



N° d'ordre NNT : 2023ISAL0048

THÈSE DE DOCTORAT DE L'UNIVERSITÉ DE LYON
opérée au sein de
l'INSA de Lyon

École Doctorale N° 162
Mécanique, Énergétique, Génie Civil et Acoustique (MÉGA)

Spécialité/discipline de doctorat :
Génie Mécanique

Soutenue publiquement le 11/07/2023, par :
Alizée BOUCHOT épouse MADRIGNAC

**Identification quantitative de caractéristiques
physiques des interfaces solides en lien avec les
propriétés tribologiques**

Devant le jury composé de :

Vincent MAGNIER	Maître de conférences, HDR	Polytech Lille	Rapporteur
David FOFI	Professeur des universités	Université de Bourgogne	Rapporteur
Sylvain PHILIPPON	Professeur des universités	Ecole nationale d'ingénieurs de Metz	Examineur
Caroline RICHARD	Professeur des universités	Université de Tours	Examinatrice
Sylvie DESCARTES	Ingénieur de recherche, HDR	INSA Lyon	Directrice de thèse
Johan DEBAYLE	Professeur de l'IMT	Mines St Etienne	Co-directeur de thèse
Guilhem MOLLON	Maître de conférences, HDR	INSA Lyon	Co-directeur de thèse
Yann GAVET	Professeur de l'IMT, HDR	Mines St Etienne	Invité

Référence : TH0978_ Alizée BOUCHOT MADRIGNAC

L'INSA Lyon a mis en place une procédure de contrôle systématique via un outil de détection de similitudes (logiciel Compilatio). Après le dépôt du manuscrit de thèse, celui-ci est analysé par l'outil. Pour tout taux de similarité supérieur à 10%, le manuscrit est vérifié par l'équipe de FEDORA. Il s'agit notamment d'exclure les auto-citations, à condition qu'elles soient correctement référencées avec citation expresse dans le manuscrit.

Par ce document, il est attesté que ce manuscrit, dans la forme communiquée par la personne doctorante à l'INSA Lyon, satisfait aux exigences de l'Établissement concernant le taux maximal de similitude admissible.

Département FEDORA – INSA Lyon - Ecoles Doctorales

SIGLE	ECOLE DOCTORALE	NOM ET COORDONNEES DU RESPONSABLE
CHIMIE	CHIMIE DE LYON https://www.edchimie-lyon.fr Sec. : Renée EL MELHEM Bât. Blaise PASCAL, 3e étage secretariat@edchimie-lyon.fr	M. Stéphane DANIELE C2P2-CPE LYON-UMR 5265 Bâtiment F308, BP 2077 43 Boulevard du 11 novembre 1918 69616 Villeurbanne directeur@edchimie-lyon.fr
E.E.A.	ÉLECTRONIQUE, ÉLECTROTECHNIQUE, AUTOMATIQUE https://edeea.universite-lyon.fr Sec. : Stéphanie CAUVIN Bâtiment Direction INSA Lyon Tél : 04.72.43.71.70 secretariat.edeea@insa-lyon.fr	M. Philippe DELACHARTRE INSA LYON Laboratoire CREATIS Bâtiment Blaise Pascal, 7 avenue Jean Capelle 69621 Villeurbanne CEDEX Tél : 04.72.43.88.63 philippe.delachartre@insa-lyon.fr
E2M2	ÉVOLUTION, ÉCOSYSTÈME, MICROBIOLOGIE, MODÉLISATION http://e2m2.universite-lyon.fr Sec. : Bénédicte LANZA Bât. Atrium, UCB Lyon 1 Tél : 04.72.44.83.62 secretariat.e2m2@univ-lyon1.fr	Mme Sandrine CHARLES Université Claude Bernard Lyon 1 UFR Biosciences Bâtiment Mendel 43, boulevard du 11 Novembre 1918 69622 Villeurbanne CEDEX sandrine.charles@univ-lyon1.fr
EDISS	INTERDISCIPLINAIRE SCIENCES-SANTÉ http://ediss.universite-lyon.fr Sec. : Bénédicte LANZA Bât. Atrium, UCB Lyon 1 Tél : 04.72.44.83.62 secretariat.ediss@univ-lyon1.fr	Mme Sylvie RICARD-BLUM Institut de Chimie et Biochimie Moléculaires et Supramoléculaires (ICBMS) - UMR 5246 CNRS - Université Lyon 1 Bâtiment Raulin - 2ème étage Nord 43 Boulevard du 11 novembre 1918 69622 Villeurbanne Cedex Tél : +33(0)4 72 44 82 32 sylvie.ricard-blum@univ-lyon1.fr
INFOMATHS	INFORMATIQUE ET MATHÉMATIQUES http://edinfomaths.universite-lyon.fr Sec. : Renée EL MELHEM Bât. Blaise PASCAL, 3e étage Tél : 04.72.43.80.46 infomaths@univ-lyon1.fr	M. Hamamache KHEDDOUCI Université Claude Bernard Lyon 1 Bât. Nautibus 43, Boulevard du 11 novembre 1918 69 622 Villeurbanne Cedex France Tél : 04.72.44.83.69 hamamache.kheddouci@univ-lyon1.fr
Matériaux	MATÉRIAUX DE LYON http://ed34.universite-lyon.fr Sec. : Yann DE ORDENANA Tél : 04.72.18.62.44 yann.de-ordenana@ec-lyon.fr	M. Stéphane BENAYOUN Ecole Centrale de Lyon Laboratoire LTDS 36 avenue Guy de Collongue 69134 Ecully CEDEX Tél : 04.72.18.64.37 stephane.benayoun@ec-lyon.fr
MEGA	MÉCANIQUE, ÉNERGÉTIQUE, GÉNIE CIVIL, ACOUSTIQUE http://edmega.universite-lyon.fr Sec. : Stéphanie CAUVIN Tél : 04.72.43.71.70 Bâtiment Direction INSA Lyon mega@insa-lyon.fr	M. Jocelyn BONJOUR INSA Lyon Laboratoire CETHIL Bâtiment Sadi-Carnot 9, rue de la Physique 69621 Villeurbanne CEDEX jocelyn.bonjour@insa-lyon.fr
ScSo	ScSo* https://edsciencessociales.universite-lyon.fr Sec. : Mélina FAVETON INSA : J.Y. TOUSSAINT Tél : 04.78.69.77.79 melina.faveton@univ-lyon2.fr	M. Bruno MILLY Université Lumière Lyon 2 86 Rue Pasteur 69365 Lyon CEDEX 07 bruno.milly@univ-lyon2.fr

*ScSo : Histoire, Géographie, Aménagement, Urbanisme, Archéologie, Science politique, Sociologie, Anthropologie

Je dédie ce manuscrit à mon grand père qui m'a transmis l'amour des mathématiques et des sciences.

TABLE DES MATIÈRES

	Page
Résumé	13
Abstract	15
Abréviation et définitions	17
Introduction	19
I État de l'art et stratégie	23
I La tribologie	25
1 Le contact	25
1.1 Contact élastique : Théorie de Hertz	25
1.2 L'aire de contact	27
1.3 Le contact adhésif	27
2 Frottement et usure	28
2.1 Le frottement	28
2.2 L'usure	30
3 Matériaux et tribologie	31
3.1 Le triplet tribologique	31
3.2 Le troisième corps dans tous ses états	35
4 Conclusion	38
II Le traitement et l'analyse d'image pour la tribologie	39
1 Qu'est ce qu'une image ?	39
2 Les étapes clés du traitement et de l'analyse d'images	41
2.1 L'affichage	41
2.2 Les filtres	42
2.3 Segmentation	43

2.4	Opérations morphologiques	45
2.5	Mesures	46
3	Analyse d'image et troisième corps	46
4	Conclusions	50
III Le <i>machine learning</i> appliqué aux études tribologiques		51
1	Qu'est ce que <i>le machine learning</i> ?	51
2	Comment utiliser le <i>machine learning</i>	53
2.1	Le pré-processing	54
2.2	La phase d'apprentissage	54
2.3	La phase d'évaluation	55
3	Algorithmes utilisés dans ce projet	56
3.1	Ajustement des hyperparamètres	57
4	Le <i>machine learning</i> au service de la tribologie	59
4.1	Objectifs	59
4.2	<i>Machine learning</i> et classification	61
4.3	<i>Machine learning</i> et prédiction	65
4.4	Observations et conclusions	66
5	Conclusions	66
II Projet Morpho-Tribo		69
IV Tribologie		71
1	Banc d'essai et conditions expérimentales	71
2	Données rhéologiques	76
3	Observations morphologiques du troisième corps	79
3.1	Protocole d'acquisition des images	79
3.2	Analyse qualitative du troisième corps	80
4	Analyse morphologique des images de particules	86
4.1	Segmentation d'images par apprentissage automatique	86
4.1.1	Schéma du processus de segmentation	87
4.1.2	Etude des performances de l'algorithme de ML	89
4.2	Détection de régions et extraction de caractéristiques	93
5	Analyse d'image des textures de troisième corps	95
5.1	Extraction des paramètres de texture	96
5.2	Interprétation des features de texture	96
6	Conclusion	97
V Morpho-Tribo		101
1	Première approche par étude graphique et analyse de sensibilité	101
1.1	Le flux d'usure	101
1.2	Le flux de recirculation	104
1.3	Conclusions	106
2	Etude morpho-tribo par <i>machine learning</i>	107

2.1	Construction des bases de données	107
2.2	Mise en œuvre et sélection de la base de données	108
2.3	Validation de la base de données	114
2.4	Évolution de la base de données.	116
3	Étude d'influence des features	119
3.1	Etude de l'influence des features	120
3.2	Sélection des features et bases réduites	125
4	Conclusion	130
VI Conclusions générales		133
1	Conclusions	133
2	Perspectives	134
2.1	Evolution de la base de données	134
2.2	Mesures in situ	135
2.3	Tentatives de corrélation avec les simulations numériques	137
2.4	Changement d'approche?	137
A Mécanique du solide		139
B Analyse des paramètres d'acquisition en microscopie		141
1	Influence de la vitesse de balayage	141
2	Influence du contraste et de la brillance	142
3	Influence de la tension d'accélération	144
C Photos des disques		147
D Cartes de frottement		149
E Images MEB		163
Bibliographie		180
Liste des figures		185
Liste des tableaux		187
Liste des crédits		189

Ce travail de thèse vise à apporter de nouvelles briques de compréhension du frottement dans les contacts non lubrifiés (frottement sec). Jusqu'à présent les scénarii quant à l'histoire du contact sont construits qualitativement. Nous nous proposons d'enrichir ces derniers à l'aide de quantifieurs relatifs à la morphologie de l'interface, nommée troisième corps. Ainsi, nous allons chercher à relier les caractéristiques morphologiques aux données rhéologiques tel que le coefficient de frottement (COF). Pour cela, le travail se déroule en quatre étapes. Tout d'abord les expérimentations tribologiques, réalisées sur un tribomètre de type pion-disque, permettent l'acquisition des signaux temporels de la force tangentielle, pour plusieurs conditions d'essais. Deuxièmement, les mesures expérimentales sont analysées, i.e. évolution du COF, et l'analyse post-mortem des surfaces frottées basée sur l'acquisition des images de l'interface à l'aide d'un microscope électronique à balayage. La troisième étape consiste à traiter et analyser les images acquises. Les images sont divisées en 2 catégories : les images de particules pour lesquelles une segmentation est opérée et les images de texture sur lesquelles sont calculées les matrices de cooccurrence. Il est alors possible d'extraire des caractéristiques de ces 2 catégories, des métriques relatives à la taille et la forme des particules segmentées et des métriques statistiques d'ordre deux des matrices de cooccurrence. L'ensemble de ces données caractérise le troisième corps. La dernière étape consiste en la recherche de corrélations entre morphologies caractéristiques du troisième corps et données rhéologiques. Pour cela des bases de données sont construites et un algorithme de machine learning de type random forest (RF) est mis en place. La RF permet de réaliser des prédictions du COF à partir des caractéristiques de l'interface, ainsi que de déterminer quelles sont les caractéristiques pertinentes menant à cette prédiction. Il est finalement possible d'élaguer la liste des caractéristiques pour ne garder que les plus représentative du frottement.

Mots clés : Contact sec, usure, MEB, troisième corps, tribologie, analyse d'image, *machine learning*.

This thesis aims to better understand the friction in non-lubricated contacts (dry friction). Until now it was possible to build scenarios about the history of the contact, we propose here to support them with quantifiers related to the morphology of the interface, called third body.

For this purpose, we will try to link the morphological characteristics to rheological data such as the coefficient of friction (COF). To do this, we must proceed in four steps: tribological experiments, post-mortem analysis, image processing and analysis and finally research of morpho-tribo correlations.

The experimentation is carried out on a disk-pion tribometer allowing the acquisition of the COF, for several test conditions. The post-mortem analyses consist of the analysis of the experimental data and the acquisition of images of the interface using a scanning electron microscope.

The images are then divided into 2 categories, the particle images which will undergo a segmentation and the texture images on which the co-occurrence matrices will be calculated. It is then possible to extract features from these 2 categories, metrics related to the size and shape of the segmented particles and second order statistical metrics from the co-occurrence matrices.

All these data are used to characterize the third body, so we will try to link them to the measured COF. For this purpose, a machine learning algorithm of the random forest (RF) type is implemented. The RF will allow us to make predictions of the COF from the characteristics of the interface, and will also allow us to determine which are the relevant characteristics leading to this prediction. It will then be possible to prune the list of features to keep only those most representative of the friction.

Keywords: Dry contact, wear, MEB, third body, tribology, image processing, *machine learning*.

ABRÉVIATIONS ET DÉFINITIONS

Abréviations

MEB : Microscope Électronique à Balayage.

COF : Coefficient de Frottement.

ML : *Machine Learning*.

MLP : Multi Layer Perceptron, réseau de neurones.

RF : Random Forest.

Vocabulaire de *machine learning*

Dans ce travail de thèse la bibliothèque Python *scikit learn* est utilisée dans sa version 1.0. Ci après quelques mots de vocabulaire permettant d'apprendre les sujets traité dans cette étude.

Base de données : Tableau regroupant les observations (ou échantillons).

Features : Descripteurs ou caractéristiques des échantillons de la base de données.

Label : Aussi appelé étiquettes, prenant la forme d'une catégorie en cas de classification ou d'une valeur en cas de régression.

Algorithme \neq Modèle : Un algorithme est une "forme" de ML, comme le MLP, la RF, ... on parle de modèle une fois ce dernier entraîné.

Hyperparamètres : Paramètres permettant de calibrer un modèle.

GridSearchCV* et *RandomizedSearchCV : Méthode de la bibliothèque *scikit-learn* pour optimiser les hyperparamètres.

Le frottement. Pourquoi étudier le frottement ?

Mécanisme quotidien, il est omniprésent. Il peut être créatif et moteur artistique, comme lors de la pratique d'un instrument à cordes comme le violon, caché dans les actions du quotidien comme le brossage des dents [Descartes *et al.*, 2015], peut être indispensable et sécuritif (plaquettes de frein) [Fillot *et al.*, 2004], à l'échelle humaine dans une prothèse de hanche [Unsworth, 1991] ou à l'échelle de la planète dans les failles sismiques [Casas *et al.*, 2022 ; Marone, 1998].

Une autre composante distincte mais pouvant lui être intimement liée, l'usure, est également un point d'intérêt majeur. En effet l'usure a un coût, tant économique qu'écologique. Dans une ère où le développement durable et l'économie de ressources et d'énergie deviennent des préoccupations de premier plan, il devient indispensable d'approfondir nos connaissances du frottement et de l'usure. Prenons des exemples concrets pour illustrer nos propos. Considérons l'usure des pneus sur la chaussée, on constate une émission de particules d'usure de la gomme, particules pouvant être dispersées dans l'air entraînant des problèmes de pollution, mais également une usure plus ou moins rapide des pneus qu'il faudra alors changer [Donaldson *et al.*, 2000 ; Kreider *et al.*, 2010 ; Orellano *et al.*, 2020]. Un autre aspect de ce changement de vision vis à vis de l'étude du frottement et de l'usure est économique. En effet avant les années 70, on considérait qu'une pièce qui s'use vite est une pièce que l'on remplace régulièrement donc une plus-value pour l'entreprise fabriquant la pièce. Aujourd'hui les mentalités et les technologies à notre disposition ont changé et permettent de faire des pièces plus durables et de mettre en place des protocoles de maintenance prédictive [Chung & Wang, 2013 ; Peng, 2002].

Ainsi contrôler le frottement revient à contrôler ses coûts et son impact sur le monde, pour cela le moyen d'investigation à notre disposition est l'étude de l'interface frottée. Il est donc nécessaire d'observer cette interface à plusieurs échelles, macroscopique afin d'évaluer la zone de contact dans sa globalité et de la caractériser : est-elle ponctuelle ? étendue ? oxydée (y a-t-il eu une réaction chimique en surface ?) ? Puis il faut regarder à l'échelle microscopique et détecter la présence de configurations particulières. Y a-t-il

des particules ? de la matière "arrachée" ? étalée ? lissée ? C'est la présence, ou l'absence de ces éléments sur l'interface frottée qui va permettre d'élaborer un scénario quant à la vie du contact [Descartes, 1997]. De plus les détachements de matière, leur quantité, ainsi que leur forme vont également apporter de l'information relative aux mécanismes d'usure en action dans le contact [Roylance & Raadnu, 1994]. La tribologie est donc l'étude de cette interface [Godet, 1984], tant d'un point de vue du frottement que de l'usure. Les techniques d'analyse d'image que nous exposerons en chapitre II permettront de nommer de façon concrète ces morphologies et configurations que l'oeil du tribologue expérimenté évalue pour raconter l'histoire du contact. Les corrélations que ce dernier effectue restent qualitatives et fortement liées à l'appréciation et l'expérience du tribologue.

C'est pourquoi des outils de *machine learning* seront mis en place afin de déterminer si des informations tribologiques telles que le coefficient de frottement, présenté en chapitre I sont gardées en mémoire dans l'interface frottée, et s'il est possible de les prédire à partir des caractéristiques quantitatives extraites des images.

Il existe vraisemblablement des descripteurs morphologiques plus pertinents que d'autre quand il est question de décrire le frottement. Ainsi le second aspect de ce travail sera de rechercher parmi les caractéristiques extraites des images de l'interface, lesquelles sont discriminantes pour réaliser la prédiction.

Il est toutefois primordial de préciser que le frottement cache une multitude de phénomènes physiques [Vakis et al., 2018] et que l'évolution de la morphologie de l'interface n'en est qu'un seul élément constitutif. La Figure 1 apporte une représentation qualitative de ces phénomènes.

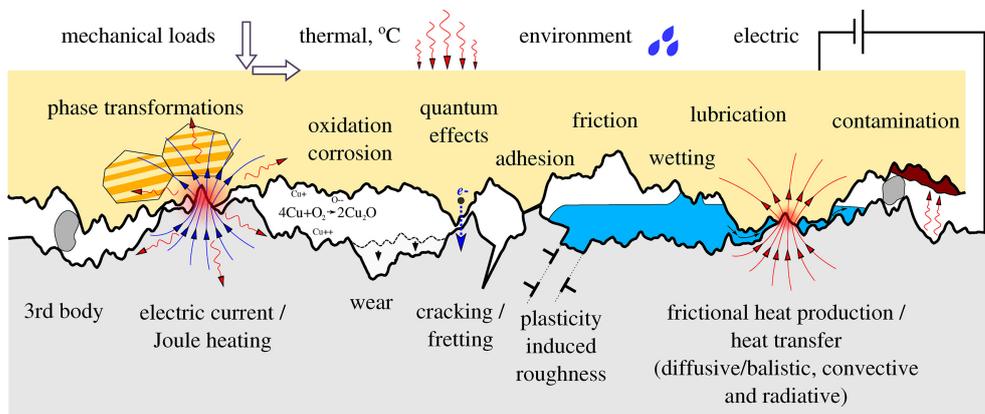


Figure 1 – Présentation des interactions tribologiques à plusieurs échelles : deux solides différents avec des surfaces rugueuses sont mis en contact et exposés à des charges mécaniques, thermiques, électriques et environnementales [Vakis et al., 2018].

C'est en connaissant cette limitation et ce cadre restreint que nous réalisons ce travail de recherche et ce manuscrit, en commençant par une première partie exposant les outils nécessaires à sa réalisation, ainsi qu'une présentation de leur utilisation actuelle dans la littérature. Puis dans une deuxième partie nous exposerons le travail réalisé en vue de trouver les liens morfo-tribo, ce à travers plusieurs étapes divisées comme suit : La

présentation des expérimentations tribologiques et l'analyse des quantités mesurées dans le chapitre IV ainsi que le traitement et l'analyse des images de l'interface frottée. Puis l'étude des caractéristiques morphologiques de l'interface ainsi que la recherche de liens avec les données tribologiques seront abordées dans le chapitre V. Enfin le chapitre VI sera consacré aux conclusions et perspectives de ce travail.

Première partie

État de l'art et stratégie

Nous sommes amenés dans un premier temps à nous poser la question : qu'est-ce que la tribologie? Le nom tribologie vient du grec "tribos" qui signifie frotter, il fut proposé par Peter Jost, un ingénieur britannique en mécanique pionnier de la discipline [Chung & Wang, 2013]. La tribologie est donc la science du frottement et regroupe l'étude du contact des surfaces, le frottement, l'usure et la lubrification.

Ces grands principes physiques ont depuis l'antiquité été mis en application mais n'ont commencé à être théorisés que tardivement, vers 1880 pour la mécanique du contact dont nous parlerons dans une première section. Nous aborderons également les principes du frottement et de l'usure, puis les concepts de troisième corps, tout en gardant à l'esprit que ce travail s'inscrit dans le cadre du frottement sec ou contact non lubrifié par un fluide.

1 Le contact

1.1 Contact élastique : Théorie de Hertz

Il s'agit d'une théorie permettant d'exprimer la distribution des contraintes en surface et sous surface [Hertz, 1881, 1882 ; Johnson & Cook, 1983 ; Johnson, 1985 ; Johnson & Johnson, 1987]. Prenons l'exemple de l'étude d'une liaison ponctuelle sphère plan, ce cas est particulièrement intéressant pour nous car, comme nous le verrons par la suite, il permet de comprendre simplement l'expérience mise en place dans ce manuscrit.

La charge est distribuée sur une aire de contact circulaire de rayon a définie comme

$$a = \left(\frac{3FR}{4E} \right)^{1/3}, \quad (\text{I.1})$$

Avec E le module de Young équivalent défini comme

$$\frac{1}{E} = \frac{1 - \nu_1^2}{E_1} + \frac{1 - \nu_2^2}{E_2} \quad (\text{I.2})$$

. Les indices représentent chaque solide (Figure I.1). Le rayon de l'aire de contact a , R le rayon de la sphère et F la force normale.

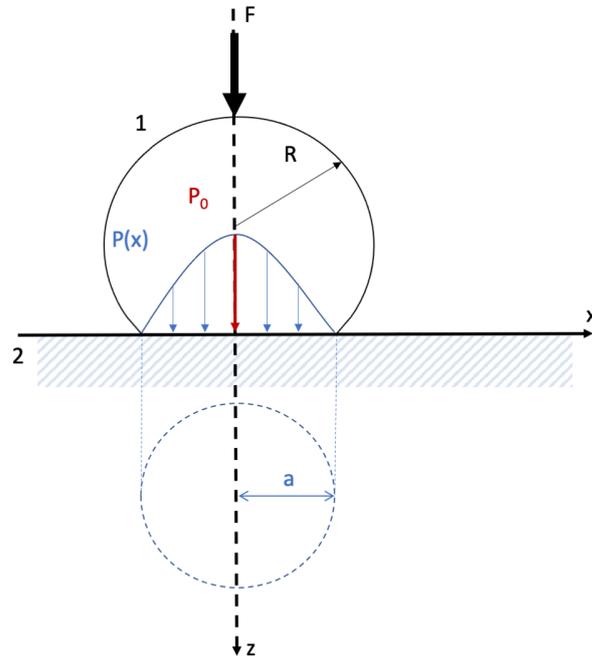


Figure I.1 – Contact de Hertz d'une sphère sur un plan, d'après [Takadom, 2007]

La distribution de pression sur l'aire de contact s'exprime comme fonction de r , prenant des valeurs de x allant de $-a$ à a , telle que :

$$P = P_0 \sqrt{1 - \left(\frac{r}{a}\right)^2} \quad r \in [-a, a] \quad (\text{I.3})$$

La pression de contact est donc nulle sur les bords et maximale au centre du contact et vaut P_0 appelée pression de Hertz et définie par l'expression

$$P_0 = \frac{3F}{2\pi a^2}.$$

Il sera possible d'évaluer la plastification dans le contact à l'aide de la pression moyenne P_m

$$P_m = \frac{F}{\pi a^2} \quad (\text{I.4})$$

en la comparant à la contrainte d'écoulement Y .

- $0 \leq P_m \leq 1.1Y \Rightarrow$ Déformation élastique
- $P_m = 1.1Y \Rightarrow$ Seuil de première plastification
- $P_m = 3Y \Rightarrow$ Plastification totale.

Sous la surface, la contrainte de cisaillement est maximale et vaut $\sigma_{max} = 0.31P_0$ au point $z = 0.48a$. C'est en ce point que se produit la première plastification.

1.2 L'aire de contact

Une surface, même lisse en apparence, présentera des aspérités microscopiques [Molinari, 2022]. Ainsi en mettant en contact deux surfaces planes et en appliquant une charge normale \mathbf{F} il y aura contact au sommet de ces aspérités, la Figure I.2 illustre ce phénomène de contact surfacique. Si on augmente la charge l'aire réelle de contact va augmenter [Bowden & Tabor, 2001 ; Greenwood & Williamson, 1966 ; Mate & Carpick, 2019].

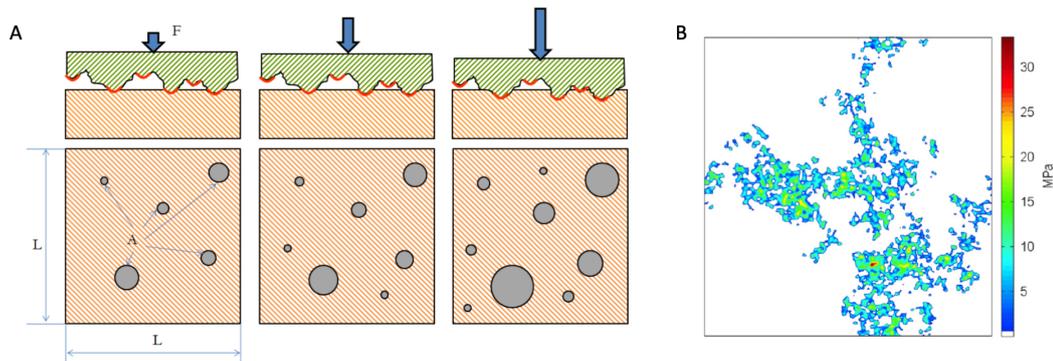


Figure I.2 – A) Modèle de contact surfacique [Brunetière, 2021]. B) Exemple de simulation numérique du contact entre une surface lisse et une surface rugueuse [Putignano et al., 2012]

On note :

- Aire réelle $A_r = \Sigma A_{r(i)}$ avec $A_{r(i)}$ aire de contact entre un doublet d'aspérités i .
- Aire apparente $A_a = xy$ avec x et y les dimensions macroscopiques de l'aire de contact (si l'on considère une surface d'étude rectangulaire).

Le rapport A_a/A_r dépend de la distribution des aspérités, de la charge et des contraintes d'écoulement. Ainsi l'aire apparente est comprise dans l'intervalle :

$$100A_r < A_a < 10000A_r$$

Au cours du frottement l'aire de contact évolue tant en termes structuraux, d'étendue, ou encore de composition chimique [Glaeser, 2012].

1.3 Le contact adhésif

Les forces d'attraction moléculaire, ou forces de Van der Waals [McNaught et al., 1997] sont négligées dans la théorie de Hertz [Hertz, 1881, 1882]. Pour le calcul de l'aire de contact ces dernières peuvent sensiblement en modifier les dimensions. Deux modèles ont alors été développés pour les prendre en compte :

- Le modèle JRK (Johnson Kendall Roberts) [Johnson et al., 1971] lequel suppose que les forces attractives sont confinées dans l'aire de contact et nulles à l'extérieur.
- Le modèle DMT (Derjaguin Muller Toporov) [Derjaguin et al., 1975 ; Pashley, 1984] pour lequel les forces attractives sont considérées comme situées à l'extérieur de la zone de contact. On suppose alors une zone de contact sphère-plan de type Hertz.

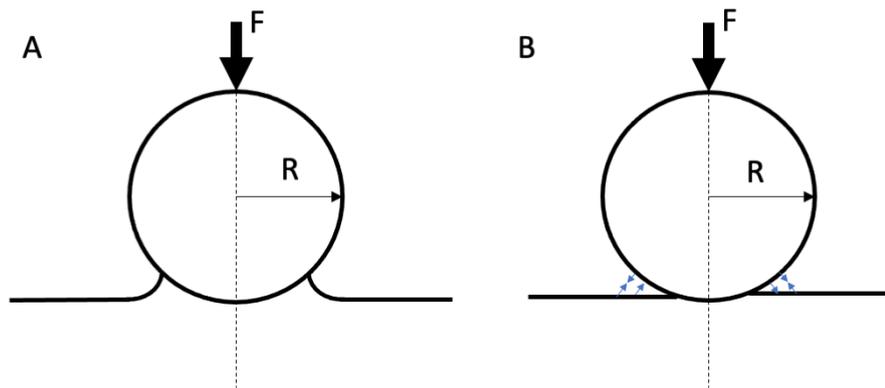


Figure I.3 – Modèles de contact avec prise en compte des forces attractives A) Modèle **JKR** : Les forces attractives sont confinées dans le contact. B) Modèle **DMT** : Contact de Hertz avec des forces attractives à l'extérieur de la zone de contact.

Le modèle JKR est généralement utilisé pour les matériaux à forte énergie de surface avec des aires de contact importantes (matériaux mous, sphère de grand rayon (quelques mm)) [Prokopovich & Perni, 2011 ; Takadoum, 2007]. Alors que le modèle DMT est utilisé pour des matériaux durs à faible énergie de surface avec de petites aires de contact (sphères de petit rayon). Toutefois notons que l'adhésion dépend également d'autres paramètres tel que la température et la durée de contact [Maugis & Barquins, 1978 ; Maugis, 1994].

2 Frottement et usure

2.1 Le frottement

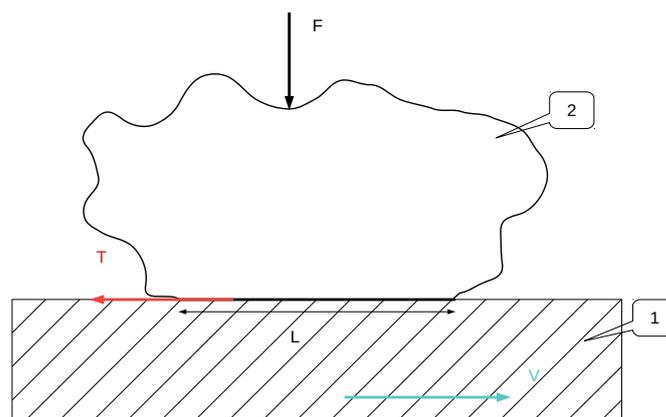


Figure I.4 – Frottement entre les solides 1 et 2

On peut voir sur la Figure I.4 la force normale notée \vec{F} que l'on note également $\vec{F} = F_n \vec{n}$, ainsi que la force tangentielle \vec{T} où $\vec{T} = F_t \vec{t}$. En connaissant F_n et en mesurant

expérimentalement F_t on peut accéder au coefficient de frottement, pouvant être interprété comme la résistance au glissement.

$$\mu = \frac{F_t}{F_n} \quad (\text{I.5})$$

On distingue les coefficients de frottement statique μ_s et dynamique μ_d avec respectivement :

- F_{ts} la force maximale qu'il faut exercer pour mettre le solide en mouvement
- F_{td} la force appliquée pour entretenir le mouvement.

Le frottement est sensible à divers paramètres tels que l'environnement dans lequel on place les matériaux ou la propreté des surfaces en contact. On peut prendre l'exemple d'une atmosphère sous vide, les surfaces sont très réactives car elles ne comportent aucune espèce adsorbées [NAZHSTKIN *et al.*, 1987]. *A contrario*, dans l'air, il se produit des réactions chimiques entre l'atmosphère et les espèces adsorbées, produisant une couche de contamination pouvant jouer un rôle de lubrifiant et ainsi réduire le coefficient de frottement [Buckley, 1978 ; Gatos, 1968]

De nombreuses théories et lois ont été développées pour caractériser le frottement, on peut citer de façon non exhaustive les contributions de Berlidor [Georges, 2000], Kragelsky [Georges, 2000] et Coulomb [Coulomb, 1821]. Les premières contributions donnant lieu à des théories nous viennent de Léonard de Vinci (1500) et furent oubliées avant d'être réactualisées par Amontons en 1699 pour donner les lois d'Amontons [Amontons, 1699] :

- La force de frottement est proportionnelle à la charge normale appliquée,
- La force de frottement est indépendante de la surface apparente de contact.
- Le coefficient de frottement est indépendant de la vitesse de glissement.

Ces 3 lois doivent être utilisées avec prudence car elles ne sont pas valables pour tous les matériaux, ni sous tous les environnements, ni pour toutes les sollicitations. Notons toutefois qu'elles s'appliquent relativement bien aux cas de frottement sec (non lubrifié), comme ça sera le cas dans cette étude.

Lors de l'élaboration de ces lois, on pensait que les aspérités de surface étaient imbriquées, mais cet aspect fut abandonné lorsque l'on constata que des surfaces bien polies pouvaient présenter des coefficients de frottement élevés [Molinari & Mercier, 2001 ; Molinari, 2022] Toutefois, il existe une rugosité optimale qui minimise le frottement. Plus la surface est lisse et les rugosités sont faibles plus grande sera la surface réelle de contact donc la composante adhésive. Au contraire, plus la surface est rugueuse et les aspérités nombreuses et fines plus la composante déformation plastique est importante.

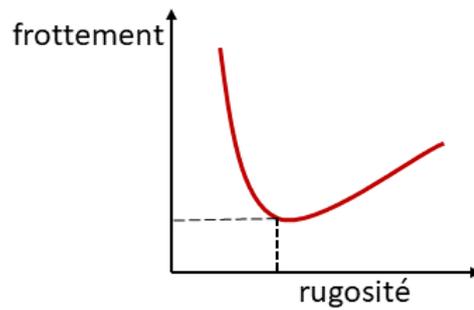


Figure I.5 – Evolution de la force de frottement en fonction de la rugosité.

La force de frottement possède donc deux composantes, une composante déformation plastique et une composante adhésive que l'on notera :

$$F_t = F_d + F_a.$$

Seule une partie de l'énergie mécanique est dissipée par le mécanisme d'usure, le reste de l'énergie est convertie en :

- énergie thermique,
- énergie acoustique avec émission d'ondes sonores(vibrations du réseau atomique),
- énergie électrique (électricité statique on parle de triboélectricité),
- énergie lumineuse (réactions chimique ou tribochimie),
- énergie de déformation ou d'écrouissage. Il y a création de désordre structural et de nombreux défauts dans les couches superficielles des matériaux antagonistes.
- énergie associée aux transformations chimiques.
- énergie de création de surfaces (fissurations, arrachement de débris).

Le poids de ces dissipations sera différent selon les matériaux, l'environnement et les conditions de sollicitation. Il n'y a pas de corrélation entre usure et frottement, l'usure ne peut être corrélée qu'avec la fraction d'énergie consommée dans le processus d'usure lui même, c'est ce processus que nous allons développer par la suite.

2.2 L'usure

Les principaux modes de dégradation des matériaux sont : l'usure, la corrosion et le vieillissement. On définit en général l'usure comme étant une perte de matière. Pour évaluer cette perte de matière on a recours aux lois de Archard [[Archard, 1953](#)].

- Première loi d'Archard :

$$V_u = aF_n L$$

avec F_n la force normale, L la distance parcouru et V_u le volume perdu/usé.

- Deuxième loi d'Archard :

$$V_u = b \frac{F_n S}{\sigma_{ij}}$$

avec σ_{ij} la contrainte d'écoulement du matériau le plus mou et S la surface de contact.

— Troisième loi d’Archard :

$$\frac{dh}{dt} = cPu$$

Le produit pression \times vitesse de glissement est proportionnel à u la vitesse d’usure et h est la profondeur de la piste d’usure.

a, b et c sont des coefficients de calage. De par la présence de ces coefficients on peut dire qu’il existe une multitude de lois d’usure. Ces lois sont écrites à partir d’expérimentations dans des conditions données sur un tribomètre donné.

De plus les lois de Archard supposent une disparition immédiate des particules d’usure et ne prend donc pas en compte leur devenir dans le contact. Des modèles numériques sont pensés et encore en cours de développement pour prendre en compte ce troisième corps [Fillot *et al.*, 2007 ; Mollon, 2019].

On dispose expérimentalement de plusieurs méthodes pour estimer le volume d’usure :

- pesage des échantillons après les tests,
- mesure du volume de matière enlevée par profilométrie 3D tactile ou optique,
- filtrage et analyse des huiles et des débris d’usure dans le lubrifiant,
- activation superficielle (marquage radioactif des surfaces).

Il est courant de distinguer différents types d’usure :

- **L’usure adhésive** : formation de jonctions (microstructures) entre les surfaces frottantes. Si les jonctions sont faibles, le cisaillement se produit à l’interface et l’usure sera nulle. Si les jonctions sont fortes, le cisaillement se produit au sein du matériau le plus mou qui est transféré sur le plus dur.
- **L’usure abrasive** : typique d’un contact entre un matériau dur et un matériau mou. On voit alors apparaître des rayures, des sillons, des copeaux...
- **L’usure par fatigue** : apparaît lorsque un matériau est soumis à des sollicitations cycliques. Sous l’effet des contraintes introduites dans les couches superficielles des fissures se développent au sein du matériau dans un plan parallèle à la surface. On parle d’usure par délamination.
- **L’usure tribochimique** : mécanisme qui fait intervenir la croissance d’un film de produits de réactions dûes aux interactions chimiques entre les surfaces frottantes et l’environnement. Le plus courant est la tribo-oxydation.

3 Matériaux et tribologie

3.1 Le triplet tribologique

Avant de mettre en contact un couple de matériaux que nous nommerons premiers corps, il faut s’assurer de leur compatibilité tribologique. Par exemple des premiers corps non-solubles entre eux présenteront pas ou peu d’adhésion et constitueront un bon couple frottant. Il faut malgré tout garder des réserves, cette règle n’étant pas toujours vérifiée [Gras, 2008 ; Takadoun, 2007]. En effet, la solubilité est une propriété volumique

alors que le frottement fait intervenir principalement les caractéristiques de surface telles que la dureté, la structure cristallographique, l'énergie de surface et la topographie. Le critère de solubilité ne tient pas compte des transformations chimiques (oxydation, transformation de phase, formation de nouveaux composés...) et structurales (transformation allotropique, recristallisation, écrouissage...) qui peuvent se produire au cours du frottement et modifier considérablement les propriétés superficielles des matériaux antagonistes [Stachowiak, 2006].

On peut voir sur la Figure I.6 le couple frottant ou premiers corps ainsi que la présence d'un troisième corps en violet. La théorie du troisième corps a été développée dans les années 70 par M. Godet [Godet, 1984].

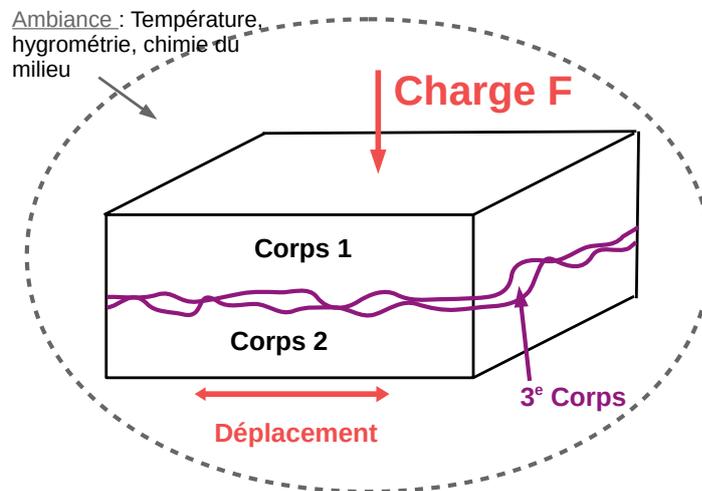


Figure I.6 – Le triplet tribologique

Cette théorie inspirée par la lubrification par un fluide propose d'appréhender le problème du contact non plus comme un problème volumique ou surfacique mais comme un problème d'interface¹. Le troisième corps sépare complètement ou partiellement les premiers corps. Dans le cas du frottement sec (sans fluide) le troisième corps est notamment constitué de débris d'usure. Dans le cas d'un contact lubrifié le lubrifiant, non formé *in situ*, sera qualifié de troisième corps artificiel. Le troisième corps a 3 fonctions :

1. Il transmet la charge appliquée au contact.
2. Il participe à l'accommodation des vitesses entre les deux premiers corps. Un mécanisme d'accommodation résulte de l'association d'un site et d'un mode d'accommodation [Berthier, 1990 ; Lepesant, 2013].

1. **Interface** : Zone où des modifications physiques, chimiques, morphologiques, mécaniques ont lieu lors d'un contact entre deux pièces. Cette zone peut comprendre une part plus ou moins importante de la surface et de la sous-surface de ces corps, ou être totalement extérieure à l'un des corps.

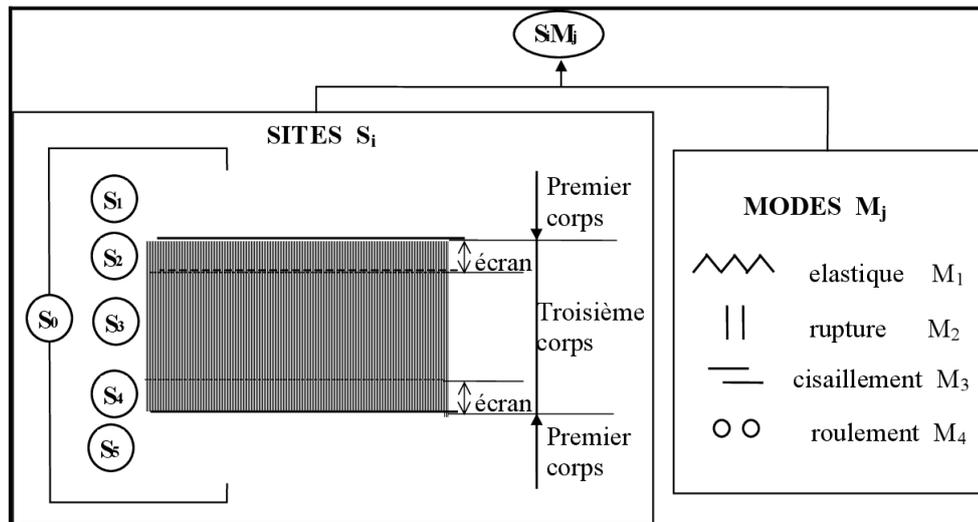


Figure I.7 – Mécanisme d'accommodation de vitesse. Source : Semantic scholar.org.

Il est important de noter que différents mécanismes, présentés en Figure I.7 peuvent coexister et évoluer dans le contact, entraînant une modification de l'interface.

3. Il sépare les corps en contact, réduisant leur interaction.
4. Il pourra également permettre d'évacuer la chaleur ou empêcher l'oxydation.

Par la suite Y. Berthier proposera de reformuler le problème d'usure à l'aide d'un circuit tribologique [Berthier, 1988, 1996 ; Descartes, 1997].

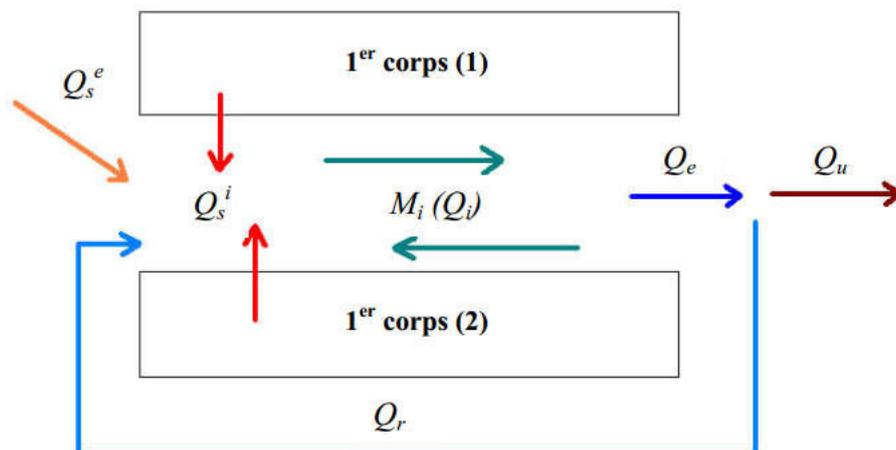


Figure I.8 – Le circuit tribologique. D'après [Berthier, 2005 ; Descartes & Berthier, 2002]

On voit sur la Figure I.8 différents débits de troisième corps, des débits sources, noté Q_s , interne (exposant i) ou externe (exposant e) respectivement en rouge et en orange sur la figure, et différents flux. Notons que le débit d'éjection Q_e en bleu peut se diviser en deux débits, le débit d'usure Q_u (en marron) dans ce cas les particules sont définitivement expulsées du contact ou le débit de recirculation Q_r (en cyan) qui est réinjecté dans le contact. On note M_i la masse de 3e corps piégé dans le contact, le troisième corps peut

alors provenir de l'extérieur, par injection de fluide par exemple, et est représenté par un débit source externe Q_s^e . Dans le cas d'un contact sec, le 3e corps est notamment issu des premiers corps on parle alors de débit source interne noté Q_s^i .

Le rodage en tribologie est la première étape de la vie d'un contact. Cette étape est le résultat de la concaténation de processus transitoires simultanés se produisant à l'interface [Blau, 2005 ; Khonsari *et al.*, 2021]. La combinaison de ces processus engendre des formes, des durées et des transitoires variés et complexes au regard de l'évolution du frottement en fonction du temps. Le frottement n'est pas le seul phénomène en jeu lors du rodage, les phénomènes d'usure influence aussi la répartition de l'énergie dans le tribosysteme, ils sont très dépendants du temps et de l'échelle. En effet, le rodage va se produire à des rythmes différents en fonction des systèmes, voir même des sous systèmes considérés. Notons que le temps permettant d'atteindre l'équilibre en terme de frottement n'est pas obligatoirement le même que celui nécessaire pour stabiliser le taux d'usure. Ainsi les conditions de rodage vont impacter les performances en régime établi. La rugosité initiale, la microstructure en extrême surface, les propriétés physico-chimiques de surface, vont jouer sur la compétition adhérence/déformabilité, donc surface/volume. Par exemple, l'endommagement des surfaces peut être du à la déformation des aspérités et/ou la formation de particules d'usure. Les processus mis en jeu vont avoir un effet sur l'évolution du coefficient de frottement ainsi que sa valeur moyenne en régime établi. Dans ce travail de thèse seul le paramètre rugosité initiale sera intégré dans les conditions opératoires.

Maintenant que nous disposons des éléments théoriques concernant la tribologie et plus particulièrement le troisième corps nous pouvons nous intéresser à la façon de le caractériser.

3.2 Le troisième corps dans tous ses états

Nous avons déjà abordé le troisième corps comme faisant partie du triplet tribologique (Figure I.6) : il joue un rôle d'interface entre les deux premiers corps en contact. C'est en étudiant ce troisième corps qu'il sera possible de retracer la vie du contact et d'élaborer un scénario [Descartes, 1997 ; Lepesant, 2013] nous pourrions également produire une cartographie qualitative afin de définir des zones de contact, présentant par exemple des sur-pression [Frache *et al.*, 2021 ; Frache, 2022 ; Noël, 1995]. Pour cela on réalise une étude post-mortem, c'est-à-dire après ouverture du contact. Considérons ici un contact ponctuel modélisé avec un pion maintenu en contact sur un disque en rotation. En s'intéressant au pion on distingue alors une zone de présence de troisième corps pouvant être partitionnée en plusieurs régions.

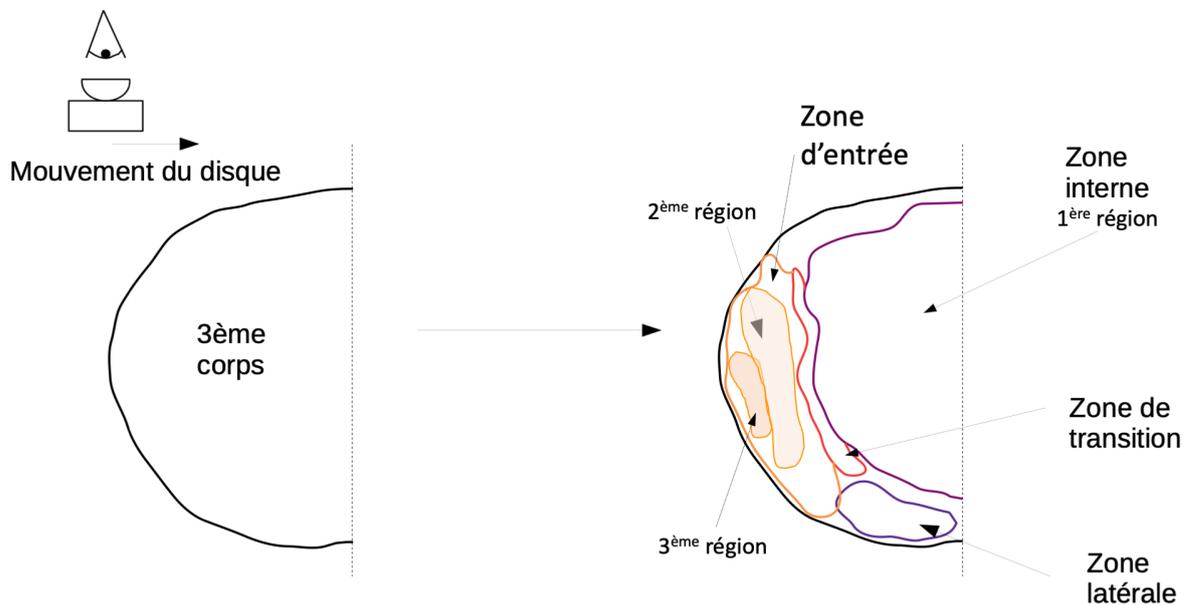


Figure I.9 – Zone de présence du troisième corps [Descartes, 1997]

La zone d'entrée (en jaune sur la Figure I.9) est constituée de deux régions que l'on nomme 2^e et 3^e région (la première étant la zone interne). La 2^e région est une zone d'accumulation de troisième corps, elle se constitue ou non en fonction des conditions d'essais. C'est un réservoir de troisième corps pouvant être découpé en deux sous régions, une sous région d'accumulation interne (au plus près de la zone de transition) et une sous région d'accumulation externe. La différence fondamentale entre ces deux sous régions est le compactage du troisième corps, il aura tendance à être plus compact en zone d'accumulation interne.

La 3^e région est composée de petites particules de troisième corps, ces dernières sont éjectées et donc perdues pour le contact.

On trouve un deuxième réservoir de troisième corps dans les zones latérales (en mauve sur la Figure I.9). Il est constitué de troisième corps plus ou moins cohésif adhérent au pion

et s'écoulant de part et d'autre de la 1^{re} région, on observe bien les différences de textures sur la Figure I.10. Les zones latérales peuvent se fragmenter sous leur propre poids (ou avec l'intervention d'une action mécanique) et tomber de part et d'autre de la piste et ainsi contribuer ou non à l'accommodation de vitesse.

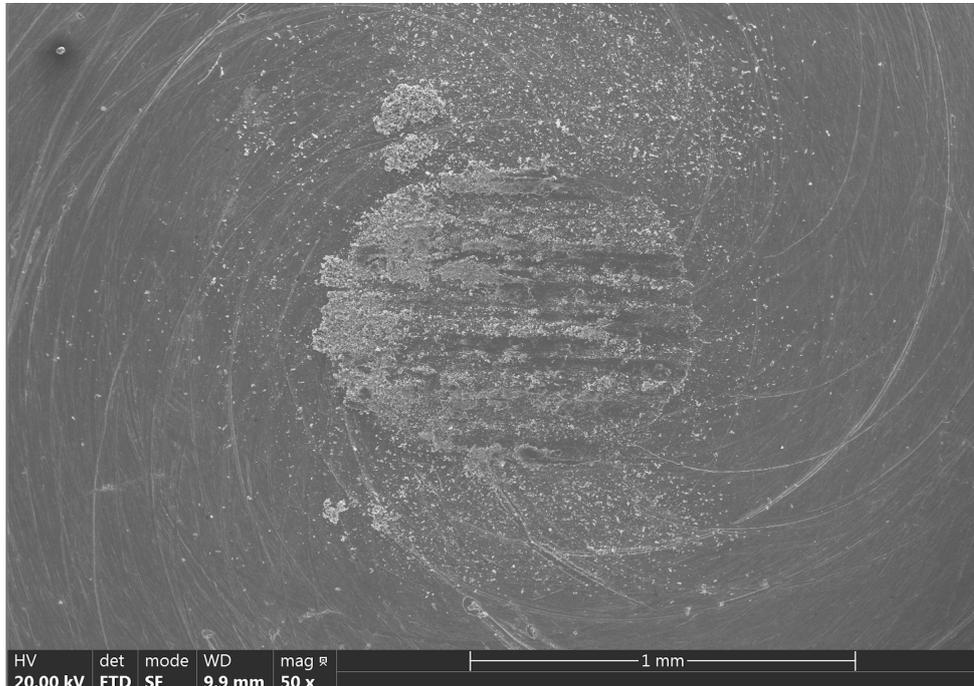


Figure I.10 – Trace sur un pion acier observée au MEB

Les fragments qui contribuent à l'accommodation de vitesse seront plus ou moins lissés et interviendront dans le débit de recirculation (circuit tribologique Figure I.8). Alors que ceux qui ne contribuent pas à l'accommodation de vitesse ne sont pas lissés et interviennent dans le débit d'usure (Figure I.8).

Nous allons faire un point sur les différentes textures de troisième corps que nous pouvons rencontrer [Descartes, 1997 ; Noël, 1995] :

- **Les textures granulaires** sont observables lorsque le troisième corps est constitué de particules élémentaires d'une taille moyenne du dixième à la dizaine de micromètre. On distingue différentes sous catégories de troisième corps granulaire :
 - La texture malaxée que l'on retrouve dans la zone d'accumulation de la 2^e région. Le troisième corps est constitué d'un amalgame de fragments dans lequel sont insérés des plaquettes et des particules. Il n'y a pas d'orientation privilégiée.
 - La texture friable. Le troisième corps non cohésif est soumis à des efforts normaux et tangentiels ce qui aura tendance à l'effriter.
 - La texture compactée est observée dans la zone d'entrée et dans les zones latérales. Les particules sont très serrées sous l'effet de la pression normale et d'un effet d'entraînement tangentiel faible.
 - La texture poudreuse va se retrouver en zone externe voir en 3^e région. Les particules n'ont pas d'orientation privilégiée et se retrouvent sous forme d'amas.
- **Les textures étalées** sont au nombre de trois :

- La texture écrasée que l'on retrouve au niveau de la zone de transition ou dans les zones latérales. Des lambeaux de troisième corps sous écrasés et un peu étalés dans une direction privilégiée correspondant au sens de déplacement.
- La texture tartinée est constituée de plaquettes ou lambeaux écrasés puis étalés sous l'effet de la pression normale et d'une force tangentielle avec une orientation privilégiée.
- La texture lissée, il s'agit de la plus cohésive. Son aspect est lisse et présente peu d'aspérités.

Remarques :

1. Les textures lissées et tartinées se retrouvent généralement dans la zone interne. On leur associe un troisième corps très cohésif.
2. On ne trouve pas de texture granulaire en zone interne.
3. Plus le troisième corps aura la capacité de s'étaler plus sa ductilité est importante.

Différents paramètres vont avoir un impact sur la rhéologie du troisième corps, c'est-à-dire sur sa ductilité, sa cohésion et son adhérence. La modification d'un des paramètres suivants peut impliquer un changement de propriété de surface des premiers corps ou de cohésion de troisième corps et donc modifier les débits de troisième corps :

- L'environnement : la température et le gaz.
- Les premiers corps : les matériaux (revêtement, substrat, propriétés mécaniques et physiques, (micro)structure), la rugosité et la géométrie.
- Le mécanisme : la raideur du système, la pression, la vitesse relative des premiers corps et l'amplitude de déplacement.

L'éjection des particules est un paramètre caractérisant l'usure [Fillot *et al.*, 2004], on cherche donc à contrôler cette éjection pour mieux contrôler l'usure. On va donc jouer sur les débits du circuit tribologique (Figure I.8) : N. Fillot propose un modèle analytique simplifié permettant une meilleure compréhension des flux et débits dans le circuit [Fillot, 2004]. Afin de bien illustrer la notion "contrôler les débits c'est contrôler l'usure" on peut reprendre son exemple sur les particules adhésives [Fillot *et al.*, 2004], l'éjection est moins grande à mesure que l'adhésion augmente. L'éjection est empêchée par la création d'une sorte de "bouchon" de particules adhésives, ainsi l'usure est diminuée. Toutefois si on considère un contact régulièrement nettoyé tel que des plaquettes de frein (changement de géométrie), la couche de troisième corps se reforme sans cesse et le débit d'éjection est infiniment grand. Ainsi dans cette configuration des particules peu adhésives engendreront une usure moindre.

Dans cette partie nous avons parlé de l'usure au sens de Archard [Archard, 1953]. L'usure, vue comme l'éjection définitive de particules hors du contact, est le résultat d'un équilibre des débits de matière au sein du contact. Les particules d'usure sont la conséquence visible de cet équilibre. Ainsi l'étude des particules d'usure peut contribuer à en apprendre plus sur la vie du contact

4 Conclusion

Dans ce chapitre nous avons présenté les outils théoriques servant à décrire le frottement, l'usure ou plus généralement l'interface d'un contact. Le fil rouge guidant la suite de ce travail est le circuit tribologique, présenté en Figure I.8. Dans ce travail de thèse nous chercherons à déterminer des caractéristiques spécifiques au flux de recirculation et au flux d'usure. Cela passera par le traitement des images de l'interface dont les techniques et les applications sont présentées au chapitre II. Puis à l'aide d'outils tel que le *machine learning*, présenté au chapitre III, nous relirons ces caractéristiques au coefficient de frottement (chapitre V).

CHAPITRE II

LE TRAITEMENT ET L'ANALYSE D'IMAGE POUR LA TRIBOLOGIE

Le traitement d'images est un domaine très vaste permettant grâce à un ensemble de méthodes de transformer des images et/ou d'en extraire des informations [Burel, 2001]. Cet outil d'investigation va nous permettre d'extraire des informations relatives à la rhéologie du troisième corps [Descartes, 1997 ; Descartes & Berthier, 2002 ; Jaza *et al.*, 2016 ; Roylance & Raadnu, 1994 ; Thomas *et al.*, 1991]. Mais avant cela il faut comprendre le fonctionnement de ces outils.

1 Qu'est ce qu'une image ?

Une image est considérée comme une matrice de dimension $(m \times n)$. On note la position de chaque pixel (i,j) où l'index i correspond à la ligne $i \in [0,m[$ et j correspond à la colonne $j \in [0,n[$.

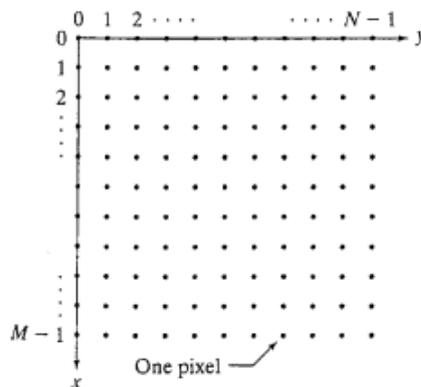


Figure II.1 – *Convention de coordonnées en analyse d'images [Gonzalez et al., 2003].*

On notera $f_{i,j}$ la valeur d'un pixel à la position (i,j) . Celle-ci peut être représentée de façon binaire (0 ou 1), ou en nuance de gris (généralement entre 0 et 255). Dans ce cas la plus petite valeur est associée au noir et la plus grande au blanc, les nuances de gris représentent les valeurs intermédiaires. Il est alors possible de décrire l'image via son histogramme. On compte les pixels appartenant à chaque nuance de gris. L'histogramme peut alors être perçu comme une densité de probabilité des niveaux de gris de l'image (exemple d'une répartition des niveaux de gris est présentée en Figure II.2).

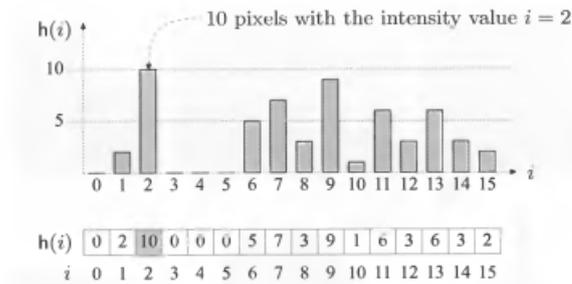


Figure II.2 – Histogramme d'une image avec $K = 16$ valeurs d'intensité possibles [Burger & Burge, 2008].

Il existe également des images couleurs. Pour représenter la couleur d'un pixel il faudra donner trois nombres correspondant au dosage de trois couleurs de base (différentes selon le système de couleurs choisi). Considérons le système de représentation des couleurs le plus répandu (RGB), qui reproduit approximativement la perception des couleurs de l'oeil humain il faudra donner trois composantes (une pour le rouge, une pour le vert et une pour le bleu) pour représenter l'image en couleur.

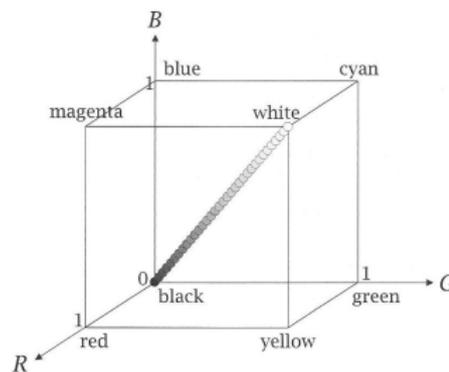


Figure II.3 – Cube des couleurs en système RGB [Efford, 2000].

Sur la Figure II.3 on peut voir la représentation schématique des intensités du système RGB mais il est important de noter que ce n'est pas le seul, on peut citer par exemple CMYK (Cyan Magenta Yellow Key) utilisé en imprimerie et Lab qui sépare la luminance de la chrominance (les couleurs) à l'instar du système visuel humain [Fairchild, 2013]. L'analyse d'image se compose de plusieurs étapes, toutefois nous nous attarderons plus spécifiquement sur [Glasbey & Horgan, 1997] :

- L'affichage ou Display
- Les filtres ou Filters
- La segmentation
- Les opérations morphologiques
- Les mesures

Chacune de ces étapes est détaillée dans la section suivante.

2 Les étapes clés du traitement et de l'analyse d'images

2.1 L'affichage

Cela semble trivial mais il est important de préciser qu'une image doit pouvoir être examinée avant d'être analysée. Il existe différents types d'affichage en fonction de l'image : binaire, en nuances de gris, en couleurs,... L'affichage d'image binaire est le plus direct puisqu'une des valeurs de pixel s'affiche en noir et l'autre en blanc. Alors que pour l'affichage des images en nuances de gris on associe une intensité d'affichage aux valeurs de pixel à l'aide d'une table de conversion (ou table de références). On peut voir un exemple d'image en nuances de gris sur l'image du centre de la Figure II.4.

