

# Sur l'utilisation du Machine Learning pour l'étude tribologique : du spectrogramme à la localisation de contact.

G. Bauman<sup>1\*</sup>, V. Magnier<sup>1</sup>, H. Wannous<sup>2</sup>

<sup>1</sup> Univ. Lille, CNRS, Centrale Lille, UMR 9013 - LaMcube - Laboratoire de Mécanique, Multiphysique, Multiéchelle, F-59000 Lille, France

\* corresponding author: guillaume.bauman@univ-lille.fr

<sup>2</sup> Ceri SN, IMT Nord Europe

---

**Résumé** — Les performances de freinage (frottement, bruit, usure etc.) restent encore mal maîtrisées en raison des conditions de contact qui reste, en apparence, « chaotique ». Malgré les efforts importants sur le développement de modélisations, les simulations numériques restent encore très éloignées de la réalité. Afin de pallier à cet écueil, une stratégie de compréhension et de quantification du « chaos » est opérée. En utilisant le machine learning, nous montrons qu'on arrive à classifier les phénomènes tout en liant les aspects multi-physique, nous permettant d'avancer vers du "smart braking".

**Mots clés** — Tribologie, approche multi-physique/multi-modale, Machine learning

---

## 1 Introduction

Les modélisations adéquates traitant de problèmes de freinage sont obligées de considérer les aspects multi-physique et multi-échelle afin de représenter au mieux la réalité. Des stratégies d'enrichissement ont été développées ces dernières années [1],[2] etc. mais restent encore très éloignées de la réalité expérimentale. La complexité des phénomènes et la présence du troisième corps notamment compliquent fortement l'étude des phénomènes de contact au sein du système. De ce fait, la littérature classique tend à admettre la nature chaotique du système, et essaye alors d'étudier l'influence de certains paramètres (matériaux[3, 4], taille du patin[3], forme du patin[3], historique de frottement[3], etc...) un à un sur des performances globales de systèmes. L'idée avancée dans ce papier est de proposer une méthodologie afin de structurer et d'organiser les phénomènes. Plus précisément, un changement de paradigme est opéré en traitant les informations multi-modales issues d'essais expérimentaux fortement instrumentés (bruit, thermocouples, etc.). Des méthodes de machine learning adaptées sont ainsi proposées.

## 2 Dispositif expérimental et données d'essais

### 2.1 Dispositif expérimental

Le dispositif expérimental utilisé pour ce travail est constitué d'un banc d'essai de type "pin-on-disc" instrumentés de nombreux capteurs. Plus précisément, l'instrumentation utilisée ici est composé d'un micro, de thermocouples noyés dans le patin en proche surface de contact, ainsi que des capteurs de mesure de forces appliquées sur le patin et de déplacement perçus du patin. Ci-dessous une photo/schéma du dispositif expérimental et du pion.




FIGURE 1 – Dispositif expérimental




FIGURE 2 – A gauche : Pion avec lame. A droite : position et dénomination des thermocouples sur le pion

Afin d’entraîner des modèles d’intelligence artificielle, le dispositif décrit plus haut a été utilisé pour générer 584 essais de freinages avec des paramètres différents (force, vitesse, durée essais). Pour chaque essai, nous avons relevé les variables suivantes :

- Bruit via micro (50000 Hz)
- Forces appliquées en différents points (50000 Hz)
- Déplacements perçus en différents points (50000 Hz)
- Températures en différents points du patin (90 Hz)

## 2.2 Description des données du micro

On s’intéresse dans ce papier en première intention aux phénomènes sonores générés durant les différents freinages. En effet, nous considérons que les résultats spectraux sont une signature à la fois du système et de son interface. Afin de se faire une idée plus concrète, quelques spectrogrammes (résultat de STFT) sont illustrés en figure 3.




