

1- Mise en contexte et introduction

Les véhicules autonomes ajustent leurs trajectoires grâce aux données fournies par leurs capteurs. Cependant, la plupart sont conçus dans des régions sans hiver, où l'adhérence optimale entre pneus et chaussée est présumée. Dans les climats froids, cette hypothèse devient erronée. Un conducteur humain adapte instinctivement sa conduite face à des adhérences réduites.

Comment un véhicule autonome peut-il détecter et intégrer ces variations pour garantir la sécurité ? En utilisant le comportement du pneu directement.

2 - Objectifs de recherche

Créer un système qui, en captant la signature acoustique et vibratoire du pneu, classe l'état des pneus en temps réel sur l'**asphalte** et sur **asphalte recouverte de neige ou de glace**:

- Détection** du glissement complet (dérapage).
- Prévision** du glissement avec une précision près de 100%.

3.1 – Méthodologie : Instrumentation




Figure 1: Caméras de détection de la force latérale sur le pneu




Figure 2: Montage des accéléromètres et du microphone en arrière du pneu (retiré dans l'image)

Le véhicule nécessite des capteurs et un système d'acquisition numérique (non illustré) pour la collecte de données acoustiques et vibratoires.

- ① Ensemble de caméras haute et basse vitesse
- ② Accéléromètre 3D basse fréquence
- ③ Accéléromètre 1D haute fréquence
- ④ Microphone IP67 classe 1