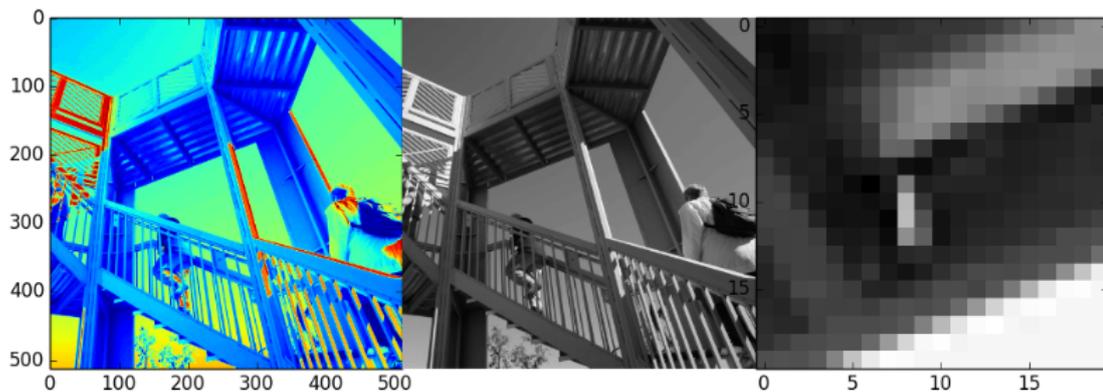


Figure II.4 – Différents affichages d'une même image avec de gauche à droite : Affichage en pseudo couleurs, affichage en nuances de gris et zoom [Gavet & Debayle, 2019].

Pour nous aider à visualiser différentes caractéristiques il est possible d'appliquer des transformations directement sur la table de références, un exemple de transformation : l'égalisation d'histogramme dont le but est de rendre l'histogramme le plus plat possible, utile dans le cas d'une image avec un mauvais contraste.

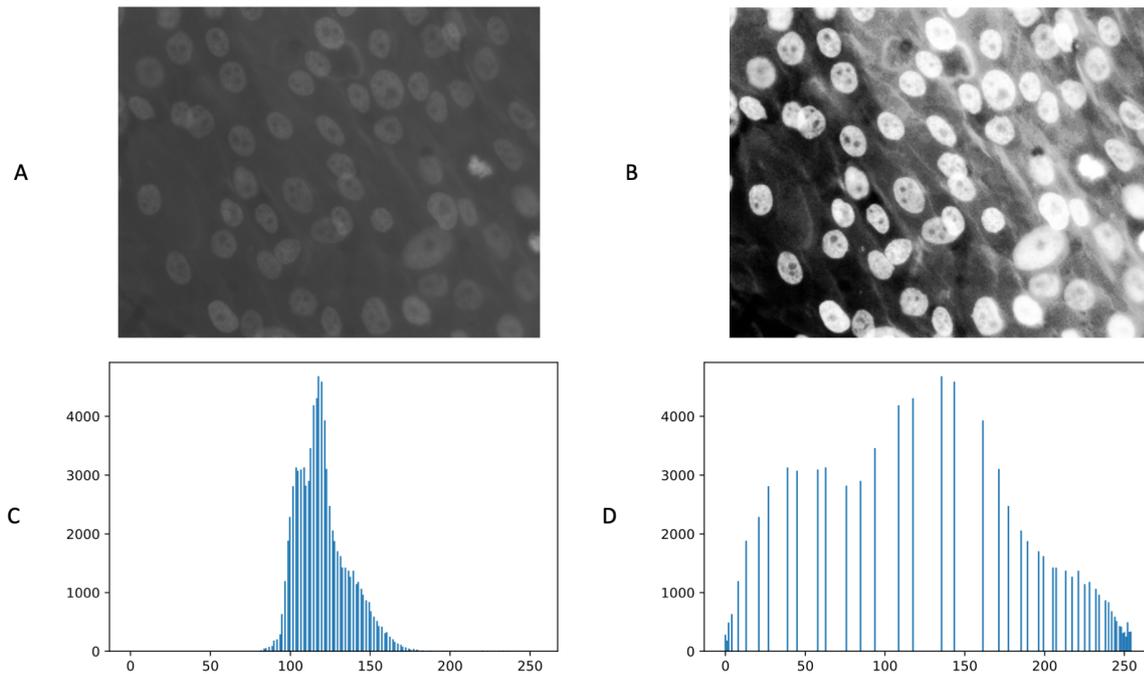


Figure II.5 – *Egalisation d’histogramme sur une image d’osteoblaste [Gavet & Debayle, 2019]. A) Image originale. B) Image après égalisation d’histogramme. C) Histogramme de l’image originale. D) Histogramme après égalisation.*

On peut voir sur la Figure II.5 qu’il est plus facile pour l’œil humain de discerner les cellules sur l’image à l’histogramme transformé que sur l’image originale, de plus on peut constater que son histogramme a été “étalé”.

Lors de l’affichage il est également possible de modifier le système de couleurs (ou color map). Ainsi certaines images en nuances de gris seront plus facilement interprétables avec des pseudos couleurs. On peut voir un exemple de l’utilisation des pseudo couleurs sur l’image de gauche de la Figure II.4. Lors de la phase d’affichage il sera également possible de réaliser des zooms comme sur l’image de droite de la Figure II.4.

2.2 Les filtres

Les opérations de filtrage sont primordiales en analyse d’image car elles vont permettre d’améliorer une image, de réduire le bruit par lissage ou d’améliorer les contours. Les filtres vont aider à l’interprétation des images et peuvent être précurseurs à d’autres analyses telles que la segmentation par exemple.

Ils vont réévaluer la valeur de chaque pixel d’une image : la nouvelle valeur d’un pixel considéré sera basé sur une combinaison linéaire ou non linéaire des valeurs de ses voisins. Les filtres sont dits linéaires si les valeurs de sorties sont des combinaisons linéaires des pixels de l’image d’origine, autrement ils sont non linéaires. Les filtres linéaires sont rapides à calculer mais auront tendance à flouter les bords des objets présents dans l’image. Alors que les filtres non linéaires seront plus longs à calculer mais permettent de conserver la netteté. On distingue deux sous catégories, les filtres passe haut et les filtres passe bas.

Pour comprendre le fonctionnement de ces filtres, il est important de noter que dans une image les hautes fréquences correspondent aux variations rapides d'intensité (comme le bruit et les contours) alors que les basses fréquences sont associées aux variations lentes. Ainsi le filtrage d'une image par un filtre passe bas donnera une image avec peu de hautes fréquences et les contours seront adoucis par le filtre. Au contraire un filtre passe haut aura tendance à accentuer le bruit et la netteté des contours.

Il existe également des filtres spécifiques pour détecter les contours : les filtres détecteurs de contours. Par exemple, le filtre appelé gradient est constitué d'une paire de filtres linéaires qui vont détecter les contours dans deux directions orthogonales.

2.3 Segmentation

La segmentation est généralement la première étape permettant l'analyse ou l'interprétation automatique d'une image. C'est une opération qui consiste à placer chaque pixel d'une image dans une catégorie correspondant à un objet ou un morceau d'objet. Généralement les pixels d'une catégorie ont une valeur similaire et/ou sont associés à une région de l'image et sont différents des pixels voisins d'autres catégories. La segmentation peut s'appliquer à des images originales ou après transformation ou application d'un filtre. La segmentation peut être entièrement automatique ou peut nécessiter une intervention humaine. On distingue 3 méthodes de segmentation :

1. Thresholding ou seuillage : La méthode de seuillage fonctionne en définissant une valeur seuil t ; on va alors allouer un pixel (i,j) à une catégorie 1 si sa valeur est inférieure ou égale à la limite ou à une catégorie 2 sinon. Cette limite peut être définie manuellement ou à l'aide d'un algorithme appliqué directement à l'histogramme de l'image. La Figure II.6 ci-après illustre l'importance qu'il faut apporter au choix de la limite lors d'une segmentation par seuillage.

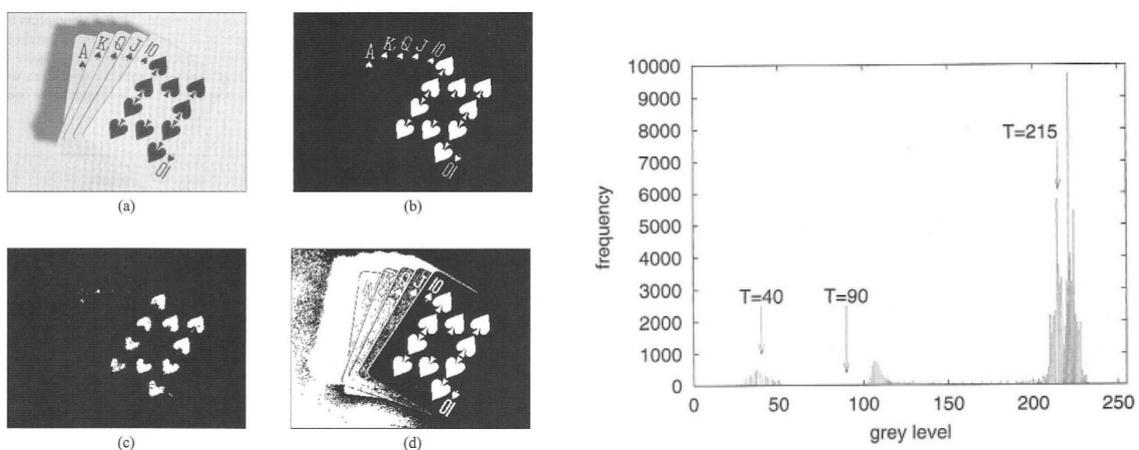


Figure II.6 – A GAUCHE : Importance du choix de la limite. (a) Image originale, (b) Choix de limite correcte ($T=90$), (c) Limite trop basse ($T=40$), (d) Limite trop haute ($T=215$). A DROITE : Histogramme de l'image originale. [Efford, 2000]

Cette méthode peut également être appliquée aux images couleurs, dans ce cas il existe deux possibilités. On peut soit sélectionner manuellement un groupe de pixels représentatif des différentes catégories et utiliser une discrimination linéaire. Soit utiliser la méthode des k-moyennes (méthode de classification automatique) dans laquelle les catégories sont automatiquement sélectionnées à partir des données.

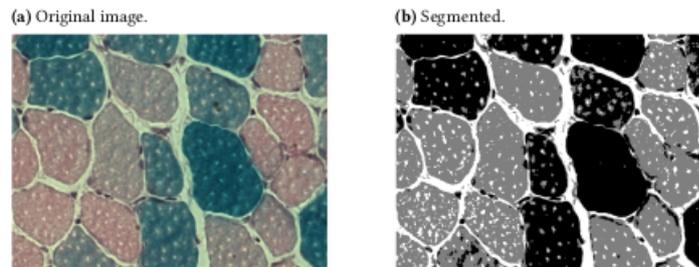


Figure II.7 – Segmentation d'une image couleur par la méthode des k-means [Gavet & Debayle, 2019]

Ces deux méthodes sont des méthodes dites d'apprentissage et relèvent du domaine du *machine learning*.

2. Approche contours : Lors de la segmentation basée sur les contours, les pixels sont initialement étiquetés comme appartenant ou non à un contour et sont répartis en catégories.
3. Approche régions : La segmentation se construit directement à partir de régions qui finissent par être séparées par des contours. Pour cela les régions peuvent “pousser” d'un point “graine” positionné manuellement ou on peut utiliser un algorithme appelé “Split-and-merge” qui trouve une partition de l'image telle que la variance des valeurs de pixel dans chaque segment soit inférieure à un seuil spécifique. Un exemple est donné à la Figure II.8.

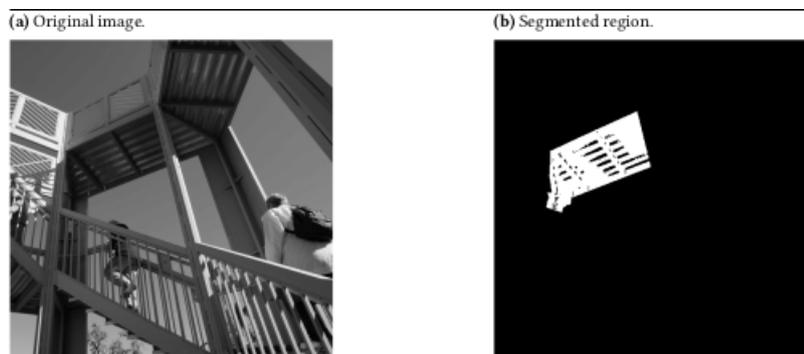


Figure II.8 – Région ayant poussée autour du pixel (189,136) [Gavet & Debayle, 2019].

Ces deux approches sont dites duales, et les méthodes comme le watershed (lignes de partage des eaux) qui allient les deux approches sont parmi les plus performantes.

2.4 Opérations morphologiques

Les opérations morphologiques permettent de réaliser des opérations sur les images dans le but d'en faciliter l'interprétation, elles vont être utilisées pour lisser une image ou aider à extraire des structures particulières. Elles sont complémentaires des autres étapes présentées ci-avant, elles sont généralement employées sur des images binaires (les opérations sont alors des opérations définies sur des ensembles) mais peuvent être étendues à des images à niveaux de gris en considérant les opérateurs minimum et maximum sur des voisinages (appelés éléments structurants).

L'opération fondamentale en morphologie est l'érosion, elle consiste à déterminer où un ensemble test (élément structurant) peut s'intégrer dans l'image. Cet élément structurant peut être un carré, un cercle, un diamant,... Il en existe un multitude mais nous présenterons un exemple avec le carré en Figure II.9 où le pixel de référence est au centre. A partir de l'érosion on peut définir différentes opérations telles que la dilatation qui est une érosion sur un ensemble complémentaire, l'ouverture constituée d'une érosion suivie d'une dilatation et la fermeture qui est une dilatation suivie d'une érosion.

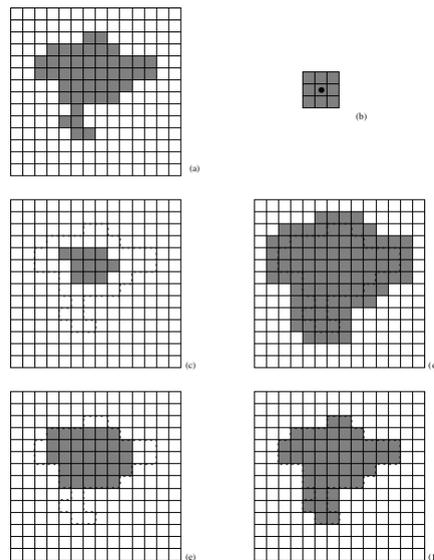


Figure II.9 – *Fonctionnement des opérations morphologiques de base. (a) canevas de base, (b) ensemble de test, (c) érosion, (d) dilatation, (e) ouverture et (f) fermeture [Glasbey & Horgan, 1997]*

Dans la Figure II.9 on peut observer de quelle manière les opérations morphologiques de bases vont avoir tendance à modifier notre image. C'est conscient de ces modifications qu'il faudra choisir la méthode la plus adaptée à notre étude. Ce ne sont toutefois pas les seules opérations possibles, lors de la "phase morphologie" on pourra "nettoyer" notre image. On pourra par exemple combler les trous, retirer les formes situées sur les bords ou encore extraire le squelette d'une structure fine, comme sur la Figure II.10.

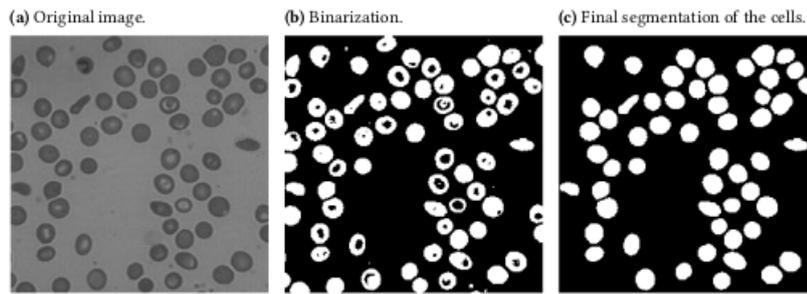


Figure II.10 – Images de cellules biologiques [Gavet & Debayle, 2019]

On peut voir sur la Figure II.10 que l'image a dans un premier temps été binarisée, cette opération a été réalisée avec la méthode de seuillage présentée dans la section segmentation. Puis elle a été nettoyée, les trous présents dans les cellules ont été comblés et les cellules en bordure d'image retirées.

Toutes ces opérations préparent le travail d'analyse et d'extraction de caractéristiques.

2.5 Mesures

Les mesures sont en général faites sur les images post-segmentation qui ont potentiellement été retravaillées avec des opérations morphologiques. Il existe plusieurs catégories de mesures [Burger & Burge, 2009] :

- Les mesures de taille : On considère alors deux types de statistiques, celles basées sur les moments telles que la surface, le moment d'inertie, le centre de gravité,... et celles basées sur les distances comme la longueur moyenne, le diamètre de Feret, l'enveloppe convexe,...
- Les mesures de forme : Il s'agit des mesures de convexité, rondeur, élongation,... Attention ces dernières sont indépendantes de la taille.
- Les descripteurs de frontière : Ce sont les mesures locales de pentes, de courbures, les descripteurs de Fourier,...
- Les descripteurs de textures : Ce sont des représentations statistiques des niveaux de gris d'une image, elles visent à évaluer la distribution de ces derniers.

Ce sont ces mesures dont nous allons avoir besoin dans ce travail de thèse pour caractériser la morphologie du troisième corps.

3 Analyse d'image et troisième corps

Nous avons vu dans la partie précédente que certaines informations sur la vie d'un contact pouvaient nous être fournies en observant le troisième corps (par exemple la texture). Toutefois cette opération est très subjective et soumise à l'expertise du tribologue. C'est pourquoi de nombreux chercheurs se sont intéressés à l'utilisation de l'analyse d'image afin d'étudier et de caractériser les particules d'usure [Roylance & Raadnu, 1994 ; Thomas *et al.*, 1991] et ainsi relier leurs propriétés aux phénomènes physiques propres au contact et plus spécifiquement à l'usure.

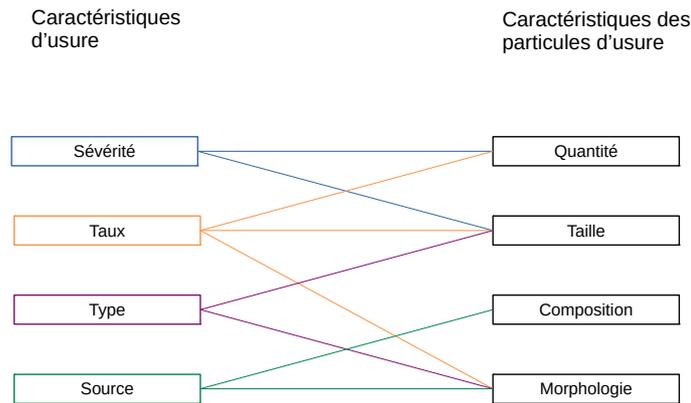


Figure II.11 – Relation entre caractéristiques d'usure et caractéristiques de particules d'usure [Roylance & Raadnu, 1994].

On voit sur la Figure II.11 que Roylance propose une correspondance entre caractéristiques d'usure et propriétés des particules. Ces propriétés sont extraites des images de troisième corps qui auront été préalablement retravaillées avec les techniques d'analyse d'image exposées dans le chapitre précédent. Un exemple en est donné en Figure II.12.

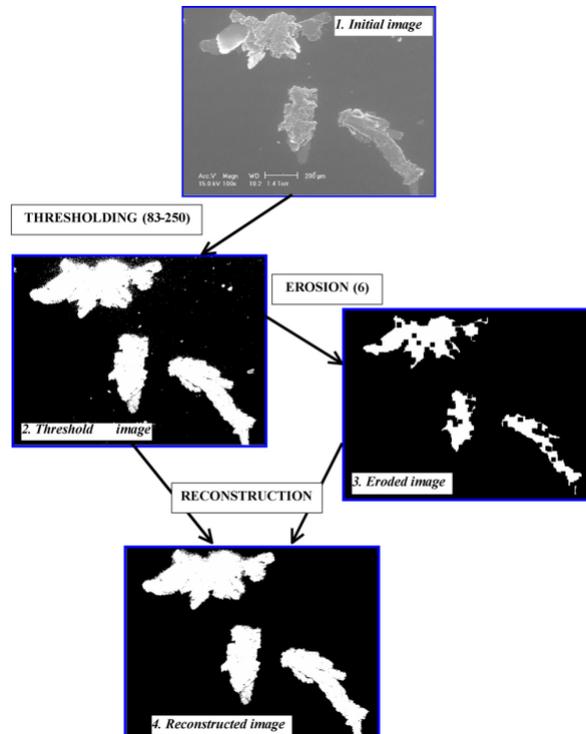


Figure II.12 – Exemple d'analyse d'image d'une particule d'usure [Kowandy et al., 2007]

Roylance propose ensuite un organigramme montrant comment à partir d'une image on peut arriver à des conclusions relatives à l'usure.

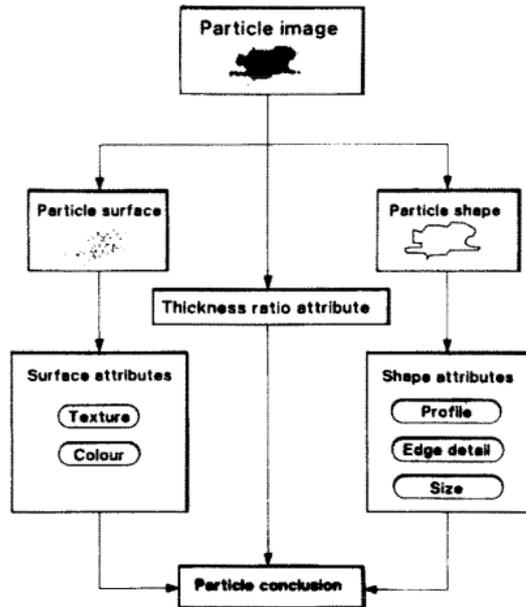


Figure II.13 – *Attributs morphologiques issus de l'analyse d'image [Roylance & Raadnui, 1994].*

A partir des descripteurs proposés en Figure II.13 il est alors possible de classer les particules en plusieurs catégories. Ces types de particules et leurs caractéristiques principales sont proposées dans le Tableau II.1.

Particle type	Features	Generation mechanism	Wear level	Possible machine operating condition
Rubbing	Thin, plane and oblong shape Size < 50 μm	By rubbing, particles caused from the damaged frictional part in the shear mixing layer	Normal	Normal wear particles without dramatic increase
Cutting	Slender or curved particles	Caused by sharp edges or hard particles penetrating the soft surface parts	Severe	Impending trouble of severe cutting wear
Spherical	Ball-like, hollow spheres	Generated by welding, grinding and erosion with the effect of temperatures in the fatigue cracks	Abnormal	An onset of early surface pitting or the severe wear under way
Fatigue	Smooth surfaces with pitting	Pitting after surface fatigue of friction pairs	Severe	Heavy load or over-speed
Severe sliding	Parallel scratches or grooves on its surface	Generated from severe sliding wear caused by excessive stress on the surface of friction pairs	Severe	The damage of oil film

Tableau II.1 – *Corrélation entre caractéristiques morphologiques et mécanismes de génération de particules d'usure [Thomas et al., 1991]*

Les descripteurs utilisés par Roylance ne sont pas les seuls exploitables, ci-après, une liste non exhaustive des descripteurs les plus fréquemment rencontrés dans la littérature.

— **Les propriétés de surface :**

- Couleur [Peng et al., 2017 ; Roylance & Raadnui, 1994]
- Texture [Roylance & Raadnui, 1994]

— **Les propriétés de forme :**

- Régularité [Jaza et al., 2016 ; Kowandy et al., 2007, 2008]
- Irrégularité [Kowandy et al., 2007, 2008]
- Circularité [Jaza et al., 2016 ; Kowandy et al., 2007, 2008 ; Thomas et al., 1991]
- Élongation [Jaza et al., 2016 ; Kowandy et al., 2007, 2008]

— **Les propriétés de frontière :**

- Lisse [Kowandy et al., 2007, 2008 ; Roylance & Raadnui, 1994]
- Rugueux [Kowandy et al., 2007, 2008 ; Roylance & Raadnui, 1994]
- Droit (rectiligne) [Kowandy et al., 2007, 2008 ; Roylance & Raadnui, 1994]
- Dentelé [Kowandy et al., 2007, 2008 ; Roylance & Raadnui, 1994]
- Incurvé [Kowandy et al., 2007, 2008 ; Roylance & Raadnui, 1994]

— **Les propriétés morphologiques :**

- Aire apparente [Kowandy et al., 2007, 2008 ; Peng et al., 2017 ; Peng & Kirk, 1998 ; Peng, 2002 ; Wang et al., 2019]

- Périmètre [Kowandy *et al.*, 2007, 2008]
- Ratio d'épaisseur [Roylance & Raadnui, 1994]
- Longueur [Kowandy *et al.*, 2007, 2008 ; Peng & Kirk, 1998 ; Peng, 2002]
- Diamètre du cercle équivalent [Kowandy *et al.*, 2007, 2008]
- Rotondité [Jaza *et al.*, 2016 ; Peng & Kirk, 1998 ; Peng, 2002 ; Roylance & Raadnui, 1994 ; Wang *et al.*, 2019]
- Ratio d'aspect [Kowandy *et al.*, 2007, 2008 ; Peng *et al.*, 2017 ; Peng & Kirk, 1998 ; Peng, 2002 ; Roylance & Raadnui, 1994 ; Thomas *et al.*, 1991 ; Wang *et al.*, 2019], le ratio d'aspect pourra être calculé avec différentes mesures, largeur, longueur, épaisseur, diamètre de Feret,...

On peut voir dans le Tableau II.1 une dernière colonne intitulée “Possible machine operating condition”, qui traduit le but industriel de nombreuses études menées sur les particules d'usure. En effet, outre le besoin de comprendre les mécanismes intervenant dans la vie du contact il est nécessaire d'en apprendre plus sur l'usure afin de prévoir la maintenance, les pannes, ou encore pour réduire la pollution et la consommation d'énergie sur les chaînes de production et/ou véhicules. C'est pourquoi une fois le lien entre caractéristiques d'usure et particules d'usure établi, les particules ont été classées dans des catégories (Rubbing, cutting,... voir Tableau II.1) en se basant sur des images de particules [Cho & Tichy, 2000 ; Kowandy *et al.*, 2007, 2008].

Remarque : Il est important de noter que souvent dans la littérature traitant de l'analyse d'image de particules d'usure il est question de contact lubrifié. A des fins d'analyses les particules sont retirées de leur site de production, le contact.

4 Conclusions

Ce chapitre aura permis d'exposer les outils de traitement et d'analyse d'image permettant, notamment, d'extraire des caractéristiques morphologiques des images de troisième corps. C'est cet ensemble de caractéristiques que nous allons chercher à relier aux données expérimentales. Pour cela nous allons avoir recours au *machine learning* ou apprentissage automatique. Ainsi dans le chapitre suivant, les principes de fonctionnement du *machine learning* sont tout d'abord présentés, de manière non exhaustive, avant une utilisation pour la tribologie.

CHAPITRE III

LE MACHINE LEARNING APPLIQUÉ AUX ÉTUDES TRIBOLOGIQUES

1 Qu'est ce que *le machine learning* ?

Commençons par donner une définition du *machine learning* ou apprentissage automatique.

“ *L'apprentissage est une modification d'un comportement sur la base d'une expérience.*”
[Benureau, 2015]

Ainsi un système (machine, homme, animal,...) va acquérir de l'expérience en produisant des réponses (outputs) à partir d'un ensemble d'entrées (inputs). Le principe du *machine learning* est de “nourrir” un système d'apprentissage à partir d'observations constituées d'inputs et d'outputs afin de lui permettre de créer et mettre à jour son modèle. Il pourra ainsi prédire quelle sera la sortie d'un nouvel input non présent dans les données ayant servi à l'entraînement.

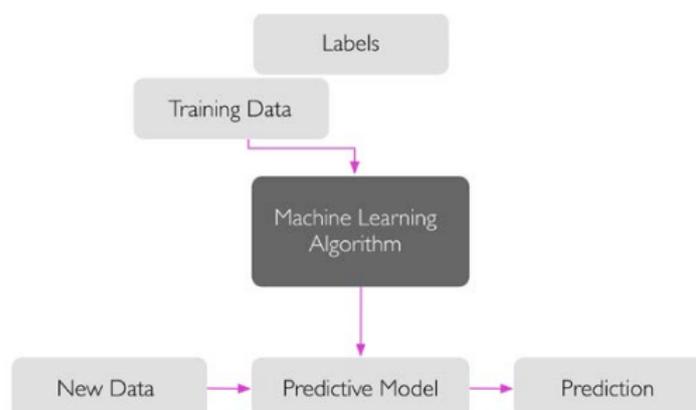


Figure III.1 – Fonctionnement simplifié du machine learning [Raschka & Mirjalili, 2017]

Les éléments fondamentaux du *machine learning* sont :

- Les données, elles servent à entraîner le modèle et à le valider,
- L'algorithme d'apprentissage, il s'agit d'une procédure que l'on exécute sur les données [Azencott, 2018].

Le *machine learning* sera utilisé pour résoudre différents types de problèmes : les problèmes que l'on ne peut pas résoudre analytiquement, ceux que l'on sait résoudre mais demandent de trop grandes ressources et ceux que l'on ne sait pas formaliser. Les réseaux de neurones et une grande partie des algorithmes utilisés étant basés sur le fonctionnement du cerveau humain [Lippmann, 1988], le *machine learning* n'est pas seulement utile dans les sciences physiques et informatiques, mais aussi dans les sciences sociales et neurologiques par exemple.

On distingue alors différents types de *machine learning* :

- L'apprentissage supervisé,
- L'apprentissage non supervisé,
- L'apprentissage de renforcement.

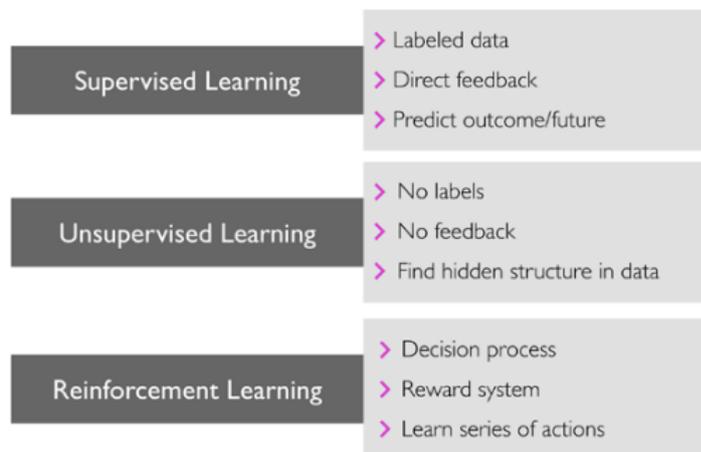


Figure III.2 – Caractéristiques des différents types de *machine learning* [Raschka & Mirjalili, 2017]

Dans notre cas, nous nous intéresserons surtout à l'apprentissage supervisé (voir section suivante). Avant de nous intéresser au fonctionnement nous commencerons par proposer un point de vocabulaire. Notre jeu de données est constitué :

1. D'échantillons aussi appelés, observations, exemples, samples ou data points.
2. De descripteurs, ce sont les caractéristiques des échantillons, ils sont aussi appelés variables, prédicteurs, attributs, features, caractéristiques,...
3. D'étiquettes, aussi appelées, cibles, labels, targets et outputs, chaque échantillon est associé à une étiquette.

Maintenant que nous disposons du vocabulaire nécessaire et du type de *machine learning* que nous souhaitons utiliser nous allons pouvoir nous intéresser au fonctionnement du modèle d'apprentissage.

2 Comment utiliser le *machine learning*

Nous avons donc choisi d'utiliser le *machine learning* supervisé dont le fonctionnement simplifié est illustré en Figure III.3.

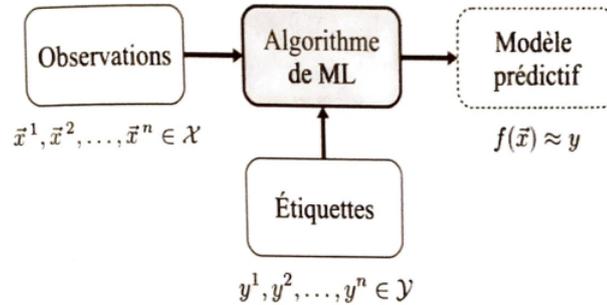


Figure III.3 – Apprentissage supervisé [Azencott, 2018]

Cette branche du *machine learning* nous permettra de résoudre des problèmes de classification binaire et multiclassés ainsi que des problèmes de régression à l'aide de différents algorithmes, il en existe des dizaines comme les réseaux de neurones [Hinton, 1990], les forêts aléatoires [Breiman, 2001], les réseaux de convolution [O'Shea & Nash, 2015]...

Comme nous l'avons vu sur la Figure III.2 nous disposons de données (échantillons) étiquetées pour entraîner l'algorithme choisi, nous permettant ainsi d'obtenir notre modèle.

Ce modèle devra être évalué avant d'être utilisé pour réaliser des prédictions ou des classifications. La Figure III.4 présente les différentes étapes détaillées ci-après.

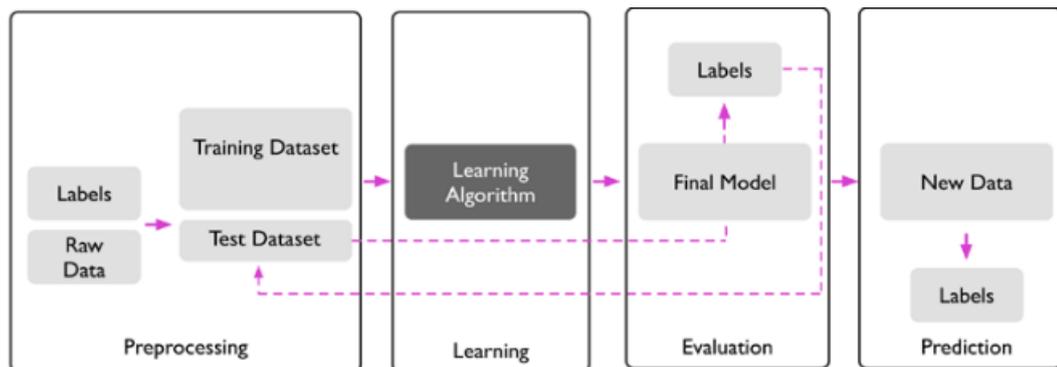


Figure III.4 – Diagramme de fonction du machine learning [Raschka & Mirjalili, 2017]

2.1 Le pré-processing

Il faut alors diviser notre base de données en jeux d'entraînement et de test. Le jeu d'entraînement permet à l'algorithme d'apprendre et ainsi de créer le modèle souhaité. Il intervient en phase d'apprentissage (Figure III.4), alors que le jeu de test sert à le valider et intervient donc en phase d'évaluation (Figure III.4), permettant de mesurer les performances de notre modèle.

Un des piliers du *machine learning* est le jeu de données, il est primordial d'avoir conscience qu'un jeu de données de mauvaise qualité aura une influence significative sur la qualité des prédictions effectuées par le modèle. Les données d'entraînement doivent être représentatives des futurs cas traités par le modèle pour obtenir une bonne généralisation. Les données sont de mauvaise qualité quand on utilise des données non ou peu pertinentes, dans ce cas on parle de "garbage in , garbage out" : si les données d'entrée sont mauvaises alors la sortie le sera aussi.

Lors du découpage (généralement aléatoire) on alloue classiquement 80% des données à l'entraînement et 20% au test. Les données sont alors organisées en matrice dont les lignes correspondent aux échantillons et les colonnes à leurs features. À cette matrice est associé un vecteur contenant les étiquettes correspondant à chaque échantillon (Figure III.5).

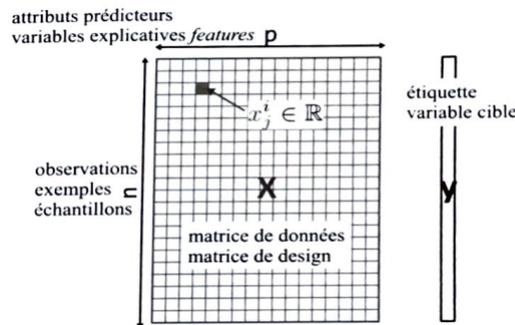


Figure III.5 – Organisation des données en apprentissage supervisé [Azencott, 2018]

2.2 La phase d'apprentissage

Maintenant que nous avons abordé le sujet des jeux de données nous allons regarder comment elles sont traitées par l'algorithme d'apprentissage. Pour une meilleure compréhension nous nous intéresserons au cas d'un neurone unique en classification binaire. La théorie du single perceptron développée par Rosenblatt en 1957 [Rosenblatt, 1957] utilisé pour la classification binaire fut améliorée par Bernard Widrow et son doctorant Tedd Hoff en 1960 et fut baptisée Adaline [Laboratories *et al.*, 1960]. C'est ce modèle que nous aborderons car il illustre les principes de minimisation de fonction de coût qui seront présentés ci-après.

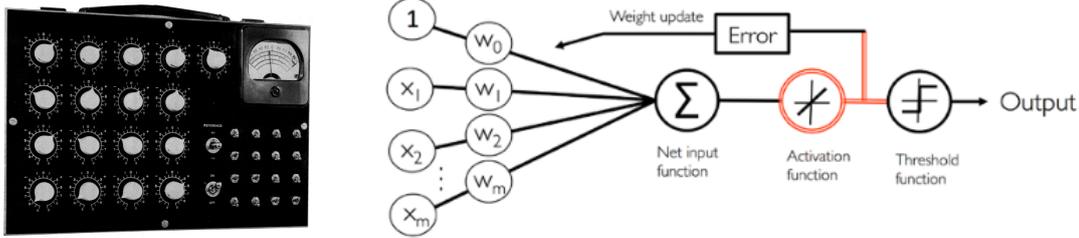


Figure III.6 – A GAUCHE : Adaline tel qu’il a été conçu en 1960 sous forme d’un dispositif analogique [Laboratories et al., 1960]. A DROITE : Schéma fonctionnel “moderne” de Adaline [Raschka & Mirjalili, 2017]

Pour chaque échantillon on a $(m+1)$ features x_i (Figure III.6) ; à chaque feature est associé un poids w_i (poids synaptiques). Ce poids synaptique va être mis à jour à chaque itération (ou epoch), ainsi

$$\mathbf{w}_{n+1} = \mathbf{w}_n + \eta \nabla J, \quad (\text{III.1})$$

Avec ∇J le gradient de la fonction coût et η le coefficient d’apprentissage.

Dans le cas d’Adaline la fonction de coût à optimiser peut être définie comme la somme au carré de l’erreur (SSE) entre les outputs calculés et les vrais labels [Raschka & Mirjalili, 2017].

C’est la présence d’une fonction d’activation dans Adaline qui le différencie du perceptron de Rosenblatt. Ainsi la procédure de modification des poids synaptiques des connexions est appliquée par la méthode des moindres carrés [Faure, 2006]. Le modèle pourra être modifié en changeant de fonction d’activation, par exemple en utilisant une sigmoïde afin d’augmenter la robustesse du modèle, ou en modifiant la façon de calculer le gradient. Nous avons utilisé ici la méthode de gradient descendant. Il est courant d’avoir recours à la méthode du gradient stochastique quand la base de données est très grande et demanderait trop de ressources avec un gradient descendant “classique”.

On peut donc conclure en disant que la phase d’apprentissage correspond à la minimisation de l’erreur entre valeurs prédites et étiquettes. Une fois l’erreur minimisée le neurone peut classer ou prédire (selon la tâche qui lui est demandée).

Un modèle est défini par des paramètres qui lui sont propres, on parle d’hyperparamètres. Ces paramètres peuvent grandement influencer la performance du modèle. Il est alors possible de créer plusieurs modèles entraînés sur la même base mais présentant des hyperparamètres différents, choisir la combinaison optimale revient à évaluer les performances des modèles.

2.3 La phase d’évaluation

Lors de la phase d’évaluation (Figure III.4) nous allons utiliser le jeu de données test que nous avons mis de côté afin d’estimer l’erreur de généralisation de notre modèle. Il est impératif d’utiliser des données non vues par l’algorithme durant son apprentissage pour calculer ses performances. Il est toutefois pertinent de calculer l’erreur de chacun des modèles indépendamment afin de choisir le plus approprié à la situation. Pour calculer

l'erreur de généralisation, il est alors nécessaire d'utiliser un autre jeu de données ; les données test ayant déjà été utilisées pour la sélection. Pour palier cela il est plus commode de découper la base de données en 3 :

- Le jeu d'entraînement sur lequel nous entraînerons nos différents modèles. Il représente communément 70% des données.
- Le jeu de validation qui servira à évaluer les modèles et sélectionner le modèle définitif. On choisit en général 20% des données.
- Le jeu de test pour calculer l'erreur de généralisation du modèle sélectionné. On prend les données restantes (généralement 10%).

Il est important de bien distinguer la sélection du modèle de son évaluation, car si on utilise le même jeu de données pour les deux opérations cela peut nous conduire à sous-estimer l'erreur de généralisation. Il est possible de ré-entraîner le modèle sélectionné à l'aide du jeu d'entraînement et de validation réunis et ainsi construire un modèle final et l'évaluer sur le jeu test.

Remarque : Si l'erreur d'apprentissage est faible mais l'erreur de généralisation élevée on dit que notre modèle surajuste. Le surajustement ou *overfitting* apparaît quand le modèle est trop complexe par rapport à la quantité de données d'apprentissage ou quand les données sont trop bruitées. Il a du mal à généraliser. Pour éviter l'*overfitting* on pourra :

- Simplifier le modèle en sélectionnant moins de paramètres.
- Réunir plus de données d'apprentissage.
- Retirer le bruit des données.

Aurélien Géron [Géron, 2019] propose un exemple illustrant bien le phénomène de sur-apprentissage : On cherche à estimer l'indice de satisfaction de la population d'un pays, les échantillons présentent de nombreuses features notamment le nom du pays. Un modèle complexe pourra détecter des structurations dans les données tel qu'un indice de satisfaction élevé quand le nom du pays contient un W (Norway, Sweden, New-Zealand, Switzerland). Mais la règle du "W-satisfaction" ne s'appliquera probablement pas au Rwanda ou Zimbabwe.

De même quand les données sont trop bruitées un modèle trop complexe pourrait trouver des sous-structures dans le bruit. C'est pourquoi il faut rester vigilant à la qualité et la pertinence des données que l'on utilise.

3 Algorithmes utilisés dans ce projet

Dans ce travail, deux algorithmes de *machine learning* ont été utilisés : Les réseaux de neurones de type *Multi Layer Perceptron* ou MLP et les *Random Forest* ou RF. Ces choix seront justifiés lors de leur implémentation dans les chapitres V pour le MLP et VI pour la RF. Nous proposons ici une description de ces modèles ainsi que les hyperparamètres permettant de les définir.

Les réseaux de neurones (MLP)

Constitué d'un ensemble de neurones répartis en couches, le réseau de neurones se caractérise par son nombre de couches, le nombre de neurones les constituant, la nature des

relations entre neurone et les fonctions d'assemblage et d'activation de chaque neurone [Khichane, 2021]. Nous avons fait le choix d'utiliser le module python scikit-learn [Pedregosa *et al.*, 2011] pour implémenter le MLP que nous utiliserons dans le chapitre IV. Ce module propose une grande variété d'algorithmes de *machine learning* et particulièrement des réseaux de neurones "simples" permettant une implémentation rapide et une prise en main simplifiée de par le nombre restreint de ses hyperparamètres, la documentation technique de scikit-learn présente les hyperparamètres ainsi que le fonctionnement général de l'algorithme [Pedregosa *et al.*, 2011].

Les forêts aléatoires (RF)

Avant de présenter la Forêt aléatoire (RF) il est nécessaire de présenter le concept d'arbre de décisions. Un arbre de décision est dans un premier temps constitué d'un noeud racine qui va contenir toutes les observations de la base d'apprentissage. Classiquement, ce noeud va se diviser en 2 noeuds enfants à l'aide d'une règle de séparation choisie en fonction de la tâche allouée à l'arbre, des exemple de règles ainsi que leur fonctionnement sont décrit dans [Azencott, 2018 ; Géron, 2019 ; Khichane, 2021 ; Raschka & Mirjalili, 2017]. Cette division est alors répétée jusqu'à l'obtention des feuilles, qui sont les niveaux les plus bas de l'arbre. La profondeur (i.e. le nombre) de ces niveaux peut être paramétrée à l'aide des hyperparamètres du modèle. Gérard Biau [Biau, 2012] propose une définition "simple" de ce concept : les arbres de décisions sont des outils permettant de couper l'espace de façon récursive avec des prises de décisions locales. De façon empirique il est constaté qu'à chaque étape de construction des arbres une règle de décision différente aurait pu être choisie. Ainsi pour palier ce phénomène il est possible de constituer une collection d'arbres appelée forêt permettant ainsi de combler l'instabilité des prédictions d'un arbre seul [Khichane, 2021]. Une autre vertu de cette méthode est la diminution de la complexité du problème car chaque arbre de la forêt va être amené à traiter moins de données [Biau, 2012]. Cet échantillonnage va également permettre de mettre de côté des données non utilisées pour construire les arbres, ces dernières seront utilisées pour faire de la sélection de variable. Comme pour le MLP il est possible de se référer à la documentation pour plus de détails quant au fonctionnement et aux hyperparamètres de cette méthode¹.

3.1 Ajustement des hyperparamètres

Pour les deux algorithmes utilisés nous serons amenés à ajuster les hyperparamètres. Ainsi comme il a été démontré par [Genuer *et al.*, 2010 ; Scornet, 2017] les hyperparamètres significatifs seront pour :

- MLP :
- *hidden-layer-sizes* : Cet hyperparamètre en cache deux : le nombre de couches et le nombre de neurones par couche.

1. MLP : https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPClassifier.html

RF : <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>

- *learning-rate-init* : Le taux d'apprentissage initial, il contrôle la taille du pas dans la mise à jour des poids.
- RF :
 - *n-estimators* : Nombre d'arbres constituant la forêt.
 - *max-depth* : La profondeur maximale de l'arbre. Si None, les nœuds sont développés jusqu'à ce que toutes les feuilles soient pures ou jusqu'à ce que toutes les feuilles contiennent moins que *min-samples-split* échantillons.
 - *min-samples-split* : Le nombre minimum d'échantillons requis pour diviser un nœud interne.
 - *max-features* : Le nombre de caractéristiques à prendre en compte lors de la recherche de la meilleure division.

Quand il s'agit d'ajuster (on parle également de tuning) les hyperparamètres il faut procéder en plusieurs étapes. La première est de déterminer quels sont les paramètres les plus influents. Pour cela il est possible de procéder de façon empirique en faisant varier tour à tour les paramètres [Genuer *et al.*, 2010 ; Scornet, 2017]. Il est également possible d'utiliser les méthodes d'analyse de sensibilité telles que la méthode de Morris [Morris, 1991], les algorithmes génétiques (GA) ou encore le plan d'expérience de Taguchi [Ansari *et al.*, 2021 ; Guo *et al.*, 2022] qui vont permettre de faire une sélection dans les paramètres à régler. Une fois les hyperparamètres pertinents sélectionnés il est possible d'utiliser deux outils développés dans scikit-learn, il s'agit de *RandomizedSearchCV* et *GridSearchCV*.

Commençons par *GridSearchCV*, l'utilisateur va créer une grille de paramètres à tester, puis définir un modèle vierge à entraîner. La méthode *GridsearchCV* va alors tester toutes les combinaisons d'hyperparamètres à sa disposition et proposer la plus performante. Cette méthode convient particulièrement aux cas où il existe une petite quantité de paramètres à tester. Si l'espace de recherche est vaste il est préférable d'utiliser *RandomizedSearchCV* [Géron, 2019]. Au lieu d'essayer toutes les combinaisons possibles, elle va en évaluer un nombre défini par l'utilisateur. A chaque itération la méthode sélectionne une valeur aléatoire de chaque hyperparamètre.

Maintenant que nous avons présenté les outils et leurs différents attributs, nous pouvons nous intéresser à leur mise en œuvre dans le domaine de la tribologie et plus spécifiquement dans le cas de contacts secs.

4 Le *machine learning* au service de la tribologie

4.1 Objectifs

Comme nous l'avons vu dans le chapitre II il est nécessaire d'avoir recours à l'analyse d'image pour analyser le 3^e corps d'un point de vue quantitatif. Cela passe par un traitement préalable de l'image puis par l'extraction de descripteurs pertinents (descripteurs de surface, morphologiques,...). Un exemple de *workflow* est proposé en Figure III.7, les images traitées ici sont prises dans le cadre d'étude de frottement sec.

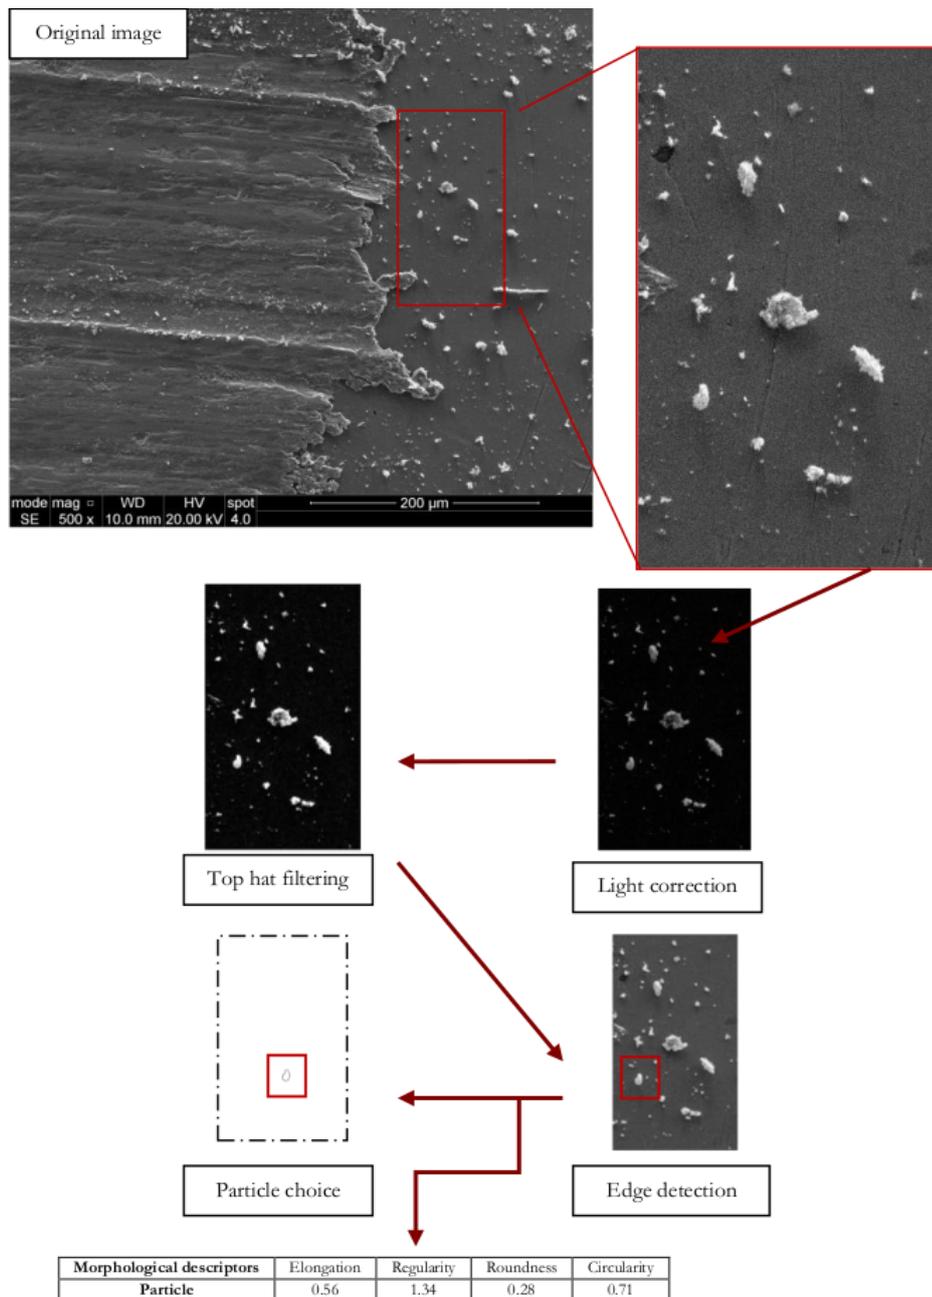


Figure III.7 – Exemple d'analyse d'image pour extraction de caractéristiques morphologiques des particules [Jaza et al., 2016]

A l'aide de ces descripteurs on peut alors classer les particules dans des familles selon le mécanisme d'usure intervenu durant leur création, cela nous permet de comprendre ce qu'il s'est passé durant le contact. Comme nous l'avons précisé de nombreuses études sont réalisées dans un cadre industriel à des fins de maintenance ou de prévision de panne. C'est avec cet objectif en tête que de nombreux chercheurs ont eu l'idée d'utiliser des algorithmes intelligents afin de lever la subjectivité et réduire le temps nécessaire à la classification manuelle.

Un autre objectif était de créer des outils à destination des industriels qui pourraient être utilisables par un technicien non tribologue. Prenons l'exemple des travaux de Peng [Peng, 2002] dans son article il présente la création d'un logiciel *tribologica* permettant d'analyser les particules d'usure contenues dans l'huile et de donner des directives de maintenance. Le fonctionnement de ce logiciel est simplifié et présenté en Figure III.8.

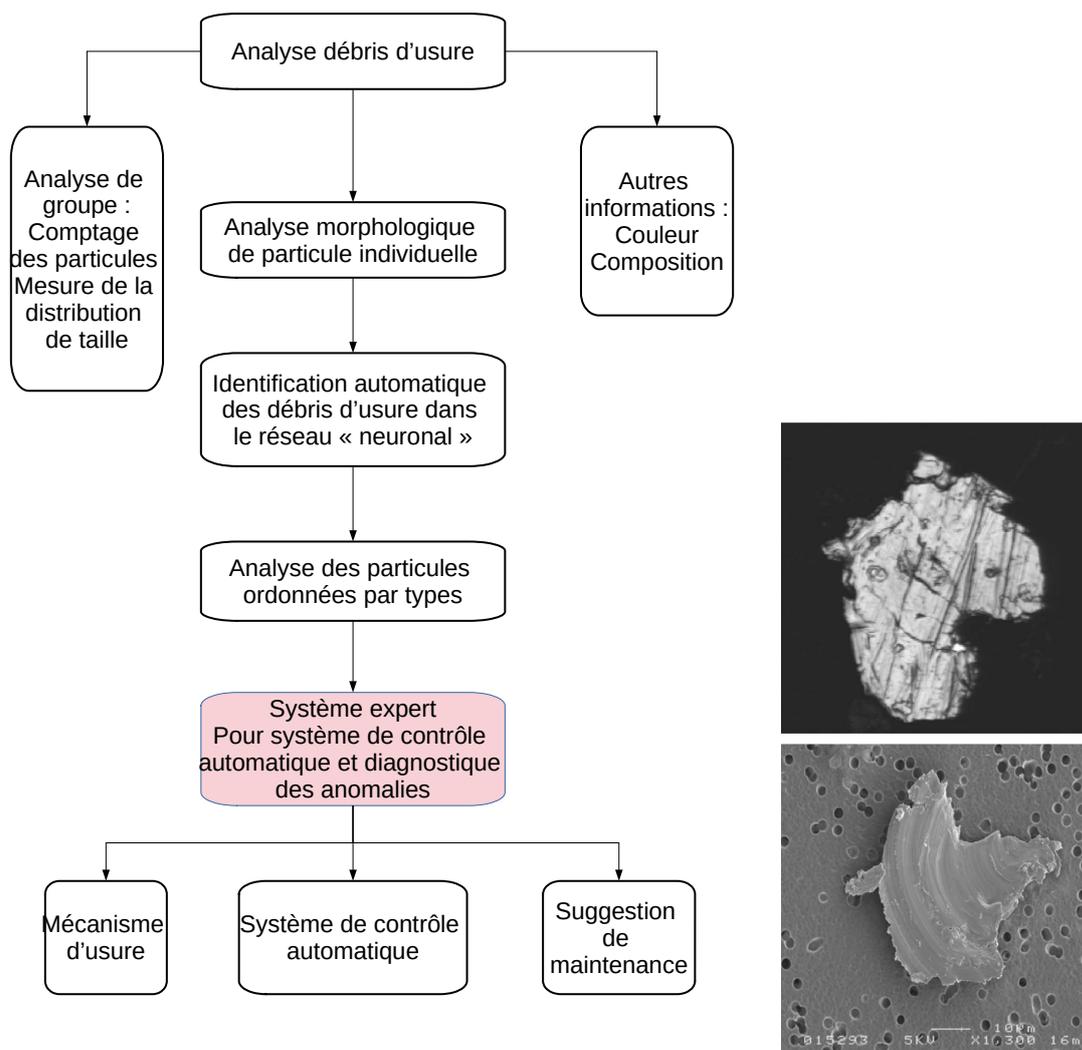


Figure III.8 – DROITE : Composants du système intégré pour le logiciel *tribologica*. GAUCHE : Exemple de particules traitées par *tribologica*. [Peng, 2002]

On retrouve dans l'organigramme de la Figure III.8 l'analyse des débris d'usure et leur ordonnancement dans des catégories permettant de déterminer quel mécanisme d'usure est prédominant dans la vie du contact.

4.2 Machine learning et classification

Cette volonté d'automatiser le processus de classification a commencé bien avant la démocratisation des réseaux de neurones, Lippmann qui exposait les propriétés de différents réseaux en 1988 [Lippmann, 1988] spécifiait bien qu'il n'y avait pas encore d'applications concrètes mais présentait le potentiel de tels outils. C'est pourquoi les débuts de la classification automatique se sont fait avec ce que l'on nomme système expert [Peng, 2002 ; Thomas *et al.*, 1991]. Ce sont des outils basés sur les machines d'inférences [Mackay, 2003] qui fonctionnent à l'aide d'une base de données constituée de faits et d'une base de connaissances constituée de règles. Le but étant de reproduire les mécanismes cognitifs d'un expert. Nous avons vu en Figure III.8 les composants du système intégré, la case rose de l'organigramme correspond au système expert dont le fonctionnement est présenté en Figure III.9.

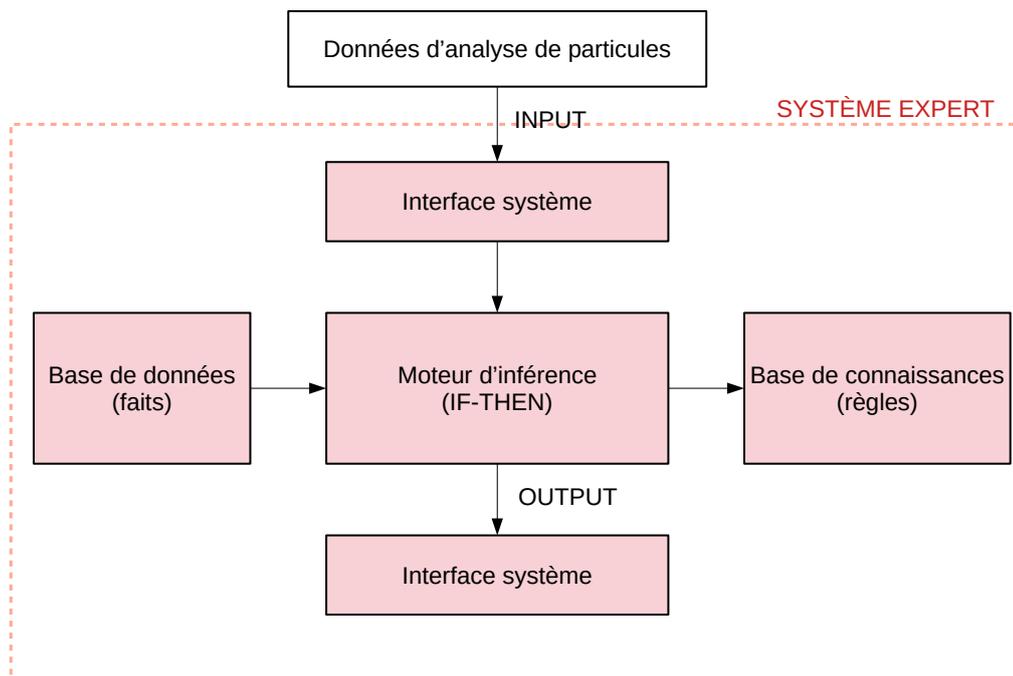


Figure III.9 – Fonctionnement du système expert de tribologica [Peng, 2002]

Le fonctionnement de tels systèmes est le suivant : si A (un fait) est vrai et si on sait que A implique B (un règle) alors A est vrai et devient un nouveau fait ou la réponse à la question d'expertise demandée. On nourrit le moteur d'inférence avec les données issues de l'analyse d'image et ce dernier pourra déterminer quel est le mécanisme d'usure

responsable de la création de ces particules ou encore suggérer des instructions de maintenance. On note toutefois (Figure III.8) que les particules sont préalablement triées par un réseau de neurones contrairement aux travaux de Thomas [Thomas *et al.*, 1991] qui n'utilisait que le système expert.

D'autres approches ont également été abordées, comme l'utilisation de méthodes statistiques et de dendrogramme [Cho & Tichy, 2000]. Ces méthodes vont permettre de lever toute subjectivité et créer des groupes de particules ayant des caractéristiques morphologiques similaires. Cela a donné des résultats concluants mais on remarque à travers la littérature que ce n'est pas la méthode majoritairement utilisée par la communauté des tribologues. En effet les systèmes expert et les méthodes statistiques ont été supplantés par l'essor des réseaux de neurones.

Réseaux de neurones : L'utilisation du *machine learning* et plus spécifiquement du réseau de neurone est une des plus répandues et donne des résultats très concluants [Peng *et al.*, 2017 ; Peng & Kirk, 1998 ; Wang *et al.*, 2019] en classification. Dans un premier temps des comparaisons de réseaux de neurones ont été réalisées, on retiendra les travaux de Peng et Kirk [Peng & Kirk, 1998] dans lesquels ils comparaient l'efficacité de deux réseaux, un supervisé et un non supervisé (pour plus de détails concernant les propriétés intrinsèques des réseaux on pourra consulter les travaux de Lippmann [Lippmann, 1988]). Dans leur cas les deux réseaux avaient donné des résultats satisfaisants, le réseau supervisé avait de meilleures performances et a donc été retenu pour des études ultérieures ainsi que pour de possibles utilisations industrielles. Toutefois les chercheurs se sont heurtés à des difficultés lors de la classification des particules "Severe sliding" et "Fatigue". Pour palier ce problème ils ont cherché à combiner les algorithmes intelligents. On peut par exemple parler du modèle hybride (Figure III.10) combinant trois algorithmes de *machine learning* (SVDD, k-moyennes, SVM), chacun intervenant sur une partie du processus de classification.

