entre auteurs, les pays, continents et revues les plus productifs, le partenariat entre pays, les mots-clés des auteurs et les tendances de la recherche sur la détection du broutement.

Cette thèse a pour objective de proposer dans un premier temps, une méthode de prédiction du choix des paramètres de coupe en exploitant l'apprentissage profond multimodal. L'apprentissage profond multimodal a été utilisé pour associer un choix de conditions de coupe (outil, vitesse de coupe, profondeur de coupe et vitesse d'avance par dents) avec un état de surface, en considérant la rugosité arithmétique moyenne (R_a) et une photo de la pièce. Nous avons construit un modèle de fusion multimodale tardive avec deux réseaux de neurones profonds, un réseau de neurones convolutif (CNN) pour traiter les données images et un réseau de neurones récurrent avec des couches de mémoire à long terme (LSTM) pour les données numériques. Cette méthode permet d'intégrer les informations provenant de deux modalités (fusion multimodale) afin de garantir la qualité de surface dans les processus d'usinage. Les difficultés rencontrées lors de l'élaboration de cette méthode nous ont orientés vers une approche unimodale pour détecter le broutement d'usinage.

Par la suite nous présentons une approche basée sur des compétences mécaniques pour d'abord identifier les traitements optimaux des signaux puis l'apprentissage profond (apprentissage par transfert) pour détecter automatiquement le phénomène de broutement en usinage. Ce travail a mis l'accent sur l'utilisation de données collectées dans les conditions industrielles contrairement à la majorité des travaux basés sur les données qui utilisent les données laboratoire. Cette méthode arrive à avoir de bonnes performances malgré le fait qu'elle ne donne aucune indication au réseau de neurones sur l'amplitude du signal, la vitesse de rotation.

Mots clés : apprentissage profond multimodal, traitement des données multimodal, paramètres de coupe, fabrication industrielle, usinage, rugosité, détection du broutement, analyse du signal vibratoire, détection des défauts.

Abstract

Data-driven techniques have provided smart manufacturing technology with unprecedented opportunities to transition to Industry 4.0-based productivity. Machine learning and deep learning are crucial in developing intelligent systems for descriptive, diagnostic, and predictive analysis of machine tools and condition monitoring of industrial manufacturing systems. Many deep learning techniques have been tested on the problems of machine tool condition monitoring, chatter detection, fault diagnosis, optimal cutting parameter selection, etc.

A bibliometric study is proposed to trace interference detection techniques, from time-frequency signal processing methods and decomposition to combining machine learning or deep learning models. A mapping analysis was performed to identify the limitations of these different techniques and to propose research directions to detect chatter in machining processes. Data were collected from the web of science (WoS 2022) by mining specific queries on chatter detection. Most of the collected papers present chatter detection using transformation or decomposition techniques. This work detected the most significant papers, most cited authors, the collaboration between authors, most productive countries, continents, and journals, partnerships between countries, authors' keywords, and research trends on chatter detection.

This thesis aims to propose a method for predicting the choice of cutting parameters by exploiting deep multimodal learning. Multimodal deep learning has been used to associate a choice of cutting conditions (tool, cutting speed, depth of cut, and feed rate per tooth) with a surface condition, considering the arithmetic mean roughness (Ra) and a photo of the part. We built a late multimodal fusion model with two deep neural networks, a convolutional neural network (CNN) to process the image data, and a recurrent neural network with long-term memory layers (LSTM) for the numerical data. This method allows the integration of information from two modalities (multimodal fusion) to eventually ensure surface quality in machining processes. The difficulties encountered during the development of this method led us to a unimodal approach to detect machining chatter.

Subsequently, we present an approach based on mechanical skills first to identify optimal signal processing and then deep learning (transfer learning) to detect the chatter phenomenon in machining automatically. This work emphasized using data collected under industrial conditions, contrary to most data-based works that use laboratory data. This method manages to have good performances despite the fact that it does not give any indication to the neural network on the amplitude of the signal, and the speed of rotation.

Keywords: deep multimodal learning, multimodal data processing, Cutting parameters, manufacturing processes, roughness, chatter detection, vibration signal analysis, Chatter, fault detection, machining.

Remerciements

Je voudrais tout d'abord adresser toute ma gratitude à mon directeur de thèse, Monsieur Bernard KAMSU-FOGUEM, pour son altruisme, sa disponibilité, son exigence, et surtout ses judicieuses orientations, qui ont été un facteur clé pour la réalisation de cette thèse.

Je tiens à remercier spécialement Monsieur Lionel ARNAUD, pour son encadrement durant la seconde phase du travail de recherche. Son accompagnement scientifique a été d'un soutien inestimable. Il a facilité la résolution des contraintes mécaniques et informatiques en proposant de nouvelles orientations qui ont contribué à alimenter ma réflexion.

Merci à Monsieur Farid NOUREDDINE, pour son encadrement dans la première phase du travail de recherche ; il s'est toujours montré à l'écoute et très disponible tout au long de la réalisation de cette thèse, ainsi pour l'inspiration, l'aide et le temps qu'il a bien voulu me consacrer.

Je tiens à exprimer toute ma reconnaissance à mon Co-directeur de thèse, Monsieur Fana TANGARA. Je le remercie de m'avoir encadré, orienté, aidé et conseillé.

Un grand merci au personnel du LGP pour leur accueil et leur franche collaboration. Un remerciement particulier à Eliane CASTA pour son aide constante dans les démarches administratives.

Merci à la coopération SCAC, Campus France pour le financement de cette thèse à travers la convention cotutelle entre l'Institut National Polytechnique de Toulouse (INPT) et Université des sciences, des techniques et des technologies de Bamako (USTTB).

Je désire aussi remercier la direction, le corps enseignants, le personnel pour m'avoir soutenu financièrement et moralement.

Enfin mes remerciements vont à ma famille et mes collègues pour m'avoir supporté, conseillé, assisté, soutenu et encouragé durant ces années d'étude. Une reconnaissance singulière est adressée à mon collègue Solemane COULIBALY pour des moments partagés d'échanges scientifiques et de richesse humaine.

Table des matières

Résumé.....	i
Abstract.....	ii
Remerciements.....	iii
Table des matières	iv
Liste des figures	vi
Liste des tableaux	viii
Chapitre 1 Introduction générale.....	1
1.1. Contexte	1
1.2. Objectifs de la thèse	8
1.3. Contributions	8
Apprentissage profond multimodal pour la prédiction du choix des paramètres de coupe dans le processus de fraisage.....	9
Revue des méthodes basées sur l'IA pour la détection du broutement dans l'usinage à partir d'une analyse bibliométrique	9
Apprentissage profond pour la détection du broutement dans l'usinage	10
1.4. Organisation du manuscrit	10
Chapitre 2 Revue des méthodes basées sur l'IA pour la détection du broutement dans l'usinage à partir d'une analyse bibliométrique	12
2.1. Introduction.....	12
2.2. Analyse bibliométrique.....	14
2.3. État de l'art	34
2.4. Discussions et perspectives	44
2.5. Conclusion	46
Chapitre 3 Apprentissage profond multimodal pour la prédiction du choix des paramètres de coupe dans le processus de fraisage.....	48
3. Apprentissage profond multimodal	48
3.1. Introduction.....	48
3.2. État de l'art sur les applications de l'apprentissage multimodales dans la fabrication industrielle	51
3.3. Méthodologie proposée pour la prédiction du choix de paramètres de coupe et l'outil de coupe	53
3.4. Discussions.....	69
3.5. Conclusion et perspectives	70
Chapitre 4 Apprentissage profond pour la détection du broutement de vibration d'usinage	72
4.1. Introduction	72
4.2. État de l'art	73
4.3. Méthode de détection du broutement	76
4.4. Résultat.....	81
4.5. Discussions.....	85
4.6. Conclusion et perspectives	86
• Application des techniques de l'IA explicable sur nos prédictions	88
• Apprentissage non supervisé pour la détection du broutement.....	89
5. Conclusion	90

Bibliographie.....	92
---------------------------	-----------

Liste des figures

Figure 1.1. La representation multimodale textes-images [70].....	3
Figure 1.2. Translation multimodale image-texte [199].	3
Figure 1.3. Alignement multimodale [85].....	4
Figure 1.4. Fusion multimodale précoce	4
Figure 1.5. Fusion multimodale tardive	5
Figure 1.6. Fusion multimodale hybride	5
Figure 1.7. Co-apprentissage multimodal son-vidéo [130].....	6
Figure 1.8. Organisation du manuscrit	11
Figure 2.1. Le modèle d'apprentissage automatique pour la classification binaire, inspiré de [138]	13
Figure 2.2. Le modèle d'apprentissage profond pour une classification binaire, inspiré de [138]	13
Figure 2.3. Classement des publications dans différents domaines de recherche.....	15
Figure 2.4. Classement des publications par type de documents.	17
Figure 2.5. Production scientifique annuelle.	17
Figure 2.6. Production scientifique annuelle exploitant le [135] terme « usinage » en recherche.	18
Figure 2.7. Classement des revues par plusieurs citations.	20
Figure 2.8. Impact local de l'auteur par indice TC.	21
Figure 2.9. Réseau de collaboration entre les auteurs.	23
Figure 2.10. La distribution de fréquence de la productivité scientifique.....	23
Figure 2.11. La cartographie pour la description de la composition hiérarchique.	24
Figure 2.12. Documents les plus cités dans cette étude.	25
Figure 2.13. Carte de la production scientifique du pays.....	27
Figure 2.14. Réseau de collaboration entre pays au niveau mondial.	27
Figure 2.15. Nuage des mots.	28
Figure 2.16. Carte conceptuelle de la méthode structurale MCA.	29
Figure 2.17. Progression temporelle des mots clés.	30
Figure 2.18. Visualisation des temporalités des mots clés dans les articles.....	30
Figure 2.19. Des groupes d'auteurs historiques et d'auteurs utilisent de nouvelles techniques de détection du broutement.	31
Figure 2.20. L'évolution des techniques d'IA dans la détection du broutement.....	32
Figure 2.21. Le nuage de mots des auteurs qui ont publié sur la détection automatique du broutement.....	33
Figure 2.22. Traitement du signal, respectivement, avec la FFT, STFT et WT [4].	35

Figure 3.1. Modèle de fusion multimodale tardive pour le diagnostic de défaillances de roulement [28].	52
Figure 3.2. Méthodologie proposée pour la prédiction du choix des paramètres coupe.	54
Figure 3.3. Processus de la collecte de données sur la fraiseuse.	56
Figure 3.4. Image des surfaces fraisées.	58
Figure 3.5. Alignement des données multimodales.	58
Figure 3.6. Fusion tardive des modèles CNN-LSTM.	62
Figure 3.7. Architecture détaillée du modèle unimodal.	63
Figure 3.8. Courbes de justesse et de perte du modèle CNN unimodal.	64
Figure 3.9. Courbes de justesse et de perte du modèle CNN unimodal avec l'arrêt précoce. ...	65
Figure 3.10. Courbes de justesse et de perte du modèle de fusion CNN-LSTM.	65
Figure 3.11. Courbes d'entraînement et de validation sur Fz et Vc en exploitant l'évaluateur mae.	67
Figure 3.12. Courbes d'entraînement et de validation sur Fz et Vc en exploitant l'évaluateur mse.	67
Figure 3.13. Courbes de perte et de précision de l'entraînement et de validation pour la classification de l'outil de coupe.	68
Figure 3.14. Matrice de confusion pour la prédiction de l'outil.	69
Figure 4.1. Méthodologie proposée pour la détection de broutement en usinage.	77
Figure 4.2. Processus de fraisage d'une paroi de voiture de train TGV (longueur ≈ 20 mètres).	78
Figure 4.3. Exemple de signal temporel (temps en secondes).	79
Figure 4.4. La transformation du domaine temporel au domaine fréquentiel.	80
Figure 4.5. Le modèle d'apprentissage par transfert.	81
Figure 4.6. Courbes de la précision et la perte de notre ensemble de données avec VGG16. .	81
Figure 4.7. Courbes de justesse et de perte de notre ensemble de données avec resnet50.	82
Figure 4.8. Courbes de justesse et de perte de notre ensemble de données avec inceptionV3.	82
Figure 4.9. Exemple de FFT des signaux bruités et non bruités.	83
Figure 4.10. Courbe ROC de trois classificateurs sur données issues des FFT bruitées et non bruitées.	85
Figure 4.11. Images des deux sources (SFTT et FFT) de données.	87
Figure 4.12. Exemple de différentes phases d'usinage identifiées.	88

Aucune entrée de table d'illustration n'a été trouvée.

Liste des tableaux

Tableau 2.1. Informations primaires sur les données.....	15
Tableau 2.2. Impact des journaux	19
Tableau 2.3. Impact des auteurs locaux	21
Tableau 2.4. Documents les plus cités dans le monde	24
Tableau 2.5. Production scientifique nationale sur les phénomènes du broutement par pays et continent dans WoS.....	26
Tableau 2.6. Les dix auteurs les plus révélateurs pour les deux groupes.....	32
Tableau 2.7. Documents les plus cités dans le monde avec leurs modèles utilisés.	33
Tableau 2.8. Comparaison entre différentes techniques de traitement du signal.	35
Tableau 2.9. Avantages et inconvénients des méthodes d'apprentissage automatique et d'apprentissage profond.....	41
Tableau 2.10. Les dix articles les plus performants en détection du broutement	42
Tableau 2.11. Liste des meilleurs modèles d'apprentissage profond avec les meilleures performances pour la détection du broutement.	43
Tableau 3.1. Modèles de l'apprentissage profond les plus courants dans la littérature et leurs applications dans l'usinage.	48
Tableau 3.2. Caractéristiques de la fraiseuse VF1	55
Tableau 3.3. Variation des paramètres d'entrée en fonction de la rugosité lors du fraisage avec l'outil ARS.....	57
Tableau 3.4. Variation des paramètres d'entrée en fonction de la rugosité lors du fraisage avec l'outil carbure.....	57
Tableau 3.5. Représentation des données des deux sources	59
Tableau 3.6. Comparaison des modèles unimodales et multimodale	66
Tableau 3.7. Les métriques d'évaluation pour la régression	68
Tableau 3.8. Rapport de classification	69
Tableau 4.1. Rapport de classification	83
Tableau 4.2. Matrice de confusion de données issues des FFT non bruitées (classe 1 : Usinage avec broutement, classe 2 : rotation à vide et, classe 3 : Usinage sans broutement)	84
Tableau 4.3. Matrice de confusion de données issues des FFT bruitées (classe 1 : Usinage avec broutement, classe 2 : rotation à vide et, classe 3 : Usinage sans broutement).....	84
Tableau 4.4. Liste de certains travaux ayant les meilleures performances en termes de justesse de classification	86

Chapitre 1 Introduction générale

1.1. Contexte

La progression rapide de la volumétrie des données dans les industries manufacturières est le fruit de la multiplication des processus d'acquisition, du stockage disponible et des possibilités de traitement de données. Cette progression permet d'envisager que l'usinage soit de plus en plus piloté par les données. L'intégration des capteurs, associés aux systèmes de communication et aux techniques de l'apprentissage machine (automatique) conduit à l'usinage intelligent, et révolutionne les paradigmes traditionnels du réglage et de la maintenance des machines historiquement basées sur des contrôles périodiques, clairement définis au départ. Les modèles pilotés par les données offrent à l'usinage des possibilités inédites qui vont faciliter la transition vers une production basée sur l'industrie 4.0, ou industrie du futur. Cette industrie repose sur des technologies comme l'internet des objets [124], les solutions de reconnaissance [84], la cybersécurité [46], le big data [55], etc. L'une des plus grandes difficultés pour la production industrielle est lorsqu'une dérive ou une panne se manifeste et qu'elle n'a pas été détectée ou éliminée à temps. L'internet des objets a favorisé la collecte de données liées à l'état et à l'environnement de fonctionnement des dispositifs industriels [201]. Cette collecte permet de fournir une vision intégrale des informations du monde physique pour effectuer un diagnostic basé sur les données, un pronostic des dispositifs et une surveillance de l'état de la santé des machines.

Les données collectées sont généralement des données multimodales dont l'intégration et la présentation sont un des challenges majeurs de la surveillance des machines et du diagnostic des défauts [160]. La multimodalité fait référence à la manière dont un événement se présente ou est expérimenté [19]. Un problème est qualifié de multimodal lorsqu'il inclut plusieurs modalités c'est-à-dire image, signal (température, vibratoire ou acoustique par ex.), texte, numérique, etc. Pour que l'intelligence artificielle parvienne à comprendre cet environnement, elle doit être capable d'interpréter simultanément ces différentes modalités. Même si la combinaison de différentes modalités ou sources d'informations pour améliorer les performances semble une tâche intéressante a priori, dans la pratique, il est difficile de combiner les différentes modalités. Cette difficulté est liée au fait que les modalités présentent des volumes d'information très différents, des temporalités très différentes, et des influences différentes sur le résultat de la prédiction.

Le traitement des données a connu des progrès considérables en intelligence artificielle. Le développement de l'apprentissage profond combiné aux techniques de capture d'images et d'analyse de séries temporelles fournit des outils puissants pour reconnaître les caractéristiques et les informations contenues dans une image, un signal, un texte. Cela a ouvert la voie à l'automatisation de l'analyse du contenu de ces modalités, en extrayant et en traitant les caractéristiques pertinentes. Les systèmes d'apprentissage utilisés sont basés sur des neurones artificiels avec des architectures dont les entités sont reliées entre elles pour former de nombreuses couches plus ou moins profondes. Dans les premières couches, ces architectures permettent un traitement hiérarchique des données à plusieurs échelles [96]. De plus, plus les couches sont profondes, plus les réponses du réseau sont invariables aux paramètres du signal qui n'ont pas d'intérêt. Basé sur l'apprentissage automatique, l'apprentissage profond permet aux modèles multicouches d'apprendre et de représenter des données avec plusieurs niveaux d'abstraction. L'apprentissage profond utilise donc plusieurs transformations, caractéristiques et représentations successives, imitant la façon dont le cerveau comprend et interprète l'information multimodale, qui capture automatiquement les structures complexes des données à grande échelle [104]. Il s'agit d'une approche émergente qui a été largement appliquée dans

des domaines traditionnels de l'intelligence artificielle, tels que l'analyse sémantique [28] l'apprentissage par transfert [32, 37], le traitement du langage naturel [114], la vision par ordinateur [207].

L'apprentissage profond a attiré l'intérêt des chercheurs pour les raisons suivantes : (i) premièrement, il a bénéficié de l'augmentation de la puissance de calcul avec l'avènement de processeurs graphiques surpuissants, pouvant être utilisés à ces fins, l'accès à du matériel à prix abordable, la qualité des plateformes informatiques et l'augmentation de la vitesse de connexion au réseau, ce qui réduit considérablement le temps d'exécution des algorithmes. (ii) deuxièmement, il dispose d'une capacité à faire face à la quantité croissante de données. (iii) troisièmement, il offre l'extraction de caractéristiques de manière non supervisée, c'est-à-dire sans expertise humaine [237]. L'apprentissage profond se développe à travers une grande famille de méthodes, englobant les réseaux de neurones, les modèles probabilistes hiérarchiques et une variété d'algorithmes d'apprentissage de caractéristiques non supervisés et supervisés. L'apprentissage profond joue un rôle croissant dans le cadre du développement de systèmes intelligents d'analyse descriptive, de diagnostic et de prédiction pour les machines-outils et la surveillance de l'état des opérations. Ces réseaux de neurones profonds peuvent jouer un rôle essentiel dans l'analyse des données multimodales, notamment pour une meilleure compréhension des caractéristiques décrivant les niveaux de qualité de surface des objets étudiés. L'apprentissage profond multimodal vise à mettre au point des modèles susceptibles de traitement et de connexion d'informations issues de modalités multiples (données issues d'éléments textuels, de signaux vibratoires ou d'images). L'apprentissage profond multimodal repose sur de grandes quantités de données provenant de capteurs hétérogènes afin d'obtenir des performances élevées et d'éviter les problèmes de surapprentissage. C'est un domaine multidisciplinaire dynamique d'importance croissante et doté d'un fort potentiel, toutefois avec de nombreux challenges. L'apprentissage automatique multimodal comprend la représentation, la translation, l'alignement, la fusion et le co-apprentissage [20].

- **La représentation multimodale :**

La représentation de données brutes dans un format compatible avec un modèle de calcul a toujours été un grand défi pour l'apprentissage machine. Une représentation multimodale est une interprétation de données utilisant des informations provenant de multiples entités modales. La représentation de plusieurs modalités pose de nombreuses difficultés : comment combiner les données provenant de sources hétérogènes, comment traiter les différents niveaux de bruit et comment traiter les données manquantes. La capacité à représenter et résumer les données multimodales d'une manière qui exploite la complémentarité et la redondance de multiples modalités est cruciale pour les problèmes multimodaux, et constitue l'épine dorsale de tout modèle de représentation.

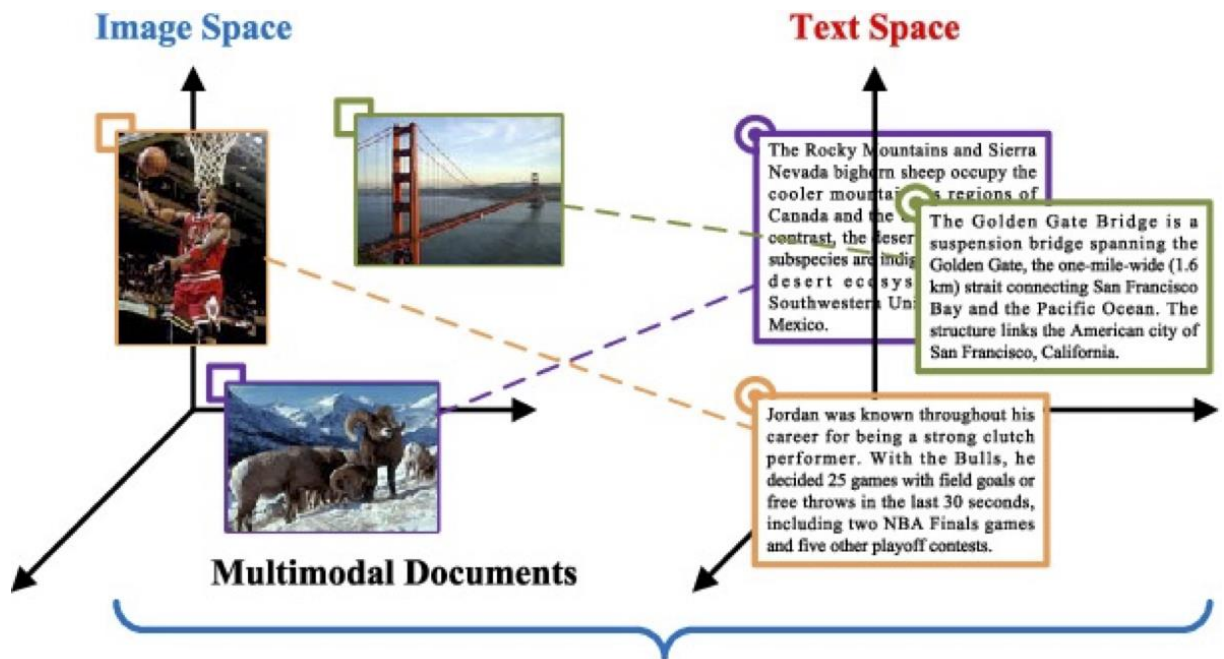


Figure 1.1. La représentation multimodale textes-images [70].

- **La Translation multimodal**

La traduction de données d'une modalité à une autre présente est une partie essentielle de l'apprentissage multimodal par machine. Si une entité est donnée dans une modalité, la tâche consiste à générer la même entité dans une modalité différente. Non seulement les données sont hétérogènes, mais la relation entre les modalités est souvent ouverte ou subjective. Par exemple, si l'on donne une image, on peut vouloir générer une phrase la décrivant ou, si l'on donne une description textuelle, on peut tenter de générer une image correspondant à celle-ci.

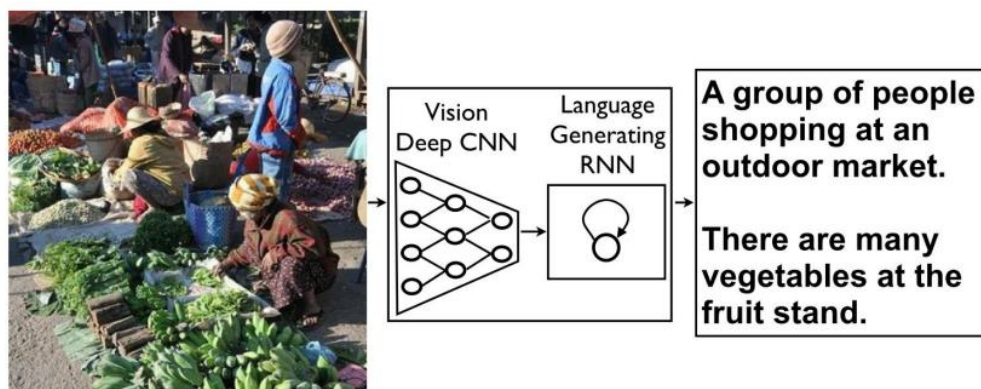


Figure 1.2. Translation multimodale image-texte [199].

- **L'alignement multimodal**

L'alignement consiste à déterminer les relations directes entre les éléments de deux ou plusieurs modalités. Les similitudes entre les différentes modalités sont mesurées et traitées pour déterminer les éventuelles dépendances et ambiguïtés à long terme entre les modalités. L'alignement multimodal comprend l'alignement implicite et explicite. Dans l'alignement explicite nous sommes particulièrement intéressés par l'alignement des sous-éléments entre les modalités, par exemple, l'alignement des étapes d'une méthode de conception d'un type de pièces de production avec la vidéo d'instruction correspondante et l'alignement implicite est

utilisé comme une étape intermédiaire (souvent latente) pour une autre tâche, par exemple, la recherche d'images basée sur la description d'un texte peut inclure une étape d'alignement entre les mots et les régions de l'image.




Figure 1.3. Aligned multimodal [85].

- **La fusion multimodale :**

L'un des thèmes originaux de l'apprentissage automatique multimodal, les travaux de la littérature distinguant les approches de fusion précoce (Figure 1.4), tardive (Figure 1.5) et hybride (Figure 1.6). Sur le plan technique, la fusion multimodale est le concept d'intégration d'informations à partir de modalités multiples avec l'objectif de prédire un résultat d'une mesure : une catégorie par classification, ou une valeur continue par régression. L'intérêt pour la fusion multimodale découle de trois principaux avantages qu'elle peut fournir. Premièrement, elle permet d'avoir accès à plusieurs modalités qui observent le même phénomène pour permettre d'obtenir des prévisions plus robustes. Secondairement, avoir accès à de multiples modalités pourrait nous permettre de capturer des informations complémentaires - quelque chose qui est non perceptible indépendamment dans les modalités individuelles. Troisièmement, un système multimodal peut toujours fonctionner quand l'une des modalités manque, par exemple reconnaître les caractéristiques d'un phénomène avec le signal visuel en l'absence de signal audio.




Figure 1.4. Fusion multimodale précoce




Figure 1.5. Fusion multimodale tardive

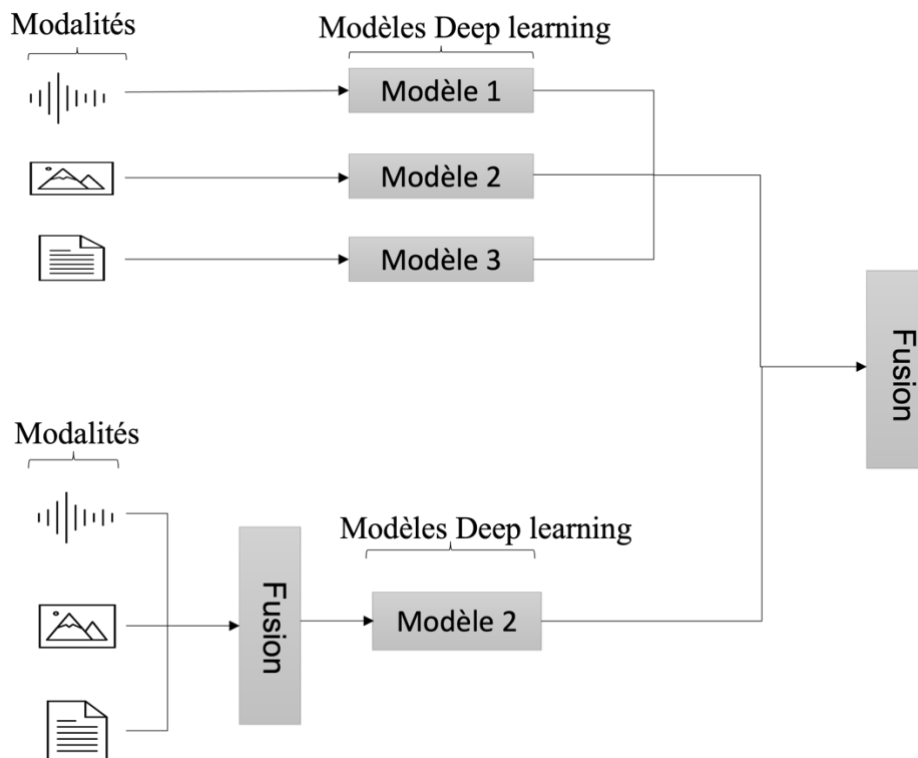


Figure 1.6. Fusion multimodale hybride

La fusion multimodale a suscité un intérêt considérable pour le traitement des données multimodales et une préoccupation générale chez les chercheurs [22]. Il existe plusieurs méthodologies capables d'intégrer des informations provenant de capteurs multimodaux pour améliorer les performances de surveillance, de diagnostic et de prédiction. La fusion de données multimodales est un domaine de recherche très dynamique appliqué dans divers secteurs industriels tels que l'automatisation, la fabrication et la robotique. L'objectif principal est de traiter des informations provenant de plusieurs sources hétérogènes afin d'estimer une vue plus précise des états structurels, fonctionnels et comportementaux d'une machine. Cela peut faciliter la reconnaissance de la scène [8, 71] et l'interaction homme-robot [48, 108]. En effet, dans certains environnements complexes, il est nécessaire d'utiliser plusieurs modalités qui

fournissent des informations supplémentaires sur la même situation et permettent d'améliorer la résolution de problèmes.

- **Le co-apprentissage Multimodal**

Les informations provenant de ces différentes modalités peuvent avoir une puissance prédictive et une topologie de bruits variables, avec éventuellement des données manquantes dans au moins une des modalités. Le co-apprentissage permet de transférer les connaissances entre les modalités, y compris leurs représentations et leurs modèles prédictifs. Le co-apprentissage explore comment l'apprentissage des connaissances d'une modalité peut aider un modèle informatique entraîné sur une modalité différente. Ce défi est particulièrement pertinent lorsque l'une des modalités a des ressources limitées (par exemple, des données annotées).

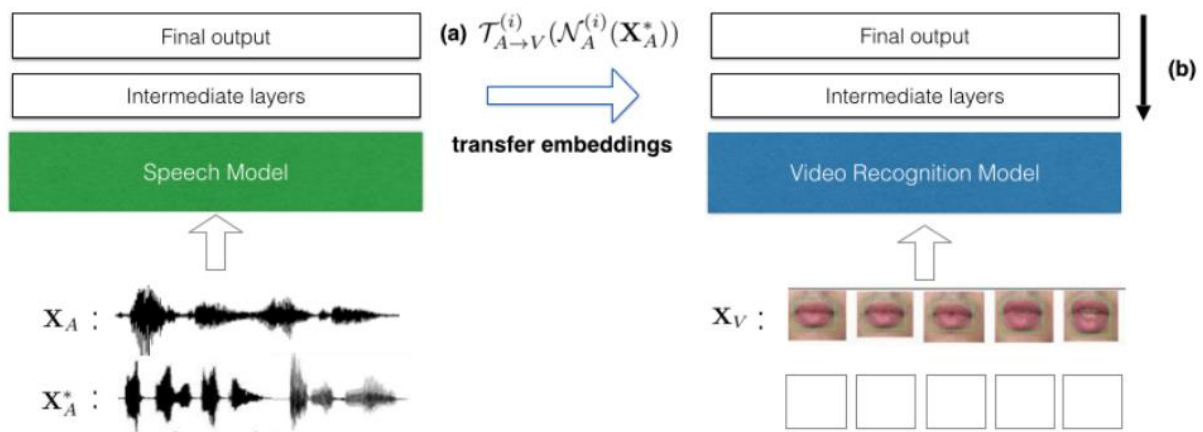


Figure 1.7. Co-apprentissage multimodal son-vidéo [130].

La plupart des démarches scientifiques dans la littérature traitant de la multimodalité sont orientées vers des applications médicales, commerciales et sociétales [70, 94], mais il y a très peu de travaux liés au cadre industriel. L'apprentissage profond multimodal n'est encore qu'à ses débuts dans le monde industriel, mais sa pertinence ne fait aucun doute. Ceci est notamment souligné par des travaux récents tels que la détection et le diagnostic des défauts [24, 47, 80], la collaboration homme-robot [111] et l'estimation de la durée de vie utile restante des systèmes dans l'industrie [7]. La majorité des recherches dans l'industrie de fabrication se sont concentrées sur la surveillance de l'état d'usure de l'outil et la prédiction de l'usure du flanc de l'outil, de la durée de vie utile restante de l'outil et collaboration homme-robot. Peu d'études ont été réalisées sur l'utilisation des modèles d'apprentissage profond ou de l'apprentissage profond multimodal pour la détection du broutement de vibration, la sélection optimale de paramètres de coupe et la surveillance de la rugosité de surface.

La surveillance du processus de coupe est l'un des principaux facteurs d'amélioration de la productivité et de la qualité des produits dans l'industrie manufacturière moderne. Sans aucun doute, la détection du broutement de la machine-outil est l'un des principaux enjeux du processus de fraisage. Historiquement, le broutement est décrit par le père de l'usinage F. W. Taylor [182] comme étant le problème le plus obscur et le plus délicat auquel le machiniste est confronté, cela est toujours le cas. Avant de recourir à des méthodes sophistiquées de sélection des caractéristiques et à des modèles d'apprentissage automatique, le traitement adéquat des signaux est la base de l'amélioration des performances des systèmes de surveillance [133].

Dans la littérature récente, de nombreux travaux [16, 63, 154, 155, 191, 220] ont été appliqués pour démontrer les potentialités de ces méthodes pour la détection du phénomène de broutement. Dans ces recherches relativement récentes, de nombreuses techniques d'apprentissage profond ont été testées, souvent mélangées à d'autres méthodes, conduisent

généralement à de bons résultats. En plus de la détection du broutement, la sélection des paramètres de coupe est importante pour obtenir des performances de coupe élevées. En général, les paramètres de coupe sont définis sur la base de l'expérience ou à l'aide de tableaux de valeurs et de formules simples. Plusieurs recherches récentes appliquant l'apprentissage automatique pour modéliser les paramètres des processus de coupe d'usinage existent dans la littérature [6, 36, 62, 196]. Ces études se concentrent en général sur la prédiction de la durée de vie de l'outil, la force de coupe et la rugosité de surface. Lors de la planification du processus d'usinage, l'outil de coupe et les paramètres de coupe sont des éléments décisifs [38, 39, 137] pour réduire considérablement la consommation d'énergie et le temps de production du processus d'usinage. Malgré l'obtention des méthodes avec de bonnes performances, on peut signaler plusieurs faiblesses méthodologiques : (i) la plupart des études utilisent des conditions d'usinage éloignées des applications industrielles, seulement quelques-unes utilisent des conditions de coupe réalistes. (ii) Il apparaît toujours dans ces études que l'amplitude des vibrations est clairement associée au broutement, ce qui rend difficile de déterminer si toutes ces techniques sophistiquées sont meilleures que la surveillance classique du niveau moyen quadratique (RMS), par exemple. (iii) De plus, toutes les études de la littérature sont basées sur des essais d'usinage en laboratoire, donc sans les contraintes du bruit et de la variété des situations à gérer dans l'industrie et des incertitudes sur les paramètres réels. Il reste donc largement à définir une méthode pratique et robuste, permettant d'identifier rapidement le broutement ou de l'éviter sans avoir besoin d'un expert en analyse vibratoire pour affiner les paramètres de détection.

Dans cette thèse, nous proposons dans un premier temps, une première approche basée sur l'apprentissage profond multimodal, montrant la capacité à identifier des liens entre des conditions de coupe et le résultat sur la pièce usinée (profil de rugosité et photo). Cette approche a pour but à terme d'aider l'usineur à sélectionner l'outil de coupe et les paramètres de coupe appropriés pour obtenir l'état de surface visé. La collecte de données qui est l'une des tâches principales de l'apprentissage profond multimodal, a été réalisée en menant des expérimentations sur une plaque d'aluminium dans un processus de fraisage. Cette collecte a permis d'obtenir deux types de données : les images des surfaces de la pièce usinée, les paramètres de coupe utilisés lors du processus de fraisage et la rugosité de surface mesurée par un rugosimètre. Ensuite, nous avons procédé à un alignement de ces données (un des défis de l'apprentissage multimodal) pour la mise en relations des deux sources. Nous avons opté pour la méthode de fusion tardive qui extrait parallèlement les caractéristiques des deux sources de données (images et numérique) avec deux modèles de réseau de neurones profond pour prédire le choix des paramètres de coupe.

Ce premier travail a apporté des résultats intéressants, mais a aussi montré des limites à la réalisation de l'approche d'apprentissage profond multimodal pour la prédiction du choix des paramètres de coupe telles que :

- L'acquisition de données multi-capteurs qui est une tâche complexe dans la fabrication.
- L'indisponibilité des experts pour le placement des capteurs et l'analyse préliminaire des données.
- Les données collectées par les différents capteurs qui ne sont généralement pas synchronisées et dont l'intégration est complexe sur des machines-outils.