3.3 – Méthodologie : Transformée d'ondelettes continues

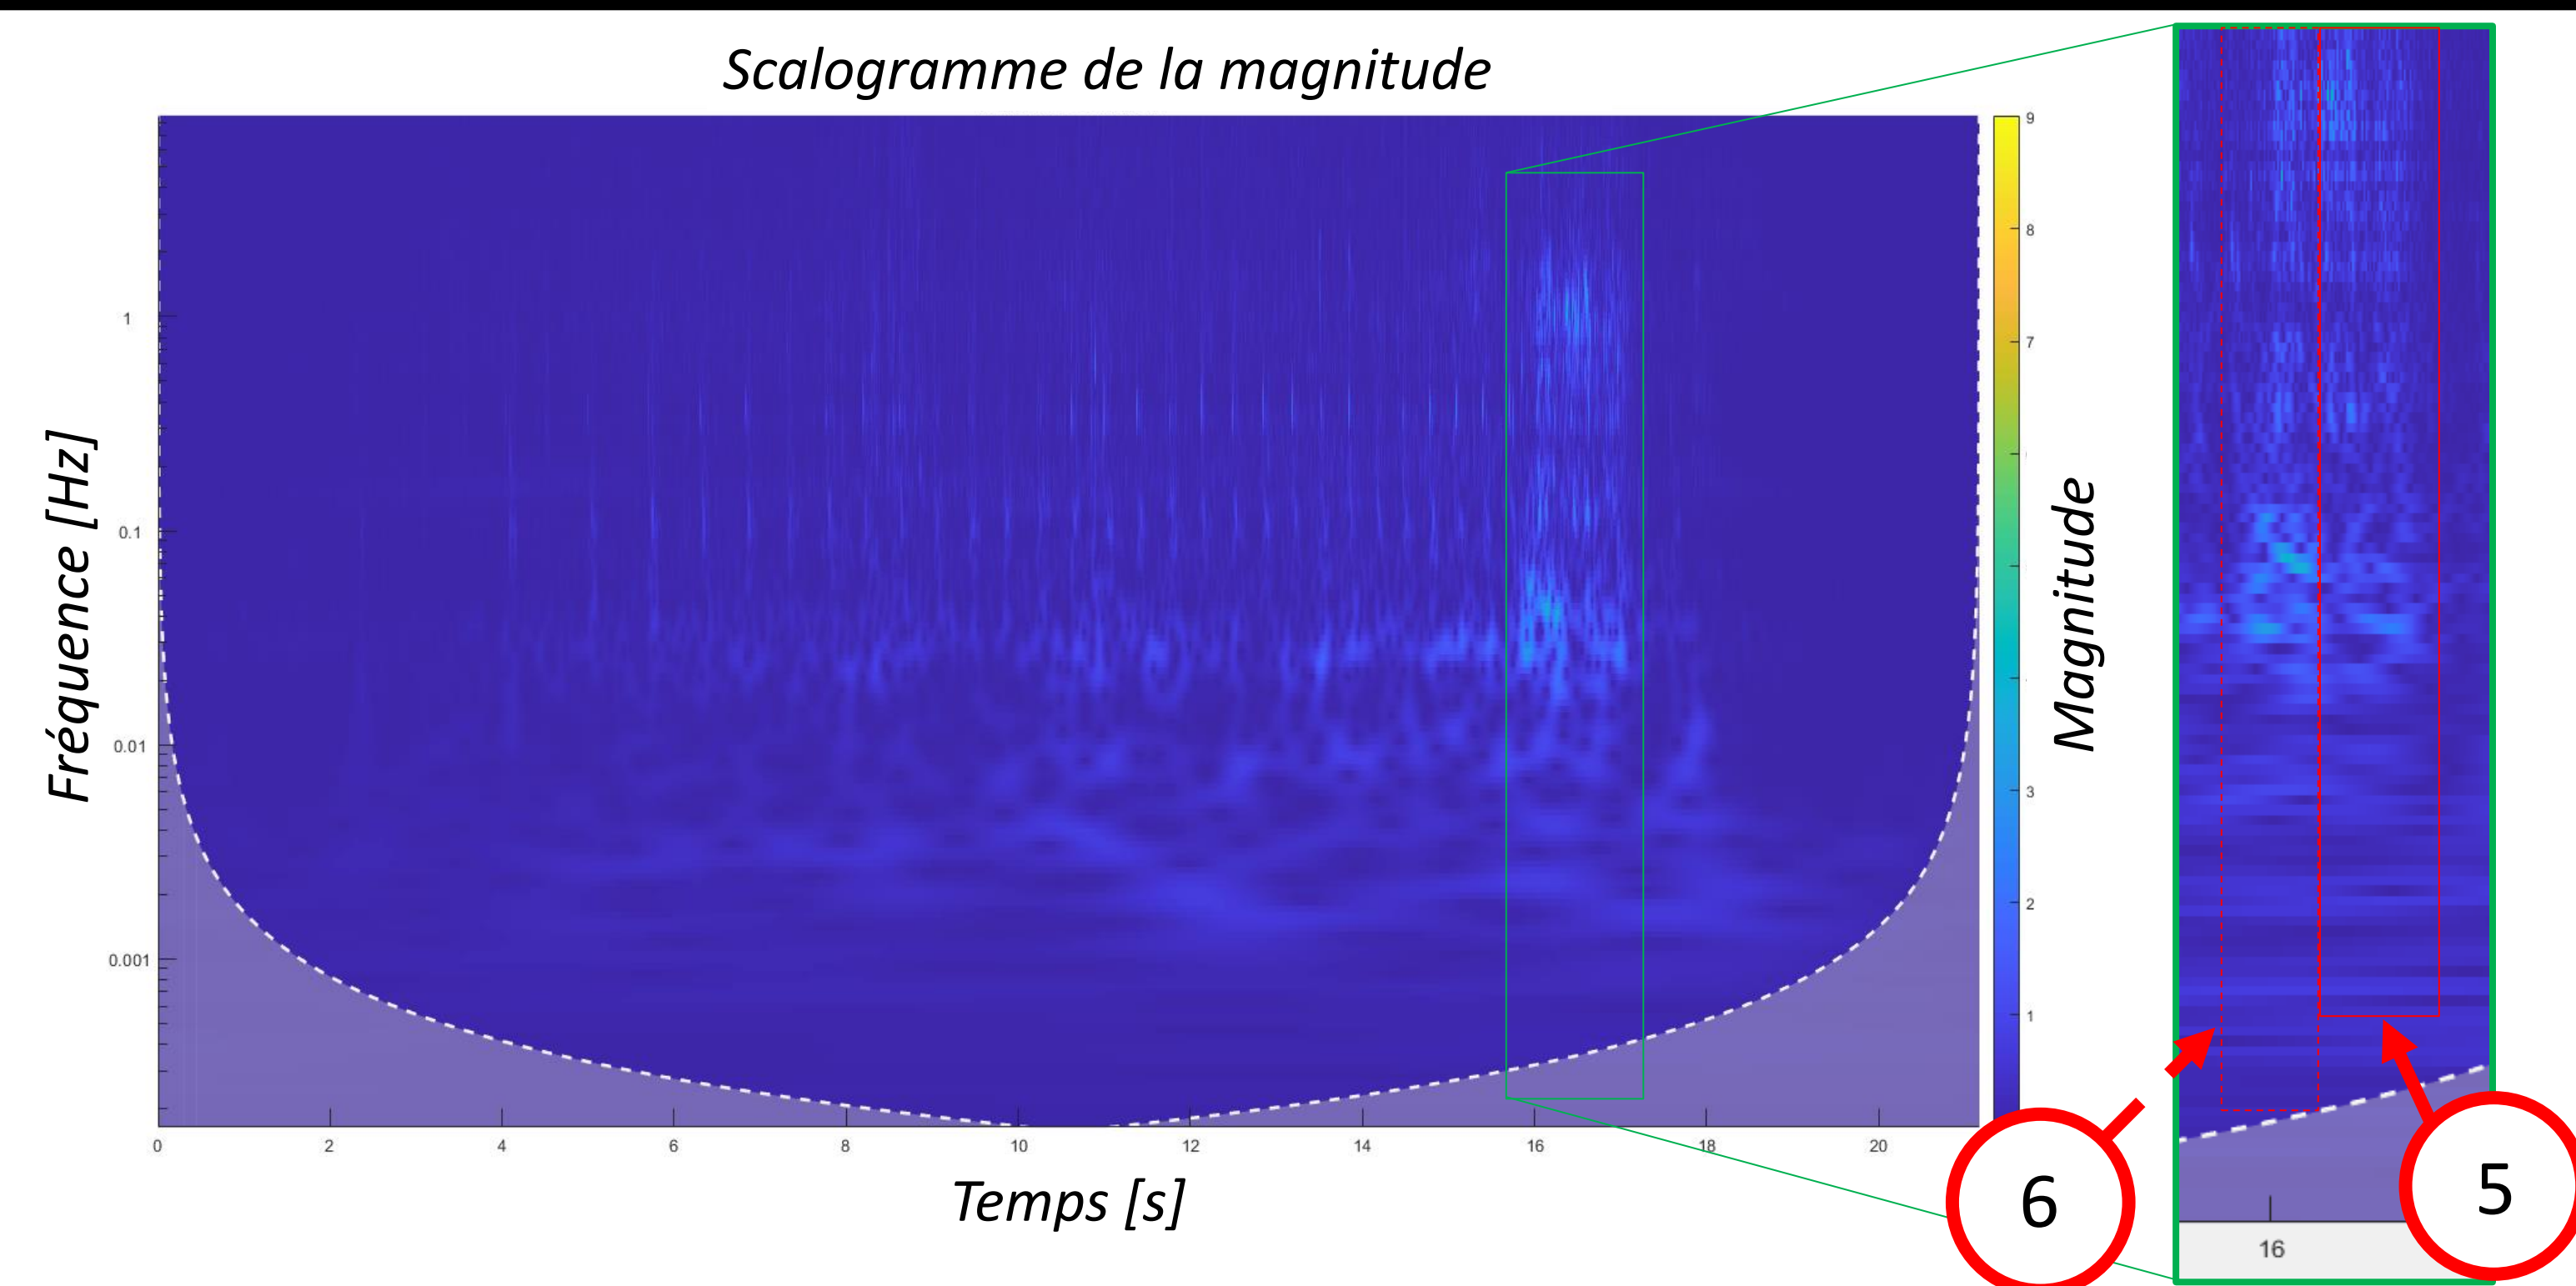


Figure 6: transformée d'ondelettes continues, l'échelle du temps est la même que celle de l'acquisition acoustique.