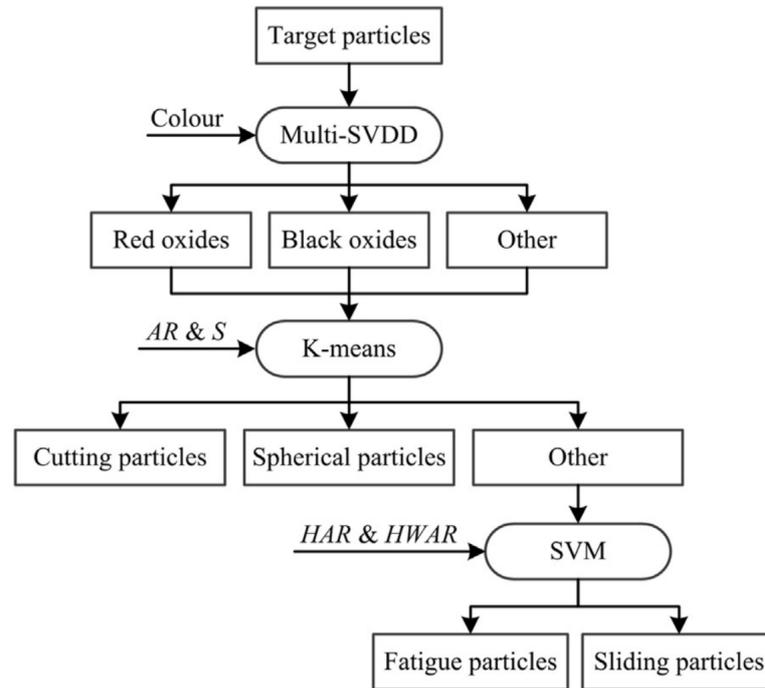


Figure III.10 – *Modèle de discrimination hybride sous forme d’arbre [Peng et al., 2017]*

Les paramètres choisis pour la classification (features) ont été suffisamment discriminants mais la méthode a besoin de plus de données et d’optimisation si l’on veut conclure sur sa précision.

Enfin dans la même optique il a été testé l’utilisation combinée de réseau de neurones de type MLP et du deep learning (via un réseau CNN Convolutional Neural Network) [Wang et al., 2019].

Point théorique sur le deep learning : Le deep learning est une sous catégorie du *machine learning*. En deep learning le réseau (constitué de nombreuses couches) va parcourir un grand nombre d’échantillons identifiés (par exemple : “cette image contient un chat”) et va extraire lui-même les caractéristiques dont il a besoin pour effectuer sa classification [Habba & Ishak, 2019]. On dit que les données d’entrée présentent un haut niveau d’abstraction.

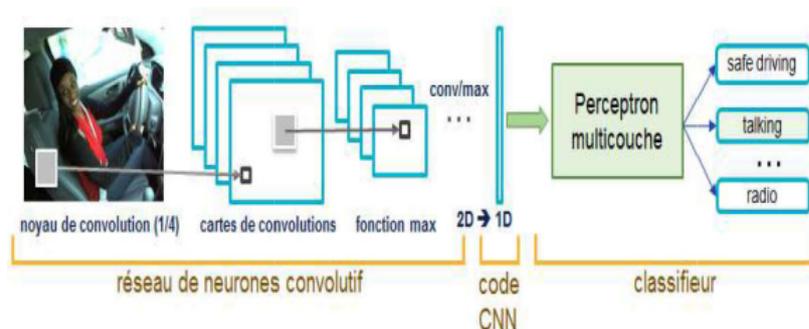


Figure III.11 – *Convolutional Neural Network [Habba & Ishak, 2019]*

Prenons l'exemple du CNN utilisé par Wang [Wang *et al.*, 2019], l'input est une image présentée au réseau sous la forme d'une matrice (2D pour les images en niveaux de gris et 3D pour les images couleurs). La première partie du réseau est la partie convolutive, elle va extraire les caractéristiques de l'image. Pour cela l'image va passer à travers différents filtres et créer des images intermédiaires appelées cartes de convolution. Ces dernières sont alors mises à plat et concaténées dans un vecteur qui contiendra les caractéristiques, il est appelé code CNN. Ce code CNN va alors servir d'entrée à un réseau MLP (Multi Layer Perceptron), qui est un "assemblage" de perceptrons qui vont alors procéder à la classification.

Toutefois attention! Le deep learning de par son fonctionnement nécessite une quantité de données d'entrée énorme, ce qui explique qu'il est peu utilisé pour des applications complexes qui produisent une quantité de données limitée.

Maintenant que nous avons défini le fonctionnement du deep learning et plus particulièrement du CNN nous pouvons nous intéresser au travail effectué par Wang [Wang *et al.*, 2019]. Comme nous l'expliquions avant les tribologues ont rencontré des difficultés pour classer certains types de particules avec les algorithmes de *machine learning*. C'est à partir de ce constat que Wang a tenté de combiner un algorithme de *machine learning* qu'il qualifie de "traditionnel", c'est-à-dire un réseau entraîné à partir d'une base de données comprenant des features et des étiquettes, avec un CNN. Les résultats obtenus sont très encourageants, 80% de précision pour le CNN là où le *machine learning* n'obtenait que 40%, et laisse entrevoir des possibilités d'applications industrielles. Ces résultats très disparates posent cependant la question de la qualité de la base de données et plus spécifiquement du choix des descripteurs utilisés. En effet, dans l'étude de [Wang *et al.*, 2019] le réseau "classique" est entraîné avec sept caractéristiques mais n'obtient qu'une performance moyenne, là où le CNN est très performant. Cela indique que ce dernier trouve des caractéristiques pertinentes dans l'image que le tribologue n'a pas sélectionné dans sa liste. Cela ouvre des perspectives quant à l'étude des descripteurs afin de définir le troisième corps avec plus d'efficacité.

4.3 Machine learning et prédiction

Jusqu'à présent nous n'avons abordé que les problèmes de classification, or comme nous l'avons exposé lors du chapitre précédent le *machine learning* peut également servir à faire de la prédiction. Cette utilisation est encore peu répandue en tribologie mais l'on retrouve quand même quelques exemples de prédiction de durée de vie de matériaux. Un exemple d'application en mécanique est réalisé par Pestana [Pestana *et al.*, 2018], il utilise un réseau de neurone contenant une couche de 14 neurones. Les résultats seront satisfaisants pour réaliser une étude préliminaire avant de lancer une campagne d'expérimentation longue et couteuse, car ils fournissent une courbe de tendance acceptable en première estimation. Mais le modèle aura besoin de plus de données expérimentales pour compléter son entraînement.

Récemment une étude a été menée par Nowell et Nowell pour prédire la durée de vie en fatigue d'un matériau (alliage d'aluminium) en essais de fretting [Nowell & Nowell, 2020]. Pour cela ils ont utilisé un modèle similaire à celui de Pestana (une seule couche de neurones) et ont réalisé plusieurs tests pour trouver les paramètres d'apprentissage les plus efficaces. Lors de cette étude il est conclu que la classification en durée de vie longue ou courte sera bien réalisée mais que la prédiction manquera de précision.

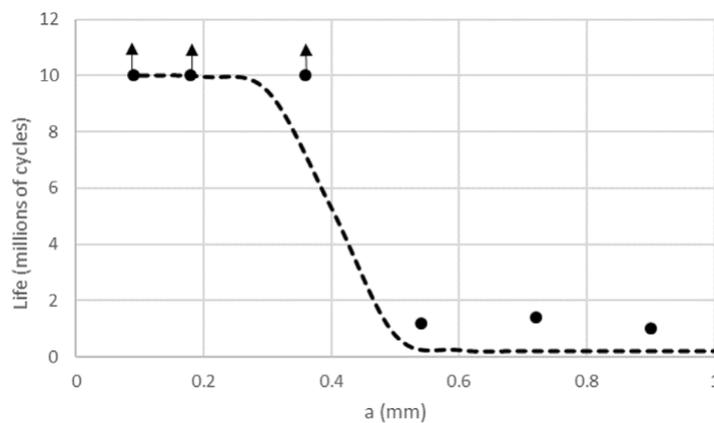


Figure III.12 – Evolution de la durée de vie en fatigue en fonction de la demi largeur de contact a . [Nowell & Nowell, 2020]

Les points sur la Figure III.12 correspondent aux données expérimentales, la flèche signifiant que la durée de vie est plus grande que le nombre de cycles effectués lors des expériences, et la courbe est la prédiction obtenue via le réseau.

Ils expliquent les écarts de prédiction par un manque de données d'entrée. On constate également que le réseau a du mal à prédire ce qu'il se passe entre les zones à grande et faible durée de vie, cela vient également d'un manque de données situées dans cette zone durant l'entraînement. Un dernier point soulevé par cette étude est l'importance qui peut être donnée à un paramètre durant la phase d'apprentissage. En effet les données ayant servi à l'entraînement du réseau de neurones sont issues des expériences de Nowell visant à évaluer l'influence de la demi-largeur de contact " a " sur la durée de vie en fatigue. Le paramètre " a " aura de par le plan d'expériences choisi un effet important.

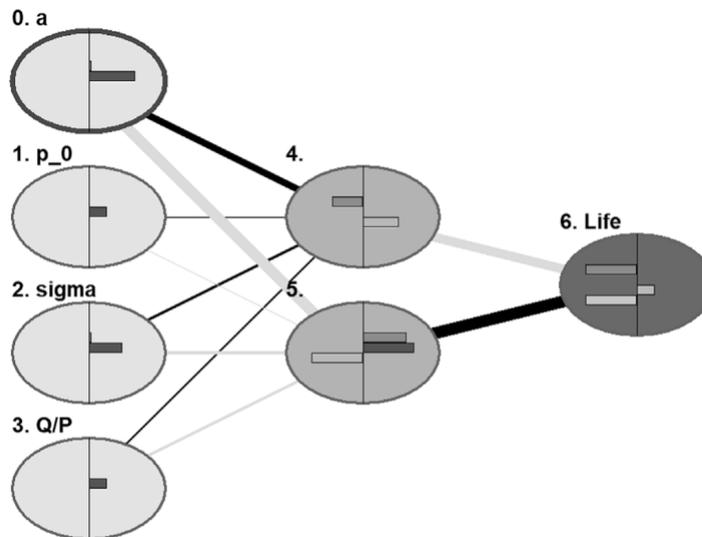


Fig. 8. Schematic of the final network with line thicknesses indicating the importance of the links. Grey links signify positive weights and black links negative weights.

Figure III.13 – Schéma illustrant le poids de chaque feature durant la phase d'apprentissage [Nowell & Nowell, 2020]

On peut donc penser en observant la Figure III.13 que ce choix de données d'entrée va influencer le réseau durant son apprentissage et nous renvoie à la vigilance qu'il faut avoir à l'élaboration de notre base de données et à la mémoire de sa construction.

4.4 Observations et conclusions

Après avoir présenté quelques utilisations du *machine learning* en lien avec la tribologie nous allons pouvoir aborder les difficultés et observations faites par les différents chercheurs. Ce qui est le plus souvent déploré est le manque de données, surtout quand il est question de prédiction. L'entraînement d'un réseau de neurone en *machine learning* demande beaucoup de données étiquetées et il est parfois difficile de les lui fournir. Prenons l'exemple de Pestana [Pestana *et al.*, 2018], les expériences pour lesquelles il cherche à faire des prédictions demandent plusieurs mois il est donc difficile d'en réaliser un grand nombre pour "nourrir" le modèle d'apprentissage. Que ce soit pour des raisons de temps ou de coût il est donc difficile de produire suffisamment de données brutes, malgré des techniques d'augmentation de données.

5 Conclusions

Cet état de l'art renforce la volonté que nous avons d'utiliser le *machine learning*, en effet, l'étude du frottement est un sujet qui regroupe les trois critères d'utilisation du *machine learning* : on ne sait pas le formaliser avec précision, il ne peut pas être résolu analytiquement, l'utilisation de méthodes alternatives telle que l'ANAVAR (analyse de la

variance) proposée au chapitre VI demande de trop grandes ressources. Il faudra toutefois garder à l'esprit certaines considérations :

- La grande disparité des matériaux, des protocoles expérimentaux et tribomètres utilisés dans la communauté scientifique rendent complexe la construction de base de données tribologique globales. Il serait nécessaire de réfléchir à des critères systématiques à mettre en place car la concaténation arbitraire des données, même à une échelle réduite (échelle d'un laboratoire) engendrerait des données non pertinentes ce qui créerait un "garbage in, garbage out" et donc des résultats médiocres.
- Une autre observation que l'on retrouve fréquemment dans la littérature est que les réseaux de neurones mis à disposition ont un côté "boite noire" qui ne permet pas une compréhension complète et une maîtrise totale du processus d'apprentissage. Cela est d'autant plus vrai lors de l'utilisation d'algorithme de type CNN (deep learning) où la donnée d'entrée est une image. C'est pour ces raisons que de plus en plus d'outils sont développés pour apporter de l'explicabilité à ces modèles [Genuer *et al.*, 2010 ; Lundberg & Lee, 2017a].

Toutefois nous avons pu voir à travers cet état de l'art des perspectives très intéressantes notamment avec l'utilisation combinée de plusieurs algorithmes intelligents ou encore l'utilisation de machine d'inférence pour compléter l'action d'un réseau de neurone. Mais le point primordial qui ressort de cet état de l'art est la qualité de la base de données, c'est le soin apporté à l'élaboration de cette dernière qui sera déterminant quant à la qualité des résultats produits par les modèles de *machine learning*, quel que soit l'algorithme utilisé.

Deuxième partie

Projet Morpho-Tribo

Dans ce chapitre nous commencerons par présenter le contexte expérimental amenant à la formation du troisième corps à étudier. Puis nous exposerons les conditions d'acquisition d'images MEB de ce dernier, pour enfin procéder son étude qualitative.

1 Banc d'essai et conditions expérimentales

Les premiers corps sont fabriqués en 35CrNiMo16 (Euronorm), un acier faiblement allié, dont les propriétés chimiques et mécaniques sont présentées dans les tableaux IV.1 et IV.2.

C(%)	Mn(%)	Si(%)	Ni(%)	Cr(%)	Mo(%)	S(%)
0,32-0,39	0,50-0,80	0,10-0,40	3,60-4,10	1,60-2,00	0,25-0,45	$\leq 0,025$

Tableau IV.1 – *Composition chimique de l'acier 35CrNiMo16*

E(MPa)	ν	$R_{p0,2\%}$ (MPa)	R_m (MPa)	Dureté
205000	0,3	0,10-0,40	3,6-4,10	50HRC

Tableau IV.2 – *Propriétés mécaniques de l'acier 35CrNiMo16*

Les expériences sont réalisées sur un tribomètre de type pion - disque. Les pions sont usinés avec un rayon de courbure de $5\text{mm} \pm 0.80$. Un nouveau pion est utilisé pour chaque essai.

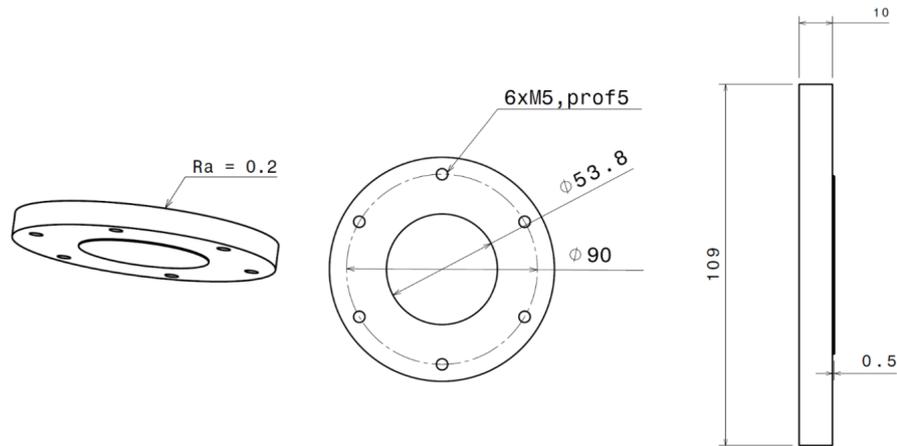


Figure IV.1 – Dessin technique des disques (ici disque de 10mm d'épaisseur)

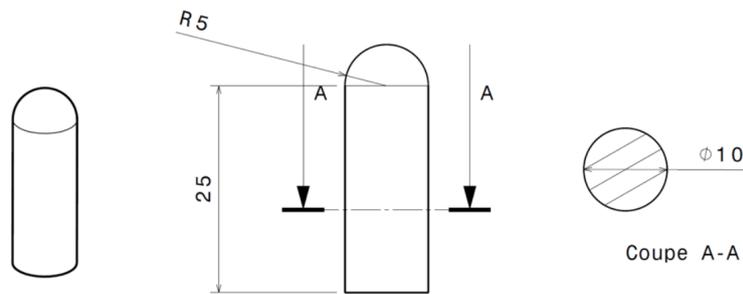


Figure IV.2 – Dessin technique des pions

Deux types de disque sont utilisés, l'un avec une épaisseur de 10mm et l'autre de 15mm.

Avant les analyses et les essais de glissement, les disques et les pions doivent être identifiés, un numéro leur est attribué et est gravé sur la tranche pour le disque et sur la base pour le pion. Afin de conserver l'information spatiale au cours des tests, nous allons ajouter un repère orthogonal au centre de ces derniers à l'aide d'un crayon à pointe diamant ainsi que des points de repère tous les 15 degrés nécessaires pour les études *post-mortem*. Les surfaces des échantillons tels que reçus sont nettoyées par ultrasons et chimiquement dans un bain d'acétone pendant 5 min. Ce nettoyage permet d'éliminer la pollution résiduelle due à la manipulation et à l'usinage des échantillons. Ensuite, un rinçage est effectué dans un bain d'éthanol pendant 5 min. Les surfaces initiales et les morphologies de surface des disques et des pions sont analysées à l'aide d'un profilomètre optique sans contact Zygo Zegage PRO. Le logiciel Mountain Mx™ permet d'obtenir des vues 3D des surfaces et les paramètres de rugosité, comme proposé en Figure IV.3. La rugosité moyenne quadratique des surfaces initiales pour les disques utilisés est de $S_a = 0.207\mu m$.

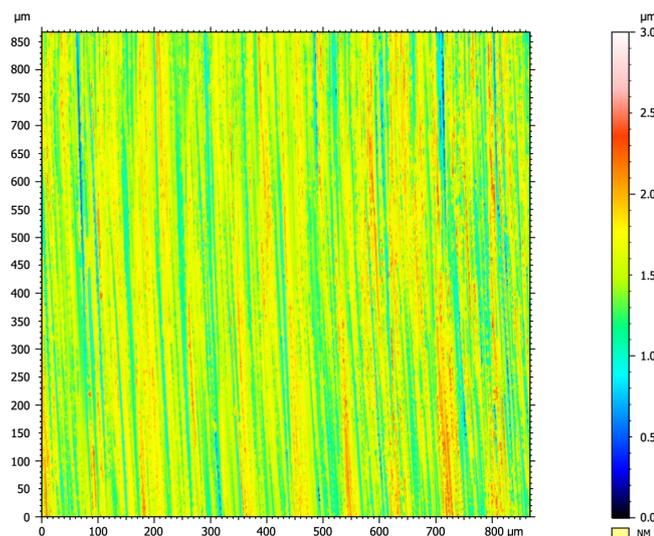


Figure IV.3 – Vue 3D de la surface initiale du disque D12

Les essais de glissement sont effectués à l'aide d'un tribomètre construit sur mesure au LaMCoS. Un croquis est présenté à la Figure IV.4

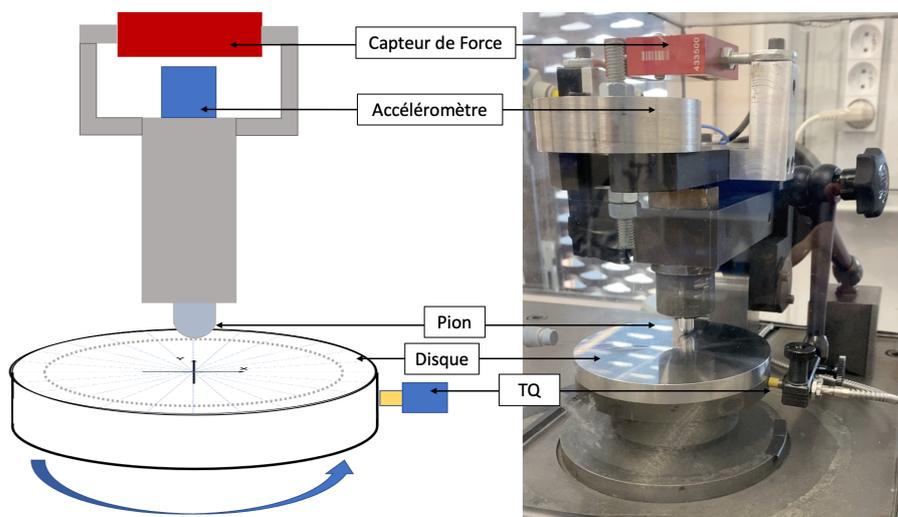


Figure IV.4 – Tribomètre Pion-Disque

D'un côté, un bras maintient l'axe en contact avec la surface du disque. De l'autre, des contrepoids sont utilisés pour s'opposer au poids de la broche, du bras de support et des différents composants du bras lui-même. La charge normale est appliquée par effet de levier, après un processus de calibration. Les forces de frottement sont mesurées à une fréquence d'échantillonnage de 1000 Hz à l'aide d'un capteur de force S (SIKA FTCA50) qui peut mesurer la traction et la compression dans une gamme de 1 à 50 N. Un capteur de déplacement à courant de Foucault de type TQ sert de compteur de tours grâce à une petite indentation réalisée dans le disque en rotation. L'ensemble est relié à une centrale d'acquisition Krypton de DEWESOFT permettant une synchronisation des

signaux. Les essais sont réalisés soit à l'air ambiant que nous qualifierons d'atmosphère libre, soit confiné sous Argon, à température ambiante (en moyenne 27°C). La force normale appliquée est maintenue constante, égale à 12.75N , pour tous les essais. La pression hertzienne maximale calculée pour la géométrie de contact correspondant à 1GPa . Le choix du couplage de la vitesse de rotation angulaire avec le rayon de la piste (R) conduit à une vitesse de glissement de $V_{lin} = 6,28\text{mm/s}$ pour tous les essais. Pour chaque type de disque, plusieurs essais aux conditions variées sont réalisés. Les essais sont réalisés et arrêtés à différents nombres de tours : 12.3, 37.5 et 87, correspondant à des distances totales de glissement de 3m, 6m et 18m, respectivement. Des tests préliminaires ont d'abord été réalisés sur des disques similaires à une distance de glissement de 18 m afin de déterminer la durée de la phase de rodage, la Figure IV.5 représente un des essais préliminaires réalisé.

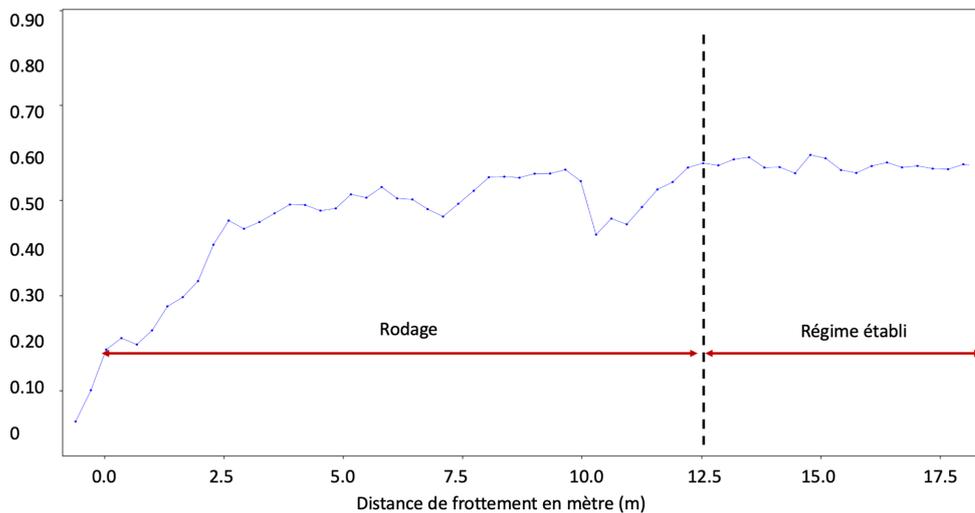


Figure IV.5 – Test préliminaire permettant de visualiser les étapes de la vie du contact : Evolution du coefficient de frottement moyen par tour en fonction de la distance frottée (D10P23).

L'étude de cette courbe permet de définir deux régimes distincts au cours de l'évolution du test. Un premier régime présentant une augmentation progressive du coefficient de frottement moyen que nous qualifierons de rodage allant de 0m à 12.5m et un régime relativement stable, asymptotique, présentant des fluctuations de faible amplitude par rapport à la valeur moyenne (de l'ordre de 5%) du coefficient de frottement, cette phase sera nommée régime établi. Les distances de 3m et 6m sont ensuite choisies pour correspondre aux phases de début et de milieu rodage. Le Tableau IV.3 résume les conditions expérimentales de la campagne d'essais, à noter que les essais en bleu seront abordés ultérieurement.

1. BANC D'ESSAI ET CONDITIONS EXPÉRIMENTALES

Nom	Disque (épaisseur)	Pion	Rayon (cm)	Vitesse (tr/min)	Distance	T (°C)	HR (%)	Atm
D10P20	10(10mm)	20	2,7	2,22	12	19,4	44	Argon
D10P21	10(10mm)	21	3,3	1,82	18	19,3	44	Argon
D10P22	10(10mm)	22	3,9	1,53	12	20,3	43	Libre
D10P23	10(10mm)	23	4,5	1,33	18	22,8	42	Libre
D11P24	11(10mm)	24	2,7	2,22	1	20	37	Libre
D11P25	11(10mm)	25	3,3	1,82	2	20	37	Libre
D11P26	11(10mm)	26	3,9	1,53	3	20	37	Libre
D11P27	11(10mm)	27	4,5	1,33	6	21	37	Libre
D12P28	12(15mm)	28	2,7	2,22	7,46	20	37	Argon
D12P29	12(15mm)	29	3,3	1,82	18	18,7	38	Argon
D12P30	12(15mm)	30	3,9	1,53	6	18,2	38	Libre
D12P31	12(15mm)	31	4,5	1,33	18	18,2	38	Libre
D17P42	17(10mm)	42	4,5	1,33	25	18,9	29,9	Libre
D151P43	151(15mm)	43	4,5	1,33	25	20	31,4	Libre

Tableau IV.3 – *Conditions expérimentales pour les essais tribologiques. (Avec T la température, HR l'humidité relative et Atm l'atmosphère)*

2 Données rhéologiques

Les données de l'accéléromètre et du capteur de force sont acquises par une centrale d'acquisition de la marque DeweSoft, avec une fréquence d'acquisition de 1000Hz. Cela permet de synchroniser les signaux et de visualiser leur évolution en direct via le logiciel fourni. Ainsi l'opérateur peut relever en temps réel tout événement venant perturber le système, permettant ainsi une étude approfondie *a posteriori*. Pour réaliser la dite étude, nous avons développé un code sous Matlab, que nous avons enrichi au cours de ce travail en fonction des besoins de l'étude. Grâce à ce programme nous pouvons traiter les signaux acquis (force tangentielle et accélération suivant les 3 axes), il est alors possible d'obtenir des cartes présentant la valeur de ces signaux en fonction de la position sur le disque et du nombre de tour, tout comme dans la Figure IV.6 présentée ci-après.

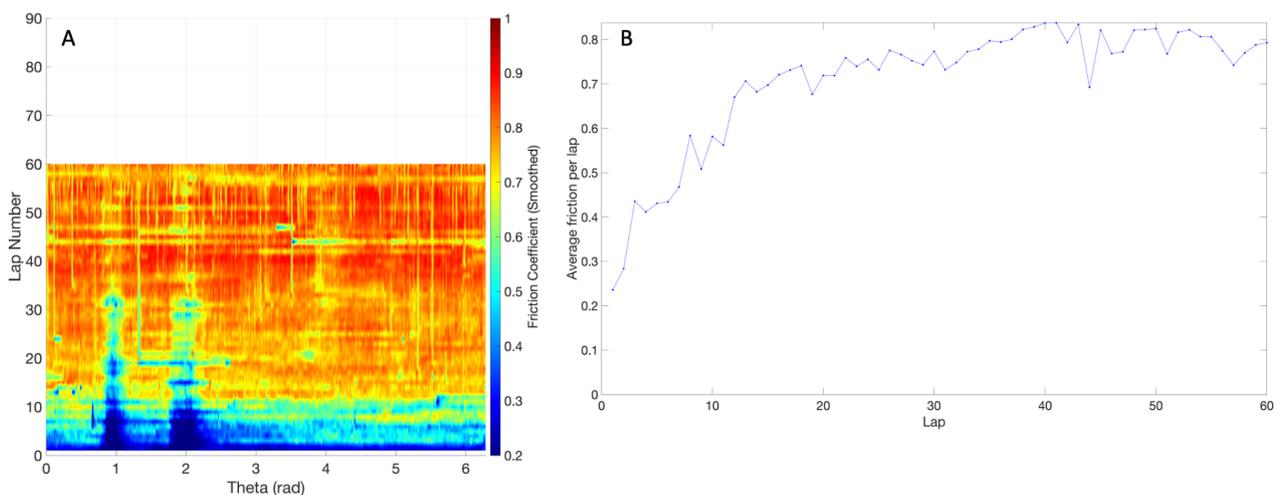


Figure IV.6 – A) Valeur instantanée du coefficient de frottement en fonction de la position sur le disque à chaque tour. B) Évolution du COF moyen par tour.

La Figure IV.6A permet de visualiser l'évolution globale de la vie du contact, on retrouve alors deux étapes définies en Figure IV.5 : le rodage jusqu'à une quarantaine de tours et une phase stationnaire présente sous la forme d'un plateau pouvant être légèrement perturbé par des événements ponctuels. Ces derniers sont difficiles à capter *a posteriori*, c'est pourquoi nos investigations tendent plutôt à rechercher une mémoire de ces événements à travers la morphologie des flux d'éjection et de recirculation.

La première question à se poser va être celle de la reproductibilité des essais. La Figure IV.7 combine les courbes d'évolution du coefficient de frottement moyen par tour : le graphe A pour les essais sous atmosphère libre et le B pour les essais sous Argon. Pour le graphe A deux tests supplémentaires ont été ajoutés, (ce sont les essais en bleu dans le Tableau IV.3), les tests D13P42 et D151P43, afin de confirmer la tendance sur une plus grande distance de frottement, ici 25m, toujours sous des conditions identiques aux tests précédents.

Les courbes suivent la même tendance générale que les essais précédents. On observe une augmentation du coefficient de frottement rapide, en 5 tours en moyenne, les phéno-

mènes rencontrés en cours de rodage ne semblent pas les mêmes pour chacun des disques mais le comportement en régime établi tend vers une valeur de frottement asymptotique de 0.65. Cette «différence de chemin» en rodage avait déjà pu être observée lors d'essais préliminaires menés sur des disques présentant des états de surface initiaux très différents (surfaces avec des stries d'usinage très profondes). Lors de cette première investigation nous avons proposé, au cas par cas, des *scenari* possibles pour expliquer ces différences, [Bouchot *et al.*, 2021a].

Le comportement sous Argon (graphe B) présente une augmentation monotone du coefficient de frottement sur les cinq premiers tours. Il s'agit d'un comportement similaire aux tests sous atmosphère libre, avec toutefois une amplitude de l'augmentation plus faible (0.15 en moyenne contre 0.5 pour l'air). Ce comportement avait déjà été observé durant le travail de [Jaza *et al.*, 2021]. Contrairement aux cas sous air, les courbes ne se superposent pas, on ne semble pas atteindre de valeur asymptotique et chaque essai a sa propre identité. Seul l'essai D10P21 possède une valeur de frottement seuillée et stable.

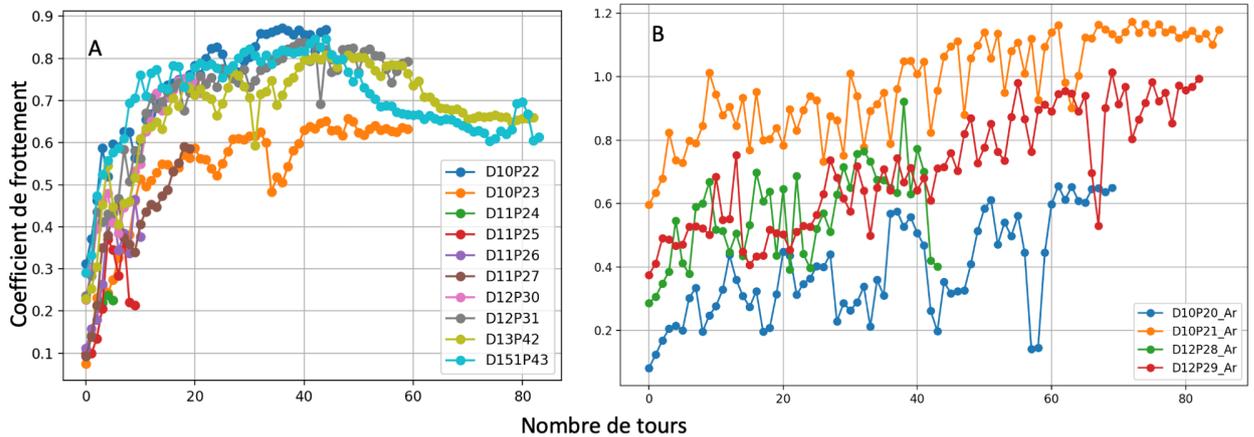


Figure IV.7 – Évolution du COF moyen par tour A) Sous Atmosphère libre B) Sous Argon.

L'observation des cartes de frottement de la Figure IV.8 donne une indication quant à la nature des perturbations du coefficient de frottement. Une bande verticale (Figure IV.8-B) sera imputée au disque, car un phénomène que l'on va retrouver périodiquement à la même localisation aura de fortes probabilités d'être propre au disque. Alors qu'une bande horizontale (Figure IV.8-A) témoigne d'un événement ponctuel qui se déplace sur la piste, donc attribué au pion.

Tout le travail d'investigation réside dans l'interprétation de ces événements et de leurs conséquences sur le troisième corps. Mais avant cela il faut s'assurer que ces phénomènes, principalement les stries verticales, ne sont pas imputables à des éléments extérieurs tels que le positionnement des vis de fixation du disque ou encore des défauts d'usinage comme des rayures. Pour tous les essais présentés dans ce manuscrit la position a bien été vérifiée et n'explique pas les événements rencontrés. De plus les disques ont été vérifiés et malgré la présence de rayures pouvant traverser les pistes de frottement elles ne sont jamais situées aux emplacements incriminés. Les photos des disques ainsi que les cartes de frottement

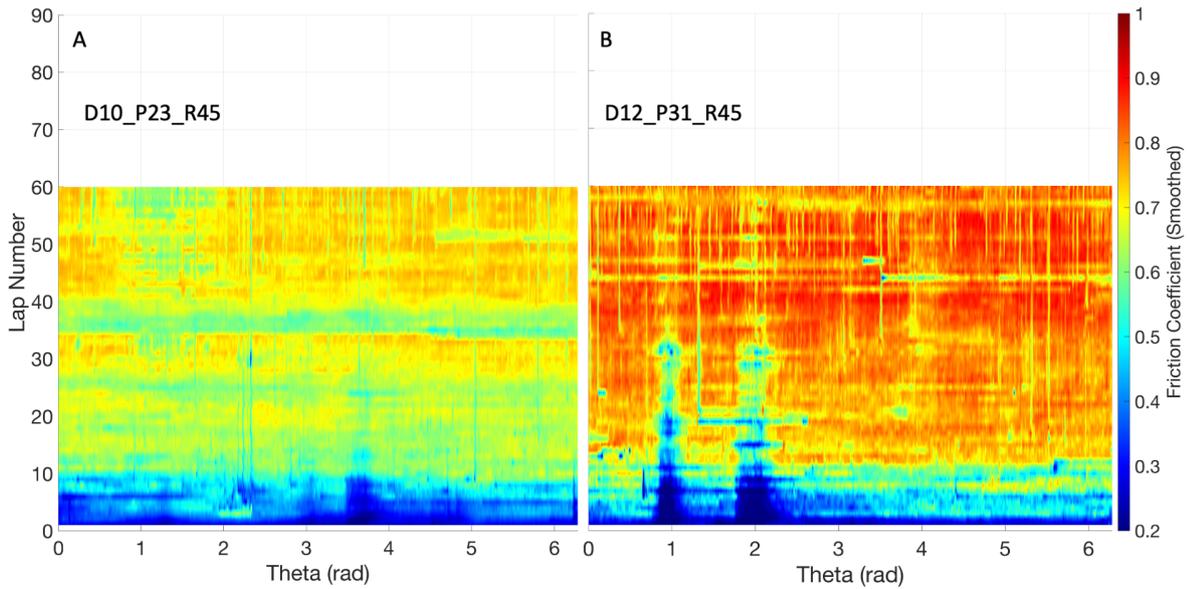


Figure IV.8 – *Cartes de frottement de deux essais présentant A) des bandes horizontales et B) des bandes verticales*

de chaque essai sont présentées en annexe C et D respectivement. Un dernier test aurait consisté à réaliser une mesure de la planéité de surface, avant le démontage du disque, afin de s'assurer qu'il n'existe aucun défaut d'usinage, ce point n'a pas été investigué lors de ces travaux mais mériterait de l'être lors de tests futurs.

3 Observations morphologiques du troisième corps

3.1 Protocole d'acquisition des images

Une fois les essais de frottement effectués, le contact est ouvert et les deux premiers corps (surfaces du disque et du pion) sont examinés au microscope électronique à balayage (MEB).

Paramètres MEB	Valeurs
Vitesse de Balayage (μs)	20
Résolution (px)	1024 x 884
Distance de travail ou WD (mm)	10
Voltage (kV)	20
Taille de Spot	5(i.e. beam current = 1,2 nA)
Format	Bitmap (.bmp)

Tableau IV.4 – Conditions d'acquisition des images MEB.

Le Tableau IV.4 présente les paramètres d'acquisition des images MEB, une discussion sur le choix de ces paramètres est proposée en annexe B. Ces acquisitions d'images, réalisées directement sur la surface du disque et du pion après ouverture du contact, permettent d'accéder au troisième corps produit lors du dernier tour sur le disque et lors des dernières secondes sur le pion, en perturbant le moins possible ce troisième corps. Un protocole est construit pour définir les emplacements des images acquises (zones d'intérêt et région d'intérêt (ROI)) et pour définir une nomenclature. Les zones d'intérêt sont définies comme indiqué sur la Figure IV.9 :

- sur le disque (Figure IV.9A), 24 positions angulaires sont définies (une tous les 15°), liées à la position initiale du disque (thêta 0° au temps 0). Ainsi, quel que soit le test effectué, les images sont prises aux mêmes endroits, permettant de systématiser le processus d'étude. Il est possible de comparer le troisième corps produit à un angle θ donné pour différentes configurations expérimentales et de rester cohérent. De plus cette configuration va permettre la mise en relation directe des images avec les signaux de frottement.
- sur le pion, la zone d'intérêt correspond à l'ensemble de la zone de contact (fig.4B), apportant une information tribologique non pertinente pour le travail d'analyse d'image présenté ici. Elle n'est donc pas présentée dans ce chapitre.

Pour chaque zone d'intérêt, 2 ROI sont définies, surlignées en rose et en jaune sur la Figure IV.9C. Les ROI sont liées à 2 catégories d'images correspondant respectivement au flux d'usure (Q_w sur la Figure I.8) et au flux de recirculation (Q_r sur la Figure I.8). Ces 2 catégories d'images sont traitées différemment lors de la phase d'analyse des images. D'une part, les images de particules éjectées d'aspect "granulaire" (en bord de piste, Figure IV.9), sont segmentées afin d'extraire des informations géométriques, topographiques et morphologiques. En revanche, les images du troisième corps au centre de la piste (Figure IV.9C), mettant en évidence son aspect aplati ou écrasé, ne permettent pas de segmentation. Il est jugé plus pertinent d'en analyser la texture. Il existe donc deux catégories

d'images, les particules et les textures, dans cette étude. Ces deux catégories d'images subissent des traitements différents, présentés en section 4 et 5 de ce chapitre.

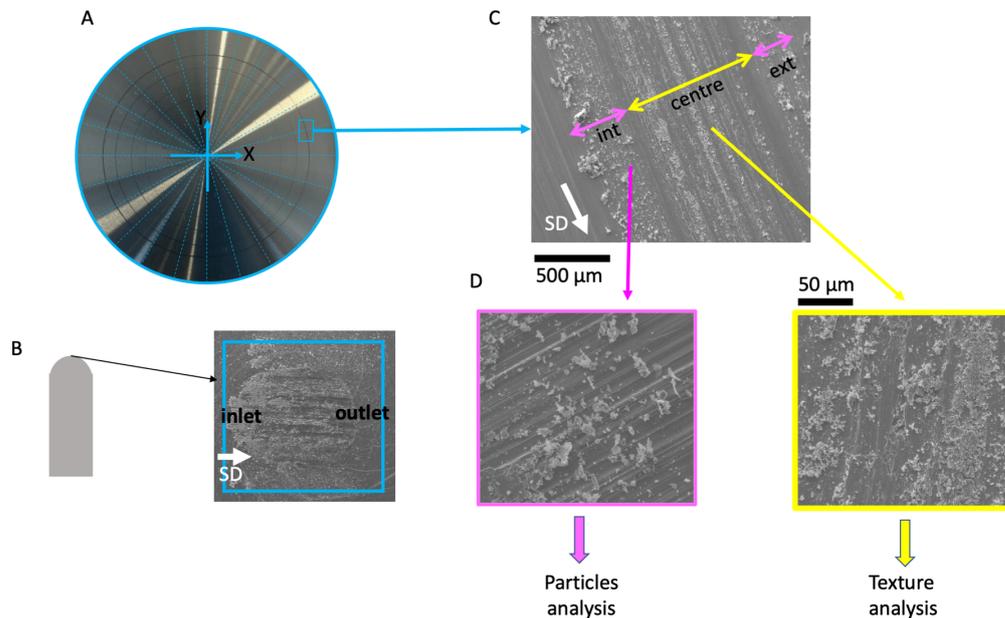


Figure IV.9 – Localisation des observations sur les disques et les broches - les zones d'intérêt A) sur le disque - B) sur le pion - C) ROI pour chaque zone d'intérêt sur le disque - D) Détails d'une ROI sélectionnée et analyse associée.

3.2 Analyse qualitative du troisième corps

Les flux de matière dans un tribosystème peut être décrit à l'aide du circuit tribologique (voir Figure I.8) [Berthier, 2005]. Les premiers corps en contact, sont en mouvement relatif; les troisièmes corps se forment à l'interface de glissement. Le flux source, Q_s , représente le détachement du matériau du premier corps pour devenir le troisième corps; le flux interne Q_i décrit le mouvement du matériau le long de l'interface; le flux d'éjection Q_e est le matériau éjecté de l'interface; le flux de recirculation Q_r est le matériau éjecté qui a été réintroduit dans l'interface; et le flux d'usure Q_w est le matériau définitivement retiré du système de glissement. La matière pouvant s'écouler à l'interface a une certaine rhéologie. Ne pouvant être mesurée, la rhéologie du troisième corps est évaluée à l'aide de descriptions qualitatives de son aspect [Bouillanne *et al.*, 2022; Descartes *et al.*, 2015; Descartes & Berthier, 2002; Noël, 1995].

Le troisième corps est considéré comme une matière plus ou moins continue, elle balance entre caractère discret (particules) ou continu (couche de tartinage) en fonction des zones d'observation du contact, on peut alors parler de compaction et de cohésion de la matière. Le troisième corps peut, dans certain cas, être considéré comme une matière granulaire discrète, plus ou moins compactée, ou se présenter sous la forme d'un écoulement plastique (matière continue).

Jusqu'à présent, l'évaluation de la rhéologie suit une procédure phénoménologique où un diagramme est nécessairement construit pour produire les échelles qualitatives de

cohésion et de ductilité [Descartes, 1997]. Afin de mettre en place une méthodologie permettant de quantifier ces caractéristiques, l'approche suivante est proposée : des analyses post-mortem des zones de contact des surfaces du disque et du pion sont réalisées après avoir soigneusement ouvert le contact à la fin de chaque essai. Les observations sont réalisées à l'aide de différents outils : microscope optique, profilomètre optique (avec le profileur optique sans contact Altimet + nouveau), microscopes électroniques à balayage (MEB, FEI Quanta 600 et Thermofischer Quattro) couplés à une microanalyse à rayons X dispersive en énergie (EDX, Oxford Instruments).

En observant les disques, la largeur de la trace d'usure est de l'ordre du millimètre. L'analyse *post-mortem* de la morphologie du troisième corps commence par l'ouverture du contact, présentée en Figure IV.10. Cette première observation à l'échelle macroscopique révèle déjà des différences significatives entre troisième corps produit sous atmosphère libre ou sous Argon. L'observation des pions montre un troisième corps sous forme de paillettes orientées verticalement par rapport à la surface du pion, pour l'Argon (Figure IV.10A), alors que dans le cas de l'atmosphère libre (B) le troisième corps est très compacté, il forme une couche agglomérée très dense. L'observation des pistes est en adéquation avec celle des pions. Pour l'Argon (A) la piste est couverte d'un troisième corps peu compact sous forme de limaille, alors que la piste produite sous air ambiant présente un troisième corps étalé/écrasé avec des zones d'éjection plus ou moins denses en fonction de la position.



Figure IV.10 – *Comparaison macroscopique du troisième corps lors de l'ouverture du contact pour des essais sous A) Argon et B) atmosphère libre. QRcode : Extrait vidéo d'un essai sous atmosphère. (SD = Sliding Direction)*

Si on s'intéresse à l'échelle microscopique on peut observer une influence significative de l'atmosphère sur la morphologie de l'interface, Figure IV.11 et IV.12. En effet, dans le cas de l'argon (images A sur les Figures) on observe une piste de frottement parsemée de matière (troisième corps). La largeur de la piste croît avec la distance parcourue, mais le troisième corps n'est pas lissé ou étalé et il est difficile de différencier flux de recirculation et débit d'usure, les deux ayant un aspect similaire. A contrario les pistes produites sous atmosphère libre présentent un aspect très différent. En rodage (Figure IV.11B), il n'y a pas d'éjection en bord de piste et du troisième corps commence à être arraché, à se déposer sur le centre puis à être progressivement écrasé, tandis que parallèlement on observe un écoulement plastique en centre de piste. Une fois le régime établi atteint, Figure IV.12B, on observe deux configurations distinctes. Le centre de piste présente une grande variété de textures, et on retrouve du troisième corps lissé, compacté, ou encore écrasé. Les bords de piste sont composés d'un ensemble de particules éjectées non compactes. Une observation de ces particules éjectées est proposée en Figure IV.13.

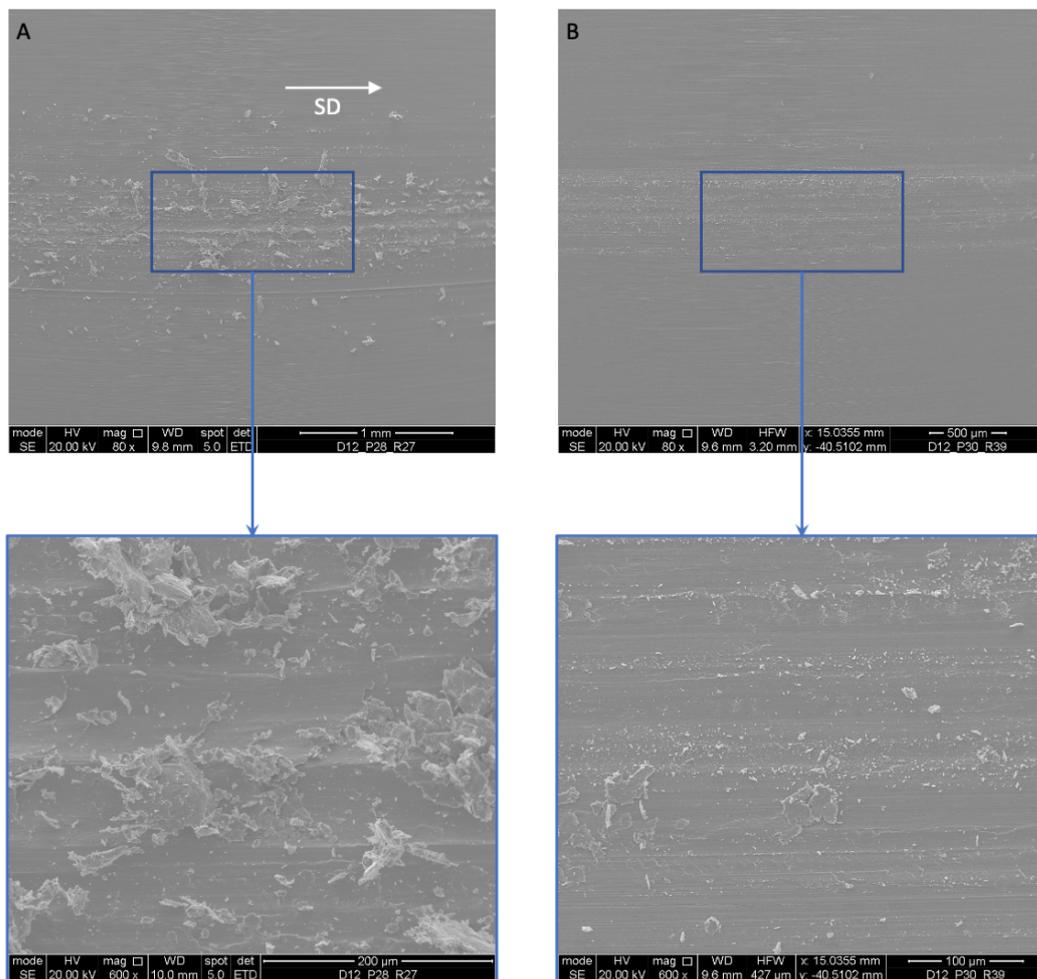


Figure IV.11 – Comparaison des pistes de frottement pour des essais sous Argon (A) et sous atmosphère libre (B), pour une distance de 6m. (SD = Sliding Direction)

3. OBSERVATIONS MORPHOLOGIQUES DU TROISIÈME CORPS

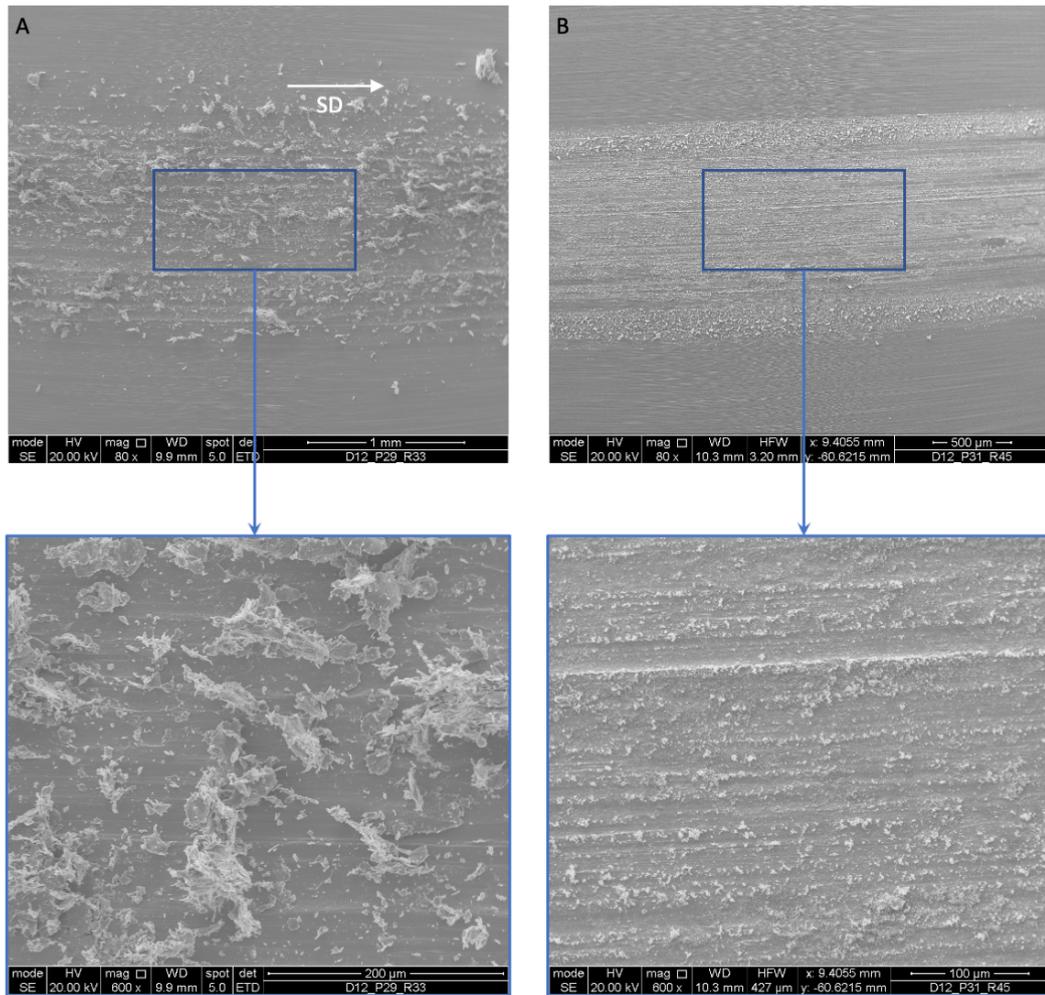


Figure IV.12 – Comparaison des pistes de frottement pour des essais sous Argon (A) et sous atmosphère libre (B), pour une distance de frottement de 18m. (SD = Sliding Direction)

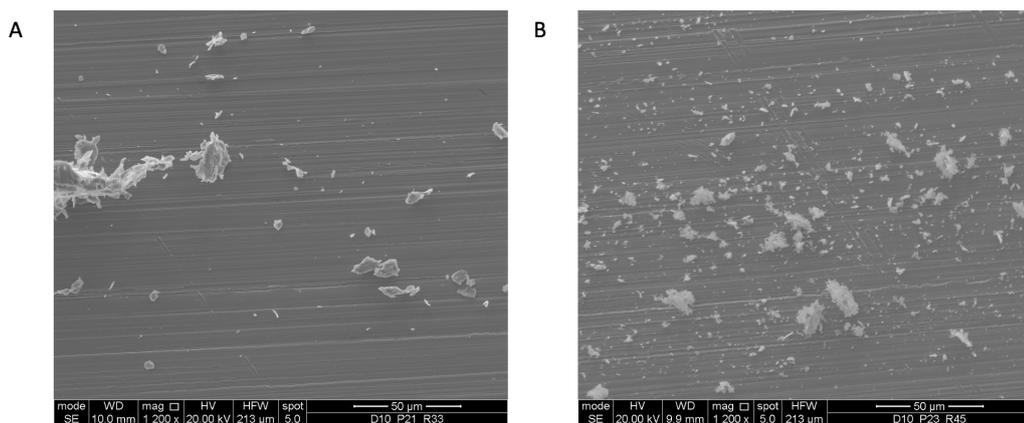


Figure IV.13 – Comparaison des extérieurs de piste pour deux essais en régime établi sous Argon (A) et sous atmosphère libre (B).

De même que dans le cas de la zone centrale, les particules éjectées sont très différentes selon l'atmosphère. Cela commence par une différence de taille significative : à même

échelle les particules produites sous Argon sont plus grosses mais moins nombreuses que les particules produites sous Air. Les particules produites sous Argon, Figure IV.13A sont très lisses, la matière semble avoir été arrachée, puis cassée en morceaux plus petits avant d'être éjectée du contact : on retrouve cet aspect limaille que l'on pouvait observer à l'échelle macroscopique. Alors que les particules produites sous atmosphère libre, Figure IV.13B, sont d'aspect poudreux : la matière semble avoir été réduite en poudre puis compactée avant d'être éjectée du contact.

Lors des tests, plusieurs événements macroscopiques peuvent survenir, comme l'émission ou non de bruit. Ce bruit pourra être ponctuel ou alors continu. Ainsi, durant les tests, il est nécessaire de relever à quel moment le bruit est produit, ou encore si il est encore présent au moment de l'arrêt du tribomètre afin de rechercher son potentiel lien avec la morphologie du troisième corps. La Figure IV.14 présente un essai sous atmosphère libre avec émission de bruit, il s'agit du même essai que celui dont les résultats avaient précédemment été présentés en Figure IV.6, la carte de frottement est présentée sous forme cylindrique, pour une meilleure visualisation. La zone où le coefficient de frottement est le plus faible, autour de 0.6, correspond à la zone d'émission sonore¹, à laquelle est associée l'image rouge. La zone de frottement élevé, 0.8, est associée à l'image bleue. L'extraction du COF du dernier tour en chaque ROI (acquisition des images) permet une visualisation plus directe des variations de ce paramètre sur le dernier tour. L'étude conjointe de la courbe et des images apporte des éléments pouvant expliquer ces différences de régimes de frottement. Les bords de piste sont similaires dans les deux cas, les débits d'éjection sont les mêmes, il faut donc se concentrer sur le flux de recirculation, au centre de la piste. Il y a ici des différences notables. En effet, la portion rouge semble plus texturée que la bleue, et présente des petits îlots de matière très lisses (encadré tirets rouges sur la Figure IV.14). En passant sur ces palettes, l'aire de contact réelle (A_r) sera significativement plus petite que l'aire apparente (A_a) entraînant un cisaillement localisé, pouvant être relié à du stick-slip à petite échelle, comme explicité dans les simulations de [Linck *et al.*, 2003].

1. Ceci a été vérifié grâce à l'analyse *a posteriori* des vidéos de l'expérimentation

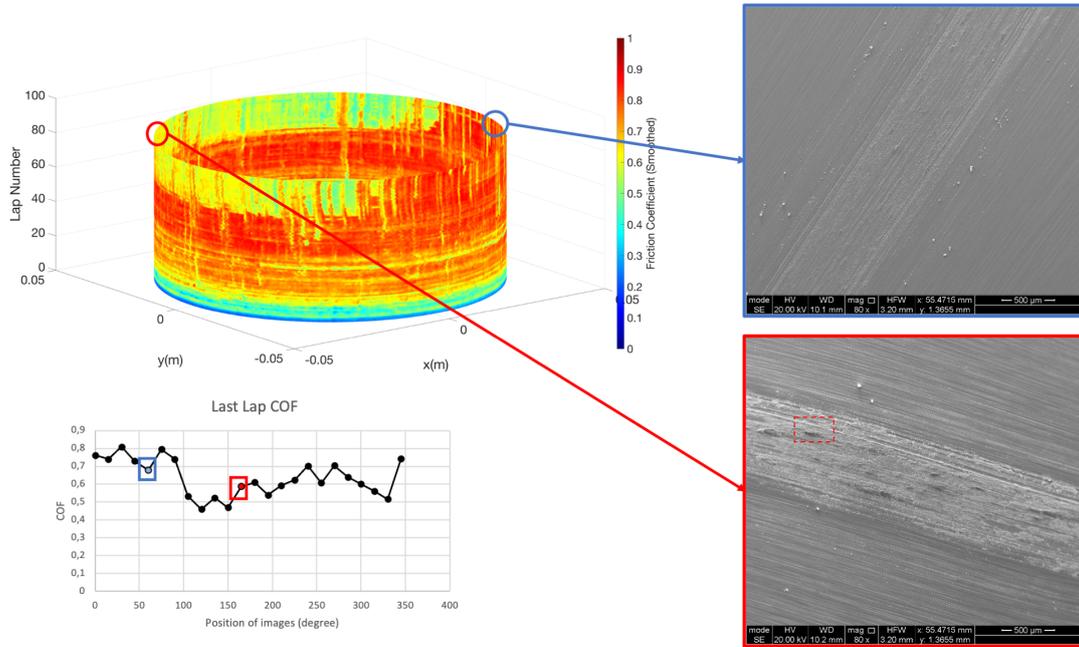


Figure IV.14 – Carte de frottement et images associées d'un test en atmosphère libre

De plus durant ce test il fut possible d'enregistrer le bruit, il s'agit d'un son émis à 480 Hz, il est possible d'écouter un extrait à l'aide du QRcode de la Figure IV.10. Notons que lors des essais sous Argon, il y a également émission d'un son. Ce dernier est beaucoup plus grave comme des pas dans une neige craquante, mais le débit de gaz dans la cuve de confinement empêche une bonne captation.

Cette analyse qualitative montre bien le lien possible entre caractéristiques du troisième corps (pour Q_r et Q_e) et valeur du coefficient de frottement. Néanmoins ces caractéristiques sont descriptives. Dans les deux sections suivantes, il s'agit maintenant de quantifier ces descriptions morphologiques du troisième corps : tout d'abord pour les particules (bords intérieur / extérieur de piste) puis pour les textures (centre de piste).

4 Analyse morphologique des images de particules

Les images de particules doivent être segmentées pour extraire les caractéristiques géométriques, morphologiques et topologiques [Debayle, 2019] des particules. Toutes les opérations de traitement d'image sont implémentées en Python3 avec les bibliothèques Scikit-learn 1.0 [Pedregosa *et al.*, 2011], OpenCV 4.5.1 [Brahmbhatt, 2013] et Scikit-image 0.18.3 [van der Walt *et al.*, 2014].

4.1 Segmentation d'images par apprentissage automatique

Il a d'abord été prévu d'utiliser des techniques de seuillage [Otsu, 1979] pour segmenter les particules de la ROI (en rose sur la Figure IV.9) mais la diversité de morphologie du troisième corps ainsi que l'état de surface des premiers corps peuvent produire de grandes erreurs lors du seuillage. Ces erreurs ont été mises en évidence lors de la mise en place du protocole, présenté dans les articles [Bouchot *et al.*, 2021b, 2022].

La Figure IV.15 illustre ces deux cas. Dans l'image 1 (Figure IV.15A), les grandes stries observées correspondent aux rainures d'usinage du disque. Lors de la segmentation par seuillage, elles ont tendance à être assimilées à des particules très allongées reliant d'autres particules entre elles créant ainsi un cluster artificiel. De plus, en essayant d'éliminer les stries au maximum en modulant le seuil, certaines particules peuvent être tronquées ou disparaître. Une phase de post-traitement est alors nécessaire pour les retirer manuellement des statistiques morphologiques. En tribologie se pose actuellement la question de savoir comment considérer les agglomérats : Faut-il les considérer comme de grosses particules isolées ou comme des amas de particules cohésives qui subiraient un traitement particulier ? La question restant ouverte, comme présenté dans [Jaza *et al.*, 2021 ; Peng & Kirk, 1998], nous avons choisi de les laisser tel-quel, quelque soit la qualité de la segmentation obtenue, en effet, la discontinuité de la texture que présente de tels objets, nécessiterait une sur segmentation des particules en surface. Toutefois, notons que ce cas de figure est rare, de l'ordre de 1,5%, donc peu impactant pour la suite du travail de recherche de corrélations.

L'image 2 (Figure IV.15B) illustre une autre difficulté rencontrée avec le seuillage : la diversité des textures. En effet, dans ces conditions expérimentales, les particules de troisième corps peuvent présenter des textures très différentes allant de très lisses à granuleuses. Ainsi, quel que soit le seuil choisi pour segmenter une particule poudreuse, il y a toujours une perte d'information résultant de cette texture complexe.

Puisque les techniques usuelles de traitement d'images, ne sont pas systématiquement efficaces et introduiraient une mauvaise caractérisation de nos objets d'étude, un processus de segmentation utilisant l'apprentissage automatique ou *machine learning* (ML) a alors été développé, présenté ci-après.