FIGURE 3 – Exemples de spectrogrammes obtenus

Les spectrogrammes présentés ci-dessus ont été obtenu en utilisant le dispositif expérimental dans des conditions d'essais similaires. Malgré cela, on observe des comportements radicalement différents. L'idée avancée dans ce papier est que le spectrogramme sonore est une signature des phénomènes se passant au contact, dont la complexité expliquerait la diversité des spectrogrammes obtenus. Malgré cette apparence chaotique (au sens qu'il ne parait pas y avoir d'organisation claire), l'objectif de ce papier est alors de proposer une méthode permettant de "clusteriser" les phénomènes et de s'attacher à les associer à des phénomènes physiques.

### 3 Étude des états temporels sonores

À travers ce papier, nous essayons de montrer que la surface de contact détermine le bruit émis lors des essais. Pour ce faire, nous avons décidé d'étudier les relations entre les spectrogrammes de bruits et les autres variables. À cet effet, on nommera dans la suite "état temporel sonore" la valeur prise par le spectrogramme du bruit à un temps fixé au cours d'un essai.

#### 3.1 Clustering d'états temporels sonores

Pour faciliter notre étude, nous avons décidé de regrouper les états temporels sonores en groupes à l'aide d'algorithmes de clustering<sup>1</sup>. Par la suite, nous avons considéré qu'il n'y avait pas de perte d'information en binarisant les données avec un seuil fixé à 70 dB ("La fréquence "t" à l'instant "s" a été exprimée à plus de 70 dB ou non"). Nous avons donc établi une base de données en échantillonnant 100 états temporels sonores par spectrogrammes binarisés de la base de données :

1. Le clustering est une tâche de Machine Learning non supervisée visant à regrouper des données sans avoir d'informations sur les groupes *a priori*.




FIGURE 4 – Création base de données d'états temporels sonores

Les phénomènes sonores observés durant les essais de freinage se manifestent principalement sous la forme de barre horizontale sur les spectrogrammes, ce qui est relativement peu complexe et nous fait donc espérer obtenir de bons résultats assez facilement. Cependant, les premiers résultats que nous avons obtenu n'étaient pas convainquant. En "zoomant" sur les spectrogrammes, on observe une légère dispersion fréquentielle 5, ce qui pose des problèmes aux algorithmes de clustering envisagés.




FIGURE 5 – Spectrogramme d'un essai entier à gauche, et zoom sur une certaine bande de fréquence à droite.

Certaines bandes de fréquence exprimées ne sont pas densément peuplées. Cela empêche nos algorithmes de les détecter avec un choix de distance classique pour les variables binaires (distance de Hamming). Pour palier ce problème, nous avons introduit la mesure de dissimilarité suivante :

**Définition : 1** (Dissimilarité entre états temporels sonores). On définit le nombre de fréquence exprimée par  $u$  et non par  $v$  selon une marge  $d$  comme :

$$D_d(u, v) = \sum_{i=1}^n u_i * \mathbb{1}_{C_d(v, i)} \text{ où } C_d(v, i) = \left( \sum_{j=\max(1, i-d)}^{\min(n, i+d)} v_j \right) > 0$$

On définit alors :

$$\text{dissim}_d(u, v) = D_d(u, v) + D_d(v, u) \quad \square$$

La figure 6 illustre cette dissimilarité.




FIGURE 6 – Explication du nombre de fréquences exprimées par  $u$  et non par  $v$

Finalement, en utilisant cette mesure et l'algorithme Kmodes[5, 6], nous avons réussi à obtenir 11 groupes visuellement différents. Ci-dessous, un exemple de groupes d'état temporel sonore obtenu :





FIGURE 7 – Groupe obtenu en clustering d'état temporel sonore. Chaque colonne est un état temporel sonore, et les états représentés viennent des spectrogrammes de l'ensemble de la base de données.

Les groupes obtenus sont cohérents. Par la suite, nous essayons de trouver des relations entre l'appartenance à ces différents groupes et la variation de la température à l'intérieur du patin pour avoir une interprétation physique des phénomènes.