Dans un second temps, nous nous sommes alors orientés vers un autre type de multimodalité couplant les signaux sonores et les images avec un focus sur un challenge singulier de l'apprentissage à savoir la translation multimodale. Compte tenu des difficultés rencontrées lors de l'acquisition de données multi-capteurs, basée sur l'apprentissage profond

pour détecter le phénomène de broutement dans l'usinage, nous pensons que la translation multimodale pourrait y apporter une contribution théorique et applicative. Pour ce faire, nous avons utilisé un signal vibratoire de l'usinage d'un système industriel ferroviaire sur (Alstom) pour générer des images avec l'analyse de la transformée de Fourier rapide, ou Fast Fourier Transform (FFT), pour attaquer la faiblesse méthodologique (i) évoquée précédemment. Pour les autres faiblesses (ii) et (iii), nous avons réalisé les FFT en les renormalisant en amplitude, et sans indiquer au système d'apprentissage les changements de paramètres d'usinage (engagements outils et rotation broche). Ensuite, une transformation a été appliquée pour extraire les caractéristiques des images obtenues à partir de la FFT en exploitant l'apprentissage par transfert via des réseaux pré-entraînés. Trois cas ont été définis comme classes (usinage sans broutement, usinage avec broutement et rotation à vide) dans le signal.

Les résultats obtenus dans nos travaux ont contribué à montrer les potentialités de la multimodalité comparée à un modèle unimodal pour l'optimisation des paramètres de coupe, dans le processus de fraisage. Pour la détection du broutement, il a été démontré que même sans information sur l'amplitude et les différentes conditions de coupe évoluant pendant l'usinage (engagements et vitesses), le modèle parvient à identifier le broutement. Cette détection non triviale est intéressante, car même un expert humain aurait eu beaucoup de difficultés à identifier le broutement dans de telles conditions. De plus, comme une partie des données de test est similaire aux données d'entraînement, la robustesse a été prouvée avec l'ajout d'une autre partie plus bruyante et ambiguë à interpréter, et malgré cela le modèle parvient à détecter aussi les cas les plus difficiles à partir de son apprentissage sur des cas faciles.

1.2. Objectifs de la thèse

Ce travail de thèse s'est intéressé aux développements des systèmes de décision pour le choix des paramètres de coupe et la détection du broutement d'usinage à l'aide des techniques d'apprentissage profond. (i) Notamment l'apprentissage profond multimodal pour la prédiction du choix des paramètres de coupe. Pour ce faire, nous avons effectué un état de l'art sur la prédiction des paramètres de coupe dans le but d'identifier les apports scientifiques exploitant les méthodes d'apprentissage automatiques et recenser les challenges. (ii) la détection du broutement d'usinage en exploitant une méthode d'apprentissage profond (les réseaux de neurones profonds). Nous avons réalisé une étude bibliométrique et identifié deux stratégies complémentaires de détection broutement d'usinage.

Étant donné que ces modèles nécessitent beaucoup de données pour obtenir une bonne performance. Nous avons collecté la base de données multimodales en menant des expériences sur une fraiseuse à commande numérique et nous avons aussi utilisé les signaux des vibrations obtenus lors d'un processus d'usinage d'Alstom Transport pour le fraisage des parois des voitures TGV.

1.3. Contributions

Pour atteindre les objectifs définis ci-dessus, tout d'abord, nous proposons l'apprentissage profond multimodal pour la prédiction du choix des paramètres de coupe. Deuxièmement, une analyse bibliométrique sur les différentes techniques de détection du broutement. Troisièmement, une approche basée sur les compétences mécaniques et les réseaux de neurones réentraînés pour détecter le broutement d'usinage dans le signal. Ces contributions sont résumées ci-dessous.

Apprentissage profond multimodal pour la prédiction du choix des paramètres de coupe dans le processus de fraisage

L'apprentissage profond multimodal a été utilisé pour associer un choix de conditions de coupe (outil, vitesse de coupe, profondeur de coupe et vitesse d'avance par dents) avec un état de surface, en considérant la rugosité arithmétique moyenne (Ra) et une photo de la pièce. Nous avons construit un modèle de fusion multimodale tardive avec deux réseaux de neurones profonds, un réseau de neurones convolutif (CNN) et un réseau de neurones récurrent avec des couches de mémoire à long terme (LSTM). Le premier réseau consiste en une première branche avec un réseau de neurones convolutif qui reçoit les images d'entrée. Dans le second réseau, la modélisation est effectuée par le réseau de neurones récurrent contenant des couches LSTM pour recevoir les données numériques d'entrée. Ceci fournit un cadre pour intégrer les informations provenant de deux modalités afin de garantir la qualité de surface dans les processus d'usinage. On observe que les performances du modèle multimodal sont meilleures que celles du modèle unimodal sur les données d'image. La précision continue à s'améliorer sur les deux ensembles (entraînement et validation), et le modèle multimodal atteint finalement de bons résultats de précision. Contrairement au modèle unimodal, qui ne parvient pas à généraliser l'entraînement sur un ensemble de données de validation. Les résultats estimés par le modèle de fusion multimodale sont encourageants pour une éventuelle application dans les processus de fraisage d'une production industrielle. Ce travail a fait l'objet d'une publication dans une revue internationale.

Kounta, C., Kamsu Foguem, B., Noureddine, F., Tangara, F., 2022. Multimodal deep learning for predicting the choice of cut parameters in the milling process. *Intelligent Systems with Applications*. <https://doi.org/10.1016/j.iswa.2022.200112>

Revue des méthodes basées sur l'IA pour la détection du broutement dans l'usinage à partir d'une analyse bibliométrique

Pour améliorer la qualité et l'efficacité des processus d'usinage, les chercheurs ont entrepris depuis longtemps de développer des techniques pour détecter, supprimer ou éviter le broutement des vibrations. Ce travail consiste à retracer les techniques de détection du broutement, depuis les méthodes de traitement du signal temps-fréquence (FFT, HHT, STFT, etc.), la décomposition (WPD, EMD, VMD, etc.) jusqu'à la combinaison avec des modèles d'apprentissage automatique ou d'apprentissage profond. Une analyse cartographique a été réalisée afin d'identifier les limites de ces différentes techniques et de proposer des axes de recherche pour détecter le broutement dans les processus d'usinage. Le fait que l'expert humain détecte le broutement en exploitant de simples spectrogrammes est confronté à la variété et à la sophistication des méthodes de traitement du signal utilisées dans la littérature, et nous a conduits à d'éventuelles techniques de détection optimales. À cette fin, l'outil bibliométrique R - Tool a été utilisé pour faciliter une analyse bibliométrique en exploitant des moyens spécifiques pour la recherche bibliométrique quantitative et la visualisation. Les données ont été collectées à partir du web of science (WoS 2022) en exploitant des requêtes particulières sur la détection du broutement. La plupart des documents recueillis présentent la détection du broutement à l'aide de techniques de transformation ou de décomposition.

Kounta, C.A.K.A., Arnaud, L., Kamsu-Foguem, B. et al. Review of AI-based methods for chatter detection in machining based on bibliometric analysis. *Int J Adv Manuf Technol* (2022). <https://doi.org/10.1007/s00170-022-10059-9>

Apprentissage profond pour la détection du broutement dans l'usinage

La plupart des travaux sur la détection du broutement sont basés sur des essais d'usinage en laboratoire, donc sans les contraintes du bruit, de la variété des situations à gérer dans l'industrie, et des incertitudes sur les paramètres (position du capteur, engagement outil, et parfois même fréquence de rotation broche). Ce travail présente une approche basée sur des compétences mécaniques pour d'abord identifier les traitements optimaux des signaux puis l'apprentissage profond pour détecter automatiquement le phénomène de broutement en usinage. Pour ce faire, on utilise des images d'entrée issues de l'analyse de la transformée de Fourier rapide sur un signal vibratoire de l'usinage d'un système ferroviaire industriel d'Alstom. Les images FFT sont d'abord recadrées en hauteur pour effectuer une renormalisation de l'échelle du signal. Cette étape de renormalisation élimine un biais systématiquement observé dans la littérature, qui ne permettait pas d'éliminer une simple corrélation avec l'amplitude du signal, du fait que le broutement est souvent, mais pas toujours, associé à des vibrations plus fortes. Les images ont ensuite été recadrées latéralement pour réduire la gamme fréquentielle entre 0-2500Hz, et rééchantillonnées afin de réduire la taille de l'image. L'apprentissage profond a été utilisé pour extraire les caractéristiques des données d'image en exploitant les réseaux de neurones profonds pré-entraînés tels que VGG16 et ResNet50. Les résultats obtenus montrent la bonne performance du modèle avec une précision de 99%. Cette généralisation est démontrée, étant donné que l'amplitude du signal n'est pas transmise au réseau et qu'il n'a pas été étiqueté que plusieurs vitesses de rotation ont été utilisées pendant l'usinage. Le modèle parvient donc bien à voir l'information du broutement dans le spectre, sans connaître l'amplitude du signal et en s'adaptant à plusieurs vitesses de rotation, ce qui même pour un expert humain deviendrait une tâche difficile. De plus, comme une partie des données de test est similaire aux données d'entraînement, la robustesse est prouvée avec l'ajout d'un autre ensemble de tests contenant des images bruitées et plus ou moins ambiguës à classer. Le modèle parvient toujours à détecter ces cas à partir de son apprentissage des cas non bruités, ce qui montre que la généralisation obtenue est réellement efficace.

[Article en révision dans le journal *Advanced in Engineering Software*]

1.4. Organisation du manuscrit

Cette thèse est structurée en quatre chapitres. Après l'introduction générale, le chapitre 2 propose une revue bibliométrique sur les méthodes de détection du phénomène de broutement, dans laquelle les techniques de détection existantes sont analysées en identifiant les limites et les avantages de littérature dans ce domaine. Le chapitre 3 fournit un état de l'art sur l'application de l'apprentissage multimodal dans les processus d'usinage et une étude de cas pour l'identification des paramètres de coupe. Une technique de détection du broutement basée sur l'apprentissage profond est proposée dans le chapitre 4. Cette méthode permet de distinguer deux cas majeurs (usinage sans broutement et usinage avec broutement). Le chapitre 5 présente

la conclusion et les perspectives. La Figure 1.8 représente l'organisation de ce manuscrit de thèse.




Figure 1.8. Organisation du manuscrit

Chapitre 2 Revue des méthodes basées sur l'IA pour la détection du broutement dans l'usinage à partir d'une analyse bibliométrique

2.1. Introduction

Historiquement, le broutement est décrit par le père de l'usinage [184] comme le problème le plus obscur et le plus délicat de tous ceux auxquels est confronté l'usineur. Dans le cas de pièces moulées et forgées de formes diverses, il n'y a probablement aucune règle ou formule qui puisse guider avec précision l'usineur pour définir les conditions de coupes et notamment les vitesses maximales sans produire de broutement. Quelques décennies plus tard, d'abord dans un livre en slovaque [188] puis dans des publications internationales par les documents [128, 187, 189], la théorie des lobes de stabilité a montré qu'il était possible de résoudre le problème du broutement. La fréquence de vibration auto-excitée appelée broutement est toujours un phénomène de vibration très connu dans l'usinage et il nuit à la qualité de la finition de surface et à la durée de vie de l'outil [1]. Le broutement se manifeste principalement par la régénération de l'ondulation provoquée par l'interaction entre la surface du matériau et l'outil à des fréquences de rotation données de la broche et par l'interaction d'un ou de plusieurs modes propres vibratoires. Plusieurs chercheurs ont étudié la technique de détection du broutement dans les signaux vibratoires, par exemple les auteurs Abele *et al.* et Jantunen *et al.* [83, 90]. Ce sont les signaux de force de coupe, d'accélération, de son et de courant électrique qui sont le plus couramment utilisés pour surveiller l'état des systèmes [174].

Plusieurs algorithmes de traitement du signal ont été appliqués avec succès à la détection de broutement, tels que la transformée de Fourier à court terme (STFT) [90, 186], la transformée en ondelettes (WT) [113, 208], la décomposition en paquets d'ondelettes (WPD) [236], la transformée de Hilbert -Huang (HHT) [31, 60, 150], la décomposition en modes empiriques (EMD) [41, 165], la décomposition en mode variationnel (VMD) [105, 112] et la décomposition moyenne locale (LMD) [148].

Généralement, cette détection est basée sur le traitement du signal et effectuée en trois étapes progressives : la collecte du signal, l'extraction des caractéristiques et la détection ou l'identification des défauts [117]. Auparavant, la détection du broutement était établie sur la base de l'expérience abondante des ingénieurs et principalement basée sur l'analyse acoustique humaine du processus. Il est également indispensable de surveiller l'état de l'outil et de détecter toute anomalie pouvant survenir lors de l'usinage afin d'éviter toute situation dangereuse [156]. Dans toute opération d'usinage, la durée de vie de l'outil de coupe affecte directement la qualité et le coût du processus. En surveillant l'état des outils, il est possible de réduire les problèmes tels que l'usure accélérée, la rupture des outils, et le broutement pendant l'usinage. Ce chapitre passe en revue la littérature sur les techniques de détection ou d'identification du broutement induit par les vibrations. Plusieurs techniques d'atténuation des vibrations, y compris la rigidification dans les machines-outils ou porte-pièces, et les techniques d'amortissement actif ou passif, existent également [132, 227]. En surveillant et en analysant les signaux vibratoires à proximité de l'outil et de la pièce, non seulement le broutement mais aussi l'état de la machine-outil peuvent être détectés efficacement, et même permettre de développer un jumeau numérique de la machine [3]. Les méthodes analytiques prédominantes utilisent des diagrammes dits de lobes de stabilité pour prédire la stabilité des procédés d'usinage. Des modèles de traitement temps-fréquence, exploitant une large gamme de transformations mathématiques et de décomposition, ont été utilisés dans la détection du broutement, que ce soit dans le fraisage, le tournage, le perçage ou la rectification. Toutes ces méthodes sophistiquées rencontrent des difficultés à détecter les vibrations non évidentes (c'est-à-dire lorsqu'il n'y a pas d'augmentation substantielle du niveau de vibration moyen, ou directement

du bruit) ainsi que dans le cas de signaux de vibration industriels, bruyants (rarement pris en compte). Ces difficultés doivent aussi être confrontées au fait que les experts du broutement n'utilisent sur le terrain que des représentations de spectre et de spectrogramme pour détecter le broutement.

Assez récemment, l'apprentissage profond (Figure 2.1) est apparu comme un concept général faisant référence au groupe de méthodes basées sur les réseaux de neurones le plus récent et le plus abouti et s'est avéré très efficace dans de nombreux domaines.




Figure 2.1. Le modèle d'apprentissage automatique pour la classification binaire, inspiré de [138]

Pour réduire la contribution humaine dans le diagnostic et la détection des défauts, l'intégration des théories d'apprentissage automatique (Figure 2.2) à l'analyse vibratoire est une voie prometteuse pour automatiser les procédures actuellement utilisées, c.f. [99].




Figure 2.2. Le modèle d'apprentissage profond pour une classification binaire, inspiré de [138]

Ce chapitre vise à fournir un examen complet des techniques de détection de broutement, des techniques de traitement temps-fréquence aux techniques d'intelligence artificielle (IA), et à identifier les thématiques les plus prometteuses et les plus émergentes. Pour effectuer cette analyse approfondie, l'outil bibliométrique R-Tool a été utilisé suivant le document [15], avec un package R destiné à faciliter l'analyse bibliométrique, basée sur le logiciel open source R, l'un des environnements logiciels les plus influents et flexibles pour les statistiques et la science des données. Cette analyse offre une nouvelle perspective sur l'évolution des techniques de détection, d'identification ou de suppression du broutement en usinage en développant une taxonomie des connaissances pour les sujets de recherche dans le domaine.

Une analyse approfondie des études passées et actuelles sur l'évolution des techniques de détection de broutement est réalisée sur 679 publications de recherche entre 1985 et 2022. Cette étude donne un aperçu de l'application de l'IA dans la détection de broutement dans l'usinage et à les confronter aux besoins industriels particuliers concernant la détection de broutement, notamment sans avoir à calibrer l'amplitude du signal vibratoire car le signal peut être plus ou moins intense selon le type de capteurs et leurs positions, ou les fréquences de fonctionnement

de la machine, qui peuvent être difficiles à capter ou erronées du fait de la présence de réducteurs ou de boîtes de vitesses, par exemple. Une autre perspective est l'opportunité d'utiliser l'apprentissage non supervisé pour détecter des phénomènes non identifiés a priori par l'expert humain.

Le reste du chapitre est organisé comme suit : Section 2.2 décrit l'analyse bibliométrique, Section 2.3 présente des travaux antérieurs sur les techniques de traitement temps-fréquence et IA pour détecter le broutement dans l'usinage, et la Section 2.4 présente des défis avec des opportunités et des solutions dans l'usinage. Le chapitre se termine par la Section 2.5.

2.2. Analyse bibliométrique

Informations sur les données

L'analyse bibliométrique identifiera les paramètres clés liés aux sources, documents, auteurs, mots-clés et pays de cette section. L'analyse bibliométrique identifiera les paramètres clés liés aux sources, aux documents, aux auteurs, aux mots-clés et aux gouvernements. Dans cette section, l'analyse nous permettra également de classer et de visualiser les publications selon leur impact, leur intérêt, la fréquence des citations et la collaboration dans le domaine de la recherche. L'intérêt de l'analyse bibliométrique est d'acquérir de nouvelles informations qui donneront une vue d'ensemble du domaine visé et serviront de sujet de perspective pour la recherche scientifique.

Les données de cette recherche ont été collectées à partir de la base de données Web of Science (WoS). Tous les articles et revues inclus dans l'analyse ont été rédigés en anglais. Étant donné que les revues systématiques de la littérature reposent sur une sélection rigoureuse des mots-clés, il a été décidé que les mots-clés, (chatter detection, time-frequency processing, machine learning, and deep learning), devraient apparaître dans le titre, les mots-clés ou le texte. Pour la stratégie de recherche de données, les requêtes suivantes ont été utilisées dans la base de données WoS ("Web of Science avril 2022") :

- ("chatter detection" OR "chatter identification" OR "chatter recognition" OR "chatter suppression")
- ("chatter detection" OR "chatter identification" OR "chatter recognition" OR "chatter suppression") AND ("machine learning" OR "Deep learning" OR "Artificial Intelligence")

La première requête a été exécutée pour récupérer 679 publications de recherche, dont 350 publications en ingénierie de fabrication, 290 publications en ingénierie mécanique et 173 publications en systèmes de contrôle d'automatisation (Figure 2.3).




Figure 2.3. Classement des publications dans différents domaines de recherche.

Le Tableau 2.1 présente les informations préliminaires sur les données collectées sur WoS entre 1985 et 2022. Ce tableau rapporte des informations telles que le nombre de documents obtenus, la période de recherche, les mots-clés de l'auteur et les mots-clés. Les auteurs fournissent les mots clés de l'auteur dans ce cas (1546) mots. Les mots-clés plus (652) sont générés à partir d'un algorithme pour extraire les mots apparaissant fréquemment dans les références de titres, pas seulement les titres de documents ou les mots-clés d'auteurs. L'outil bibliométrique nous a permis de connaître l'apparence de l'auteur (1425), les auteurs de documents mono-auteur (11), les auteurs de documents multi-auteurs (1414), le nombre moyen d'auteurs par document (2,25), et la collaboration indice (2.27). La Figure 2.4 présente le classement des publications par type de document, avec 482 articles, 155 comptes rendus et 14 comptes rendus.

Tableau 2.1. Informations primaires sur les données.

Description	Résultats
Période	1985 :2022
Sources (revues, livres, etc.)	250
Documents	679
Moyenne annuelle de publication	7,13
Moyenne de citations par documents	18
Moyenne des citations par an et par doc	2,179
Références	10565
TYPE de DOCUMENT	
article	482

article ; chapitre de livre	5
article ; accès rapide	6
article ; compte-rendu	14
correction	1
lettre	2
compte-rendu	155
Enquête	14
CONTENU DU DOCUMENT	
Mots-clés Plus (ID)	652
Mots clés de l'auteur (DE)	1546
AUTEURS	
Auteurs	1425
Apparitions d'auteurs	2484
Authors of single-authored documents	11
Authors of multi-authored documents	1414
AUTHOR'S COLLABORATION	
Documents à auteur unique	12
Documents par auteur	0,476
Auteurs par document	2,1
Co-auteurs par documents	3,66
Indice de collaboration	2,12

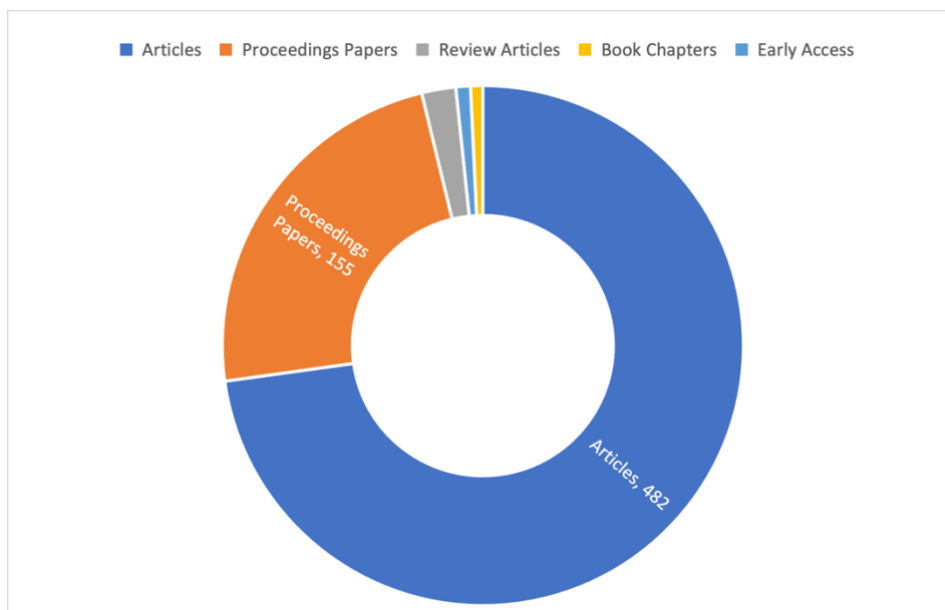


Figure 2.4. Classement des publications par type de documents.

La Figure 2.5 montre la fréquence de publication au cours de la période 1985-avril 2022. Les publications scientifiques sur les techniques de détection de broutement ont commencé à atteindre 40 publications par an en 2017, et l'évolution a culminé en 2019 avec 83 publications. Entre janvier et avril 2022, il y a eu 26 articles sur la détection du broutement.




Figure 2.5. Production scientifique annuelle.

La croissance de la production scientifique annuelle est due à l'élargissement de la base d'observation avec l'ajout de nouveaux supports de publication (revues, actes de congrès, chapitres d'ouvrages collectifs, etc.) dans la base de données comme (WoS et Scopus). Cet ajout se fait de deux manières, et d'une part, les bases d'observation intègrent les revues existantes après un processus de sélection pour mieux couvrir la production scientifique mondiale. Les revues sont également créées en développant de nouvelles thématiques scientifiques [121]. La

Figure 2.6 illustre cette croissance en exploitant le terme plus générique « machining » comme requête.




Figure 2.6. Production scientifique annuelle exploitant le [135] terme « usinage » en recherche.

Dans la présente étude, on note que la détection du broutement est vue presque autant du côté de la fabrication que du côté mécanique. En revanche, a priori, il ne serait vu que du côté de la fabrication et éventuellement comme un système automatique. La plupart des publications datent de moins de 6 ans, et de nombreuses études ont porté sur le développement d'algorithmes analytiques et numériques pour la prédiction du broutement [129], [64][56].

L'intégration de concepts tels que l'Internet des objets (IoT) a considérablement façonné l'industrie manufacturière. Le développement de la science et de la technologie a permis l'intégration de concepts tels que l'IoT car des technologies multi-capteurs volumétriques et fiables sont intégrées pour collecter des données. La croissance de la taille des données dans l'industrie et le stockage et le traitement des mégadonnées soulignent la nécessité d'une fabrication axée sur les données en tant que composant essentiel de la fabrication intelligente. À cette fin, la recherche s'est concentrée sur la combinaison de modèles basés sur la physique (FFT, WT, etc.) avec des modèles informatiques basés sur les données (apprentissage automatique et apprentissage profond) [139, 158].

Sources

Pour montrer la dynamique de la croissance de la productivité des revues, leurs impacts et nombre de citations, et leurs réseaux de collaborations, le Tableau 2.2 présente les revues les plus productives selon le nombre de publications (NP), le nombre de citations (TC), et les impacts (h-index, g-index, m-index). Le H-index [76] est défini comme le nombre de publications pour lesquelles l'auteur a reçu au moins des h-citations. Le G-index est une mesure au niveau de l'auteur proposée par Egghe [53], qui est calculée sur la base de la distribution des citations reçues par les publications d'un auteur donné, étant donné un ensemble d'articles classés par ordre décroissant du nombre de citations qu'ils ont reçues. m-index [26] est le nombre de publications pour lesquelles l'auteur a reçu au moins h-citations.

Tableau 2.2. Impact des journaux

Sources	h_index	g_index	m_index	TC	NP	PY_start
International Journal of Advanced Manufacturing Technology	21	30	0.78	1414	94	1996
International Journal of Machine Tools & Manufacture	30	44	0.97	2661	44	1992
Mechanical Systems and Signal Processing	17	29	0.49	860	31	1988
Journal of Manufacturing Science and Engineering-Transactions of the Asme	12	22	0.44	493	26	1996
CIRP Annals-Manufacturing Technology	13	18	0.62	2146	18	2002
Proceedings of the Institution of Mechanical Engineers Part B-Journal of Engineering Manufacture	8	14	0.38	214	16	2002
Journal of Sound and Vibration	12	15	0.48	709	15	1998
Journal of Vibration and Control	8	12	0.62	209	12	2010
Precision Engineering-Journal of the International Societies for Precision Engineering and Nanotechnology	7	10	0.58	117	10	2011
Measurement	6	9	1	122	9	2017
Journal of Materials Processing Technology	6	8	0.26	473	8	2000
Journal of Intelligent Manufacturing	5	7	0.17	121	7	1994
Materials	4	6	1	59	6	2019
Advances in Manufacturing	3	5	0.5	32	5	2017
Applied Sciences-Basel	4	5	0.67	29	5	2017
Chinese Journal of Aeronautics	5	5	0.33	223	5	2008
International Journal of Mechanical Sciences	5	5	0.38	177	5	2010
Machining Science and Technology	3	5	0.14	70	5	2002
Mechatronics	3	5	0.14	82	5	2001
Chinese Journal of Mechanical Engineering	3	4	0.23	30	4	2010

« International Journal of Advanced Manufacturing Technology » est la revue la plus productive (94) en nombre de publications soit plus de 25% des articles. « International Journal of Machine Tools & Manufacture » arrive en deuxième position (44) et « Mechanical Systems and Signal Processing » avec 31 publications en troisième position. Cependant, il convient de noter que la revue la plus productive n'est pas nécessairement la plus citée. Par exemple, « CIRP Annals-Manufacturing Technology » est plus cité que « Mechanical Systems and Signal Processing » car moins productive que « International Journal of Advanced Manufacturing Technology » (Figure 2.7).

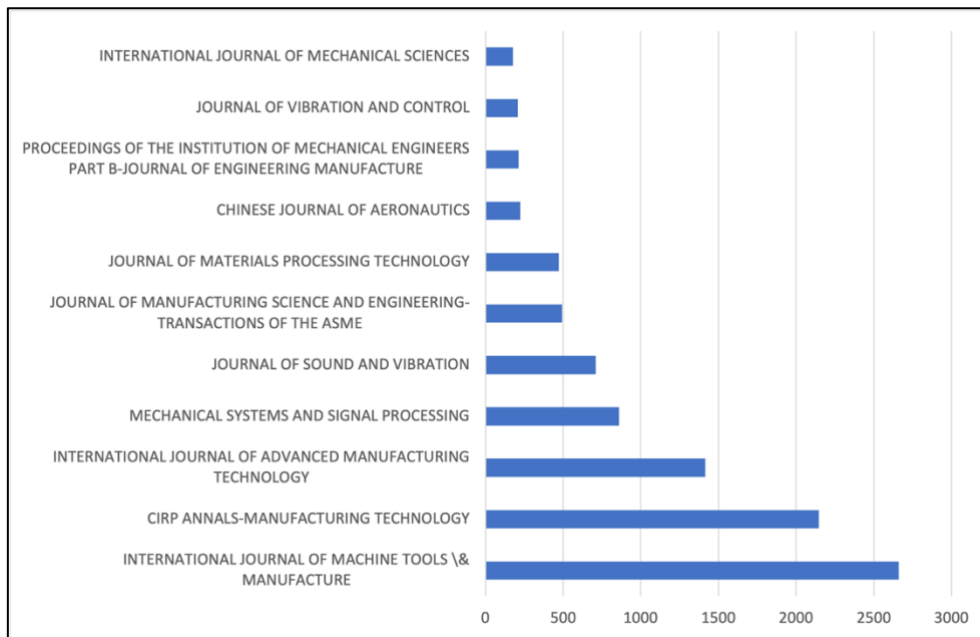


Figure 2.7. Classement des revues par plusieurs citations.

Sur la Figure 2.7, l'axe vertical montre les noms des revues de publication scientifique, et l'axe horizontal indique le nombre de citations de revues dans la recherche sur les techniques de détection de broutement. Les journaux sont classés par ordre décroissant. L'International Journal of Machine Tools & Manufacture est en tête avec 2661 (TC), suivi de CIRP Anales-Manufacturing Technology 2146 (TC) et International Journal of Manufacturing Technology, etc.

Auteurs

L'outil bibliométrique comptabilise les citations locales d'un article et d'un auteur dans les références les plus citées. Le nombre de citations locales présente le nombre d'apparitions d'un auteur dans les documents collectés pour cette étude. D'après la Figure 2.8, Y. Altintas est l'auteur le plus cité (1585 citations au total), le nombre dans le cercle est le nombre de citations locales, et la longueur du trait dépend de ce nombre.




Figure 2.8. Impact local de l'auteur par indice TC.

Y. Altintas est probablement le chercheur le plus célèbre sur les vibrations d'usinage (voir Tableau 2.3). Il a été expliqué que la majeure partie du processus de broutement en faisant l'équation et en enrichissant les modèles d'IA avec les modèles mécaniques. Il démontre avec un modèle de simulation numérique sur le fraisage dynamique que l'utilisation d'une vitesse de broche variable en continu peut être un moyen de supprimer le broutement [10]. Il a été suivi par D. Dornfeld (731 citations au total), qui ne se spécialise pas dans l'usinage des vibrations, la science de données ou l'IA, mais a été prolifique dans l'usinage de précision et l'utilisation de capteurs. K. Jemielniak partage le même score avec G. O'Donnell et R. Teti (726 citations au total), qui sont des chercheurs classiques travaillant depuis des décennies sur l'usinage. Ces auteurs ont une excellente connaissance du domaine et proposent de nouvelles techniques pour détecter, identifier ou localiser le broutement pour la stabilité de l'usinage dans le temps. Ils travaillent avec D. Dornfeld sur un article dans *Advanced Monitoring of Machining Operations* passant en revue les contributions passées et proposant une mise à jour complète sur les technologies de capteurs, le traitement du signal et, surtout, les stratégies de prise de décision pour la surveillance des processus [185].

Tableau 2.3. Impact des auteurs locaux

Auteurs	h_index	g_index	m_index	TC	NP	Année
Y. Altintas	12	16	0.4	1585	16	1992
D. Dornfeld	2	2	0.2	731	2	2010
K. Jemielniak	1	1	0.1	726	1	2010
G. O'Donnell	1	1	0.1	726	1	2010
R. Teti	1	1	0.1	726	1	2010
C. Brecher	3	5	0.2	635	5	2010
H. Cao	9	15	0.9	540	15	2013

J. Munoa	9	14	0.6	504	14	2009
M. Weck	1	1	0.05	502	1	2004
G. Stepan	6	13	0.4	446	13	2008
X. Zhang	10	19	1.7	427	19	2017
E. Budak	3	4	0.1	399	4	2000
X. Chen	8	12	1	394	12	2015
Z. Chen	7	8	0.4	348	8	2007
Z. Dombovari	4	6	0.6	336	6	2016
X. Beudaert	4	5	0.5	323	5	2015
D. Mei	6	6	0.4	319	6	2007
S. Smith	3	3	0.1	301	3	1992
C. Liu	7	12	1	292	12	2016
M. Sortino	3	4	0.2	292	4	2008

L'indice TC indique que les auteurs les plus cités ne sont pas forcément les plus productifs. Pour plus de détails, la Figure 2.9 présente un réseau montrant les liens de collaboration entre les auteurs. Leur distance dans les liens de co-citation indique la relation entre les auteurs. Les relations sont fortes lorsque la connexion de collaboration est plus courte. Dans ce cas, il y a dix groupes de collaboration (X. Liu et Y. Li) sont le premier groupe, suivi de (H. Gao, M. Wang et Y. Zhang) et (H. Liu et Y. Wang).

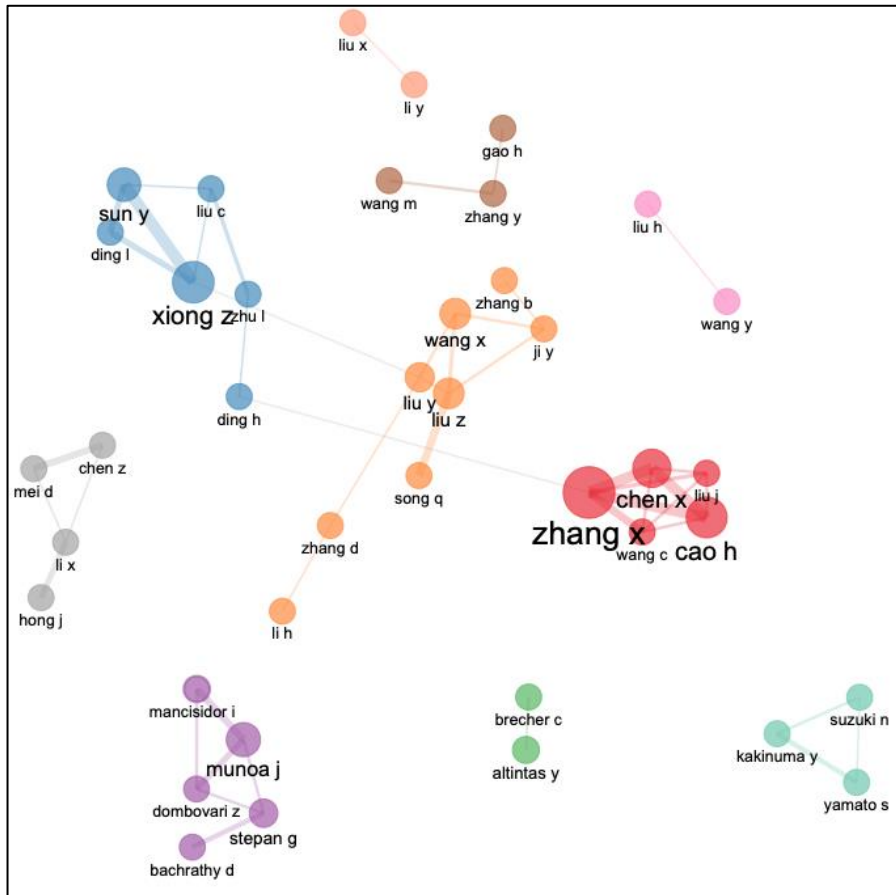


Figure 2.9. Réseau de collaboration entre les auteurs.

La Figure 2.10 est proposée selon la loi de Lotka, définissant l'axe des abscisses comme le nombre d'articles et l'axe des ordonnées comme le nombre d'auteurs de différents domaines. Les auteurs peuvent être cités dans les documents en tant qu'auteur principal. On peut voir sur la figure que plus de 1000 auteurs représentant 71% des auteurs ont écrit au moins un article sur les phénomènes de chatter.




Figure 2.10. La distribution de fréquence de la productivité scientifique.

La Figure 2.11 présente une structure arborescente qui retrace la composition hiérarchique des techniques d'analyse de signal et de détection de broutement utilisées dans le passé. Cette figure montre la combinaison de fréquence des mots-clés utilisés dans le domaine de la détection de broutement, tels que « détection de broutement », qui apparaissait comme mot-clé à côté des mots-clés suivants : « wavelet, chatter suppression, stability, model and dynamics », et le mot-clé « vibration » est également apparu avec « identification, suppression, regenerative chatter, chatter stability, classification, reconnaissance, etc. » dans la plupart des publications. Cette représentation montre que seuls les termes « ondelette » et « fréquence » ont été utilisés pour la détection de broutement. Cependant, il y a plusieurs variantes de la transformée de Fourier et d'autres techniques de décomposition, comme la méthode de décomposition Ensemble Empirical Mode Decomposition (EEMD).




Figure 2.11. La cartographie pour la description de la composition hiérarchique.

Le Tableau 2.4 présente les articles les plus cités partagés dans WoS entre 1985 et avril 2022. Notamment, l'article Teti *et al.* [185] publié dans CIRC Annals-Manufacturing Technology avec (726 citations). Dans cet article, les auteurs fournissent une vue d'ensemble du développement et de la mise en œuvre de la surveillance par capteur des opérations d'usinage. En particulier, le document passe en revue les contributions passées du CIRP dans ces domaines et fournit une étude des technologies de capteurs, du traitement du signal et des stratégies de prise de décision pour la surveillance des processus d'usinage. L'article scientifique Altintas *et al.* [11], également publié dans CIRC Annals-Manufacturing Technology, arrive en deuxième position avec 502 citations. Les auteurs discutent des principes fondamentaux de la loi de stabilisation du broutement en usinage en abordant les processus non linéaires.