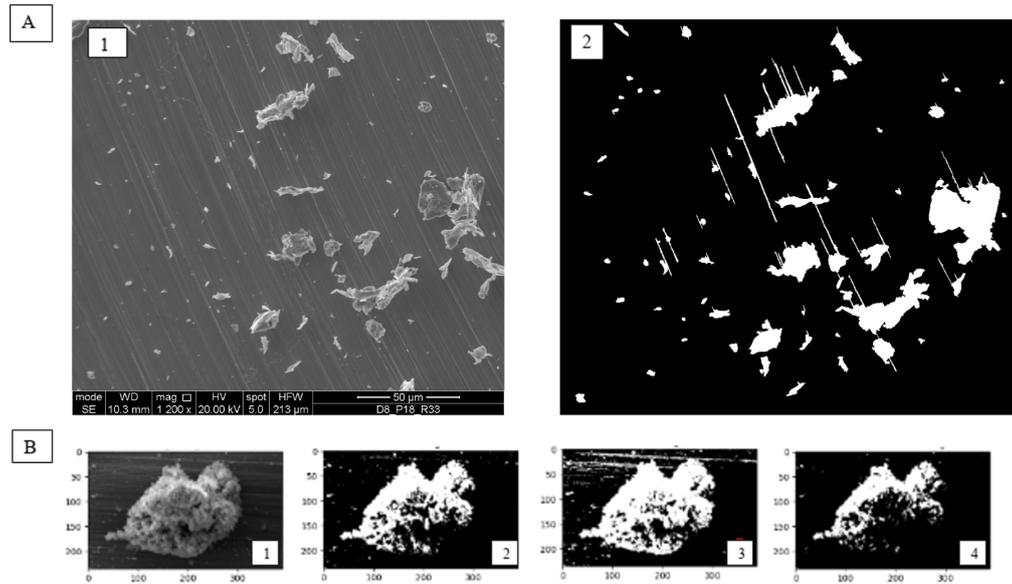


Figure IV.15 – A) Influence de l'état initial de la surface sur le seuil 1) image originale, 2) seuil Otsu . B) Seuils de segmentation pour les particules texturées 1) image originale, 2) seuil Otsu (seuil = 95), 3) seuil manuel (seuil = 75) et 4) seuil manuel (seuil = 120)

4.1.1 Schéma du processus de segmentation

Ce processus de segmentation est composé de deux étapes principales dont le résultat est la détection de particules (Figure IV.16). L'objectif est de classer chaque pixel d'une image comme appartenant ou non à une particule. Dans un premier temps, des particules représentatives sont sélectionnées afin d'être utilisées pour l'entraînement.

Ces images d'entraînement sont extraites d'une vue MEB et sont composées d'une ou plusieurs particules. Pour être le plus représentatif possible, nous avons sélectionné 3 images sous atmosphère libre et 3 sous argon. Chaque pixel de l'ensemble d'entraînement est étiqueté à l'aide d'une segmentation manuelle appelée "segmentation experte". La deuxième étape correspond à l'extraction de caractéristiques pour chaque pixel, qui sont classées en deux catégories :

- Les caractéristiques morphologiques : Elles sont composées des pixels de huit images produites par quatre reconstructions par érosion et quatre reconstructions par dilatation utilisant la morphologie mathématique. Dans les deux cas, les éléments structurants sont des cercles de rayon $R = [2, 4, 6, 8]$ pixels [Niemueller, 2006].
- Les caractéristiques de texture : Elles sont composées de quatre «Local Binary Pattern» (LBP) [Ojala *et al.*, 2002] invariants en rotation avec un nombre de points $P = 8$ et un cercle de rayon $R = [2, 4, 6, 8]$ pixels.

Ainsi, chaque pixel des images d'entraînement est étiqueté et décrit par douze caractéristiques à valeur réelle. Pour construire une base de données avec le moins de biais possible les données sont mélangées, puis cette base de données est divisée en deux sous-ensembles : 80% sont alloués à l'entraînement et 20% au test. La base de données est donc composée

de 3 904 848 échantillons (pixels), tous décrits par douze caractéristiques et étiquetés avec une valeur booléenne, 1 (le pixel fait partie de la particule) et 0 (il fait partie du fond). Le système de mélange aléatoire garantit une variété dans le choix des pixels, évitant ainsi de trouver des groupes de pixels consécutifs liés au milieu ou aux bords des particules ou encore au fond plus ou moins ombragé par la présence ou non de particules. L'algorithme d'apprentissage automatique est ensuite entraîné et évalué, ses performances seront présentées plus loin. Il est donc possible de segmenter des images complètes inconnues du modèle (étapes vertes sur la Figure IV.16), en attribuant à chaque pixel de cette image l'étiquette Vrai ou Faux, qui correspond à "l'intérieur" ou "l'extérieur" de la particule. Pour ce faire, cette nouvelle image est présentée comme entrée du code. Elle subit les mêmes opérations que les images d'entraînement afin d'extraire les caractéristiques de chacun de ses pixels. Ces caractéristiques sont les entrées de l'algorithme de classification, et la sortie est une image binaire. Ces images segmentées doivent par la suite être nettoyées à l'aide d'opérations de morphologie mathématiques pour éliminer les petits objets, les objets sur les bords, les artefacts et enfin les trous à l'intérieur des régions segmentées.

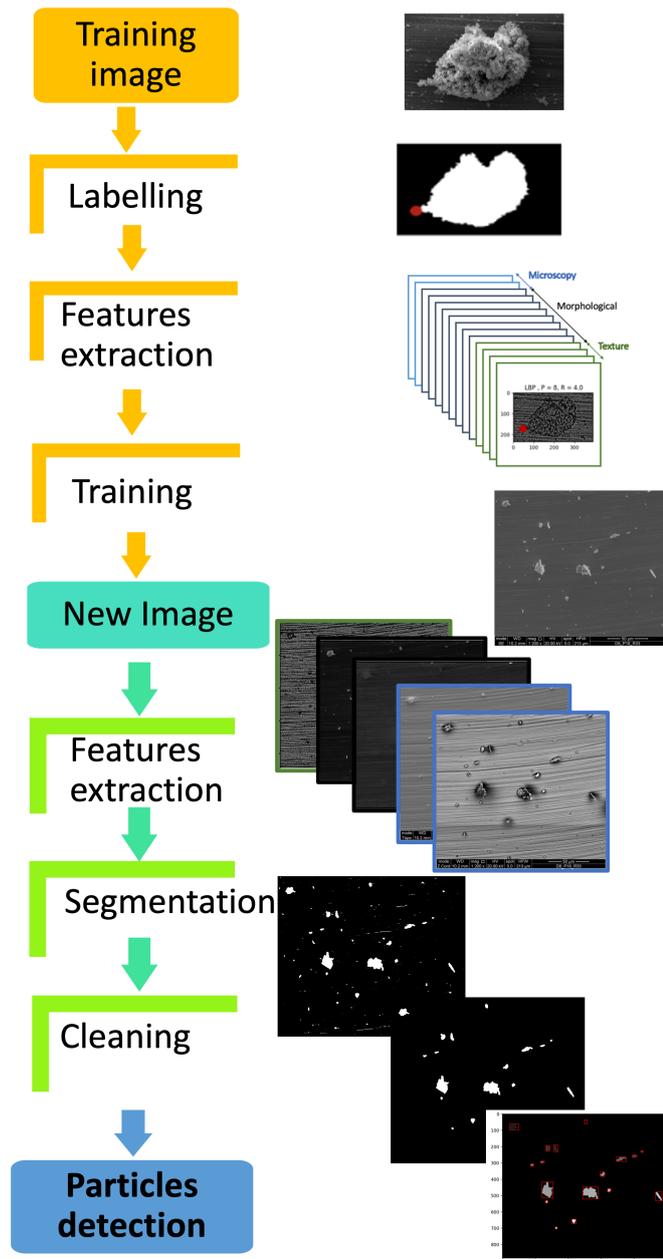


Figure IV.16 – Organigramme du fonctionnement général du code SIMaLea (Segmentation d'Images par MACHine LEARNING).

4.1.2 Etude des performances de l'algorithme de ML

Dans un premier temps, ce processus de segmentation est effectué sans aucune considération a priori concernant le choix de l'algorithme à sélectionner. Ainsi, sept modèles sont entraînés : un perceptron multicouche (MLP), une machine à vecteur de support (SVM), une forêt aléatoire (RF) et quatre méthodes d'ensemble, un ensemble de MLP (bag MLP), un ensemble de SVM (bag SVM), un ensemble de RF (bag RF) et un ensemble des trois méthodes (Vote)[Géron, 2019].

Pour choisir la méthode la plus appropriée à utiliser pour le processus de segmentation, une évaluation des performances est effectuée en calculant et en étudiant la matrice de

confusion, et les métriques associées sur l'ensemble de test :

Taux de vrais positifs (rappel, sensibilité)

$$TPR = \frac{TP}{(TP + FN)}$$

Taux de vrais négatifs (spécificité)

$$TNR = \frac{TN}{(TN + FP)}$$

Valeur prédictive positive (précision)

$$PPV = \frac{TP}{(TP + FP)}$$

Accuracy

$$Acc = \frac{(TP + TN)}{(TP + FN + TN + FP)}$$

Précision Equilibrée

$$BA = \frac{(TPR + TNR)}{2}$$

Score F1 (moyenne harmonique de la précision et de la sensibilité)

$$F1 = 2 \times \frac{(PPV \times TPR)}{(PPV + TPR)}$$

Avec les valeurs de la matrice de confusion Vrais positifs (TP), Vrais négatifs (TN), Faux positifs (FP) et Faux négatifs (FN).

Globalement, chaque algorithme obtient des résultats de performance très satisfaisants (Tableau IV.5). Ces résultats sont compris entre 0 et 1, et un algorithme obtenant un score de 1 ne se trompe jamais. Ainsi nos modèles présentent une précision (ACC) moyenne de 0.920, ce qui signifie qu'en moyenne 8% des pixels sont mal classifiés. La *random forest* ressort comme étant le modèle le plus performant, puisque toutes ses métriques de performance sont supérieures à celles des autres. Mais ces résultats, à eux seuls, ne permettent pas de discriminer l'algorithme le plus pertinent. En effet, si les erreurs commises lors du processus de segmentation se situent sur les frontières des particules, le travail de caractérisation sera biaisé. (Sachant que les erreurs commises sur le centre de l'objet peuvent éventuellement être corrigées par les opérations géométriques. Le travail de segmentation (classification) décrit ci-dessus est effectué sur des pixels. L'objectif de cette étude est de caractériser des objets (particules). Ainsi, la capacité des algorithmes à traiter une image MEB complète contenant un certain nombre de particules doit être évaluée.

	TPR	TNR	PPV	ACC	BA	F1
MLP	0,890	0,936	0,928	0,914	0,913	0,908
RF	0,903	0,967	0,961	0,936	0,935	0,931
SVM	0,864	0,968	0,961	0,918	0,916	0,910
Vote	0,896	0,962	0,955	0,930	0,929	0,925
BagMLP	0,860	0,965	0,958	0,915	0,912	0,906
BagRF	0,897	0,958	0,951	0,929	0,927	0,923
BagSVM	0,833	0,956	0,946	0,897	0,895	0,886

Tableau IV.5 – Métrique de performance des algorithmes ML (travail effectué sur les pixels)

Des images tests (4 images, 80 particules) subissent plusieurs segmentations : une segmentation manuelle identique à celle réalisée sur l'image d'entraînement, et une segmentation par chacun des algorithmes d'apprentissage candidats. Les distances entre les segmentations manuelle et automatique des particules sont calculées et permettent de sélectionner le meilleur modèle. A cette fin, les distances de Dice et de Jaccard [Dice, 1945 ; Jaccard, 1902] sont utilisées. Le coefficient de Jaccard peut être interprété comme la relation entre le cardinal de l'intersection des ensembles et le cardinal de l'union des ensembles. Ainsi, la distance de Jaccard mesure la dissimilarité entre deux ensembles. De même, la distance de Dice est une autre opération sur les ensembles. Les distances sont définies comme suit :

$$D_{jac} = 1 - J(A,B)$$

où $J(A,B)$ est le coefficient de Jaccard défini comme suit

$$J(A,B) = \frac{|A \cap B|}{|A \cup B|}$$

Et,

$$D_{Dice} = 1 - DICE$$

où DICE est le coefficient de Dice défini comme

$$DICE = 2 \frac{|A \cap B|}{|A| + |B|}$$

Dans ce contexte, A correspond à la segmentation manuelle et B à la segmentation ML. Ces indices ($DICE$ et $J(A,B)$) peuvent varier de 0 à 1, 0 correspondant à des ensembles très dissemblables et 1 à des ensembles similaires. Dans le Tableau IV.6 l'évolution des distances est évaluée, il s'agit donc du comportement inverse des indices.

	D_{Jac}	D_{Dice}
MLP	0,2059	0,1148
RF	0,3812	0,2355
SVM	0,9912	0,9825
Vote	0,3515	0,2132
BagMLP	0,1815	0,0998
BagRF	0,4353	0,2782
BagSVM	0,3164	0,1879

Tableau IV.6 – Évaluation des deux distances entre les images segmentées par apprentissage automatique et la "vérité terrain". Pour des raisons mathématiques, D_{Jac} est toujours plus grand que D_{Dice} .

Les modèles les plus performants de l'évaluation des performances au niveau des pixels (Tableau IV.5), ne sont pas nécessairement ceux qui obtiennent le meilleur résultat sur les particules complètes (Tableau IV.6).

A l'échelle de l'objet "particule", deux algorithmes ressortent, mais nous avons dû faire un choix entre MLP et MLP Bagging avec une distance de Dice de 0.1148 et 0.0998, respectivement. Pour prendre cette décision, un facteur déterminant est rentré en compte : le tuning des hyperparamètres du modèle. En effet, pour obtenir un classifieur performant il est nécessaire de régler les hyperparamètres qui le définissent, cette phase étant primordiale mais n'étant pas le coeur du sujet traité ici, il a été choisi de sélectionner le modèle ayant un nombre d'hyperparamètres restreint pouvant être calibrés à l'aide des outils fournis par la bibliothèque scikit-learn. Ainsi l'algorithme sélectionné est le MLP et il sera dimensionné comme suit :

- Nombre de couches cachées $n = 2$
- Nombre de neurones par couche cachée $m = 20$
- Taux d'apprentissage initial = 0.001
- Solver = 'adam'
- Nombre d'itérations maximum = 1000
- Tol = 0.001
- N iter no change = 20

La Figure IV.17 illustre le résultat de la segmentation obtenue avec l'algorithme sélectionné. Notons qu'au cours de cette étude, il a été décidé de travailler à l'échelle du pixel. D'une part, ceci améliore la commodité des calculs : en effet, cela permet d'obtenir une grande base de données ($\sim 9\,000\,000$ échantillons) sans utiliser de méthode artificielle d'augmentation des données. D'autre part, la simplicité de l'objet d'étude (le pixel) permet d'utiliser des algorithmes d'apprentissage automatique "simples" avec une consommation de ressources modérée (pas besoin d'utiliser un GPU). Pour les investigations tribologiques qui suivront, et pour garantir un traitement efficace de l'objet "particule", l'étude des performances des algorithmes a donc été réalisée à 2 échelles : pixel et objet. Enfin, lorsqu'une nouvelle image est présentée, chacun de ses pixels est classifié afin de former une image binaire. Cette dernière est ensuite nettoyée par des opérations de morphologie mathématique, c'est-à-dire que les trous des zones représentatives des particules sont

comblés, les petits éléments dont la surface est inférieure à 10 pixels de côté sont supprimés ainsi que les éléments situés sur les bords de l'image. Pour chaque test de friction effectué, 24 zones d'intérêt sont sélectionnées sur la piste du disque (une tous les 15°, 0 étant la position de l'axe au début et à la fin du test) et 21 sur le pion (Figure IV.9A et IV.9B) ce qui représente 69 images. Elles subiront ce processus de segmentation afin d'extraire les informations des régions correspondant aux particules d'usure. La Figure IV.17-A, présente les images originales à segmenter et la Figure IV.17-B donne une vue de la segmentation effectuée par l'apprentissage automatique.

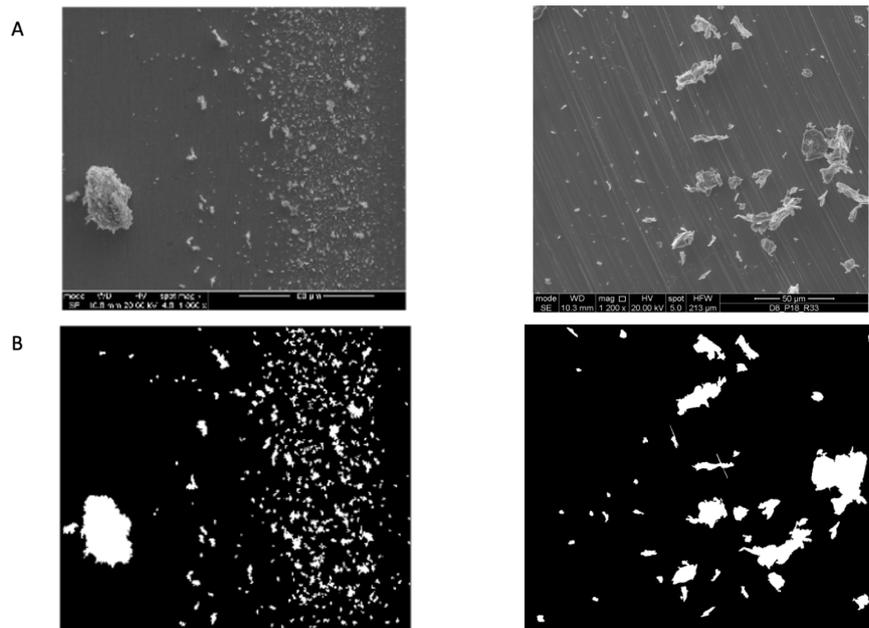


Figure IV.17 – *Évaluation visuelle et qualitative du résultat de la segmentation par apprentissage automatique, A) images originales, B) images segmentées après l'étape de nettoyage.*

4.2 Détection de régions et extraction de caractéristiques

Un autre processus est développé pour identifier les régions segmentées (dernière étape de la Figure IV.16), correspondant aux particules, et pour extraire leurs caractéristiques morphologiques, géométriques et topologiques [Jaza *et al.*, 2021 ; Rivollier *et al.*, 2010]. Pour cela les objets binaires sont détectés, leur contour est extrait sous la forme d'une série de coordonnées de points permettant de reconstruire le polygone assimilé au contour. Les descripteurs typiques utilisés en tribologie caractérisent la taille et la forme [Kowandy *et al.*, 2008 ; Roynance & Raadnuj, 1994] tels que la surface, le périmètre, l'aire de l'enveloppe convexe, l'élongation, la rondeur, la sphéricité et le rapport d'aspect. D'autres descripteurs viennent enrichir cette liste tels que la solidité, l'extension et le diamètre équivalent. Ces caractéristiques de forme sont définies comme suit :

$$Circularity = \frac{4\pi Aire}{Perimetre^2}$$

La circularité (Circularity) correspond à la sphéricité en 2D.

$$Roundness = \frac{4Aire}{\pi Longueur_{AxeMajeur}^2}$$

La rondeur (Roundness) définit l'angularité des coins de la particule.

$$Elongation = \frac{Longueur_{AxeMineur}}{Longueur_{AxeMajeur}}$$

L'allongement (elongation) est également appelé excentricité, à l'instar d'une ellipse.

$$Solidity = \frac{Aire}{AireConvexe}$$

La solidité (Solidity) est la mesure de la concavité globale d'une particule.

$$AspectRatio = \frac{LargeurBoundingBox}{LongueurBoundingBox}$$

Il s'agit du rapport entre la largeur et la hauteur du rectangle de délimitation (ou bounding box) de l'objet.

$$Extent = \frac{Aire}{AireBoundingBox}$$

L'extension (Extent) est le rapport entre la surface du contour et la surface du rectangle de délimitation.

$$EquivalentDiameter = \sqrt{\frac{4Aire}{\pi}}$$

Le diamètre équivalent (Equivalent Diameter) est le diamètre du cercle dont la surface est la même que celle du contour. Ces descripteurs sont calculés avec la bibliothèque d'analyse d'image OpenCV [Brahmbhatt, 2013], car elle travaille avec des polygones définis par une liste de points, ce qui était nécessaire pour évaluer les nouveaux descripteurs de forme que nous voulions introduire : les tenseurs de Minkowski [Mantz *et al.*, 2008]. Ces descripteurs sont classés dans la catégorie caractéristiques de forme, ils sont parfois assimilés/comparés à des descripteurs de Fourier, car en 2D ils vont permettre de reconstituer une forme à l'aide d'une série de Fourier. Les tenseurs de Minkowski sont toutefois très dépendant de la taille et de l'orientation d'une forme, c'est pourquoi une métrique indépendante en rotation, en translation et en changement d'échelle est développée, la métrique de structure de Minkowski (MSM) q_s . Ces MSM sont aux nombres de 11 (pour s allant de 2 à 12) et sont représentatives d'une forme quelle que soit sa taille ou son orientation. Par exemple, q_2 est sensible aux formes en bâtonnets, q_3 quant à elle, peut être utilisé pour trouver des formes avec une symétrie triple prédominante, comme les triangles équilatéraux et q_6 est utilisé pour détecter les hexagones réguliers (ces métriques sont un raffinement des paramètres d'ordre d'orientation de Steinhardt [Mickel *et al.*, 2013]). Afin de les calculer, le code de morphométrie appelé Pypaya2 dont le fonctionnement est décrit dans [Schaller *et al.*, 2020] est utilisé.

Une fois tous ces descripteurs calculés il est possible d'effectuer diverses analyses statistiques afin d'évaluer la population de particules à chaque localisation étudiée. Ainsi chaque particule sera décrite par 21 caractéristiques de taille et de forme.

5 Analyse d'image des textures de troisième corps

Comme précisé précédemment, le flux de recirculation est étudié comme une texture. Pour cela, il a été décidé d'utiliser la matrice de cooccurrence d'Haralick [Haralick, 1979] et d'extraire différentes caractéristiques de la texture telles que l'homogénéité, l'énergie, l'entropie, le contraste, la dissimilarité ou la corrélation. La Figure IV.18 illustre le fonctionnement de cette méthode.

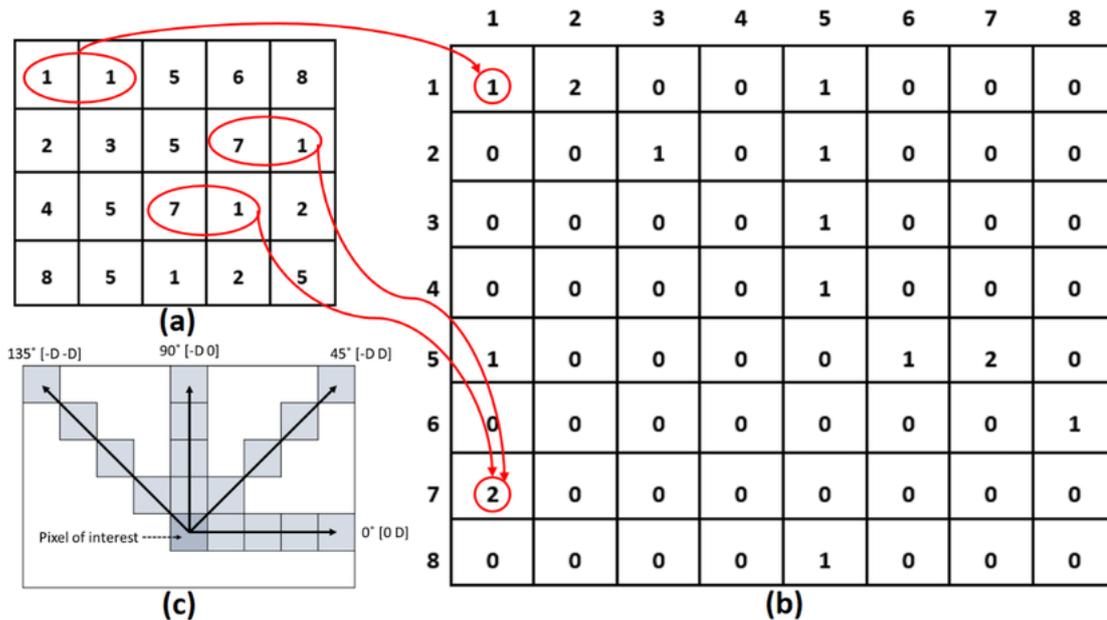


Figure IV.18 – Illustration de la méthode d'exploitation de la matrice de cooccurrence des niveaux de gris (GLCM) de l'image d'entrée (a) à l'image GLCM (b). (c) illustre les relations spatiales des pixels dans le tableau des décalages de lignes et des décalages de colonnes, où D représente la distance par rapport au pixel d'intérêt. Les cercles rouges indiquent la fréquence de cooccurrence d'une combinaison différente de niveaux de gris dans l'image d'entrée et les flèches indiquent le nombre de cooccurrences dans l'image GLCM, d'après [Ahmed, 2020].

L'image MEB sera la donnée d'entrée du code et la matrice de cooccurrence (Grey Level Cooccurrence Matrix GLCM) est calculée avec 3 distances de 1,2,3 pixels et 4 angles $0, \pi/4, \pi/2$ et $3\pi/4$ (comme préconisé par [Haralick, 1979]). A partir de ces 12 matrices, les caractéristiques de la texture sont extraites, suivant les formules explicitées en sous-section 5.1. Les valeurs moyennes de ces caractéristiques permettent d'être indépendant de la direction choisie. Compte tenu de la direction de glissement, la texture a une direction préférentielle, en prenant les moyennes des caractéristiques nous créons artificiellement une isotropie de l'interface de contact, qui pourra être levée et étudiée avec les mêmes outils dans de prochaines études. Le code fournit un fichier CSV contenant toutes les données brutes et les premiers moments statistiques (moyenne et écart-type).

5.1 Extraction des paramètres de texture

Parmi tous les descripteurs de texture existants, nous avons choisi dans nos premiers travaux d'investigation de traiter les descripteurs qui donneraient lieu à une explication au sens de la tribologie, comme l'entropie de la matrice de cooccurrence, en tant que descripteur de désordre comme mentionné dans [Bouchot *et al.*, 2022]. C'est également le cas pour l'homogénéité ou l'énergie. Dans cette configuration, l'entropie peut être interprétée comme un indicateur de désordre dans l'image et donc de l'interface. En effet, l'entropie extraite de la matrice de co-occurrence d'une surface lisse (qui peut correspondre aux premiers tours de test) est plus faible que lorsqu'il y a production de particules de corps tiers (non éjectées à ce stade). Cependant, dans certains cas, une fois le régime stationnaire atteint, le troisième corps au centre de la piste est écrasé, voire lissé, et l'entropie tend à diminuer. Ainsi, l'entropie apparaît a priori comme un paramètre étroitement lié à la texture du troisième corps central (flux de recirculation). L'entropie (entropy) est définie comme suit :

$$Entropy = - \sum_{i,j=0}^{L-1} P(i,j) \log_2 P(i,j)$$

Avec P le niveau de gris du pixel de coordonnées (i,j).

L'homogénéité est définie comme

$$Homogeneity = \sum_{i,j} \frac{1}{1 + (i - j)^2} P(i,j)$$

Elle tend à augmenter lorsque la texture devient grossière, c'est-à-dire lorsque la texture comporte des régions homogènes.

L'énergie (energy) est une mesure de l'uniformité, elle diminue lorsque les valeurs de niveau de gris ne sont plus équiprobables, elle est calculée comme suit

$$Energy = \sqrt{\sum_{i,j} P(i,j)^2}$$

Ces métriques sont des moments statistiques d'ordre deux, ainsi on va chercher à leur donner un sens en s'appuyant sur les images à notre disposition.

5.2 Interprétation des features de texture

Les caractéristiques de texture extraites de la matrice de cooccurrence sont calculées pour un angle et une distance données et la configuration du tribomètre va induire une direction privilégiée dans les images. Afin de s'affranchir de cette orientation, les résultats présentés ci-après seront les valeurs moyennes des paramètres de texture. Ainsi, par exemple, quand il sera question de l'énergie il faudra comprendre moyenne de l'énergie pour les douze configurations calculées.

La Figure IV.19 illustre une interprétation de certaines des caractéristiques de texture. Les images A présentent une même entropie alors que l'homogénéité et l'énergie sont plus petites sur l'image de droite. Cette baisse peut s'expliquer par la présence de petites particules sur les zones lisses (encadré rouge), la texture devient alors plus fine et l'homogénéité

diminue. Les images B présentent le cas inverse, l'énergie et l'homogénéité sont identiques alors que l'entropie est plus élevée sur l'image de gauche. Cette augmentation est due à une zone de fort chaos (encadré rouge) que l'on ne retrouve pas sur l'image de droite.

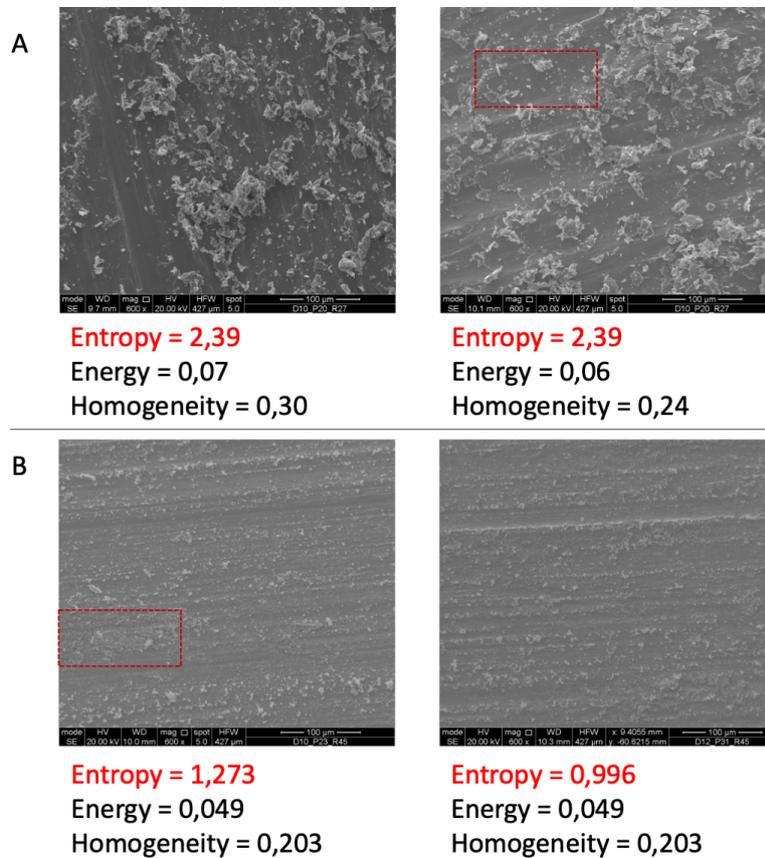


Figure IV.19 – Illustration des caractéristiques de texture

6 Conclusion

Ce chapitre a permis de présenter la composante expérimentale de ce travail de thèse : les tests tribologiques, l'acquisition d'images MEB, puis l'étude du troisième corps d'un point de vue qualitatif afin de décrire sa morphologie et de rechercher son lien avec le frottement. Les tests menés dans le cadre de cette étude sont réalisés avec le même matériau dans des conditions expérimentales différentes : changement d'atmosphère, de distance de frottement, de système mécanique (épaisseur du disque), tout en conservant une force normale ainsi qu'une vitesse tangentielle constante.

Nous avons donc pu observer une bonne reproductibilité des tests sous atmosphère libre (Figure IV.7) avec des valeurs de frottement en régime établi tendant vers une valeur asymptotique de 0.65. Ce n'est pas le cas pour l'Argon, puisque les courbes sont chaotiques, présentant de fortes oscillations. Ces courbes au comportement erratique, bien que difficilement exploitables en l'état, ont un intérêt significatif dans le chapitre V pour brouter les bases de données. Les différences entre air et Argon sont significatives lors de l'observation du troisième corps. Que l'on s'intéresse au flux de recirculation ou au

débit d'usure les morphologies sont très différentes. Le troisième corps, produit lors des tests sous Argon, se détache des premiers corps et est éjecté sous forme de morceaux relativement gros et lisses, là où le troisième corps produit sous air ambiant est écrasé en centre de piste ou réduit en poudre pour être éjecté. Ces configurations spatiales et ces morphologies sont alors mises en parallèle du coefficient de frottement mesuré au dernier tour du test ayant engendré leur production, afin de visualiser s'il existe un lien entre elles et les variations de COF mesurées, Figure IV.14. Ces descriptions morphologiques et ces corrélations sont qualitatives et tendent à être enrichies de descripteurs quantitatifs. L'extraction de ces descripteurs passe par une étape de traitement et d'analyse d'image.

Le traitement des images est une étape primordiale de ce projet, c'est la qualité des informations recueillies qui influencera l'étape de corrélation morphologie-rhéologie présentée en chapitre V.

Il est donc important de signaler que l'algorithme de segmentation présente 2 défauts à prendre en considération :

- Lorsque les images présentent de gros agglomérats avec une diversité de textures importantes, l'algorithme aura tendance à segmenter la couche supérieure de particules. La masse est alors considérée comme faisant partie intégrante du *background*, Figure IV.20. Cet événement, bien que préoccupant car pouvant créer des biais dans les études ultérieures reste très rares, moins de dix occurrences sur les 672 images traitées. Elles sont volontairement laissées dans les données afin de créer du « bruit » pour limiter les effets de surapprentissage.

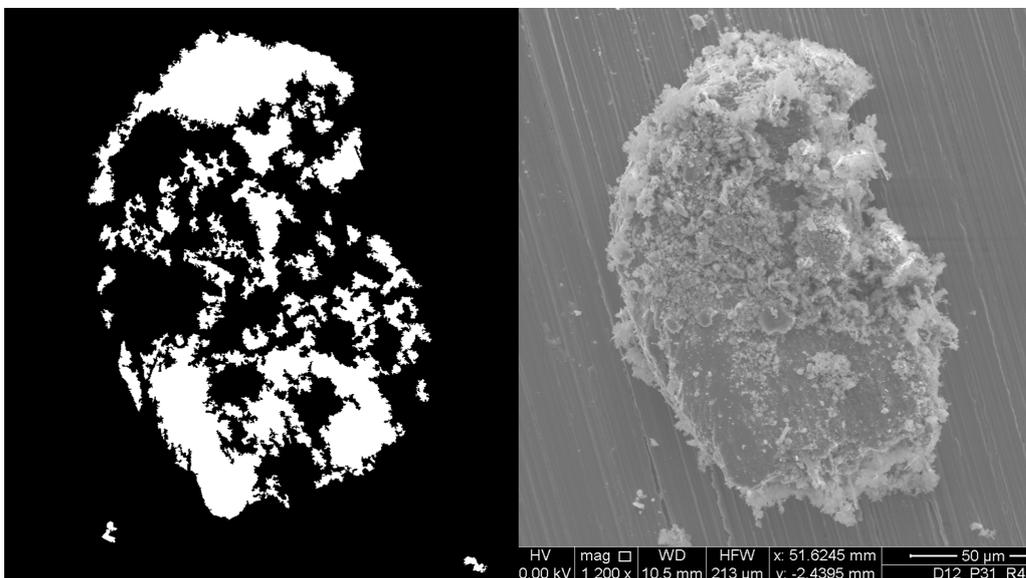


Figure IV.20 – Exemple de segmentation d'un agglomérat

- Les particules produites sous Argon restent difficiles à segmenter du fait de leur apparence similaire au *background* : elles semblent transparentes. Leurs contours ne sont pas toujours bien définis, car trop sombres, les zones ne seront pas fermées, ce qui ne permettra pas de remplir les zones segmentées lors de la phase de nettoyage. Pour palier cela, il a été envisagé d'enrichir la Base de Données avec d'autres images

de particules produites sous Argon, mais cela n'a pas amélioré les performances de classification.

L'étude du flux de recirculation par extraction de descripteurs de texture étant relativement nouvelle, nous avons choisi de nous concentrer sur les valeurs moyennes des caractéristiques de la matrice de cooccurrence, tout en gardant à l'esprit la possibilité de prendre en considération les variations dues à l'orientation des traces de frottement.

C'est l'ensemble de ces caractéristiques, de texture et morphologiques, que nous allons chercher à relier aux données rhéologiques dans le chapitre suivant dans un premier temps par une approche graphique qualitative puis à l'aide du *machine learning* dans un but prédictif.

Le flux de matière dans un système de glissement peut être décrit à l'aide du circuit tribologique (voir Figure I.8). Les premiers corps, en contact, sont en mouvement relatif; le troisième corps se forme à l'interface de glissement. Le flux source, Q_s , représente le détachement du matériau du premier corps pour devenir le troisième corps; le flux interne Q_i décrit le mouvement du matériau le long de l'interface; le flux d'éjection Q_e est le matériau éjecté de l'interface; le flux de recirculation Q_r est le matériau éjecté qui a été réintroduit dans l'interface; et le flux d'usure Q_w est le matériau définitivement retiré du système de glissement. Durant cette étude, il est proposé d'étudier la morphologie du troisième corps retrouvé dans les différents flux, et d'établir quels liens existent entre ces différentes configurations et les conditions expérimentales menant à la production de ce troisième corps. Pour cela une première approche par analyse de sensibilité est proposée afin d'en évaluer les avantages et les limitations. Approche sur laquelle nous nous appuyerons pour valider notre volonté d'utiliser le *machine learning*¹

1 Première approche par étude graphique et analyse de sensibilité

Pour rappel, pour chaque essai, il a été acquis : - pour les particules (flux d'usure), 2 images par zone d'intérêt à un angle θ donné, soit 48 images par essai - pour les textures (flux de recirculation), 1 image par zone d'intérêt, soit 24 images par essai.

1.1 Le flux d'usure

Les particules éjectées qui composent le flux d'usure (Figure I.8) quittent le contact et se déposent sur les bords de la piste. Cependant, il n'y a pas d'indication expérimentale sur le moment de l'éjection. Sur la Figure IV.9, les différents points correspondent aux

1. Vocabulaire présenté au chapitre .

24 ROI définies précédemment (figures IV.9A, IV.9C) et pour les 14 essais. Sur le dernier tour des tests considérés (Tableau IV.3), le coefficient de frottement n'est pas le même à toutes les positions, mais les paramètres morphologiques étudiés gardent une valeur presque constante le long du tour de piste, $\simeq 0.4$, $\simeq 0.8$, $\simeq 0.8$ et $\simeq 0.6$ respectivement pour la circularité, la rondeur, la solidité et l'élongation. Les valeurs nulles de ces descripteurs correspondent à une absence de particules, donc à un débit d'usure nul.

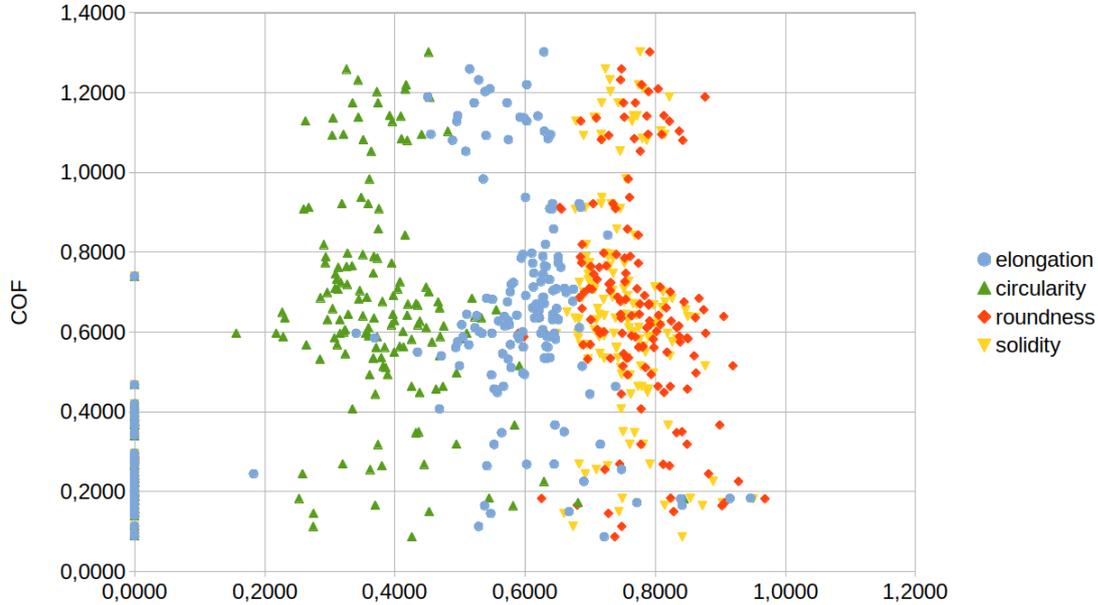


Figure V.1 – Évolution du COF mesuré au dernier tour en fonction de la circularité et de l'élongation.

La Figure V.1 et le manque d'informations temporelles concernant chaque particule d'usure individuelle, soutiennent l'hypothèse qu'il n'y a pas de corrélation apparente entre ces quatre caractéristiques morphologiques (circularité, rondeur, solidité et élongation) et l'évolution du COF. Ces résultats sont en accord avec les résultats de Jaza [Jaza *et al.*, 2016].

Afin de déterminer quels sont les paramètres qui influenceraient les variations du coefficient de frottement, une étude de sensibilité est réalisée en utilisant les indices de Sobol [Saltelli & Sobol', 1995]. Il est important de noter qu'il n'existe pas de formule analytique connue reliant le coefficient de frottement aux paramètres de formes des particules éjectées. Pour surmonter ce problème, une régression polynomiale multi-variée, utilisant la méthode des moindres carrés, est utilisée [Van Huffel & Vandewalle, 1991]. Il est donc possible d'obtenir une expression sous la forme d'un polynôme de degré 3, déterminé après constatation qu'un degré supérieur n'apporte rien de plus quant à la qualité de la régression, avec un coefficient de régression

$$R^2 = 1 - \frac{\sum_{i=0}^n (y_i - \tilde{y}_i)^2}{\sum_{i=0}^n (y_i - \bar{y}_i)^2} = 0.8336 \quad (\text{V.1})$$

avec n le nombre de points, y_i la valeur mesurée au point i , \tilde{y}_i la valeur prédite au point i et \bar{y} la valeur moyenne mesurée, et d'évaluer l'évolution du COF en fonction de l'allongement,

de la circularité, de la rondeur et de la solidité.

$$COF = f(Circularity, Elongation, Solidity, Roundness)$$

A partir de cette régression, il est possible de calculer trois types d'indices de sensibilité :

- L'indice de Sobol d'ordre 1 (S1)

$$S1_i = \frac{Var(E(Y|X_i))}{Var(Y)}$$

qui évalue la contribution de chaque paramètre X_i sur le coefficient de frottement.

- L'indice total (St) qui évalue la contribution globale d'une variable d'entrée

$$St_i = \sum_{k \neq i} S_k$$

$\#i$ représente tous les indices, i inclus.

- Et enfin, avec la décomposition de la variance [Gourieroux & Monfort, 1995], les indices de second ordre (S2) qui rendent compte de l'influence de l'interaction de deux paramètres sur la sortie du modèle.

Les indices $S1_{conf}$ et ST_{conf} , présentés dans le Tableau V.1 correspondent à un intervalle de confiance pour les indices considérés, il s'agit d'une mesure standard en analyse de sensibilité. Afin d'obtenir une première étude significative et une régression la plus fiable possible, l'essai sélectionné pour extraire les données est un essai en régime stationnaire ($D = 18m$ de frottement) sous atmosphère libre, les ROI ont été sélectionnées tous les 15° sur la piste du disque, produisant ainsi 48 images contenant chacune 3 à 70 particules. Les valeurs des caractéristiques des particules sont moyennées par image et mises en relation avec le COF mesuré lors du passage dans la zone d'étude.

Dans le cas du disque étudié ici, l'analyse des indices présentés dans le Tableau V.1 montre que, bien que lors de l'analyse graphique (Figure 4.1), il ne semble pas y avoir de corrélation entre le COF et les caractéristiques des formes (ici l'élongation et la circularité), la variation de certains paramètres affecte la variance du COF. Ainsi, les paramètres ayant une influence majeure sont l'élongation (35%), la rondeur (34%) et l'interaction élongation-rondeur (21%). L'indice total S_T permet d'évaluer s'il existe également une interaction triple. Par exemple, si on considère la rondeur, sa contribution totale est de $S_T = 0.5963$ et $S_1 + S_2 = 0.5480$; elle intervient dans des interactions triples à hauteur de 4.83%. Grâce à ces indices, il est possible de fournir aux tribologues des informations sur la pertinence de l'utilisation de certains paramètres pour définir un modèle. Dans cette étude de sensibilité, il faut garder à l'esprit qu'il s'agit de valeurs relatives aux paramètres sélectionnés. L'introduction de nouveaux paramètres pourrait modifier l'interprétation, il a été décidé ici de n'utiliser que ces paramètres tribologiques en première intention.

Sobol Indices	Elongation	Circularity	Roundness	Solidity
S1	0,3548	0,0021	0,3388	0,0391
$S1_{conf}$	0,0230	0,0025	0,01931	0,0076
ST	0,6110	0,0098	0,5963	0,0892
ST_{conf}	0,0309	0,0007	0,0309	0,0056
S2		0,0007	0,2092 0,0014	0,0077 0,0002 0,0068

Tableau V.1 – Indices de Sobol pour l'analyse des paramètres morphologiques.

1.2 Le flux de recirculation

Les textures de surface traduisent des flux de recirculation. La même approche que pour le flux d'usure est utilisée mais s'appuyant sur les descripteurs de texture.

Sur le graphique présenté à la Figure V.2, les points correspondent aux différents ROI sélectionnées pour différentes distances de frottement (Tableau IV.3). L'évaluation des graphes de la Figure V.2 suggère qu'il existe des tendances claires quant au COF en fonction des paramètres de texture considérés. L'entropie semble évoluer de façon monotone avec la distance de glissement. Lors des études préliminaires menées en amont [Bouchot *et al.*, 2021a], cette tendance avait déjà pu être observée ; cependant à ce moment là, il n'était pas encore question de relation COF-entropie mais uniquement de faire une visualisation de l'évolution de l'entropie au cours des phases de la vie du contact. Alors que l'énergie et l'homogénéité sont en lien avec les phases de la vie du contact (rodage et régime établi).

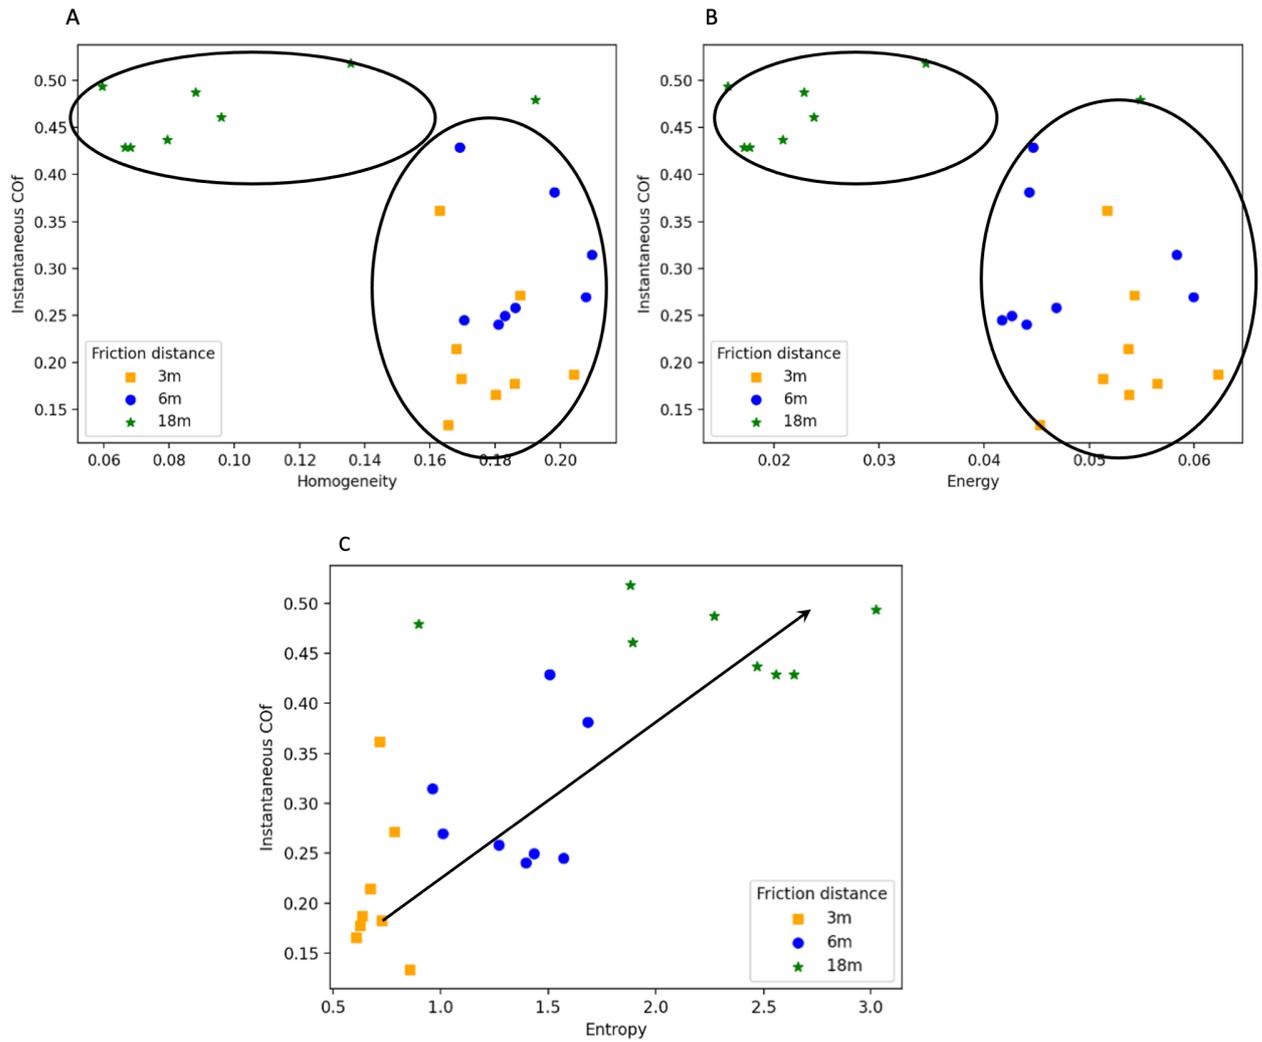


Figure V.2 – Évolution du coefficient de friction (COF) en fonction de A) l'homogénéité, B) l'énergie et C) l'entropie.

De manière similaire à l'analyse du flux d'usure (sous-section 1.1), il est possible de réaliser une analyse de sensibilité avec les paramètres de texture, i.e. l'énergie, l'entropie et l'homogénéité afin d'évaluer leur influence sur la variance du coefficient de frottement. L'analyse des indices de Sobol (Tableau V.2) permet de conclure que dans la configuration étudiée, les paramètres les plus importants sont l'homogénéité (49%) et l'énergie (25%). Graphiquement, il est possible de voir cette corrélation à travers les valeurs élevées du COF pour les faibles valeurs de l'homogénéité et d'énergie (Figure V.2B-V.2C). Les deux clusters de points observés correspondent à deux régimes de frottement différents : l'état stationnaire (frottement élevé) et la phase de rodage (forte variabilité des valeurs de COF, pas de corrélation apparente avec les paramètres homogénéité et énergie).

Sobol Indices	Energy	Entropy	Homogeneity
S1	0,2449	0,0460	0,4942
$S1_{conf}$	0,0173	0,0106	0,0269
ST	0,4207	0,1205	0,7067
ST_{conf}	0,0216	0,0066	0,0304
S2		0,0040	0,1395 0,0392

Tableau V.2 – Indices de Sobol calculés pour l'analyse des paramètres de texture.

Les données fournies par l'analyse graphique et l'analyse de sensibilité permettent d'aborder l'étude de la texture avec deux visions :

- Une vision évolutive, reposant sur la mesure de l'évolution d'un paramètre au cours de la vie du contact [Bouchot *et al.*, 2021a] et permettant de construire un scénario.
- Une vision "corrélative", consistant à déterminer quel panel de caractéristiques extraites de l'image permet de remonter aux paramètres rhéologiques tels que le coefficient de frottement.

Ces deux visions ne doivent pas être mises en opposition. Elles sont complémentaires et permettront d'affiner la compréhension actuelle des flux de troisième corps en contact. Elles peuvent également être applicables dans d'autres configurations, notamment dans des études avec prise en compte de l'évolution temporelle, et peuvent donc donner lieu à d'autres études.

1.3 Conclusions

Une fois les images traitées, il est possible de rechercher s'il existe des corrélations entre les données tribologiques et les caractéristiques du troisième corps. Dans le cas du flux d'usure, sur le graphe présenté en Figure V.1, il semble n'y avoir aucun lien apparent entre coefficient de frottement et propriétés morphologiques des particules. Quelque soit la valeur de ce dernier les descripteurs garderont une valeur constante. L'analyse de sensibilité apporte une information allant à l'encontre de ce constat, la variance de certains paramètres tel que l'élongation pourrait influencer la variance du coefficient de frottement. La distance de frottement semble plus prometteuse lorsqu'il s'agit de texture. Même si, grâce à l'analyse de sensibilité, il est désormais possible de quantifier l'influence des paramètres sélectionnés sur la variation du coefficient de friction.

L'analyse de sensibilité présentée ici est réalisée à partir d'une régression polynomiale construite à partir d'une sélection non exhaustive de descripteurs. Ainsi l'outil, en tant que tel est très prometteur et pourrait apporter beaucoup dans notre domaine d'étude. Il présente néanmoins des limitations. En effet, pour réaliser la régression il a fallu sélectionner des paramètres (ici 4 pour les particules et 3 pour les textures), ainsi on a arbitrairement créé un lien avec notre sortie (le COF). De plus, l'analyse a été faite en étudiant séparément les particules puis les textures. Donc, lors du calcul des indices de sobol nous obtenons une contribution des paramètres sélectionnés alors qu'ils ne sont peut-être pas les plus pertinents pour décrire le frottement.

Et comme l'avait déjà montré Jaza [Jaza *et al.*, 2021], la morphologie du troisième corps permet de remonter aux conditions expérimentales et plus largement aux mécanismes d'usure comme dans les travaux de Roylance [Banda *et al.*, 2022 ; Chen *et al.*, 2019 ; Roylance & Raadnui, 1994 ; Sieberg & Hanke, 2023]. L'étude de la Figure V.1 nous permet d'avancer que la morphologie est aussi étroitement liée aux matériaux des premiers corps, car les particules présentées sont produites sous différentes conditions expérimentales (distance de frottement, atmosphère,...). Il serait intéressant de connaître les principaux paramètres influençant la durée de vie du contact. En effet, s'il apparaît que la morphologie du troisième corps est dépendante des conditions expérimentales initiales, il serait intéressant de les déterminer dans le but de mieux contrôler la phase de rodage (début de la vie du contact) par exemple. D'autre part, les descripteurs utilisés ici et qui ont un sens physique pour un tribologue ne semblent pas suffisants pour caractériser le troisième corps. C'est pourquoi des descripteurs supplémentaires tels que les métriques des tenseurs de Minkowski [Mantz *et al.*, 2008] ont été ajoutés dans la construction des bases de données, et présentées en section 2.1.

Afin de lever ces limitations et pour étudier les descripteurs, il est décidé de mettre en place des modèles de machine learning.

2 Etude morpho-tribo par *machine learning*

2.1 Construction des bases de données

La première étude présentée en section 1 aura permis de mettre en lumière l'existence de corrélations entre frottement et morphologie du troisième corps. Pour aller plus loin dans cette investigation, nous nous proposons d'utiliser le *machine learning*. Cette nouvelle approche permettra de prendre en considération plus de caractéristiques ainsi que leurs potentielles interactions afin de réaliser une prédiction des paramètres rhéologiques. Pour cela, la première étape est la construction de bases de données. Cette approche initiée par R. Jaza [Jaza, 2020] est novatrice en tribologie, il n'existe pas de profil de base de données tribologique type, nous n'avons donc aucun *a priori* sur leur contenu. Pour être le plus exhaustif possible, quatre bases de données sont construites, le Tableau V.3 récapitule leurs contenus. Elles sont représentatives de plusieurs approches, décrites en bleu dans le Tableau. Ces bases sont construites à partir des huit premiers tests présentés dans le Tableau IV.3. Ces tests sont tous réalisés sur des disque de 10mm d'épaisseur. La désignation des bases va donner une information relative à leur contenu. Par exemple, le mot clé *part* sera relatif à des descripteurs de particules prises individuellement, *partStat* sera lié aux premiers moments statistiques des descripteurs de particules, donc au débit d'éjection, enfin *text* fera référence aux descripteurs de texture et sera donc intimement lié au flux de recirculation.

Désignation	Nombre d'échantillons	Nombre de features	Contenu
DBpart	7354	21	Descripteurs de chaque particule en chaque position angulaire. Etude locale du débit d'usure.
DBpartStat	192	84	Premiers moments statistiques des descripteurs de particules associés à chaque position angulaire + nombre de particules. Etude du débit d'usure à l'échelle globale, uniquement.
DBtext	192	7	Descripteurs de texture associés à chaque position angulaire. Etude du flux de recirculation uniquement.
DBtextPartStat	192	91	Descripteurs de texture + premiers moments statistiques des descripteurs de particules associés à chaque position angulaire. Etude du flux de recirculation avec prise en compte du débit d'usure.

Tableau V.3 – Description des bases de données construites à partir des caractéristiques morphologiques de troisième corps.

Ces bases ont été construites à partir des 8 premiers tests présentés dans le Tableau IV.3, c'est à dire ceux réalisés sur des disques de 10mm d'épaisseur, les 4 suivants sont utilisés pour construire les bases dites de validation qui permettront d'évaluer la capacité de généralisation des modèles correspondants, ce sont les tests sur les disques de 15mm.

2.2 Mise en œuvre et sélection de la base de données

A l'instar de la phase d'analyse d'images pour la segmentation des particules, la bibliothèque python scikit learn [Pedregosa *et al.*, 2011] est choisie pour implémenter, l'algorithme de *machine learning*. Toutefois, le choix va cette fois-ci s'orienter vers la forêt aléatoire ou *random forest* (RF), ceci pour trois raisons :

1. A modèle équivalent, elle aura un temps de calcul plus raisonnable qu'un algorithme «simple», type MLP SVM... Grâce à la parallélisation des calculs [Azencott, 2018 ; Géron, 2019]. Cette caractéristique, quoique non négligeable pour les gros modèles, n'est pas essentielle ici.
2. De par sa nature de méthode d'ensemble, avec *bagging*, la forêt aléatoire permet de travailler avec de petites bases de données ayant une grande dimension, c'est-à-dire un nombre restreint d'échantillons mais un grand nombre de features [Genuer *et al.*, 2010 ; Géron, 2019].

3. Enfin, sa capacité à évaluer l'influence des features lors du processus d'apprentissage et de prédiction [Biau, 2012].

Le programme est développé sous la forme d'un notebook python et fonctionne de la façon suivante (résumé dans la Figure V.3) :

- Ouverture de la base de données.
- Lors de l'étape de préparation des données, il faut normaliser la base de données, considération qui n'avait pas lieu d'être pour la base de données allouée à la segmentation des particules étant donné qu'elle était entièrement composée de valeurs de niveau de gris. Le découpage en un jeu d'entraînement et un jeu de test est 80 % et 20 % respectivement.
- Le tuning des paramètres va suivre le même protocole que proposé au chapitre I, une recherche des hyperparamètres optimaux globale avec RandomizedSearchCV, puis une recherche plus fine avec GridSearchCV (voir nomenclature et état de l'art p. 17,51).
- S'en suit une phase d'entraînement.
- Puis la Forêt est évaluée tout d'abord par le calcul du R2 avec l'eq. V.1. Ce coefficient de détermination n'est pas le plus adapté aux problèmes de régressions multivariées car très sensible aux valeurs extrêmes, mais a le mérite d'apporter une indication quantifiable de la bonne marche du processus de prédiction [Géron, 2019 ; Khichane, 2021]. C'est pour cela que l'erreur moyenne sur les prédictions est calculée, nommée ErrMoy et définie comme

$$ErrMoy = \frac{|y_{pred} - y_{mesuré}|}{nb_{mesures}}$$

L'erreur moyenne est très dépendante de la manière dont les jeux d'entraînement et de test sont découpés. Pour lever l'aléatoire lié à cette opération on peut reproduire plusieurs fois la procédure de découpage et moyenner les performances obtenues. On parle alors de CrossValidation, et la performance est évaluée en calculant la racine de l'erreur quadratique moyenne appelée CVscore. Le CVscore est calculé pour dix découpages successifs². Les résultats pour chaque base de données sont calculés sur l'ensemble des jeux de test (Tableau V.4).

- Enfin la forêt est sauvegardée dans un fichier binaire, pour pouvoir être réutilisée par la suite.

2. Aussi appelés *fold*s.

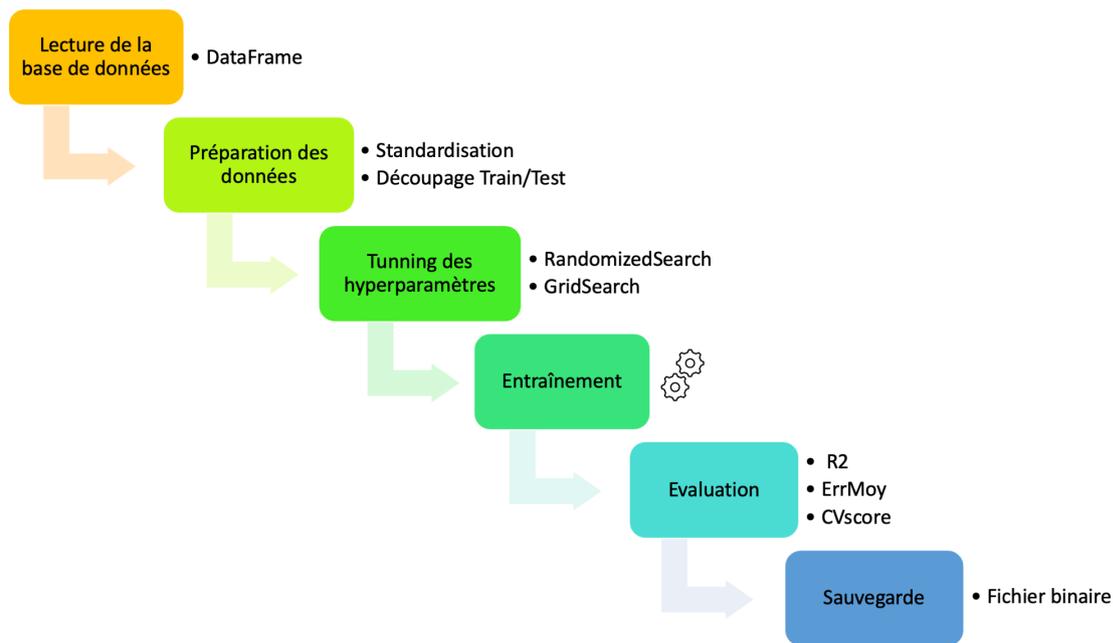


Figure V.3 – Fonctionnement du code de machine learning

Ce processus est mis en place pour chacune des bases de données, il en résulte 4 fichiers binaires contenant les quatre forêts dimensionnées et entraînées. Lors de l'établissement de ces performances nous n'avons pas fait face à des cas de suspicion de surapprentissage, ainsi les métriques proposées dans le Tableau V.4 sont établies sur les ensembles de test.