La transformée d'ondelettes continues permet d'analyser les signaux en décomposant les données en **composantes de fréquence et de temps**, offrant ainsi une représentation détaillée et localisée des variations du signal [1,2].

- ⑤ Zone de glissement identifié par l'analyse du flanc du pneu
- ⑥ Zone de prévision du glissement (pneu fortement sollicité, sans décrochage)

4 - Résultats

Le système de collecte et d'analyse des données fonctionne parfaitement. Les données préliminaires démontrent que le réseau de neurones optimisé est à la fois rapide et performant. La prévision du glissement se fait suffisamment rapidement permettant un changement de trajectoire évitant le glissement complet.

État réel	Classification		
	Normal	Pré-glissement	Glissement
Normal	3040	1	95
Pré-glissement	1	95	2
Glissement			35

Figure 8: Résultats de la classification

3.2 – Méthodologie : Collecte et préparation des données

Des caméras enregistrent la déformation du flanc du pneu, permettant de détecter son état et d'identifier temporellement les glissements. Les signaux acoustiques et vibratoires sont filtrés à l'aide d'un filtre passe-bande de 100 à 10 000 Hz. Cependant, dans le domaine temporel, aucun motif clair n'émerge de ces données.




Figure 3: Le pneu à l'instant **avant** le glissement. Notez l'absence complète du flanc du pneu dans l'ovale.



Figure 4: Le pneu à l'instant **après** le glissement. Notez le flanc du pneu dans l'ovale à la suite de la réduction de l'effort latéral lors de l'interaction entre le pneu et la chaussée.




Figure 5: Acquisition des signaux acoustiques (en vert). Le début du glissement est indiqué sur la figure (en orange).

3.4 – Méthodologie : Détection par réseau de neurones




Figure 7: Structure d'un réseau de neurones avec délai temporel.

La phase finale consiste à entraîner un réseau de neurones à délai temporel pour classifier l'état du pneu. La prise en compte de la causalité dans l'évolution du comportement du pneu est essentielle, ce qui est intégré grâce au délai temporel du réseau. Ce réseau permet de classer l'état du pneu en trois catégories : normal, fortement sollicité (prévision du glissement) ou en glissement complet.

5 - Conclusion

Le projet a réussi à classifier en temps réel sur l'asphalte:

- La **détection** du glissement se fait à 100% de précision.
- La **prévision** se fait plus de 0,2 s avant le glissement à 99% de précision.

Les essais hivernaux sont terminés. Les données doivent être traitées pour voir si la détection et prévision sont aussi performantes en conditions hivernales.

Références

- [1] Lilly, J. M., and S. C. Olhede. Generalized Morse Wavelets as a Superfamily of Analytic Wavelets. IEEE Transactions on Signal Processing 60, no. 11 (November 2012): 6036–6041. <https://doi.org/10.1109/TSP.2012.2210890>.
- [2] Wang, X. (Ed.). (2020). Automotive tire noise and vibrations: Analysis, measurement and simulation. Butterworth-Heinemann.
- [3] Rodríguez-López, M. A., López-González, L. M., López-Ochoa, L. M., & Las-Heras-Casas, J. (2018). Methodology for Detecting Malfunctions and Evaluating the Maintenance Effectiveness in Wind Turbine Generator Bearings Using Generic versus Specific Models from SCADA Data. Energies, 11(4), 746.

Remerciements



Canada
Research
Chairs

Chaires
de recherche
du Canada