Tableau 2.4. Documents les plus cités dans le monde

Document	Citations Total (TC)	TC par an	TC Normalisé
----------	----------------------	-----------	--------------

R. Teti 2010, [185]	726	55.85	11.44
Y. Altintas, [11]	502	26.42	5.78
J. Munoa 2016, [132]	290	41.43	10.25
E. Abele 2010, [1]	286	22	4.51
M. Siddhpura 2012, [166]	261	23.73	13.19
T. Delio 1992, [49]	173	5.58	3.04
Z. Yao 2010, [225]	161	12.38	2.54
U. Bravo 2005, [29]	159	8.83	3
N.D. Sims 2007, [168]	147	9.19	4.02
Y. Altintas 1992, [10]	138	4.45	2.42

De plus, la Figure 2.12 donne un aperçu des 10 articles les plus cités dans notre réseau de 679 documents (citations locales) pour la détection intelligente du broutement. Il faut le distinguer des documents les plus cités au niveau mondial (citations globales) qui font référence au nombre total de citations dans le monde. Il a été constaté que la détection de broutement a attiré l'attention de chercheurs dans de nombreux autres domaines.




Figure 2.12. Documents les plus cités dans cette étude.

Production scientifique sur les phénomènes du broutement par pays et continent

Le Tableau 2.5 montre que la Chine, le Canada (principalement à cause de l'auteur Y. Altintas) et les États-Unis occupent les premières places en fonction du nombre de citations totales, de la fréquence de publication et du nombre moyen de citations par article. La Chine occupe la première place avec 3707 citations au total sur 781 publications, suivie du Canada avec 1560 citations au total sur 75 publications, et des États-Unis, qui apparaissent 1256 fois au total sur 140 publications. On note qu'aucun pays africain ne semble clairement présent, et seul le Brésil représente l'Amérique du Sud, ce qui s'explique généralement par le faible développement des industries manufacturières et de la recherche. L'Algérie et l'Égypte font partie de cette étude sur le phénomène du chatter, mais seulement avec 24 citations sur 7 articles

publiés (Figure 2.13). La Figure 2.14 montre le réseau de collaboration entre les pays, montrant néanmoins un large éventail d'interactions.

Tableau 2.5. Production scientifique nationale sur les phénomènes du broutement par pays et continent dans WoS

Pays	Fréquence	Citations Totals	Moyenne de citation d'article
CHINA	781	3707	13.24
CANADA	75	1560	45.88
USA	140	1256	23.26
ITALY	47	1180	62.11
SPAIN	84	823	32.92
GERMANY	66	460	21.90
UNITED KINGDOM	66	395	21.94
AUSTRALIA	25	391	43.44
INDIA	93	364	9.84
IRAN	71	307	10.23
JAPAN	79	298	12.42
SLOVENIA	24	281	28.10
POLAND	54	150	7.50
HUNGARY	52	142	8.35
BRAZIL	32	117	9.75
FRANCE	30	109	13.62
TURKEY	35	102	9.27
THAILAND	16	86	14.33
SINGAPORE	7	70	35.00
SWEDEN	5	70	70.00




Figure 2.13. Carte de la production scientifique du pays.




Figure 2.14. Réseau de collaboration entre pays au niveau mondial.

Technologies ou modèles les plus courants utilisés pour la prédiction, la détection ou la stabilisation du broutement

Cette section analyse les mots clés les plus fréquents et leurs niveaux de cooccurrence. Ces mots-clés sont considérés comme les éléments essentiels de la représentation du concept de connaissance qui révèlent la structure du sujet de recherche. La taille des mots dans le nuage, Figure 2.15, détermine le nombre d'occurrences et la densité des mots dans les publications. À noter que le mot le plus fréquent est clairement stabilité (avec 178 occurrences), suivi de vibration, prédiction et détection de broutement avec respectivement 122, 115 et 101 occurrences.




Figure 2.15. Nuage des mots.

Cela montre que le modèle physique (« surface », « tool », « cutting force », « régénératif », etc.) est considéré comme secondaire par rapport aux propriétés supposées du signal (« stability », « vibration », « chatter ») et les objectifs de détection (« identification », « prediction », « suppression »), et selon les auteurs les techniques utilisées peuvent varier, comme « wavelet », « Hilbert-Huang transform » et « empirical mode decomposition ». Le mot de prédominance « stability » montre que le broutement est fortement lié au concept mathématique d'instabilité et de divergence exponentielle à l'infini, associé à un modèle très simplifié alors que l'usineur sait qu'il n'en est rien en pratique, on observe juste un changement d'amplitude plus ou moins forte et un changement de fréquences vibratoires. Des auteurs ont cherché à maîtriser les phénomènes de broutement vibratoire en proposant des techniques de stabilisation d'outils [35], suppression du broutement [69, 149], identification ou détection des phases de broutement [110, 191, 214], ou prédiction du broutement avec des techniques d'intelligence artificielle dans différentes opérations d'usinage [191, 194, 227].

La Figure 2.16 présente une carte de structure conceptuelle des mots-clés des auteurs. Cette carte applique la technique d'analyse MCA, une technique exploratoire multivariée proposée dans l'outil biblioshiny. La Figure 2.16 montre le réseau de cooccurrence des mots-clés des auteurs divisé en trois groupes. Les cinquante mots les plus utilisés par les auteurs sont répartis entre les clusters. Le cluster rouge a trente-trois éléments, le cluster bleu a onze éléments et le cluster vert a six éléments. Le cluster rouge prédomine avec des mots liés aux procédés d'usinage (fraisage, fraisage en bout, alésage, tournage, rectification, etc.). Le cluster bleu représente les mots sur les méthodes de transformations et d'extraction des caractéristiques du signal vibratoire. Le cluster vert se concentre sur l'outil de coupe d'usinage et son amortissement avec des mots comme (machine-outil, usinage, vibrations, amortissement actif et apprentissage automatique).

Conceptual Structure Map - method: MCA

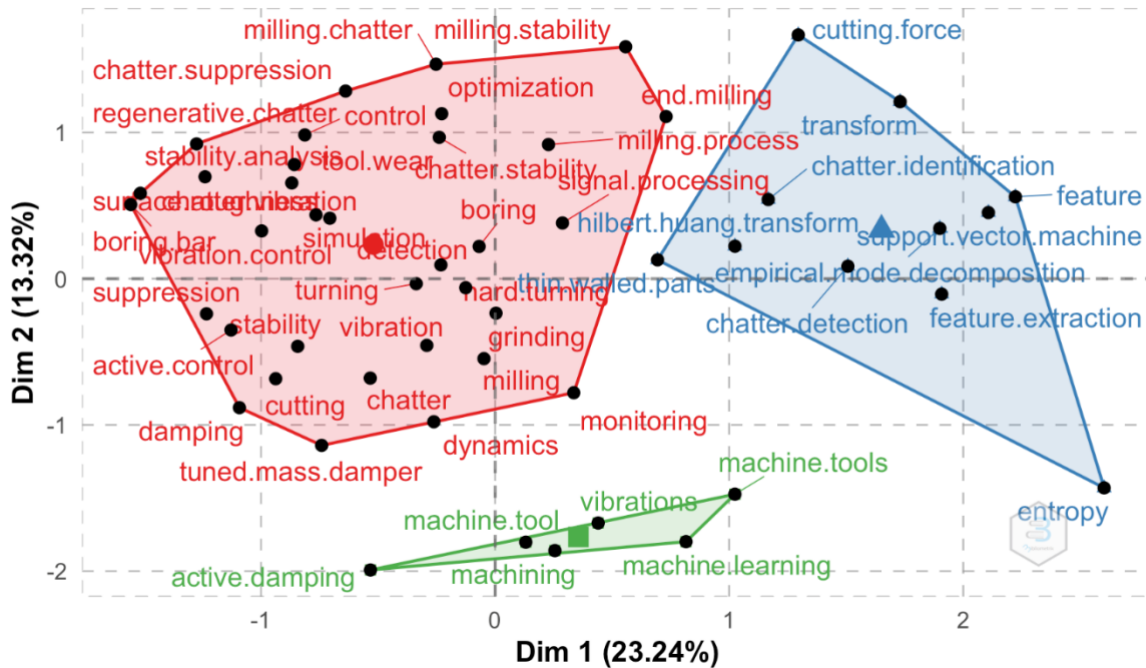


Figure 2.16. Carte conceptuelle de la méthode structurale MCA.

Cette analyse regroupe des données étendues avec plusieurs variables dans un espace de faible dimension pour produire un graphique de cluster intuitif. Il utilise la distance plane pour illustrer la similitude entre les mots-clés. Les mots-clés proches du point central indiquent qu'ils ont récemment fait l'objet d'une attention particulière. Par exemple, dans le groupe rouge, le mot-clé « detection » est au centre, entouré de mots comme tournage, contrôle des vibrations et alésage.

Plusieurs éléments sont analysés sur la dynamique des mots-clés et les tendances. Le premier est l'évolution des mots-clés des auteurs Figure 2.17 Après 2016, certains mots-clés ont augmenté significativement plus vite que d'autres : techniques d'identification (dont les ondelettes) et suppression du broutement. En outre, il montre la tendance des mots-clés avec une fréquence minimale de 10 apparitions. Il semble qu'entre 2019 et 2020, les recherches sur l'identification du broutement, la surveillance et, plus récemment, l'apprentissage automatique se soient multipliées. Dans le détail, différentes techniques telles que l'intelligence artificielle (réseau de neurones, SVM, CNN, etc.) et le traitement du signal (HHT, EMD, FFT, STFT, etc.) ont été impliquées. Ces techniques ont permis d'extraire les caractéristiques du signal pour aider l'expert humain à prendre des décisions et servent très souvent de base à l'apprentissage des méthodes d'intelligence artificielle (Figure 2.18).




Figure 2.17. Progression temporelle des mots clés.




Figure 2.18. Visualisation des temporalités des mots clés dans les articles.

Applications d'intelligence artificielle

Dans cette partie, un deuxième enregistrement a été réalisé en ajoutant quelques mots clés ("Machine Learning" OU "Deep Learning" OU "Intelligence Artificielle") pour voir l'étendue de l'application des techniques d'intelligence artificielle pour la détection de broutement en usinage.

La plupart des études sur la détection des vibrations vibratoires ont utilisé des techniques de traitement du signal ou des modèles numériques basés sur la physique exploitant les données vibratoires.

Avec l'émergence des techniques d'intelligence artificielle dans divers domaines, les chercheurs ont combiné des techniques de traitement du signal et des modèles d'IA (apprentissage automatique et apprentissage profond) pour l'extraction de caractéristiques et la prise de décision dans la détection du broutement. Cette requête d'analyse particulière a été utilisée pour filtrer les articles qui utilisent l'IA pour identifier ou détecter le broutement. Le résultat de la requête donne 75 documents sur 679 exploitants des techniques d'IA ; La Figure 20 montre la tendance de l'utilisation de l'IA au fil des ans pour la détection du broutement. La plupart de ces documents ont été publiés entre 2016 et 2021, et les modèles d'apprentissage automatique (SVM et ANN) sont les plus utilisés. La Figure 2.20 montre que les premiers articles publiés sur la détection de broutement par des techniques d'IA remontent à 1994. C'est en 2020 que plus de 19% de ces publications ont été faites, soit 15 articles. On peut le voir dans la liste des documents les plus cités au niveau mondial (Tableau 2.7) avec notamment le document Yao *et al.* [225], qui proposait une approche pour détecter et identifier le broutement vibratoire en exploitant WT pour extraire les caractéristiques du signal. La prise de décision SVM (classification) a été citée 165 fois. En seconde position, le document Cao *et al.* [33] est un article de synthèse sur le concept d'usinage intelligent, et cet article est cité 131 fois. Le document Lamraoui *et al.* [57] est en troisième position avec 67 citations au total. Ces auteurs ont également proposé une méthodologie de détection intelligente des phénomènes de broutement dans un processus de fraisage à l'aide d'un réseau de neurones artificiels. Toutes ces informations bibliographiques montrent qu'au-delà des premiers groupes d'auteurs publiant historiquement sur le broutement d'usinage, de nouveaux auteurs développent de nouvelles techniques de détection du broutement (Figure 2.19).




Figure 2.19. Des groupes d'auteurs historiques et d'auteurs utilisent de nouvelles techniques de détection du broutement.




Figure 2.20. L'évolution des techniques d'IA dans la détection du broutement.

Le Tableau 2.6 donne la liste des dix auteurs des deux groupes par ordre de nombre de documents publiés.

Tableau 2.6. Les dix auteurs les plus révélateurs pour les deux groupes.

Auteurs historiques		Auteurs exploitant les nouvelles techniques	
Auteurs	Articles	Auteurs	Articles
X. Zhang	21	FA. Khasawneh	4
Z. Xiong	18	B. Sener	4
Y. Altintas	17	B. Singh	4
J. Munoa	16	HO. Unver	4
H. Cao	15	H. Cao	3
Z. Liu	14	MC. Chen	3
G. Stepan	14	X. Chen	3
Y. Sun	14	J. Liu	3
X. Wang	14	A. Otto	3
X. Chen	13	YS. Tarng	3

Un regard sur les mots des auteurs exploitant les nouvelles techniques montre un nuage de mots contenant les techniques d'IA (apprentissage automatique ou apprentissage profond) les plus utilisées, les modèles de traitement du signal basés sur la physique et les opérations d'usinage impliquées (Figure 2.21). Parmi les modèles d'apprentissage automatique utilisés par

[34]	39	MLP	-	Tournage
[78]	33	SVM	EMD	Tournage
[179]	32	-	IBR	Fraisage en bout
[37]	27	SVM	WPT	Fraisage en bout
[191]	20	CNN	CWT	Fraisage
[202]	20	-	HHT	Fraisage
[165]	19	ANN	EEMD	Tournage
[227]	18	SVM	WPT-EEMD	Tournage
[133]	18	ANN	DWT	Fraisage à la scie
[180]	17	ANN	-	Perçage
[109]	17	BPNN	VMD	Fraisage
[212]	15	SVM	-	Fraisage
[242]	14	CNN	-	Fraisage
[52]	12	Hybrid Clustering	FFT	Fraisage
[65]	11	ANN	WPT	Tournage
[161]	10	KNN	-	Fraisage
[27]	10	PNN	WD-HHT	Tournage

2.3. État de l'art

Application des techniques de traitement du signal pour la détection de broutement

En général, en usinage, les capteurs détectent des signaux non stationnaires et sachant que la FFT nécessite une fenêtre temporelle définie (classiquement 0,1 à 1s en usinage), cela introduit inévitablement un retard de détection de l'ordre de quelques périodes d'échantillonnage, et de toute façon, une distorsion liée au fait que la FFT est trop globale pour représenter un signal avec des amplitudes et des fréquences variables dans le temps. La STFT tente de compenser ce défaut en exploitant une fenêtre glissante et en multipliant les FFT, permettant d'identifier plus finement les évolutions du signal. La HHT n'est pas contrainte par les hypothèses de stationnarité et de linéarité requises pour la FFT et peut générer des informations de signal de vibration plus précoce que la FFT. En revanche, la HHT reste une méthode très empirique et est connue pour rencontrer des difficultés à distinguer des fréquences proches, ce qui nécessite d'éliminer la partie haute fréquence du signal, ce qui apparaît souvent en usinage. Quant à la STFT, malgré la technique du fenêtrage, elle est limitée par la largeur de

la fenêtre, qui affiche la résolution temporelle et fréquentielle. Basée sur le principe d'incertitude de Heisenberg [213], cette résolution ne peut être arbitrairement élevée, et il s'agit toujours de faire un compromis entre résolution temporelle et fréquentielle. La théorie des ondelettes (WT) présentée dans le document [122] a réduit le problème lié au fenêtrage posé par la STFT en exploitant plusieurs fenêtres de longueurs différentes. Dans la WT, l'analyse des hautes fréquences est réalisée avec des fenêtres plus étroites pour obtenir une meilleure résolution temporelle et des fenêtres expansives pour les basses fréquences, pour avoir une résolution fréquentielle optimale (Figure 2.22).




Figure 2.22. Traitement du signal, respectivement, avec la FFT, STFT et WT [4].

Tableau 2.8. Comparaison entre différentes techniques de traitement du signal.

Transformation	FFT (Fast Fourier Transform)	WT (Wavelet Transform)	HHT (Hilbert Huang Transform)
Base	a priori	a priori	Adaptatif (en fréquence)
Fréquence	Convolution : échelle globale, incertitude	Convolution : échelle globale, incertitude	Différenciation : échelle locale, certitude
Entrée	ξ : fréquence	a : Mise à l'échelle ; b : facteur de décalage temporel	t : temps ; x(t) : signal
Présentation	Décomposition : $f(x) = \int_{-\frac{\pi}{2}}^{+\frac{\pi}{2}} \hat{f}(\xi) e^{i2p\xi x} d\xi$ Fonction de base : harmonique (sin, cos) Coefficients : $f(\xi) = \int_{-\frac{\pi}{2}}^{+\frac{\pi}{2}} \hat{f}(x) e^{i2p\xi x} dx$	Décomposition : $f(x) = \sum_{j,k=-\infty}^{\infty} c_{jk} \Psi_{jk}(x)$ Fonction de base : famille orthogonale $\Psi \in L^2(\mathbb{R})$ $\Psi_{jk}(x) = 2^{\frac{j}{2}} \Psi(2^j x - k)$ $\langle \Psi_{jk}, \Psi_{lm} \rangle = \int_{-\infty}^{\infty} \Psi_{jk}(x) \overline{\Psi_{lm}(x)} dx = \delta_{jl} \delta_{km}$ Coefficients :	Décomposition : $X(t) = \sum_{j=1}^n c_j + r_n$ c_j : fonction de mode intrinsèque (splines cubiques) r_n : fonction résiduelle Fonction de base : splines cubiques Coefficients : Obtenu par un processus itératif avec un critère d'arrêt.

		$C_{jk} = [W_{\psi}f](2^{-j}, k2^{-j})$ $[W_{\psi}f](a, b) = \frac{1}{\sqrt{ a }} \int_{-\infty}^{\infty} \psi\left(\frac{x-b}{a}\right) f(x) dx$ <p>Avec $a = 2^{-j}$ and $b = k2^{-j}$</p> <p>dilatation dyadic, and position dyadic)</p>	(La fréquence instantanée est calculée à l'aide de la transformation de Hilbert).
Non-stationnaire	No (or using Short Time Fourier Transform, STFT)	oui	oui
Extraction caractéristique	non	discrète : non, continue : oui	oui
Base théorique	Théorie complète	Théorie complète	Empirique
Mérites	Obtient l'information sur la fréquence	Communique des informations dans le domaine du temps et de la fréquence	Fournit à la fois une haute résolution temporelle et une haute résolution en fréquence.
Limitations	N'évolue pas dans le domaine temporel (ou en exploitant la STFT-	Sélection de la fonction de base	Distinction des fréquences proches, problème de mélange (évitée en exploitant l'EEMD)
Application :			
- Fraisage	- 25 articles	- 70 articles	- 34 articles
- Tournage	- 05 articles	- 30 articles	- 08 articles
- Perçage	- 02 articles	- 19 articles	- 01 article
- Meulage	- 02 articles	- 07 articles	- 05 articles

Un autre modèle WT, la Wavelet Packet Transform (WPT), décompose les approximations et les détails pour générer plus de bandes de fréquences et offrir plus de possibilités d'obtenir plus de caractéristiques de signal. Contrairement à la STFT, à la WT, ou WPT, la HHT correspond plus à un processus pratiqué sur un jeu de données qu'à un outil théorique aussi clairement défini que les méthodes précédentes. Le HHT est composé d'une étape EMD pour obtenir la décomposition du signal en une base quasi-orthogonale appelée Intrinsic-Mode-Functions (IMF). L'analyse dans le temps des fréquences associées à chaque IMF permet de générer des « Hilbert Spectra Analysis » (HSA) pour approfondir l'analyse du signal. Susanto *et al.* [177] montre néanmoins que l'application de la HHT dans l'analyse du spectre fournit une résolution temporelle et haute fréquence supérieure à celles offertes par le STFT.

Le Tableau 2.8 compare les différentes techniques de transformation (Fourier, Wavelet et Hilbert) en fonction du type de fréquence, de la présentation, de la linéarité de fréquence, de la stationnarité et de la capacité d'extraction de caractéristiques.

Les auteurs utilisent ces techniques pour analyser le signal dans plusieurs domaines de l'usinage, tels que le fraisage [106, 157, 176], le tournage [177] et les rotors [206].

L'article Siddhpura *et al.* [43] est une revue de la recherche sur le broutement vibratoire dans les opérations de tournage. Ils passent en revue les techniques de prédiction, de détection et de contrôle des vibrations. Ils comparent différentes méthodes analytiques pour la prédiction de la stabilité du broutement, telles que le diagramme de lobe de stabilité (SLD), les diagrammes de Nyquist et la méthode d'analyse par éléments finis. Les auteurs Fu *et al.* et Wan *et al.* [60, 60] proposent une méthode de transformation de Hilbert–Huang pour la détection précoce du broutement en ligne avant l'endommagement des pièces. Elle mesure le signal de vibration et effectue une décomposition en une série de fonctions de mode empirique en appliquant la décomposition de mode empirique d'ensemble. L'analyse spectrale de Hilbert-Huang est ensuite utilisée sur les caractéristiques de la fonction empirique pour calculer le spectre temps-fréquence. En raison des propriétés non linéaires et non stationnaires des vibrations lors du processus de fraisage, les auteurs Cao *et al.* [15] proposent une approche auto-adaptative : Ensemble Empirical Mode Decomposition (EEMD). Ils analysent les signaux de vibration avec EEMD pour extraire des indices non linéaires comme indicateurs de vibration. Puis ils intègrent l'IMF sensible contenant les informations de broutement pertinentes pour obtenir un nouveau signal. Les deux fonctions non linéaires sans dimension précisées reflétaient l'état du broutement dans le domaine temporel et fréquentiel, offrant une solution alternative pour identifier le broutement dans le processus de fraisage. Étant donné que la détection de broutement en ligne implique un prétraitement du signal, l'extraction des fonctionnalités sensibles et le développement de modèles de surveillance en temps réel sont cruciaux. Les auteurs Yan *et al.* [223] proposent une nouvelle approche pour identifier le broutement dans le fraisage. Cette méthode utilise la décomposition en mode variationnel optimisé (OVMD) pour décomposer les mesures de force de coupe et extraire les sous-composants contenant des informations de broutement à l'aide d'un algorithme de recuit simulé (SA). L'entropie approximative et de l'échantillon détecte l'apparition du broutement, et les résultats montrent de meilleures performances que l'EMD mentionné précédemment.

Thaler *et al.* [186] ont expérimenté une configuration multisensorielle composée de son, d'accélération et de force de coupe pour détecter le broutement dans le sciage à ruban. L'analyse expérimentale montre que le signal sonore est le plus approprié pour la détection de broutement. Ils adoptent une méthodologie qui prétraite le signal avec la STFT pour extraire des caractéristiques dans l'espace des fréquences, c'est-à-dire la hauteur de pics de fréquence spécifiques, avec un seuil optimal. Une analyse discriminante quadratique est appliquée aux caractéristiques extraites pour détecter le broutement. Liu *et al.* [106] combine la décomposition en mode empirique, la décomposition en paquets d'ondelettes (WPD) et la transformée de Hilbert-Huang (HHT) pour identifier le broutement. Étant donné que l'IMF change en fonction du spectre de puissance ou de l'amplitude de fréquence, la décomposition de mode empirique est utilisée pour sélectionner les principales caractéristiques de la reconstruction du signal. Le WPD a permis de reconstruire le signal en deux étapes en exploitant le maximum d'énergie. Le modèle HHT est la distribution de fréquence et d'énergie dans le domaine temporel. Considérant que HHT prend en charge les signaux non stationnaires et non linéaires, Peng *et al.* [140] proposent une technique de détection de broutement pour la barre d'alésage en comparant deux types de signaux provenant d'une jauge de contrainte et d'un capteur FBG par HHT. Ces signaux sont ensuite décomposés en plusieurs IMF à l'aide de la technique EMD. La transformée est appliquée à chaque IMF pour obtenir les fréquences instantanées avec le temps et les

amplitudes. Ces résultats montrent que le HHT peut être considéré comme une technique simple et fiable pour détecter les vibrations de broutement. Cependant, comme la plupart des études, les conditions industrielles sont très éloignées de la réalité et le broutement est généralement clairement associé à une amplitude vibratoire accrue.

Chen *et al.* [42] présentent une méthode de détection de broutement basée sur l'analyse d'image des bandes de fréquences dominantes à partir de spectrogrammes STFT. Le bruit environnemental lié au broutement et aux bandes de fréquences à haute énergie est localisé par un opérateur d'énergie au carré du spectre FFT synthétisé. La méthode d'extraction de caractéristiques proposée est vérifiée sous divers paramètres de coupe de fraisage en trois classes (coupe stable, léger broutement et broutement important). Les résultats montrent l'efficacité des caractéristiques d'image temps-fréquence des bandes de fréquences dominantes pour la détection de broutement, et ses performances sont meilleures que l'extraction de caractéristiques dans le domaine temporel et les méthodes basées sur les ondelettes en termes de capacités de séparabilité. Cette approche s'apparente à une analyse d'expert humain sur STFT. Cependant, elle est appliquée à des applications industrielles non réalistes. De même, Uekita *et al.* [192] proposent un système combinant STFT et analyse d'aplatissement spectral dans le domaine temps-fréquence pour identifier des informations pertinentes sur le broutement et les vibrations transitoires à partir du signal d'un accéléromètre. Le système proposé permet non seulement d'empêcher la défaillance de l'outil en détectant l'apparition d'un broutement, mais fournit également des informations complètes sur l'état de l'outil. Les auteurs du document [30] détectent le broutement en ligne en surveillant l'énergie vibratoire. À l'aide d'un filtre de Kalman, ils suppriment les forces de vibrations forcées dans le domaine du temps discret et toutes les autres composantes périodiques. Ensuite, ils trouvent l'amplitude et la fréquence du broutement entre les deux harmoniques de fréquence de passage des dents consécutives à l'aide de l'opérateur d'énergie non linéaire. Le broutement est déterminé lorsque l'énergie de la composante de broutement augmente par rapport à l'énergie des vibrations forcées. Cette méthode détecte le broutement plus tôt dans des intervalles de temps discrets que les méthodes basées sur le domaine fréquentiel comme la FFT.

La grande variété d'analyses de signal pour détecter le broutement montre que cela reste une tâche très délicate, notamment pour une détection précoce, c'est-à-dire avant que l'amplitude des vibrations ne soit déjà importante, et qu'il soit trop tard pour pouvoir préserver la qualité de la pièce. De plus, toutes ces études sont basées sur des essais d'usinage en laboratoire, donc sans les contraintes du bruit et de la variété des situations à gérer dans l'industrie. Par conséquent, il reste largement à définir une méthode pratique et robuste, permettant d'identifier rapidement le broutement sans avoir besoin d'un expert pour affiner les paramètres de détection.

Application des techniques d'intelligence artificielle à la détection du broutement

L'émergence de l'industrie 4.0 pour augmenter la productivité et réduire les coûts de production a incité l'utilisation de centres d'usinage automatiques sans personnel ou de systèmes d'usinage intelligents. Dans ces nouveaux systèmes, la machine-outil doit être capable d'effectuer automatiquement certaines activités telles que la détection et l'évitement des collisions, la surveillance de l'état de l'outil, l'optimisation, ou au moins l'adaptation des paramètres de coupe en situation dégradée, la détection et, si possible, la suppression des vibrations dues au broutement. Plus précisément, l'intégration de systèmes de détection de broutement dans l'unité de contrôle de la machine-outil serait une amélioration significative de l'usinage. Ainsi, l'identification et la détection des vibrations dans les processus d'usinage ont été un domaine de recherche actif au cours des deux dernières décennies.

Apprentissage automatique

L'une des difficultés dans l'étude du broutement est que les équations qui décrivent le broutement sont généralement des équations différentielles terme à retard et non linéaires, difficile à étudier mathématiquement ou numériquement. La plupart des outils existants d'identification du broutement reposent sur la définition d'une métrique qui capture les caractéristiques du broutement et d'un seuil qui signale son apparition. La difficulté de choisir ces métriques, généralement confiées à des experts, peut être facilitée grâce à des techniques de machine learning [116]. L'apprentissage automatique est maintenant couramment utilisé pour relier les signaux de vibration mesurés à l'usure. Il y a généralement trois phases : la collecte des signaux, l'extraction des caractéristiques et l'apprentissage ou l'apprentissage des modèles, communément appelé méthode « signal-ingénierie des caractéristiques-modèle » (Figure 2.1). La collecte de signaux vise à collecter autant de modèles de signaux et leurs états d'usure correspondants que possible [116]. La grande variété de l'ensemble de données est la base du modèle pour obtenir de bonnes performances de généralisation. L'extraction de caractéristiques vise à identifier plusieurs paramètres de caractéristiques clés à partir des signaux initialement enregistrés pour déterminer la relation entre le signal et les états d'usure. Les caractéristiques sont généralement définies manuellement, ce qui nécessite une grande expertise humaine. Parmi les méthodes d'apprentissage automatique utilisées dans la détection automatique du broutement, la majorité des techniques d'identification qui s'appuient sur les machines à vecteurs de support (SVM) [238], les réseaux de neurones artificiels (ANN) [32, 209], l'apprentissage non supervisé [181], et des modèles d'apprentissage profond comme le réseau de neurones convolutifs.

Une étude plus approfondie montrera la croissance des mots au fil des ans. L'un des premiers articles exploitant une méthode d'apprentissage automatique dans les années 1990 pour détecter le broutement est le document Tarng *et al.* [180] qui utilise le réseau de neurones pour apprendre les caractéristiques du spectre de force de poussée dans le processus de forage de manière adaptative. Cardi *et al.* [34], ont conçu un observateur pour un système de contrôle en temps réel pour atténuer le broutement dans un processus de tournage exploitant des réseaux de neurones artificiels. Pour améliorer la qualité de surface et réduire les vibrations et l'usure de l'outil de coupe, Lamraoui *et al.* [95] propose une approche basée sur le perceptron multicouche (MLP) et la fonction de base radiale (RBF) pour détecter le broutement dans un processus de fraisage. Bonda *et al.* [27], atteignent une précision de 100 % pour la détection du broutement en combinant WT et HHT pour l'extraction des caractéristiques du signal et un réseau de neurones probabiliste pour la classification, mais encore une fois, dans une situation d'usure très simpliste, loin des applications industrielles, les conditions de coupe étant très éloignées de la spécification du fabricant d'outils, et avec une corrélation claire entre le broutement et l'amplitude des vibrations.

Pour détecter le broutement, Arriaza *et al.* [16] ont utilisé plusieurs capteurs (son, vibrations de la broche, vibrations de la pièce) et a créé plusieurs réseaux de neurones multicouches en les ajustant aux entrées de différents signaux et conditions de coupe pour évaluer quels capteurs ou combinaison de capteurs pourrait fournir une source d'information fiable pour surveiller le broutement, mais sans réponses claires. Kuljanic *et al.* [92], ont utilisé les paramètres statistiques du WT comme entrée d'un réseau de neurones pour développer un système intelligent de détection de broutement. Pourtant, étonnamment, le meilleur indicateur de broutement était corrélé avec le capteur de force axiale. Cette direction n'est pas censée vibrer fortement dans une telle situation. Ils ont combiné l'analyse des données topologiques (TDA) et le classificateur de régression logistique (LRC) pour avoir une excellente performance pour la détection du broutement en virage, mais cela n'a été fait que sur des données simulées. Pour vérifier la stabilité du broutement, les auteurs Kumar *et al.* [93] utilisent un

modèle de réseau de neurones artificiel basé sur un réseau de rétropropagation pour prédire les zones de coupe stables et le taux d'enlèvement de métal (mais en exploitant la direction du capteur perpendiculaire à la direction principale de vibration du broutement, ce qui est aussi surprenant).

En 2010, les auteurs Yao *et al.* [225] ont combiné transformée en ondelettes et SVM pour la détection précoce du broutement. Le classificateur SVM a été conçu pour une reconnaissance basée sur le vecteur de caractéristiques dérivé de l'écart type de la transformée en ondelettes et du rapport d'énergie des paquets d'ondelettes de la bande de fréquence du signal. HongQi *et al.* [78], les auteurs proposent un système de surveillance de l'état de coupe basé sur le signal de courant du moteur d'avance. Ils appliquent un classificateur SVM aux caractéristiques extraites par le modèle EMD pour développer un système intelligent de détection de broutement avec une précision de 95%. Une méthode innovante de détection de broutement de coupe basée sur WT et SVM multi classes est proposée dans le document [164]. Pour simplifier la complexité de calcul lorsque la classification SVM binaire se transforme en classification multi-classes, l'algorithme fait en sorte que chaque type d'échantillon ait un SVM sphérique. Une combinaison d'analyse en composantes principales (ACP) et de SVM est présentée dans le document [159] pour reconnaître la génération du broutement. Ils extraient les caractéristiques du signal vibrationnel avec la FFT et étiquettent les vecteurs FFT pour servir de données d'entrée au modèle d'apprentissage. Pour augmenter la précision de la détection des vibrations, Wan *et al.* [203] combine un algorithme Adaptive Boosting (Adaboost) et SVM avec l'entraînement d'un classificateur robuste pour la détection du broutement. En plus de la combinaison Adaboost-SVM, ils extraient les caractéristiques avec un autoencodeur de débruitage empilé prenant en compte les échantillons mal étiquetés. SVM montre ses capacités d'identification dans le fraisage miroir, qui est une technique efficace pour améliorer la qualité des pièces usinées monolithiques. Il assure les relations miroir de la fraise et de la tête d'appui. Wang *et al.* [212] utilisent le facteur Q pour construire un vecteur de caractéristiques en déterminant le spectre de puissance de la bande de fréquence. Ensuite, le SVM est utilisé pour diagnostiquer et détecter l'état de fraisage. Ils proposent une méthodologie de détection du broutement en ligne basée sur le WPT et la suppression de fonctionnalités récursives par SVM lors du processus de fraisage en bout. Dans le document [211], les auteurs Wang *et al.* construisent un modèle VMD-SVM pour identifier le broutement dans le processus de fraisage robotisé. Shi *et al.* [161] utilisent un classificateur d'apprentissage automatique K-plus proches voisins pour détecter le broutement dans le processus de fraisage à grande vitesse. Ils créent un cluster contenant deux catégories de conditions de coupe, condition du broutement et condition normale. Pour faciliter le processus d'extraction des caractéristiques, Yesili *et al.* [228] présente une approche basée sur la caractérisation de la série temporelle du processus de découpe à l'aide de ses caractéristiques topologiques TDA. Ils intègrent les séries chronologiques sous forme de clusters en exploitant le théorème de Takens, les coordonnées de Carlsson, etc.

Plusieurs classificateurs comme SVM, Logistic Regression Classifier (LRC), Random Forest et Gradient Boosting sont combinés pour détecter le broutement. Li *et al.* [100] proposent un modèle SVM multi-classes (deux SVM en cascade) pour détecter les phénomènes de broutement. Pour cela, ils étudient deux indicateurs, d'une part, la variance en temps réel des signaux de force de fraisage dans le domaine temporel, et d'autre part, le rapport d'énergie des ondelettes des signaux d'accélération basé sur le WPT. Ensuite, la détection de broutement est effectuée par l'entraînement de deux SVM. Pan *et al.* [139] ont proposé une approche pour identifier le broutement dans le processus d'alésage. Elle consiste à fusionner les caractéristiques de plusieurs capteurs pour obtenir les signaux de traitement. La transformation EMD décompose ces signaux. Les indicateurs des signaux décomposés sont calculés en effectuant une combinaison de caractéristiques multi-capteurs. Ils utilisent une SVM comme

modèle de classification, un modèle d'identification avec l'un des meilleurs résultats (95,56 % de précision) pour identifier le broutement. Le Tableau 2.9 montre les avantages et les inconvénients de ces méthodes.

Tableau 2.9. Avantages et inconvénients des méthodes d'apprentissage automatique et d'apprentissage profond

Méthode	Avantages	Inconvénients
SVM	<ul style="list-style-type: none"> - Bon dans les grands espaces - Toujours efficace dans les situations où le nombre de dimensions est supérieur au nombre d'échantillons - Multi-usages 	<ul style="list-style-type: none"> - Difficulté de gérer le nombre de caractéristiques beaucoup plus élevé que le nombre d'échantillons. - Le coût du calcul des estimations de probabilité est très élevé. - Nécessite une supervision humaine pour la tâche d'identification des caractéristiques.
MLP	<ul style="list-style-type: none"> - Capacité à apprendre des modèles non linéaires - Apprentissage en ligne 	<ul style="list-style-type: none"> - Les MLP à couche cachée ont une fonction de perte non convexe dans laquelle il existe plus d'un minimum local. Par conséquent, différentes initialisations de poids aléatoires peuvent conduire à une précision de validation différente. - Le modèle MLP nécessite de définir un certain nombre d'hyperparamètres tels que le nombre de neurones cachés, de couches et d'itérations. - MLP est sensible à l'échelle des caractéristiques - Nécessite une supervision humaine pour la tâche d'extraction de caractéristiques
CNN	<ul style="list-style-type: none"> - Ne nécessitent pas de supervision humaine pour la tâche d'extraction des caractéristiques. - Reconnaissance et classification précises des images - Partage des poids - Minimise le calcul par rapport à un réseau neurones normal. 	<ul style="list-style-type: none"> - Nécessite beaucoup d'échantillons de données d'entraînement. - Difficulté à classer des images ayant des positions différentes. - Tendance à être beaucoup plus lente en raison d'opérations comme le maxpool. - Nécessite très souvent une machine dotée d'une très

	- La même connaissance est utilisée dans tous les emplacements de l'image	bonne unité de traitement graphique (GPU).
--	---------------------------------------------------------------------------	--------------------------------------------

Le Tableau 2.10 présente la liste des dix articles avec les meilleures valeurs de précision.