	DBpart	DBpartStat	DBtext	DBtextPartStat
R^2	0.0742	0.4193	0.7232	0.6807
ErrMoy	0.1644	0.1540	0.1318	0.1363
CVscore	0.2068±0.017	0.2243±0.08	0.2101±0,102	0.1978±0.05

Tableau V.4 – Métriques de performance des forêts aléatoires évaluées sur le jeu de test.

Toutes les bases ne se valent pas en terme de qualité pour réaliser une bonne prédiction. C'est l'étude conjointe des métriques de performance qui va permettre de choisir la base contenant l'information la plus pertinente.

Dans un premier temps nous avons testé la base DBpart étant donné son statut "historique". En effet dans la littérature c'est bien à partir des caractéristiques morphologiques des particules qu'il est possible de remonter aux conditions de tests [Jaza *et al.*, 2016] ou aux mécanismes d'usure [Kowandy *et al.*, 2007 ; Roylance & Raadnu, 1994]. La base *DBpart*, contenant uniquement des particules individuelles, présente un coefficient de régression très faible, indiquant une prédiction de mauvaise qualité sur le jeu de test, l'erreur moyenne semble à première vue du même ordre que les autres, on va donc chercher à tracer la valeur prédite du COF en fonction de la valeur mesurée afin de visualiser les écarts de prédictions (Figure V.4).

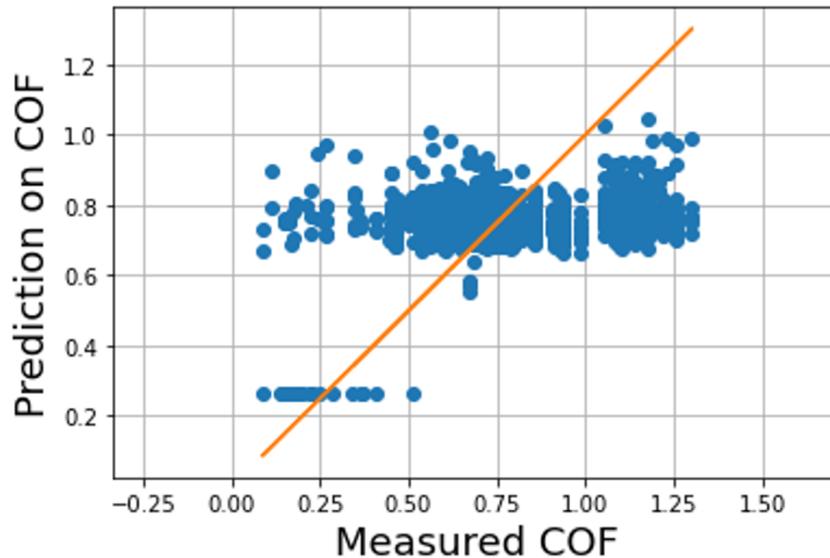


Figure V.4 – Comparaison de la valeur de COF mesurée et prédite à partir de la base *DBpart*

On constate donc que le modèle prédit systématiquement une valeur proche de 0.7, notre base étant composée de 4 tests en rodage, donc présentant peu d'éjection de particules et de 4 tests en régime établi avec une augmentation significative du nombre de particules jusqu'à 100 attribuées à un même coefficient de frottement. Il semblerait que le COF associé à la présence d'une particule soit assimilé à la valeur asymptotique de frottement observée sur la Figure IV.7. Ce constat est cohérent avec l'étude graphique de la section précédente (Figure V.1), étant donné notre méconnaissance du moment de création et d'éjection des particules, il semble incongru de vouloir attribuer à une particule la valeur de COF mesurée au dernier tour de l'essai.

Afin d'étudier non plus la particule mais bien le flux d'usure, il est envisagé dans un second temps, de moyenniser les valeurs et de comptabiliser les particules sur leur lieu d'éjection. C'est dans cette optique que la base *DBpartStat* est construite, car elle contient les premiers moments statistiques des descripteurs morphologiques des particules en un site de mesure donné, ainsi que le nombre de particules à chaque position angulaire (Tableau V.3). Les résultats sont alors bien plus élevés avec un R^2 sur le jeu de test de 0.4193. Le tracé des valeurs prédites en fonction des valeurs mesurées, en Figure V.5 montre que même si les prédictions présentent une erreur il y a quand même une plus grande variété de valeurs prédites. La valeur de l'erreur moyenne est plus élevée que pour la base *DBpart*, mais ne trouve pas sa source dans les mêmes mécanismes. En effet, nous avons constaté précédemment que les particules éjectées étaient principalement présentes en régime établi et étaient assimilées à un COF asymptotique, or ici l'absence de particule est caractérisée non plus par une absence d'information mais par un débit d'usure nul. Cela laisse penser qu'il existe une information, certes incomplète, relative au COF dans le flux d'éjection global.

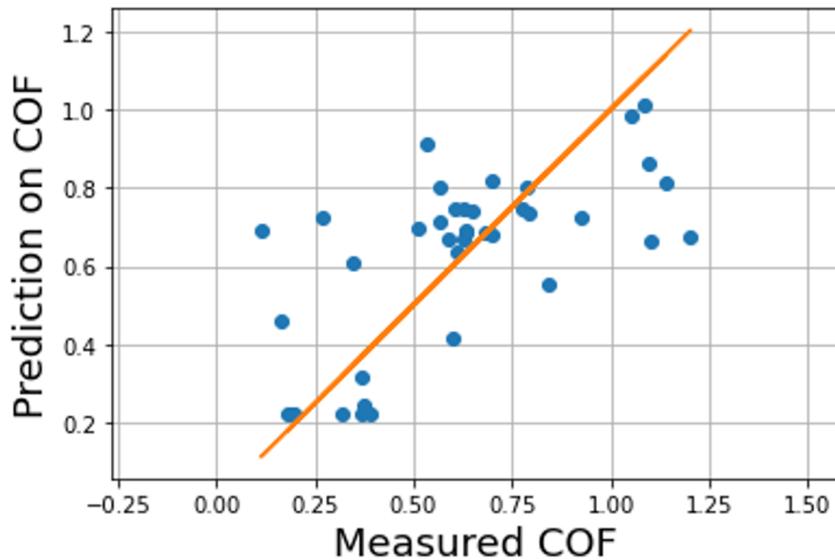


Figure V.5 – Comparaison de la valeur de COF mesurée et prédite à partir de la base *DBpartStat*

Dans les deux premiers cas présentés, le *CVscore* est supérieur à 0.20 ce qui est considéré comme un écart élevé pour un coefficient de frottement mesuré dans la gamme [0.2, 1.2]. L'information est donc ailleurs.

C'est pourquoi nous allons regarder, dans un troisième temps, du côté du flux de recirculation et donc de la base de données *DBtext* qui contient les descripteurs de texture.

Dans le cas de *DBtext* la qualité de la prédiction s'améliore ($R^2 = 0.7232$). L'étude du graphe associé, Figure V.6, montre des valeurs prédites de plus en plus proches des valeurs expérimentales.

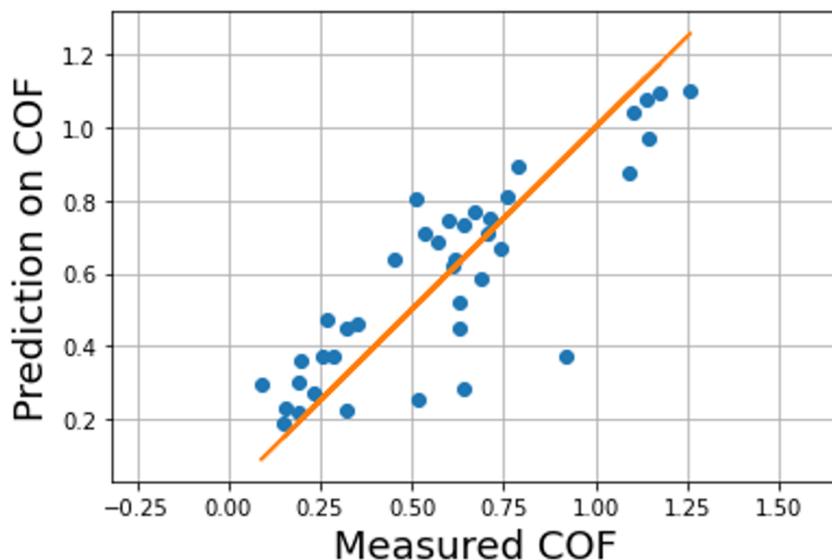


Figure V.6 – Comparaison de la valeur de COF mesurée et prédite à partir de la base *DBtext*

L'information relative au COF semble en partie "écrite" dans la morphologie du troisième corps en centre de piste. La suite logique est donc d'aller voir dans un quatrième temps, si il est possible d'obtenir encore plus d'informations en combinant les données liées au flux d'usure et celles liées au flux de recirculation. Pour cela on utilise la base *DBtextPartStat*. Cette base contient à la fois des données sur les particules et sur les textures (tableau V.3).

Cette dernière base présente des performances similaires à *DBtext*, voir même un peu moins bonne au regard du R^2 et de *ErrMoy*. La Figure V.7 est également similaire à celle obtenue pour *DBtext*.

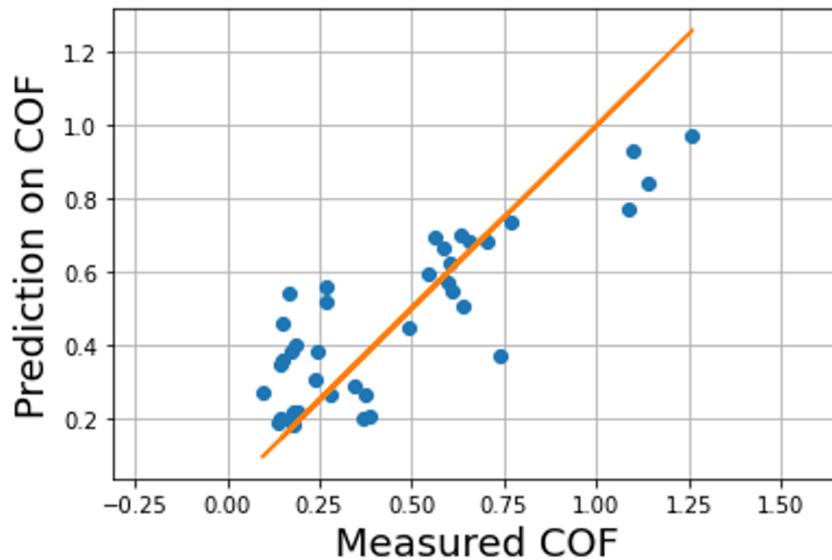


Figure V.7 – Comparaison de la valeur de COF mesurée et prédite à partir de la base *DBtextPartStat*

Ce qui va donc permettre de comparer ces prédictions est le *CVscore*. L'erreur moyenne de prédiction est plus faible avec *DBtextPartStat*. De plus, l'écart type est également plus faible. Cette base est donc statistiquement plus représentative et permet d'effectuer des prédictions plus stables.

C'est donc *DBtextPartStat* qui va être gardée et éprouvée sur les essais effectués sur les disques de 15mm d'épaisseur (voir Tableau IV.3).

2.3 Validation de la base de données

À l'issue de l'évaluation des performances, seule *DBtextPartStat* est conservée ainsi que la forêt aléatoire entraînée sur cette base. Cette méthode ayant montré des résultats satisfaisants lors de l'entraînement et du test, la question de la généralisation se pose. Pour cela, les données des quatre derniers essais du Tableau IV.3 ont été mises de côté, la particularité de ces données est qu'elles ont été produites à l'aide d'un disque de 15mm d'épaisseur. L'idée est de voir si le modèle généralise correctement sur de nouvelles données produites sur un nouveau disque, nouveau disque ayant une géométrie légèrement différente (ce qui ajoute une difficulté supplémentaire). L'analyse des cartes de frottement de deux essais issus des bases de données et de validation présentées en Figure V.8 montre une tendance générale relativement similaire (A-2 et B-2) mais des valeurs de coefficient de frottement plus élevées, de l'ordre de 23%, pour le disque de 15mm (D12P31R45). L'histoire du contact, tour par tour est elle très différente, l'essai A présente une période en milieu de vie de forte diminution du COF, ainsi qu'un dernier tour non constant. Un événement est manifestement survenu entre 1 et 2 radians. L'essai B possède deux zones du disque en début de contact présentant un faible COF, puis le frottement va s'uniformiser, malgré quelques événements ponctuels entraînant de légères baisses du COF. Ces événements peuvent être imputables à un morceau de troisième corps qui se serait détaché (du pion ou du disque) et que se ferait écraser sur la piste. L'idée ici sera de voir si notre modèle est capable de prédire le COF associé au troisième corps de ce nouvel essai, malgré une différence en terme de mécanisme, élément du triplet tribologique (chapitre I p.25). En effet, d'un point de vue mécanique, le changement d'épaisseur de disque a nécessité de modifier la hauteur du bras maintenant le pion par l'ajout d'une cale sur le tribomètre. D'un point de vue tribologique, cette modification peut induire des changements de dynamique locale au contact [Di Bartolomeo *et al.*, 2012 ; Tonazzi *et al.*, 2018] et donc, des variations de troisième corps au niveau du contact.

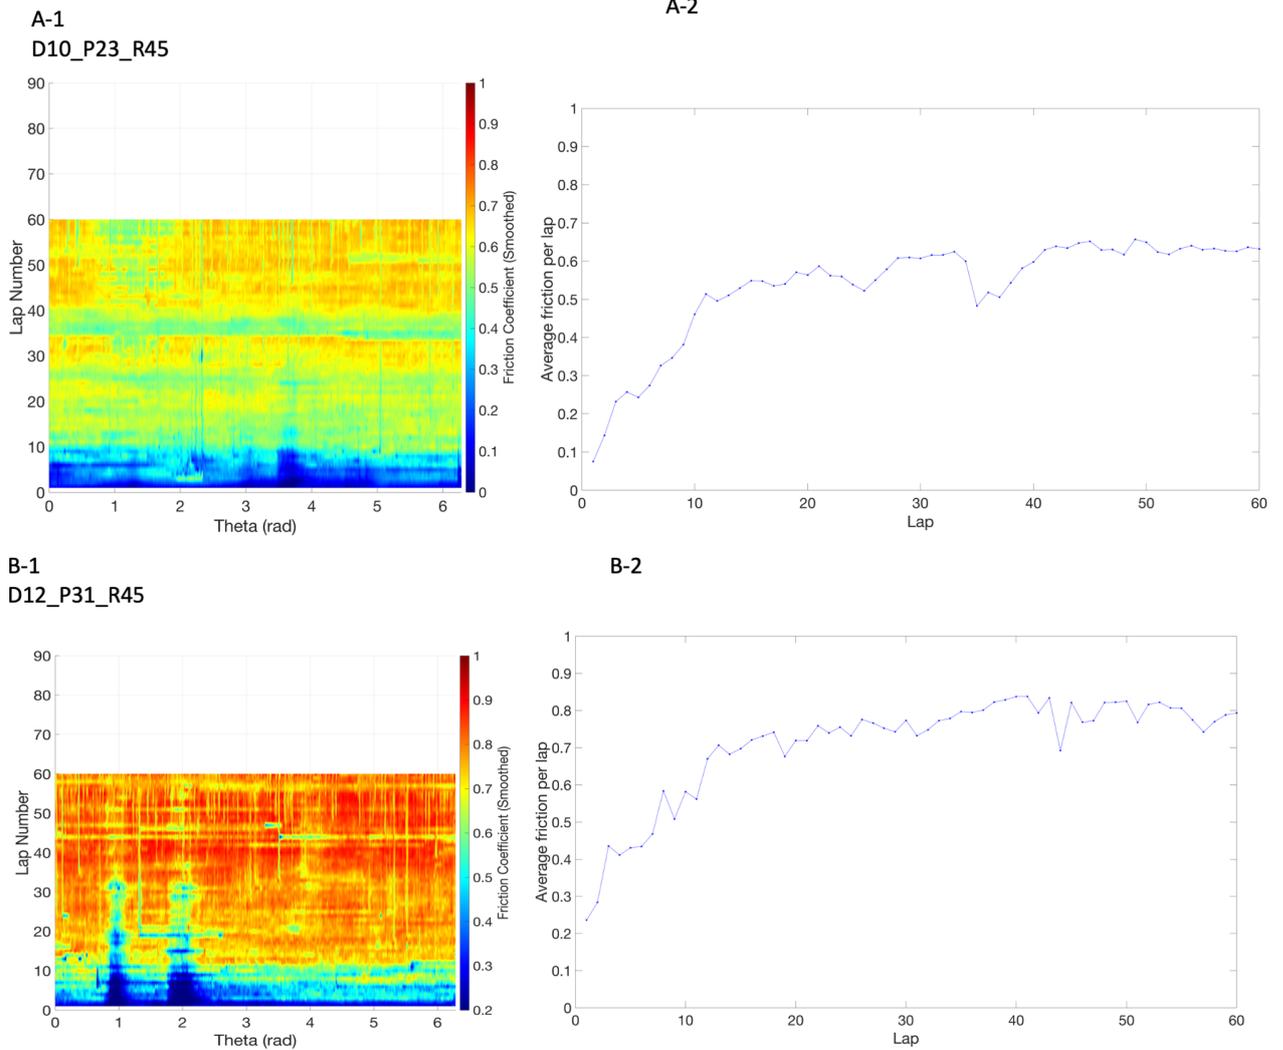


Figure V.8 – Évolution du frottement lors d’essais en régime établi pour un disque de 10 mm d’épaisseur (A) et de 15mm d’épaisseur (B)

Ci après les résultats obtenus lors du test de généralisation,

- $R^2 = -0.0937$
- $ErrMoy = 0.2143$
- $CVscore = 0.1937 \pm 0.1306$

Le coefficient de régression associé à cette prédiction $R^2 = -0.0937$ est négatif ce qui est associé à une prédiction de très mauvaise qualité. En effet, la Figure V.9 présente des valeurs très éclatées autour de la droite *Valeurs Mesurées = Valeurs Prédites*

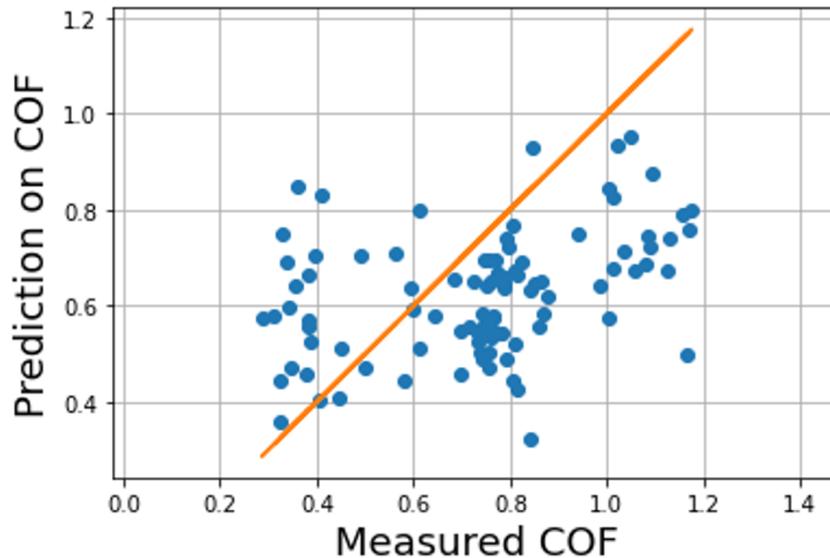


Figure V.9 – Comparaison de la valeur de COF mesurée et prédite à partir des tests produits sur des disques de 15mm d'épaisseur. En orange Mesure = Prediction.

L'erreur de prédiction moyenne de 0.2143 est très importante et au regard du *CV score* la prédiction n'est pas stable. Bien que naïvement l'épaisseur du disque ne laissait pas envisager de différences significatives dans la prédiction, il s'est avéré que cette modification du système mécanique engendre des difficultés pour l'algorithme à prédire le COF. Cette différence significative doit donc être prise en compte lors de la création de la base de données, cette dernière doit donc évoluer pour être plus versatile.

2.4 Évolution de la base de données.

Comme exposé précédemment le modèle entraîné sur les données issues des disques de 10mm d'épaisseur, ne permet pas de généraliser sur des données produites à partir d'un système mécanique différent (disque de 15mm d'épaisseur). Pour palier ce problème une nouvelle base de données est construite à partir des données produites sur les disques de 10 et de 15mm, les tables de valeurs sont concaténées et mélangées de façon aléatoire. La nouvelle base ainsi obtenue est nommée *DBmix* et a pour dimensions :

- 288 Echantillons
- 91 Features
- 1 Label : COF

Comme précédemment la base de données est divisée en un jeu d'entraînement (80%) et un jeu de test (20%), puis la RF est dimensionnée à l'aide des outils présentés au chapitre I. Le Tableau V.5 présente les hyperparamètres optimaux de la RF.

Hyperparamètre	Valeurs
n-estimators	1200
n-samples-split	2
n-samples-leaf	1
max-features	'auto'
max-depth	None
Bootstrap	True

Tableau V.5 – *Hyperparamètres optimisés pour le traitement de la base DBmix*

La forêt dimensionnée est entraînée et sauvegardée, ses performances sur le jeu de test sont les suivantes :

- $R^2 = 0.5758$
- $ErrMoy = 0.1382$
- $CVscore = 0.1806 \pm 0.0476$

Le R^2 est moins élevé que pour *DBtextPartStat* présenté dans le Tableau V.4, mais rappelons que cette métrique est très dépendante des valeurs extrêmes [Khichane, 2021], ce qui est le propre de notre problème. Toutefois, on va retrouver une $ErrMoy$ et un $CVscore$ similaires voir meilleurs pour ce dernier. De plus, graphiquement, la Figure V.10, montre des valeurs de prédiction moins dispersées autour de la droite $Mesure = Prédiction$.

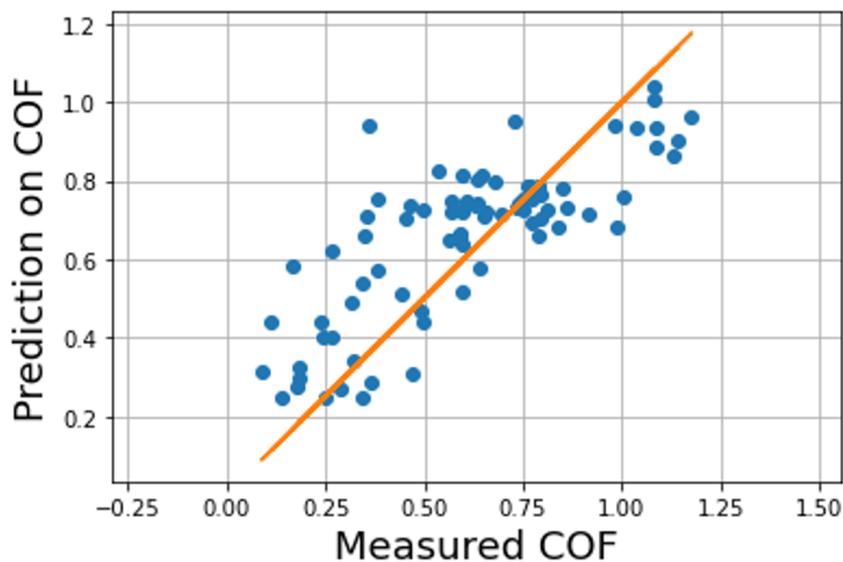


Figure V.10 – *Comparaison de la valeur de COF mesurée et prédite à partir de DBmix. En orange $Mesure = Prédiction$.*

Ces résultats sont plus satisfaisants que ceux présentés précédemment (Figures V.9), mais pour les obtenir nous avons dû utiliser les données initialement conservées pour tester la généralisation du modèle.

La capacité de généralisation sera donc éprouvée sur les tests supplémentaires présentés au chapitre IV. Pour rappel, il s'agit de deux tests en régime établi dont les conditions sont dans le Tableau IV.3 à la page 75.

Les caractéristiques du troisième corps produit lors de ces essais sont alors évaluées par le modèle entraîné sur *DBmix* et donnent les résultats suivants :

- $R^2 = -2.1070$
- $ErrMoy = 0.1438$
- $CVscore = 0.0882 \pm 0.0371$

Ces résultats, surtout le R^2 posent question, la prédiction est jugée mauvaise au regard de ce dernier, malgré une erreur moyenne et un $CVscore$ très bons. Pour en savoir plus nous nous intéressons à la Figure V.11. Elle montre des valeurs regroupées en "cluster" autour d'une portion de droite dans l'intervalle $[0.5, 0.8]$, cela s'explique par la nature des tests, qui sont deux essais en régime établi sous atmosphère libre.

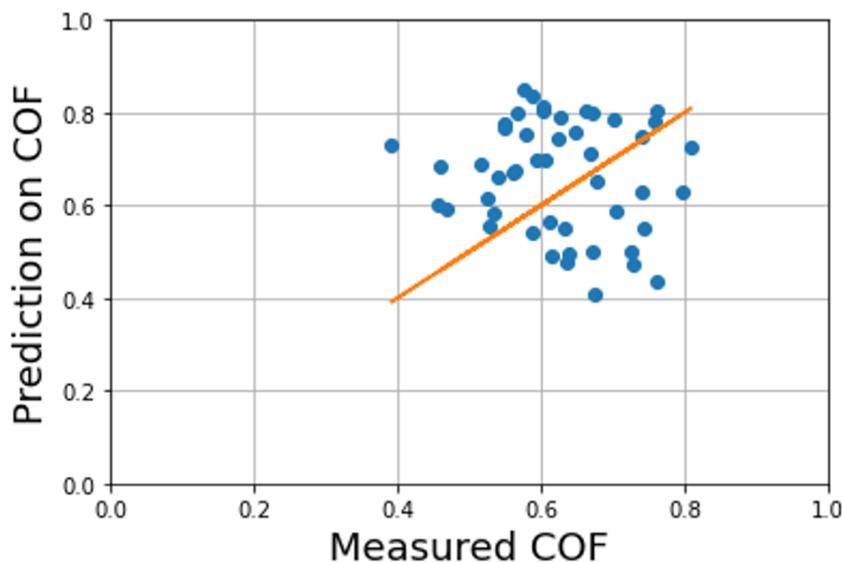


Figure V.11 – Comparaison de la valeur de COF mesurée et prédite à partir des nouveaux tests. En orange Mesure = Prédiction.

Notons que l'essai D17P42 contenu dans ces données présente une forte discontinuité dans les valeurs du COF lors des derniers tours, la Figure V.12 présente la carte de frottement de cet essai. Ces brusques changements de COF peuvent perturber la prédiction et donc le R^2 . Le $CVscore = 0.08$ est très encourageant d'un point de vue tribologique, il signifie qu'en moyenne sur 10 découpages aléatoires des données, l'erreur moyenne commise sur la prédiction est inférieure à 0.10. Cette prédiction est réalisée sur des disques "neufs" de 10 et de 15mm, donc peu importe le chemin parcouru, l'information a pu être récupérée.

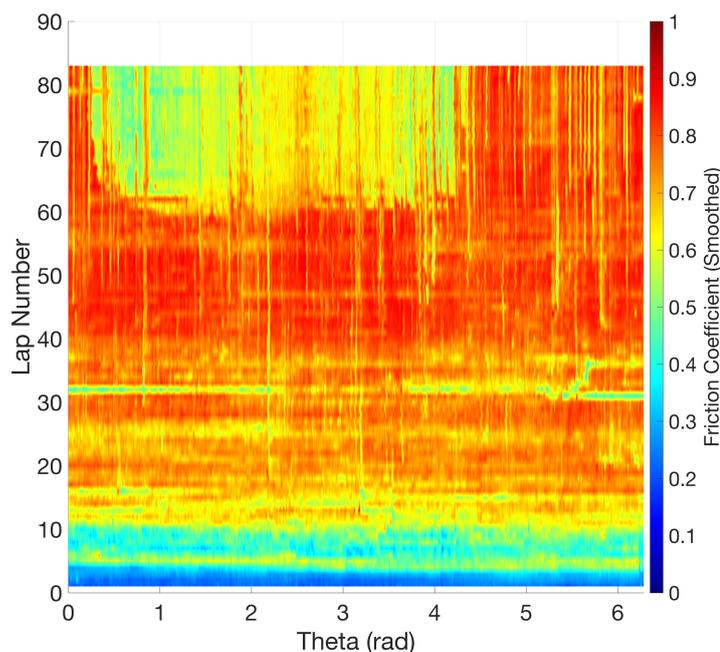


Figure V.12 – Carte de frottement de l'essai D17P42

La création de *DBmix* aura donc permis d'améliorer la capacité de généralisation du modèle. L'erreur de prédiction reste toutefois supérieure à l'erreur évaluée sur le jeu de test, ce qui peut s'expliquer par la variabilité de résultats expérimentaux. En effet, comme l'illustre la Figure IV.7, les essais présentent une tendance commune mais un historique très distinct. Cet historique peut être gardé en mémoire dans le troisième corps, par le biais d'un flux d'éjection plus ou moins important ou par un flux de recirculation plus ou moins lissé. Autant d'évènements qui peuvent bruite les données exploitées par le modèle et ainsi introduire de l'erreur dans la prédiction. Notons que ces résultats sont très satisfaisants au regard de leur statut de première tentative de prédiction du COF à partir du troisième corps. C'est donc ce modèle et la base ayant servi à le construire qui vont être exploités dans la section suivante, dans laquelle il sera question d'étude d'influence des features dans le processus de prédiction.

3 Étude d'influence des features

Avant de se lancer dans cette dernière étape il est important de reprendre le cheminement parcouru.

1. Mise en place de tests tribologiques
2. Acquisition des images de troisième corps
3. Exploitation des données tribologiques
4. Traitement des images
5. Prédiction du COF à partir des informations extraites des images

Le tribologue ne peut pas se contenter d'un outil qui serait uniquement prédictif, il a besoin de connaître quelles informations ont permis d'obtenir cette prédiction afin de

mieux comprendre l'information codée dans le troisième corps. Pour cela nous allons présenter ici une approche exploitant les compétences intrinsèques de la *random forest*.

3.1 Etude de l'influence des features

Lors de l'entraînement de la *random forest* un paramètre nommé impureté est calculé avant chaque séparation en noeuds fils, le but étant de minimiser cette impureté afin d'obtenir des arbres les plus purs possible. Il est alors possible d'évaluer l'influence des features en calculant leur influence sur la diminution moyenne de l'impureté, on parle alors de Mean Decrease in Impurity (MDI). Le calcul des MDI permet de classer les features par ordre d'influence comme le montre la figure V.13.

On voit sur la Figure V.13 qu'une caractéristique (feature) est prédominante dans le processus de prédiction. Il s'agit de *nb-part-ext*, c'est-à-dire, le nombre de particules éjectées en extérieur de piste en un lieu donné, autrement dit, une caractéristique intrinsèque du flux d'usure. Les caractéristiques de texture semble également influentes, liées au flux de recirculation, tout comme les 7e et 8e métriques de Minkowski, donc des caractéristiques de forme.

Ces informations sont à prendre avec du recul car établies lors de l'entraînement, elles ne sont donc pas représentatives de la capacité de généralisation du modèle. De plus, elles sont très influencées par les caractéristiques à forte cardinalité comme peut l'être *q7-std-ext* [Breiman, 2001]. Pour lever ces limitations une nouvelle méthode est mise en place : *Permutation influences* [Breiman, 2002]. Cette méthode consiste à évaluer la performance du modèle lorsque une feature est supprimée. Cette suppression est simulée en mélangeant les valeurs du paramètre considéré de façon aléatoire. Afin d'être statistiquement représentative, cette opération est répétée plusieurs fois, 5 fois dans notre cas. De plus, cette évaluation peut être faite sur le jeu de test, apportant ainsi une information plus riche que MDI quant aux paramètres permettant de généraliser une prédiction. On obtient alors la Figure V.14

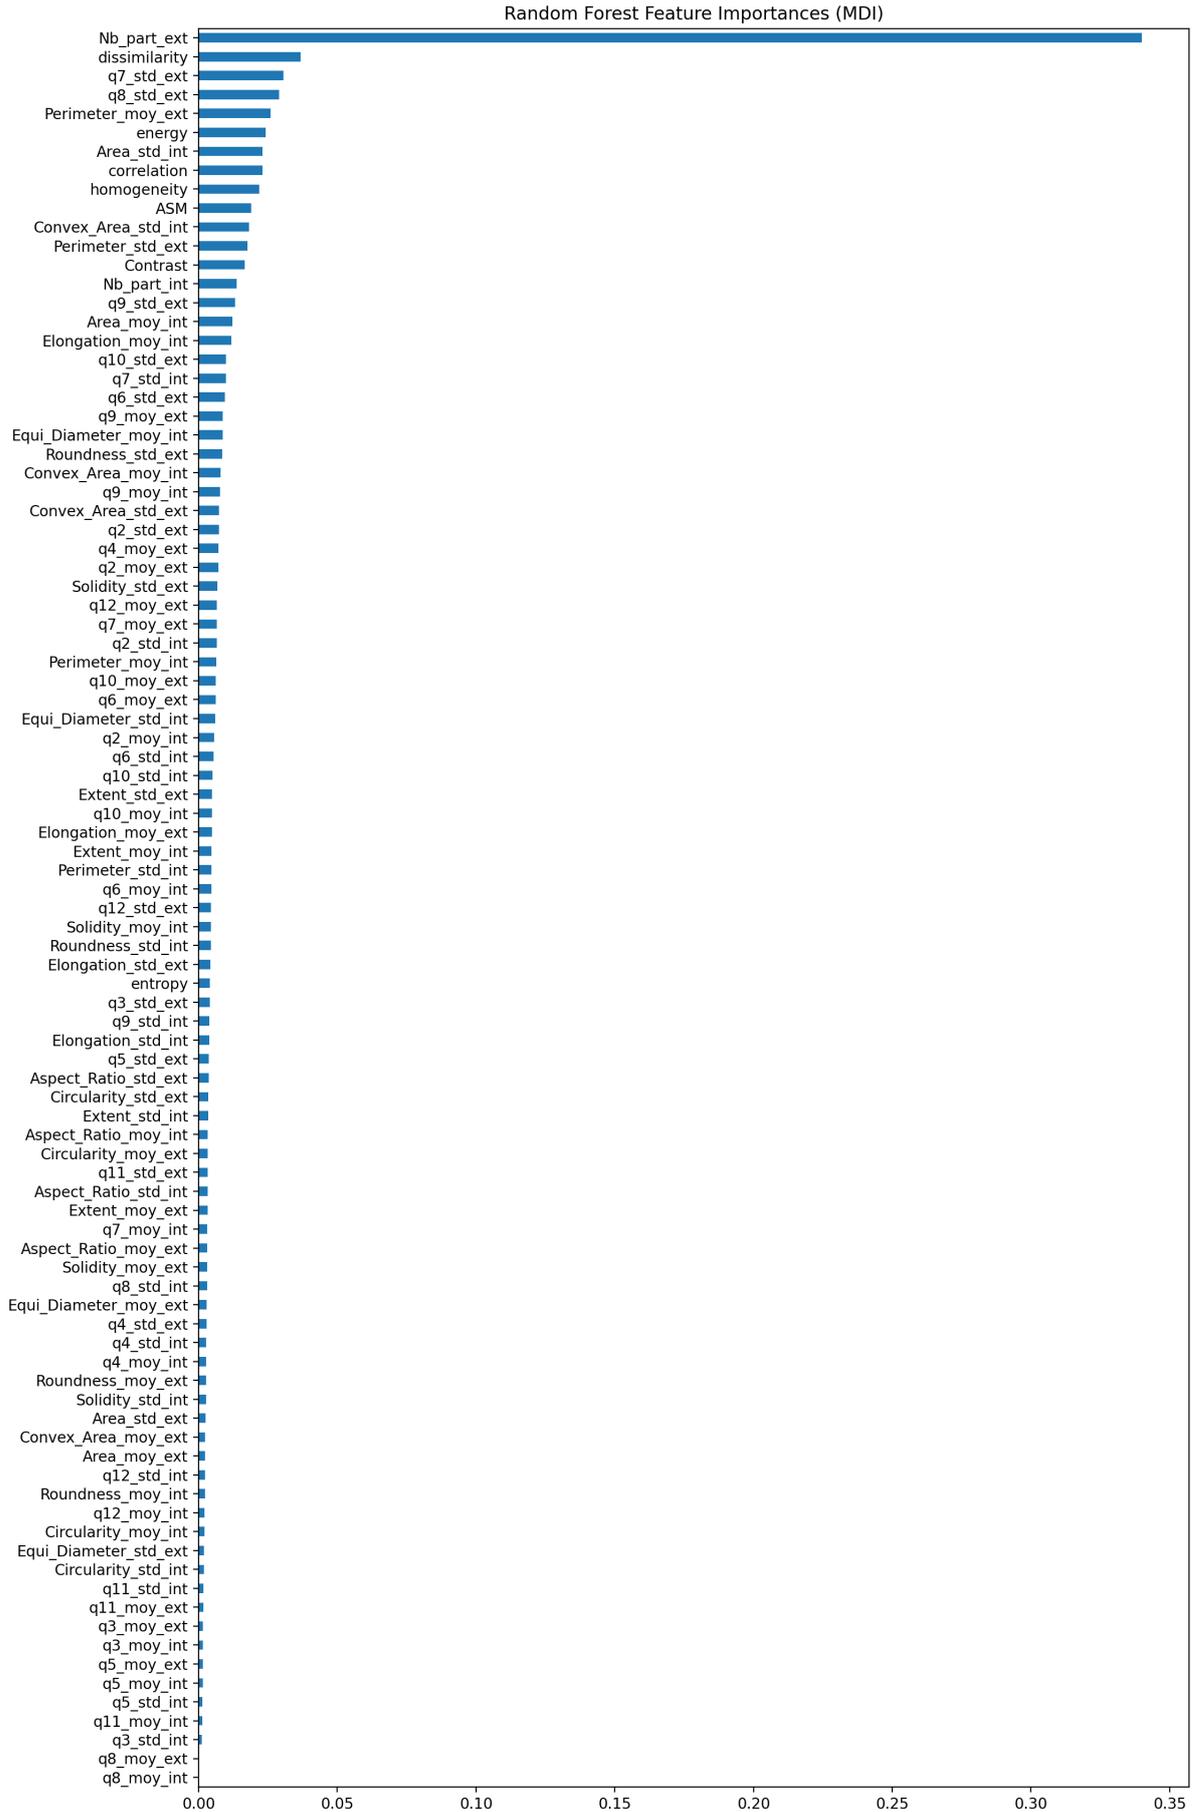


Figure V.13 – Influence des caractéristiques calculée avec la méthode MDI

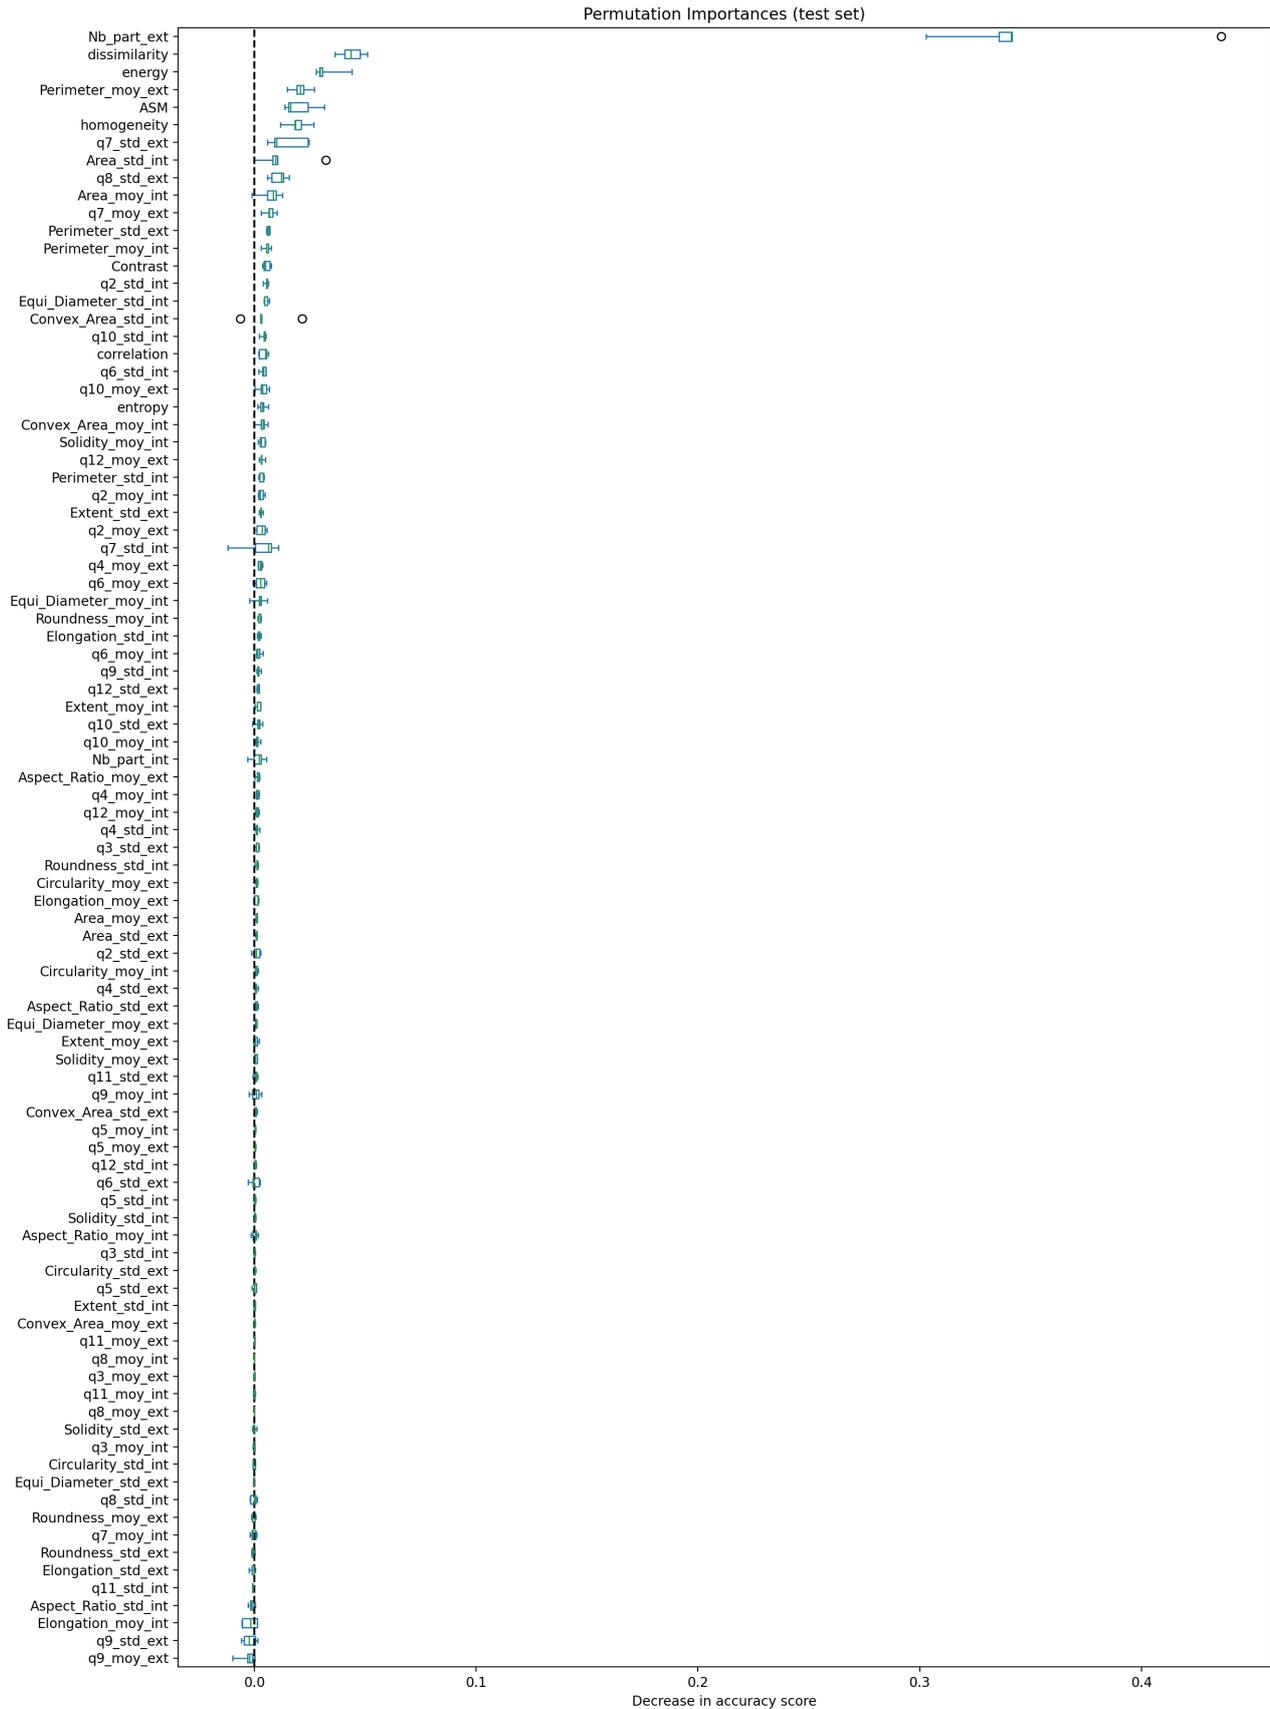


Figure V.14 – Influence par permutation sur le jeu de test de DBmix.

Le paramètre le plus influent reste *nb-part-ext*. L'ordre des autres paramètres a changé mais sans changements profonds : un paramètre jusqu'ici connoté non pertinent par MDI ne devient pas un des plus performants et réciproquement, ce qui aurait témoigné d'un surapprentissage. Ainsi les Figures V.13 et V.14 nous apportent deux informations capitales relatives à la stabilité de notre modèle et à l'importance des caractéristiques lui servant à faire des prédictions.

Ces méthodes ont apporté de l'information quant aux features pertinentes. On sait que *nb-part-ext* et *dissimilarity* sont les plus discriminantes lors du processus de régression, mais il est possible d'aller encore plus loin grâce au SHAP, Shapley Additive exPlanations, développé par Scott M. Lundberg [Lundberg & Lee, 2017b]. Cette méthode va permettre d'évaluer l'influence de chaque feature sur la prédiction comme précédemment. C'est ce que montre la figure V.16, où on retrouve bien *nb-part-ext* en tête ainsi que les features de texture et de forme déjà présentées comme pertinentes. Mais la méthode est légèrement différente : une valeur moyenne de prédiction est calculée, elle se nomme *base-value* ou ϕ_0 , et les indices de SHAP ϕ_i de chaque feature i vont s'ajouter ou se retrancher à cette valeur pour atteindre la prédiction. Les indices de SHAP se calculent de la façon suivante [Lundberg & Lee, 2017b]

$$\sum_{S \subseteq N \setminus \{i\}} \frac{|S|!(M - |S| - 1)!}{M!} (f_x(SU_i) - f_x(S)) \quad (V.2)$$

avec M le nombre de variables, S un ensemble de variable, f_x la fonction de prédiction à l'instant x et i la $i^{\text{ème}}$ variable. Ainsi pour obtenir un prédiction y_{pred} on peut écrire

$$f(x) = y_{pred} = \phi_0 + \sum_{i=1}^M \phi_i z'_i \quad \text{avec} \quad z'_i = \begin{cases} 1 & \text{si variable observée} \\ 0 & \text{sinon} \end{cases} \quad (V.3)$$

Cette approche va donner une indication relative à "l'orientation" de l'influence de chaque caractéristique, Lundberg [Lundberg & Lee, 2017a] illustre ce processus de façon très pédagogique avec la figure V.15.

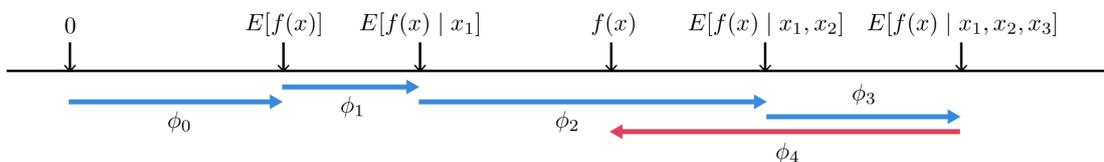


Figure V.15 – Schéma de fonctionnement des indices SHAP par [Lundberg & Lee, 2017a]

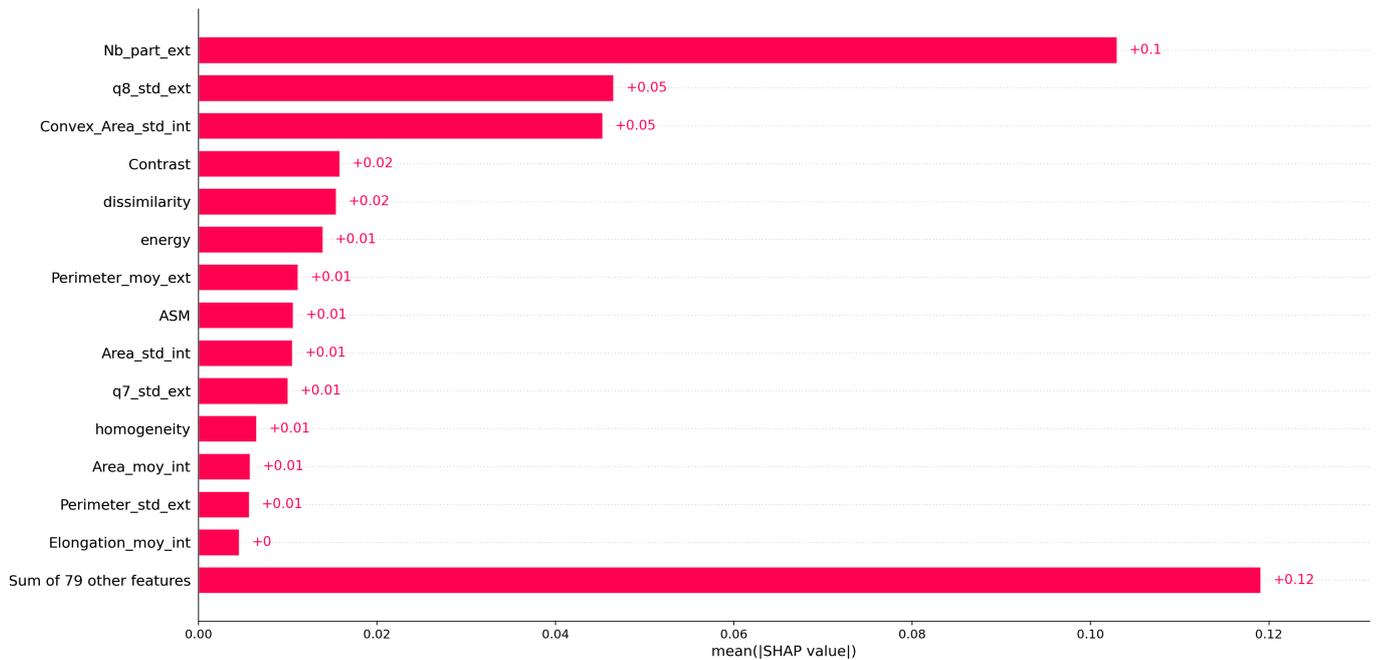


Figure V.16 – Influence globale des features par SHAP

Si on applique cette méthode d'analyse des features à notre problème nous obtenons la Figure V.17 : chaque point correspond à une donnée du jeu de test de *DBmix*, les points roses sont les valeurs élevées de la variable considérée et les bleus ses valeurs faibles. L'épaisseur des zones témoigne de la densité de points. Ainsi on peut voir que plus *nb-part-ext* est élevé plus il aura un impact significatif positif sur la prédiction. D'un point de vue tribologique, les résultats relatifs à *Nb-part-ext* sont cohérents. En effet, il y a une plus forte densité de points à valeurs élevées, correspondant à une forte éjection donc au régime établi, alors que le nombre de valeurs basses est plus petit et va faire baisser la valeur moyenne de la prédiction permettant ainsi de remonter à des COF propre au rodage. En revanche, si on considère *energy*, qui témoigne de la régularité de la texture, ce sont ses valeurs les plus basses qui vont avoir un impact positif, donc les textures les plus irrégulières, alors que ces valeurs élevées auront tendance à faire baisser la *base-value*. Ces observations sont en adéquation avec les observations qualitatives établies précédemment (cf chapitre IV).

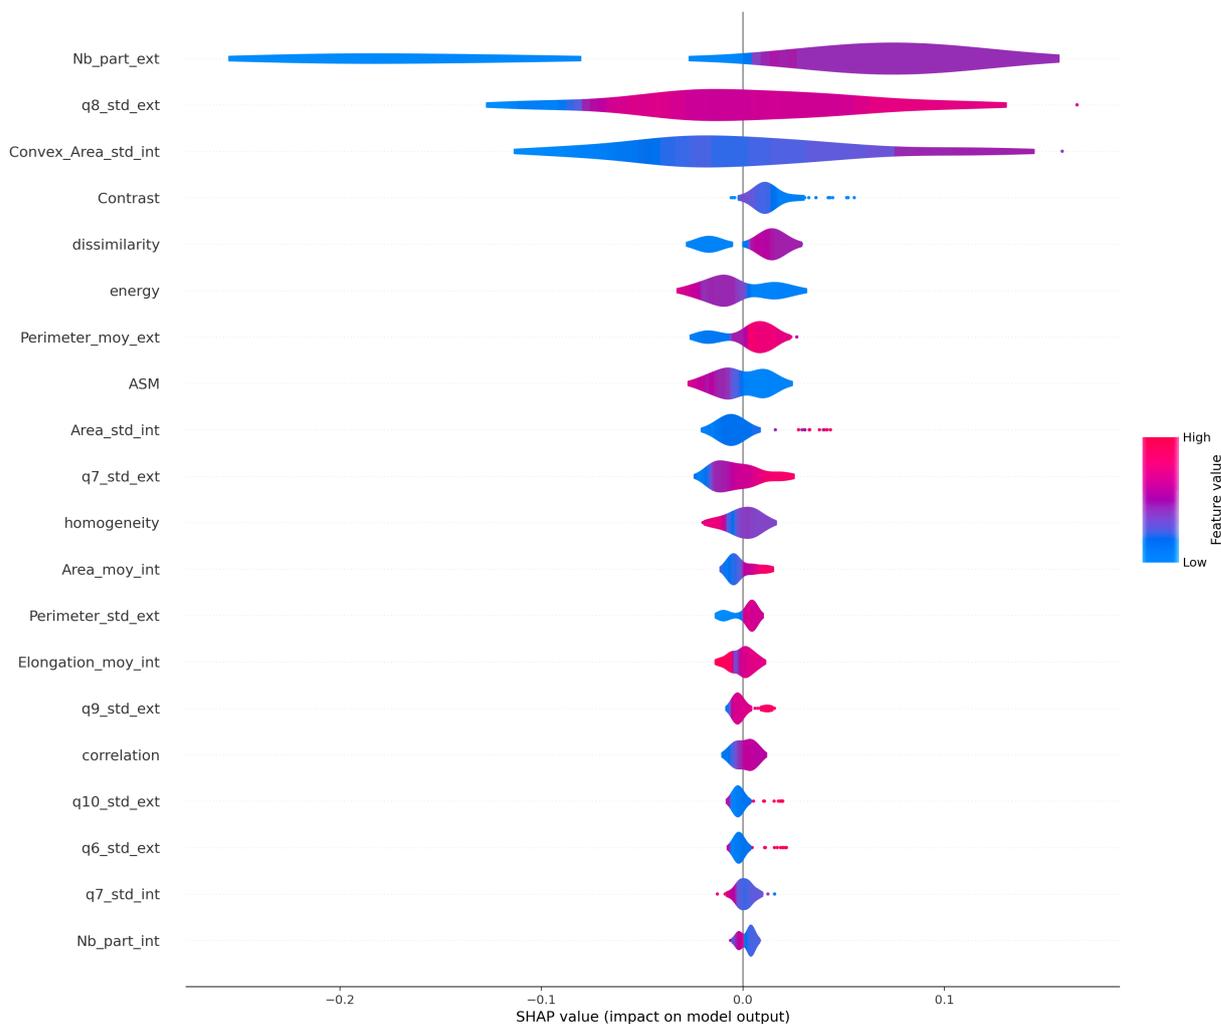


Figure V.17 – Valeurs SHAP des features influents sur la prédiction, calculées sur le jeu de test de *DBmix*

Nous avons donc connaissance de l'évaluation des features, il ne semble pas nécessaire de toutes les conserver pour obtenir une prédiction satisfaisante. Nous nous proposons donc d'en sélectionner un nombre restreint et de créer des bases de données réduites. Puis nous évaluerons la performance de ces nouvelles bases comme précédemment.

3.2 Sélection des features et bases réduites

Il existe deux outils dans la bibliothèque scikit-learn [Pedregosa *et al.*, 2011] pour sélectionner des features pertinentes pour le processus de prédiction : RFE (Recursive Features Elimination) et RFECV (soit RFE with Cross Validation). La différence notable entre les deux est la possibilité de piloter le nombre de caractéristiques à sélectionner dans RFE alors que dans RFECV ce choix est automatique et éprouvé par plusieurs validations successives (Cross Validation). Ces fonctions de sélection s'appuient sur la méthode MDI (Mean Decrease Influence). La méthode de sélection est la suivante :

1. Une forêt est ajustée sur toutes les variables

2. L'importance de chaque variable est évaluée
3. La moins importante est retirée
4. Le processus est rebouclé en ré-entraînant la forêt à chaque itération

L'idée ici va être d'avoir 2 approches, une basée sur la bibliothèque scikit-learn et son RFECV, et l'autre sur une sélection de features manuelle réalisée à partir des méthodes d'évaluation d'influence. Commençons avec le RFECV, suite à l'évaluation par validation croisée, il est possible de sélectionner 6 features :

- *Contrast*,
- *ASM*,
- *correlation*,
- *q6-moy-ext*,
- *q7-std-ext*,
- *Nb-part-ext*.

Les paramètres de texture *dissimilarity* et *energy* jusqu'alors bien classés ont disparu de la liste restreinte, du fait de leur étroite corrélation avec d'autres comme *ASM/energy* et *dissimilarity/contrast* [Maillard, 2003]. Il est très intéressant de noter que cette sélection permet de décrire tant le flux de recirculation (*Contrast*, *ASM*, *correlation*) que le débit d'usure (*q6-moy-ext*, *q7-std-ext*, *nb-part-ext*), ce qui est cohérent avec notre approche initiale de création de base de données. De plus, les caractéristiques propres aux particules d'usure sont des caractéristiques de forme et vont donc être relativement indépendante de l'échelle d'observation, ce qui peut être non négligeable dans une perspective de répétabilité de ces travaux.

La RF est entraînée et dimensionnée sur cette nouvelle base. Sur le jeu de test de *DBmix* les performances sont exprimées dans le Tableau V.6. Le R^2 a augmenté ce qui est synonyme d'une prédiction de meilleure qualité. Bien que *ErrMoy* est plus élevé pour le modèle RFECV le *CVscore* témoigne, par sa diminution, d'une meilleure stabilité, éprouvée sur des découpages aléatoires successifs. Afin de voir comment évolue la prédiction avec une variété de features plus étendue, nous réalisons une sélection de 20 features, représentatives du flux de recirculation et du débit d'éjection. Le nombre de features a été fixé de façon empirique : après plusieurs entraînements et calculs de MDI, en moyenne 20 features ont une influence supérieure à 1%, la sélection est ensuite réalisée à partir des 3 études d'influence en ne conservant que les plus influentes. La liste est donc la suivante :

- *Contrast*,
- *dissimilarity*,
- *homogeneity*,
- *energy*,
- *correlation*,
- *q10-moy-ext*,
- *Aspect-Ratio-std-ext*,
- *Roundness-std-ext*,
- *Solidity-std-ext*,
- *q6-std-ext*,
- *q7-std-ext*,

- *q8-std-ext*,
- *Convex-Area-moy-int*,
- *Equi-Diameter-moy-int*,
- *q2-moy-int*,
- *Convex-Area-std-int*,
- *q2-std-int*,
- *q10-std-int*,
- *Nb-part-ext*,
- *Nb-part-int*.

Une nouvelle forêt est entraînée et dimensionnée sur cette nouvelle base réduite et présente des performances très satisfaisantes (Tableau V.6). Le R^2 a encore augmenté et l'erreur moyenne a diminué : des 3 configurations étudiées c'est la plus basse. L'étude du *CVscore* nous indique que l'erreur est en moyenne plus élevée que pour la base à 6 features mais reste inférieure à celle de la base complète. Simplifier le modèle comme préconisé dans la littérature [Azencott, 2018 ; Géron, 2019], en réduisant le nombre de features, semble améliorer la qualité de la prédiction.

	Base Complète	Base RFECV	Base Manuelle
Nb features	91	6	20
R^2	0.5758	0.6265	0.6615
ErrMoy	0.1382	0.1472	0.1351
CVscore	0.1806±0.048	0.1680±0.068	0.1742±0,056

Tableau V.6 – Performances des forêts aléatoires évaluées sur le Test set des bases réduites.

La question de la généralisation sur les tests supplémentaires (en bleu dans le Tableau IV.3) se pose alors. Les performances de la base complète ainsi que celles des deux nouvelles bases réduites sont proposées dans le Tableau V.7.

A première vue les trois bases se valent, les *CVscore* sont très proches. Au regard de *ErrMoy* et R^2 la base RFECV est la moins performante des trois. On va alors s'intéresser au tracé de la prédiction en fonction de la mesure pour visualiser l'ensemble des prédictions, Figure V.18.

	Base Complète	Base RFECV	Base Manuelle
Nb features	91	6	20
R^2	-2.1070	-3.6423	-1.9984
ErrMoy	0.1438	0.1751	0.1406
CVscore	0.0882±0.037	0.0869±0.027	0.0859±0,031

Tableau V.7 – Performances des forêts aléatoires évaluées sur les tests supplémentaires en bleu dans Tableau IV.3.

Les prédictions ne sont pas identiques, mais restent toutes regroupées dans un même *cluster*. Il n'y a pas de différences flagrantes entre les 3 bases, on ne constate pas d'outlayer

propre a une base. Toutefois, on peut noter que la base issue de la sélection manuelle aura moins tendance à surestimer les valeurs du COF. Ainsi, en considérant cette tendance, ainsi que ses performances, elle apparaît comme la plus pertinente quand il est question de prédire le coefficient de frottement.

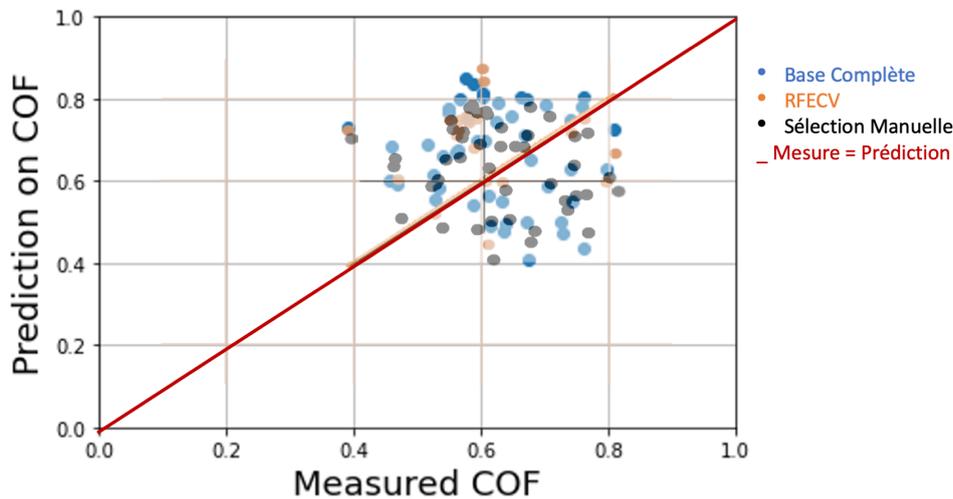


Figure V.18 – Comparaison de la valeur de COF mesurée et prédite établi sur les tests supplémentaires.