### 3.2 Analyse descriptive de relations entre état temporel sonores et température du patin

Le but de cette partie est de trouver des relations entre l'appartenance aux groupes d'état temporels sonores et la température locale à l'intérieur du patin qui représente donc un état de contact. En appliquant quelques opérations d'upsampling et de découpe des données, nous sommes capables de déterminer l'évolution de la température correspondant à un état temporel sonore (la STFT se basant sur des fenêtres des données). Après avoir testé plusieurs quantités d'intérêt (Température, gradient de température etc.), nous avons choisi d'étudier la moyenne des accroissements de températures correspondant aux individus des groupes des états temporels sonores définis précédemment. Les résultats obtenus pour quelques groupes sont représentés en figures 8






FIGURE 8 – Travail sur l'accroissement moyen de la température du patin pour 3 groupes d'états temporels sonores. A gauche : Moyenne d'accroissement de la température avec localisation sur le patin. A droite : Interval Bootstrap[7] "bca" des moyennes à 99% avec correction de bonferroni[8]

Lorsque deux intervalles bootstrap des moyennes ne s'intersectent pas, on peut dire à 99% que pour ce groupe d'état temporels sonores, le patin chauffe plus en une localisation qu'un autre. Par exemple, pour le premier graphe, on voit que la localisation "TC\_BE\_S" chauffe beaucoup moins que les autres (la localisation tend même à décroître en température).

## 4 Conclusions

Nous avons réussi à mettre en place une démarche multi-modale des phénomènes sonores apparaissant durant les freinages. Nous avons pu également identifier et associer les comportements thermiques correspondant aux groupes de comportements sonores. Les observations ont montré que des différences de comportement apparaissait d'un groupe à l'autre. Ces résultats ne sont pas anodins car l'augmentation de température étant due à la pression, on peut faire des hypothèses sur la topologie de surface à partir des graphes précédents : par exemple, si la température augmente sur une localisation particulière, on peut imaginer que le contact se concentre dans cette zone spécifique. Ce travail nous permet donc, à partir du bruit émis lors des essais d'émettre des hypothèses sur la topologie de contact qui est un point clé en vue des dimensionnement des systèmes de frein (usure, bruit, etc.).

## 5 Perspectives

Ce travail nous montre l'intérêt que peut avoir l'application de méthodes de machine learning à des domaines tel que la tribologie. Il reste cependant encore des pistes d'amélioration :

- Premièrement, l'analyse effectuée en 3.2 ne tient pas en compte du moment de l'essai car une moyenne est effectuée : on comprends assez bien que la température augmente plus rapidement au début qu'à la fin du freinage. Il serait donc intéressant de trouver une analyse prenant en compte ces informations.
- Deuxièmement, il serait intéressant de ré-appliquer la même démarche sur des données générées à partir de matériaux différents. Cela serait intéressant, car même si les conclusions ne sont pas les mêmes, appliquer la méthode développée dans ce papier pourrait être une manière de caractériser les phénomènes sonores/thermiques de différents matériaux.

## Références

- [1] *Multiscale thermomechanical strategies for rough contact modeling : application to braking systems* , PhD Thesis, 2017.
- [2] I. Temizer, P. Wriggers *A multiscale contact homogenization technique for the modeling of third bodies in the contact interface*, Comput. Methods Appl. Mech. Eng. 198, 495–510, 2008

- [3] Martin Duboc *Etude multi-échelle du crissement : dispositif expérimental et éléments de compréhension*, PhD Thesis, 2013.
- [4] Davis Naidoo Ramasami *Influence of friction material test sequence on disc brake squeal*, PhD thesis, 2014.
- [5] Zhexue Huang, *CLUSTERING LARGE DATA SETS WITH MIXED NUMERIC AND CATEGORICAL VALUES*, 1997
- [6] Nelis J. de Vos, *kmodes categorical clustering library*, <https://github.com/nicodv/kmodes>, 2015
- [7] Thomas J. DiCiccio, Bradley Efron, *Bootstrap confidence intervals*, *Statistical Science*, 1996, vol 11, pages 189-228.
- [8] [https://en.wikipedia.org/wiki/Bonferroni\\_correction](https://en.wikipedia.org/wiki/Bonferroni_correction)