Tableau 2.10. Les dix articles les plus performants en détection du broutement

Littérature	Prétraitement	Modèle d'apprentissage	Usinage	Justesse
[92]	WT	MLP	Fraisage	94%
[225]	WT	SVM	Tournage	95%
[78]	EMD	SVM	Tournage	95%
[164]	WT	SVM		95%
[95]	-	MLP-RBF	Fraisage	97%
[37]	WPT	SVM	Fraisage	95%
[87]	TDA	LRC	Tournage	97%
[205]	WPT-FFT-SSA	SVM	Fraisage	96%
[211]	VMD	SVM	Fraisage	92.59%
[100]	WPT	SVM	Fraisage	96.66%
[226]	DTW	KNN	Tournage	98%
[227]	WPT	SVM	Tournage	95%

Il est important de noter que dans toutes ces publications, les phénomènes de broutement sont associés à une augmentation de l'amplitude du signal vibratoire et que la plupart des expériences de vérification sont loin des applications industrielles.

Apprentissage profond

Au fur et à mesure que la dimension d'entrée augmente, les modèles d'apprentissage automatique sont rapidement bloqués par de nombreux minima locaux ou ne parviennent pas à converger à temps. Ces limitations nécessitent une expertise humaine dans l'extraction de caractéristiques pour réduire la dimension des entrées de signal d'origine avec des méthodes statistiques. Malgré le succès des techniques d'extraction manuelle de caractéristiques pour les modèles d'apprentissage automatique dans plusieurs problèmes, elles présentent certains inconvénients tels que (1) les caractéristiques extraites sont spécifiques et non généralisées pour résoudre différents problèmes, et (2) l'ensemble des caractéristiques extraites qui est une représentation partielle, au lieu d'une représentation complète du signal d'origine. (3) Le modèle

de classification, formé sur des caractéristiques partielles, représente une relation non partielle entre les caractéristiques et les états d'usinage plutôt que la relation bénéfique entre le signal et les états d'usinage [152]. Cette étape d'expertise humaine pour l'extraction de caractéristiques vise à réduire la dimension de l'entrée. Les progrès de l'intelligence artificielle ont permis à des techniques telles que l'apprentissage profond d'extraire des caractéristiques directement en tant que données d'entrée (Figure 2.2).

L'une des méthodes les plus courantes est le réseau de neurones convolutifs (CNN), qui est devenu une technique populaire pour transformer les données en informations en raison de sa capacité à traiter les données brutes et à reconnaître automatiquement les représentations des caractéristiques des données à travers plusieurs niveaux d'abstraction [66]. Gao et al [63] ont construit un modèle d'apprentissage profond pour détecter le broutement en exploitant le signal de vibration converti en spectre temps-fréquence comme entrée. Le réseau de neurones profonds extrait les caractéristiques temps-fréquence, et le signal de vibration est ensuite décomposé en bande de broutement par le VMD. Une SVM est introduite pour classer les caractéristiques extraites de la détection de broutement. Les auteurs Xu *et al.* [220] ont utilisé des images de la surface interne du roulement pour détecter des défauts de roulement causés par des vibrations ou du broutement, mais une telle technique n'est pas adaptée à la surveillance in situ. Ils transforment les signaux de vibration en une image temps-fréquence en exploitant la transformée en ondelettes continue (CTW). Basé sur le scalogramme CWT, Tran *et al.* [191] propose une méthodologie basée sur CNN pour détecter le broutement dans un processus de fraisage. Les signaux de force de coupe enregistrés sont imagés à l'aide de CWT, puis classés en trois catégories (stable, transit et instable). Ces images sont introduites en entrée du CNN pour la classification sans le processus d'extraction de caractéristiques. Un réseau de neurones profonds est formé pour détecter les différentes phases du broutement. Dun *et al.* [52] ont réussi à voir du broutement sur l'image de la pièce usinée en mixant CNN et algorithme génétique et à pallier le problème d'oscillation lié à l'utilisation des algorithmes génétiques en optimisant leur algorithme. Rahimi et al. [144] présentent une approche de détection du broutement combinant un réseau de neurones convolutifs et un modèle basé sur la physique. Ils utilisent le réseau de neurones convolutif pour simuler le fonctionnement du cerveau humain en connectant des neurones virtuels avec des poids accordés résultant en une prédiction d'un état. Un modèle intelligent de détection du broutement est proposé dans le document [154], les auteurs combinent un prétraitement CWT et un réseau de neurones profonds à convolution (DCNN). Dans le document [194], les auteurs combinent AlexNet, un réseau de neurones profonds pré-entraîné, et une solution analytique exploitant l'apprentissage par transfert pour détecter le broutement. Un autre type de réseau de neurones à mémoire longue à court terme (LSTM) est proposé dans le document [197] pour détecter le broutement en fonction de la séquence des courants de commande. Le Tableau 2.11 répertorie les articles qui ont obtenu les meilleures performances en matière de détection du broutement en exploitant soit l'apprentissage automatique, soit l'apprentissage profond.

Tableau 2.11. Liste des meilleurs modèles d'apprentissage profond avec les meilleures performances pour la détection du broutement.

Littérature	Prétraitement	Modèle d'apprentissage	Usinage	Justesse
[59]	WT	CNN	Fraisage	99%
[63]	VMD	CNN	-	92.57%

[242]	-	CNN	Fraisage	98.8%
[220]	CWT-CNN	CNN	Tournage	99%
[191]	CWT	CNN	Fraisage	99.67%
[144]	STFT	CNN	Fraisage	98.90
[154]	CWT	DCNN	Fraisage	99.98
[194]	EMD	AlexNet	Fraisage	82-100%
[197]	-	LSTM	Fraisage	98%

Dans ces recherches relativement récentes, de nombreuses techniques d'apprentissage profond ont été testées, souvent mélangées à d'autres méthodes, et conduisent généralement à de bons résultats. La plupart des études utilisent encore des conditions d'usinage éloignées des applications industrielles, mais certaines publications utilisent des conditions de coupe réalistes. Malheureusement, il est toujours évident dans tous les travaux que l'amplitude des vibrations est fortement liée au broutement et il est donc difficile de démontrer si toutes ces techniques sophistiquées seraient meilleures qu'une simple surveillance du niveau RMS.

2.4. Discussions et perspectives

Les processus d'usinage sont décrits avec précision à partir de modèles dynamiques complexes contenant des non-linéarités, des retards et des effets stochastiques. Compte tenu de la nature de ces modèles et des défis pratiques qui incluent des variables temporelles, le passage de la conception (formes numériques et analytiques) de l'usinage à l'analyse vibratoire des signaux de coupe réalistes reste difficile. Cette étude catégorise les différentes techniques de détection de broutement à l'aide de signaux vibratoires en trois étapes. Premièrement, les techniques de traitement ou de décomposition temps-fréquence, qui décomposent le signal en plusieurs fragments en exploitant une méthode de transformation pour obtenir les informations de broutement pertinentes. Ensuite, la FFT, par exemple, est appliquée à des éléments qui chevauchent les fréquences de broutement identifiées sur le signal. Ces techniques nécessitent beaucoup de temps d'analyse de la part d'un expert, qui visualise ces fragments pour détecter le broutement. Plusieurs auteurs ont utilisé des caractéristiques extraites par des techniques de transformation comme données d'entrée pour les classificateurs d'apprentissage automatique afin de résoudre ce problème. Les caractéristiques sont étiquetées au format entrée-sortie pour former le classifieur afin de reconnaître les différentes phases du signal (broutement).

Plusieurs études majeures (Tableau 2.10) ont démontré des résultats prometteurs dans l'application de techniques d'apprentissage automatique à l'analyse des signaux vibratoires pour détecter, identifier, stabiliser ou supprimer le broutement cible. Ces méthodes d'apprentissage automatique ne peuvent pas gérer des données de grande dimension en raison de la limitation de la capacité de modélisation [96].

Contrairement aux méthodes d'apprentissage automatique conventionnelles, l'apprentissage profond extrait automatiquement les caractéristiques à un niveau supérieur et fusionnera l'extraction et la classification des caractéristiques en une seule structure afin de ne pas nécessiter beaucoup d'essais et d'erreurs. À l'instar des modèles d'apprentissage automatique, l'apprentissage profond a également amélioré les performances de détection du

broutement. Certains auteurs atteignent une précision de près de 100 % en exploitant la technique d'apprentissage par transfert (Tableau 2.11). Malgré l'excellente capacité des modèles d'IA à fournir des prédictions très précises dans la détection des vibrations, ils sont toujours confrontés à des défis importants : (a) les contraintes de temps et d'expertise humaine pour l'étiquetage des données, en particulier lorsque le nombre de classes est élevé avant l'entraînement du modèle ; (b) les besoins en ressources informatiques importantes lors des phases d'apprentissage et de classification pour se lancer ; (c) le manque de transparence en raison de leur nature inhérente de boîte noire.

- Pour atténuer le problème d'étiquetage des données, on peut utiliser les options suivantes :
 - Apprentissage semi-supervisé qui combine apprentissage supervisé et non supervisé. Des algorithmes d'apprentissage non supervisés sont utilisés pour générer automatiquement des étiquettes, qui seront ensuite introduites dans des algorithmes d'apprentissage supervisé. L'apprentissage semi-supervisé présente un avantage significatif dans la réduction du coût d'étiquetage de grands ensembles de données. Les modèles d'apprentissage non supervisés peuvent traverser des données de grande dimension et distinguer des groupes ou des points de données atypiques dans un ensemble de données. Les caractéristiques extraites par les différentes techniques de transformation (WT, FFT, STFT, HHT) ou techniques de décomposition (EMD et EEMD) peuvent être catégorisées par des techniques non supervisées comme KNN ou K-means. Les clusters obtenus par ces méthodes sont considérés comme des classes et serviront de données d'entrée pour un modèle d'apprentissage supervisé.
 - Analyse de données topologiques (TDA) qui permet d'extraire des informations à partir d'ensembles de données de grande dimension, incomplets ou bruités. TDA permet de combiner la topologie algébrique avec d'autres outils mathématiques pour développer une étude de forme purement mathématique. L'un des principaux outils de TDA est l'homologie persistante qui a attiré l'attention de nombreux chercheurs pour l'analyse de signaux topologiques [87, 228]. La combinaison de TDA pour l'étiquetage des données et l'apprentissage par transfert pour l'extraction de caractéristiques peut être un outil puissant pour la détection du broutement.
- Le problème des ressources de calcul lors de l'entraînement du modèle peut être résolu par des plates-formes informatiques hautes performances telles que les unités de traitement graphique (GPU) et les unités de traitement de tenseur (TPU) telles que la collaboration GPU de Google (Google Collab), Azure Machine Learning et Amazon Web Services.
- Les modèles d'intelligence artificielle actuellement utilisés, principalement des réseaux de neurones convolutifs ou profonds, sont si complexes qu'il est quasiment impossible pour leur concepteur d'en comprendre pleinement le fonctionnement, d'où le terme de boîte noire. Cependant, expliquer ses décisions peut apporter de multiples avantages à un machiniste. Pour clarifier et expliquer cette notion de boîte noire, le document [21] propose le concept d'IA explicable. Tout en améliorant les performances de ces modèles, l'IA explicable aide à identifier les problèmes et les failles dans les ensembles de données et le fonctionnement des modèles, permettant aux experts, aux scientifiques des données et aux utilisateurs de comprendre et de faire confiance aux modèles avec leurs prédictions, en tenant compte de la conformité réglementaire.
- Dans ces études, les auteurs cherchent soit à détecter, soit à supprimer le broutement. Étant donné que le broutement affecte la qualité des pièces, les performances et la durée de vie de l'outil de coupe, les vibrations peuvent être atténuées

en tenant compte de tous ces éléments dynamiques. L'apprentissage multimodal peut être une solution à intégrer lors de la conception de modèles de détection de broutement qui considère tous les éléments et leurs caractéristiques intrinsèques, capacités et limites et contribuera de manière significative à la détection de broutement. La fusion multimodale est l'un des thèmes originaux de l'apprentissage automatique multimodal, avec des travaux dans la littérature privilégiant les approches de fusion précoce, tardive et hybride. Techniquement, la fusion multimodale intègre des informations provenant de plusieurs modalités pour prédire un résultat de mesure : une catégorie par classification ou une valeur continue par régression [19].

- Pour éviter le broutement dans les processus de coupe, on peut penser à développer une machine-outil intelligente pour détecter, décider et contrôler les conditions de coupe afin de garantir l'opération d'usinage optimale. Pour cela, l'apprentissage par renforcement peut utiliser un algorithme leur permettant d'effectuer une tâche en leur donnant des indices positifs ou négatifs au fur et à mesure qu'il travaille sur la façon de terminer le travail. Les règles de récompense sont définies, laissant l'algorithme décider des étapes à suivre pour maximiser sa récompense et accomplir la tâche.
- Le placement de capteurs dans l'outil de coupe représente une progression dans la surveillance du processus d'outil, permettant aux utilisateurs de collecter les données nécessaires pour créer des jumeaux numériques plus précis pour les processus d'usinage. Les auteurs ont déjà exploré ce concept d'usinage intelligent en présentant quatre outils, dont un outil intelligent basé sur la force de coupe, un outil de coupe basé sur la température de coupe, un servo d'outil rapide (FTS) et des pinces intelligentes pour une ultra-précision. Le document [44] introduit le concept d'usinage intelligent pour minimiser les parcours d'outils et le temps d'usinage, améliorer la qualité de surface des composants, augmenter la durée de vie de l'outil, usiner avec précision des structures complexes spécifiques, permettre une détection autonome avec auto-apprentissage pour améliorer les performances du processus et détecter dynamiquement le processus de coupe. Ces technologies peuvent être utilisées pour surveiller le processus d'usinage et l'usure de l'outil comme l'un des moyens de résoudre le phénomène de broutement gênant.
- En pratique, les auteurs du document [204] ont expérimenté un outil intelligent pour une opération de perçage à grande vitesse sur une pièce de Circuit Imprimé (PCB) multicouche. Tout d'abord, il a été démontré en mesurant le déplacement axial que l'outil intelligent effectue une autoprotection de la broche pendant l'expérience. L'outil intelligent détecte l'usure de l'outil de perçage, en particulier les plus sévères, qui commencent à la périphérie de l'outil et diminuent progressivement vers le centre puisque le tranchant principal extérieur est soumis au couple le plus élevé que ses adjacents. Cela signifie que la qualité du trou dépend du nombre de trous percés.

2.5. Conclusion

Dans ce chapitre, nous fournissons une analyse cartographique des différentes techniques de détection de broutement, de la méthode de traitement et de décomposition du signal temps-fréquence à l'application de l'intelligence artificielle pour la détection automatique. Cette analyse cartographique nous a permis de visualiser les articles les plus significatifs, les auteurs les plus cités, la collaboration entre auteurs, les pays, continents et revues les plus productifs, le partenariat entre pays, les mots-clés des auteurs et les tendances de la recherche sur la détection du broutement. Cette analyse a montré les limites des techniques classiques de traitement du signal temps-fréquence pour expliquer la valeur de l'application de l'IA pour l'extraction de caractéristiques et la prise de décision. Une comparaison entre les différentes techniques de traitement a été établie dans le Tableau 2.8, montrant l'utilisation des grands

principes de chaque méthode. Malgré la croissance de l'IA (apprentissage automatique et apprentissage en profondeur) dans divers domaines, les techniques traditionnelles de traitement du signal continuent de compléter les modèles d'IA dans la détection du broutement. Les chercheurs n'utilisent pas souvent les techniques d'IA pour détecter les phénomènes du broutement par rapport à d'autres domaines. Dans cette analyse, 679 articles ont été collectés, mais seulement 75 articles concernaient l'application des différentes méthodes d'apprentissage automatique ou d'apprentissage profond, dont les citations globales sont présentées dans le Tableau 2.7. Nous avons également discuté des limites des autres techniques d'IA et proposé des solutions pour atténuer les problèmes de données volumineuses, le coût du temps de calcul et le manque de transparence de ces modèles, qui entravent considérablement son utilisation dans des domaines aussi traditionnels que l'usinage. Ces solutions peuvent permettre la mise en place d'un système multimodal pour considérer et relier les éléments qui causent le broutement et le développement d'un outil de coupe intelligent utilisant l'apprentissage par renforcement. Enfin, nous proposons d'utiliser des algorithmes d'IA explicables pour acquérir des connaissances scientifiques supplémentaires sur les modèles d'IA et améliorer la compréhension de situations complexes.

Nous avons également discuté des limites des autres techniques d'IA et proposé des solutions pour atténuer les problèmes de données volumineuses, le coût du temps de calcul et le manque de transparence de ces modèles, qui entravent considérablement son utilisation dans des domaines aussi traditionnels que l'usinage. Ces solutions peuvent permettre la mise en place d'un système multimodal pour considérer et relier les éléments qui causent le broutement et le développement d'un outil de coupe intelligent exploitant la multimodalité des données. Dans cette optique, la diversité données d'apprentissage fournie par la multimodalité est apparue comme une piste de réflexion pertinente.

Plus généralement, les capacités prédictives des réseaux de neurones apportent aux acteurs des moyens complémentaires de vérification des réglages des machines et d'anticipation de leurs défauts afin d'ouvrir les pistes de réflexions permettant de les éviter. L'identification des paramètres de coupe en utilisant les réseaux de neurones profonds peut s'inscrire dans une approche plus globale de surveillance et de maintenance des équipements. En l'occurrence, l'opérateur pourrait se servir de cette multimodalité comme des sources de données complémentaires (par exemple entre les données numériques et images) pour enrichir sa compréhension du problème traité. La représentation multimodale favorise une modélisation plus riche et par ricochet des moyens d'analyses plus puissants, notamment pour l'aide à la vérification du caractère approprié des paramètres de coupe d'une opération d'usinage. C'est ainsi que dans le chapitre suivant, nous proposons une approche d'apprentissage profond multimodal sur des données d'une opération de fraisage en vue d'une identification pertinente des paramètres de coupe.

Chapitre 3 Apprentissage profond multimodal pour la prédiction du choix des paramètres de coupe dans le processus de fraisage

3. Apprentissage profond multimodal

L'objectif de ce chapitre est de présenter tout d'abord l'apprentissage profond multimodal et ses challenges dans la section 3.1. La section 3.2 un état de l'art sur l'apprentissage profond multimodal dans les processus de fabrication industrielle. Le reste du chapitre présente un cas d'étude sur l'apprentissage profond multimodal appliqué dans le processus de fraisage pour la prédiction du choix des paramètres, en discutant des résultats, les difficultés rencontrées.

3.1. Introduction

Les progrès de la recherche sur l'apprentissage automatique multimodal ont connu une croissance rapide au cours de la dernière décennie dans plusieurs domaines, dont la vision par ordinateur. Le potentiel croissant des sources de données multimodales et des algorithmes d'apprentissage profond a contribué à l'universalité croissante de l'apprentissage profond multimodal. Cela requiert le développement de modèles capables de traiter et d'analyser de façon cohérente les données multimodales [237].

Basé sur l'apprentissage automatique (machine learning), l'apprentissage profond permet aux réseaux informatiques en couches d'apprendre et de représenter les données avec différents niveaux d'abstraction. L'apprentissage profond se caractérise par une cascade d'opération de multiples couches de traitement linéaire et non linéaire pour apprendre les représentations hiérarchiques des données. Actuellement, il existe plusieurs architectures d'apprentissage profond, et ce sujet de recherche est en pleine expansion, de nouveaux modèles sont mis au point pratiquement chaque jour. Les architectures de réseaux de neurones profonds les plus courants sont résumées dans le Tableau 3.1.

Tableau 3.1. Modèles de l'apprentissage profond les plus courants dans la littérature et leurs applications dans l'usinage.

Architecture	Avantages	Inconvénients	Application dans l'usinage
Auto-Encoders (AE)	<ul style="list-style-type: none"> • Clustering • Réduction de dimensionnalité • Compression des données • Récupération d'informations 	<ul style="list-style-type: none"> • Extraction des caractéristiques les plus pertinentes non garanties 	<ul style="list-style-type: none"> • Détection des défauts [12, 13, 81] • Surveillance de l'état [5, 89, 193] • Détection du broutement[52] • Usure de l'outil[18, 75, 173]
Deep Boltzmann Network (DBN)	<ul style="list-style-type: none"> • Robuste aux variations d'hyperparamètres par rapport à certains autres modèles de machine learning comme MLP ANN ou SVM 	<ul style="list-style-type: none"> • Pré-entraînement couche par couche de manière non supervisée • Application de la rétropropagation au modèle pré-entraîné 	<ul style="list-style-type: none"> • Détection de défaut [231] Détection du broutement [58] • Prédiction de l'usure de l'outil[43]

	<ul style="list-style-type: none"> • Corrige les limites de la rétropropagation conventionnelle • Efficace pour la représentation de haut niveau des données d'entrée 		
Convolutional Neural Network (CNN)	<ul style="list-style-type: none"> • Abstraction des caractéristiques à travers une série de couches convolutionnelles et de mise en commun • Traitement des données sous la forme de plusieurs tableaux 	<ul style="list-style-type: none"> • Coût de calcul élevé • Réglage des hyperparamètres difficile 	<ul style="list-style-type: none"> - Surveillance de l'état de l'usure de l'outil [98, 127, 171] - Détection du broutement [154, 191, 194] - Prédiction de la rugosité de surface [2, 147]
Recurrent Neural Network (RNN)	<ul style="list-style-type: none"> • Traite les données de séries chronologiques • Capable d'être lié à un CNN pour former un modèle hybride qui capture à la fois les corrélations séquentielles et spatiales dans les données 	<ul style="list-style-type: none"> • Dépendance temporelle dans les données séquentielles • Problème gradient de fuite 	<ul style="list-style-type: none"> - Prédiction de l'usure de l'outil et de la durée de vie utile restante [219, 232, 240] - Détection du broutement [61, 162, 175, 190] •- Prédiction de la rugosité de surface [2, 136]

Au cours des dernières années, divers chercheurs ont démontré le succès de ces modèles d'apprentissage profond dans l'application de la surveillance de la santé des machines. Ces modèles d'apprentissage profond sont largement utilisés pour le diagnostic des pannes [40, 51, 169], la prédiction de la durée de vie restante [118, 142, 221], et la surveillance de l'état des équipements mécaniques [101, 215].

Compte tenu du succès incontestable de l'apprentissage profond dans le domaine de la vision, la croissance naturelle de la recherche sur l'apprentissage profond mène à des problématiques qui impliquent des données multimodales plus volumineuses et plus complexes. Ces jeux de données multimodales sont composés de données provenant de différents capteurs qui observent des phénomènes communs, et l'objectif est d'utiliser les données de manière complémentaire afin d'apprendre une situation ou tâche complexe [145]. L'un des principaux avantages de l'apprentissage profond est qu'il est possible d'apprendre automatiquement une représentation hiérarchique pour chaque modalité, au lieu de concevoir ou d'élaborer manuellement des caractéristiques spécifiques à la modalité qui sont ensuite transmises à un algorithme d'apprentissage automatique [172]. Le succès des techniques d'apprentissage profond multimodal vient de nombreux facteurs, comme l'existence de de grands volumes d'ensembles de données multimodales, les super calculateurs et la possibilité de représentation des caractéristiques d'organisation hiérarchique à plusieurs échelles.

Un des challenges pratiques pour les chercheurs en apprentissage profond est de renforcer la corrélation et la redondance entre les modalités. Bien que la perception du monde soit facile pour un être humain à travers des informations complètes provenant de multiples organes sensoriels, la confusion entre les diverses sources de données pour les machines représente un véritable challenge pour les analyses futures [70]. Pour résoudre le problème de la divergence entre les informations provenant des données originales de chaque modalité avant l'apprentissage, la fusion multimodale au niveau des caractéristiques est utilisée pour fusionner les caractéristiques extraites de chaque modalité. Quant à la méthode de fusion au niveau de la décision, elle intègre les connaissances générées par les informations multimodales dans différents modèles de base. Ensuite, une décision de fusion équilibrée est prise pour les résultats de ces modèles. En combinant la fusion au niveau des caractéristiques et la fusion au niveau des décisions, la fusion multimodale hybride présente une structure plus souple et consensuelle.

Ces techniques de fusion ont l'objectif de traiter des informations provenant de plusieurs sources hétérogènes afin d'estimer une vision quasi précise des états structurels, fonctionnels et comportementaux d'une machine. Les observations de ces états fournissent des éléments d'analyses et de réflexions aux spécialistes et professionnels du secteur. Cela offre l'opportunité à une gamme d'outils de raisonnement avec parfois leur service numérique interactif dans le diagnostic de défaut d'usinage [24, 46, 47, 80, 83], la collaboration homme-machine [107, 216], le domaine médical [151], les véhicules à conduite autonome [243], la fabrication additive [160].

L'apprentissage multimodal rencontre quelques défis identifiés par les auteurs [20]. Il s'agit de la représentation, la traduction, l'alignement [230], la fusion [141] et le co-apprentissage [143]. Ces défis apparaissent différents malgré l'existence d'un phénomène de croisement. Ils sont souvent appliqués conjointement pour effectuer plusieurs opérations à l'aide de modèles d'apprentissage profond multimodaux. Par exemple, pour effectuer une fusion multimodale, il est nécessaire d'appliquer une représentation pour acquérir des informations supplémentaires et complémentaires. Certains auteurs ont mentionné l'utilisation de la multimodalité dans le contexte industriel.

Dans ce chapitre nous nous intéressons à la prédiction des paramètres de condition de coupe et l'outil de coupe approprié pour la reproduction d'un état de surface d'une pièce usinée. L'usinage de pièces et la maîtrise des états de surface sont un besoin constant des systèmes de production industrielle. La reproduction de certaines pièces originales ou la mise en œuvre de nouvelles pièces est une technique de fabrication qui doit prendre en compte à la fois la rugosité de surface, les conditions de coupe, l'outil de coupe, les dimensions et les signaux de vibration [79]. Dans ce contexte, les trois principaux composants de l'usinage par commande numérique par ordinateur ou *computer numerical control* (CNC) sont une machine-outil, une pièce à usiner et un outil de coupe. Plus précisément, le fraisage qui est un processus d'enlèvement de matière d'une pièce par l'outil de coupe, qui s'accompagne d'une série de modifications de la forme géométrique et des paramètres physiques, tels que la résistance à la coupe, la température de coupe, l'usure de l'outil, etc. Lors de la planification du processus d'usinage, l'outil de coupe et les paramètres de coupe choisis sont des éléments décisifs sur le résultat final. Une sélection appropriée des outils de coupe et des paramètres de coupe peut aussi réduire considérablement la consommation d'énergie et le temps de production du processus d'usinage [137, 215]. La maîtrise de la qualité et la réduction de la consommation d'énergie des machines-outils pour les opérations de tournage ou de fraisage sont importantes pour promouvoir la fabrication durable. Des études ont montré que la sélection de paramètres de coupe optimaux est une approche efficace pour réduire la consommation d'énergie de coupe dans l'usinage [38]. Pour illustrer cela, un intérêt particulier est accordé au fraisage, qui est un processus de fabrication dans lequel l'enlèvement de matière sous forme de copeaux résulte de la combinaison de deux mouvements

: la rotation de l'outil de coupe, d'une part, et l'avancement de la pièce, d'autre part. En fraisage, la qualité de la surface est le facteur complexe et très important dans l'évaluation des composants fabriqués.

Nous proposons une approche pour aider à sélectionner l'outil de coupe et les paramètres de coupe appropriés pour reproduire automatiquement une qualité de surface, à partir de son image et de sa rugosité moyenne arithmétique. Dans un premier temps, nous commençons par l'acquisition de données, et la constitution de bases de données à partir d'éléments hétérogènes. Dans cette base de données, des liens ont été établis entre les modalités pour faciliter les étapes suivantes de la méthodologie de fusion proposée dans le contexte industriel considéré. L'originalité de notre proposition se situe à deux niveaux : i) l'alignement de données textuelles avec des images annotées pour une meilleure acquisition de données multimodales ; ii) la combinaison de plusieurs modalités pour améliorer la prédiction de paramètres cruciaux (vitesse de coupe, profondeur de coupe radiale, et avance par dent) pour assurer une bonne qualité de surface.

Après cette introduction, la section 3.2 présente l'état de l'art sur les applications de l'apprentissage multimodales dans la fabrication industrielle. La section 3.3 montre la méthodologie proposée pour l'apprentissage par fusion multimodale. La section 3.4 consiste à analyser et discuter les résultats. Enfin, la section 3.5 présente la conclusion du chapitre.

3.2. État de l'art sur les applications de l'apprentissage multimodales dans la fabrication industrielle

Dans la littérature, la plupart des actions traitant de la multimodalité sont orientées vers des applications commerciales, médicales et sociétales [70, 94, 145], mais il y a très peu de travaux liés au cadre industriel. Nous constatons également que le potentiel de l'apprentissage automatique multimodal n'en est encore qu'à ses débuts dans le monde de la fabrication industrielle, mais que sa pertinence ne fait aucun doute. Ceci est notamment souligné par des travaux récents exploitant un réseau de neurones multibranches pour le pronostic de pannes à partir de données multimodales [224].

Dans certains environnements complexes, il est nécessaire d'utiliser plusieurs modalités qui fournissent des informations supplémentaires ou complémentaires sur la même situation et offrent une grande opportunité pour la résolution des problèmes. Le mécanisme d'une procédure multimodale s'est révélé utile pour la détection et le diagnostic des défauts [24, 47, 80, 83], la surveillance de l'état des machines [48, 74], l'estimation de la durée de vie utile restante (RUL) des systèmes dans les systèmes industriels [12, 20, 36, 48]. L'approche basée sur les données de la durée de vie utile restante (RUL) peut être utile pour estimer l'état des outils de coupe pendant le processus de fraisage [93]. Les auteurs [93] ont proposé une structure de réseau de neurones profond hybride qui comprend deux modèles parallèles (un LSTM et un CNN) connectés à un réseau de neurones multicouche entièrement connecté qui fusionne la sortie de chaque modèle pour entraîner un modèle de prédiction la RUL. Le LSTM est utilisé pour extraire les caractéristiques temporelles tandis que le CNN est utilisé simultanément pour extraire les caractéristiques spatiales, qui sont ensuite combinées pour donner la prédiction globale du RUL. Pour résoudre les problèmes des méthodes conventionnelles de prédiction de la longévité des roulements, qui se concentrent sur la précision de la prédiction en ignorant le coût et le temps, les auteurs [23] proposent une méthode d'apprentissage des caractéristiques basée sur les données avec un RNN bidirectionnel profond à multi échelles pour estimer la durée de vie utile restante des systèmes industriels. Ils réalisent des expériences sur la base de données NASA C-MAPSS pour évaluer la capacité d'estimation de la méthode. Un autre modèle pour la prédiction du RUL a été défini par les auteurs [45] dans plusieurs conditions d'utilisation avec plusieurs types de défauts. Une modélisation simultanée sur les données de

surveillance multisensorielles et les données sur les conditions de fonctionnement en exploitant parallèlement deux réseaux de neurones, LSTM et Gated Recurrent Unit (GRU) pour capturer les informations sur les conditions de fonctionnement dans le but d'améliorer les performances pronostiques. Les auteurs Marei *et al.* [126] ont proposé une technique de prédiction de la durée de vie utile restante de l'outil de coupe basée sur une combinaison CNN-LSTM pour un usinage optimal. Comme modèle CNN, un ResNet-18 pré-entraîné est utilisé pour extraire les caractéristiques de l'outil de coupe et un réseau LSTM pour l'extraction des caractéristiques des paramètres de condition d'usinage. Les résultats obtenus ont permis de constater la pertinence de l'utilisation des données multimodales.

Dans le contexte d'un diagnostic de défauts, les auteurs Ma *et al.* [120] suggèrent un modèle d'autoencodeur à couplage profond, qui capture les signaux sensoriels multimodaux appartenant à un espace mesurable, telles que les données sonores et vibratoires, et intègre l'extraction de caractéristiques des données multimodales sans effort dans la fusion de données pour le diagnostic des modes de défaut. Une méthode d'apprentissage profond basée sur la fusion de fonctionnalités multimodales pour le diagnostic en ligne de machines tournantes a été présentée par Zhou *et al.* [239]. Ces auteurs réalisent une simulation et une étude de cas pratique est menée pour valider l'efficacité de la méthode. La méthode proposée a été comparée à la méthode basée sur le réseau de neurones convolutionnel sans fusion de caractéristiques. Une augmentation d'environ 5% des performances de la méthode de fusion par rapport à la méthode sans fusion a été observée. Nous pouvons voir sur la Figure 3.1 un modèle de fusion multimodale utilisé pour le diagnostic de la défaillance d'un roulement, qui est composé de quatre parties : l'acquisition de données multimodales, la fusion multimodale au niveau des caractéristiques, l'entraînement et l'optimisation des modèles d'apprentissage profond, et la fusion multimodale au niveau de la décision. Les échantillons d'images en niveaux de gris et les échantillons de séries temporelles sont introduits dans le CNN et le réseau de croyances profondes ou Deep Belief Network (DBN), respectivement, pour former plusieurs couches cachées et optimiser les paramètres du modèle, afin d'obtenir des classificateurs de base pour le diagnostic des défauts de roulements.

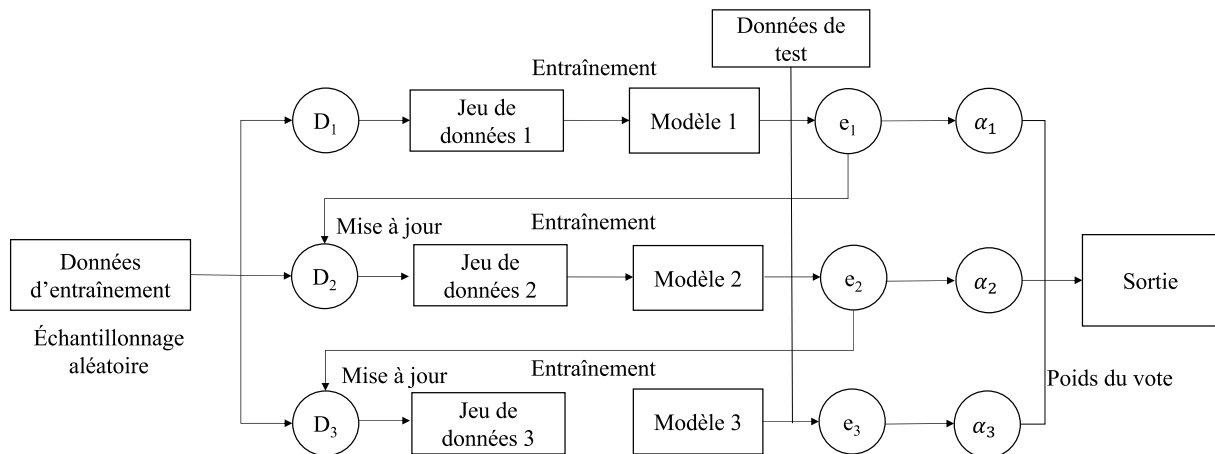


Figure 3.1. Modèle de fusion multimodale tardive pour le diagnostic de défaillances de roulement [28].

Les auteurs Yang *et al.* [224] ont proposé une méthode basée sur la construction d'un réseau de neurones profond multibranches contenant trois branches pour le pronostic des défaillances : i) la branche image, qui utilise un modèle CNN pour extraire les caractéristiques de l'image ; ii) la branche texte, qui extrait les caractéristiques des enregistrements d'inspection à l'aide d'un modèle CNN et iii) la branche de données numériques, qui dispose d'un vecteur d'informations numériques à l'aide d'un réseau neurone feedforward. Fu *et al.* [57] proposent un plan d'extraction de caractéristiques multimodales pour obtenir des représentations

hiérarchiques à partir du signal de vibration original et de l'enveloppe actuelle. Tout d'abord, ils forment deux couches entièrement connectées pour réduire rapidement la dimension d'entrée et apprendre les caractéristiques primaires. Ensuite, deux couches convolutives sont empilées pour apprendre une représentation plus compacte et meilleure des caractéristiques de chaque modèle. Les caractéristiques extraites sont ensuite remodelées en plusieurs vecteurs, et chaque vecteur codera implicitement une caractéristique de défaut. Finalement, l'algorithme de routage dynamique est implémenté comme l'intégration du module de fusion et du classificateur. Pendant la phase d'apprentissage, le signal de vibration injecté par biais et le signal de courant converti sont introduits dans le réseau à différentes entrées. Ensuite, la procédure de routage dynamique met en relation les différentes sources avec les différents modèles de défaut, puis effectue les prédictions. Lv *et al.* [119] ont proposé une approche de fusion multimodale pour le diagnostic des défauts de roulement. Le jeu de données multimodales est composé des caractéristiques artificielles extraites de manière non supervisée par un RBM et des caractéristiques de modèle issues de l'analyse de domaine temps-fréquence. Pour montrer l'efficacité de la méthode, des ensembles de données de roulements ont été utilisés. Sur la même veine, He *et al.* [73] ont proposé un modèle de détection de défaut et d'estimation de la durée de vie restante de l'outil dans le processus de gravure par broyeur ionique basé sur la fusion de données multimodales.

La majorité des recherches dans l'industrie de fabrication se sont concentrées sur la surveillance de l'état d'usure de l'outil et la prédiction de l'usure du flanc de l'outil, de la durée de vie utile restante de l'outil et collaboration homme-robot. Peu d'études ont été réalisées sur l'utilisation des modèles d'apprentissage profond ou de l'apprentissage profond multimodal, la sélection optimale de paramètres de coupe et la surveillance de la rugosité de surface. Il serait intéressant de mettre en place un modèle basé sur l'apprentissage profond multimodal pour la prédiction du choix de paramètre de coupe et l'outil de coupe approprié pour une tâche donnée.

3.3. Méthodologie proposée pour la prédiction du choix de paramètres de coupe et l'outil de coupe

3.3.1. Les étapes de la méthodologie proposée

Dans cette section, nous expliquons la méthodologie de travail proposée. Elle comprend six étapes, à savoir la collecte et la préparation des données, le choix des modèles de traitement, la fusion des modèles, l'entraînement des modèles fusionnés et l'interprétation du résultat.