On peut regarder l’influence des paramètres sur la prédiction avec les mêmes outils que précédemment. Considérons d’abord les MDI, Figure V.19. Les features apportent toutes une contribution comprise entre 3.5 et 6% lors de l’entraînement, aucune ne ressort comme cela pouvait être le cas sur la base complète. Toutefois la hiérarchie est conservée ; *nb-part-ext* reste la feature la plus influente suivie par des features de texture.

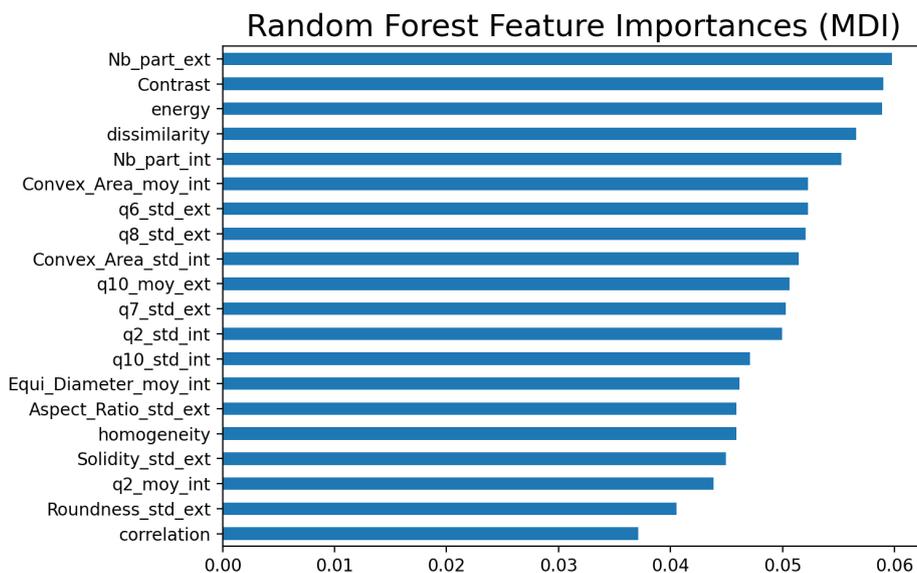


Figure V.19 – Évaluation des features par MDI.

Le calcul de l'influence par permutation présenté en Figure V.20, ne fait pas ressortir de feature engendrant un surapprentissage. La plus influente reste *nb-part-ext*, *contrast* est rétrogradé à la 5^e place à cause de la variabilité de son influence. Son impact moyen la placerait avant *nb-part-int* mais les moustaches de la boîte indiquent que dans de nombreux cas, son influence est moindre. Les indices de SHAP, présentés en Figure V.21 vont apporter des informations complémentaires.

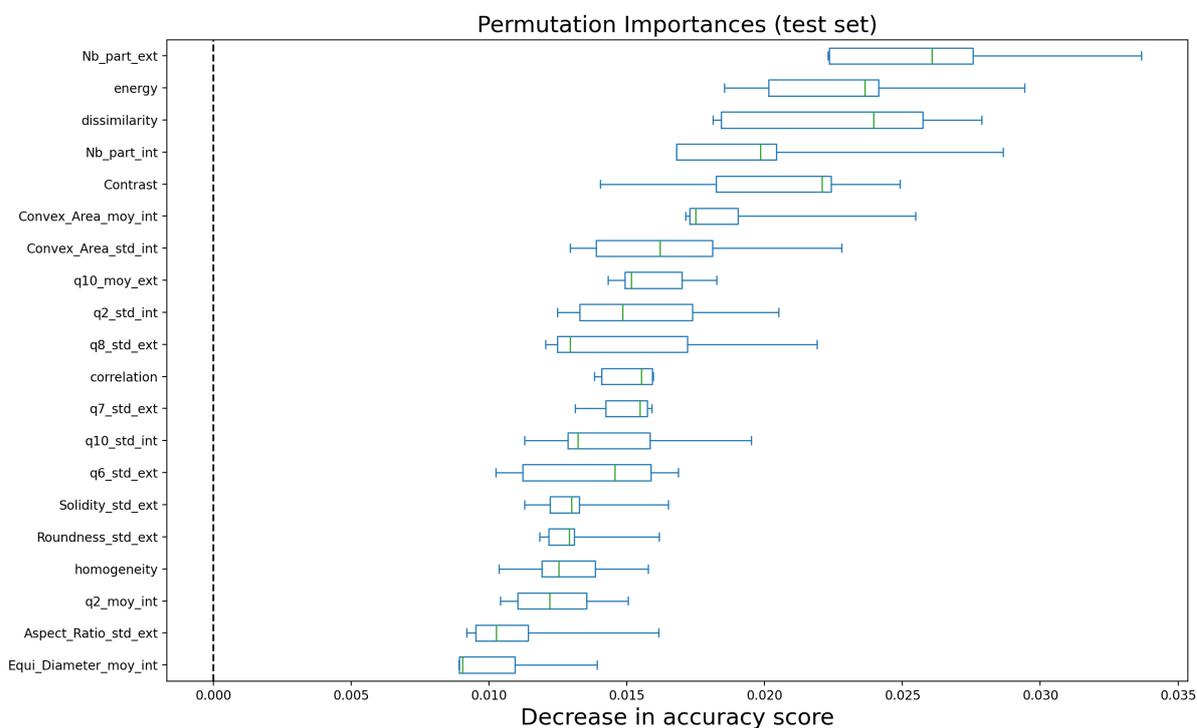


Figure V.20 – Évaluation des features par permutation.

La hiérarchie des indices SHAP et de l'influence par permutation est très similaire. Les neuf caractéristiques présentées comme les plus influentes présentent toutes une forte cardinalité, les valeurs élevées auront un impact positif ou négatif sur la prédiction et réciproquement pour les valeurs faibles. A l'exception de *contrast*, dans ce cas les valeurs faibles semblent avoir un impact positif et négatif sur la prédiction, ce qui peut expliquer sa baisse d'influence lors du passage des MDI au *permutation importances*.

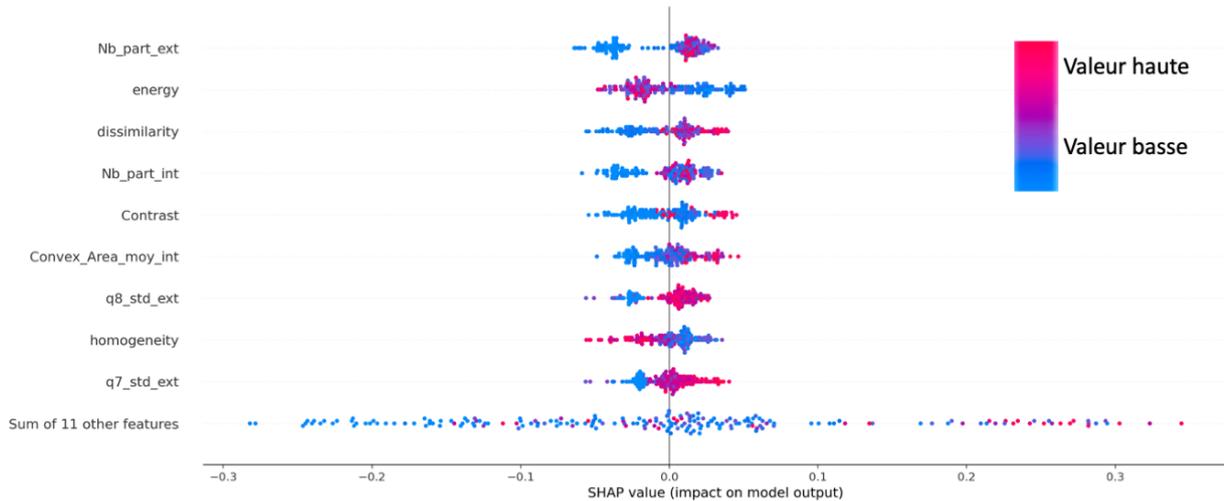


Figure V.21 – *Evaluation des features avec les indices SHAP.*

Malgré ces variations, les études d’influence de features, que ce soit sur la base complète ou les bases réduites, nous apportent une information de premier ordre quant à la localisation de l’information dans le 3e corps. En effet, il s’avère possible de réaliser une prédiction encourageante à partir des informations contenues dans la texture du flux de recirculation (cf. Circuit tribologique, Figure I.8) auxquelles il est nécessaire d’ajouter des informations relatives au débit d’éjection, ou débit d’usure. Il faudra nécessairement une quantification de la matière éjectée, *nb-part-ext*, ainsi que des caractéristiques en lien avec la forme des particules.

4 Conclusion

L’étude morpho-tribo par *machine learning* aura donc permis de montrer qu’il est possible de réaliser des prédictions du COF à partir de données extraites d’images de troisième corps. Mais pour cela, il faut la bonne base de données. La première étape consistant à sélectionner la base pertinente, va dans le sens de l’analyse de sensibilité préalablement effectuée : l’information est contenue en partie dans la texture du troisième corps en centre de la piste. Mais ces descripteurs seuls ne suffisent pas, c’est ce qu’avaient montré les métriques de performance du Tableau V.4 : il faut leur adjoindre des données relatives au débit d’usure. Ce constat a par la suite été corroboré par les études d’influence des features. En effet, la caractéristique majeure intervenant dans le processus de régression est le nombre de particules éjectées en extérieur de piste, suivie par des descripteurs de texture principalement. Il faut donc considérer le circuit tribologique (Figure I.8) dans son ensemble pour remonter au COF : sachant que nous n’avons pas accès aux débits sources et que nous sommes limités par notre accès restreint à l’interface, nous ne pouvons caractériser que le dernier tour.

Malgré ces limitations, les prédictions proposées sont jugées satisfaisantes et ont permis d’accéder à une nouvelle liste de descripteurs venant s’ajouter à ceux présentés au chapitre II. Cela permet donc d’ajouter des outils de caractérisation de l’interface au panel à la

disposition des tribologues, et d'apporter une dimension quantitative aux scénarios de vie du contact pouvant être proposés.

Cette étude permet également de mettre en lumière un autre point, relatif à la reproductibilité. La tentative de généralisation sur les disques de 15mm d'épaisseur s'étant révélée infructueuse, il a fallu créer une nouvelle base de données prenant en compte les différentes géométries à notre disposition.

1 Conclusions

Lors de l'introduction de ce manuscrit nous évoquions la nécessité de contrôler le frottement, mais pour cela il est nécessaire de le comprendre. Un des moyens à notre disposition est d'étudier l'interface de contact et de créer des scénarios pour expliquer l'évolution de cette dernière, scénarios caractérisants le troisième corps de façon qualitative comme il a été présenté au chapitre IV mais soumis à l'expertise, l'appréciation et le vocabulaire de l'observateur. C'est pourquoi l'utilisation de l'analyse d'images en tribologie est un sujet de recherche depuis longtemps II.

Dans la majeure partie des cas, ce type d'études passe par une phase de segmentation, par seuillage notamment, des particules d'usure éjectées du contact. La caractérisation de ces particules apportant des informations sur leur mode d'obtention. Le travail présenté au chapitre IV section 4 permet de gagner en temps et en objectivité lors de cette phase initiale primordiale. En effet, il est possible de segmenter toutes les images issues d'un même test, sous réserve d'entraîner le modèle d'apprentissage automatique avec des particules représentatives. L'autre avantage de cette méthode est que, quel que soit l'état initial de la surface, il est possible d'obtenir une segmentation avec un minimum d'artefacts. Par exemple le process a permis de s'affranchir des stries présentes sur la surface qui "touchent" les particules ; il n'y pas de clusters générés, limitant les erreurs lors de la phase d'extraction des caractéristiques. Notre étude va également s'intéresser au troisième corps non éjecté du contact, nommé flux de recirculation sur le circuit tribologique (Figure I.8). Les images de ce troisième corps sont alors considérées comme des textures sur lesquelles des descripteurs vont être calculés à partir des matrices de co-occurrence.

Les descripteurs ainsi obtenus sont rangés dans des bases de données thématiques afin d'être corrélés au COF. Pour cela deux approches sont proposées dans le chapitre V, une étude préliminaire basée sur l'analyse graphique et les indices de Sobol et une approche basée sur le *machine learning*.

L'étude préliminaire aura permis de visualiser que certains descripteurs entretiennent un lien étroit avec le coefficient de frottement. Toutefois cette étude est bridée par un nombre restreint de caractéristiques sélectionnées et tend à être enrichie, c'est pour cela qu'un modèle de *machine learning* basé sur un algorithme de forêt aléatoire en régression est déployé.

L'utilisation du *machine learning* proposé dans ce travail s'articule autour de deux axes majeurs : la prédiction du coefficient de frottement et l'étude d'influence des descripteurs permettant de réaliser cette prédiction. C'est pour ces raisons que le choix du *machine learning* s'est fait au détriment du *deep learning*, l'explicabilité est au coeur de nos préoccupations.

A l'issue de cette étude nous avons pu conclure qu'en l'état, avec les descripteurs et les données à notre disposition, il est possible de réaliser une prédiction avec une erreur moyenne de 0.14. Cette prédiction s'est avérée généralisable, avec la même qualité, sur de nouvelles données expérimentales. Cela répond donc au premier axe. Pour ce qui est du deuxième, l'évaluation des descripteurs, nous sommes, à l'issue de cette étude, à même de proposer une liste réduite de vingt descripteurs, composée de features propres aux textures, de caractéristiques morphologiques des particules éjectées et de la quantité de ces dernières. Cette base que l'on nomme "base réduite" présente les mêmes performances que la base complète et permet de se concentrer sur la manière dont chaque descripteur influence la prédiction, notamment grâce aux indices SHAP.

2 Perspectives

2.1 Evolution de la base de données

Les bases de données constituées dans le cadre de ce travail ont permis de réaliser des prédictions du coefficient de frottement avec une précision jugée satisfaisante dans le contexte. Dans l'avenir, il pourrait être envisagé de modifier la construction des bases afin d'améliorer les performances du modèle de prédiction. Pour cela nous proposons plusieurs approches :

- Enrichir la liste des descripteurs de texture, avec l'ajout des features utilisées par le code SIMaLea (Segmentation d'Images par *MAchine LEArning*) : les LBP, définis par leurs premiers moments statistiques.
- Ajouter des descripteurs de l'interface non extraits des images, comme la largeur et la profondeur de la trace de frottement, la rugosité locale ou encore les espèces chimiques retrouvées sur l'interface.
- Ajouter des essais réalisés avec des conditions expérimentales différentes : matériaux, vitesses, cinématiques...

Toutes ces possibilités peuvent être mises en place dans le même contexte expérimental que les essais présentés ci-avant, toutefois la littérature met en avant le manque de données et la variabilité induite par la diversité des tribomètres. C'est pourquoi une perspective ambitieuse menée à long terme pourrait être la mise en place d'un protocole à l'échelle d'un laboratoire voir d'une équipe, dans le but d'acquérir une quantité de données signifi-

ficative, toutes produites dans des contextes très variés avec un panel de mécanismes et de matériaux très riche.

2.2 Mesures in situ

Des études ont récemment été menées à l'aide d'un microtribomètre dans un MEB environnemental [Sayilan *et al.*, 2023], permettant une étude qualitative *in situ* du troisième corps lors du rodage. Avec de ce type de banc de test il est possible d'étudier l'évolution des paramètres morphologiques du troisième corps en fonction du nombre de cycles effectués, Figure VI.1.

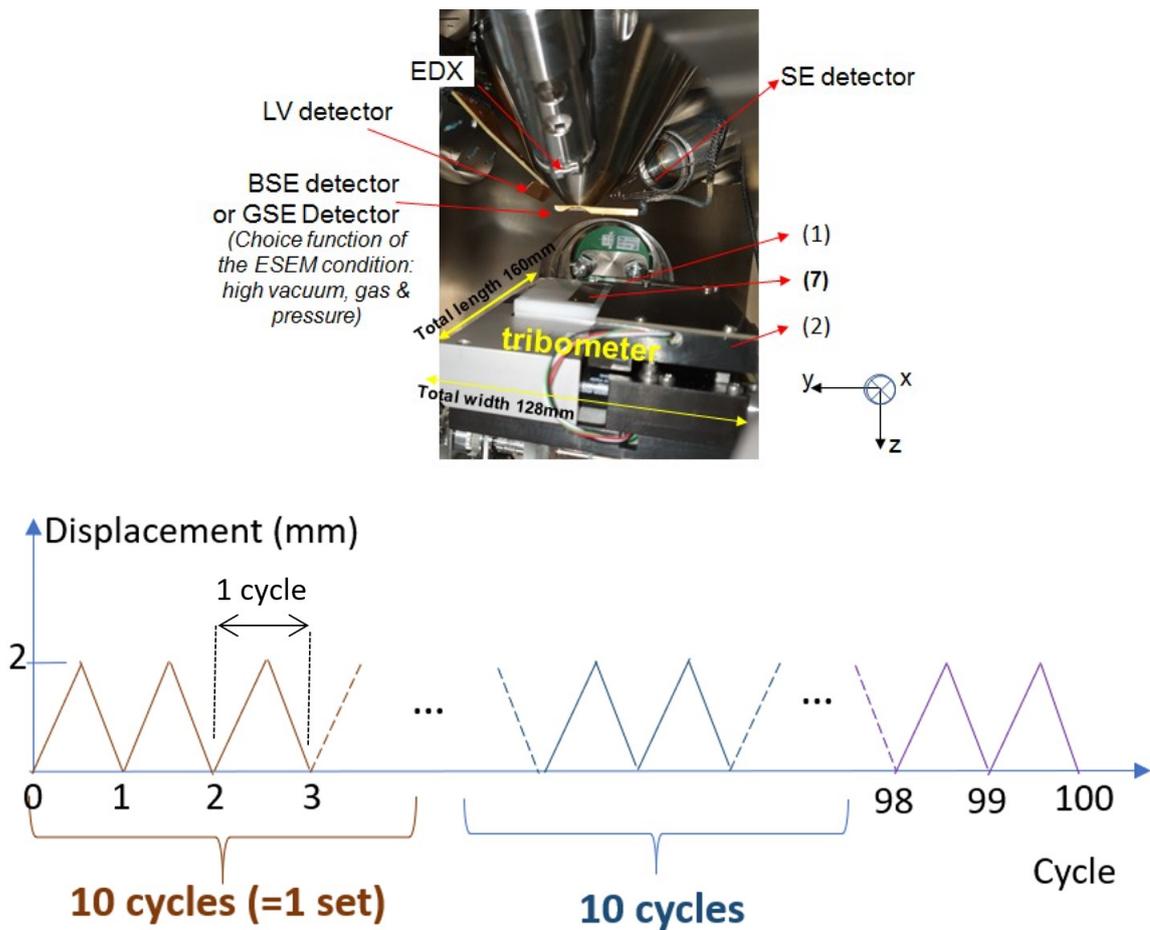


Figure VI.1 – De haut en bas : Présentation du tribomètre dans le MEB, Evolution en cycles du déplacement du bras, d'après [Sayilan *et al.*, 2023]

Une preuve de concept est proposée en Figure VI.2, montrant l'évolution de l'homogénéité (caractéristique de texture) en fonction du nombre de cycles.

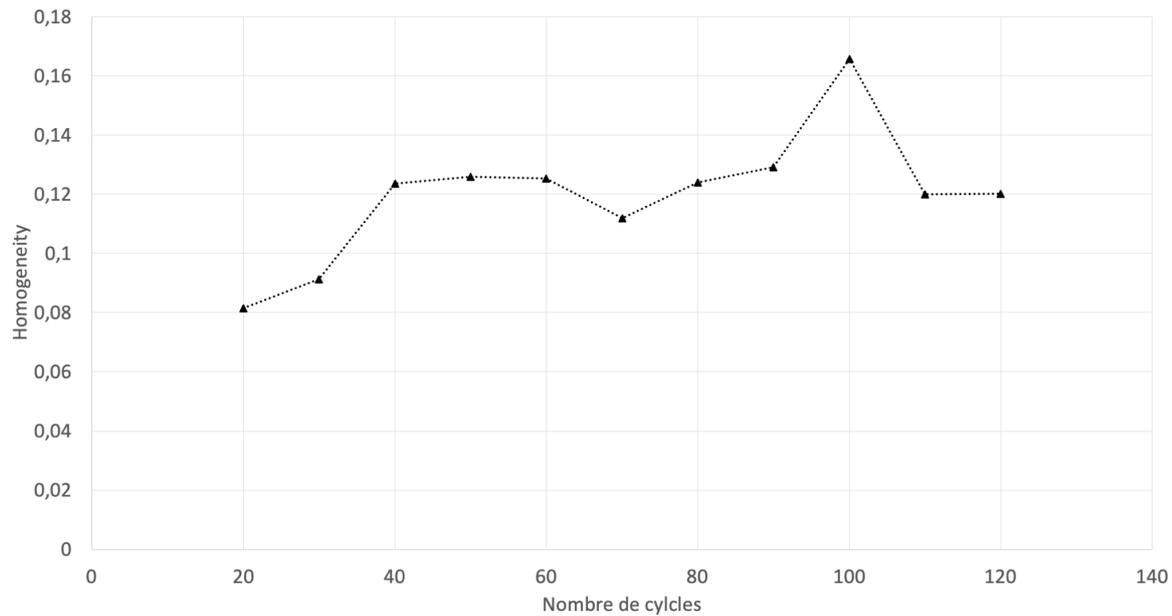


Figure VI.2 – *Évolution de l'homogénéité en fonction du nombre de cycles. (contact acier-acier, P_{max} Hertz initiale = 1GPa)*

Ce tribomètre pourra donc être utilisé dans des études futures, basées sur les mêmes axes que les travaux présentés ici mais ajoutant une dimension temporelle pour évaluer le frottement.

2.3 Tentatives de corrélation avec les simulations numériques

De nombreuses simulations numériques sont menées à l'aide d'éléments discrets, afin de comprendre le comportement des flux de matière dans le contact à l'échelle microscopique.

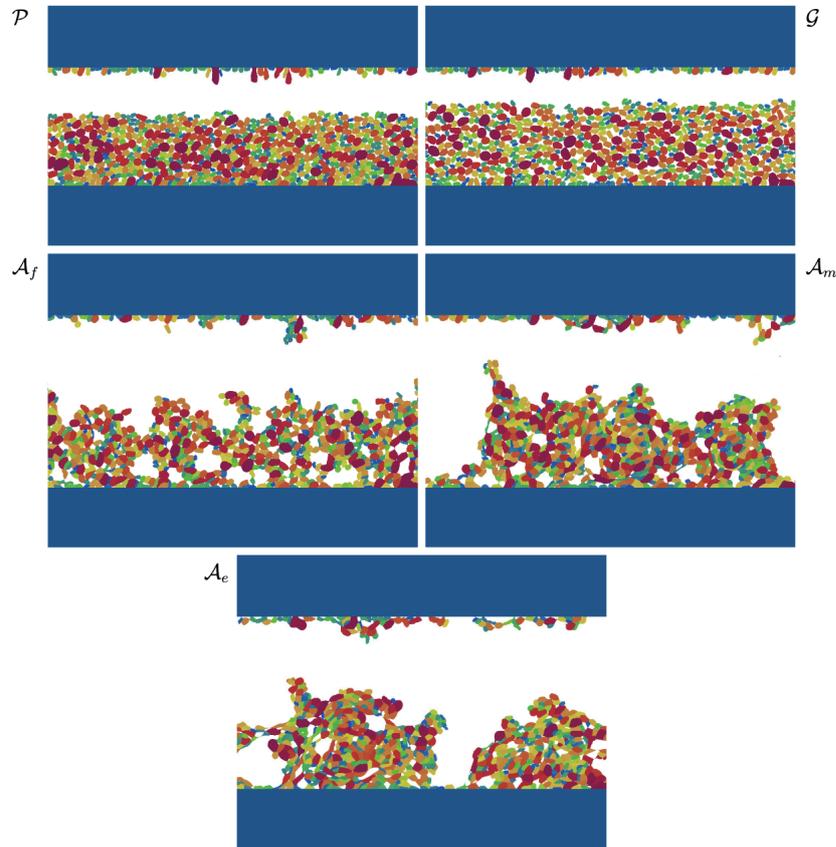


Figure VI.3 – Vue des simulations avec 700 particules lors de l'ouverture du contact. De haut en bas et de gauche à droite : régime plastique P , granulaire G , aggloméré A_f (cohésion faible), aggloméré A_m (cohésion moyenne), aggloméré A_e (cohésion élevée)[Bouillanne et al., 2022]

A l'issue de ces simulations il est alors possible "d'ouvrir" le contact et de réaliser une image de l'interface frottante, comme présenté en Figure VI.3. Il s'agirait d'un observable relativement similaire aux images MEB proposées dans ce travail de thèse. Ainsi il pourrait être envisagé d'utiliser des algorithmes de *machine learning* pour créer du dialogue entre le numérique et l'expérimental et donc enrichir nos connaissances du frottement.

2.4 Changement d'approche ?

On peut également aborder une perspective basée sur un changement d'approche du problème. De récentes études en tribologie [Butt et al., 2023 ; Sieberg & Hanke, 2023] s'orientent vers le *deep learning* et les réseaux de neurones convolutifs pour classer les particules d'usure en fonction de leur mécanisme de production. A l'instar de l'évolution des techniques d'étude des mécanismes d'usure (utilisation des machines d'inférence, puis du *machine learning* et enfin du *deep learning*) nous pourrions envisager d'utiliser également les réseaux de convolution. Toutefois cette utilisation devra être accompagnée de

nombreux tests préliminaires visant à trouver la bonne échelle d'étude. En effet, l'objet d'entrée de tel réseau est une image, or nous avons prouvé au travers de nos travaux de thèse que les caractéristiques morphologiques du troisième corps permettant de remonter au frottement sont propres aux flux d'usure **et** de recirculation. Ils sont donc indissociables et devront potentiellement apparaître ensemble à l'image.

Tenseur de contraintes Commençons par poser quelques notions et notations propres à la mécanique du solide [Takadoum, 2007]. Soit un solide soumis à une sollicitation $d\vec{F}$ au point P.

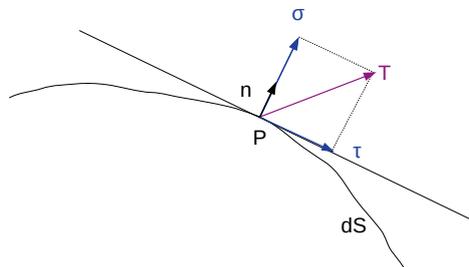


Figure A.1 – *Élément de surface au point P*

On notera un élément de surface dS de normale \vec{n} .

$$\begin{aligned} d\vec{F} &= \vec{T} dS \\ \vec{T} &= \vec{\sigma} + \vec{\tau} \end{aligned} \quad (\text{A.1})$$

\vec{T} est le vecteur contrainte, où σ est la composante normale du vecteur de contraintes et τ la composante tangentielle ou de cisaillement.

— On note le tenseur des contraintes au point P $\bar{\bar{\sigma}}$:

$$\bar{\bar{\sigma}}(P) = \begin{pmatrix} \sigma_{xx} & \sigma_{xy} & \sigma_{xz} \\ \sigma_{yx} & \sigma_{yy} & \sigma_{yz} \\ \sigma_{zx} & \sigma_{zy} & \sigma_{zz} \end{pmatrix} \quad (\text{A.2})$$

Pour les matériaux isotropes $\sigma_{ij} = \sigma_{ji}$

- Diagonalisation du tenseur des contraintes : les contraintes principales sont exprimées dans un nouveau repère orthonormé, dont les vecteurs constituant la base sont les directions principales. Le tenseur des contraintes principales se note :

$$\bar{\bar{\sigma}} = \begin{pmatrix} \sigma_I & 0 & 0 \\ 0 & \sigma_{II} & 0 \\ 0 & 0 & \sigma_{III} \end{pmatrix} \quad (\text{A.3})$$

- Décomposition du tenseur des contraintes :

$$\begin{pmatrix} \sigma_I & 0 & 0 \\ 0 & \sigma_{II} & 0 \\ 0 & 0 & \sigma_{III} \end{pmatrix} = \begin{pmatrix} \sigma_m & 0 & 0 \\ 0 & \sigma_m & 0 \\ 0 & 0 & \sigma_m \end{pmatrix} + \begin{pmatrix} \sigma_I - \sigma_m & 0 & 0 \\ 0 & \sigma_{II} - \sigma_m & 0 \\ 0 & 0 & \sigma_{III} - \sigma_m \end{pmatrix} \quad (\text{A.4})$$

Le tenseur en bleu est la partie sphérique du tenseur des contraintes principales représentant la pression hydrostatique, le tenseur en vert est appelé tenseur déviateur ou composante de cisaillement.

Critère de plasticité En général ce critère s'exprime comme $f(\sigma_{ij}) = 0$, lorsque cette condition est vérifiée le matériau se déforme plastiquement. Avec les contraintes principales on écrit $f'(\sigma_I, \sigma_{II}, \sigma_{III}) = 0$. Avec $\sigma_I \geq \sigma_{II} \geq \sigma_{III}$.

Il existe plusieurs critères de plasticité mais nous en citerons deux (les plus rencontrés dans la littérature) :

- Critère de Tresca [Tresca, 1864] ou critère de scission maximale. La plastification se produit lorsque le cisaillement maximum atteint un seuil.

$$\tau_{max} = \frac{\sigma_I - \sigma_{III}}{2} \geq k$$

avec k la contrainte limite d'écoulement en cisaillement que l'on peut écrire $k = \frac{Y}{2}$ avec Y la contrainte d'écoulement obtenue à partir d'essais en traction.

- Critère de Von-Mises [Mises, 1913] : Il y a déformation plastique lorsque l'énergie élastique de distorsion emmagasinée atteint une valeur critique.

$$(\sigma_I - \sigma_{II})^2 + (\sigma_{II} - \sigma_{III})^2 + (\sigma_{III} - \sigma_I)^2 = 2Y^2 = 6k^2$$

ANNEXE B

ANALYSE DES PARAMÈTRES D'ACQUISITION EN MICROSCOPIE

Pour acquérir les images en MEB, plusieurs paramètres d'acquisition sont à gérer : la vitesse de balayage, le contraste/brillance, la tension d'accélération ainsi que la résolution en pixels. Certains paramètres tel que le grandissement, le format de l'image ainsi que la résolution ont été fixé dès le début dans un soucis d'optimisation de temps d'acquisition et de capacité de stockage. En tout 1008 images ont été acquises sur les disques.

1 Influence de la vitesse de balayage

Afin de d'évaluer l'influence de la vitesse de balayage, plusieurs images d'une même région (texture et particules) ont été prises. La Figure B.1 montre l'évolution des paramètres morphologiques du troisième corps en fonction de la vitesse de balayage.

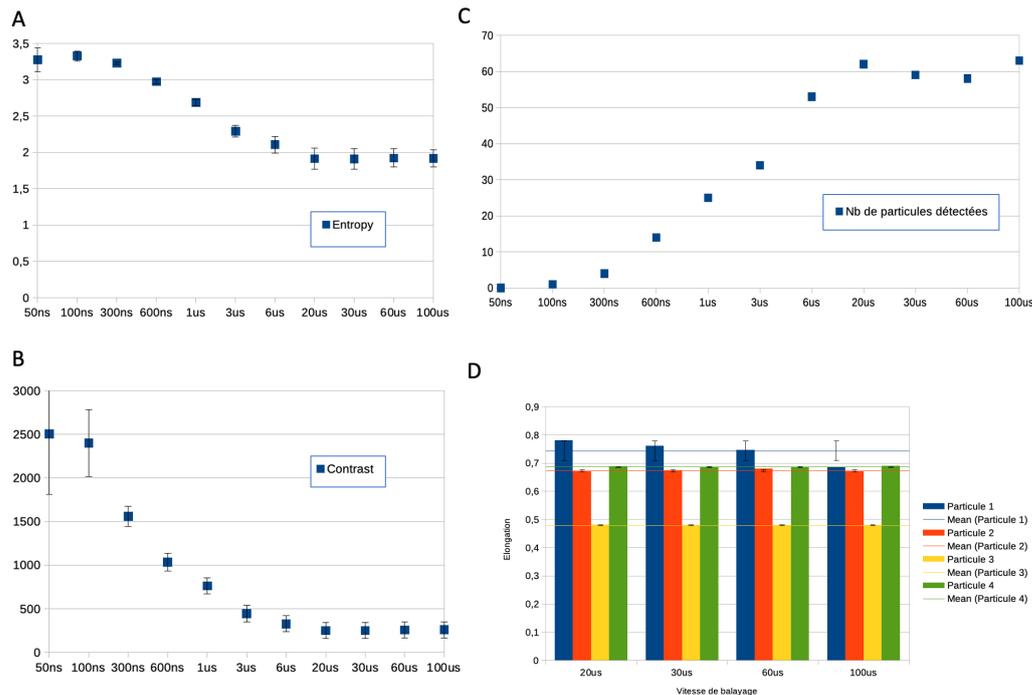


Figure B.1 – Influence de la vitesse de balayage sur l'extraction des données morphologiques du troisième corps. A) Entropy (texture). B) Contrast (texture). C) Nombre de particules éjectées. D) Elongation de 4 particules.

Les paramètres de texture (A et B sur la Figure) vont se stabiliser à partir d'une vitesse de $20\mu s/ligne$, la même tendance est observée sur le dénombrement des particules éjectées (C). Afin d'évaluer l'impact de cette vitesse de balayage sur les paramètres de forme des particules, quatre particules ont été sélectionnées dans les images. L'élongation mesurée sur ces particules pour chaque vitesse du plateau (Figure B.1 C) est présentée en (D). On constate donc que cette dernière n'évolue pas pour trois des quatre particules sélectionnées.

Ainsi les images MEB proposées dans ce travail seront toutes réalisées avec une vitesse de balayage de $20\mu s/ligne$, vitesse minimum permettant d'acquérir un maximum d'information sans perte.

2 Influence du contraste et de la brillance

Surexposer ou sous exposer les images induit une perte d'information. La Figure B.2 propose une mesure relative de la perte d'information lors du calcul des caractéristiques de taille de particules. Une image surexposée pourra donc entraîner une erreur pouvant aller jusqu'à 8% sur certaines caractéristiques comme le périmètre.

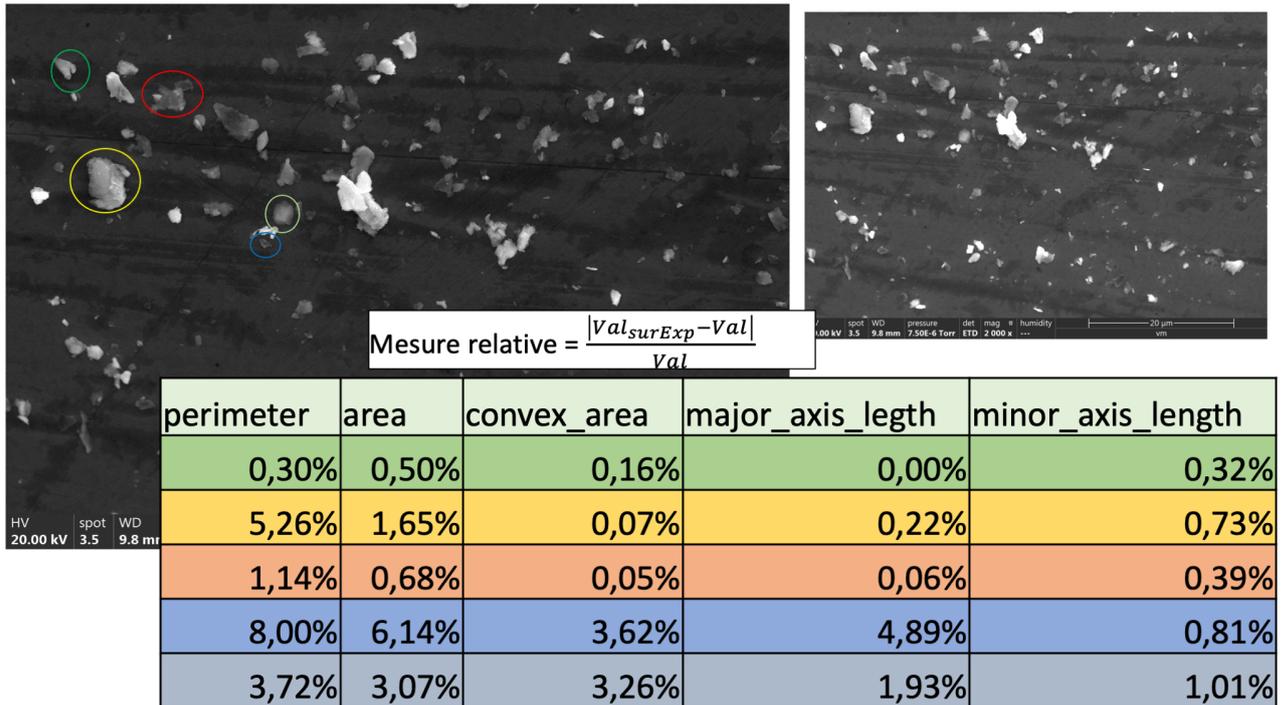
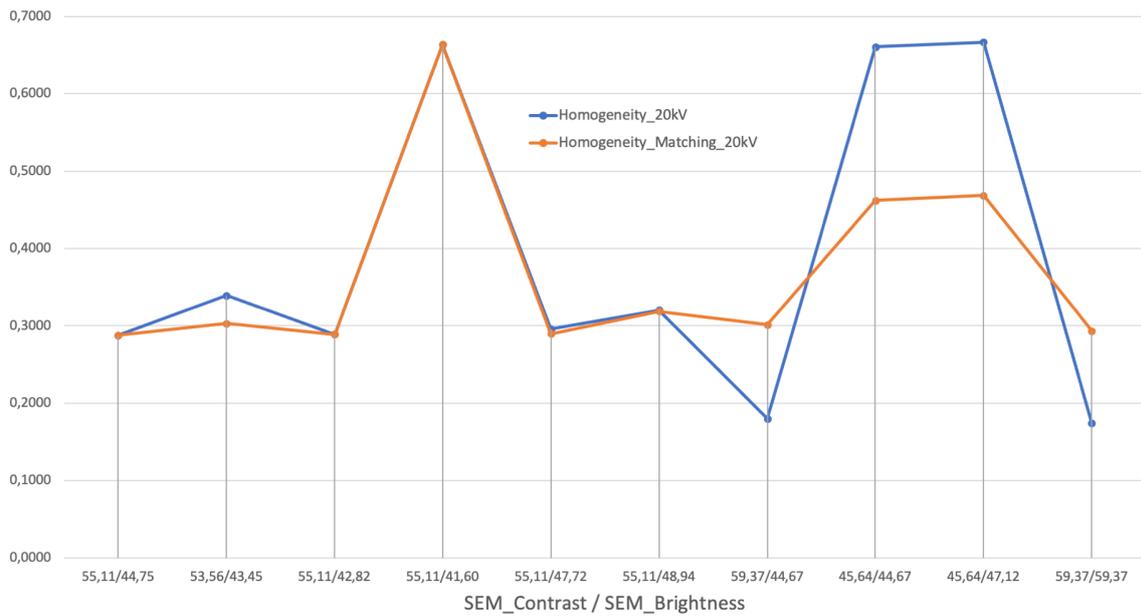


Figure B.2 – *Caption*

La Figure B.3 se concentre sur un paramètre de texture, l'homogénéité. Lors de ce test plusieurs images d'une même texture ont été prise pour différentes valeurs du couple *Contrast/Brightness*, allant d'une augmentation ou diminution modérée à une surexposition ou sous exposition de l'image. La courbe bleue est la mesure "brute" de l'homogénéité et la courbe orange est une mesure réalisée sur des images ayant subit une modification d'histogramme par matching. On constate que cette modification tend à lisser les valeurs de l'homogénéité pour les variations modérées, mais ne peut pas reconstituer l'information perdue. Ainsi il faudra fixer une valeur moyenne pour chaque paramètres et la conserver pour chaque tests pour rester le plus consistant possible. Dans notre cas nous avons le couple *Contrast/Brightness* = $\sim 46 / \sim 46$.

Figure B.3 – *Caption*

3 Influence de la tension d'accélération

L'influence du voltage s'évalue pour les paramètres de texture. A notre échelle d'étude nous avons besoin de régler le MEB avec un voltage de 20kV, mais nous nous proposons de quantifier les écarts sur les descripteurs de texture que peuvent engendrer deux voltages (2kV et 20kV) pour 2 images de texture présentés en Figure B.4. L'écart relatif entre les paramètres de texture mesurés pour 2kV et 20kV sur les images 1 et 2 sont donnés au Tableau B.1. Ainsi on observe que quatre des sept descripteurs de texture présente un écart inférieur à 10%, ils sont pas perturbés par le changement de voltage. Alors que es paramètre traitant de l'homogénéité et de la régularité de la texture vont être fortement influencés par le voltage, on note 42.75% d'écart pour l'ASM.

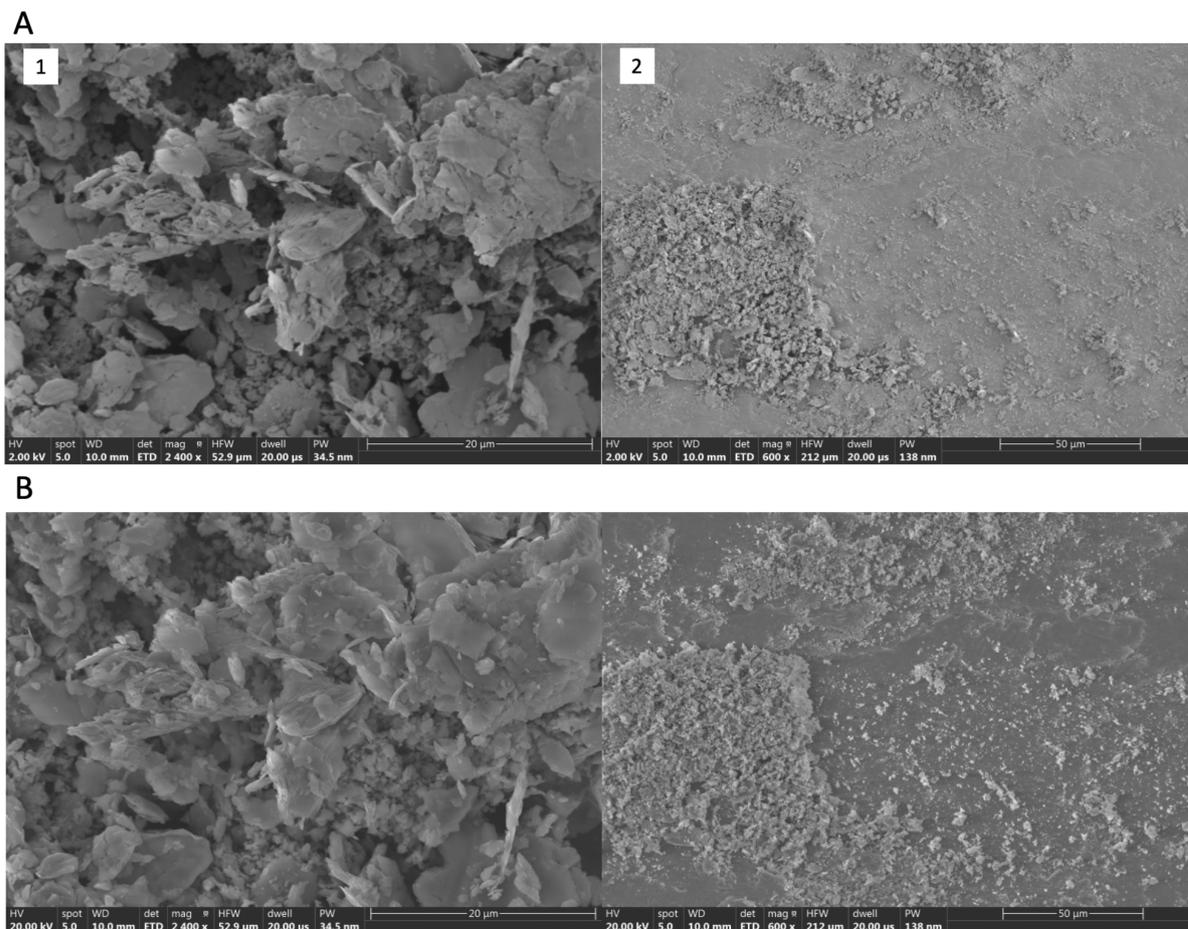


Figure B.4 – Images de texture de troisième corps pour différents voltages : A) 2kV B) 20kV.

	Image 1	Image 2
Contrast	2.28	4.17
Dissimilarity	7.81	4.24
Homogeneity	10.18	26.40
ASM	38.73	42.75
Energy	21.78	24.23
Correlation	2.04	4.58
Entropy	2.00	3.20

Tableau B.1 – Mesure de l'écart relatif entre les paramètres de texture calculés pour 2kV et 20kV sur les images présentée en Figure B.4

Ces écarts sont à considérer pour rester consistant lors des travaux d'investigation, notamment lors de l'utilisation du *machine learning* au chapitre V.

ANNEXE C

PHOTOS DES DISQUES



Figure C.1 – *Photo du disque 10*



Figure C.2 – *Photo du disque 11*



Figure C.3 – *Photo du disque 12*

ANNEXE D

CARTES DE FROTTEMENT

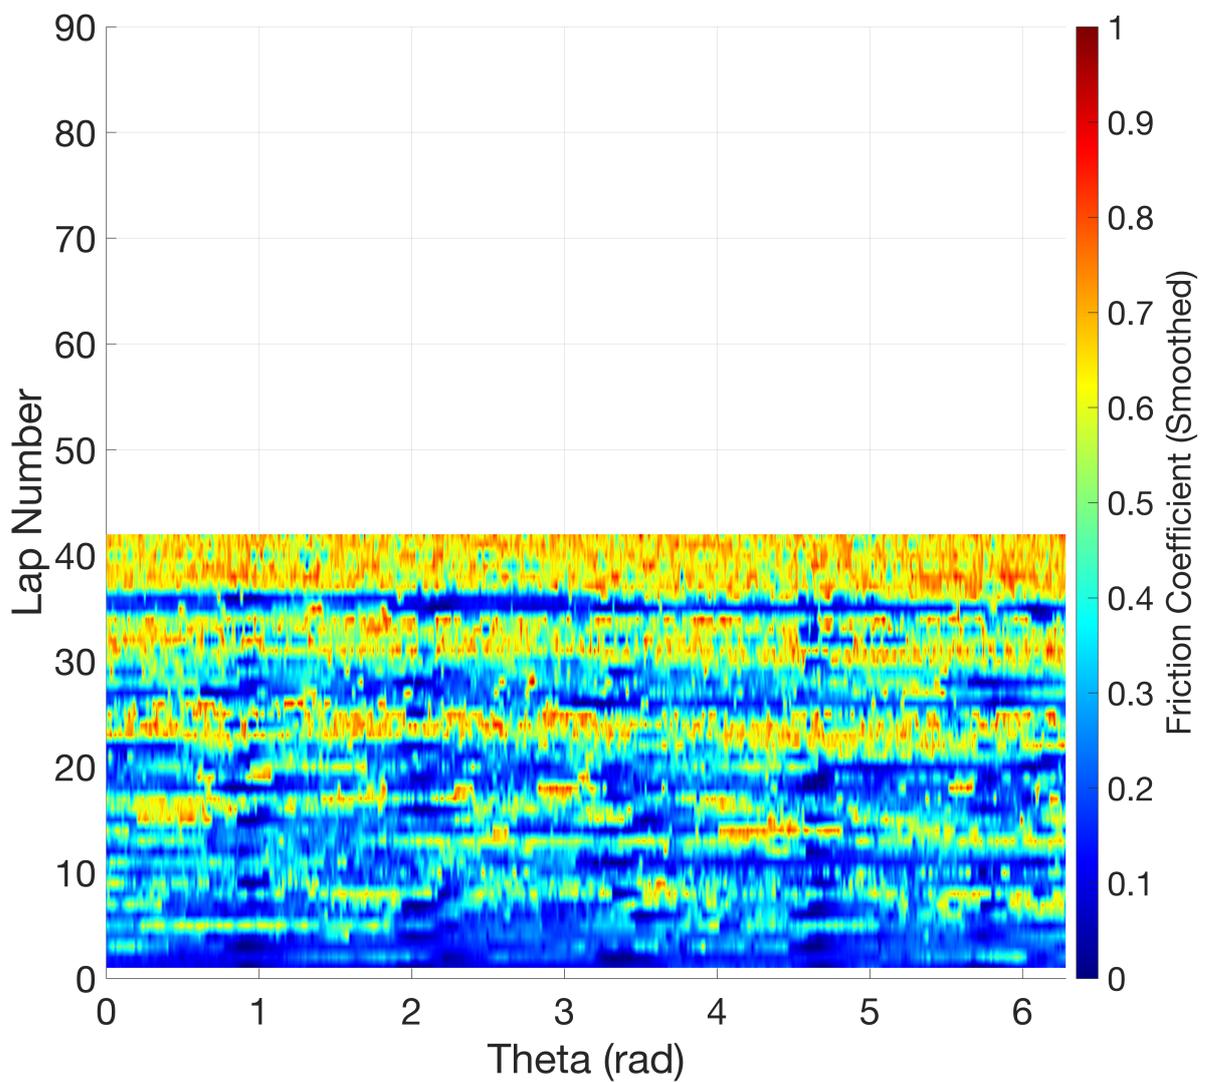


Figure D.1 – Test : D10P20 - Argon - 12m

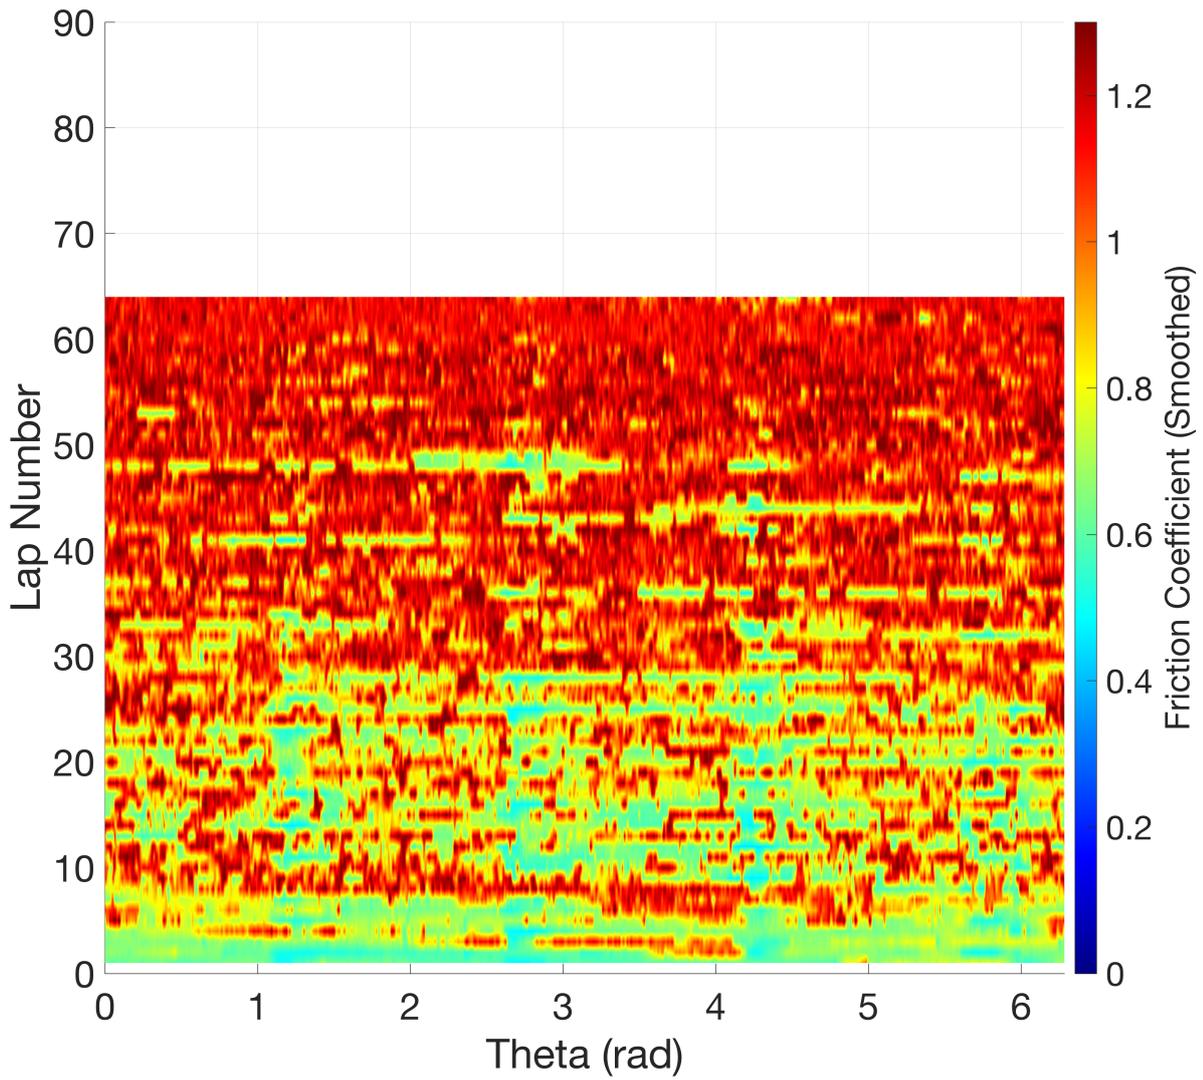


Figure D.2 – *Test : D10P21 - Argon - 18m*

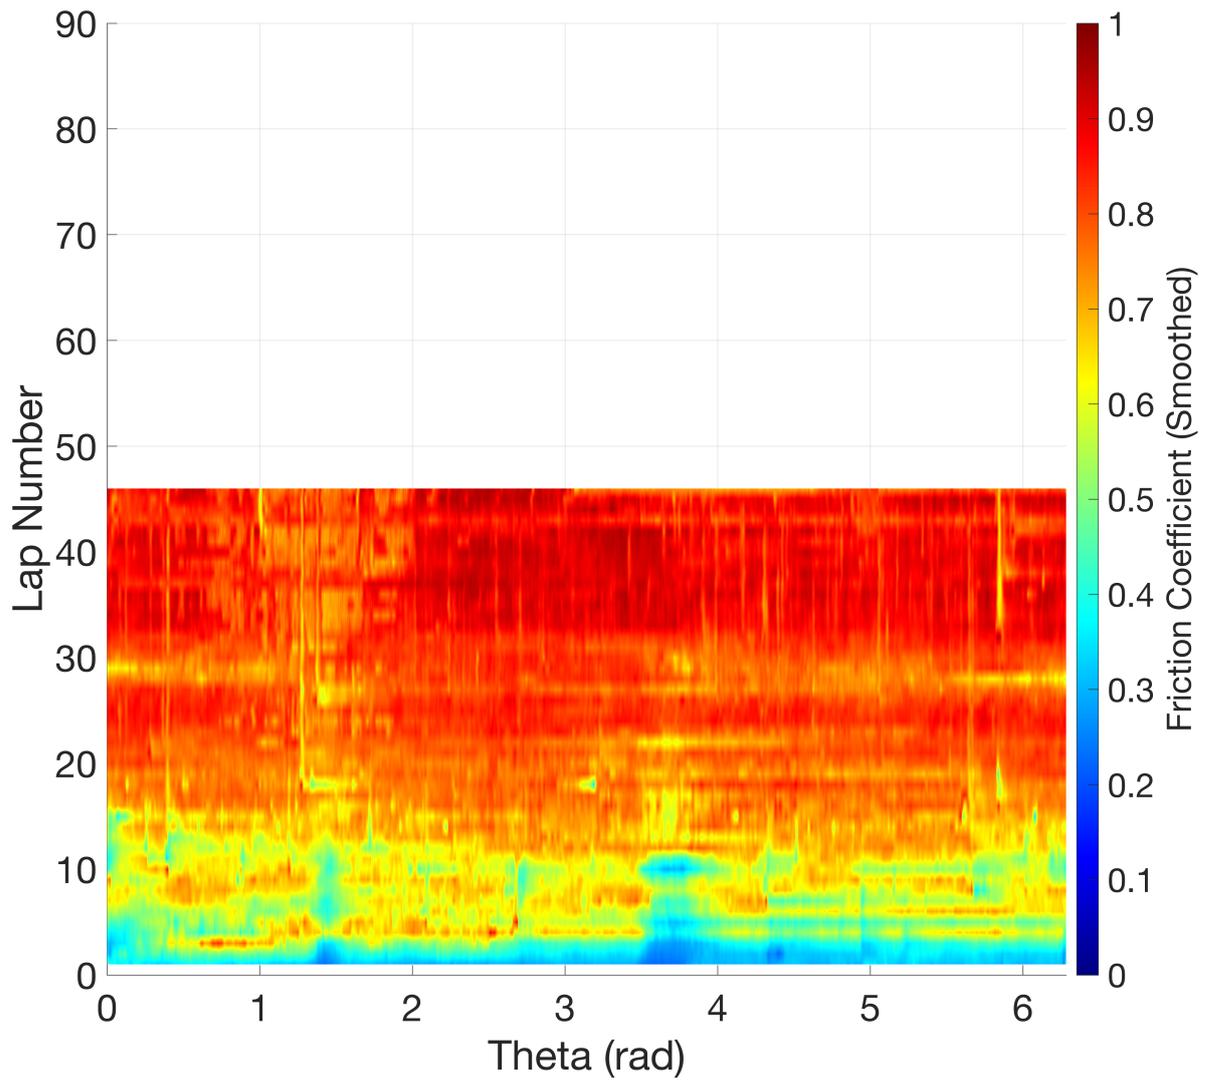


Figure D.3 – *Test : D10P22 - Atm libre - 12m*

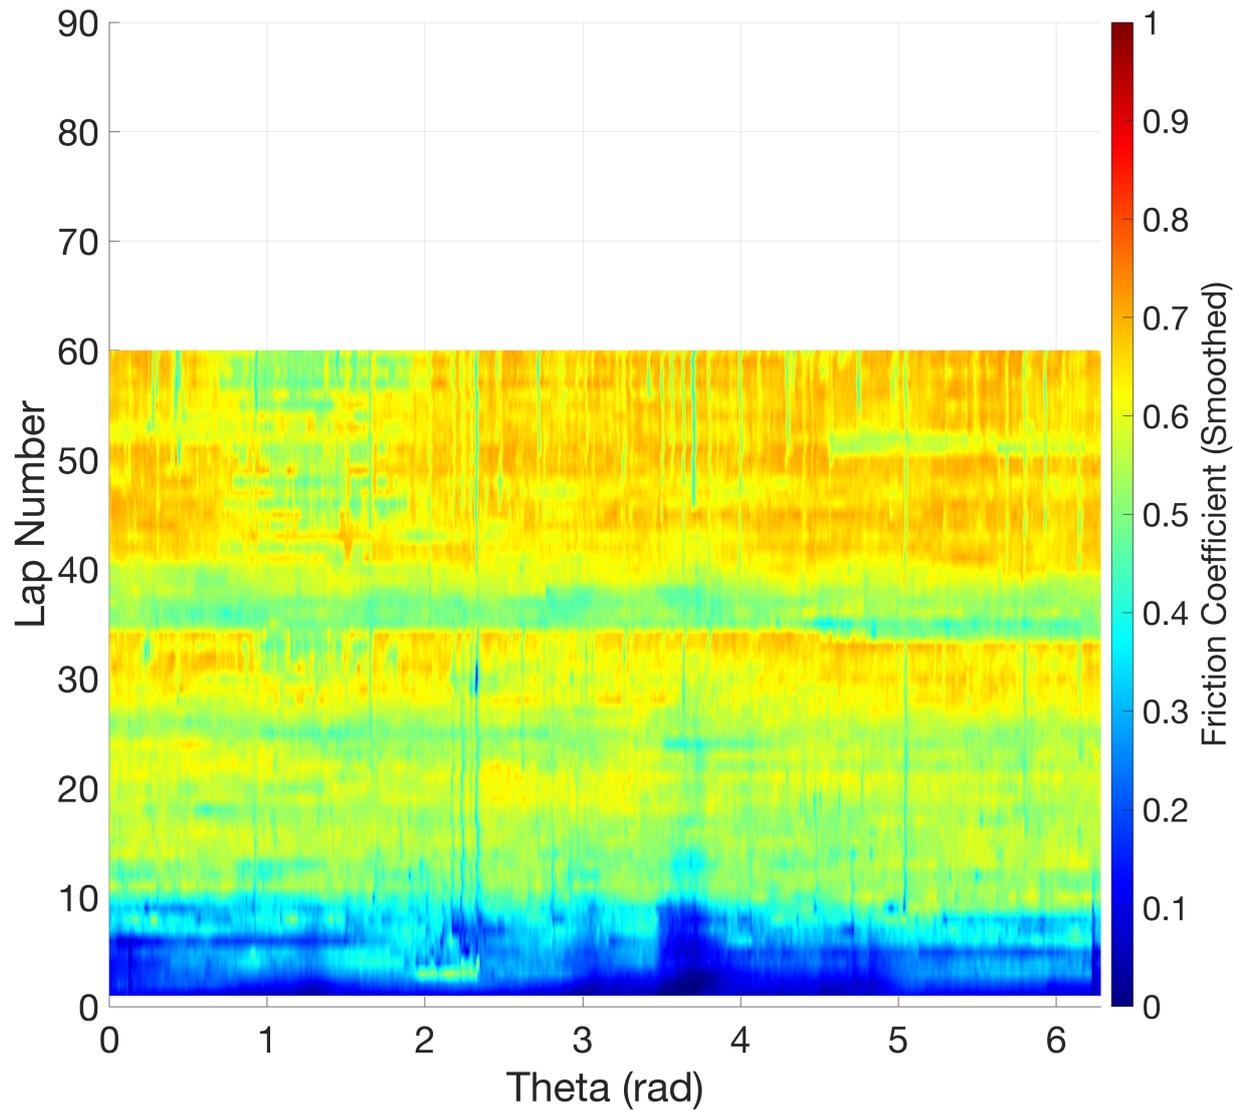


Figure D.4 – Test : D10P23 - Atm libre - 18m

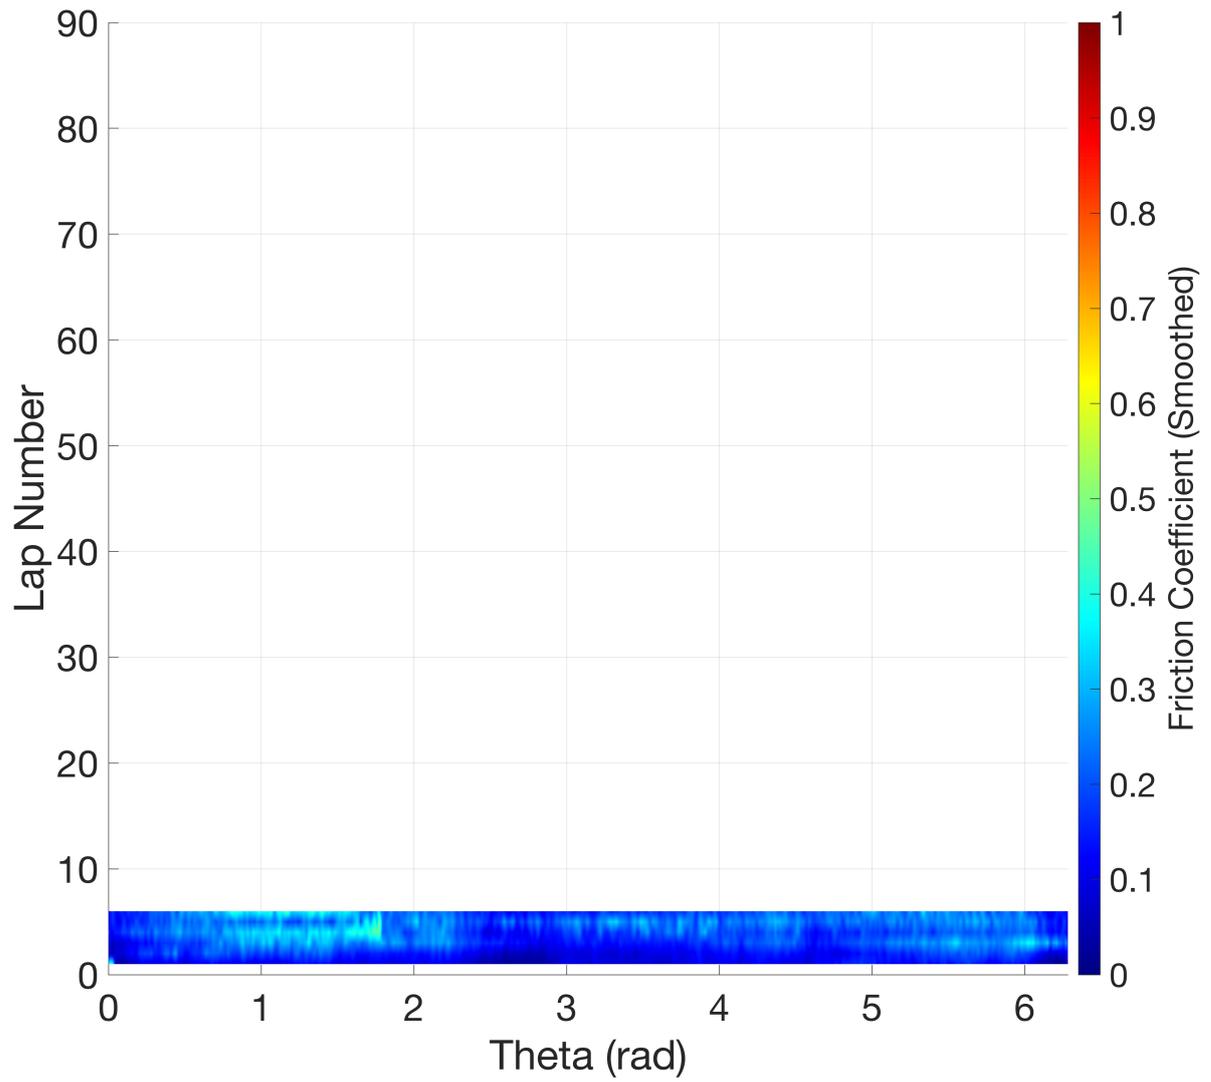


Figure D.5 – Test : D11P24 - Atm libre - 1m

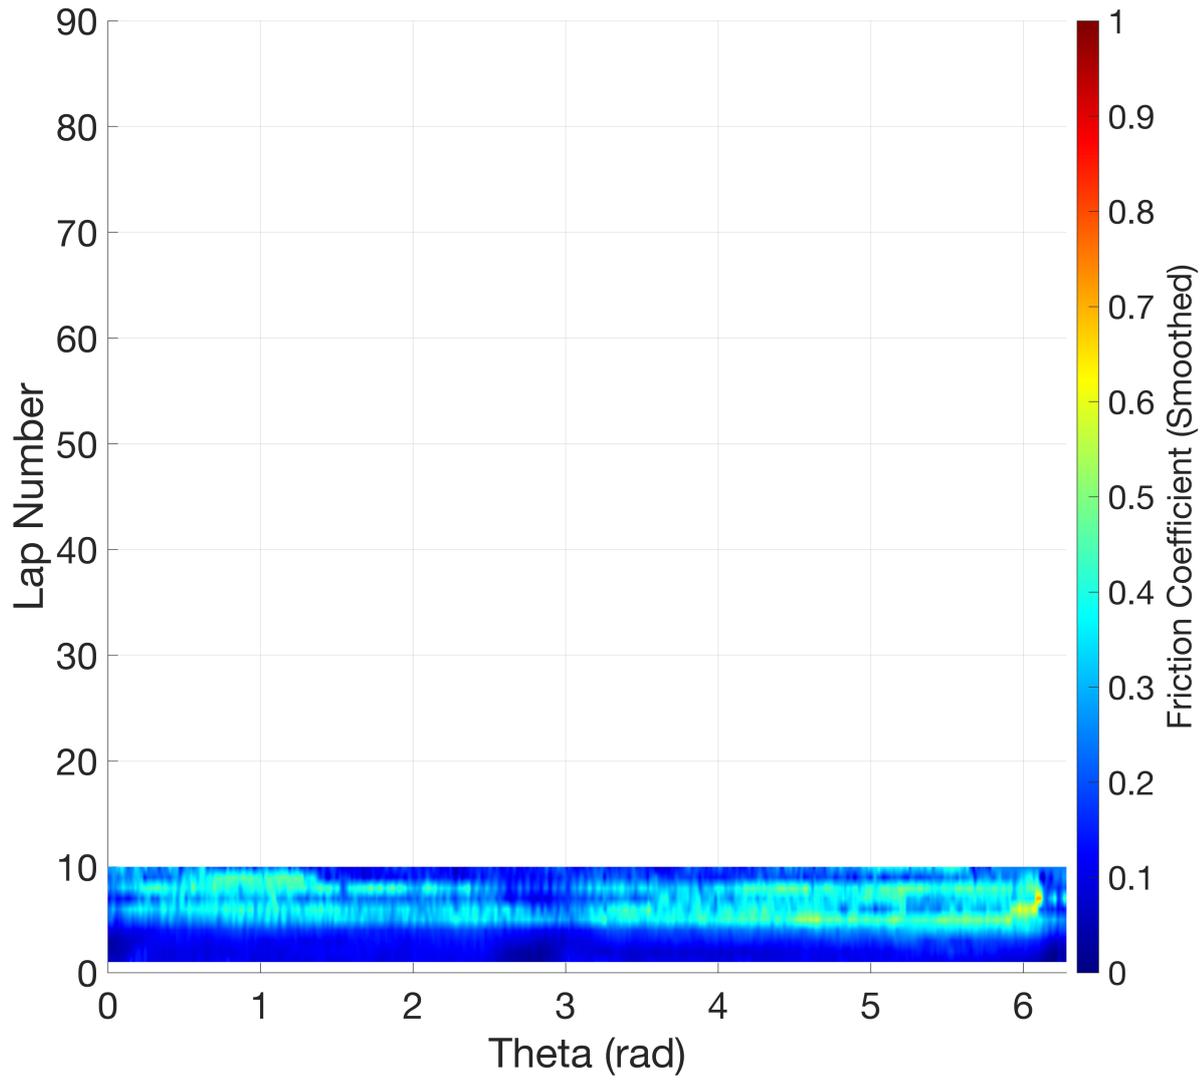


Figure D.6 – Test : D11P25 - Atm libre - 2m

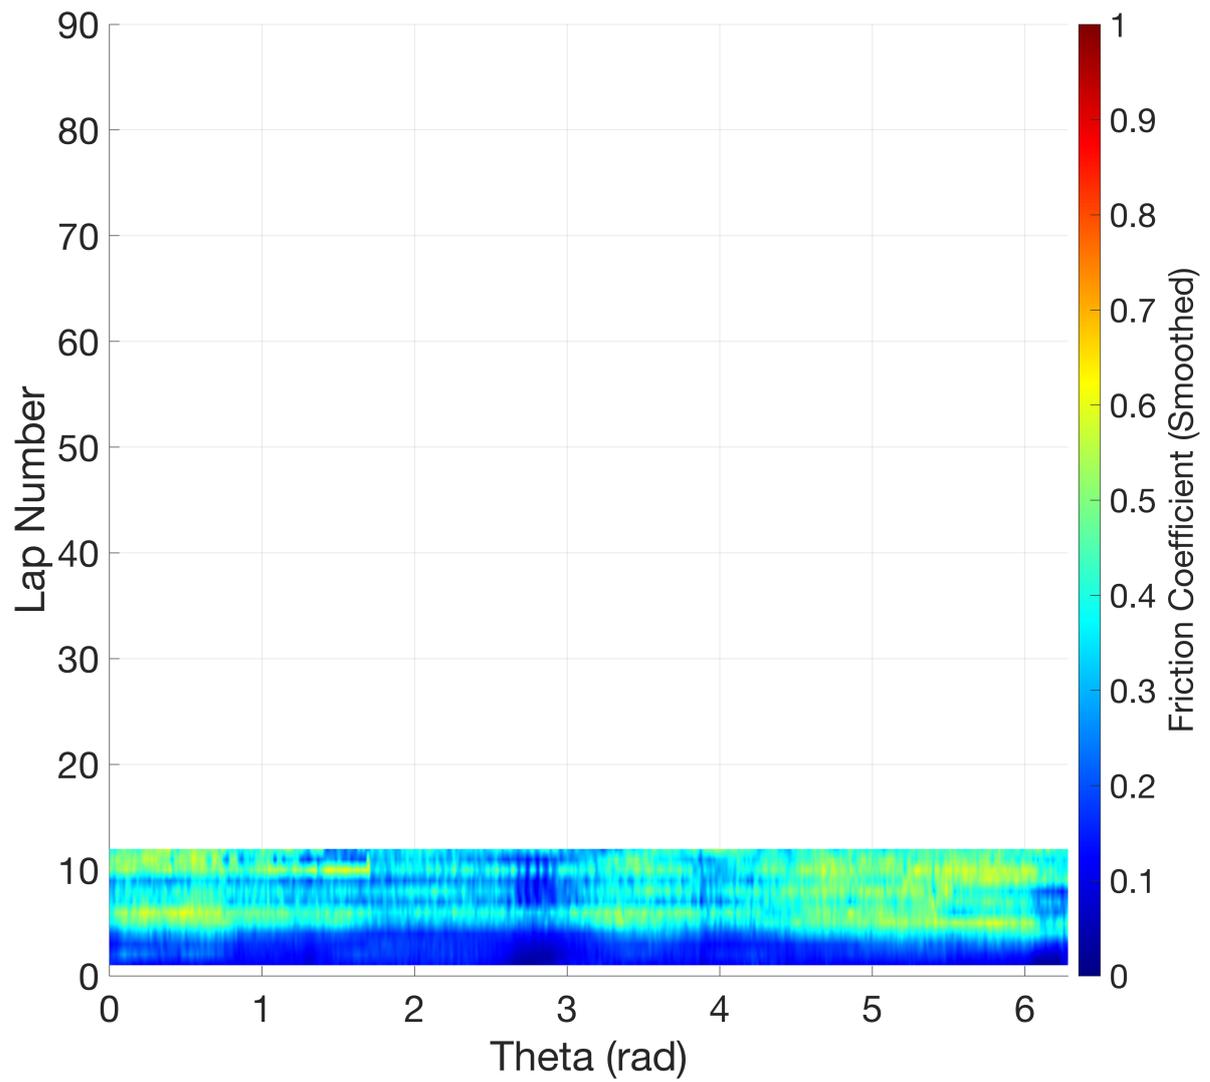


Figure D.7 – Test : D11P26 - Atm libre - 3m

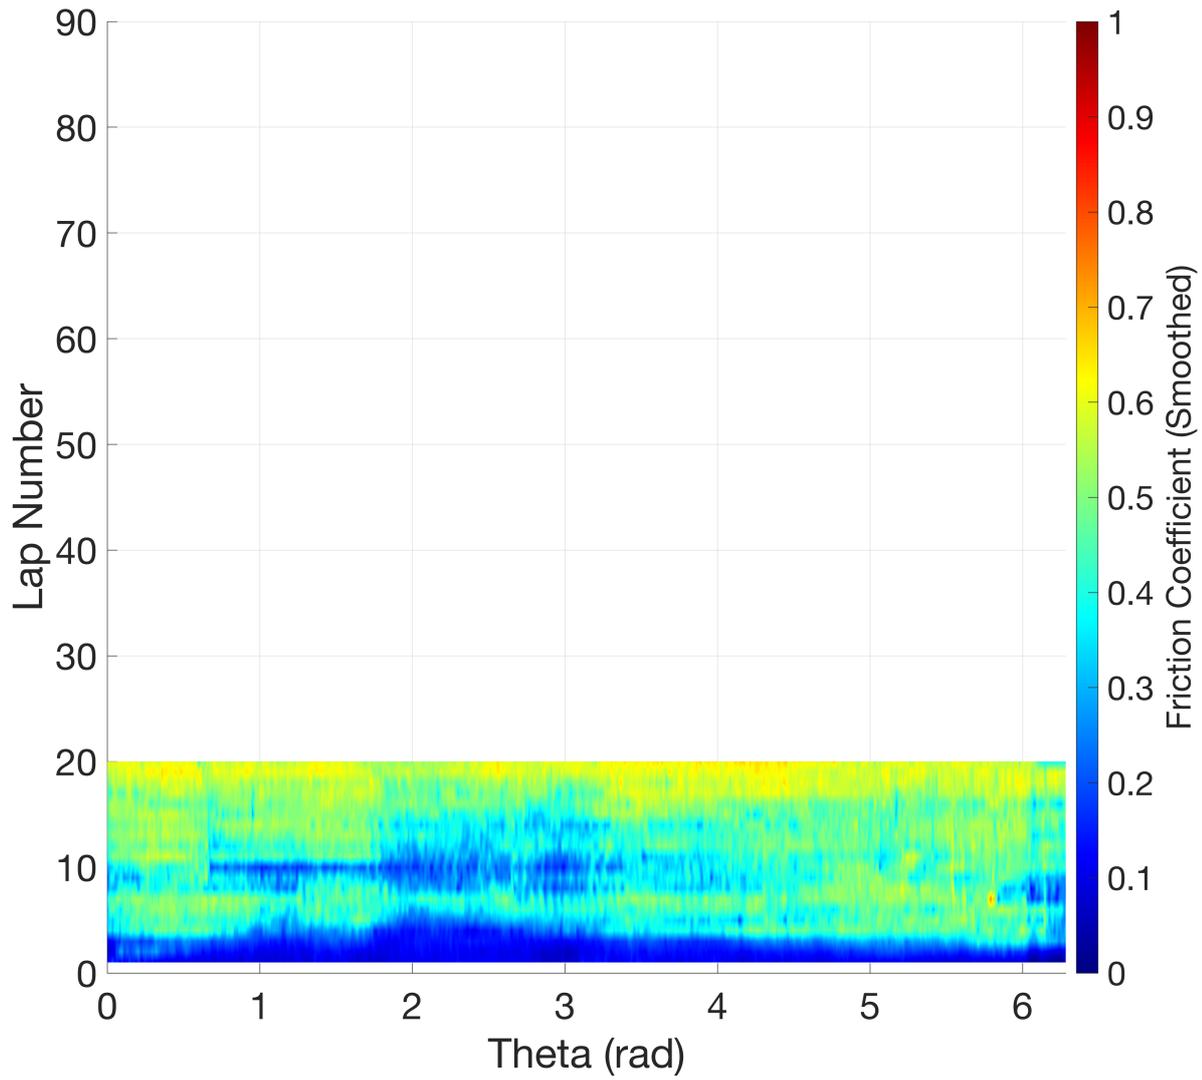


Figure D.8 – Test : D11P27 - Atm libre - 6m

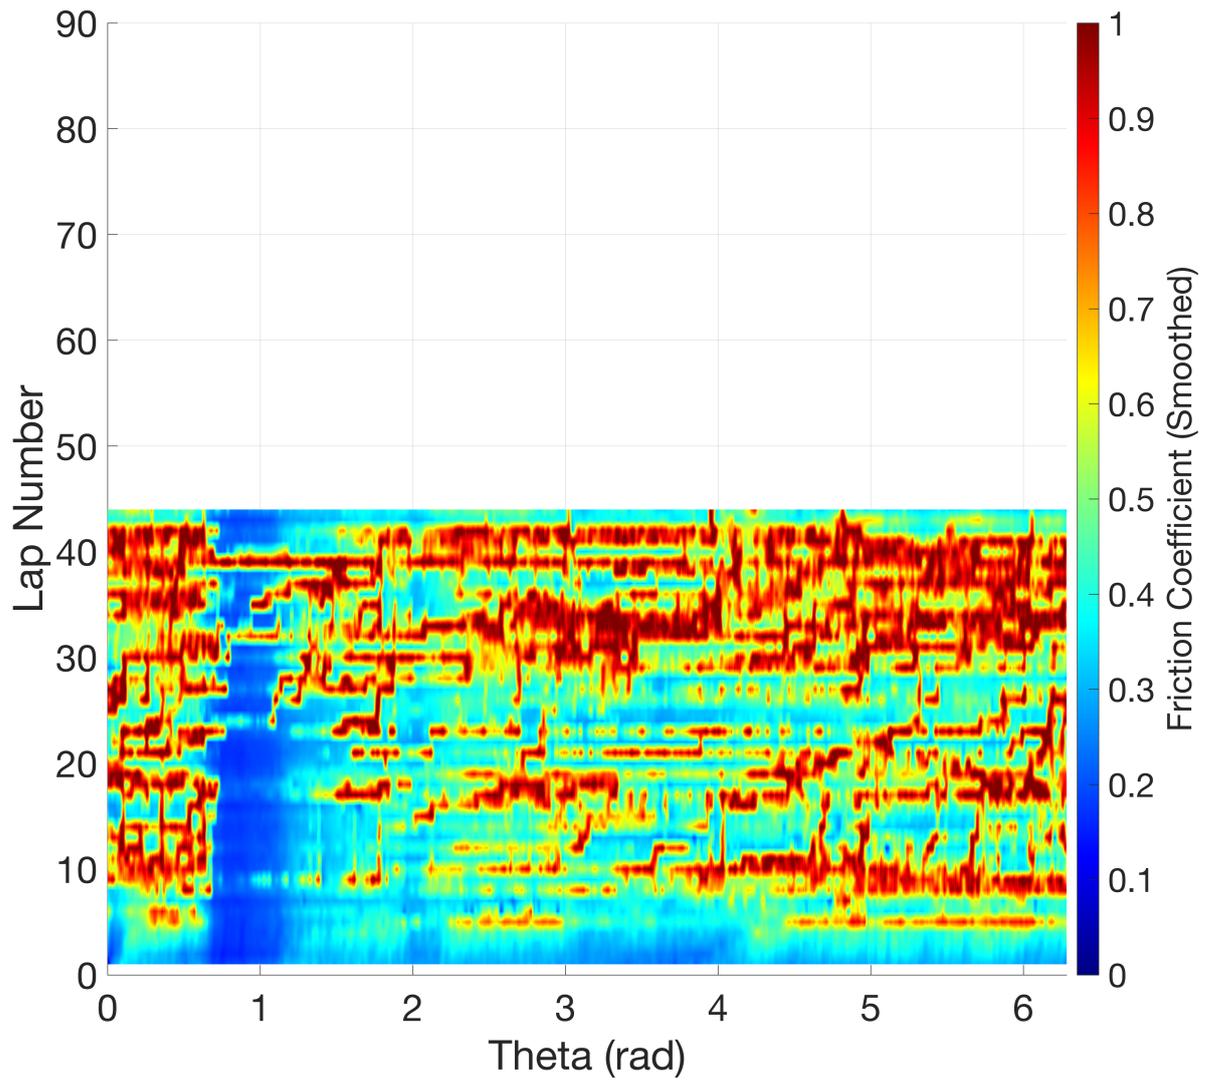


Figure D.9 – *Test : D12P28 - Argon - 7.5m*

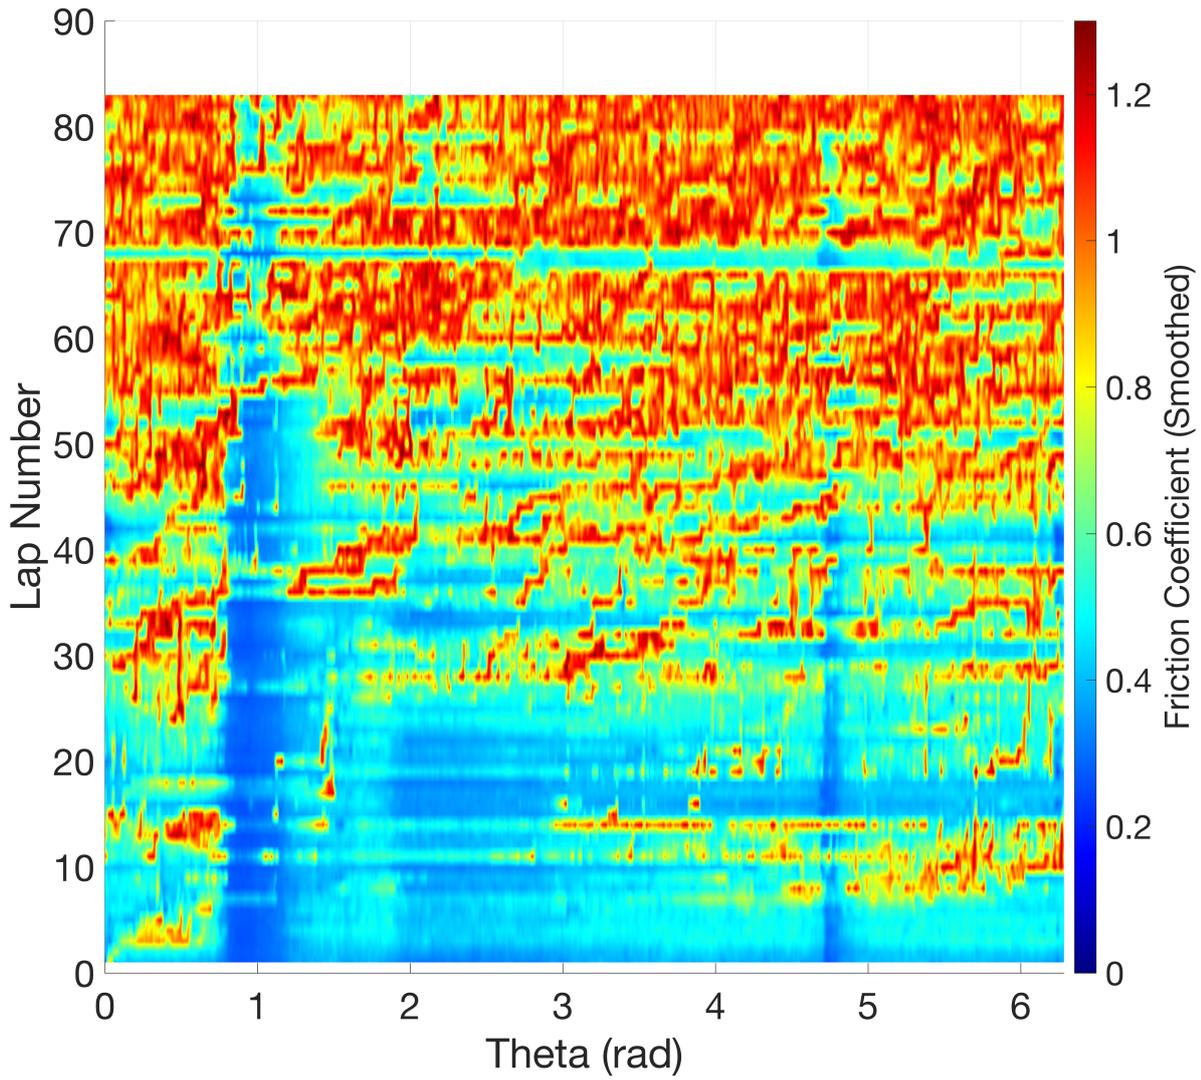


Figure D.10 – Test : D12P29 - Argon - 18m

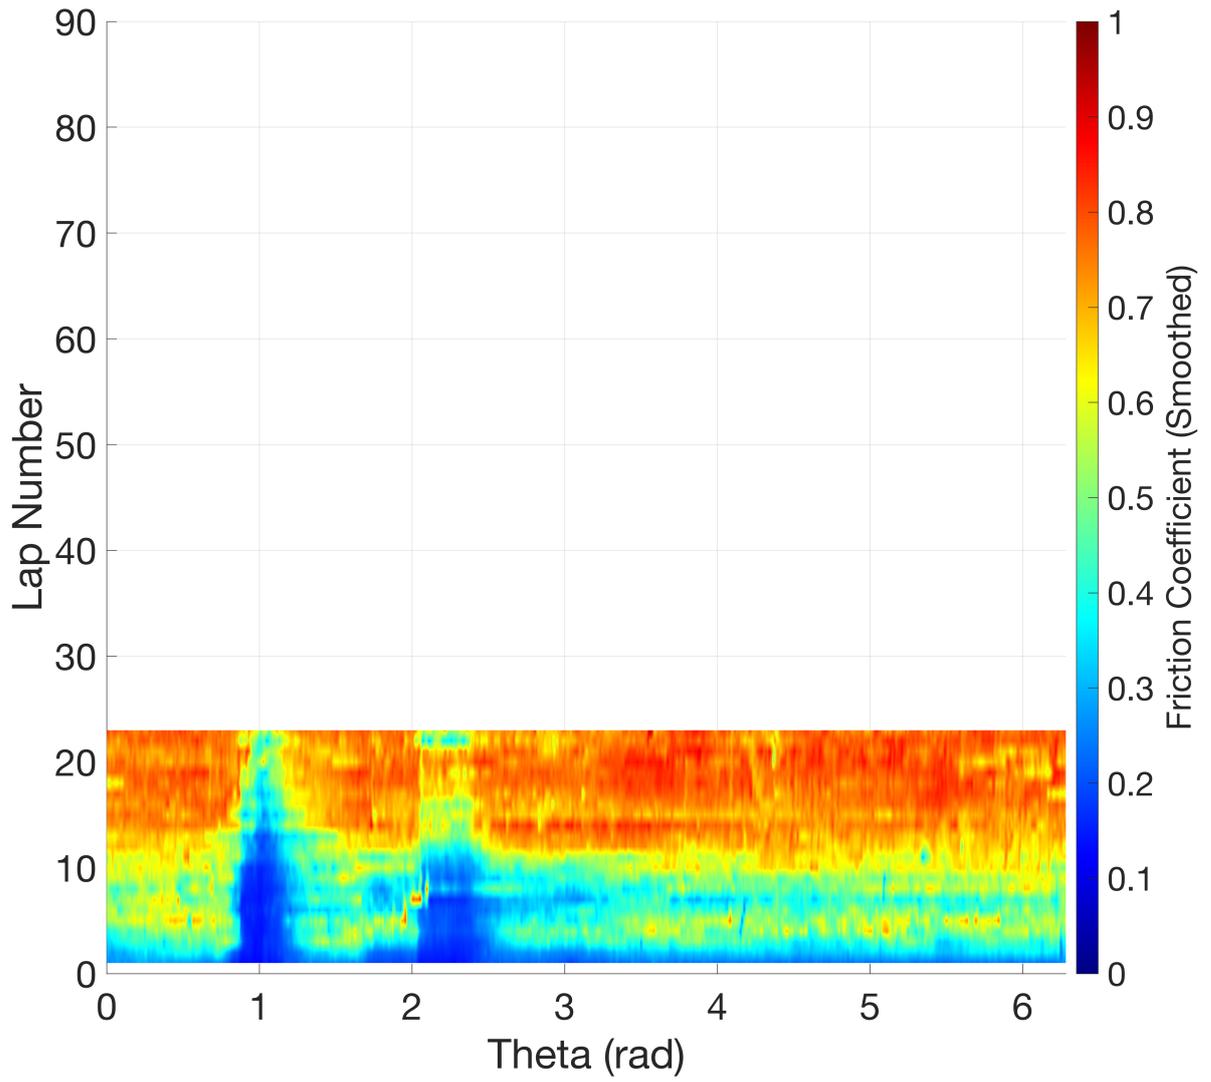


Figure D.11 – *Test : D12P30 - Atm libre - 6m*

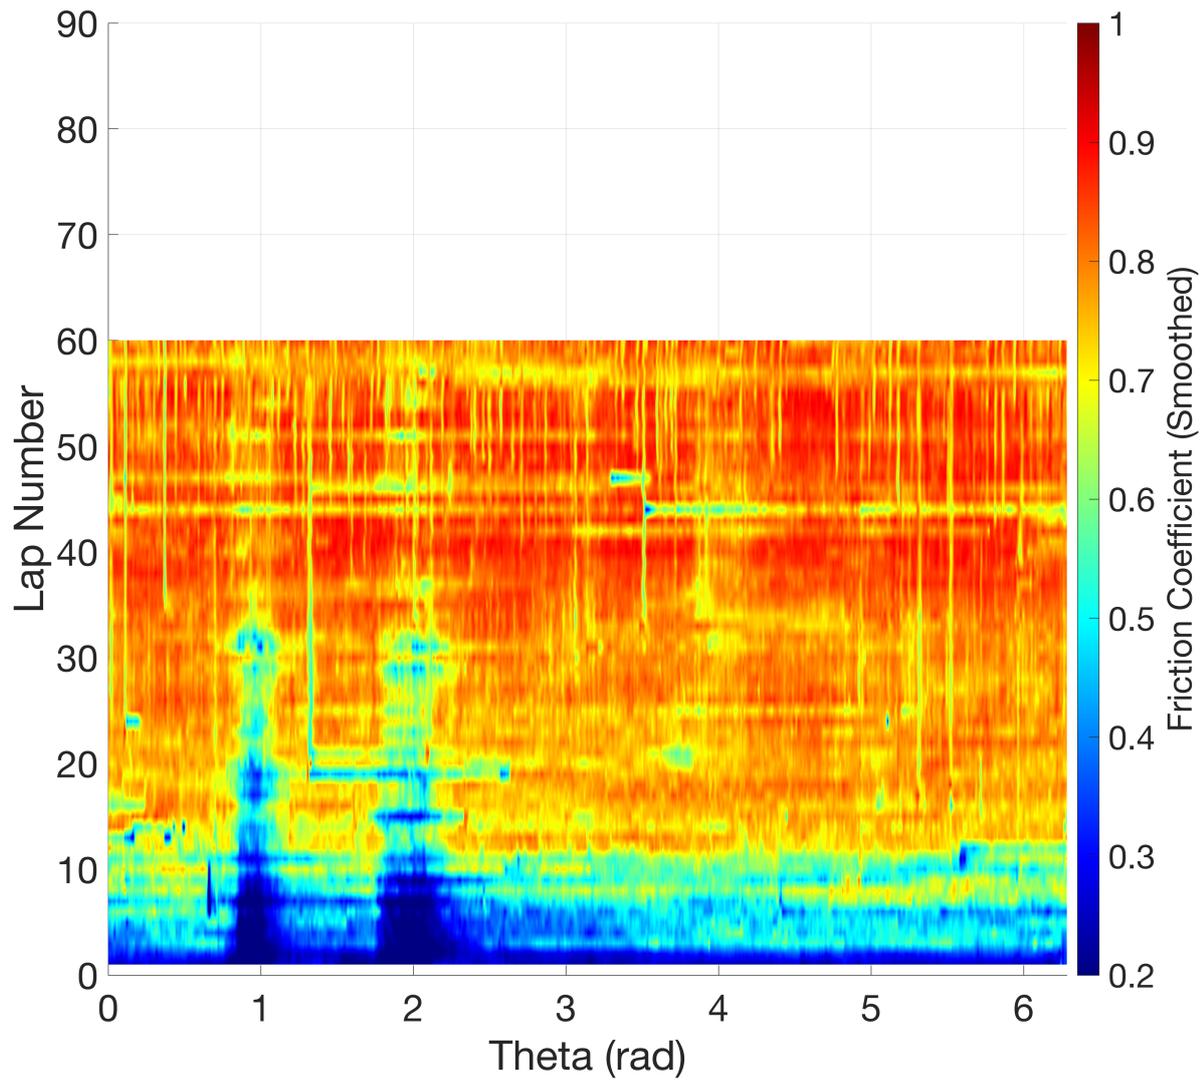


Figure D.12 – Test : D12P31 - Atm libre - 18m

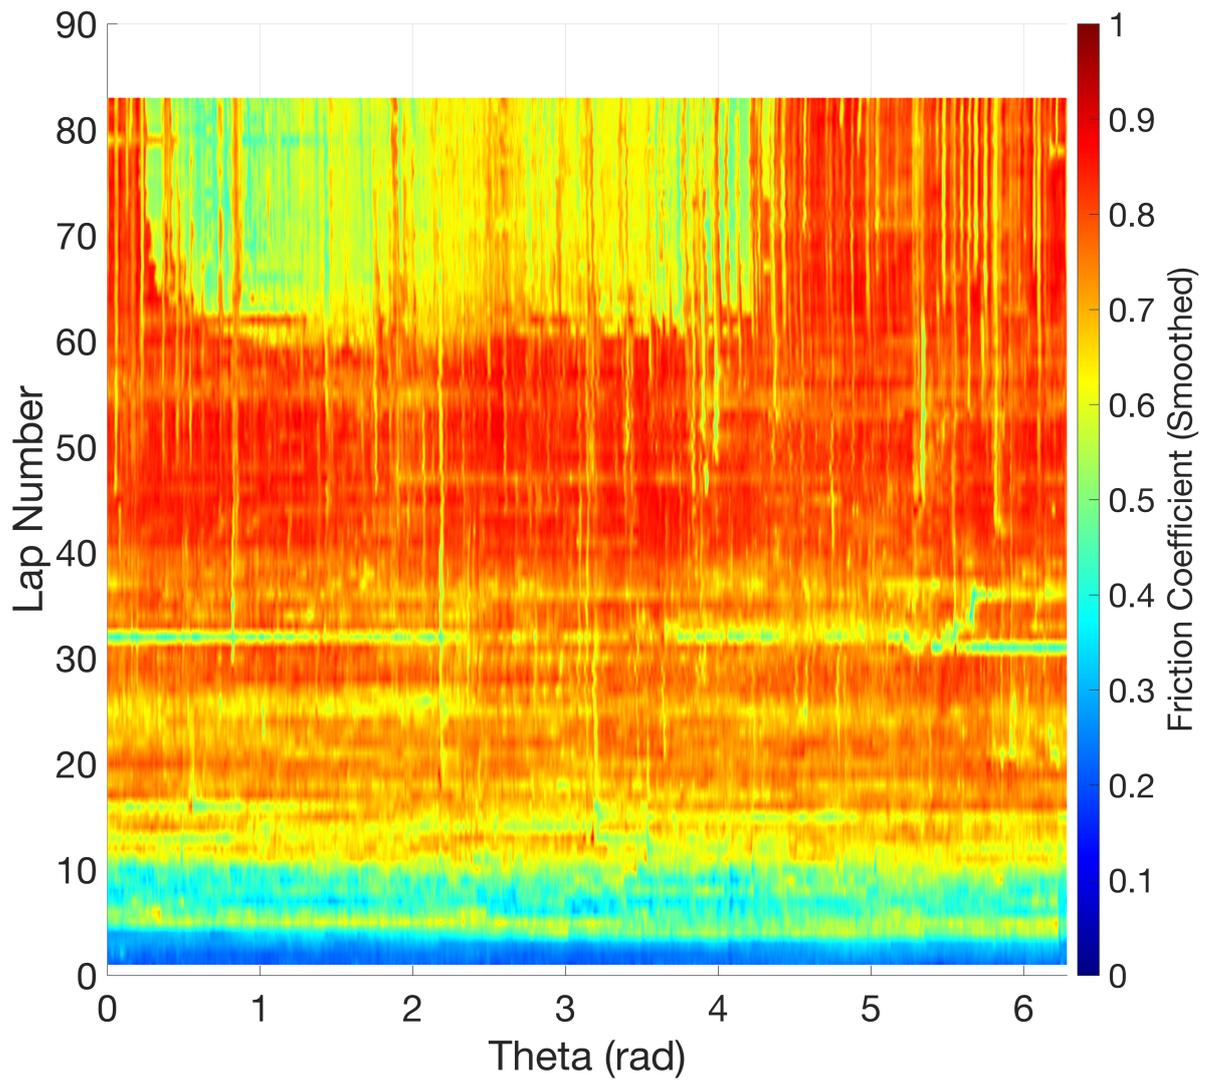


Figure D.13 – *Test : D17P42 - Atm libre - 25m*

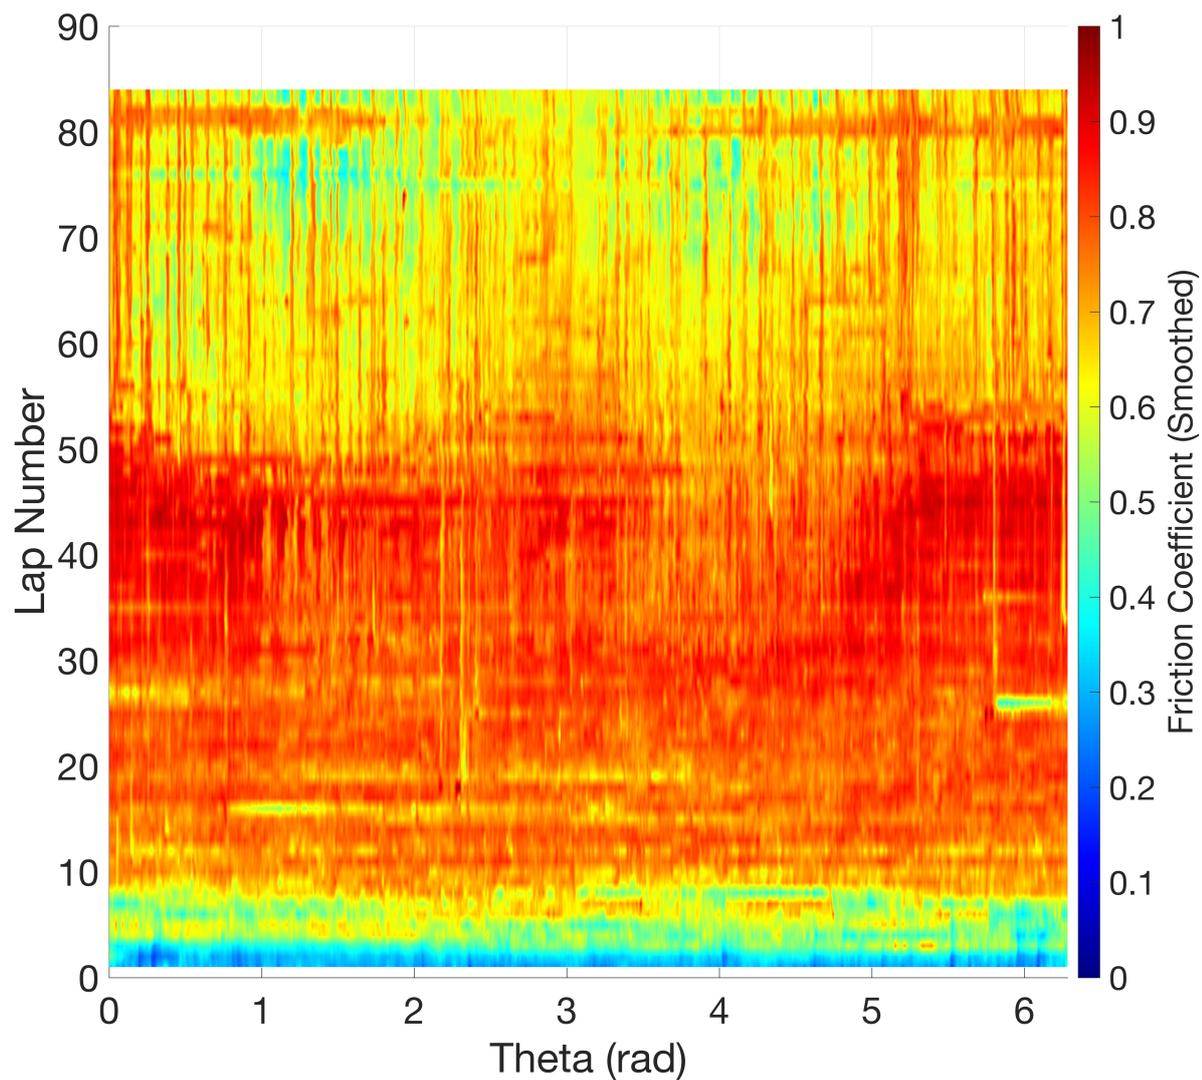


Figure D.14 – Test : D151P43 - Atm libre - 25m

Cette annexe propose des planches d'images MEB pour des essais en régime établi. Elles vont permettre de visualiser l'aspect du troisième corps produit sous atmosphère libre et Argon en chaque position du disque (ROI centre, extérieur et extérieur, Figure E.1).

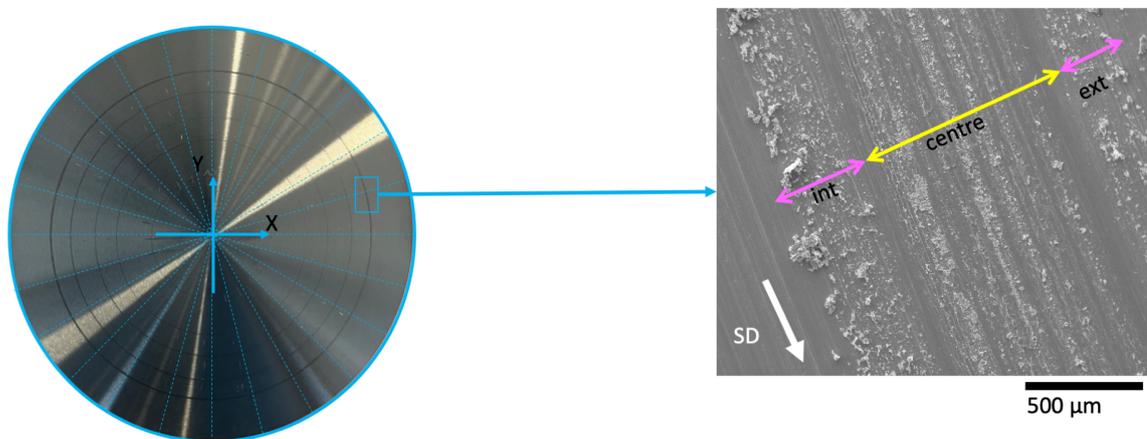


Figure E.1 – *Rappel des ROI sur le disque.*

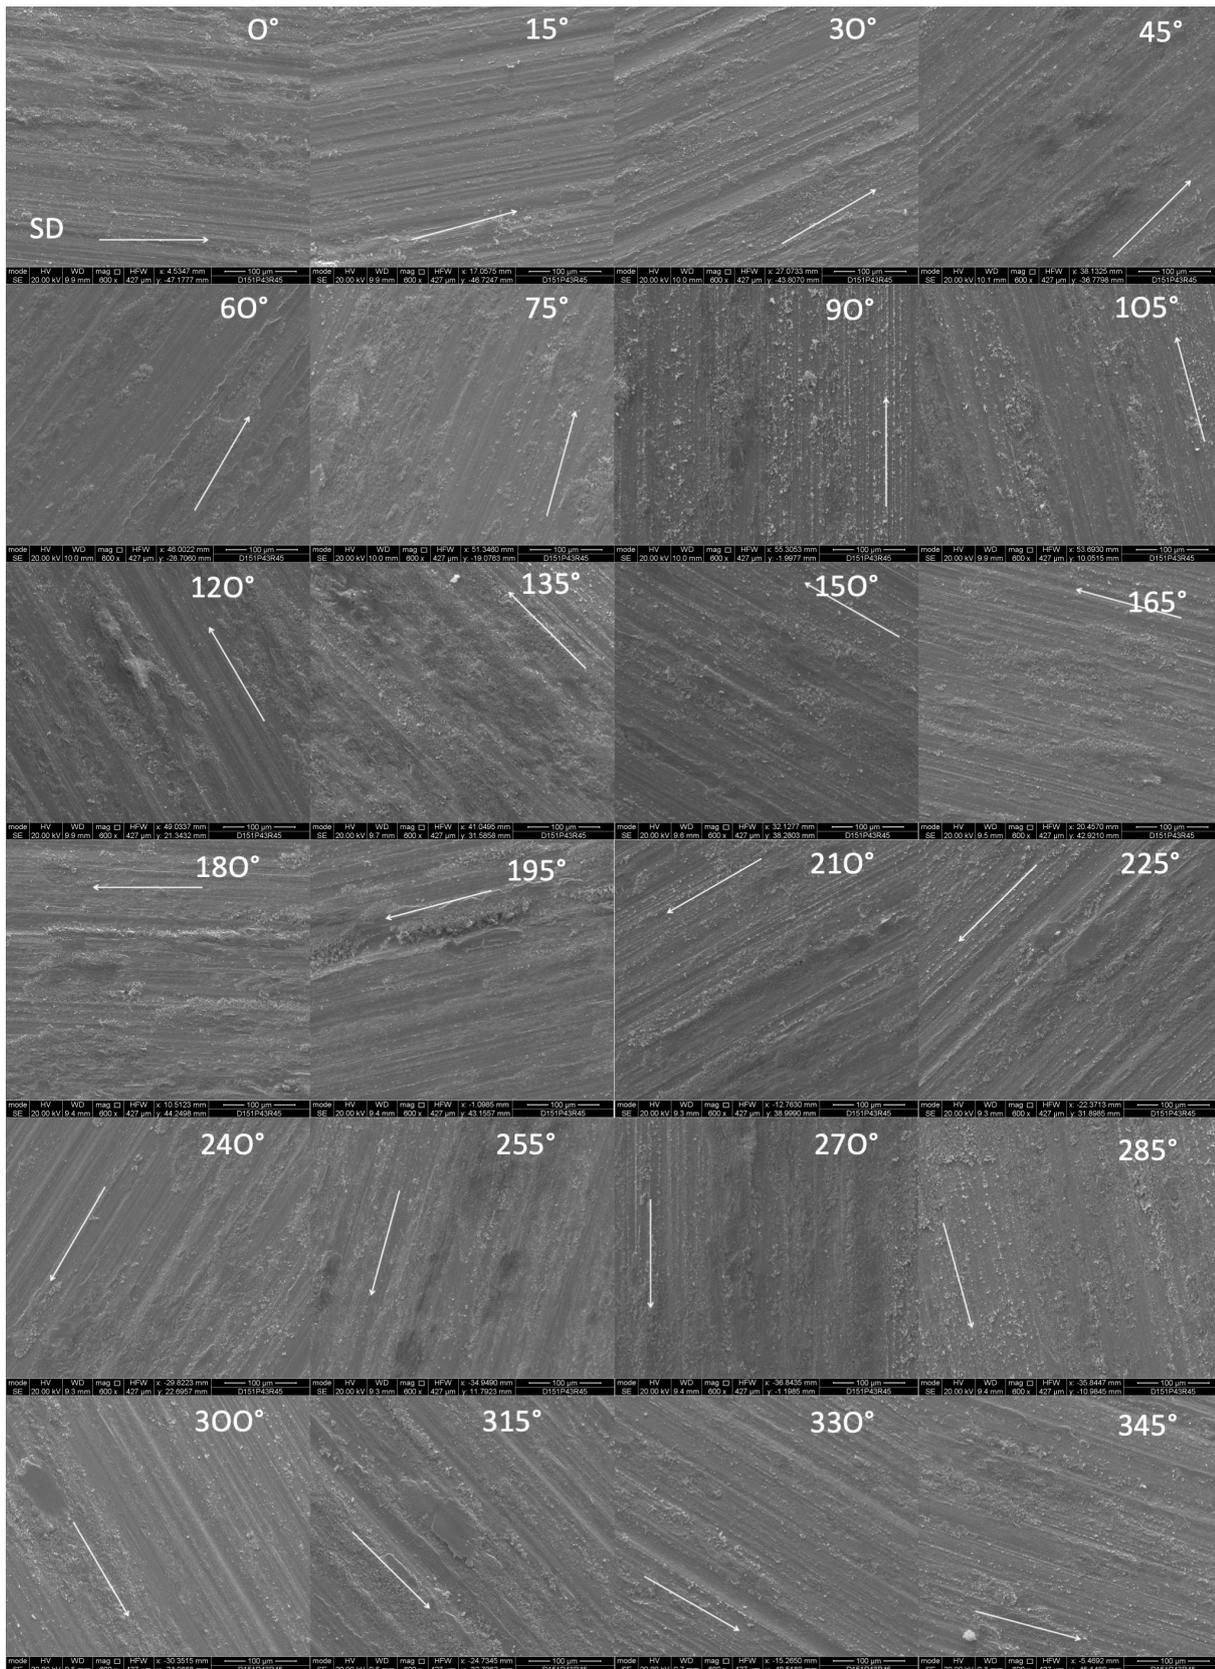


Figure E.2 – Images de centre de piste en atmosphère libre ; essai D151P43.

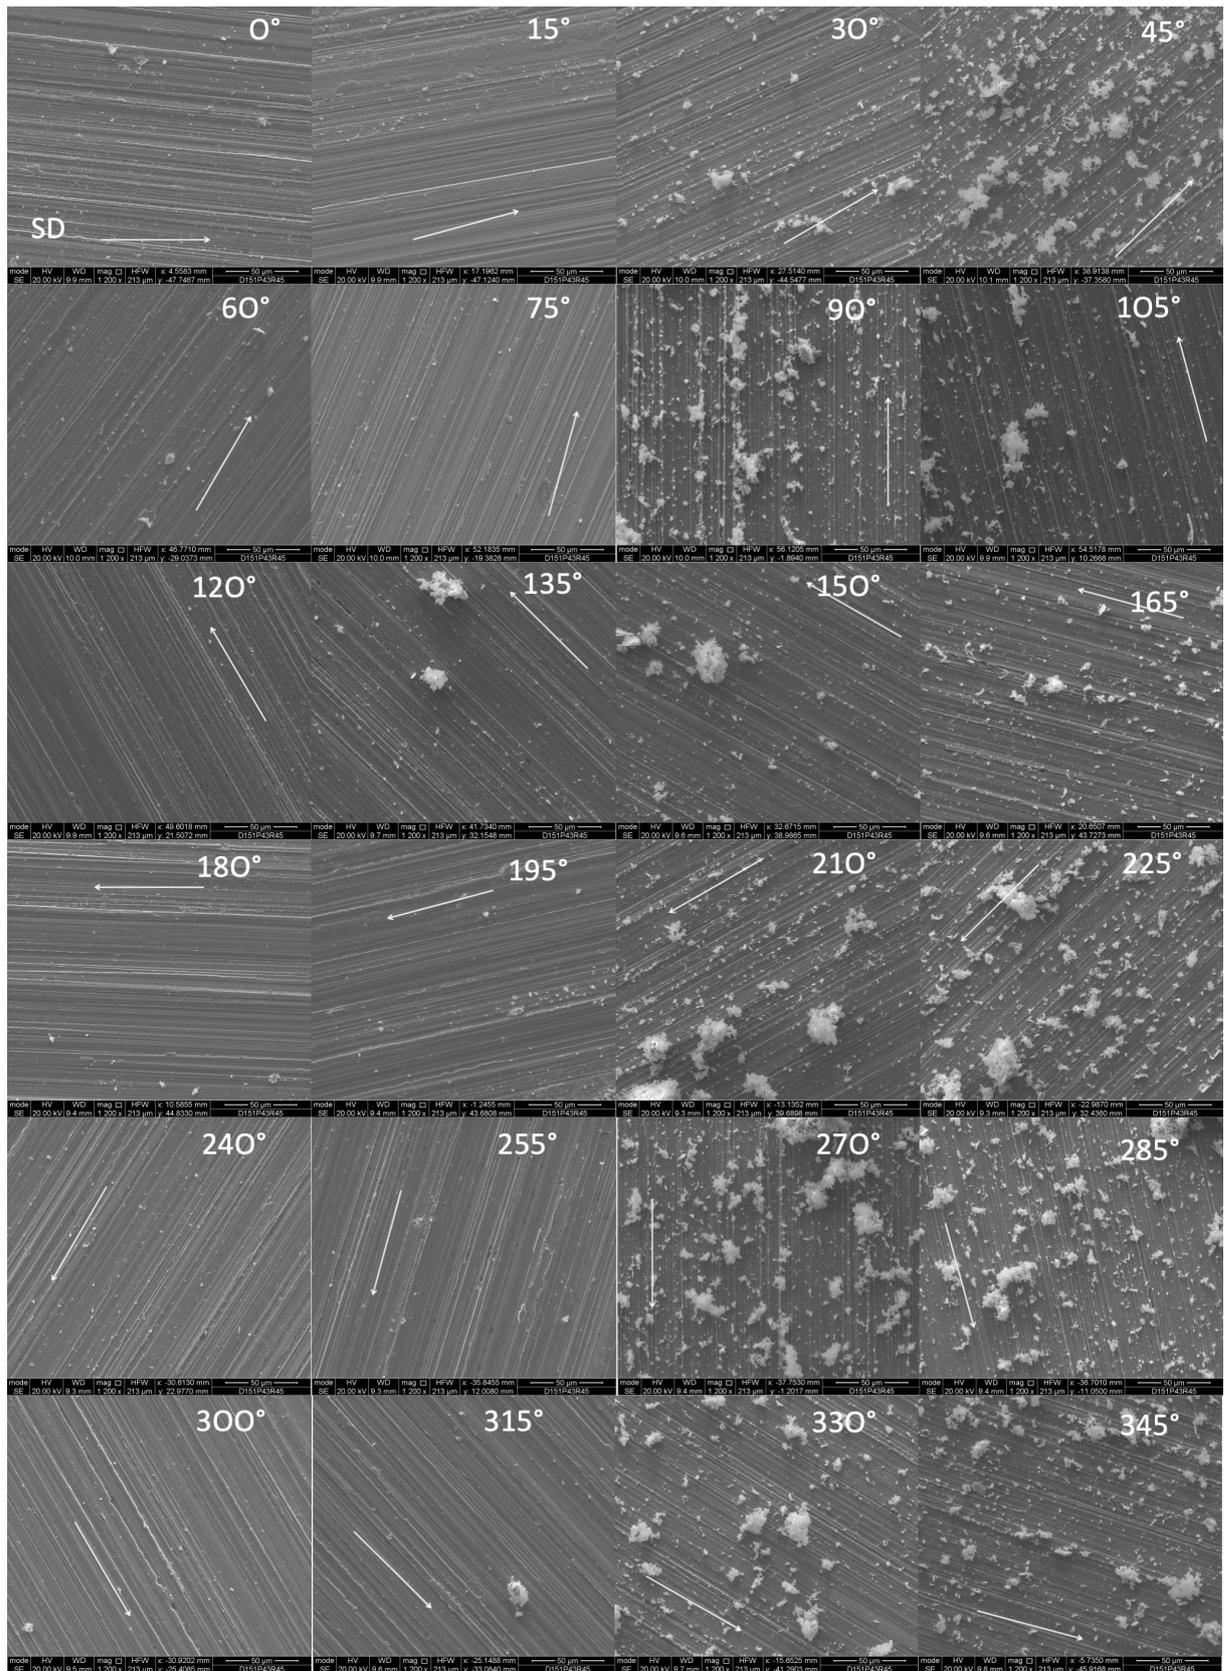


Figure E.3 – Images d'extérieur de piste en atmosphère libre ; essai D151P43.

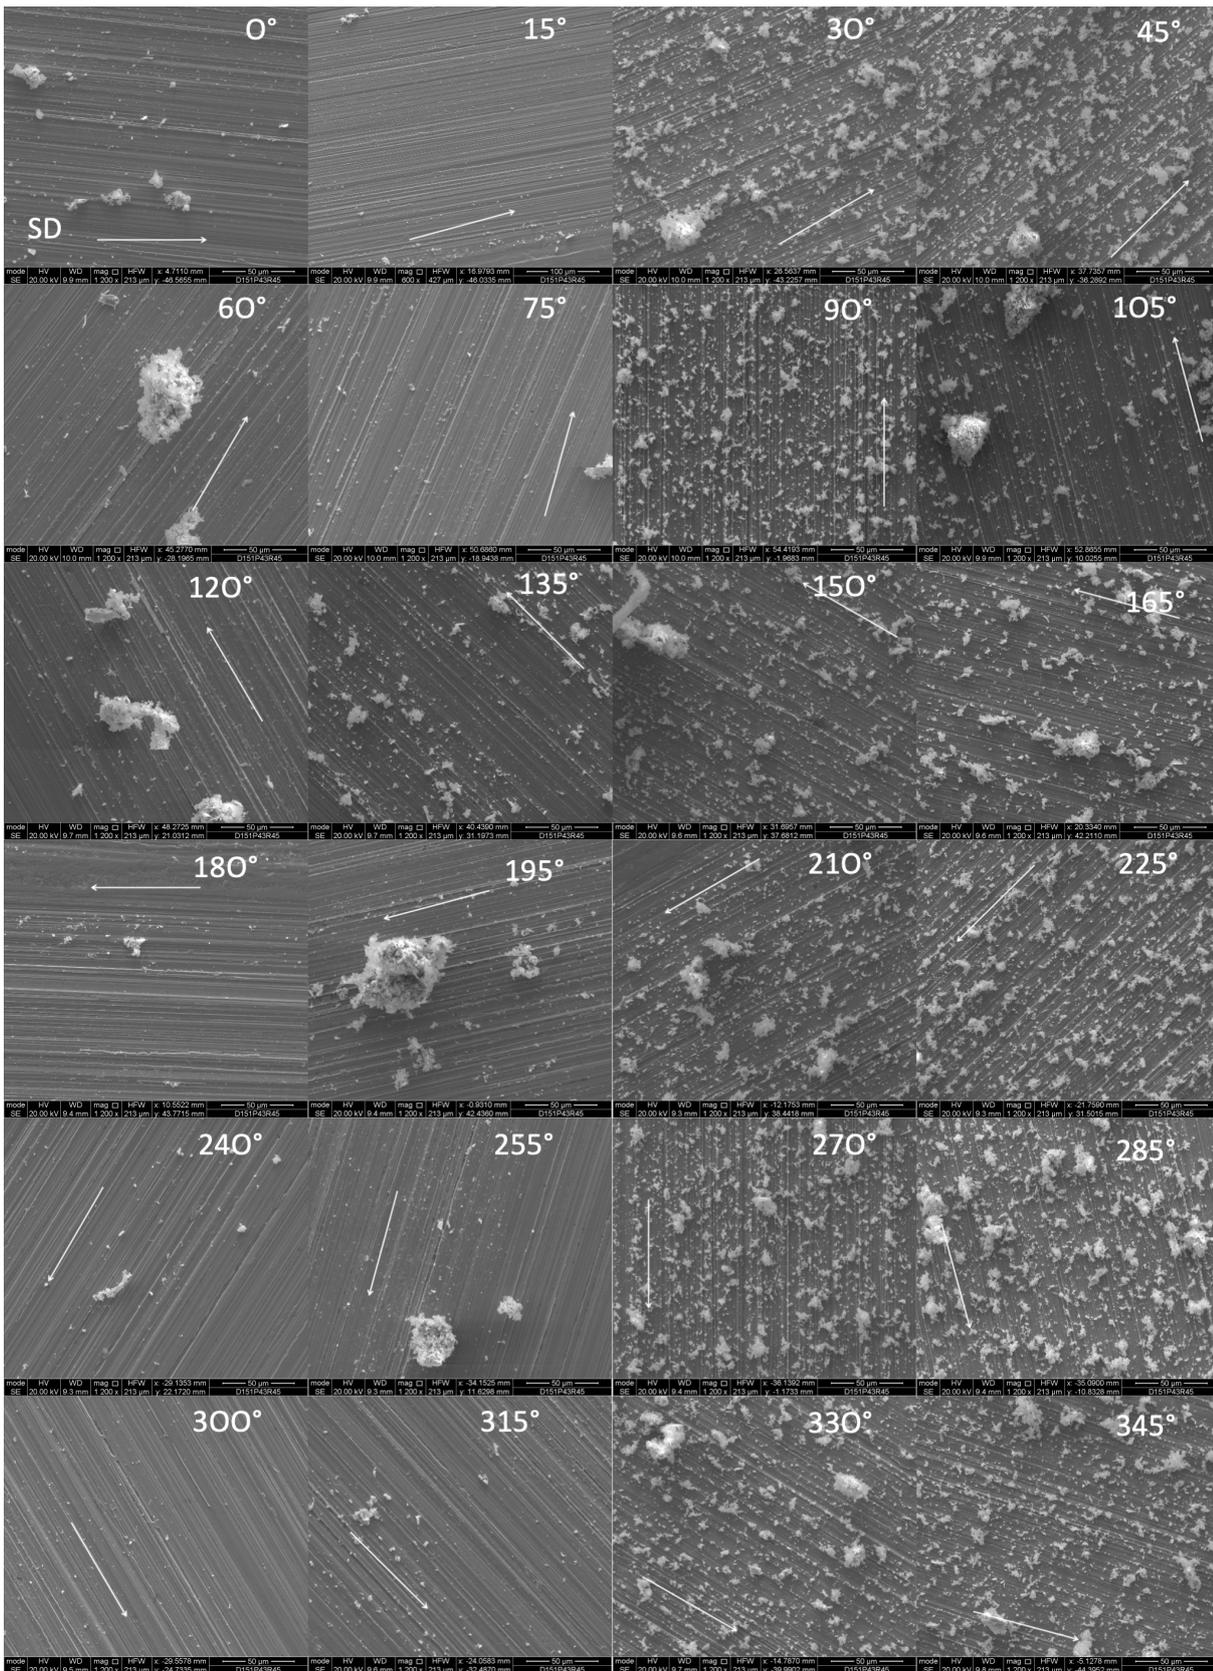


Figure E.4 – Images d'intérieur de piste en atmosphère libre ; essai D151P43.