- *Collecte et préparation des données* : les données sont collectées à partir d'un processus de fraisage sur une plaque d'aluminium et mises dans un format approprié pour le traitement. Ces expériences ont donné lieu à deux types d'ensembles d'images et de données numériques.
- *Alignement* : il s'agit d'un processus de mise en correspondance d'éléments provenant de deux ou plusieurs modalités. Cette phase permet de déterminer la relation entre chaque image de l'expérience et ses conditions de coupe (base de données numériques).
- *Choix des modèles de traitement* : cette étape consiste à créer un modèle adapté au traitement de chaque type de données. Dans ce cas, un CNN est proposé pour traiter les images et un RNN avec des couches LSTM pour les données numériques.
- *Fusion de modèles* : elle permet de tirer parti de plusieurs modalités pour résoudre le même problème. Un modèle de fusion tardive est proposé, c'est-à-dire une fusion au niveau du modèle pour effectuer l'entraînement.
- *Interprétation du résultat* : elle consiste à fournir des informations sur le résultat obtenu concernant les données utilisées et le processus d'apprentissage : les courbes d'entraînement et de validation. Les résultats sont interprétés à l'aide des indicateurs de performance les plus populaires : la précision de la classification et le taux de perte. La

précision permet de transmettre simplement et efficacement des informations chiffrées. Le taux de perte est un complément essentiel de la précision. La fonction de perte est basée sur le calcul de l'entropie croisée. Elle quantifie la différence entre deux distributions probabilistes. Un taux de perte négligeable représente une meilleure performance du modèle. La fonction d'entropie croisée de la perte est présentée dans les fonctions 1 et 2.

$$L = \frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (1)$$

$$L = - \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (2)$$

La couche de sortie du modèle est définie avec n nœuds (un nœud pour chaque classe) et plus la valeur de la fonction de perte est proche de 0, plus elle est fiable. La précision est le rapport entre le nombre de classes correctement prédites et le nombre total d'exemples.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3)$$

$$Accuracy(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n 1(\hat{y}_i = y_i) \quad (4)$$

\hat{y}_i est la valeur prédite du i ème échantillon, y_i représente la valeur réelle et n le nombre d'échantillons. Les variables TP, TN, FP et FN représentent les vrais positifs, les vrais négatifs, les faux positifs et les faux négatifs.

Les étapes de cette approche sont présentées de manière schématique par la Figure 3.2.

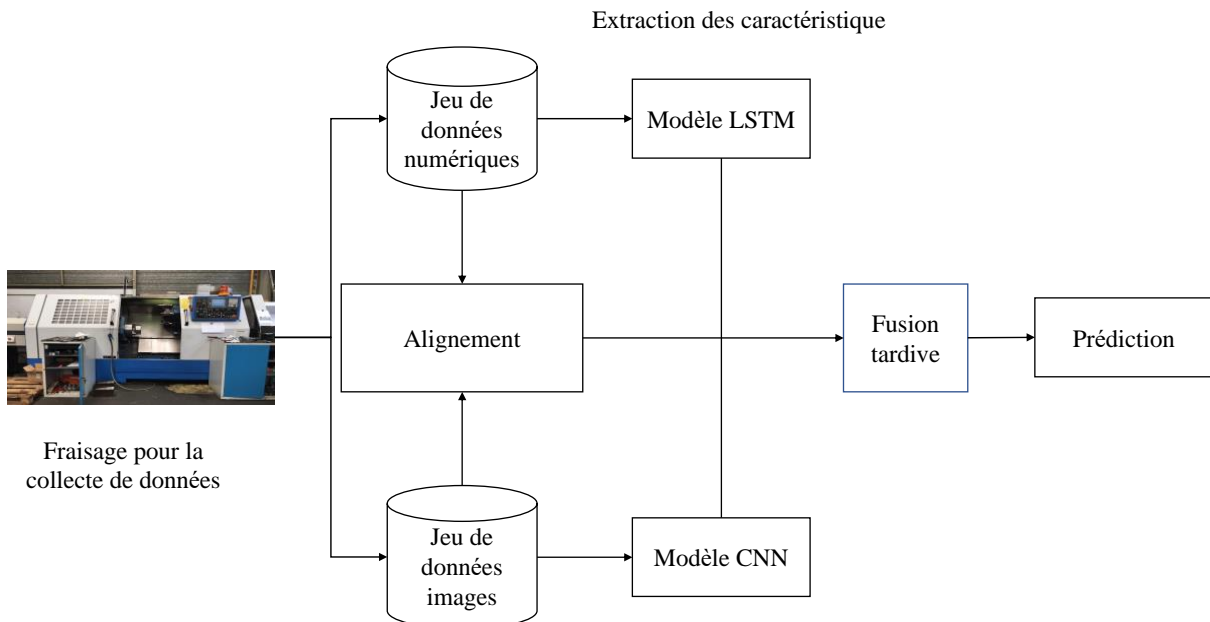


Figure 3.2. Méthodologie proposée pour la prédiction du choix des paramètres coupe.

3.3.2. L'étude de cas

Les machines à outils spécialisées, telles que les fraiseuses CNC, sont devenues des composants essentiels des centres d'usinage pour leur capacité à usiner des formes complexes sans démonter la pièce. Le processus de fraisage pour l'usinage de précision consiste à couper le métal pour concevoir des pièces mécaniques de précision. Le processus de fraisage est réalisé par un assistant CNC et se compose de quatre étapes. La première étape consiste à programmer l'ordinateur à partir de l'interface en exploitant un logiciel de programmation automatique de FAO (fabrication assistée par ordinateur) ou de CAO (conception assistée par ordinateur). Le processus de programmation s'effectue en saisissant une série de chiffres et de lettres après avoir effectué les calculs appropriés. Une fois cette programmation faite, la pièce à usiner et l'outil de coupe sont placés en fonction du type de coupe à effectuer ; l'étape suivante consiste à lancer le processus de fraisage pour un usinage de précision. En exploitant des techniques d'apprentissage profond, ce système sera capable de prédire les conditions de coupe pour reproduire une pièce existante en disposant des images et de la rugosité moyenne arithmétique de la pièce. Comme il existe des millions de combinaisons d'outils, il est impossible de faire de telles prédictions à l'œil nu. L'approche développée peut être utilisée comme un système d'aide à la décision pour déterminer les conditions de coupe appropriées pour la reproduction d'une pièce existante.

3.3.2.1. Le processus de fraisage

Le processus de fraisage est une opération d'usinage exploitant des outils rotatifs sur une pièce donnée. Dans cette étude, le fraisage a été effectué sur une fraiseuse CNC (Haas VF1type), les données sont collectées en expérimentant sur une plaque d'aluminium AU4G (2017A) en exploitant différentes conditions de coupe pour obtenir plusieurs finitions de surface. Le Tableau 3.2 nous donne un aperçu des caractéristiques de la fraiseuse.

Tableau 3.2. Caractéristiques de la fraiseuse VF1

Description	Valeurs
Vitesse maximale de la broche	8100 tr/min
Couple maximal de la broche	122.0 Nm à 2000 tr/min
Fraisage maximal	16.5 m/min
Vitesses de déplacement rapides X-Y-Z	25.4 m/min
Force maximale X-Y-Z	11343 N
Capacité de changement d'outil	30
Diamètre maximal de l'outil	89 mm
Palette interne	257 cm x 251 cm x 257 cm
Palette externe	249 cm x 232 cm x 254 cm
Vitesse de la broche	8100 tr/min
Puissance broche	22.4 kW

Le type d'outil de coupe dépend du type de machine (conventionnelle ou CNC), de la puissance de la machine, la pièce à usiner (acier, aluminium, etc.) et le type d'opération (fraisage, perçage, tournage, etc.). En générale, le choix se fait entre le carbure de tungstène et l'acier rapide supérieur (ARS) :

- Les outils carbures : composés de carbure de tungstène et de titane très consistant préfabriqués dans du cobalt. Cette consistance naturelle reste presque intacte à chaud, ce qui permet d'utiliser des vitesses de coupe très élevées. Ces outils sont particulièrement utilisés lors que les états de surface de haute qualité sont souhaités. Ces outils sont différenciés en deux types, les carbures non revêtus et les carbures revêtus qui sont plus résistant à l'usure. Ils sont plus utilisés sur les machines à commande numérique.
- Les outils acier rapide supérieur (ARS) : Ce sont des aciers fortement alliés, composés éléments chimiques additionnelles (tungstène, manganèse, chrome, vanadium, molybdène) qui permettent d'optimiser les caractéristiques de l'outil. Il existe deux types d'outils ARS : les outils monoblocs utilisés dans les processus (fraisage, tournage, perçage et d'alésage) et les outils brasés constitués de deux matériaux différents comme l'outil couteau ARS. Ces outils ont une capacité limitée de découpage, et n'arriverons pas à couper pas les aciers trop durs. Les ARS sont particulièrement utilisés pour les pièces tendres comme le bois et le plastiques et peuvent aussi effectuer des opérations telles que la réalisation des formes particulières (fraisures de vis, rainures, etc.) sur matériaux comme l'aluminium et le cuivre.

Dans ce cas, ces deux outils de coupe ont été utilisés sur les plaques (carbure de tungstène et ARS) pour effectuer le fraisage (comme indiqué sur la Figure 3.3).

Plusieurs vitesses de coupe (120, 140, 160, 180 et 200) ont été utilisées avec une variation de l'avance par dent (0,01, 0,02, 0,03, 0,04 et 0,05) pour chaque vitesse de coupe et l'avance qui est restée constante tout au long de l'opération. Chaque valeur de la vitesse de coupe a été combinée avec toutes les valeurs de l'avance par dent à l'aide des outils de coupe. Ces opérations ont produit plusieurs états de surface qui ont servi de base de données pour cette étude.




Figure 3.3. Processus de la collecte de données sur la fraiseuse.

Le fraisage des échantillons de plaques d'aluminium obtenus lors de l'expérimentation ont permis d'obtenir deux types de données : les images des surfaces usinées et les valeurs de la moyenne arithmétique de la rugosité de ces surfaces. Chaque combinaison de conditions de coupe a été utilisée pour obtenir un état de surface, et les valeurs de la moyenne arithmétique de la rugosité de surface sont calculées par un rugosimètre. Ce calcul a permis de construire la

base de données numérique avec les valeurs des paramètres de coupe (rugosité, vitesse d'avance, vitesse de coupe et vitesse d'avance par dent) utilisés. Les Tableau 3.3 et

Tableau 3.4 montrent les combinaisons possibles des conditions de coupe avec les deux outils de coupe avec la vitesse de coupe (V_c en m/min), la vitesse d'avance par dent (F_z en mm/dents) et la rugosité moyenne arithmétique. Sur la ligne F_z/V_c , on trouve les valeurs de la vitesse de coupe, la colonne représente la vitesse d'avance par dent, et le centre représente les valeurs de la rugosité arithmétique.

Tableau 3.3. Variation des paramètres d'entrée en fonction de la rugosité lors du fraisage avec l'outil ARS

V_c (m/min) \ F_z (mm/dent)	120	140	160	180	200
0.01	1.14 μm	1.16 μm	1.05 μm	1.07 μm	0.87 μm
0.02	1.21 μm	1.27 μm	1.17 μm	1.12 μm	0.96 μm
0.03	1.55 μm	1.33 μm	1.49 μm	1.35 μm	1.25 μm
0.04	1.67 μm	1.6 μm	1.52 μm	1.46 μm	1.49 μm
0.05	1.76 μm	1.61 μm	1.61 μm	1.50 μm	1.51 μm

Tableau 3.4. Variation des paramètres d'entrée en fonction de la rugosité lors du fraisage avec l'outil carbure

V_c (m/min) \ F_z (mm/dent)	120	140	160	180	200
0.01	1.14 μm	1.15 μm	0.98 μm	0.96 μm	0.82 μm
0.02	1.15 μm	1.19 μm	1.01 μm	0.98 μm	0.85 μm
0.03	1.27 μm	1.26 μm	1.13 μm	1.02 μm	0.93 μm
0.04	1.31 μm	1.48 μm	1.26 μm	1.25 μm	1.06 μm
0.05	1.60 μm	1.52 μm	1.46 μm	1.36 μm	1.15 μm

Par exemple, lorsque $F_z = 0,01$ mm/dent et $V_c = 120$ m/min, la valeur de R_a est de 1,14. Comme les données originales sont à des échelles très différentes, elles ont été normalisées. Toutes les valeurs sont ramenées entre 0 et 1. Les données à échelle variable sont une des difficultés de l'analyse, une variable numérique dont la plage de valeurs est comprise entre 0 et 1000 est plus volumineuse dans l'analyse qu'une variable dont les valeurs sont comprises entre 0 et 1, ce qui poserait un problème de biais par la suite. Pour ce faire, chaque valeur est normalisée comme suit :

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (5)$$

Cette procédure utilise uniquement les valeurs min et max pour normaliser.

Ensuite, ces échantillons ont été convertis en plusieurs séries d'images par une caméra 108mp pour obtenir une base de données d'images avec une résolution optimale afin que les empreintes laissées par les outils soient reconnaissables. Chacune d'entre elles est étiquetée avec sa valeur Ra et les paramètres des conditions de coupe afin d'établir le lien entre les deux sources. Chaque combinaison des paramètres des conditions de coupe des Tableau 3.3 et

Tableau 3.4 correspond à une surface fraisée. Nous pouvons voir dans la Figure 3.4 l'aperçu de quelques plaques usinées.




Figure 3.4. Image des surfaces fraisées.

3.3.2.2. Le processus d'alignement

Nous passons par un processus d'alignement de nos données multimodales, qui consiste à relier les caractéristiques correspondantes de chaque modalité. Dans notre cas, ce processus se fait d'abord en déterminant les caractéristiques des empreintes d'outils laissées sur l'image pendant l'usinage pour la reconnaissance des outils d'usinage et les caractéristiques extraites des données numériques. Enfin, nous identifions les relations directes qui relient les caractéristiques de ces deux sources de données (voir Figure 3.5). D'un côté se trouvent les données numériques, et de l'autre, l'image des surfaces usinées, le but de ce processus est de relier chaque image à sa valeur de rugosité et aux conditions de coupe. Nous pouvons voir ce processus dans le Tableau 3.5, le lien entre chaque image et les conditions de coupe de l'usinage (rugosité, avance par dent, vitesse de coupe, et outils de coupe) formant les composantes d'un vecteur associée à chaque image dans un fichier CSV.

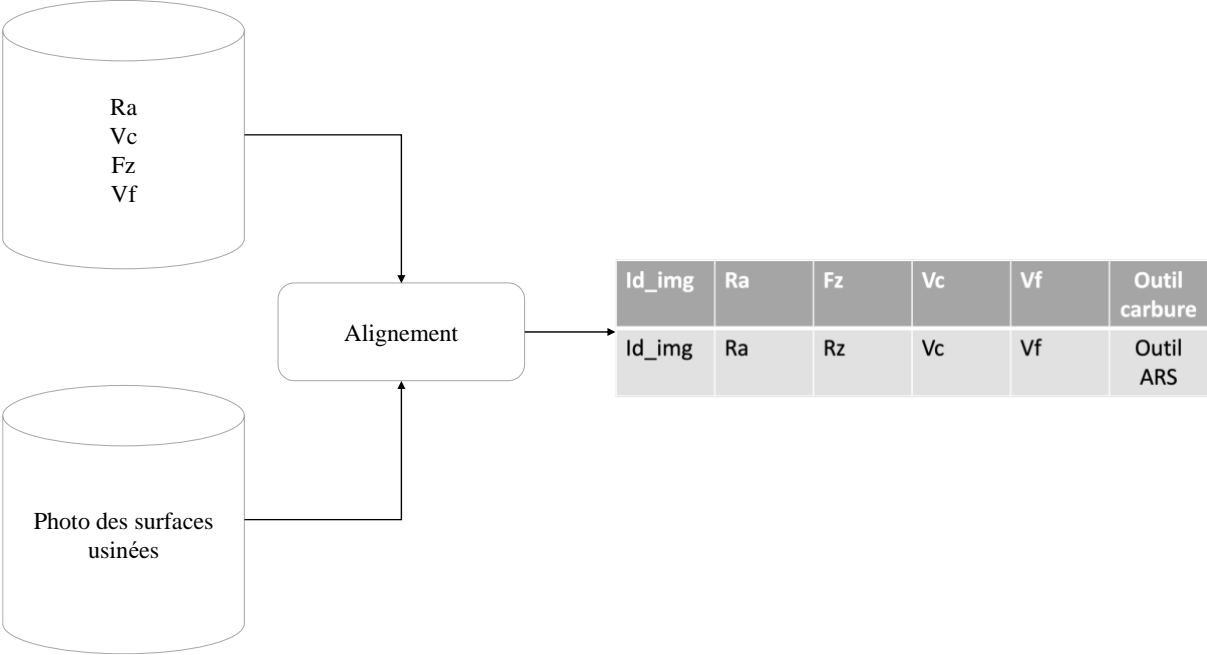








Figure 3.5. Alignement des données multimodales.

Tableau 3.5. Représentation des données des deux sources

Image	Ra (μm)	Fz (mm/dent)	Vc (m/min)	Outil
	1.14	0.01	120	ARS
	1.21	0.02	120	ARS
	1.55	0.03	120	ARS
	1.07	0.01	180	ARS
	1.12	0.02	180	ARS
	1.60	0.05	180	ARS

3.3.2.3. Le processus d'augmentation de données

Étant donné que cette approche consiste à la modélisation d'une méthode d'apprentissage profond qui nécessite une grande quantité de données pour avoir une bonne performance. Après la procédure d'alignement, un processus d'augmentation de données a été réalisé sur la base de données dans le but de l'enrichir et de la diversifier pour pouvoir entraîner et tester le modèle proposé. Il existe plusieurs techniques d'augmentation, comme les transformations géométriques qui sont intéressantes pour les espaces vectoriels, car elles sont des bijections des ensembles géométriques vers eux-mêmes. On peut les catégoriser en fonction des éléments conservés [198] dont notamment la conservation des distances et angles orientés avec les déplacements (translations et rotations) ou la conservation des rapports de distances avec les similitudes (isométries et homothéties).

Les réseaux de neurones convolutifs présentent des invariances par les déplacements [123], et de ce fait une augmentation par translations et rotations, n'apporterait pas de véritable diversité à l'ensemble d'apprentissage. C'est ainsi que nous nous sommes orientés vers une transformation géométrique par similitude avec l'homothétie pour réaliser une augmentation de données pouvant booster la diversité des données d'apprentissage. En effet, une expérimentation antérieure en adaptation de domaines avec une augmentation de données reposant sur l'homothétie nous a fourni des résultats prometteurs dans une application

météorologique [47]. C'est ainsi qu'il nous a paru naturel de se tourner à nouveau vers l'homothétie pour une augmentation de données multimodal avec une contrainte d'alignement des données numériques et de images.

Dans cette étude, le processus d'augmentation de données consiste à redimensionnement des images, appelé homothétie en terme plus mathématique. Il s'agit d'une transformation géométrique permettant d'agrandir ou de réduire une image selon un rapport d'homothétie k et un centre O plus précisément $h_{(O,k)}$. Le rapport d'homothétie affecte la taille de l'image et cela peut également avoir un effet sur l'orientation de l'image.

3.3.2.4. Les modèles d'apprentissage profond de la méthodologie

3.3.2.4.1. Le modèle CNN

Un processus de normalisation a été effectué sur les données d'image dans la phase d'apprentissage du réseau. Puisque les images brutes ont une dimension variable et que chaque pixel des canaux RVB est dans la plage $[0, 255]$. Cette normalisation mettra à l'échelle les valeurs des pixels au même niveau. Dans le modèle d'apprentissage profond, la sortie de chaque couche est l'entrée de la couche suivante. La normalisation à l'entrée facilitera l'apprentissage et pour obtenir une meilleure performance d'apprentissage, elle est effectuée à l'entrée de chaque couche. Le modèle se compose de cinq couches CNN, qui sont utilisées pour extraire les caractéristiques de l'image. À la sortie de chaque couche de convolution, un processus de normalisation est effectué en exploitant la couche de normalisation des lots (« Batch-normalization »). Les couches CNN empilées sont analysées par une couche de mise en commun maximale (« Maxpooling »), qui réduit les dimensions des données en combinant les sorties des clusters neuronaux d'une couche en un seul neurone dans la couche suivante. Les couches CNN sont constituées de 3 filtres de taille (3×3) . La taille maximale des filtres des couches de clustering est de (2×2) . Nous ajoutons deux autres couches, une couche d'exclusion (« dropout ») pour désactiver les parties aléatoires des neurones afin que le réseau s'adapte au manque d'informations et une couche d'aplatissement (« flatten ») pour rassembler toutes les images (matrices) dont nous disposons en un seul (long) vecteur. Le modèle CNN reçoit en entrée une série d'images de dimension $250*166$ par une couche de convolution suivie d'une opération de normalisation. Ensuite, le reste des couches de convolution est suivi par des couches de mise en commun pour compresser leurs sorties et ne retenir que les informations essentielles. Toutes les caractéristiques sont conservées dans une couche aplatie préparée pour l'opération de fusion. Le côté droit de la Figure 3.6 montre l'architecture détaillée du modèle CNN de la méthodologie.

3.3.2.4.2. Le modèle LSTM

Le modèle LSTM se compose d'une couche d'entrée, et de deux couches LSTM empilées pour l'extraction de caractéristiques à partir de données numériques. Chacune de ces couches comprend une structure de 64 neurones, et une troisième couche aplatie (voir à gauche de Figure 3.6). Dans cette partie, une opération de normalisation des données a été effectuée avant leur introduction dans le réseau.

3.3.2.4.3. Le processus de fusion

La fusion des modèles CNN-LSTM a attiré l'attention des chercheurs dans différents domaines [88]. Mou *et al.* [131] proposent un modèle de fusion CNN-LSTM pour détecter le niveau de stress d'un conducteur. Les résultats de cette méthode surpassent les modèles de l'état de l'art avec une précision moyenne de 95,5%. D'autre part, Hatami *et al.* [72] utilisent la fusion LSTM-CNN dans le domaine médical pour prédire le résultat clinique des patients victimes d'un accident vasculaire cérébral. Pour améliorer l'extraction efficace et éviter la perte

d'informations sur les signaux d'électroencéphalographie (EEG), H. Li *et al.*[101] extrait les caractéristiques spatiales avec CNN et les caractéristiques temporelles avec LSTM, puis fusionne leurs sorties. Cette technique a amélioré la précision de l'EEG. La fusion LSTM-CNN s'est avérée efficace dans le diagnostic des défaillances de boîtes de vitesses. Cette fusion a permis de déterminer le type de défaut et sa localisation Shi *et al.* [163]. Sur la base de cette littérature, un modèle de fusion multimodale LSTM-CNN est conçu pour traiter les données.

Parmi les méthodes de fusion existantes, nous utilisons la fusion au niveau du modèle de classificateur appelée fusion tardive, car nous effectuons l'extraction des caractéristiques pour les deux modèles en parallèle et ensuite nous fusionnons les sorties de ces modèles en formant un réseau de bout en bout avec un vecteur de sortie dont les composantes sont les types d'outils de coupe et les paramètres des conditions de coupe. La première partie reçoit la sortie du modèle LSTM pour les données numériques avec une sortie de 192 neurones de caractéristiques et la seconde partie reçoit la sortie du réseau CNN pour les images avec une sortie de 162688 neurones. Les sorties du modèle LSTM (partie gauche de la Figure 3.6) et du modèle CNN (partie droite de la Figure 3.6) sont fusionnées avec la fonction concaténer, puis une fonction d'activation (relu) est appliquée à la fusion. Une couche entièrement connectée est ajoutée avec 128 unités pour former les sorties du réseau. Chaque paramètre a sa propre couche de sortie pour effectuer une évaluation de chaque sortie. La prédiction des paramètres qui ont une valeur numérique est effectuée par une technique de régression exploitant l'erreur quadratique moyenne (MSE) et la fonction de perte de l'erreur absolue moyenne (MAE) comme métriques. Seul l'outil de coupe est prédit avec la fonction d'activation softmax (ARS et carbure), la fonction de perte d'entropie croisée catégorique et la précision comme métriques. Cette fusion peut être visualisée sur la Figure 3.6.




Figure 3.6. Fusion tardive des modèles CNN-LSTM.

3.3.2.4.4. Les résultats

Nous avons d'abord utilisé un jeu de données contenant une seule entrée (images) et les paramètres des conditions de coupe (vitesse de coupe, vitesse d'avance, profondeur de coupe) qui seront les valeurs à prédire. Pour cela, nous implémentons une architecture CNN contenant des couches de convolution et de mise en commune (maxpooling). Ce CNN est créé pour la prédiction par régression en remplaçant la couche entièrement connectée (fully connected layer) utilisée pour la classification avec la fonction d'activation par trois autres couches entièrement connectées aux nœuds représentant chaque valeur à prédire. Ces couches entièrement connectées sont dotées d'une fonction d'activation linéaire pour la régression de nos paramètres de conditions de coupe (voir Figure 3.7). Nous entraînons ensuite le modèle CNN avec une fonction de perte d'erreur quadratique moyenne (mse) pour prédire les valeurs continues.





Figure 3.7. Architecture détaillée du modèle unimodal.

Nous pouvons utiliser la courbe d'apprentissage pour évaluer le comportement des modèles d'apprentissage automatique. Dans notre cas, le modèle a été entraîné sur 60 époques avec une fonction d'activation linéaire et une fonction de perte MSE. Sur la Figure 3.8, nous pouvons remarquer à gauche la courbe représentant la dynamique de la justesse des données d'entraînement et de validation, qui se déroule plutôt bien malgré l'écart entre les deux bases de données. À droite, nous avons la courbe de perte sur laquelle nous identifions que la perte de validation est supérieure à la perte d'entraînement. Dans ce cas, cela indique que l'ensemble de données d'entraînement est plus accessible à la prédiction pour le modèle que l'ensemble de données de validation. Cela montre que la capacité de généralisation du modèle unimodal est faible et peu fiable.

Justesse de l'entraînement et de validation



Perte de l'entraînement et de validation

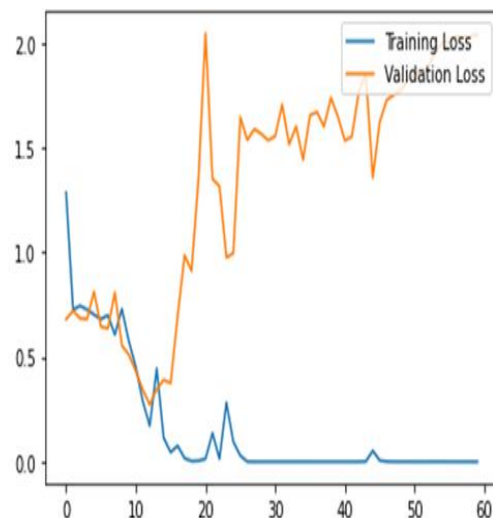


Figure 3.8. Courbes de justesse et de perte du modèle CNN unimodal.

Pour corriger ce problème dû au surajustement, nous avons appliqué une approche d'arrêt précoce appelée Early stopping, une méthode qui régularise les modèles d'apprentissage profond en arrêtant l'entraînement après un certain nombre (patience) d'époques une fois que les performances du modèle ne progressent plus sur un jeu de données de validation sélectionné [134]. En effet, tout au long de l'entraînement, les meilleurs poids du modèle sont conservés et mis à jour. Dans ce travail, l'arrêt précoce a été conçu pour surveiller la courbe de perte de validation et arrêter l'entraînement lorsque cette perte de validation ne progresse plus pendant quatre époques (patience de 4). Pendant l'apprentissage, le meilleur poids du modèle est conservé dès que la valeur de la perte de validation diminue. Dans cette configuration, l'apprentissage du modèle s'arrête après 17 époques sur les 60 époques initialement prévues (Figure 3.9).




Figure 3.9. Courbes de justesse et de perte du modèle CNN unimodal avec l'arrêt précoce.

Dans la partie " Justesse de l'entraînement et de la validation " du modèle de fusion LSTM-CNN, la courbe bleue représente la précision des données d'entraînement, et la courbe orange celle des données de test (voir Figure 3.10). Pendant l'entraînement d'un modèle profond (ou réseau de neurones profond), le modèle peut être évalué à chaque itération (époque). D'une part, il est évalué sur le jeu de données d'entraînement pour donner une idée de la qualité de l'apprentissage du modèle, c'est-à-dire de son efficacité.

D'autre part, le modèle peut également être évalué sur le jeu de données de validation, qui donne une idée de sa capacité de généralisation [86]. Dans notre travail, les échantillons du jeu de données de validation ne font pas partie des données d'entraînement de notre modèle, c'est-à-dire que les deux jeux de données sont distincts. La forme des courbes de perte montre un point d'inflexion dans la perte de validation qui peut être le point auquel l'entraînement pourrait être arrêté, car l'expérimentation après ce point conduira probablement à un modèle trop ajusté. En lisant les courbes de perte dans la phase de validation, nous observons la stabilité du modèle jusqu'à la 13ème époque, qui est le point d'inflexion.

Nous remarquons que la précision continue de s'améliorer sur les deux ensembles (entraînement et test), ce qui nous permet d'éviter le surajustement des données. Dans la deuxième partie, "Perte d'entraînement et de validation", les courbes de perte d'entraînement et de validation connaissent simultanément une diminution, une phase en dents de scie et une phase de stabilité.




Figure 3.10. Courbes de justesse et de perte du modèle de fusion CNN-LSTM.

Nous pouvons observer dans le Tableau 3.6 que le modèle de fusion multimodale surpasse le modèle unimodal par sa capacité à s'adapter aux ensembles de données d'entraînement et de validation. Ainsi, nous justifions que le choix multimodal est meilleur que le modèle unimodal. Les systèmes multimodaux capturent plus d'informations que les systèmes unimodaux. Bien que les modèles unimodaux soient performants, ils ne tiennent pas compte des informations entre les modalités. L'extraction des caractéristiques essentielles d'une seule modalité avant la fusion ne tient pas compte de la cohérence et de la complémentarité de l'interaction multimodale et influence la prise de décision finale. En d'autres termes, une modalité peut fournir des informations supplémentaires à l'autre modalité, et les caractéristiques de fusion des deux contribuent différemment à la décision finale. En raison de la quantité minimale d'échantillons d'entraînement dans notre ensemble de données, le modèle CNN sur l'ensemble de données d'image rencontre des phases de surajustement sur l'ensemble de données de validation, et le modèle LSTM sur l'ensemble de données numériques ne parvient pas à converger sur les ensembles d'entraînement et de validation. Néanmoins, le modèle de fusion multimodale est plus performant, ce qui indique sa meilleure capacité de généralisation.

Tableau 3.6. Comparaison des modèles unimodales et multimodale

Type de donnée	Modèle	Taux de perte de l'entraînement	Justesse de l'entraînement	Taux de perte de validation	Justesse de validation
Données numériques	LSTM	0.7281	0.4701	0.6971	0.4667
Données images	CNN	0.0013	0.9667	1.8527	0.9000
Données images-Données numériques	CNN-LSTM	0.0068	0.9985	0.0196	0.9931

Pour montrer l'efficacité de l'entraînement, nous avons d'abord modifié la distribution de l'ensemble de données, passant d'ensembles d'entraînement (70%) et de validation (30%) à des ensembles d'entraînement (50%), de validation (20%) et de test (30%). Ensuite, nous avons attribué une couche de sortie à chaque paramètre, comme le montre la Figure 3.7. La prédiction des paramètres qui ont une valeur numérique est effectuée par une technique de régression exploitant l'Erreur Quadratique Moyenne (MSE) (équation 6), et la fonction de perte de l'erreur absolue moyenne (MAE) comme métriques (équation 7). Seul l'outil de coupe est prédit avec la fonction d'activation softmax (ARS et carbure), la fonction de perte d'entropie croisée catégorique et la justesse (« accuracy ») comme métrique. Les courbes de la Figure 3.11 montrent l'écart entre l'ensemble d'apprentissage et l'ensemble de validation sur 16 époques avec une taille de lot de 16 en exploitant la métrique dite erreur absolue moyenne ou Mean Absolute Error (MAE) sur les sorties Vc et Fz. Cet écart est calculé par la fonction de perte MAE généralement utilisée pour la régression.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (6)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (7)$$




Figure 3.11. Courbes d'entraînement et de validation sur Fz et Vc en exploitant l'évaluateur mae.

La Figure 3.11 montre que la fonction MAE est plus performante sur la sortie Vc que Fz. Au début de l'apprentissage, nous trouvons un grand écart entre les deux ensembles, mais à partir de 10 époques, les deux ensembles se rapprochent.




Figure 3.12. Courbes d'entraînement et de validation sur Fz et Vc en exploitant l'évaluateur mse.

La Figure 3.12 montre une diminution des taux d'erreur des sorties Fz et Vc par rapport aux courbes MAE. La fonction MSE met l'accent sur les erreurs significatives, contrairement à la fonction MAE, qui n'est pas sensible aux valeurs aberrantes. La Figure 3.13 montre les courbes de perte et de précision de la sortie de l'outil de coupe. Le modèle parvient à classer l'outil de

coupe avec une précision de plus de 97 % et un taux de perte faible ; les valeurs de cette étape sont résumées dans le tableau 6.




Figure 3.13. Courbes de perte et de précision de l'entraînement et de validation pour la classification de l'outil de coupe.

Le Tableau 3.7 montre les valeurs des paramètres d'évaluation sur l'ensemble de test. Les métriques utilisées pour le test sont MSE et MAE. La métrique MAE est la plus efficace dans les phases d'entraînement, de validation et de test grâce à sa capacité à ne pas être sensible aux valeurs aberrantes. MAE permet de quantifier l'erreur commise par le modèle. Plus elle est élevée, moins le modèle est efficace. Contrairement à MAE, MSE pénalise plus fortement les erreurs significatives que les erreurs mineures.

Tableau 3.7. Les métriques d'évaluation pour la régression

Sortie	Perte	MSE	MAE	Justesse
Vc	0.013	0.00027	0.013	-
Fz	0.34	0.34	0.50	-
Tool	0.017	-	-	0.97

Pour la prédiction d'outil qui a été considérée comme un cas de classification (ARS et carbure), le Tableau 3.8 montre le rapport de classification. Ce rapport illustre les principales métriques de classification par classe : précision, rappel et score f1. Ces métriques sont calculées par rapport aux vrais et faux positifs et aux vrais et faux négatifs. La précision est la capacité d'un modèle à ne pas classer un échantillon de la classe positive ARS qui appartient à la classe Carbure et est définie dans l'équation 8.

$$\text{Précision} = \frac{\text{Vrais Positifs}}{(\text{Vrais Positifs} + \text{False Positifs})} \quad (8)$$

Le rappel est la capacité d'un modèle à rechercher toutes les instances positives. Il est défini dans l'équation 9.

$$Rappel = \frac{Vrais\ Positifs}{(Faux\ Positifs + Faux\ Negatifs)} \quad (9)$$

Le score F1 représente le pourcentage de prédictions correctes, équation 10.

$$F1 - score = \frac{2 * (Précision * Rappel)}{(Précision + Rappel)} \quad (10)$$

Tableau 3.8. Rapport de classification

	Précision	Rappel	f1-score
Carbure	1.00	0.90	0.95
ARS	0.97	1.00	0.99

Pour une explication plus approfondie du Tableau 3.8 et la Figure 3.14 représente la matrice de confusion de la prédiction de l'outil de coupe. Sur la première ligne, sur 727 échantillons de la classe carbure, 90 sont classés dans la classe ARS, et 2777 échantillons de la classe ARS sont tous classés dans leur classe réelle, ce qui justifie une précision de 100% pour la classe carbure, et 97% pour ARS.




Figure 3.14. Matrice de confusion pour la prédiction de l'outil.

3.4. Discussions

La méthodologie utilisée était basée sur une stratégie de fusion tardive, permettant d'utiliser au mieux chaque modèle. Le fait de séquencer les résultats d'apprentissage de ces

modèles le plus tard possible favorise la flexibilité dans la gestion de la multimodalité. Certains travaux de la littérature utilisent souvent des bases de données synthétiques pour modéliser des conditions industrielles nécessitant une fusion multimodale. Dans notre étude de cas, nous avons travaillé à la construction d'une base de données alimentée par des expériences réalisées sur une fraiseuse CNC sous la supervision d'un expert du domaine. Après avoir exécuté nos modèles de réseaux de neurones sur ces données, le modèle de fusion peut effectuer des tâches de classification sans l'intervention de l'expert afin de prédire le choix des paramètres de coupe pour la reproduction d'une nouvelle pièce. L'avantage pratique qui en résulte est de faciliter la copie de pièces usinées. Il est d'abord nécessaire d'identifier le choix des paramètres de coupe et de l'outil de coupe approprié sur une fraiseuse CNC.

Il est conseillé d'utiliser plusieurs modalités (dans ce cas, numériques et images) pour fournir des informations supplémentaires sur le processus d'usinage considéré afin d'obtenir de meilleures performances que les modèles unimodaux. En appliquant la fusion multimodale tardive à nos modèles de réseaux de neurones, la précision a augmenté de manière significative par rapport à celle trouvée dans le modèle exploitant une seule modalité. La fusion multimodale tardive s'est avérée particulièrement pertinente lors de l'utilisation de données numériques et d'images de la pièce à usiner pour la prédiction des conditions de coupe et la sélection des outils d'usinage.

Nous avons également adapté la structure du modèle à nos données d'entrée, et, à nos données de sortie souhaitées. Cela permet également de maintenir et de mettre à jour les modèles développés lorsque des ajustements appropriés sont justifiés pour améliorer le processus d'apprentissage. L'estimation des hyperparamètres est essentielle pour obtenir une meilleure qualité de modèle, mais elle est très gourmande en ressources. Il peut être utile d'utiliser la méthode GridSearchCV, qui effectue une recherche approfondie des valeurs des paramètres spécifiés pour un estimateur. Néanmoins, cela nécessite une énorme puissance de calcul pour accéder à plusieurs optimiseurs et choisir le meilleur. Il est nécessaire de trouver des moyens appropriés pour identifier et mettre en œuvre des mesures d'efficacité afin d'optimiser les paramètres le plus rapidement possible. Cela peut être réalisé en essayant moins d'options de paramètres dans chaque cycle d'apprentissage ou en exploitant RandomizedSearchCV (au lieu de GridSearchCV), qui nous permet d'échantillonner un nombre fixe de paramètres à partir des distributions spécifiées.