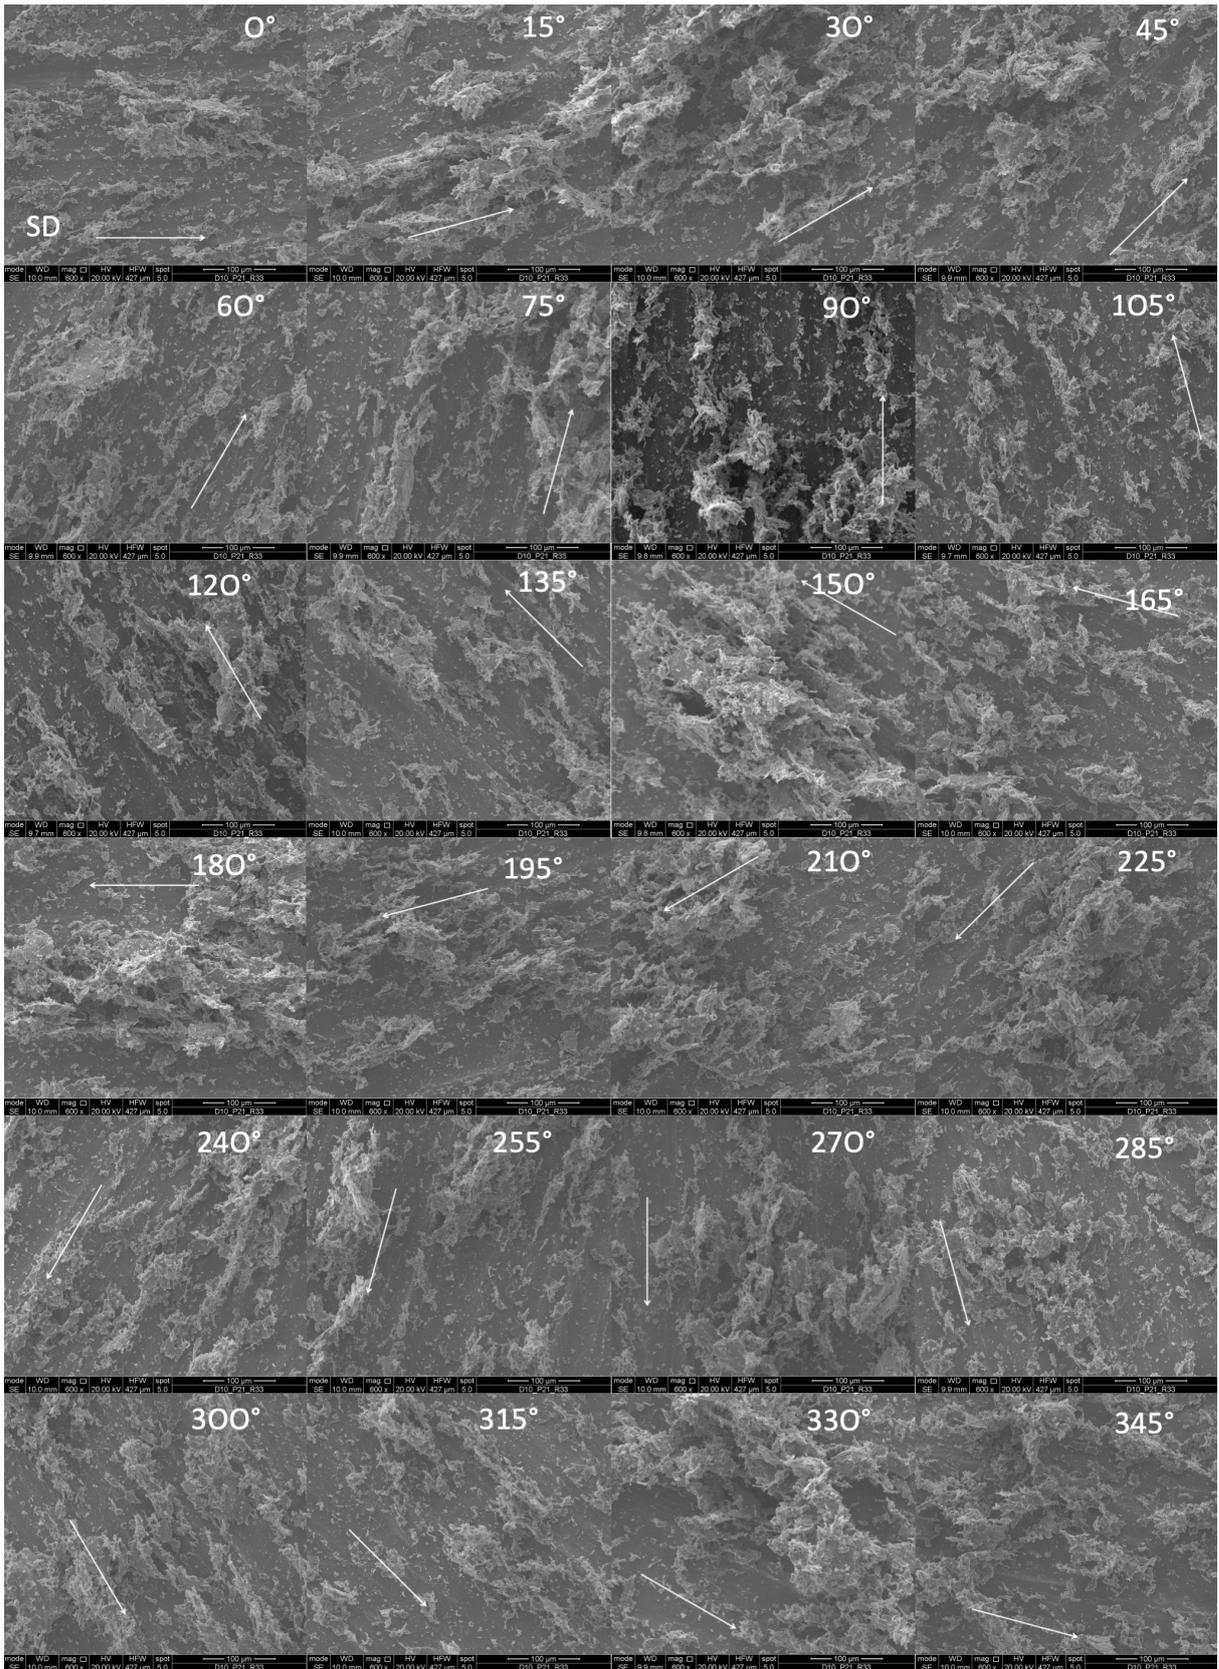


Figure E.5 – Images de centre de piste sous Argon ; essai D10P21.

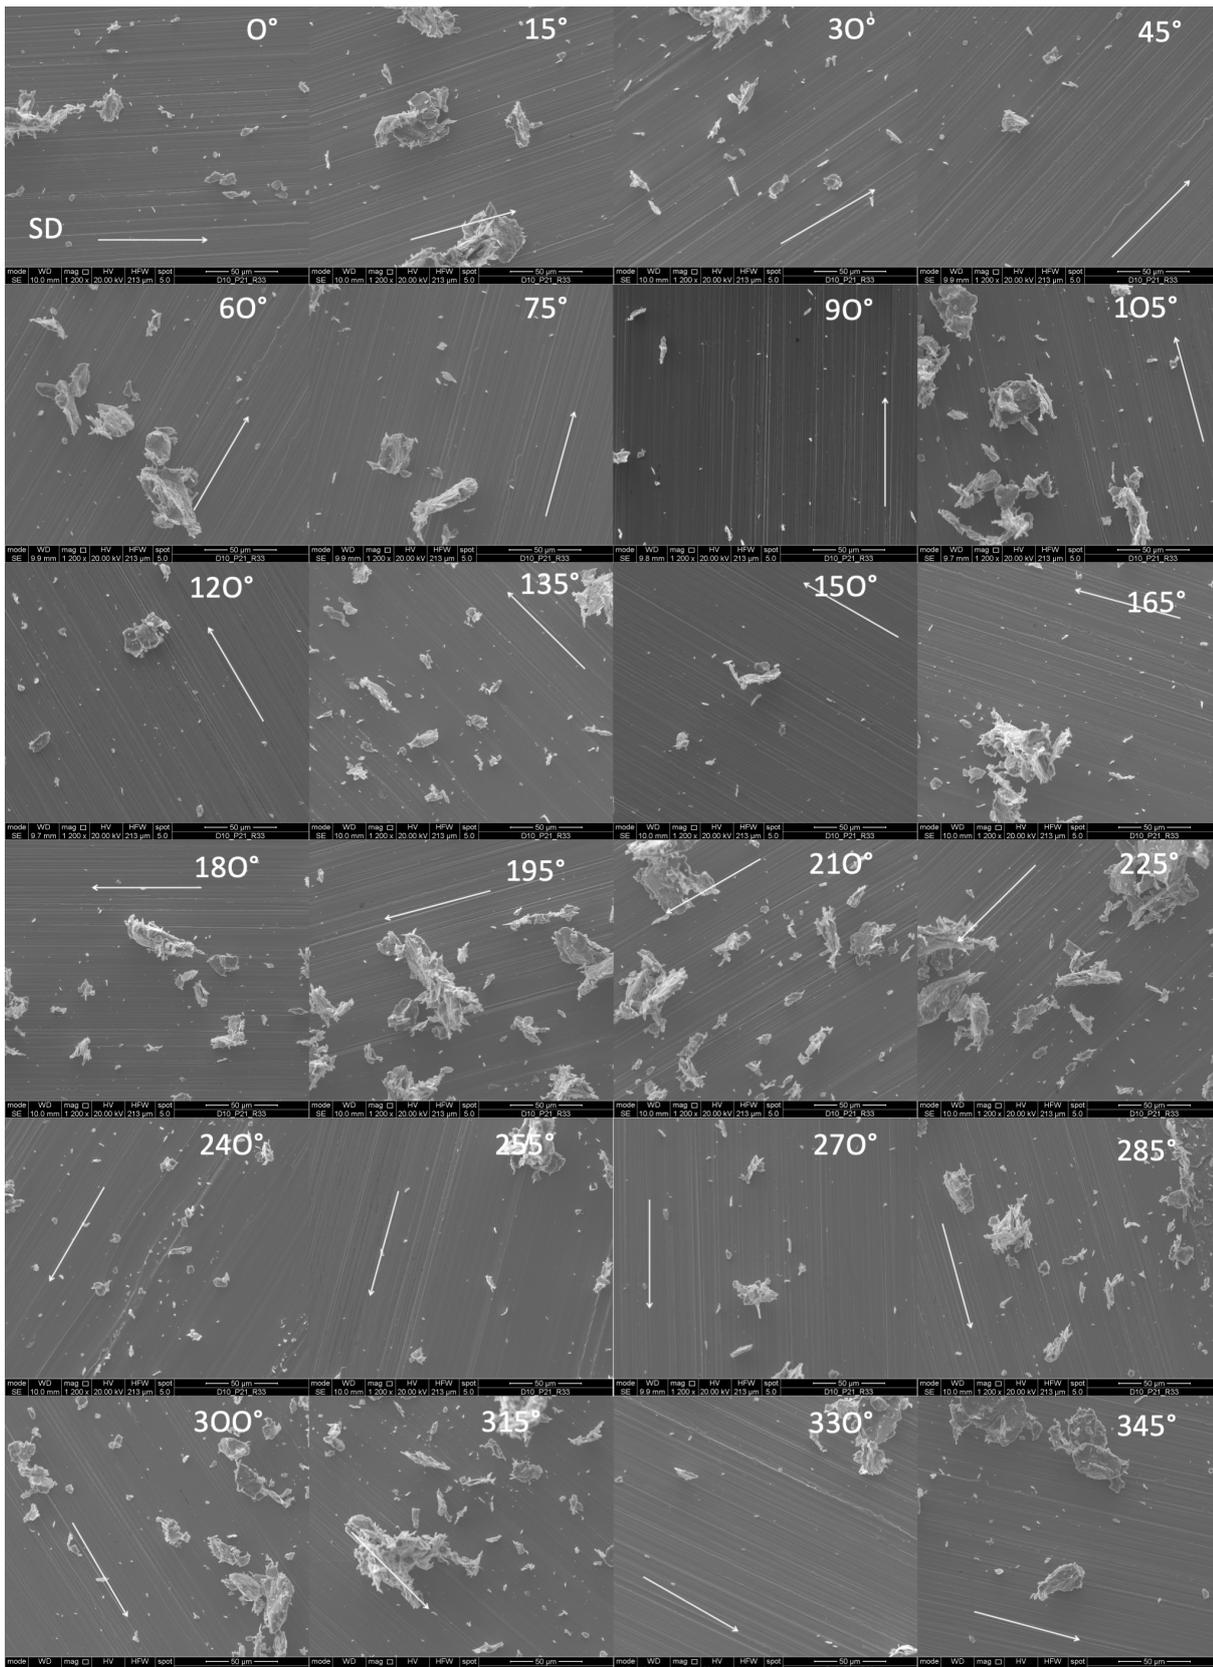


Figure E.6 – Images d'extérieur de piste sous Argon ; essai D10P21.

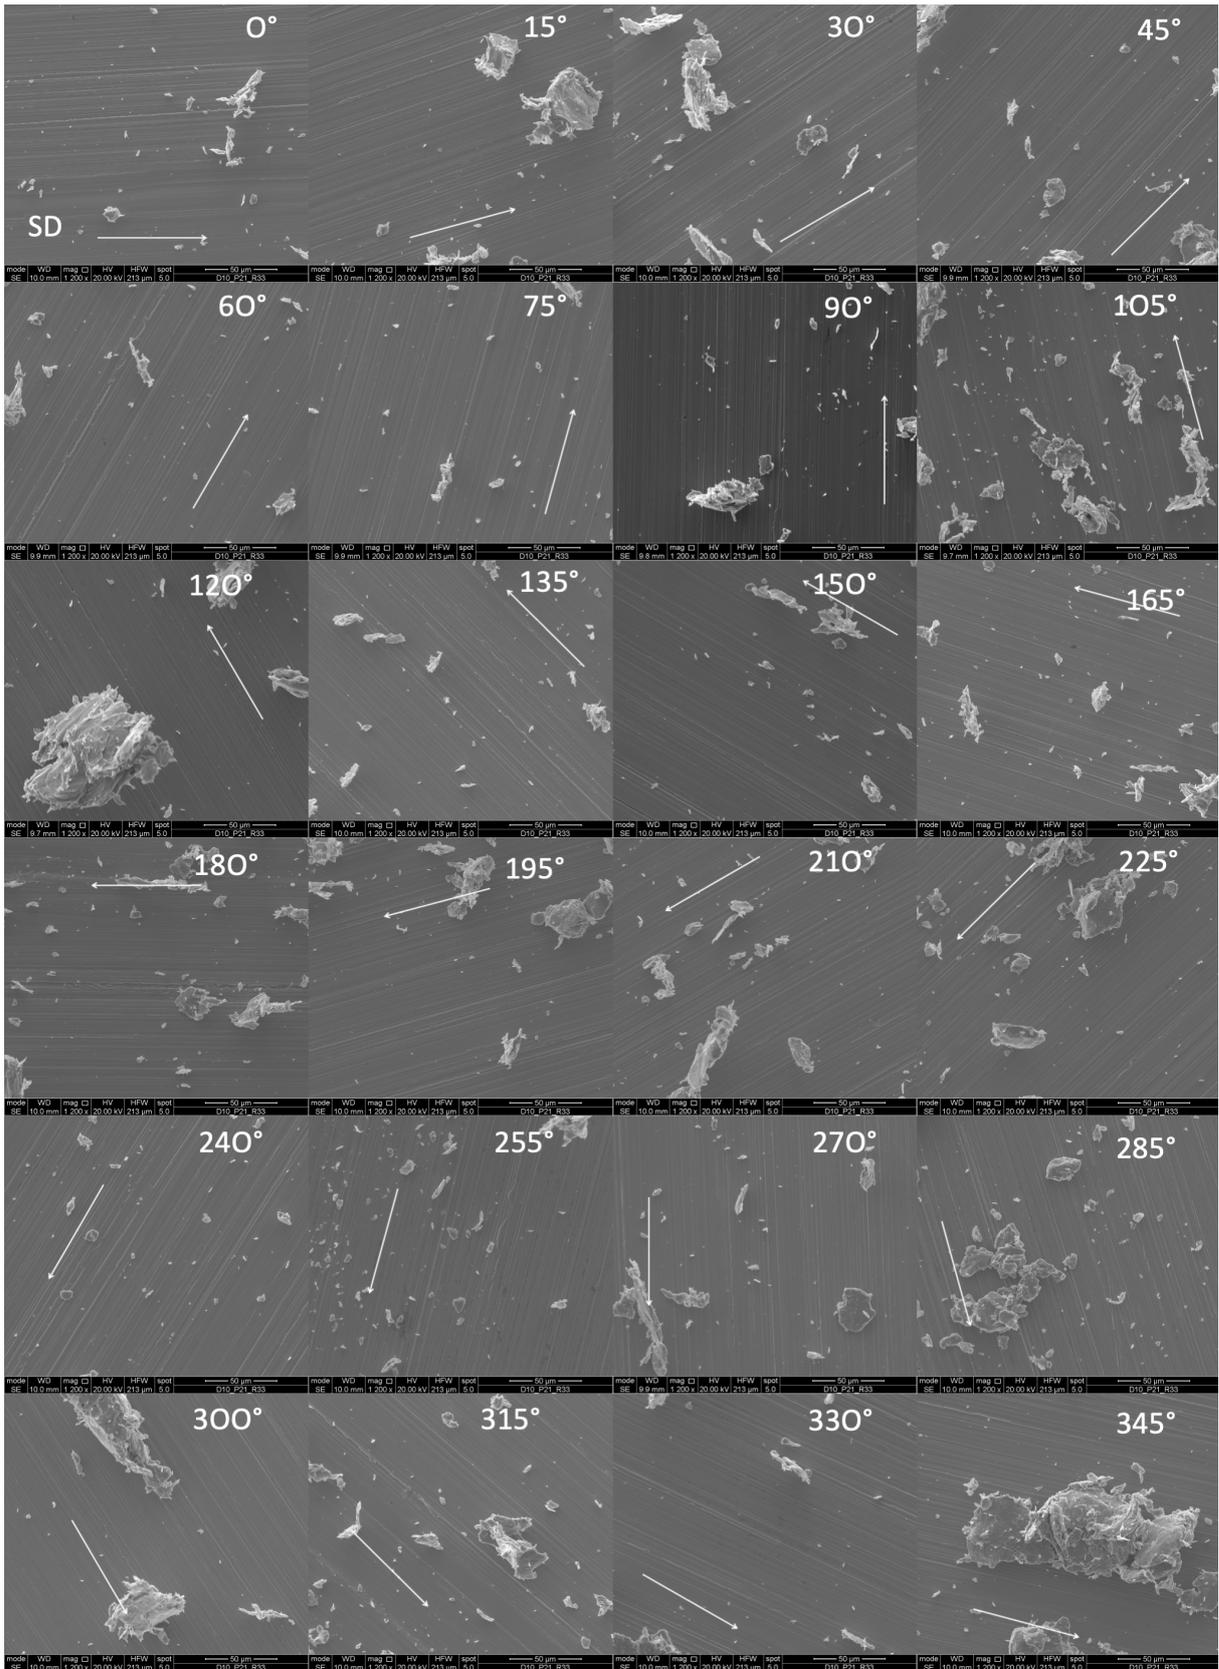


Figure E.7 – Images d'intérieur de piste sous Argon ; essai D10P21.

BIBLIOGRAPHIE

- Ahmed, Mohammed. 2020 (08). *Morphological Quality Assessment of Seed using Radiographic Image Analysis*. Ph.D. thesis. (p. 95, 183)
- Amontons, Guillaume. 1699. *De la résistance causée dans les machines. Tant par les frottements des parties qui les composent, que par la raideur des cordes qu'on emploie, et la manière de calculer l'un et l'autre*. Paris : Académie Royale des Sciences. (p. 29)
- Ansari, Sam, Alnajjar, Khawla A, Abdallah, Saeed, Saad, Mohamed, & El-Moursy, Ali A. 2021. Parameter Tuning of MLP, RBF, and ANFIS Models Using Genetic Algorithm in Modeling and Classification Applications. *Pages 660–666 of : 2021 International Conference on Information Technology (ICIT)*. IEEE. (p. 58)
- Archard, JeFoa. 1953. Contact and rubbing of flat surfaces. *Journal of applied physics*, **24**(8), 981–988. (p. 30, 37)
- Azencott, Chloe Agathe. 2018. *Introduction au machine learning*. Dunod. (p. 52, 53, 54, 57, 108, 127, 182)
- Banda, Tiyamike, Jie, Bryan Yeoh Wei, Farid, Ali Akhavan, & Lim, Chin Seong. 2022. Machine vision and convolutional neural networks for tool wear identification and classification. *Pages 737–747 of : Recent Trends in Mechatronics Towards Industry 4.0 : Selected Articles from iM3F 2020, Malaysia*. Springer. (p. 107)
- Benureau, Fabien. 2015 (May). *Self-Exploration of Sensorimotor Spaces in Robots*. Theses, Université de Bordeaux. (p. 51)
- Berthier, Y. 2005. Third-body reality - consequences and use of the third-body concept to solve friction and wear problems. *Pages 291–316 of : Wear - Materials, Mechanisms and Practice*. Chichester, England : John Wiley & Sons Ltd. (p. 33, 80, 181)
- Berthier, Yves. 1988. *Mécanismes et tribologie*. Ph.D. thesis. Thèse de doctorat dirigée par Godet, Maurice Tribologie Lyon, INSA 1988. (p. 33)
- Berthier, Yves. 1990. Experimental evidence for friction and wear modelling. *Wear*, **139**(1), 77–92. (p. 32)

- Berthier, Yves. 1996. Maurice Godet's Third Body. *Pages 21 – 30 of : Dowson, D., Taylor, C.M., Childs, T.H.C., Dalmaz, G., Berthier, Y., Flamand, L., Georges, J.-M., & Lubrecht, A.A. (eds), The Third Body Concept Interpretation of Tribological Phenomena. Tribology Series, vol. 31. Elsevier. (p. 33)*
- Biau, Gérard. 2012. Analysis of a random forests model. *The Journal of Machine Learning Research*, **13**(1), 1063–1095. (p. 57, 109)
- Blau, Peter J. 2005. On the nature of running-in. *Tribology International*, **38**(11), 1007–1012. Tribology International A Celebration Issue. (p. 34)
- Bouchot, Alizée, Ferrieux, Amandine, Debayle, Johan, Mollon, Guilhem, & Descartes, Sylvie. 2021a. Image processing applied to tribological dry contact analysis. *Wear*, **476**, 203748. (p. 77, 104, 106)
- Bouchot, Alizée, Ferrieux-Paquet, Amandine, Descartes, Sylvie, Mollon, Guilhem, & Debayle, Johan. 2021b. Towards a quantitative characterization of wear particles using image analysis and machine learning. *Pages 302–308 of : Fifteenth International Conference on Quality Control by Artificial Vision*, vol. 11794. SPIE. (p. 86)
- Bouchot, Alizée, Ferrieux-Paquet, Amandine, Mollon, Guilhem, Descartes, Sylvie, & Debayle, Johan. 2022. Segmentation and morphological analysis of wear track/particles images using machine learning. *Journal of Electronic Imaging*, **31**(5), 051605–051605. (p. 86, 96)
- Bouillanne, Olivier, Mollon, Guilhem, Saulot, Aurélien, Descartes, Sylvie, Serres, Nathalie, Chassaing, Guillaume, & Demmou, Karim. 2022. How vorticity and agglomeration control shear strength in soft cohesive granular flows. *Granular Matter*, **24**(2), 55. (p. 80, 137, 184)
- Bowden, Frank Philip, & Tabor, David. 2001. *The friction and lubrication of solids*. Vol. 1. Oxford university press. (p. 27)
- Brahmbhatt, Samarth. 2013. *Practical OpenCV*. 1 edn. Apress. (p. 86, 94)
- Breiman, Leo. 2001. Random forests. *Machine learning*, **45**, 5–32. (p. 53, 120)
- Breiman, Leo. 2002. Manual on setting up, using, and understanding random forests v3. 1. *Statistics Department University of California Berkeley, CA, USA*, **1**(58), 3–42. (p. 120)
- Brunetière, Noël. 2021. Introduction à la tribologie. (p. 27, 181)
- Buckley, Donald H. 1978. Tribological properties of surfaces. *Thin Solid Films*, **53**(3), 271–283. (p. 29)
- Burel, Gilles. 2001. *Introduction au traitement d'images simulation sous matlab*. Hermes science. (p. 39)
- Burger, W., & Burge, M.J. 2008. *Digital image processing : An algorithmic Introduction Using Java*. Springer. (p. 40, 181)

- Burger, Wilhelm, & Burge, M.J. 2009. *Principles of digital image processing : Core algorithms*. 1 edn. Springer. (p. 46)
- Butt, Hans-Jürgen, Graf, Karlheinz, & Kappl, Michael. 2023. *Physics and chemistry of interfaces*. John Wiley & Sons. (p. 137)
- Casas, Nathalie, Mollon, Guilhem, & Daouadji, Ali. 2022. DEM analyses of cemented granular fault gouges at the onset of seismic sliding : peak strength, development of shear zones and kinematics. *Pure and Applied Geophysics*, jan. (p. 19)
- Chen, Qipeng, Xie, Qingsheng, Yuan, Qingni, Huang, Haisong, & Li, Yiting. 2019. Research on a Real-Time Monitoring Method for the Wear State of a Tool Based on a Convolutional Bidirectional LSTM Model. *Symmetry*, **11**(10). (p. 107)
- Cho, Unchung, & Tichy, John A. 2000. Quantitative correlation of wear debris morphology : Grouping and classification. *Tribology International*, **33**(7), 461–467. (p. 50, 62)
- Chung, Yip-wah, & Wang, Q Jane. 2013. *Encyclopedia of tribology : With 3650 Figures and 493 Tables*. Springer. (p. 19, 25)
- Coulomb, Charles Augustin. 1821. *Théorie des machines simples en ayant égard au frottement de leurs parties et à la raideur des cordages*. Bachelier. (p. 29)
- Debayle, Johan. 2019. Geometrical and morphometrical tools for the inclusion analysis of metallic alloys. *Metallurgical Research & Technology*, **116**(5), 508. (p. 86)
- Derjaguin, Boris V, Muller, Vladimir M, & Toporov, Yu P. 1975. Effect of contact deformations on the adhesion of particles. *Journal of Colloid and interface science*, **53**(2), 314–326. (p. 27)
- Descartes, S., Courtieux, L., Berthier, Y., & Peditto, F. 2015. Tribological study of oral care silica. *Tribology International*, **82**(PB), 551–560. (p. 19, 80)
- Descartes, Sylvie. 1997. *Lubrification solide a partir d'un revêtement de MoSx : conséquences de la rhéologie et des débits de troisième corps sur le frottement*. Ph.D. thesis. Thèse de doctorat dirigée par Berthier, Yves Mécanique Lyon, INSA 1997. (p. 20, 33, 35, 36, 39, 81, 181)
- Descartes, Sylvie, & Berthier, Yves. 2002. Rheology and flows of solid third bodies : Background and application to an MoS1.6 coating. *Wear*, **252**(7-8), 546–556. (p. 33, 39, 80, 181)
- Di Bartolomeo, M., Massi, F., Baillet, L., Culla, A., Fregolent, A., & Berthier, Y. 2012. Wave and rupture propagation at frictional bimaterial sliding interfaces : From local to global dynamics, from stick-slip to continuous sliding. *Tribology International*, **52**, 117–131. (p. 114)
- Dice, Lee R. 1945. Measures of the amount of ecologic association between species. *Ecology*, **26**(3), 297–302. (p. 91)
- Donaldson, Kenneth, Ian Gilmour, M, & MacNee, William. 2000. Asthma and PM10. *Respiratory research*, **1**(1), 12–15. (p. 19)

- Efford, N. 2000. *Digital Image processing : A practical introduction using java*. (p. 40, 43, 181, 182)
- Fairchild, Mark D. 2013. *Color appearance models*. John Wiley & Sons. (p. 40)
- Faure, Alain. 2006. *Classification et commande par réseaux de neurones*. Hermes sciences. (p. 55)
- Fillot, N., Iordanoff, I., & Berthier, Y. 2007. Wear modeling and the third body concept. *Wear*, **262**(7), 949–957. (p. 31)
- Fillot, Nicolas. 2004. *Etude mécanique de l'usure : Modélisation par Eléments Discrets des débits de troisième corps solide*. Ph.D. thesis. Thèse de doctorat dirigée par Berthier, Yves Mécanique Lyon, INSA 2004. (p. 37)
- Fillot, Nicolas, Iordanoff, Ivan, & Berthier, Yves. 2004. A Granular Dynamic Model for the Degradation of Material. *Journal of Tribology*, **126**(3), 606. (p. 19, 37)
- Frache, L., Komba, E. Houara, Philippon, D., Galipaud, J., De Barros, M.I., Douillard, T., Masenelli-Varlot, K., Bouscharain, N., Maheo, Y., Sarlin, R., Le Jeune, G., Berthier, Y., Bou-Said, B., & Massi, F. 2021. Observation of a modified superficial layer on heavily loaded contacts under grease lubrication. *Tribology International*, **158**(2020), 106921. (p. 35)
- Frache, Lucas. 2022. *Tribological characterization of heavily loaded oscillating bearings in aeronautics : dependence of lifecycles and contact accommodation mechanisms on grease lubrication*. Ph.D. thesis. (p. 35)
- Gatos, HC. 1968. Structure of surfaces and their interactions. *NASA, WASHINGTON INTERDISCIPLINARY APPROACH TO FRICTION AND WEAR 1968*. (p. 29)
- Gavet, Yann, & Debayle, Johan. 2019. *Image Processing Tutorials with Python®*. (p. 41, 42, 44, 46, 181, 182)
- Genuer, Robin, Poggi, Jean-Michel, & Tuleau-Malot, Christine. 2010. Variable selection using random forests. *Pattern recognition letters*, **31**(14), 2225–2236. (p. 57, 58, 67, 108)
- Georges, Jean-Marie. 2000. *Frottement, usure et lubrification : tribologie ou science des surfaces*. CNRS éditions. (p. 29)
- Glaeser, William A. 2012. *Characterization of tribological materials*. Momentum Press. (p. 27)
- Glasbey, C. A., & Horgan, G. W. 1997. Image Analysis for the Biological Sciences. *Biometrics*, **53**(2), 783. (p. 40, 45, 182)
- Godet, Maurice. 1984. The third-body approach : A mechanical view of wear. *Wear*, **100**(1-3), 437–452. (p. 20, 32)
- Gonzalez, Rafael C., Woods, Richard E., & E, Steven L. 2003. *Digital image processing using MATLAB*. (p. 39, 181)

- Gourieroux, Christian, & Monfort, Alain. 1995. *Statistics and econometric models*. Vol. 1. Cambridge University Press. (p. 103)
- Gras, René. 2008. *Tribologie : Principes et solutions industrielles*. L'Usine nouvelle. (p. 31)
- Greenwood, James A, & Williamson, JB Pl. 1966. Contact of nominally flat surfaces. *Proceedings of the royal society of London. Series A. Mathematical and physical sciences*, **295**(1442), 300–319. (p. 27)
- Guo, Zhiqiang, Xu, Lina, & Asgharzadeholiaee, Nona Ali. 2022. A Homogeneous Ensemble Classifier for Breast Cancer Detection Using Parameters Tuning of MLP Neural Network. *Applied Artificial Intelligence*, **36**(1), 2031820. (p. 58)
- Géron, Aurélien. 2019. *Machine learning avec Scikit-learn*. Dunod. (p. 56, 57, 58, 89, 108, 109, 127)
- Habba, Abdelaziz, & Ishak, Omar. 2019. *La classification des images satellitaires par l'apprentissage profond (Deep learning)*. Ph.D. thesis, Université Ahmed Draia - Adrar. (p. 63, 182)
- Haralick, Robert M. 1979. Statistical and structural approaches to texture. *Proceedings of the IEEE*, **67**(5), 786–804. (p. 95)
- Hertz, H. 1881. H. Hertz, Über die Berührung fester elastischer Körper, Journal für die reine und angewandte Mathematik 92, 156-171 (1881). *Journal für die reine und angewandte Mathematik*, **171**, 156–171. (p. 25, 27)
- Hertz, Heinrich. 1882. Ueber die Berührung fester elastischer Körper. (p. 25, 27)
- Hinton, Geoffrey E. 1990. Connectionist learning procedures. *Pages 555–610 of : Machine learning*. Elsevier. (p. 53)
- Jaccard, Paul. 1902. Distribution comparée de la flore alpine dans quelques régions des Alpes occidentales et orientales. *Bulletin de la Murithienne*, 81–92. (p. 91)
- Jaza, Rabii. 2020. *Towards a prediction of the tribological behaviour of a contact with third body particles : Relating the morphological descriptors of the third body particles with the rheological parameters of the contact*. Ph.D. thesis, Université de Lyon. (p. 107)
- Jaza, Rabii, Mollon, Guilhem, Descartes, Sylvie, Paquet, Amandine, & Berthier, Yves. 2016. Relating the morphological description of the third body to its rheological behaviour. *Plants Invade the Land*, 1–2. (p. 39, 49, 50, 59, 102, 110, 182)
- Jaza, Rabii, Mollon, Guilhem, Descartes, Sylvie, Paquet, Amandine, & Berthier, Yves. 2021. Lessons learned using machine learning to link third body particles morphology to interface rheology. *Tribology International*, **153**(2021), 106630. (p. 77, 86, 93, 107)
- Johnson, Gordon R, & Cook, William H. 1983. A computational constitutive model and data for metals subjected to large strain, high strain rates and high pressures. *the Seventh International Symposium on Ballistics*, 541–547. (p. 25)
- Johnson, K. L. 1985. *Contact Mechanics*. Cambridge University Press. (p. 25)

- Johnson, Kenneth Langstreth, & Johnson, Kenneth Langstreth. 1987. *Contact mechanics*. Cambridge university press. (p. 25)
- Johnson, Kenneth Langstreth, Kendall, Kevin, & Roberts, aAD. 1971. Surface energy and the contact of elastic solids. *Proceedings of the royal society of London. A. mathematical and physical sciences*, **324**(1558), 301–313. (p. 27)
- Khichane, Madjid. 2021. *Le Machine Learning avec Python*. Edition ENI. (p. 57, 109, 117)
- Khonsari, M.M., Ghatrehsamani, Sahar, & Akbarzadeh, Saleh. 2021. On the running-in nature of metallic tribo-components : A review. *Wear*, **474-475**, 203871. (p. 34)
- Kowandy, C., Richard, C., Chen, Y. M., & Tessier, J. J. 2007. Correlation between the tribological behaviour and wear particle morphology-case of grey cast iron 250 versus Graphite and PTFE. *Wear*, **262**(7-8), 996–1006. (p. 47, 49, 50, 110, 182)
- Kowandy, C., Richard, C., & Chen, Y. M. 2008. Characterization of wear particles for comprehension of wear mechanisms. Case of PTFE against cast iron. *Wear*, **265**(11-12), 1714–1719. (p. 49, 50, 93)
- Kreider, Marisa L., Panko, Julie M., McAtee, Britt L., Sweet, Leonard I., & Finley, Brent L. 2010. Physical and chemical characterization of tire-related particles : Comparison of particles generated using different methodologies. *Science of The Total Environment*, **408**(3), 652–659. (p. 19)
- Laboratories, Stanford University. Stanford Electronics, Widrow, B., of Naval Research, United States. Office, Corps, United States. Army Signal, Force, United States. Air, & Navy, United States. 1960. *Adaptive "adaline" neuron using chemical "memistors."*. (p. 54, 55, 182)
- Lepesant, Pauline. 2013. *Mécanisme d'accomodation et débits de premiers et troisième corps à haute température : étude et modélisation phénoménologique*. Ph.D. thesis. (p. 32, 35)
- Linck, V, Baillet, Laurent, & Berthier, Yves. 2003. Modeling the consequences of local kinematics of the first body on friction and on third body sources in wear. *Wear*, **255**(1-6), 299–308. (p. 84)
- Lippmann, Richard P. 1988. An introduction to computing with neural nets. *ACM SIGARCH Computer Architecture News*, **16**(1), 7–25. (p. 52, 61, 62)
- Lundberg, Scott M, & Lee, Su-In. 2017a. Consistent feature attribution for tree ensembles. *arXiv preprint arXiv :1706.06060*. (p. 67, 123, 184)
- Lundberg, Scott M, & Lee, Su-In. 2017b. A unified approach to interpreting model predictions. *Advances in neural information processing systems*, **30**. (p. 123)
- Mackay, David J.C. 2003. *Information Theory, Inference, and Learning Algorithms*. (p. 61)
- Maillard, Philippe. 2003. Comparing texture analysis methods through classification. *Photogrammetric engineering and remote sensing*, **69**(4), 357–368. (p. 126)

- Mantz, Hubert, Jacobs, Karin, & Mecke, Klaus. 2008. Utilizing Minkowski functionals for image analysis : a marching square algorithm. *Journal of Statistical Mechanics : Theory and Experiment*, **2008**(12), P12015. (p. 94, 107)
- Marone, Chris. 1998. Laboratory-derived friction laws and their application to seismic faulting. *Annual Review of Earth and Planetary Sciences*, **26**(1), 643–696. (p. 19)
- Mate, C Mathew, & Carpick, Robert W. 2019. *Tribology on the small scale : a modern textbook on friction, lubrication, and wear*. Oxford Graduate Texts. (p. 27)
- Maugis, D, & Barquins, M. 1978. Fracture mechanics and the adherence of viscoelastic bodies. *Journal of Physics D : Applied Physics*, **11**(14), 1989. (p. 28)
- Maugis, Philippe. 1994. *Formation de composés intermétalliques Ti-Al par interdiffusion réactive en couches minces*. Ph.D. thesis, Paris 11. (p. 28)
- McNaught, Alan D, Wilkinson, Andrew, et al. 1997. *Compendium of chemical terminology*. Vol. 1669. Blackwell Science Oxford. (p. 27)
- Mickel, Walter, Kapfer, Sebastian C, Schröder-Turk, Gerd E, & Mecke, Klaus. 2013. Shortcomings of the bond orientational order parameters for the analysis of disordered particulate matter. *The Journal of chemical physics*, **138**(4), 044501. (p. 94)
- Mises, R v. 1913. Mechanik der festen Körper im plastisch-deformablen Zustand. *Nachrichten von der Gesellschaft der Wissenschaften zu Göttingen, Mathematisch-Physikalische Klasse*, **1913**, 582–592. (p. 140)
- Molinari, Alain, & Mercier, Sébastien. 2001. Micromechanical modelling of porous materials under dynamic loading. *Journal of the Mechanics and Physics of Solids*, **49**(7), 1497–1516. (p. 29)
- Molinari, Jean-François. 2022. Interactions élastiques entre aspérités de contact et usure adhesive. In : *Congrès français de mécanique (CFM 2022)*. (p. 27, 29)
- Mollon, Guilhem. 2019. Solid flow regimes within dry sliding contacts. *Tribology Letters*, **67**(4), 120. (p. 31)
- Morris, Max D. 1991. Factorial sampling plans for preliminary computational experiments. *Technometrics*, **33**(2), 161–174. (p. 58)
- NAZHESTKIN, BP, LELIKOV, OP, & VOROB'EV, AN. 1987. Etude de l'usure des matériaux lors du frottement sous vide. *Vestnik mašinstroeniâ*, 7–10. (p. 29)
- Niemueller, Tim. 2006. Automatic detection and segmentation of cracks in underground pipeline images. In : *Seminar : Medical Image Processing*. Citeseer. (p. 87)
- Noël, Bruno. 1995. *Dégradations tribologiques de contacts de géométrie conforme sollicités par impact-frottement*. Ph.D. thesis, Lyon, INSA. (p. 35, 36, 80)
- Nowell, D., & Nowell, P. W. 2020. A machine learning approach to the prediction of fretting fatigue life. *Tribology International*. (p. 65, 66, 182)
- Ojala, Timo, Pietikainen, Matti, & Maenpaa, Topi. 2002. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions*

- on pattern analysis and machine intelligence*, **24**(7), 971–987. (p. 87)
- Orellano, Pablo, Reynoso, Julieta, Quaranta, Nancy, Bardach, Ariel, & Ciapponi, Agustin. 2020. Short-term exposure to particulate matter (PM10 and PM2.5), nitrogen dioxide (NO₂), and ozone (O₃) and all-cause and cause-specific mortality : Systematic review and meta-analysis. *Environment International*, **142**, 105876. (p. 19)
- O’Shea, Keiron, & Nash, Ryan. 2015. An introduction to convolutional neural networks. *arXiv preprint arXiv :1511.08458*. (p. 53)
- Otsu, Nobuyuki. 1979. A threshold selection method from gray-level histograms. *IEEE transactions on systems, man, and cybernetics*, **9**(1), 62–66. (p. 86)
- Pashley, M.D. 1984. Further consideration of the DMT model for elastic contact. *Colloids and Surfaces*, **12**, 69–77. (p. 27)
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., Blondel, M., Prettenhofer, P., Weiss, R., Dubourg, V., Vanderplas, J., Passos, A., Cournapeau, D., Brucher, M., Perrot, M., & Duchesnay, E. 2011. Scikit-learn : Machine Learning in Python. *Journal of Machine Learning Research*, **12**, 2825–2830. (p. 57, 86, 108, 125)
- Peng, Yeping, Wu, Tonghai, Cao, Guangzhong, Huang, Sudan, Wu, Hongkun, Kwok, Ngaiming, & Peng, Zhongxiao. 2017. A hybrid search-tree discriminant technique for multivariate wear debris classification. *Wear*, **392-393**(September), 152–158. (p. 49, 50, 62, 63, 182)
- Peng, Z., & Kirk, T. B. 1998. Automatic wear-particle classification using neural networks. *Tribology Letters*, **5**(4), 249–257. (p. 49, 50, 62, 86)
- Peng, Zhongxiao. 2002. An integrated intelligence system for wear debris analysis. *Wear*, **252**(9-10), 730–743. (p. 19, 49, 50, 60, 61, 182)
- Pestana, Mielle Silva, Kalombo, Remy Badibanga, Freire Júnior, Raimundo Carlos Silveiro, Ferreira, Jorge Luiz Almeida, da Silva, Cosme Roberto Moreira, & Araújo, José Alexander. 2018. Use of artificial neural network to assess the effect of mean stress on fatigue of overhead conductors. *Fatigue and Fracture of Engineering Materials and Structures*, **41**(12), 2577–2586. (p. 65, 66)
- Prokopovich, Polina, & Perni, Stefano. 2011. Comparison of JKR- and DMT-based multi-asperity adhesion model : Theory and experiment. *Colloids and Surfaces A : Physico-chemical and Engineering Aspects*, **383**(1), 95–101. A collection of papers presented at the 14th International Conference on Surface Forces. (p. 28)
- Putignano, C, Afferrante, L, Carbone, G, & Demelio, G. 2012. The influence of the statistical properties of self-affine surfaces in elastic contacts : A numerical investigation. *Journal of the Mechanics and Physics of Solids*, **60**(5), 973–982. (p. 27, 181)
- Raschka, S., & Mirjalili, V. 2017. *Python Machine Learning : Machine Learning and Deep Learning with Python, scikit-learn, and TensorFlow, 2nd Edition*. 2e edn. Packt Publishing. (p. 51, 52, 53, 55, 57, 182)

- Rivollier, Séverine, Debayle, Johan, & Pinoli, Jean-Charles. 2010. Shape representation and analysis of 2D compact sets by shape diagrams. *Pages 411–416 of : 2010 2nd International Conference on Image Processing Theory, Tools and Applications*. IEEE. (p. 93)
- Rosenblatt, F. 1957. *The Perceptron, a Perceiving and Recognizing Automaton Project Para*. Report : Cornell Aeronautical Laboratory. Cornell Aeronautical Laboratory. (p. 54)
- Roylance, B. J., & Raadnui, S. 1994. The morphological attributes of wear particles - their role in identifying wear mechanisms. *Wear*, **175**(1-2), 115–121. (p. 20, 39, 46, 47, 48, 49, 50, 93, 107, 110, 182)
- Saltelli, Andrea, & Sobol', Il'ya Meerovich. 1995. Sensitivity analysis for nonlinear mathematical models : numerical experience. *Matematicheskoe Modelirovanie*, **7**(11), 16–28. (p. 102)
- Sayilan, Aslihan, Mary, Nicolas, Philippon, David, Steyer, Philippe, & Descartes, Sylvie. 2023. Tribological analysis of TiN film during run-in period : An in situ investigation under controlled environment in eSEM. *Surface and Coatings Technology*, **455**(02), 129228. (p. 135, 184)
- Schaller, Fabian M., Wagner, Jenny, & Kapfer, Sebastian C. 2020. papaya2 : 2D Irreducible Minkowski Tensor computation. *Journal of Open Source Software*, **5**(54), 2538. (p. 94)
- Scornet, Erwan. 2017. Tuning parameters in random forests. *ESAIM : Proceedings and Surveys*, **60**, 144–162. (p. 57, 58)
- Sieberg, Philipp M, & Hanke, Stefanie. 2023. Challenges and potentials in the classification of wear mechanisms by artificial intelligence. *Wear*, **522**, 204725. (p. 107, 137)
- Stachowiak, Gwidon W. 2006. *Wear : materials, mechanisms and practice*. (p. 32)
- Takadoun, Jamal. 2007. *Matériaux et surfaces en Tribologie*. Hermes Science Publications. (p. 26, 28, 31, 139, 181)
- Thomas, A. D.H., Davies, T., & Luxmoore, A. R. 1991. Computer image analysis for identification of wear particles. *Wear*, **142**(2), 213–226. (p. 39, 46, 49, 50, 61, 62, 187)
- Tonazzi, Davide, Massi, Francesco, Baillet, Laurent, Brunetti, Jacopo, & Berthier, Yves. 2018. Interaction between contact behaviour and vibrational response for dry contact system. *Mechanical Systems and Signal Processing*, **110**, 110–121. (p. 114)
- Tresca, H. 1864. *Mémoire sur l'écoulement des corps solides soumis à des fortes pressions, Compte-Rendu*, 59. (p. 140)
- Unsworth, A. 1991. Tribology of human and artificial joints. *Proceedings of the Institution of Mechanical Engineers, Part H : Journal of Engineering in Medicine*, **205**(3), 163–172. (p. 19)
- Vakis, A.I., Yastrebov, V.A., Scheibert, Julien, Nicola, Lucia, Dini, Daniele, Minfray, Clothilde, Almqvist, Andreas, Paggi, Marco, Lee, Seunghwan, Limbert, Georges, Molinari, Jean-François, Anciaux, Guillaume, Aghababaei, Ramin, Echeverri Restrepo, Sebas-

- tián, Papangelo, Antonio, Cammarata, Antonio, Nicolini, Paolo, Putignano, Carmine, Carbone, Giuseppe, Stupkiewicz, Stanislaw, Lengiewicz, Jakub, Costagliola, Gianluca, Bosia, Federico, Guarino, Roberto, Pugno, N.M., Müser, M.H., & Ciavarella, Michele. 2018. Modeling and simulation in tribology across scales : An overview. *Tribology International*, **125**(sep), 169–199. (p. [20](#), [181](#))
- van der Walt, Stéfan, Schönberger, Johannes L., Nunez-Iglesias, Juan, Boulogne, François, Warner, Joshua D., Yager, Neil, Gouillart, Emmanuelle, Yu, Tony, & the scikit-image contributors. 2014. scikit-image : image processing in Python. *PeerJ*, **2**(6), e453. (p. [86](#))
- Van Huffel, Sabine, & Vandewalle, Joos. 1991. *The total least squares problem : computational aspects and analysis*. SIAM. (p. [102](#))
- Wang, S., Wu, T. H., Shao, T., & Peng, Z. X. 2019. Integrated model of BP neural network and CNN algorithm for automatic wear debris classification. *Wear*, **426-427**(September 2018), 1761–1770. (p. [49](#), [50](#), [62](#), [63](#), [64](#))

LISTE DES FIGURES

1	Présentation des interactions tribologiques à plusieurs échelles : deux solides différents avec des surfaces rugueuses sont mis en contact et exposés à des charges mécaniques, thermiques, électriques et environnementales [Vakis <i>et al.</i> , 2018].	20
I.1	Contact de Hertz d'une sphère sur un plan, d'après [Takadoum, 2007]	26
I.2	A) Modèle de contact surfacique[Brunetière, 2021]. B) Exemple de simulation numérique du contact entre une surface lisse et une surface rugueuse [Putignano <i>et al.</i> , 2012]	27
I.3	Modèles de contact avec prise en compte des force attractives A) Modèle JKR : Les forces attractives sont confinées dans le contact. B) Modèle DMT : Contact de Hertz avec des forces attractives à l'extérieur de la zone de contact.	28
I.4	Frottement entre les solides 1 et 2	28
I.5	Evolution de la force de frottement en fonction de la rugosité.	30
I.6	Le triplet tribologique	32
I.7	Mécanisme d'accommodation de vitesse. Source : Semanticscholar.org. . . .	33
I.8	Le circuit tribologique. D'après [Berthier, 2005 ; Descartes & Berthier, 2002]	33
I.9	Zone de présence du troisième corps [Descartes, 1997]	35
I.10	Trace sur un pion acier observée au MEB	36
II.1	Convention de coordonnées en analyse d'images [Gonzalez <i>et al.</i> , 2003]. . . .	39
II.2	Histogramme d'une image avec $K = 16$ valeurs d'intensité possibles [Burger & Burge, 2008].	40
II.3	Cube des couleurs en système RGB [Efford, 2000].	40
II.4	Différents affichages d'une même image avec de gauche à droite : Affichage en pseudo couleurs, affichage en nuances de gris et zoom [Gavet & Debayle, 2019].	41
II.5	Egalisation d'histogramme sur une image d'osteoblaste [Gavet & Debayle, 2019]. A) Image originale. B) Image après égalisation d'histogramme. C) Histogramme de l'image originale. D) Histogramme après égalisation.	42

II.6	A GAUCHE : Importance du choix de la limite. (a) Image originale, (b) Choix de limite correcte (T=90), (c) Limite trop basse (T=40), (d) Limite trop haute (T=215). A DROITE : Histogramme de l'image originale. [Efford, 2000]	43
II.7	Segmentation d'une image couleur par la méthode des k-means [Gavet & Debayle, 2019]	44
II.8	Région ayant poussée autour du pixel (189,136) [Gavet & Debayle, 2019].	44
II.9	Fonctionnement des opérations morphologiques de base. (a) canevas de base, (b) ensemble de test, (c) érosion,(d) dilatation, (e) ouverture et (f) fermeture [Glasbey & Horgan, 1997]	45
II.10	Images de cellules biologiques [Gavet & Debayle, 2019]	46
II.11	Relation entre caractéristiques d'usure et caractéristiques de particules d'usure [Roylance & Raadnui, 1994].	47
II.12	Exemple d'analyse d'image d'une particule d'usure [Kowandy <i>et al.</i> , 2007]	47
II.13	Attributs morphologiques issus de l'analyse d'image [Roylance & Raadnui, 1994].	48
III.1	Fonctionnement simplifié du <i>machine learning</i> [Raschka & Mirjalili, 2017]	51
III.2	Caractéristiques des différents types de <i>machine learning</i> [Raschka & Mirjalili, 2017]	52
III.3	Apprentissage supervisé [Azencott, 2018]	53
III.4	Diagramme de fonction du <i>machine learning</i> [Raschka & Mirjalili, 2017]	53
III.5	Organisation des données en apprentissage supervisé [Azencott, 2018]	54
III.6	A GAUCHE : Adaline tel qu'il a été conçu en 1960 sous forme d'un dispositif analogique [Laboratories <i>et al.</i> , 1960]. A DROITE : Schéma fonctionnel "moderne" de Adaline [Raschka & Mirjalili, 2017]	55
III.7	Exemple d'analyse d'image pour extraction de caractéristiques morphologiques des particules [Jaza <i>et al.</i> , 2016]	59
III.8	DROITE : Composants du système intégré pour le logiciel <i>tribologica</i> . GAUCHE : Exemple de particules traitées par <i>tribologica</i> . [Peng, 2002]	60
III.9	Fonctionnement du système expert de <i>tribologica</i> [Peng, 2002]	61
III.10	Modèle de discrimination hybride sous forme d'arbre [Peng <i>et al.</i> , 2017]	63
III.11	Convolutional Neural Network [Habba & Ishak, 2019]	63
III.12	Evolution de la durée de vie en fatigue en fonction de la demi largeur de contact a. [Nowell & Nowell, 2020]	65
III.13	Schéma illustrant le poids de chaque feature durant la phase d'apprentissage[Nowell & Nowell, 2020]	66
IV.1	Dessin technique des disques (ici disque de 10mm d'épaisseur)	72
IV.2	Dessin technique des pions	72
IV.3	Vue 3D de la surface initiale du disque D12	73
IV.4	Tribomètre Pion-Disque	73
IV.5	Test préliminaire permettant de visualiser les étapes de la vie du contact : Evolution du coefficient de frottement moyen par tour en fonction de la distance frottée (D10P23).	74

IV.6	A) Valeur instantanée du coefficient de frottement en fonction de la position sur le disque à chaque tour. B) Évolution du COF moyen par tour.	76
IV.7	Évolution du COF moyen par tour A) Sous Atmosphère libre B) Sous Argon.	77
IV.8	Cartes de frottement de deux essais présentant A) des bandes horizontales et B) des bandes verticales	78
IV.9	Localisation des observations sur les disques et les broches - les zones d'intérêt A) sur le disque - B) sur le pion - C) ROI pour chaque zone d'intérêt sur le disque - D) Détails d'une ROI sélectionnée et analyse associée.	80
IV.10	Comparaison macroscopique du troisième corps lors de l'ouverture du contact pour des essais sous A) Argon et B) atmosphère libre. QRcode : Extrait vidéo d'un essai sous atmosphère. (SD = Sliding Direction)	81
IV.11	Comparaison des pistes de frottement pour des essais sous Argon (A) et sous atmosphère libre (B), pour une distance de 6m. (SD = Sliding Direction)	82
IV.12	Comparaison des pistes de frottement pour des essais sous Argon (A) et sous atmosphère libre (B), pour une distance de frottement de 18m. (SD = Sliding Direction)	83
IV.13	Comparaison des extérieurs de piste pour deux essais en régime établi sous Argon (A) et sous atmosphère libre (B).	83
IV.14	Carte de frottement et images associées d'un test en atmosphère libre	85
IV.15	A) Influence de l'état initial de la surface sur le seuil 1) image originale, 2) seuil Otsu . B) Seuils de segmentation pour les particules texturées 1) image originale, 2) seuil Otsu (seuil = 95), 3) seuil manuel (seuil = 75) et 4) seuil manuel (seuil = 120)	87
IV.16	Organigramme du fonctionnement général du code SIMaLea (Segmentation d'Images par MACHine LEARNING).	89
IV.17	Évaluation visuelle et qualitative du résultat de la segmentation par apprentissage automatique, A) images originales, B) images segmentées après l'étape de nettoyage.	93
IV.18	Illustration de la méthode d'exploitation de la matrice de cooccurrence des niveaux de gris (GLCM) de l'image d'entrée (a) à l'image GLCM (b). (c) illustre les relations spatiales des pixels dans le tableau des décalages de lignes et des décalages de colonnes, où D représente la distance par rapport au pixel d'intérêt. Les cercles rouges indiquent la fréquence de cooccurrence d'une combinaison différente de niveaux de gris dans l'image d'entrée et les flèches indiquent le nombre de cooccurrences dans l'image GLCM, d'après [Ahmed, 2020].	95
IV.19	Illustration des caractéristiques de texture	97
IV.20	Exemple de segmentation d'un agglomérat	98
V.1	Évolution du COF mesuré au dernier tour en fonction de la circularité et de l'élongation.	102
V.2	Évolution du coefficient de friction (COF) en fonction de A) l'homogénéité, B) l'énergie et C) l'entropie.	105
V.3	Fonctionnement du code de <i>machine learning</i>	110

V.4	Comparaison de la valeur de COF mesurée et prédite à partir de la base <i>DBpart</i>	111
V.5	Comparaison de la valeur de COF mesurée et prédite à partir de la base <i>DBpartStat</i>	112
V.6	Comparaison de la valeur de COF mesurée et prédite à partir de la base <i>DBtext</i>	112
V.7	Comparaison de la valeur de COF mesurée et prédite à partir de la base <i>DBtextPartStat</i>	113
V.8	Évolution du frottement lors d'essais en régime établi pour un disque de 10 mm d'épaisseur (A) et de 15mm d'épaisseur (B)	115
V.9	Comparaison de la valeur de COF mesurée et prédite à partir des tests produits sur des disques de 15mm d'épaisseur. En orange <i>Mesure = Prediction</i>	116
V.10	Comparaison de la valeur de COF mesurée et prédite à partir de <i>DBmix</i> . En orange <i>Mesure = Prediction</i>	117
V.11	Comparaison de la valeur de COF mesurée et prédite à partir des nouveaux tests. En orange <i>Mesure = Prediction</i>	118
V.12	Carte de frottement de l'essai D17P42	119
V.13	Influence des caractéristiques calculée avec la méthode MDI	121
V.14	Influence par permutation sur le jeu de test de <i>DBmix</i>	122
V.15	Schéma de fonctionnement des indices SHAP par [Lundberg & Lee, 2017a]	123
V.16	Influence globale des features par SHAP	124
V.17	Valeurs SHAP des features influents sur la prédiction, calculées sur le jeu de test de <i>DBmix</i>	125
V.18	Comparaison de la valeur de COF mesurée et prédite établi sur les tests supplémentaires.	128
V.19	Évaluation des features par MDI.	128
V.20	Évaluation des features par permutation.	129
V.21	Évaluation des features avec les indices SHAP.	130
VI.1	De haut en bas : Présentation du tribomètre dans le MEB, Evolution en cycles du déplacement du bras, d'après [Sayılan <i>et al.</i> , 2023]	135
VI.2	Évolution de l'homogénéité en fonction du nombre de cycles. (contact acier-acier, Pmax Hertz initiale = 1GPa)	136
VI.3	Vue des simulations avec 700 particules lors de l'ouverture du contact. De haut en bas et de gauche à droite : régime plastique P, granulaire G, aggloméré Af (cohésion faible), aggloméré Am (cohésion moyenne), aggloméré Ae (cohésion élevée)[Bouillanne <i>et al.</i> , 2022]	137
A.1	Elément de surface au point P	139
B.1	Influence de la vitesse de balayage sur l'extraction des données morphologiques du troisième corps. A) Entropy (texture). B) Contrast (texture). C) Nombre de particules éjectées. D) Elongation de 4 particules.	142
B.2	Caption	143
B.3	Caption	144

B.4	Images de texture de troisième corps pour différents voltages : A) 2kV B) 20kV.	145
C.1	Photo du disque 10	147
C.2	Photo du disque 11	148
C.3	Photo du disque 12	148
D.1	Test : D10P20 - Argon - 12m	149
D.2	Test : D10P21 - Argon - 18m	150
D.3	Test : D10P22 - Atm libre - 12m	151
D.4	Test : D10P23 - Atm libre - 18m	152
D.5	Test : D11P24 - Atm libre - 1m	153
D.6	Test : D11P25 - Atm libre - 2m	154
D.7	Test : D11P26 - Atm libre - 3m	155
D.8	Test : D11P27 - Atm libre - 6m	156
D.9	Test : D12P28 - Argon - 7.5m	157
D.10	Test : D12P29 - Argon - 18m	158
D.11	Test : D12P30 - Atm libre - 6m	159
D.12	Test : D12P31 - Atm libre - 18m	160
D.13	Test : D17P42 - Atm libre - 25m	161
D.14	Test : D151P43 - Atm libre - 25m	162
E.1	Rappel des ROI sur le disque.	163
E.2	Images de centre de piste en atmosphère libre ; essai D151P43.	164
E.3	Images d'extérieur de piste en atmosphère libre ; essai D151P43.	165
E.4	Images d'intérieur de piste en atmosphère libre ; essai D151P43.	166
E.5	Images de centre de piste sous Argon ; essai D10P21.	167
E.6	Images d'extérieur de piste sous Argon ; essai D10P21.	168
E.7	Images d'intérieur de piste sous Argon ; essai D10P21.	169

LISTE DES TABLEAUX

II.1	Corrélation entre caractéristiques morphologiques et mécanismes de génération de particules d'usure [Thomas <i>et al.</i> , 1991]	49
IV.1	Composition chimique de l'acier 35CrNiMo16	71
IV.2	Propriétés mécaniques de l'acier 35CrNiMo16	71
IV.3	Conditions expérimentales pour les essais tribologiques. (Avec T la température, HR l'humidité relative et Atm l'atmosphère)	75
IV.4	Conditions d'acquisition des images MEB.	79
IV.5	Métrique de performance des algorithmes ML (travail effectué sur les pixels)	91
IV.6	Évaluation des deux distances entre les images segmentées par apprentissage automatique et la "vérité terrain". Pour des raisons mathématiques, D _{jac} est toujours plus grand que D _{dice}	92
V.1	Indices de Sobol pour l'analyse des paramètres morphologiques.	104
V.2	Indices de Sobol calculés pour l'analyse des paramètres de texture.	106
V.3	Description des bases de données construites à partir des caractéristiques morphologiques de troisième corps.	108
V.4	Métriques de performance des forêts aléatoires évaluées sur le <i>jeu de test</i>	110
V.5	Hyperparamètres optimisés pour le traitement de la base <i>DBmix</i>	117
V.6	Performances des forêts aléatoires évaluées sur le <i>Test set</i> des bases réduites.	127
V.7	Performances des forêts aléatoires évaluées sur les tests supplémentaires en bleu dans Tableau IV.3.	127
B.1	Mesure de l'écart relatif entre les paramètres de texture calculés pour 2kV et 20kV sur les images présentée en Figure B.4	145

LISTE DES CRÉDITS

Les figures, images et photographies non créditées sont l'œuvre de l'auteur et sont partageables sous la licence CC-BY-NC-SA (attribution de l'œuvre à l'auteur, utilisation non commerciale et partage dans les mêmes conditions).



FOLIO ADMINISTRATIF

THÈSE DE L'UNIVERSITÉ DE LYON OPÉRÉE AU SEIN DE L'INSA LYON

NOM : BOUCHOT - MADRIGNAC
(avec précision du nom de jeune fille, le cas échéant)

DATE de SOUTENANCE : 11/07/2023

Prénoms : Alizée

TITRE : Identification quantitative de caractéristiques physiques des interfaces solides en lien avec les propriétés tribologiques

NATURE : Doctorat

Numéro d'ordre : 2023ISAL0048

École doctorale : Mécanique, Énergétique, Génie Civil et Acoustique (MÉGA)

Spécialité : Génie Mécanique

RÉSUMÉ : Ce travail de thèse vise à apporter de nouvelles briques de compréhension du frottement dans les contacts non lubrifiés (frottement sec). Jusqu'à présent les scénarii quant à la l'histoire du contact sont construits qualitativement. Nous nous proposons d'enrichir ces derniers à l'aide de quantifieurs relatifs à la morphologie de l'interface, nommée troisième corps. Ainsi, on va chercher à relier les caractéristiques morphologiques aux données rhéologiques tel que le coefficient de frottement (COF).

Pour cela, le travail se déroule en quatre étapes. Tout d'abord les expérimentations tribologiques, réalisées sur un tribomètre de type pion-disque, permettent l'acquisition des signaux temporels de la force tangentielle, pour plusieurs conditions d'essais. Deuxièmement, les mesures expérimentales sont analysées, i.e. évolution du COF, et l'analyse post-mortem des surfaces frottées basée sur l'acquisition des images de l'interface à l'aide d'un microscope électronique à balayage. La troisième étape consiste en le traitement et l'analyse des images acquises. Les images sont divisées en 2 catégories : les images de particules pour lesquelles une segmentation est opérée et les images de texture sur lesquelles sont calculées les matrices de cooccurrence. Il est alors possible d'extraire des caractéristiques de ces 2 catégories, des métriques relatives à la taille et la forme des particules segmentées et des métriques statistiques d'ordre deux des matrices de cooccurrence. L'ensemble de ces données caractérise le troisième corps. La dernière étape consiste en la recherche de corrélations entre morphologies caractéristiques du troisième corps et données rhéologiques. Pour cela des bases de données sont construites et un algorithme de machine learning de type random forest (RF) est mis en place. La RF permet de réaliser des prédictions du COF à partir des caractéristiques de l'interface, ainsi que de déterminer quelles sont les caractéristiques pertinentes menant à cette prédiction. Il est finalement possible d'élaguer la liste des caractéristiques pour ne garder que les plus représentative du frottement.

MOTS-CLÉS : Contact sec, usure, MEB, troisième corps, tribologie, analyse d'image, machine learning..

Laboratoire de recherche : Laboratoire de Mécanique des Contacts et des Structures (LaMCoS)

Directeur de thèse : Sylvie DESCARTES, Johan DEBAYLE

Président de jury :

Composition du jury :