3.5. Conclusion et perspectives

Dans ce chapitre, un intérêt important de la méthodologie proposée est la possibilité de réutiliser les connaissances des modèles d'apprentissage profond. En termes de multimodalité, l'exploitation est faite de données multimodales dont la combinaison intelligente au sein de plusieurs modèles favorise la généralisation de l'apprentissage de nos données sur la base d'apprentissage et sur la base de validation pour la prédiction du choix des paramètres de coupe. Nous utilisons les connaissances du domaine de l'usinage automatique pour concevoir un modèle de réseau de neurones à deux branches basées sur la fusion multimodale pour prédire le choix des paramètres de coupe et de l'outil de coupe approprié pour l'usinage. L'outil de coupe et les paramètres de coupe sont des éléments essentiels qui influencent la qualité des pièces usinées. Cette qualité joue un rôle crucial dans les critères d'acceptation des composants de haute précision qui ont été usinés.

La sélection adéquate de l'outil de coupe et des paramètres de coupe appropriés peut réduire considérablement le temps de production du processus d'usinage et, par conséquent, la consommation d'énergie. Dans les cas où la qualité des données est limitée, la multimodalité permet au système de fonctionner sans l'une des modalités. On observe également que les

performances du modèle de fusion multimodale sont meilleures que celles du modèle unimodal pour la prédiction des paramètres de coupe.

Sur le plan théorique, la contribution se concentre sur le déploiement d'une procédure efficace pour l'apprentissage automatique multimodal. En particulier, un principe d'alignement a été mis en œuvre pour établir des correspondances entre les images et les données numériques. Cet alignement a permis d'améliorer la précision des résultats obtenus, qui se sont considérablement améliorés. Au niveau applicatif, la contribution concerne le développement d'une approche d'intelligence artificielle pour la prédiction de paramètres adaptés à un type d'usinage. Dans ce cas, la prédiction proposée vise à aider aux choix guidant la configuration appropriée des outils et des paramètres de section. Nous prévoyons d'effectuer plusieurs séries d'expériences en ajoutant d'autres types d'outils de coupe, tels que des outils de perçage et de tournage, afin d'augmenter la taille de la base de données. Nous pourrions alors utiliser des capteurs sonores pour obtenir des signaux de vibration afin de réaliser une analyse vibratoire qui nous permettra de soulever et de résoudre plusieurs problèmes tels que l'usure des outils et la détection des défauts d'usinage. En outre, nous envisageons d'appliquer un autre des défis de la multimodalité, le co-apprentissage, qui permet de gérer l'absence d'une des modalités dans la phase de test. Dans le co-apprentissage, il existe plusieurs cas d'utilisation des modalités, comme dans le cas où toutes les sources de données sont utilisées pour effectuer l'apprentissage et permettent l'absence d'une des modalités pour effectuer le test. Une ou plusieurs modalités peuvent être absentes lors de l'entraînement mais se retrouver dans la phase de test. Le co-apprentissage est le transfert de connaissances entre les modalités, leur permettant d'être complémentaires pour mettre en œuvre un système multimodal qui fonctionne sans une ou plusieurs modalités.

Dans ce chapitre nous avons rencontré quelques difficultés pour la mise en place de la méthode de prédiction du choix des paramètres de condition d'usinage. L'efficacité des modèles d'apprentissage profond multimodal dépend d'une grande quantité de données. La collecte de données a été très difficile, et nous n'avons pas pu réaliser suffisamment d'expériences pour obtenir la quantité nécessaire. Nous avons dû avoir recours à un algorithme d'augmentations de données pour avoir ces résultats. Ceci a nécessité des circonstances dérogatoires pour l'usage d'une machine d'usinage (fraiseuse) avec deux ingénieurs experts à notre disposition, ce qui n'est pas toujours aisé. Étant donné ces difficultés, nous nous sommes orientés vers un problème d'analyse du signal de vibration d'usinage pour détecter le broutement et dont les données sont issues des partenaires industriels.

Le prochain chapitre est une étude sur l'apprentissage profond pour la détection du broutement basé sur les modalités signal et image. Plus particulièrement, nous proposons une approche combinant des connaissances mécaniques et informatiques pour l'optimisation la chaîne du processus d'apprentissage. Tout d'abord, les connaissances mécaniques permettent la pertinente identification des différentes phases des signaux afin d'y effectuer des traitements adéquats pour la sélection des parties les plus déterminantes. Il s'agit de transformer le signal en image par le biais d'une transformée de Fourier rapide (FFT). Cette transformation consiste à un des challenges multimodal (la translation multimodale) qui permet d'obtenir une modalité (signal) à partir d'une autre modalité (image). Ensuite, les connaissances informatiques servent à l'apprentissage profond basé sur l'apprentissage par transfert qui est appliqué sur ces images pour détecter automatiquement le phénomène de broutement dans le signal vibratoire.

Chapitre 4 Apprentissage profond pour la détection du broutement de vibration d'usinage

4.1. Introduction

Le broutement, décrit par plusieurs auteurs historiques [183, 189], correspond à l'interaction entre une pièce et un outil de coupe dans un processus d'usinage. Le broutement se traduit par des marques irrégulières (défaut) sur une surface usinée. Il représente l'une des difficultés les plus gênantes dans les processus d'usinage typiques, tels que le tournage, le fraisage et le perçage, mais aussi la rectification.

Les mesures vibratoires sont très largement appliquées en surveillance des machines, car elles permettent une détection rapide et précise des dysfonctionnements de production [125]. L'analyse vibratoire des signaux peut fournir des indicateurs d'état des phénomènes vibratoires existants, permettre de garantir la qualité des pièces usinées et faciliter la prise de décision pour remédier aux problèmes. Il existe des techniques d'analyse qui permettent de détecter le plus tôt possible les signaux faibles avec l'établissement de véritables courbes de tendance [200]. Un spectre de vibrations est une donnée dans laquelle il est possible de lire des défauts extrêmement ténus, comme l'écaillage d'une bille dans un roulement. L'analyse vibratoire des signaux est l'un des moyens les plus populaires pour surveiller l'état des machines tournantes en fonctionnement [135].

L'identification, la stabilité et la détection du broutement sont des domaines de recherche en croissance depuis des décennies. Des recherches récentes sur la détection du broutement d'usinage se concentrent sur les applications avancées de l'apprentissage automatique ou de l'apprentissage profond en raison de leur capacité à résoudre des problèmes très complexes et non linéaires liés aux ensembles de données de grandes dimensions [68, 96]. L'intelligence artificielle appliquée à l'analyse des vibrations est utile tant pour les experts que pour les non-spécialistes. En ce qui concerne les premiers, elle évite de perdre du temps à analyser les signaux de machines en bon état ou présentant des défauts évidents. Les experts pourront surveiller un parc plus important et consacrer plus de temps aux cas complexes afin de réduire le risque d'erreur dans l'analyse. Pour les non-experts, l'intelligence artificielle leur permet de proposer un premier diagnostic relativement fiable, leur donnant une nouvelle autonomie dans leur prise de décision et optimisant ainsi l'appel aux experts.

Au fil du temps, des recherches se sont concentrées sur l'IA appliquée au domaine industriel, et de nombreuses études montrent [14, 97, 195] que ces techniques sont parmi les principaux catalyseurs pour faire évoluer un système de fabrication traditionnel vers l'industrie 4.0. Avec le développement numérique de l'industrie manufacturière, les processus de fabrication se sont diversifiés, automatisés et personnalisés. Les exigences multiples pour la fabrication des pièces, ont considérablement augmenté. Les anomalies dans le processus d'usinage doivent être systématiquement détectées, qu'elles soient facilement observables, comme dans les opérations de finition, ou non, comme dans les opérations d'ébauche, qui ne sont généralement pas soumises à une observation systématique. La productivité de toute opération de fraisage repose sur la capacité à enlever la matière le plus rapidement possible [17]. Cependant, le taux d'enlèvement de matière est très limité en raison du broutement et de tous les effets indésirables qui accompagnent ce phénomène. Les chercheurs ont élaboré plusieurs méthodologies pour le contrôler [222].

La plupart des méthodes existantes de détection du broutement se basent sur les indicateurs de broutement qui extraient les caractéristiques du signal, mais les seuils des indicateurs de broutement ainsi conçu doivent généralement être identifiés manuellement pour

chaque condition de coupe considérée. Ce problème de détection automatique du broutement basé sur les données peut être considéré comme un cas de classification dans l'apprentissage automatique [54].

Dans ce chapitre nous proposons une méthode plus performante qui intègre les compétences des experts en broutement pour extraire les caractéristiques physiques, sur la base d'une transformation du domaine temporel au domaine fréquentiel par le biais de la transformée de Fourier rapide ou Fast Fourier Transform (FFT). La plupart des méthodes, probablement la totalité, s'appuient sans toujours l'expliquer sur l'analyse de l'amplitude du signal vibratoire et sur la comparaison des fréquences mesurées par rapport à la fréquence de rotation broche. Dans des essais faits en laboratoire, la corrélation entre le phénomène de broutement, l'amplitude vibratoire et les fréquences qui apparaissent est souvent triviale, ce qui pose des questions sur l'intérêt des méthodes de détection très sophistiquées proposées. En pratique, en situation industrielle, ces informations d'amplitude et de fréquence ne sont pas toujours très fiables, du fait de la position très variable des capteurs, et du fait que des opérations de maintenance secondaires peuvent créer un décalage entre la vitesse de rotation réelle et supposée. Ainsi, pour déterminer clairement si notre approche aurait un intérêt réel en situation industrielle nous avons choisi d'effacer dans le signal les informations de vitesse de rotation de la broche et de l'amplitude moyenne du signal. Ainsi, après la FFT nous appliquons une transformation directement sur l'image de nos FFT, pour supprimer les informations de fréquence et d'amplitude, puis pour extraire les caractéristiques nous appliquons l'apprentissage par transfert via des réseaux de neurones profonds pré-entraînés. Cette méthode extrait les caractéristiques des données d'images du signal brut pour effectuer la détection des phases d'usinage liées aux phénomènes de vibration durant le processus d'usinage notamment le broutement, l'usinage sans broutement et la rotation sans usinage.

Le reste de ce chapitre est organisé comme suit. La section 4.2 fournit un état de l'art sur l'application de l'apprentissage profond dans la surveillance et la détection de défaut dans les processus d'usinages. La section 4.3 traite la méthodologie proposée pour la détection du broutement en usinage. La section 4.4 présente les résultats de la détection du broutement de l'approche proposée. La discussion est présentée à la section 4.5, et la conclusion dans la section 4.6.

4.2. État de l'art

Ce point a déjà été évoqué dans le chapitre précédent, nous avons identifié qu'il existe clairement deux groupes d'auteurs qui ont étudié le phénomène de broutement. Le premier groupe d'auteurs (J. Tlustý, Y. Altintas, J. Munoa, etc.), publiant historiquement sur l'usinage et en particulier le broutement d'usinage et des auteurs tels que (HO. Unver, B. Sener et etc.) publiant plutôt sur les capteurs qui ont développé de nouvelles techniques de détection du broutement.

Il existe plusieurs travaux dans la littérature qui cherchent à détecter le broutement avec les techniques de traitement de signal (FFF, STFT, WT, EMD, HHT, etc.) et qui ont montré une certaine efficacité pour la tâche [218]. Les auteurs Huda *et al.* [80] expérimentent un processus de tournage en appliquant une usure artificielle à l'outil de coupe. Ils collectent deux types de signal (normal et broutement) avec un microphone, et ces signaux sont ensuite analysés par la FFT et WT pour identifier le broutement grâce aux pics d'amplitude significatifs dans le cas de broutement. Ding *et al.* [50] transforment la force de coupe en domaine fréquentiel en appliquant la FFT pour détecter le broutement en comparant le spectre de puissance par un seuil de pic prédéfini. Chen *et al.* [42] proposent une approche d'extraction des caractéristiques du broutement en analysant les images des bandes de fréquences dominantes à travers les spectrogrammes issues de la STFT. Afazov *et al.* [3] détectent le broutement avec la FFT sur

les forces de coupe mesurées. La transformée en ondelettes (WT) a aussi été appliquée sur la force de coupe mesurée par un dynamomètre au niveau de l'outil pour détecter le broutement [229]. D'autres auteurs appliquent en complément les méthodes analytiques et numériques comme le diagramme de lobes de stabilité pour mieux identifier le broutement [9, 170].

D'une manière générale ces techniques d'analyse rencontrent des difficultés à détecter le broutement à un stade précoce c'est-à-dire avant que l'amplitude des vibrations ne soit déjà importante, et qu'il soit trop tard pour pouvoir préserver la qualité de la pièce.

Le broutement étant décrit par des équations très non linéaires, notamment à cause d'un terme de retard dans des équations différentielles de type masse-ressort, qui ne sont pas faciles à maîtriser du point de vue mathématique ou numérique. Les outils de traitement de signal ou les méthodes analytiques reposent en général sur l'identification d'un seuil qui caractérise l'apparition du broutement. Cette tâche généralement effectuée par un expert peut être facilitée par les méthodes d'apprentissage automatique. Les méthodes d'apprentissage automatique (SVM [78, 225], ANN) sont couramment appliquées dans l'analyse du signal vibratoire. Un système intelligent de surveillance multi-capteurs avec trois unités pour les processus de tournage est proposé par Zhang *et al.* [233]. Les trois unités sont mises en œuvre en intégrant deux capteurs à faible coût, un compteur d'énergie et un accéléromètre. Ce dispositif de surveillance intégré offre une grande précision de prédiction pour les trois conditions du processus, une applicabilité généralisée sur une large gamme de conditions de fonctionnement et une robustesse satisfaisante face aux incertitudes du processus et de la mesure. Pour la détection du broutement, ils atteignent une précision de 96,88%, même lorsqu'ils changent la configuration. Chen *et al.* [37] et Zheng *et al.* [238] proposent une méthode de détection du broutement en fraisage en bout, basée sur la transformation de paquets d'ondelettes (WPT) et le SVM comme extracteur de caractéristique. Zhu *et al.* [241] décomposent le signal des forces de coupe brutes par la fonction EEMD dans le but d'obtenir un ensemble de Fonctions de mode intrinsèque (IFM). Les IFM contenant des situations de broutement ont été retenues et subissent un processus de réduction de dimension par la méthode d'analyse en composantes principales. Le processus de détection est ensuite effectué par un SVM non linéaire. Shrivastava *et al.* [165] proposent une autre méthode d'apprentissage automatique, par réseau de neurones artificiels pour prédire le broutement d'outil dans un processus de tournage. Khasawneh *et al.* [87] combinent l'apprentissage automatique supervisé avec l'analyse des données topologiques (TDA) pour produire un descripteur de processus capable de détecter le broutement.

Ces méthodes sont développées en trois étapes : la collecte de données, l'extraction de caractéristiques et l'entraînement du modèle. La phase de décision ne nécessite ensuite pas d'intervention humaine, mais il y a certaines limites, comme la sensibilité aux erreurs de mesure, l'étiquetage par un expert des données d'apprentissage. Ces limites peuvent être corrigées par des techniques d'apprentissage non supervisé comme la méthode K-means [52] qui ne nécessite pas d'étiquetage, ou par les méthodes d'apprentissage profond.

Pour la conception des méthodes capables de déceler les évolutions anormales sur les machines, l'apprentissage profond permet de développer des techniques de diagnostic pour le suivi du signal vibratoire. L'objectif de l'apprentissage profond est d'élaborer des algorithmes permettant de modéliser avec un niveau élevé d'abstraction des données via des architectures intercalant des cascades d'opérations linéaires et non linéaires. Il s'agit donc d'effectuer des tâches d'analyse pour un apprentissage supervisé ou non supervisé. Cet apprentissage est notamment relatif à la classification (sorties discrètes) ou à la régression (sorties continues) afin de prédire les réponses à des questions posées sur des ensembles de données de grande taille [96]. L'apprentissage profond est devenu une technique populaire pour l'extraction d'informations (caractéristiques) dans les données, en raison de sa capacité à traiter les données

brutes et à reconnaître automatiquement des caractéristiques à travers plusieurs niveaux d'abstraction [66].

L'intégration de l'apprentissage profond dans le diagnostic intelligent des défauts des machines tournantes a obtenu un grand succès et a profité aux applications industrielles [234]. Par rapport à l'apprentissage automatique classique, l'apprentissage profond extrait automatiquement les caractéristiques à un niveau supérieur et fusionne l'extraction et la classification des caractéristiques en une seule structure pour ne pas avoir besoin d'un grand nombre d'essais et d'erreurs, ce qui permet d'obtenir des performances fiables [210] [82]. L'anticipation des problèmes dans le contexte industriel est primordiale pour l'identification des signaux faibles et la réduction des temps d'intervention. Les objectifs poursuivis sont multiples : (i) la réduction du nombre d'arrêts sur casse, (ii) la fiabilisation de l'outil de production, (iii) l'augmentation du taux de disponibilité, (iv) l'amélioration de la gestion du stock de pièces détachées. En effet, à partir des vibrations régulièrement recueillies sur une machine tournante, l'analyse vibratoire consiste à détecter, voire anticiper, d'éventuels dysfonctionnements [67].

La détection de ces dysfonctionnements va se faire très souvent via le traitement d'image qui bénéficie d'un ensemble de méthodes de détection et d'analyse pour permettre l'automatisation d'une tâche spécifique. Cette technologie peut concerner la classification pour catégoriser les objets, ou la détection pour localiser une anomalie ou un défaut de fabrication dans une image. La segmentation représentant aussi une tâche de détection mais au pixel près pour situer un élément sur une image. L'analyse des images offre ainsi des moyens puissants pour visualiser et reconnaître les défauts identifiés sur les systèmes considérés.

En général, selon Hoang *et al.* [77] la détection intelligente des défauts est composée de trois étapes : la collecte de données, l'extraction des caractéristiques et la classification des défauts. Pour la collecte de données, les capteurs de vibrations sont largement utilisés en raison de leur disponibilité et de leurs sensibilités élevées. Ce processus dépend des données qui reflètent la problématique posée. Il existe plusieurs outils pour transformer les signaux obtenus à partir de ces capteurs comme la transformée de Fourier [103][25], les ondelettes de Mortelet [24] et la transformation de paquets d'ondelettes de Daubechies, Mallat et Meyer [217]. Le processus d'extraction des caractéristiques est élément essentiel pour l'obtention d'une bonne précision dans la détection intelligente. Ce processus est divisé en deux types, les méthodes basées sur la physique et celles basées sur les données. Les méthodes basées sur la physique extraient les caractéristiques à partir du domaine temporel, du domaine fréquentiel et du domaine temps-fréquence. Les méthodes basées sur les données utilisent les techniques d'apprentissage automatique ou profond pour extraire les caractéristiques les plus informatives sur les données.

À travers la fusion de l'analyse temps-fréquence et des réseaux neuronaux profonds, Liao *et al.* [102] proposent une méthode de surveillance du processus de fabrication. Les signaux d'émission acoustique ont été acquis pendant des opérations de tournage avec différentes vitesses de broche, vitesses d'avance et profondeurs de coupe. On constate dans la revue de littérature, que les auteurs s'attaquent aussi bien aux problèmes de surveillance de l'état du process et de l'état des machines en temps réel, la détection et le diagnostic de défauts de roulement des machines tournantes, la détection du broutement en prenant en compte certains aspects comme le changement de vitesse de rotation, la vitesse d'avance et très généralement l'amplitude moyenne de la fréquence.

Un modèle hybride qui regroupe un réseau de neurones profond pré-entraîné Alexnet [91] et un modèle basé sur la théorie des vibrations auto-excités, sur la base de transformée de

Fourier à court terme STFT pour détecter le broutement [194]. Sener *et al.* [154] appliquent la transformée en ondelette continue pour le prétraitement du signal en obtenant des images riches en information sur le broutement. Ces images sont ensuite exploitées comme données d'entraînement d'un réseau de neurones profond. Tran *et al.* [191] présentent une approche de détection de broutement en temps réel. Cette approche est basée sur le scalogramme de la transformée en ondelette continue et le réseau de neurones convolutifs pour prédire les états (stables, transitoires et instables). Un modèle d'apprentissage par transfert composé des solutions analytiques et un réseau de neurones à convolution (CNN) est proposé par Unver *et al.* [194] pour détecter le broutement. Shi *et al.* [162] utilisent une variante de LSTM pour détecter le broutement dans les processus de fraisage à grande vitesse. La détection de broutement en ligne basée sur le signal de courant d'une machine CNC est présentée par Vashisht *et al.* [197]. Un LSTM est alors entraîné pour détecter le broutement sur la base de la séquence simulée de courants de contrôle.

Dans la littérature, de nombreuses techniques d'apprentissage profond ont obtenu des résultats satisfaisants. Ces études utilisent en général des données issues des conditions d'usinage éloignées des applications industrielles, mais certains articles utilisent des conditions de coupe réalistes. L'amplitude des vibrations est fortement liée au broutement dans les données publiées et il est donc difficile de déterminer si toutes ces techniques sophistiquées seraient meilleures qu'une simple surveillance du niveau RMS.

Dans ce chapitre nous traitons différemment le problème en développant une méthode d'apprentissage automatique qui utilise l'analyse vibratoire, avec un traitement spécifique des images des FFT pour éliminer les biais possibles sur l'amplitude et les fréquences connues, et l'apprentissage profond pour la détection du broutement en usinage, avec une phase supplémentaire de vérification sur des signaux dits ambigus. La méthode est composée de deux types de transformation à savoir une transformation sur la physique (du domaine temporel au domaine fréquentiel) et une transformation sur les données en exploitant plusieurs réseaux pré-entraînés VGG16 [167], inceptionV3 [178] et ResNet50 [74]. Ce qui distingue le modèle proposé des méthodes de surveillance classiques qui se basent en général sur l'amplitude des signaux et l'analyse des pics de fréquences tout en connaissant très précisément les vitesses de rotation.

4.3. Méthode de détection du broutement

La présente section expose les détails des étapes de la méthode à partir de l'acquisition de données, de la construction des bases d'entraînement, de validation et de test du modèle d'apprentissage profond proposé, ainsi que l'extraction des caractéristiques des données et la construction du modèle de détection de broutement en usinage (voir Figure 4.1).




Figure 4.1. Méthodologie proposée pour la détection de broutement en usinage.

4.3.1. Acquisition de données

En analyse vibratoire, le signal temporel est un élément clé, car il représente l'information réelle transmise par la machine-outil ou ses capteurs à partir des contraintes qui sont générées par le processus de fabrication mécanique de tournage, fraisage, perçage, etc. Comme première

étape de toute mesure, les analyseurs de vibrations enregistrent ce signal temporel, puis le traitent pour en extraire différentes caractéristiques. En général, la taille du signal temporel considéré pour l'analyse dépend fondamentalement de la fréquence d'échantillonnage et de la période considérée. Un mauvais réglage de ces paramètres peut facilement conduire à un signal qui ne révèle aucune information d'anomalie, malgré l'existence de défauts. Dans cette étude de cas, le signal temporel a été enregistré à l'aide d'un accéléromètre Kistler de type 8776A50M6, aimanté sur le porte-pièce, connecté à un conditionneur de signal Roga Plug-n-Daq, et enregistré à 22kHz à l'aide du logiciel Audacity. Les mesures ont été effectuées lors d'un processus d'usinage d'Alstom Transport pour le fraisage de parois de voitures TGV, illustré par la Figure 4.2.



Figure 4.2. Processus de fraisage d'une paroi de voiture de train TGV (longueur ≈ 20 mètres).

Après analyse du signal avec l'aide d'un expert en analyse vibratoire d'usinage, plusieurs phases d'usinage ont été identifiées : usinage sans broutement, rotation sans usinage, et usinage avec broutement. L'identification précise a été faite par l'expert qui a étiqueté ces différentes phases du signal dans un fichier tableur contenant la période et l'étiquette de chaque phase. Nous avons ensuite exporté le signal au format .wav en renormalisant le signal pour éviter la saturation du fichier .wav tout en gardant une précision maximale. Un exemple du signal temporel utilisé pour la collecte des données est visualisé par la Figure 4.3, ce qui montre de fortes variations d'amplitudes qui peuvent être tout aussi bien dues à l'apparition du broutement, ou à la proximité de l'usinage à cet instant par rapport au capteur, tout au long des nombreuses heures d'usinage.




Figure 4.3. Exemple de signal temporel (temps en secondes).

4.3.2. Préparation des données

Le signal temporel dans le fichier .wav est traité avec le langage Python en exploitant la bibliothèque Librosa pour traiter le signal de 16 minutes 58 secondes. Le signal est transformé du domaine temporel au domaine fréquentiel car l'analyse dans le domaine fréquentiel permet de facilement isoler et identifier certaines composantes fréquentielles ciblées, et présente donc certains avantages par rapport à l'analyse dans le domaine temporel. L'une des transformations les plus courantes de l'analyse dans le domaine des fréquences est la transformée de Fourier rapide (FFT), qui permet d'obtenir efficacement des spectres à bande étroite. Dans le cas de la détection du broutement d'usinage, plusieurs préparations de signaux FFT ont été effectuées dans les intervalles étiquetés, toutes les 0,1 et 0,2 secondes pour enrichir les données d'entraînement et augmenter la quantité de données étiquetées. Ensuite, des images des FFT ont été générées. Pour la réduction de la taille de l'image, la fréquence est échantillonnée sur 1024 lignes dans la gamme de valeurs entre 0-2500Hz, la valeur en décibel est comprise entre la valeur minimale de -20 dB et la valeur maximale de -10 dB. Cette réduction nous permet de ne conserver que la partie supérieure de l'image de la FFT, qui est la plus informative, c'est-à-dire les pointes dominantes. Les images sont ensuite triées selon leurs étiquettes respectives (rotation à vide : 1582 images, usinage sans broutement : 5514 images et usinage avec broutement : 3089 images) pour construire les bases de données d'entraînement (représentant 70% des images soit 7126 images) et de validation (représentant 30% des images soit 3054 images).

Pour la base de données de test, un autre type de signal contenant une partie bruyante, appelée aussi ambiguë, car plus difficile à analyser pour un expert humain, et une partie non bruyante/non ambiguë a été utilisée. Ces signaux ne sont pas bruyants au sens d'un bruit aléatoire, car il s'agit de signaux présentant des caractéristiques intermédiaires, qui obligent l'expert à effectuer des analyses beaucoup plus approfondies pour identifier le phénomène dominant. La proposition de tels moyens pour les reconnaître automatiquement pourrait faire gagner beaucoup de temps à l'expert. Ces données seront utilisées pour tester la capacité du modèle proposé à classifier des données qu'il n'a jamais vues, et qui auraient été difficiles à étiqueter. Un aperçu de cette transformation est présenté dans la Figure 4.4.




Figure 4.4. La transformation du domaine temporel au domaine fréquentiel.

4.3.3. Extraction des caractéristiques

Dans cette partie, nous nous intéressons à une technique couramment utilisée dans le domaine de l'apprentissage profond qui est l'apprentissage par transfert. Cette technique applique les connaissances déjà apprises par d'autres modèles pour résoudre des problèmes similaires. Il existe plusieurs modèles d'architectures pouvant être utilisés dans une démarche d'apprentissage par transfert. Dans cette étude, nous engageons deux modèles d'architectures qui sont le VGG16 [167], inceptionV3 [178] et ResNet50 [74] pour l'extraction des caractéristiques des ensembles de données image. L'apprentissage par transfert utilise des modèles existants qui ont été minutieusement sélectionnés pour leur efficacité et conçus par des experts pour obtenir de hautes performances sur dans la tâche cible considérée à l'instar de la classification d'images. Étant donné que les réseaux de neurones profonds demandent une grande quantité de données, on a recours à l'apprentissage par transfert pour apprendre à cartographier à partir d'une entrée caractéristiques essentielles utiles à une résolution de problème à afficher sur la sortie désirée. L'apprentissage par transfert est un moyen rapide et efficace pour faire face au manque qualitatif ou quantitatif de données. Dans cette étude nous adaptons les modèles pré-entraînés à notre ensemble de données pour la détection de broutement en usinage.

Dans l'apprentissage profond, un réseau de neurone convolutif est composée de deux grandes parties, une partie inférieure pour extraire les caractéristiques utiles à la reconnaissance de l'image et une partie supérieure pour la tâche de classification. Nous ne prenons que la partie inférieure pour l'extraction des caractéristiques et nous adaptons la partie classification à notre cas d'étude, vu que le modèle VGG16 par exemple comporte 1000 classes.

4.3.4. Construction du modèle de classification des différentes phases d'usinage

Pour concevoir le modèle de classification, le modèle est d'abord initialisé par la fonction Sequential en langage python sous keras. Ensuite, une couche d'aplatissement est ajoutée pour aplanir les données et d'autres couches cachées entièrement connectées sont ajoutées. La technique du « dropout » (couche d'exclusion), qui consiste à abandonner des unités (cachées et visibles) dans un réseau de neurones, est utilisée pour réduire l'« overfitting » (le surapprentissage) pendant le processus d'apprentissage. Comme il s'agit d'une classification catégorielle étiquetée, la dernière fonction d'activation est toujours la fonction Softmax. La

fonction d'entropie croisée catégorielle est choisie comme fonction de perte avec l'ajout de trois neurones à la fin pour les trois classes (Figure 4.5). Après avoir créé et compilé le modèle, l'apprentissage des données d'entraînement et de validation est effectué.

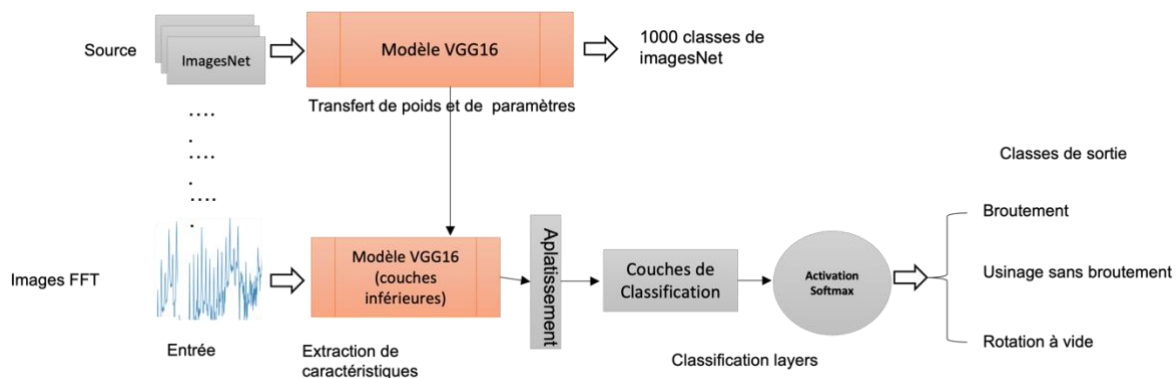


Figure 4.5. Le modèle d'apprentissage par transfert.

4.4. Résultat

Cette partie consiste à présenter les résultats obtenus par l'approche proposée. Les figures (Figure 4.6, Figure 4.7 et Figure 4.8) montrent les courbes de précision et de perte de notre jeu de données basé sur l'extraction de caractéristiques par VGG16 et ResNet50. Puisque cette étude utilise des techniques d'apprentissage par transfert pour extraire les caractéristiques du jeu de données. Le modèle est entraîné sur 30 époques. La Figure 4.6 montre un cas de bon ajustement avec la diminution de la perte d'entraînement et de validation sur l'ensemble de validation jusqu'à un point de stabilité avec la déviation minimale entre la perte d'entraînement et de validation. Contrairement à la Figure 4.7 dont les caractéristiques sont extraites par le modèle ResNet50 qui présente des points d'inflexion dans les courbes de perte et de justesse. Malgré l'existence de dents de scie, ce modèle parvient à avoir un résultat plutôt satisfaisant.




Figure 4.6. Courbes de la précision et la perte de notre ensemble de données avec VGG16.




Figure 4.7. Courbes de justesse et de perte de notre ensemble de données avec resnet50.




Figure 4.8. Courbes de justesse et de perte de notre ensemble de données avec inceptionV3.

Puis le test du modèle est réalisé avec un jeu de données de test contenant des signaux similaires à ceux utilisés en entraînement et d'autres, plus bruyants ou ambigus (Figure 4.9), pour tester la fiabilité et la capacité de généralisation de notre modèle. Sur cette base, nous parvenons à trouver une précision de 98,82% avec le VGG16. Pour visualiser ces résultats, nous utilisons des techniques telles que la matrice de confusion, et le score F1 pour montrer à quel point le modèle que nous avons créé peut faire des prédictions intéressantes sur des données inconnues et non triviales.




Figure 4.9. Exemple de FFT des signaux bruités et non bruités.

Pour obtenir le tableau des mesures de classification, nous avons dû convertir nos données de test dans un format différent, un tableau qui rassemble nos données de test en un seul ensemble et les identifie par plusieurs indices. Dans le Tableau 4.1, les facteurs les plus influents et les plus importants sont la précision et le score F1. Plus ce score est élevé, plus le modèle utilisé est performant.

Tableau 4.1. Rapport de classification

	Precision %	Recall %	F1-score %	support
Usinage avec broutement	100	100	100	1544
Rotation à vide	93	100	96	733
Usinage sans broutement	100	98	99	2814

La précision est le rapport entre le nombre d'individus correctement attribués à une classe et le nombre d'individus total attribués à ladite classe. Le recall définit le rapport entre le nombre d'individus correctement attribués à une classe et le nombre d'individus appartenant à la classe. Le F1-score combine la précision et le recall du modèle, il est défini comme la moyenne harmonique de la précision et du recall du modèle.

Pour montrer la capacité d'un modèle d'apprentissage profond à prédire, on compare son résultat à la réalité en exploitant la matrice de confusion. Sur les Tableau 4.2 et Tableau 4.3 on peut visualiser le calcul de la matrice de confusion sur notre ensemble de données test.

Tableau 4.2. Matrice de confusion de données issues des FFT non bruitées (classe 1 : Usinage avec broutement, classe 2 : rotation à vide et, classe 3 : Usinage sans broutement)

		Prédit			Total
		Classe 1	Classe 2	Classe 3	
Réal	Classe 1	1539	0	5	1544
	Classe 2	0	733	0	733
	Classe 3	0	55	2759	2814

Tableau 4.3. Matrice de confusion de données issues des FFT bruitées (classe 1 : Usinage avec broutement, classe 2 : rotation à vide et, classe 3 : Usinage sans broutement)

		Prédit			Total
		Classe 1	Classe 2	Classe 3	
Réal	Classe 1	90	14	0	104
	Classe 2	0	0		9
	Classe 3	48	137	31	204

Sur 1544 échantillons de données de test non bruitées de la classe 1 du Tableau 4.2, seules 5 images ont été mal classées dans la classe d'usinage sans broutement, toutes les images de la classe de rotation sans usinage sont des vrais positifs et sur 2814 images de la classe d'usinage sans broutement 55 sont classées dans la classe de rotation sans usinage et les 2759 restantes sont bien classées. Après l'évaluation des données ambiguës, le modèle obtient une précision de prédiction de 73,71%. On peut voir dans le Tableau 4.3 que la plus grande partie de cette divergence se trouve dans la classe 3, dont 48 éléments sont considérés comme de l'usinage avec du broutement.

Sur chaque colonne de la matrice on trouve une classe prédite par notre modèle et les représentations des classes réelles. On trouve généralement quatre catégories dans la matrice :

True Positive (TP) : signifie que la prédiction et la valeur réelle sont positives.

True Negative (TN) : la prédiction et la valeur réelle sont toutes négatives.

False Positive (FP) : la prédiction est positive alors que la valeur réelle est négative.

False Negative (FN) : la prédiction est négative alors que la valeur réelle est négative.

Pour évaluer la densité de sortie de nos trois classes nous traçons une courbe (Figure 4.10) appelée ROC (Receiver Operating Characteristic) qui calcule le rapport entre le taux de vrais positifs (TPR) et le taux de faux positifs (FPR).




Figure 4.10. Courbe ROC de trois classificateurs sur données issues des FFT bruitées et non bruitées.

Ces courbes servent à comparer nos différents classificateurs. Plus une courbe a des valeurs élevées qui se rapprochent de 1, plus l'aire sous la courbe est grande et moins le classificateur commet des erreurs. D'une manière simplifiée, le classificateur retourne une réponse qui est soit mauvaise ou soit bonne. L'aire sous la courbe ROC interprète cette probabilité. Si la valeur de l'aire d'un classificateur est inférieure à 0,5 (50%), cela indique que le marqueur est non-informatif. Une augmentation de l'aire indique une amélioration des capacités discriminatoires, avec un maximum de 1,0 (100%). Dans notre cas, avec les données non bruitées, toutes les valeurs de nos classificateurs se rapprochent de 100% et même dans le cas des données bruitées seule la valeur de l'un d'entre eux est inférieure à 80%, c'est ce qui corrobore la capacité de généralisation du modèle proposé. De plus, il est à noter que l'étiquetage réalisé par l'expert sur ces données ambiguës a eu une fiabilité du même ordre, auto-estimée par lui à $\approx 90\%$, ce qui montre encore plus la qualité de l'analyse proposée par notre modèle.

4.5. Discussions

L'apprentissage profond nourrit un algorithme à l'aide de données pour qu'il apprenne par lui-même à effectuer une tâche donnée. Dans les problèmes de classification, cet apprentissage prédit des résultats que l'on doit comparer à la réalité pour mesurer sa performance. On utilise généralement la matrice de confusion, appelée aussi tableau de contingence. Elle mettra non seulement en valeur les prédictions correctes et incorrectes, mais nous donnera surtout un indice sur le type d'erreurs commises. Comme nous pouvons le voir dans nos données normalisées, notre modèle est assez bon pour classer le type d'usage sans prendre en compte la notion de la vitesse de rotation et les valeurs des fréquences, ce qui est remarquable et le distingue de la bibliographie. Après l'apprentissage et la validation des données avec notre modèle, de très bons résultats sont obtenus avec une précision de 99,71% pour le vgg16, 99,67% pour resnet50 et 99,64 pour inceptionV3.

Le modèle a juste besoin de l'image de la FFT en entrée, ce qui est très facile à générer, puis il se débrouille tout seul pour classer ces images dans leurs classes respectives. Nous avons testé le modèle pour voir comment il arrive à généraliser la prédiction avec un signal non ambigu qui contient l'information la plus pure pour détecter les types d'usage et un autre signal ambigu contenant des cas un peu moins purs. Les résultats de notre test sur le signal ambigu nous montrent que l'on peut faire de l'apprentissage sur des données simples et que la reconnaissance s'en sort naturellement sur des données moins simples. Ces signaux ambigus mettent généralement en difficulté l'analyse humaine, ceci d'autant plus que ces signaux sont brefs, donc avec peu de données disponibles pour pouvoir en plus réaliser un apprentissage sur de tels signaux. Cette capacité de reconnaissance est due à la puissance du transfert learning pour l'extraction des caractéristiques et du fait que nous n'avons pris en compte sur les images

FFT générées que les pics significatifs. En comparaison avec les approches proposées dans la littérature pour la détection des défauts, nous ne nous intéressons qu'à l'image pour faire apprendre au modèle les différentes phases de l'usinage. Cette étude ne s'intéresse qu'à l'image de la FFT pour faire apprendre au modèle les différentes phases de l'usinage, et surtout sans considérer l'amplitude du signal et sans permettre à l'algorithme de repérer des fréquences précises liées à la vitesse de rotation, car nos données correspondaient à plusieurs vitesses de rotation utilisées, ce qui était souvent une limitation des approches proposées dans la littérature qui pouvaient de façon triviale se baser sans le dire sur l'amplitude du signal ou certains pics de fréquence caractéristiques. Le Tableau 4.4 présente une liste de certains travaux ayant utilisés les techniques de l'intelligence artificielle pour détecter le broutement en obtenant les meilleures performances en termes de justesse (precision) de classification.

Tableau 4.4. Liste de certains travaux ayant les meilleures performances en termes de justesse de classification

Réf..	Prétraitement	Données d'entrée	Classification	Justesse
Ce papier	FFT	Images FFT	Multi-label	99,71%
[154]	CWT	Images-paramètres de coupe	Multi-label	99,88%
[242]	Réduction taille	Images	Binaire	98,26%
[191]	CWT	Images	Multi-label	99,67%
[144]	STFT	Images	Multi-label	98,90%
[197]		Signal	Multi-label	98%

4.6. Conclusion et perspectives

Dans ce chapitre, l'approche proposée combine l'analyse des vibrations et l'apprentissage profond pour détecter le broutement dans un processus d'usinage industriel. Avec le signal brut à la source, un modèle puissant a été développé pour la détection des différentes phases d'usinage en appliquant la transformée de Fourier rapide sur le signal pour générer les images qui ont formé la base de données. L'utilisation de réseaux pré-entraînés avec l'apprentissage par transfert nous a permis d'extraire des caractéristiques des données pour soutenir une généralisation du modèle. Dans la méthode classique d'analyse des vibrations d'usinage, plusieurs paramètres sont pris en compte pour définir les différentes phases, notamment l'amplitude du signal et la vitesse de rotation, ce qui permet de comparer la position des pics mesurés concernant les harmoniques de cette vitesse.

Les résultats de la vérification et de la visualisation par la courbe ROC et la matrice de confusion montrent que l'application des techniques d'apprentissage profond sur les données d'usinage industriel obtient de très bonnes performances. Ceci est d'autant plus remarquable que l'amplitude du signal n'est pas transmise au réseau (la FFT lui est transmise en recalibrant l'échelle sur le signal maximum), ni la vitesse de rotation, et encore moins le fait que plusieurs vitesses de rotation ont été considérées. Le modèle montre donc sa capacité à identifier l'information du broutement dans le spectre, en s'adaptant automatiquement à plusieurs vitesses de rotation. Par ailleurs, certaines des données de test sont similaires aux données d'entraînement, mais une partie est plus bruitée et équivoque. Là encore, le réseau de neurones

a bien détecté ces cas à partir de son apprentissage sur les cas non bruités. Ce modèle peut être utilisé à court terme pour assister un expert en analyse de signaux, notamment pour lui faciliter la tâche sur des usinages longs avec des signaux bruyants ou ambigus. Nous résumons en détail nos travaux futurs pour la détection du broutement d'usinage. Ces travaux sont basés sur l'application, de la multimodalité en exploitant plusieurs sources de données, de l'IA explicable dans le but d'apporter plus de compréhension dans les processus de prise de décision intelligente, et de l'apprentissage non supervisé comme outil d'étiquetage pour la construction du jeu de données.

- **La détection des zones de transition en exploitant deux sources de données (FFT et STFT)**

L'analyse des vibrations en usinage est une tâche difficile, même pour les experts humains, car plusieurs phénomènes interviennent simultanément et évoluent rapidement. En effet, une machine-outil en mouvement, même à vide, génère déjà de nombreuses vibrations, liées aux balourds, aux roulements, aux moteurs, aux asservissements, notamment. S'ajoute en usinage un signal puissant et rapidement évolutif, l'usinage, et parfois s'ajoute encore dessus le broutement, plus ou moins puissant. L'identification des zones de transition entre l'usinage normal et l'apparition de vibration (broutement) est un aspect important de l'analyse pour les experts.

Concernant la détection du broutement, les experts humains s'appuient bien sûr sur les FFT, mais aussi sur les spectrogrammes (STFT), pour mieux identifier les phénomènes en détectant aussi les transitions entre les phénomènes, ce qui constitue une forme de multimodalité, bien que basée sur le même signal de départ. Les deux types de transformation (FFT et STFT) sur le même signal pour obtenir deux types d'images très différentes et aussi associées à des temporalités différentes (Figure 4.11). L'approche que nous proposons se compose de quatre étapes : (i) la transformation des données, (ii) construction du jeu de données, (iii) construction d'un modèle d'apprentissage multimodal, (iv) classification des phases d'usinages (rotation à vide, usinage, broutement, transition).

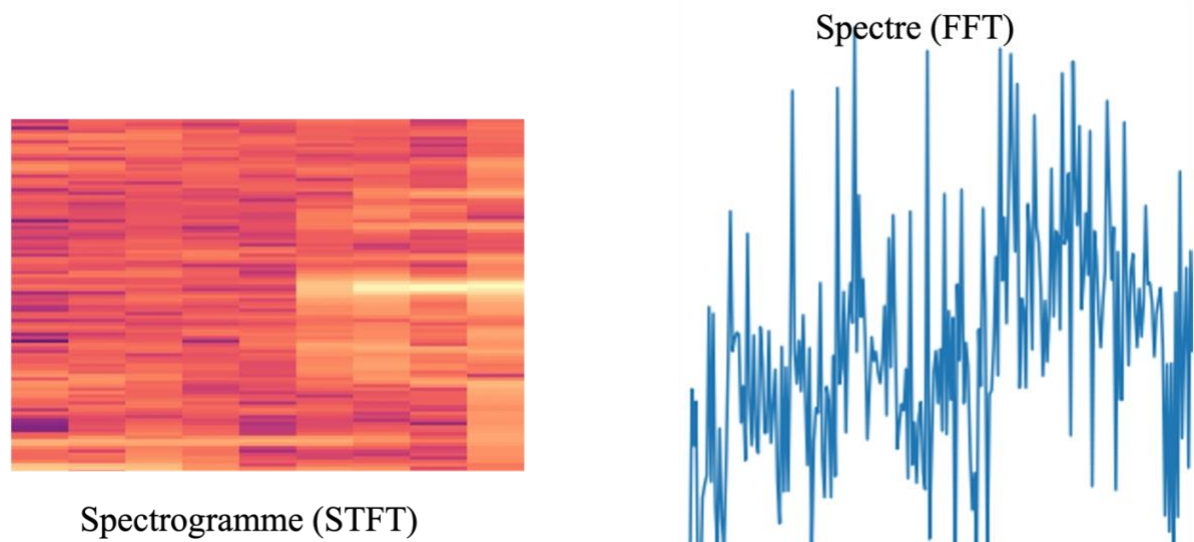


Figure 4.11. Images des deux sources (STFT et FFT) de données.

Ces états d'usinage présentés dans la Figure 4.12 sont considérés comme des classes pour l'apprentissage du modèle. Nous proposons alors deux modèles d'apprentissage profond qui opèrent de manière parallèle sur nos deux types d'image et ensuite un processus de fusion sera effectué pour concaténer les sorties des deux modèles afin de prédire ces états.

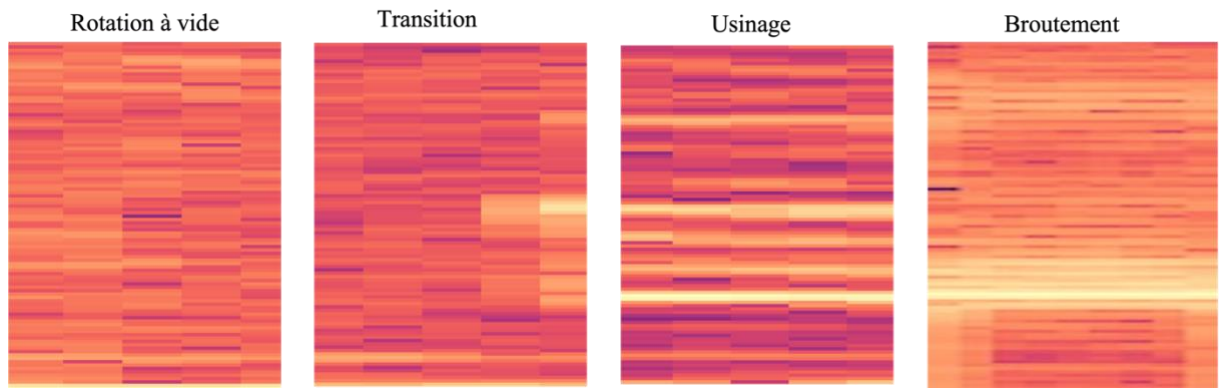


Figure 4.12. Exemple de différentes phases d'usinage identifiées.

Ces états d'usinage sont considérés comme des classes pour l'apprentissage du modèle. Nous proposons alors deux modèles d'apprentissage profond qui opèrent de manière parallèle sur nos deux types d'images et ensuite un processus de fusion sera effectué pour concaténer les sorties des deux modèles afin de prédire ces états.

En plus de combiner ainsi la FFT et STFT pour détecter le broutement nous envisageons d'associer aussi une autre source d'information, utilisée parfois par les experts pour distinguer des phénomènes sinon indistinguables : la STFT de la réponse du système à une perturbation sur la vitesse de rotation ou sur l'avance à la dent. Cette STFT pourrait être déclenchée sur demande par une première réponse du réseau, lorsque la réponse n'est pas assez claire et qu'il y a un risque pour le process d'usinage.

- **Application des techniques de l'IA explicable sur nos prédictions**

Dans cette partie, nous proposons d'utiliser une méthode de l'explicabilité (Grad-CAM, lime, etc.) sur la prédiction du modèle de détection pour comprendre le fonctionnement de ces réseaux de neurones profonds, et transmettre l'information à l'usineur ou à l'expert. Il s'agit de fournir une information compréhensible par l'humain qui permette de comprendre sur quels aspects ces méthodes se basent pour détecter tel ou tel état d'usinage dans les images fournies.

La méthode d'explication visuelle Gradient-weighted Class Activation Mapping (Grad-CAM) proposé par Selvaraju *et al.* [153] est un exemple pour rendre les décisions plus transparentes sur des modèles basés sur les CNN. Le Grad-Cam s'applique à tout type de concept (données) introduit dans un réseau de neurones de classification. Cette technique explore le réseau de la couche de convolution jusqu'à la couche finale pour produire une carte de localisation des caractéristiques déterminantes. Elle permet de mettre en évidence les régions importantes de l'image ayant conduit à donner une réponse précise. Kim *et al.* ont utilisé cette technique pour le diagnostic de défaut de roulement. Local Interpretable Model-Agnostic Explanations (LIME) est aussi l'une des méthodes de visualisation qui contribue à l'explication des prédictions individuelles. Cette technique est indépendante du modèle de prédiction et peut donc être appliquée à n'importe quel modèle de régression ou de classification supervisé. LIME présentée par Ribeiro *et al.* [146] elle s'applique à trois types de données (tableur, textes et images).

L'idée serait qu'après la réalisation des phases d'extraction des caractéristiques et de la classification des images (spectrogrammes et spectre) issues de la STFT et FFT sur le signal vibratoire d'usinage, les modèles d'explications visuelles XAI sont appliqués sur les prédictions pour obtenir un meilleur discernement entre les phases d'usinage.

- **Apprentissage non supervisé pour la détection du broutement**

Nous prévoyons d'utiliser les modèles d'apprentissage non supervisé dans lequel le modèle associé va apprendre de lui-même à explorer à l'aide de multiples échelles de FFT et STFT et comprendre des données pour ensuite les regrouper en sous-ensembles d'éléments similaires (clustering). Avec l'apprentissage non supervisé, le modèle pourrait aller jusqu'à nous indiquer un changement de comportement sur une machine et nous montrer d'où vient le changement. Il pourrait même alimenter l'expertise en découvrant dans les données des indices qui demeurent pour l'instant invisibles à l'œil de l'expert, comme évoqué dans le chapitre précédent, notamment en explorant méthodiquement différentes résolutions d'analyse FFT et STFT, ce que l'expert n'a généralement pas le temps de faire. Les données extraites par les différentes techniques de transformation (FFT, STFT) pourraient alors être catégorisées par des techniques non supervisées comme l'algorithme K-plus proches voisins (KNN) ou K-moyennes (K-means). Les clusters obtenus par ces méthodes sont considérés comme des classes et serviront de données d'entrée pour un modèle d'apprentissage supervisé. Le but de l'apprentissage non supervisé c'est d'alléger le processus d'étiquetage du signal par l'expert

5. Conclusion

Dans ce manuscrit de thèse, nous avons fourni des pistes pour l'automatisation de la surveillance d'un processus d'usinage, en l'occurrence le fraisage.

Tout d'abord il a été proposé une première méthodologie basée sur l'apprentissage profond multimodal pour la prédiction du choix des paramètres de coupe en lien avec un état de surface visé. La sélection optimale des paramètres de coupe est très importante pour assurer une meilleure qualité de surface des pièces usinées, une durée de vie plus longue des outils de coupe et pour augmenter la productivité. Cette sélection de conditions de coupe peut aussi aboutir à une diminution des forces de coupe et des vibrations en particulier.

Une deuxième méthodologie a été proposée pour détecter automatiquement le phénomène de broutement dans le signal vibratoire d'usinage industriel. Cette méthodologie consiste à combiner les compétences mécaniques et informatiques afin de surmonter les difficultés rencontrées dans la littérature sur ce sujet. On focalise ici sur le broutement, identifié comme l'un des problèmes les plus obscurs de l'industrie mécanique et dont la stabilisation, la détection ou l'identification reste un défi majeur pour les chercheurs.

La première contribution se concentre sur le déploiement d'une procédure efficace pour l'apprentissage profond multimodal basée sur les données collectées lors d'une opération de fraisage. Ce travail consiste à :

- La collecte de données multimodales : deux types de données sont collectées, une source de données image provenant des photos des surfaces usinées et une deuxième source contenant les données numériques en occurrence les paramètres de coupe choisis lors du fraisage et la rugosité moyenne arithmétique des surfaces usinées mesurée par un rugosimètre.
- L'alignement qui a consisté à la mise relation des échantillons des deux sources de données.
- L'élaboration des modèles de traitement des sources de données : chaque source de données a été traitée séparément avec un modèle de réseau de neurones différent.
- La fusion des deux modèles de réseau de neurones et la prise de décision.

Les résultats obtenus sont plutôt encourageants, car il a été constaté que les performances du modèle de fusion multimodale sont meilleures que celles du modèle unimodal pour la prédiction des paramètres de coupe. Les difficultés rencontrées pour la mise en place de la méthode de prédiction du choix des paramètres de condition d'usinage nous ont amenés vers un problème d'analyse du signal de vibration d'usinage pour détecter le broutement et dont les données sont à notre disposition.

Pour la deuxième méthodologie, concernant la détection du broutement, nous avons réalisé une étude bibliométrique pour bien identifier les différentes techniques utilisées dans la littérature, notamment toutes celles à partir de la méthode de traitement et de décomposition du signal temps-fréquence jusqu'à l'application de l'intelligence artificielle pour la détection automatique. Cette étude nous a permis d'identifier :

- Les articles les plus significatifs, les auteurs les plus cités, la collaboration entre auteurs, les pays, continents et revues, ainsi que les mots-clés utilisés par les auteurs et les tendances les plus récentes sur la recherche sur la détection du broutement.
- Les limites des techniques classiques de traitement du signal temps-fréquence
- L'importance de l'apprentissage automatique pour l'extraction de caractéristiques et la prise de décision.

- Les biais liés à la seule utilisation des données issues des conditions d'usinage de laboratoire, éloignées des applications industrielles, même si quelques publications utilisent des conditions de coupe simplifiées mais relativement réalistes.

À partir de cette étude bibliométrique, nous avons proposé une méthodologie basée sur des compétences mécaniques pour d'abord identifier les traitements optimaux du signal puis exploiter la puissance de l'apprentissage profond, en nous basant sur l'apprentissage par transfert pour détecter automatiquement le phénomène de broutement dans un signal vibratoire d'usinage industriel. Cette méthodologie a été réalisée en plusieurs étapes :

- La collecte du signal vibratoire d'usinage industriel.
- La transformation du domaine temporel au domaine fréquentiel en appliquant la transformée de fourier rapide pour générer des images, et leur redimensionnement.
- L'étiquetage des données d'images pour construire l'ensemble de données.
- L'extraction des caractéristiques des images par l'apprentissage par transfert.
- La classification des différentes phases constatées dans le signal vibratoire, sur des données tests de différentes difficultés.

Les résultats du modèle ont montré que l'application des techniques d'apprentissage profond sur les images FFT obtient de très bonnes performances. Contrairement à beaucoup, voire la totalité, des travaux antérieurs, notre modèle ne donne aucune information au réseau de neurones sur l'amplitude du signal ni la vitesse de rotation. En effet dans la littérature ces informations sont trop souvent corrélées de façon triviale avec le broutement, en partie du fait qu'il s'agit chaque fois de mesures faites en laboratoire, sur des usinages très simples, et avec des capteurs idéalement positionnés. Notre modèle arrive non seulement à capturer les informations du broutement dans le spectre ainsi fourni, mais obtient même d'aussi bons résultats que ceux de la littérature, ce qui prouve enfin d'après nous de façon indiscutable la performance de telles approches. Ce modèle peut être utilisé à court terme pour assister un expert en analyse de signaux, notamment pour lui faciliter la tâche sur des usinages longs avec des signaux bruyants ou ambigus.

Bibliographie

1. Abele, E. et al.: Machine tool spindle units. *CIRP Ann.* 59, 2, 781–802 (2010). <https://doi.org/10.1016/j.cirp.2010.05.002>.
2. Acayaba, G.M.A., Escalona, P.M. de: Prediction of surface roughness in low speed turning of AISI316 austenitic stainless steel. *CIRP J. Manuf. Sci. Technol.* 11, 62–67 (2015). <https://doi.org/10.1016/j.cirpj.2015.08.004>.
3. Afazov, S., Scrimieri, D.: Chatter model for enabling a digital twin in machining. *Int. J. Adv. Manuf. Technol.* 110, 9–10, 2439–2444 (2020). <https://doi.org/10.1007/s00170-020-06028-9>.
4. Aggarwal, S., Chugh, N.: Signal processing techniques for motor imagery brain computer interface: A review. *Array.* 1–2, 100003 (2019). <https://doi.org/10.1016/j.array.2019.100003>.
5. Ahmad, S. et al.: Autoencoder-based Condition Monitoring and Anomaly Detection Method for Rotating Machines. (2021). <https://doi.org/10.48550/ARXIV.2101.11539>.
6. Alajmi, M.S., Almeshal, A.M.: Modeling of Cutting Force in the Turning of AISI 4340 Using Gaussian Process Regression Algorithm. *Appl. Sci.* 11, 9, 4055 (2021).
7. Al-Dulaimi, A. et al.: A multimodal and hybrid deep neural network model for Remaining Useful Life estimation. *Comput. Ind.* 108, 186–196 (2019). <https://doi.org/10.1016/j.compind.2019.02.004>.
8. Alkhalaf, S.: A robust variance information fusion technique for real-time autonomous navigation systems. *Measurement.* 179, 109441 (2021). <https://doi.org/10.1016/j.measurement.2021.109441>.
9. Altıntaş, Y., Budak, E.: Analytical Prediction of Stability Lobes in Milling. *CIRP Ann.* 44, 1, 357–362 (1995). [https://doi.org/10.1016/S0007-8506\(07\)62342-7](https://doi.org/10.1016/S0007-8506(07)62342-7).
10. Altintas, Y., Chan, P.K.: In-process detection and suppression of chatter in milling. *Int. J. Mach. Tools Manuf.* 32, 3, 329–347 (1992). [https://doi.org/10.1016/0890-6955\(92\)90006-3](https://doi.org/10.1016/0890-6955(92)90006-3).
11. Altintas, Y., Weck, M.: Chatter Stability of Metal Cutting and Grinding. *CIRP Ann.* 53, 2, 619–642 (2004). [https://doi.org/10.1016/S0007-8506\(07\)60032-8](https://doi.org/10.1016/S0007-8506(07)60032-8).
12. Alvarez, G.P.: Real-Time Fault Detection and Diagnosis Using Intelligent Monitoring and Supervision Systems. *IntechOpen* (2020). <https://doi.org/10.5772/intechopen.90158>.
13. Amini, N., Zhu, Q.: Fault detection and diagnosis with a novel source-aware autoencoder and deep residual neural network. *Neurocomputing.* 488, 618–633 (2022). <https://doi.org/10.1016/j.neucom.2021.11.067>.
14. Angelopoulos, A. et al.: Tackling Faults in the Industry 4.0 Era—A Survey of Machine-Learning Solutions and Key Aspects. *Sensors.* 20, 1, 109 (2019). <https://doi.org/10.3390/s20010109>.
15. Aria, M., Cuccurullo, C.: bibliometrix: An R-tool for comprehensive science mapping analysis. *J. Informetr.* 11, 4, 959–975 (2017).
16. Arriaza, O.V. et al.: Chatter Identification using Multiple Sensors and Multi-Layer Neural Networks. *Procedia Manuf.* 17, 150–157 (2018). <https://doi.org/10.1016/j.promfg.2018.10.030>.
17. Arriaza, O.V. et al.: Chatter Identification using Multiple Sensors and Multi-Layer

- Neural Networks. In: Sormaz, D. et al. (eds.) 28th International Conference on Flexible Automation and Intelligent Manufacturing (faim2018): Global Integration of Intelligent Manufacturing and Smart Industry for Good of Humanity. pp. 150–157 Elsevier Science Bv, Amsterdam (2018). <https://doi.org/10.1016/j.promfg.2018.10.030>.
18. Bai, M. et al.: Convolutional neural network-based deep transfer learning for fault detection of gas turbine combustion chambers. *Appl. Energy*. 302, 117509 (2021). <https://doi.org/10.1016/j.apenergy.2021.117509>.
 19. Baltrusaitis, T. et al.: Multimodal Machine Learning: A Survey and Taxonomy. *IEEE Trans. Pattern Anal. Mach. Intell.* 41, 2, 423–443 (2019). <https://doi.org/10.1109/TPAMI.2018.2798607>.
 20. Baltrušaitis, T. et al.: Multimodal Machine Learning: A Survey and Taxonomy. *ArXiv170509406 Cs.* (2017).
 21. Barredo Arrieta, A. et al.: Explainable Artificial Intelligence (XAI): Concepts, taxonomies, opportunities and challenges toward responsible AI. *Inf. Fusion*. 58, 82–115 (2020). <https://doi.org/10.1016/j.inffus.2019.12.012>.
 22. Bayouhd, K. et al.: A survey on deep multimodal learning for computer vision: advances, trends, applications, and datasets. *Vis. Comput.* (2021). <https://doi.org/10.1007/s00371-021-02166-7>.
 23. Behera, S. et al.: Multiscale deep bidirectional gated recurrent neural networks based prognostic method for complex non-linear degradation systems. *Inf. Sci.* 554, 120–144 (2021). <https://doi.org/10.1016/j.ins.2020.12.032>.
 24. Behzad, M. et al.: Inaccessible rolling bearing diagnosis using a novel criterion for Morlet wavelet optimization. *J. Vib. Control*. 1077546321989503 (2021). <https://doi.org/10.1177/1077546321989503>.
 25. Bengherbia, B. et al.: FPGA implementation of a wireless sensor node with a built-in ADALINE neural network coprocessor for vibration analysis and fault diagnosis in machine condition monitoring. *Measurement*. 163, 107960 (2020). <https://doi.org/10.1016/j.measurement.2020.107960>.
 26. von Bohlen and Halbach, O.: How to judge a book by its cover? How useful are bibliometric indices for the evaluation of “scientific quality” or “scientific productivity”? *Ann. Anat. - Anat. Anz.* 193, 3, 191–196 (2011). <https://doi.org/10.1016/j.aanat.2011.03.011>.
 27. Bonda, A.G.Y. et al.: Vibration signature based stability studies in internal turning with a wavelet denoising preprocessor. *Measurement*. 154, 107520 (2020). <https://doi.org/10.1016/j.measurement.2020.107520>.
 28. Bouwmans, T. et al.: Deep neural network concepts for background subtraction: A systematic review and comparative evaluation. *Neural Netw.* 117, 8–66 (2019). <https://doi.org/10.1016/j.neunet.2019.04.024>.
 29. Bravo, U. et al.: Stability limits of milling considering the flexibility of the workpiece and the machine. *Int. J. Mach. Tools Manuf.* 45, 15, 1669–1680 (2005). <https://doi.org/10.1016/j.ijmachtools.2005.03.004>.
 30. Caliskan, H. et al.: On-Line Energy-Based Milling Chatter Detection. *J. Manuf. Sci. Eng.* 140, 11, (2018). <https://doi.org/10.1115/1.4040617>.
 31. Cao, H. et al.: Chatter identification in end milling process using wavelet packets and Hilbert–Huang transform. *Int. J. Mach. Tools Manuf.* 69, 11–19 (2013).

<https://doi.org/10.1016/j.ijmachtools.2013.02.007>.

32. Cao, H. et al.: Early chatter detection in end milling based on multi-feature fusion and 3 sigma criterion. *Int. J. Adv. Manuf. Technol.* 92, 9–12, 4387–4397 (2017). <https://doi.org/10.1007/s00170-017-0476-x>.
33. Cao, H. et al.: The concept and progress of intelligent spindles: A review. *Int. J. Mach. Tools Manuf.* 112, 21–52 (2017). <https://doi.org/10.1016/j.ijmachtools.2016.10.005>.
34. Cardi, A.A. et al.: Workpiece dynamic analysis and prediction during chatter of turning process. *Mech. Syst. Signal Process.* 22, 6, 1481–1494 (2008). <https://doi.org/10.1016/j.ymsp.2007.11.026>.
35. Cen, L. et al.: A Method for Mode Coupling Chatter Detection and Suppression in Robotic Milling. *J. Manuf. Sci. Eng.* 140, 8, (2018). <https://doi.org/10.1115/1.4040161>.
36. Charalampous, P.: Prediction of Cutting Forces in Milling Using Machine Learning Algorithms and Finite Element Analysis. *J. Mater. Eng. Perform.* 30, 3, 2002–2013 (2021). <https://doi.org/10.1007/s11665-021-05507-8>.
37. Chen, G.S., Zheng, Q.Z.: Online chatter detection of the end milling based on wavelet packet transform and support vector machine recursive feature elimination. *Int. J. Adv. Manuf. Technol.* 95, 1–4, 775–784 (2018). <https://doi.org/10.1007/s00170-017-1242-9>.
38. Chen, X. et al.: Energy efficient cutting parameter optimization. *Front. Mech. Eng.* 16, 2, 221–248 (2021). <https://doi.org/10.1007/s11465-020-0627-x>.
39. Chen, X. et al.: Integrated optimization of cutting tool and cutting parameters in face milling for minimizing energy footprint and production time. *Energy.* 175, 1021–1037 (2019). <https://doi.org/10.1016/j.energy.2019.02.157>.
40. Chen, X. et al.: Research on deep learning in the field of mechanical equipment fault diagnosis image quality. *J. Vis. Commun. Image Represent.* 62, 402–409 (2019). <https://doi.org/10.1016/j.jvcir.2019.06.007>.
41. Chen, Y. et al.: An intelligent chatter detection method based on EEMD and feature selection with multi-channel vibration signals. *Measurement.* 127, 356–365 (2018). <https://doi.org/10.1016/j.measurement.2018.06.006>.
42. Chen, Y. et al.: Feature extraction using dominant frequency bands and time-frequency image analysis for chatter detection in milling. *Precis. Eng.* 56, 235–245 (2019). <https://doi.org/10.1016/j.precisioneng.2018.12.004>.
43. Chen, Y. et al.: Predicting tool wear with multi-sensor data using deep belief networks. *Int. J. Adv. Manuf. Technol.* 99, 5–8, 1917–1926 (2018). <https://doi.org/10.1007/s00170-018-2571-z>.
44. Cheng, K. et al.: Smart Cutting Tools and Smart Machining: Development Approaches, and Their Implementation and Application Perspectives. *Chin. J. Mech. Eng.* 30, 5, 1162–1176 (2017). <https://doi.org/10.1007/s10033-017-0183-4>.
45. Cheng, Y. et al.: Multi-dimensional recurrent neural network for remaining useful life prediction under variable operating conditions and multiple fault modes. *Appl. Soft Comput.* 118, 108507 (2022). <https://doi.org/10.1016/j.asoc.2022.108507>.
46. Corallo, A. et al.: Cybersecurity in the context of industry 4.0: A structured classification of critical assets and business impacts. *Comput. Ind.* 114, 103165 (2020). <https://doi.org/10.1016/j.compind.2019.103165>.

47. Coulibaly, L. et al.: Learning with deep Gaussian processes and homothety in weather simulation. *Neural Comput. Appl.* 34, 20, 17441–17453 (2022). <https://doi.org/10.1007/s00521-022-07386-z>.
48. Cuayáhuitl, H.: A data-efficient deep learning approach for deployable multimodal social robots. *Neurocomputing.* 396, 587–598 (2020). <https://doi.org/10.1016/j.neucom.2018.09.104>.
49. Delio, T. et al.: Use of Audio Signals for Chatter Detection and Control. *J. Eng. Ind.* 114, 2, 146–157 (1992). <https://doi.org/10.1115/1.2899767>.
50. Ding, S.L. et al.: Chatter Detection in High Speed Machining of Titanium Alloys. *Key Eng. Mater.* 458, 289–294 (2010). <https://doi.org/10.4028/www.scientific.net/KEM.458.289>.
51. Duan, L. et al.: Deep learning enabled intelligent fault diagnosis: Overview and applications. *J. Intell. Fuzzy Syst.* 35, 5, 5771–5784 (2018). <https://doi.org/10.3233/JIFS-17938>.
52. Dun, Y. et al.: A chatter detection method in milling of thin-walled TC4 alloy workpiece based on auto-encoding and hybrid clustering. *Mech. Syst. Signal Process.* 158, 107755 (2021). <https://doi.org/10.1016/j.ymssp.2021.107755>.
53. Egghe, L.: Theory and practise of the g-index. *Scientometrics.* 69, 1, 131–152 (2006). <https://doi.org/10.1007/s11192-006-0144-7>.
54. El-Sappagh, S. et al.: Multimodal multitask deep learning model for Alzheimer's disease progression detection based on time series data. *Neurocomputing.* 412, 197–215 (2020). <https://doi.org/10.1016/j.neucom.2020.05.087>.
55. Faheem, M. et al.: CBI4.0: A cross-layer approach for big data gathering for active monitoring and maintenance in the manufacturing industry 4.0. *J. Ind. Inf. Integr.* 24, 100236 (2021). <https://doi.org/10.1016/j.jii.2021.100236>.
56. Farahani, N.D., Altintas, Y.: Chatter Stability of Serrated Milling Tools in Frequency Domain. *J. Manuf. Sci. Eng.* 144, 3, 031013 (2022). <https://doi.org/10.1115/1.4052007>.
57. Fu, P. et al.: Dynamic Routing-based Multimodal Neural Network for Multi-sensory Fault Diagnosis of Induction Motor. *J. Manuf. Syst.* 55, 264–272 (2020). <https://doi.org/10.1016/j.jmsy.2020.04.009>.
58. Fu, Y. et al.: Analysis of Feature Extracting Ability for Cutting State Monitoring Using Deep Belief Networks. *Procedia CIRP.* 31, 29–34 (2015). <https://doi.org/10.1016/j.procir.2015.03.016>.
59. Fu, Y. et al.: Machining vibration states monitoring based on image representation using convolutional neural networks. *Eng. Appl. Artif. Intell.* 65, 240–251 (2017). <https://doi.org/10.1016/j.engappai.2017.07.024>.
60. Fu, Y. et al.: Timely online chatter detection in end milling process. *Mech. Syst. Signal Process.* 75, 668–688 (2016). <https://doi.org/10.1016/j.ymssp.2016.01.003>.
61. Fuentes-Alvarez, R. et al.: Assistive robotic exoskeleton using recurrent neural networks for decision taking for the robust trajectory tracking. *Expert Syst. Appl.* 193, 116482 (2022). <https://doi.org/10.1016/j.eswa.2021.116482>.
62. Gangan, O. et al.: Review on Modelling of Cutting Parameter using Machine Learning.
63. Gao, H.N. et al.: Identification of Cutting Chatter Through Deep Learning and Classification. *Int. J. Simul. Model.* 19, 4, 667–677 (2020). <https://doi.org/10.2507/IJSIMM19->

4-CO16.

64. Gao, J. et al.: Chatter detection and stability region acquisition in thin-walled workpiece milling based on CMWT. *Int. J. Adv. Manuf. Technol.* 98, 1–4, 699–713 (2018). <https://doi.org/10.1007/s00170-018-2306-1>.
65. García Plaza, E. et al.: Multi-Sensor Data Fusion for Real-Time Surface Quality Control in Automated Machining Systems. *Sensors.* 18, 12, 4381 (2018). <https://doi.org/10.3390/s18124381>.
66. Glaeser, A. et al.: Applications of deep learning for fault detection in industrial cold forging. *Int. J. Prod. Res.* 59, 16, 4826–4835 (2021). <https://doi.org/10.1080/00207543.2021.1891318>.
67. Glowacz, A. et al.: Detection of Deterioration of Three-phase Induction Motor using Vibration Signals. *Meas. Sci. Rev.* 19, 6, 241–249 (2019). <https://doi.org/10.2478/msr-2019-0031>.
68. Goodfellow, I. et al.: *Deep learning*. MIT press (2016).
69. Gousskov, A.M. et al.: Chatter suppression in boring with tool position feedback control. *J. Vibroengineering.* 19, 5, 3512–3521 (2017). <https://doi.org/10.21595/jve.2017.17777>.
70. Guo, W. et al.: Deep Multimodal Representation Learning: A Survey. *IEEE Access.* 7, 63373–63394 (2019). <https://doi.org/10.1109/ACCESS.2019.2916887>.
71. Gupta, A. et al.: Deep Learning for Object Detection and Scene Perception in Self-Driving Cars: Survey, Challenges, and Open Issues. *Array.* 100057 (2021). <https://doi.org/10.1016/j.array.2021.100057>.
72. Hatami, N. et al.: CNN-LSTM Based Multimodal MRI and Clinical Data Fusion for Predicting Functional Outcome in Stroke Patients. (2022). <https://doi.org/10.48550/ARXIV.2205.05545>.
73. He, A., Jin, X.: Failure Detection and Remaining Life Estimation for Ion Mill Etching Process Through Deep-Learning Based Multimodal Data Fusion. *J. Manuf. Sci. Eng.* 141, 10, 101008 (2019). <https://doi.org/10.1115/1.4044248>.
74. He, K. et al.: Deep Residual Learning for Image Recognition. *ArXiv151203385 Cs.* (2015).
75. He, Z. et al.: Research on tool wear prediction based on temperature signals and deep learning. *Wear.* 478–479, 203902 (2021). <https://doi.org/10.1016/j.wear.2021.203902>.
76. Hirsch, J.E.: An index to quantify an individual’s scientific research output. *Proc. Natl. Acad. Sci.* 102, 46, 16569–16572 (2005). <https://doi.org/10.1073/pnas.0507655102>.
77. Hoang, D.-T., Kang, H.-J.: A survey on Deep Learning based bearing fault diagnosis. *Neurocomputing.* 335, 327–335 (2019). <https://doi.org/10.1016/j.neucom.2018.06.078>.
78. HongQi, L. et al.: On-line chatter detection using servo motor current signal in turning. *Sci. China-Technol. Sci.* 54, 12, 3119–3129 (2011). <https://doi.org/10.1007/s11431-011-4595-6>.
79. Hu, L. et al.: Optimisation of cutting parameters for improving energy efficiency in machining process. *Robot. Comput.-Integr. Manuf.* 59, 406–416 (2019). <https://doi.org/10.1016/j.rcim.2019.04.015>.
80. Huda, F. et al.: Chatter detection in turning process using sound signal and simple microphone. *IOP Conf. Ser. Mater. Sci. Eng.* 830, 4, 042027 (2020).

<https://doi.org/10.1088/1757-899X/830/4/042027>.

81. Jana, D. et al.: CNN and Convolutional Autoencoder (CAE) based real-time sensor fault detection, localization, and correction. *Mech. Syst. Signal Process.* 169, 108723 (2022). <https://doi.org/10.1016/j.ymsp.2021.108723>.
82. Janiesch, C. et al.: Machine learning and deep learning. *Electron. Mark.* 31, 3, 685–695 (2021). <https://doi.org/10.1007/s12525-021-00475-2>.
83. Jantunen, E.: A summary of methods applied to tool condition monitoring in drilling. *Int. J. Mach. Tools Manuf.* 42, 9, 997–1010 (2002). [https://doi.org/10.1016/S0890-6955\(02\)00040-8](https://doi.org/10.1016/S0890-6955(02)00040-8).
84. Javaid, M. et al.: Exploring impact and features of machine vision for progressive industry 4.0 culture. *Sens. Int.* 3, 100132 (2022). <https://doi.org/10.1016/j.sintl.2021.100132>.
85. Karpathy, A. et al.: Deep Fragment Embeddings for Bidirectional Image Sentence Mapping. (2014). <https://doi.org/10.48550/ARXIV.1406.5679>.
86. Kawaguchi, K. et al.: Generalization in Deep Learning. (2017). <https://doi.org/10.48550/ARXIV.1710.05468>.
87. Khasawneh, F.A. et al.: Chatter Classification in Turning using Machine Learning and Topological Data Analysis. *IFAC-Pap.* 51, 14, 195–200 (2018). <https://doi.org/10.1016/j.ifacol.2018.07.222>.
88. Kim, T., Kim, H.Y.: Forecasting stock prices with a feature fusion LSTM-CNN model using different representations of the same data. *PLOS ONE.* 14, 2, e0212320 (2019). <https://doi.org/10.1371/journal.pone.0212320>.
89. Kohlheb, T. et al.: Embedded autoencoder-based condition monitoring of rotating machinery. In: 2021 26th IEEE International Conference on Emerging Technologies and Factory Automation (ETFA). pp. 1–4 IEEE, Vasteras, Sweden (2021). <https://doi.org/10.1109/ETFA45728.2021.9613697>.
90. Kolluru, K., Axinte, D.: Coupled interaction of dynamic responses of tool and workpiece in thin wall milling. *J. Mater. Process. Technol.* 213, 9, 1565–1574 (2013). <https://doi.org/10.1016/j.jmatprotec.2013.03.018>.
91. Krizhevsky, A. et al.: ImageNet Classification with Deep Convolutional Neural Networks. In: Pereira, F. et al. (eds.) *Advances in Neural Information Processing Systems* 25. pp. 1097–1105 Curran Associates, Inc. (2012).
92. Kuljanic, E. et al.: Development of an intelligent multisensor chatter detection system in milling. *Mech. Syst. Signal Process.* 23, 5, 1704–1718 (2009). <https://doi.org/10.1016/j.ymsp.2009.01.003>.
93. Kumar, T.P. et al.: A multi-sensor information fusion for fault diagnosis of a gearbox utilizing discrete wavelet features. *Meas. Sci. Technol.* 30, 8, 085101 (2019). <https://doi.org/10.1088/1361-6501/ab0737>.
94. Lahat, D. et al.: Multimodal Data Fusion: An Overview of Methods, Challenges, and Prospects. *Proc. IEEE.* 103, 9, 1449–1477 (2015). <https://doi.org/10.1109/JPROC.2015.2460697>.
95. Lamraoui, M. et al.: Détection de bavardage dans les fraiseuses par classification de réseau neuronal et sélection de caractéristiques. *J. Vib. Control.* 21, 7, 1251–1266 (2015). <https://doi.org/10.1177/1077546313493919>.

96. LeCun, Y. et al.: Deep learning. *Nature*. 521, 7553, 436–444 (2015). <https://doi.org/10.1038/nature14539>.
97. Lee, C., Lim, C.: From technological development to social advance: A review of Industry 4.0 through machine learning. *Technol. Forecast. Soc. Change*. 167, 120653 (2021). <https://doi.org/10.1016/j.techfore.2021.120653>.
98. Lee, C.-H. et al.: An Intelligent System for Grinding Wheel Condition Monitoring Based on Machining Sound and Deep Learning. *IEEE Access*. 8, 58279–58289 (2020). <https://doi.org/10.1109/ACCESS.2020.2982800>.
99. Lei, Y. et al.: Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mech. Syst. Signal Process.* 138, 106587 (2020). <https://doi.org/10.1016/j.ymsp.2019.106587>.
100. Li, D.-D. et al.: Chatter identification of thin-walled parts for intelligent manufacturing based on multi-signal processing. *Adv. Manuf.* 9, 1, 22–33 (2021). <https://doi.org/10.1007/s40436-020-00299-x>.
101. Li, Z. et al.: A novel ensemble deep learning model for cutting tool wear monitoring using audio sensors. *J. Manuf. Process.* 79, 233–249 (2022). <https://doi.org/10.1016/j.jmapro.2022.04.066>.
102. Liao, Y. et al.: Manufacturing process monitoring using time-frequency representation and transfer learning of deep neural networks. *J. Manuf. Process.* 68, 231–248 (2021). <https://doi.org/10.1016/j.jmapro.2021.05.046>.
103. Lin, H.-C. et al.: Bearing vibration detection and analysis using enhanced fast Fourier transform algorithm. *Adv. Mech. Eng.* 8, 10, 1687814016675080 (2016). <https://doi.org/10.1177/1687814016675080>.
104. Litjens, G. et al.: A survey on deep learning in medical image analysis. *Med. Image Anal.* 42, 60–88 (2017). <https://doi.org/10.1016/j.media.2017.07.005>.
105. Liu, C. et al.: Chatter detection in milling process based on VMD and energy entropy. *Mech. Syst. Signal Process.* 105, 169–182 (2018). <https://doi.org/10.1016/j.ymsp.2017.11.046>.
106. Liu, C. et al.: The chatter identification in end milling based on combining EMD and WPD. *Int. J. Adv. Manuf. Technol.* 91, 9, 3339–3348 (2017). <https://doi.org/10.1007/s00170-017-0024-8>.
107. Liu, H. et al.: Deep Learning-based Multimodal Control Interface for Human-Robot Collaboration. *Procedia CIRP*. 72, 3–8 (2018). <https://doi.org/10.1016/j.procir.2018.03.224>.
108. Liu, H. et al.: Towards Robust Human-Robot Collaborative Manufacturing: Multimodal Fusion. *IEEE Access*. 6, 74762–74771 (2018). <https://doi.org/10.1109/ACCESS.2018.2884793>.
109. Liu, J. et al.: A hybrid health condition monitoring method in milling operations. *Int. J. Adv. Manuf. Technol.* 92, 5–8, 2069–2080 (2017). <https://doi.org/10.1007/s00170-017-0252-y>.
110. Liu, M.-K. et al.: Hybrid model- and signal-based chatter detection in the milling process. *J. Mech. Sci. Technol.* 34, 1, 1–10 (2020). <https://doi.org/10.1007/s12206-019-1201-5>.
111. Liu, S. et al.: Multimodal Data-Driven Robot Control for Human–Robot Collaborative Assembly. *J. Manuf. Sci. Eng.* 144, 5, 051012 (2022). <https://doi.org/10.1115/1.4053806>.

112. Liu, T. et al.: Chatter detection in camshaft high-speed grinding process based on VMD parametric optimization. *Measurement*. 187, 110133 (2022). <https://doi.org/10.1016/j.measurement.2021.110133>.
113. Liu, Y. et al.: Early chatter detection in gear grinding process using servo feed motor current. *Int. J. Adv. Manuf. Technol.* 83, 9, 1801–1810 (2016). <https://doi.org/10.1007/s00170-015-7687-9>.
114. Lopez, M.M., Kalita, J.: Deep Learning applied to NLP. (2017). <https://doi.org/10.48550/ARXIV.1703.03091>.
115. Lu, J. et al.: Transfer learning using computational intelligence: A survey. *Knowl.-Based Syst.* 80, 14–23 (2015). <https://doi.org/10.1016/j.knosys.2015.01.010>.
116. Lu, L. et al.: Effects of Extrinsic Noise Factors on Machine Learning-Based Chatter Detection in Machining. *Smart Sustain. Manuf. Syst.* 5, 1, 167–180 (2021). <https://doi.org/10.1520/SSMS20210007>.
117. Lu, S. et al.: A review of stochastic resonance in rotating machine fault detection. *Mech. Syst. Signal Process.* 116, 230–260 (2019). <https://doi.org/10.1016/j.ymssp.2018.06.032>.
118. Luo, J., Zhang, X.: Convolutional neural network based on attention mechanism and Bi-LSTM for bearing remaining life prediction. *Appl. Intell.* 52, 1, 1076–1091 (2022). <https://doi.org/10.1007/s10489-021-02503-2>.
119. Lv, D. et al.: Fault diagnosis of rolling bearing based on multimodal data fusion and deep belief network. *Proc. Inst. Mech. Eng. Part C J. Mech. Eng. Sci.* 235, 22, 6577–6585 (2021). <https://doi.org/10.1177/09544062211008464>.
120. Ma, M. et al.: Deep Coupling Autoencoder for Fault Diagnosis With Multimodal Sensory Data. *IEEE Trans. Ind. Inform.* 14, 3, 1137–1145 (2018). <https://doi.org/10.1109/TII.2018.2793246>.
121. Maddi, A., OST: La position scientifique de la France dans le monde et en Europe, 2005-2018. (2021).
122. MALLAT, S.: A THEORY FOR MULTIREOLUTION SIGNAL DECOMPOSITION - THE WAVELET REPRESENTATION, (1989). <https://doi.org/10.1109/34.192463>.
123. Mallat, S.: Understanding deep convolutional networks. *Philos. Trans. R. Soc. Math. Phys. Eng. Sci.* 374, 2065, 20150203 (2016). <https://doi.org/10.1098/rsta.2015.0203>.
124. Manavalan, E., Jayakrishna, K.: A review of Internet of Things (IoT) embedded sustainable supply chain for industry 4.0 requirements. *Comput. Ind. Eng.* 127, 925–953 (2019). <https://doi.org/10.1016/j.cie.2018.11.030>.
125. Manhertz, G., Bereczky, A.: STFT spectrogram based hybrid evaluation method for rotating machine transient vibration analysis. *Mech. Syst. Signal Process.* 154, 107583 (2021). <https://doi.org/10.1016/j.ymssp.2020.107583>.
126. Marei, M., Li, W.: Cutting tool prognostics enabled by hybrid CNN-LSTM with transfer learning. *Int. J. Adv. Manuf. Technol.* 118, 3–4, 817–836 (2022). <https://doi.org/10.1007/s00170-021-07784-y>.
127. Martínez-Arellano, G. et al.: Tool wear classification using time series imaging and deep learning. *Int. J. Adv. Manuf. Technol.* 104, 9–12, 3647–3662 (2019). <https://doi.org/10.1007/s00170-019-04090-6>.
128. Merrit, H.: Theory of self-excited machine-tool chatter. *Trans ASME J Eng Ind.* 87, 4,

447 (1965).

129. Ming, Z. et al.: An analytical method to select spindle speed variation parameters for chatter suppression in NC machining. *J. Vibroengineering*. 16, 1, 447–463 (2014).

130. Moon, S. et al.: Multimodal Transfer Deep Learning with Applications in Audio-Visual Recognition. (2014). <https://doi.org/10.48550/ARXIV.1412.3121>.

131. Mou, L. et al.: Driver stress detection via multimodal fusion using attention-based CNN-LSTM. *Expert Syst. Appl.* 173, 114693 (2021). <https://doi.org/10.1016/j.eswa.2021.114693>.

132. Munoa, J. et al.: Chatter suppression techniques in metal cutting. *CIRP Ann.* 65, 2, 785–808 (2016). <https://doi.org/10.1016/j.cirp.2016.06.004>.

133. Nasir, V., Cool, J.: Intelligent wood machining monitoring using vibration signals combined with self-organizing maps for automatic feature selection. *Int. J. Adv. Manuf. Technol.* 108, 5–6, 1811–1825 (2020). <https://doi.org/10.1007/s00170-020-05505-5>.

134. Naushad, R. et al.: Deep Transfer Learning for Land Use and Land Cover Classification: A Comparative Study. *Sensors*. 21, 23, 8083 (2021). <https://doi.org/10.3390/s21238083>.

135. Nirwan, N.W., Ramani, H.B.: Condition monitoring and fault detection in roller bearing used in rolling mill by acoustic emission and vibration analysis. *Mater. Today Proc.* (2021). <https://doi.org/10.1016/j.matpr.2021.05.447>.

136. Ntemi, M. et al.: Infrastructure monitoring and quality diagnosis in CNC machining: A review. *CIRP J. Manuf. Sci. Technol.* 38, 631–649 (2022). <https://doi.org/10.1016/j.cirpj.2022.06.001>.

137. Okokpujie, I.P. et al.: Experimental data-set for prediction of tool wear during turning of Al-1061 alloy by high speed steel cutting tools. *Data Brief*. 18, 1196–1203 (2018). <https://doi.org/10.1016/j.dib.2018.04.003>.

138. Palade, V. et al.: Guest Editorial: Special Issue on Deep Representation and Transfer Learning for Smart and Connected Health. *IEEE Trans. Neural Netw. Learn. Syst.* 32, 2, 464–465 (2021). <https://doi.org/10.1109/TNNLS.2021.3049931>.

139. Pan, J. et al.: Boring chatter identification by multi-sensor feature fusion and manifold learning. *Int. J. Adv. Manuf. Technol.* 109, 3, 1137–1151 (2020). <https://doi.org/10.1007/s00170-020-05611-4>.

140. Peng, W. et al.: Chatter identification using HHT for boring process. Presented at the International Conference on Optical Instruments and Technology (OIT2013), Beijing, China December 23 (2013). <https://doi.org/10.1117/12.2037988>.

141. Poria, S. et al.: Fusing audio, visual and textual clues for sentiment analysis from multimodal content. *Neurocomputing*. 174, 50–59 (2016). <https://doi.org/10.1016/j.neucom.2015.01.095>.

142. Qin, Y. et al.: Macroscopic–Microscopic Attention in LSTM Networks Based on Fusion Features for Gear Remaining Life Prediction. *IEEE Trans. Ind. Electron.* 67, 12, 10865–10875 (2020). <https://doi.org/10.1109/TIE.2019.2959492>.

143. Rahate, A. et al.: Multimodal Co-learning: Challenges, applications with datasets, recent advances and future directions. *Inf. Fusion*. 81, 203–239 (2022). <https://doi.org/10.1016/j.inffus.2021.12.003>.

144. Rahimi, M.H. et al.: On-line chatter detection in milling with hybrid machine learning and physics-based model. *CIRP J. Manuf. Sci. Technol.* 35, 25–40 (2021).

<https://doi.org/10.1016/j.cirpj.2021.05.006>.

145. Ramachandram, D., Taylor, G.W.: Deep Multimodal Learning: A Survey on Recent Advances and Trends. *IEEE Signal Process. Mag.* 34, 6, 96–108 (2017). <https://doi.org/10.1109/MSP.2017.2738401>.

146. Ribeiro, M.T. et al.: “Why Should I Trust You?”: Explaining the Predictions of Any Classifier. (2016). <https://doi.org/10.48550/ARXIV.1602.04938>.

147. Rifai, A.P. et al.: Evaluation of turned and milled surfaces roughness using convolutional neural network. *Measurement.* 161, 107860 (2020). <https://doi.org/10.1016/j.measurement.2020.107860>.

148. Rother, A. et al.: A brief review and a first application of time-frequency-based analysis methods for monitoring of strip rolling mills. *J. Process Control.* 35, 65–79 (2015). <https://doi.org/10.1016/j.jprocont.2015.08.010>.

149. Rusinek, R. et al.: Dynamics Aspect of Chatter Suppression in Milling. In: Onate, E. et al. (eds.) 11th World Congress on Computational Mechanics; 5th European Conference on Computational Mechanics; 6th European Conference on Computational Fluid Dynamics, Vols Ii - Iv. pp. 3056–3067 Int Center Numerical Methods Engineering, 08034 Barcelona (2014).

150. Rusinek, R., Lajmert, P.: Chatter Detection in Milling of Carbon Fiber-Reinforced Composites by Improved Hilbert–Huang Transform and Recurrence Quantification Analysis. *Materials.* 13, 18, 4105 (2020). <https://doi.org/10.3390/ma13184105>.

151. Sait, U. et al.: A deep-learning based multimodal system for Covid-19 diagnosis using breathing sounds and chest X-ray images. *Appl. Soft Comput.* 109, 107522 (2021). <https://doi.org/10.1016/j.asoc.2021.107522>.

152. Schmidt, J. et al.: Recent advances and applications of machine learning in solid-state materials science. *Npj Comput. Mater.* 5, 1, 83 (2019). <https://doi.org/10.1038/s41524-019-0221-0>.

153. Selvaraju, R.R. et al.: Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization. (2016). <https://doi.org/10.48550/ARXIV.1610.02391>.

154. Sener, B. et al.: A novel chatter detection method for milling using deep convolution neural networks. *Measurement.* 182, 109689 (2021). <https://doi.org/10.1016/j.measurement.2021.109689>.

155. Sener, B. et al.: Intelligent Chatter Detection in Milling using Vibration Data Features and Deep Multi-Layer Perceptron. In: Wu, X.T. et al. (eds.) 2020 Ieee International Conference on Big Data (big Data). pp. 4759–4768 Ieee, New York (2020). <https://doi.org/10.1109/BigData50022.2020.9378223>.

156. Serin, G. et al.: Review of tool condition monitoring in machining and opportunities for deep learning. *Int. J. Adv. Manuf. Technol.* 109, 3, 953–974 (2020). <https://doi.org/10.1007/s00170-020-05449-w>.

157. Seyrek, P. et al.: An Evaluation Study of EMD, EEMD, and VMD For Chatter Detection in Milling. *Procedia Comput. Sci.* 200, 160–174 (2022). <https://doi.org/10.1016/j.procs.2022.01.215>.

158. Shao, Q. et al.: Hybrid PCA-SVM Method for Pattern Recognition of Chatter Gestation. In: 2011 Second International Conference on Digital Manufacturing Automation. pp. 598–601 (2011). <https://doi.org/10.1109/ICDMA.2011.149>.

159. Shao, Q., Feng, C.J.: Pattern Recognition of Chatter Gestation Based on Hybrid PCA-

- SVM. *Appl. Mech. Mater.* 120, 190–194 (2011). <https://doi.org/10.4028/www.scientific.net/AMM.120.190>.
160. Shen, B. et al.: Multimodal-based weld reinforcement monitoring system for wire arc additive manufacturing. *J. Mater. Res. Technol.* 20, 561–571 (2022). <https://doi.org/10.1016/j.jmrt.2022.07.086>.
161. Shi, F. et al.: A Reinforced k-Nearest Neighbors Method With Application to Chatter Identification in High-Speed Milling. *IEEE Trans. Ind. Electron.* 67, 12, 10844–10855 (2020). <https://doi.org/10.1109/TIE.2019.2962465>.
162. Shi, F. et al.: Chatter detection in high-speed milling processes based on ON-LSTM and PBT. *Int. J. Adv. Manuf. Technol.* 111, 11–12, 3361–3378 (2020). <https://doi.org/10.1007/s00170-020-06292-9>.
163. Shi, J. et al.: Planetary gearbox fault diagnosis using bidirectional-convolutional LSTM networks. *Mech. Syst. Signal Process.* 162, 107996 (2022). <https://doi.org/10.1016/j.ymsp.2021.107996>.
164. Shi, W. et al.: Application of Continuous Wavelet Features and Multi-Class Sphere SVM to Chatter Prediction. In: Wang, C.Y. et al. (eds.) *High Speed Machining*. pp. 675–680 Trans Tech Publications Ltd, Stafa-Zurich (2011). <https://doi.org/10.4028/www.scientific.net/AMR.188.675>.
165. Shrivastava, Y., Singh, B.: A comparative study of EMD and EEMD approaches for identifying chatter frequency in CNC turning. *Eur. J. Mech. - ASolids.* 73, 381–393 (2019). <https://doi.org/10.1016/j.euromechsol.2018.10.004>.
166. Siddhpura, M., Paurobally, R.: A review of chatter vibration research in turning. *Int. J. Mach. Tools Manuf.* 61, 27–47 (2012). <https://doi.org/10.1016/j.ijmachtools.2012.05.007>.
167. Simonyan, K., Zisserman, A.: Very Deep Convolutional Networks for Large-Scale Image Recognition. *ArXiv14091556 Cs.* (2015).
168. Sims, N.D.: Vibration absorbers for chatter suppression: A new analytical tuning methodology. *J. Sound Vib.* 301, 3, 592–607 (2007). <https://doi.org/10.1016/j.jsv.2006.10.020>.
169. Siyu, L. et al.: Deep Learning in Fault Diagnosis of Complex Mechanical Equipment. *Int. J. Perform. Eng.* 16, 10, 1548 (2020). <https://doi.org/10.23940/ijpe.20.10.p6.15481555>.
170. Smith, S., Tlustý, J.: Efficient Simulation Programs for Chatter in Milling. *CIRP Ann.* 42, 1, 463–466 (1993). [https://doi.org/10.1016/S0007-8506\(07\)62486-X](https://doi.org/10.1016/S0007-8506(07)62486-X).
171. Song, K. et al.: Intelligent recognition of milling cutter wear state with cutting parameter independence based on deep learning of spindle current clutter signal. *Int. J. Adv. Manuf. Technol.* 109, 3–4, 929–942 (2020). <https://doi.org/10.1007/s00170-020-05587-1>.
172. Stahlschmidt, S.R. et al.: Multimodal deep learning for biomedical data fusion: a review. *Brief. Bioinform.* 23, 2, bbab569 (2022). <https://doi.org/10.1093/bib/bbab569>.
173. Sun, C. et al.: Deep Transfer Learning Based on Sparse Autoencoder for Remaining Useful Life Prediction of Tool in Manufacturing. *IEEE Trans. Ind. Inform.* 15, 4, 2416–2425 (2019). <https://doi.org/10.1109/TII.2018.2881543>.
174. Sun, Y. et al.: Beat Effect in Machining Chatter: Analysis and Detection. *J. Manuf. Sci. Eng.* 143, 1, (2020). <https://doi.org/10.1115/1.4047736>.
175. Sun, Y. et al.: Online chatter detection considering beat effect based on Inception and LSTM neural networks. *Mech. Syst. Signal Process.* 184, 109723 (2023).

<https://doi.org/10.1016/j.ymsp.2022.109723>.

176. Susanto, A. et al.: Application of Hilbert–Huang transform for vibration signal analysis in end-milling. *Precis. Eng.* 53, 263–277 (2018). <https://doi.org/10.1016/j.precisioneng.2018.04.008>.

177. Susanto, A. et al.: Chatter identification in turning process based on vibration analysis using Hilbert-Huang transform. *J. Mech. Eng. Sci.* 14, 2, 6856–6868 (2020). <https://doi.org/10.15282/14.2.2020.25.0537>.

178. Szegedy, C. et al.: Rethinking the Inception Architecture for Computer Vision. *ArXiv151200567 Cs.* (2015).

179. Tansel, I.N. et al.: Detecting chatter and estimating wear from the torque of end milling signals by using Index Based Reasoner (IBR). *Int. J. Adv. Manuf. Technol.* 58, 1–4, 109–118 (2012). <https://doi.org/10.1007/s00170-010-2838-5>.

180. Tarng, Y. et al.: Online Drilling Chatter Recognition and Avoidance Using an Art2 - a Neural-Network. *Int. J. Mach. Tools Manuf.* 34, 7, 949–957 (1994). [https://doi.org/10.1016/0890-6955\(94\)90027-2](https://doi.org/10.1016/0890-6955(94)90027-2).

181. Tarng, Y., Chen, M.: An Intelligent Sensor for Detection of Milling Chatter. *J. Intell. Manuf.* 5, 3, 193–200 (1994). <https://doi.org/10.1007/BF00123923>.

182. Taylor, F.W.: On the art cutting metals. *Trans ASME.* 29, 31–350 (1906).

183. Taylor, F.W.: On the art of cutting metals,. American Society of mechanical engineers, New York (1907).

184. Taylor, F.W.: Taylor : sur l’art de couper les métaux - Google Scholar. New York, The American Society of Mechanical Engineers, [1907].

185. Teti, R. et al.: Advanced monitoring of machining operations. *CIRP Ann.* 59, 2, 717–739 (2010). <https://doi.org/10.1016/j.cirp.2010.05.010>.

186. Thaler, T. et al.: Chatter detection in band sawing based on discriminant analysis of sound features. *Appl. Acoust.* 77, 114–121 (2014). <https://doi.org/10.1016/j.apacoust.2012.12.004>.

187. Tlustý, J.: The stability of the machine tool against self-excited vibration in machining. *Proc Int Res Prod. Eng. Pittsburgh ASME.* 465, (1963).

188. Tlustý, J., Špaček, L.: Samobuzené kmity v obráběcích strojích. ČSAV (1954).

189. Tobias, S., Fishwick, W.: Theory of regenerative machine tool chatter. *The engineer.* 205, 7, 199–203 (1958).

190. Tran, M.-Q. et al.: Effective multi-sensor data fusion for chatter detection in milling process. *ISA Trans.* (2021). <https://doi.org/10.1016/j.isatra.2021.07.005>.

191. Tran, M.-Q. et al.: Milling chatter detection using scalogram and deep convolutional neural network. *Int. J. Adv. Manuf. Technol.* 107, 3, 1505–1516 (2020). <https://doi.org/10.1007/s00170-019-04807-7>.

192. Uekita, M., Takaya, Y.: Tool condition monitoring technique for deep-hole drilling of large components based on chatter identification in time–frequency domain. *Measurement.* 103, 199–207 (2017). <https://doi.org/10.1016/j.measurement.2017.02.035>.

193. Ullah, F. et al.: Machine health surveillance system by using deep learning sparse autoencoder. *Soft Comput.* 26, 16, 7737–7750 (2022). <https://doi.org/10.1007/s00500-022->

06755-z.

194. Unver, H.O., Sener, B.: A novel transfer learning framework for chatter detection using convolutional neural networks. *J. Intell. Manuf.* (2021). <https://doi.org/10.1007/s10845-021-01839-3>.
195. Usuga Cadavid, J.P. et al.: Machine learning applied in production planning and control: a state-of-the-art in the era of industry 4.0. *J. Intell. Manuf.* 31, 6, 1531–1558 (2020). <https://doi.org/10.1007/s10845-019-01531-7>.
196. Varghese, A. et al.: Tool life stage prediction in micro-milling from force signal analysis using machine learning methods. *J. Manuf. Sci. Eng.* 143, 5, (2021).
197. Vashisht, R.K., Peng, Q.: Online Chatter Detection for Milling Operations Using LSTM Neural Networks Assisted by Motor Current Signals of Ball Screw Drives. *J. Manuf. Sci. Eng.* 143, 1, (2020). <https://doi.org/10.1115/1.4048001>.
198. Venema, G.: *The foundations of geometry*. Pearson Prentice Hall, Upper Saddle River, N.J (2006).
199. Vinyals, O. et al.: Show and Tell: A Neural Image Caption Generator. (2014). <https://doi.org/10.48550/ARXIV.1411.4555>.
200. Vishwakarma, M. et al.: Vibration Analysis & Condition Monitoring for Rotating Machines: A Review. *Mater. Today Proc.* 4, 2, Part A, 2659–2664 (2017). <https://doi.org/10.1016/j.matpr.2017.02.140>.
201. Wan, J. et al.: Toward Dynamic Resources Management for IoT-Based Manufacturing. *IEEE Commun. Mag.* 56, 2, 52–59 (2018). <https://doi.org/10.1109/MCOM.2018.1700629>.
202. Wan, S. et al.: Investigation on milling chatter identification at early stage with variance ratio and Hilbert-Huang transform. *Int. J. Adv. Manuf. Technol.* 95, 9–12, 3563–3573 (2018). <https://doi.org/10.1007/s00170-017-1410-y>.
203. Wan, S. et al.: Milling chatter detection by multi-feature fusion and Adaboost-SVM. *Mech. Syst. Signal Process.* 156, 107671 (2021). <https://doi.org/10.1016/j.ymsp.2021.107671>.
204. Wang, C. et al.: An experimental investigation on ultra-precision instrumented smart aerostatic bearing spindle applied to high speed micro-drilling. *J. Manuf. Process.* 31, 324–335 (2018). <https://doi.org/10.1016/j.jmapro.2017.11.022>.
205. Wang, E. et al.: A Hybrid Chatter Detection Method Based on WPD, SSA, and SVM-PSO. *Shock Vib.* 2020, e7943807 (2020). <https://doi.org/10.1155/2020/7943807>.
206. Wang, H., Ji, Y.: A Revised Hilbert–Huang Transform and Its Application to Fault Diagnosis in a Rotor System. *Sensors.* 18, 12, 4329 (2018). <https://doi.org/10.3390/s18124329>.
207. Wang, J. et al.: Deep learning for smart manufacturing: Methods and applications. *J. Manuf. Syst.* 48, 144–156 (2018). <https://doi.org/10.1016/j.jmsy.2018.01.003>.
208. Wang, L., Liang, M.: Chatter detection based on probability distribution of wavelet modulus maxima. *Robot. Comput.-Integr. Manuf.* 25, 6, 989–998 (2009). <https://doi.org/10.1016/j.rcim.2009.04.011>.
209. Wang, M., Fei, R.Y.: On-line chatter detection and control in boring based on an electrorheological fluid. *Mechatronics.* 11, 7, 779–792 (2001). [https://doi.org/10.1016/S0957-4158\(00\)00044-1](https://doi.org/10.1016/S0957-4158(00)00044-1).
210. Wang, P. et al.: Comparative analysis of image classification algorithms based on traditional machine learning and deep learning. *Pattern Recognit. Lett.* 141, 61–67 (2021).

<https://doi.org/10.1016/j.patrec.2020.07.042>.

211. Wang, Y. et al.: A kMap optimized VMD-SVM model for milling chatter detection with an industrial robot. *J. Intell. Manuf.* (2021). <https://doi.org/10.1007/s10845-021-01736-9>.
212. Wang, Y. et al.: Mirror milling chatter identification using Q-factor and SVM. *Int. J. Adv. Manuf. Technol.* 98, 5–8, 1163–1177 (2018). <https://doi.org/10.1007/s00170-018-2318-x>.
213. Werner, R.F., Farrelly, T.: Uncertainty from Heisenberg to Today. *Found. Phys.* 49, 6, 460–491 (2019). <https://doi.org/10.1007/s10701-019-00265-z>.
214. Xi, S. et al.: Zoom synchrosqueezing transform-based chatter identification in the milling process. *Int. J. Adv. Manuf. Technol.* 101, 5–8, 1197–1213 (2019). <https://doi.org/10.1007/s00170-018-3002-x>.
215. Xiang, L. et al.: Condition monitoring and anomaly detection of wind turbine based on cascaded and bidirectional deep learning networks. *Appl. Energy.* 305, 117925 (2022). <https://doi.org/10.1016/j.apenergy.2021.117925>.
216. Xiong, D. et al.: Deep Learning for EMG-based Human-Machine Interaction: A Review. *IEEECAA J. Autom. Sin.* 8, 3, 512–533 (2021). <https://doi.org/10.1109/JAS.2021.1003865>.
217. Xiong, S. et al.: A Novel End-To-End Fault Diagnosis Approach for Rolling Bearings by Integrating Wavelet Packet Transform into Convolutional Neural Network Structures. *Sensors.* 20, 17, 4965 (2020). <https://doi.org/10.3390/s20174965>.
218. Xu, L.M. et al.: Analysis of Chatter Marks in Accurate Grinding on Optical Curve Grinder. *Key Eng. Mater.* 304–305, 497–501 (2006). <https://doi.org/10.4028/www.scientific.net/KEM.304-305.497>.
219. Xu, X. et al.: A novel multi-scale CNN and attention mechanism method with multi-sensor signal for remaining useful life prediction. *Comput. Ind. Eng.* 169, 108204 (2022). <https://doi.org/10.1016/j.cie.2022.108204>.
220. Xu, Y. et al.: A hybrid deep-learning model for fault diagnosis of rolling bearings. *Measurement.* 169, 108502 (2021). <https://doi.org/10.1016/j.measurement.2020.108502>.
221. Yan, H. et al.: Industrial Big Data Analytics for Prediction of Remaining Useful Life Based on Deep Learning. *IEEE Access.* 6, 17190–17197 (2018). <https://doi.org/10.1109/ACCESS.2018.2809681>.
222. Yan, S., Sun, Y.: Early chatter detection in thin-walled workpiece milling process based on multi-synchrosqueezing transform and feature selection. *Mech. Syst. Signal Process.* 108622 (2021). <https://doi.org/10.1016/j.ymssp.2021.108622>.
223. Yang, K. et al.: Early chatter identification based on an optimized variational mode decomposition. *Mech. Syst. Signal Process.* 115, 238–254 (2019). <https://doi.org/10.1016/j.ymssp.2018.05.052>.
224. Yang, Z. et al.: A multi-branch deep neural network model for failure prognostics based on multimodal data. *J. Manuf. Syst.* 59, 42–50 (2021). <https://doi.org/10.1016/j.jmsy.2021.01.007>.
225. Yao, Z. et al.: On-line chatter detection and identification based on wavelet and support vector machine. *J. Mater. Process. Technol.* 210, 5, 713–719 (2010). <https://doi.org/10.1016/j.jmatprotec.2009.11.007>.

226. Yesilli, M.C. et al.: Chatter detection in turning using machine learning and similarity measures of time series via dynamic time warping. *J. Manuf. Process.* 77, 190–206 (2022). <https://doi.org/10.1016/j.jmapro.2022.03.009>.
227. Yesilli, M.C. et al.: On transfer learning for chatter detection in turning using wavelet packet transform and ensemble empirical mode decomposition. *CIRP J. Manuf. Sci. Technol.* 28, 118–135 (2020). <https://doi.org/10.1016/j.cirpj.2019.11.003>.
228. Yesilli, M.C. et al.: Topological feature vectors for chatter detection in turning processes. *Int. J. Adv. Manuf. Technol.* (2022). <https://doi.org/10.1007/s00170-021-08242-5>.
229. Yoon, M.C., Chin, D.H.: Cutting force monitoring in the endmilling operation for chatter detection. *Proc. Inst. Mech. Eng. Part B J. Eng. Manuf.* 219, 6, 455–465 (2005). <https://doi.org/10.1243/095440505X32292>.
230. Yu, B. et al.: Feature-guided Multimodal Sentiment Analysis towards Industry 4.0. *Comput. Electr. Eng.* 100, 107961 (2022). <https://doi.org/10.1016/j.compeleceng.2022.107961>.
231. Yu, J., Liu, G.: Knowledge extraction and insertion to deep belief network for gearbox fault diagnosis. *Knowl.-Based Syst.* 197, 105883 (2020). <https://doi.org/10.1016/j.knosys.2020.105883>.
232. Yu, W. et al.: Remaining useful life estimation using a bidirectional recurrent neural network based autoencoder scheme. *Mech. Syst. Signal Process.* 129, 764–780 (2019). <https://doi.org/10.1016/j.ymssp.2019.05.005>.
233. Zhang, B., Shin, Y.C.: A multimodal intelligent monitoring system for turning processes. *J. Manuf. Process.* 35, 547–558 (2018). <https://doi.org/10.1016/j.jmapro.2018.08.021>.
234. Zhang, S. et al.: Rotating machinery fault detection and diagnosis based on deep domain adaptation: A survey. *Chin. J. Aeronaut.* (2021). <https://doi.org/10.1016/j.cja.2021.10.006>.
235. Zhang, Y., Ji, J.: Intelligent Fault Diagnosis of a Reciprocating Compressor Using Mode Isolation Convolutional Deep Belief Networks. *IEEEASME Trans. Mechatron.* 26, 3, 1668–1677 (2021). <https://doi.org/10.1109/TMECH.2020.3027912>.
236. Zhang, Z. et al.: Chatter detection in milling process based on the energy entropy of VMD and WPD. *Int. J. Mach. Tools Manuf.* 108, 106–112 (2016). <https://doi.org/10.1016/j.ijmachtools.2016.06.002>.
237. Zhao, R. et al.: Deep learning and its applications to machine health monitoring. *Mech. Syst. Signal Process.* 115, 213–237 (2019). <https://doi.org/10.1016/j.ymssp.2018.05.050>.
238. Zheng, Q. et al.: Chatter detection in milling process based on the combination of wavelet packet transform and PSO-SVM. <https://doi.org/10.1007/s00170-022-08856-3>.
239. Zhou, F. et al.: A Multimodal Feature Fusion-Based Deep Learning Method for Online Fault Diagnosis of Rotating Machinery. *Sensors.* 18, 10, 3521 (2018). <https://doi.org/10.3390/s18103521>.
240. Zhou, J.-T. et al.: Tool remaining useful life prediction method based on LSTM under variable working conditions. *Int. J. Adv. Manuf. Technol.* 104, 9–12, 4715–4726 (2019). <https://doi.org/10.1007/s00170-019-04349-y>.
241. Zhu, L. et al.: Vibration recognition for peripheral milling thin-walled workpieces using sample entropy and energy entropy. *Int. J. Adv. Manuf. Technol.* 108, 9–10, 3251–3266 (2020). <https://doi.org/10.1007/s00170-020-05476-7>.

242. Zhu, W. et al.: An optimized convolutional neural network for chatter detection in the milling of thin-walled parts. *Int. J. Adv. Manuf. Technol.* 106, 9, 3881–3895 (2020). <https://doi.org/10.1007/s00170-019-04899-1>.

243. Zhu, W. et al.: End-to-end driving model based on deep learning and attention mechanism. *J. Intell. Fuzzy Syst.* 42, 4, 3337–3348 (2022). <https://doi.org/10.3233/JIFS-211206>.