

RAPPORT - TP 3

IA semi-supervisée




fig. 1 : Illustration

Détection d'anomalies à l'aide d'images - Auto Encodeur

Encadrant : M. Ivan VAZQUEZ-MUNOZ
M. D. KNITTEL

12/03/2026

Question 1 : Transformée de Fourier

Dans cette première partie, je vous montre seulement une fenêtre de chaque signal de A à F, respectivement.

On remarque dans la figure 2, un pic fin dans les 22 kHz quasiment pour tous les signaux, ceci vient bien sûr des harmoniques de hautes fréquences liées à la rotation mécanique de la machine.

Le spectre est bien sûr propre avec une décroissance progressive vers les hautes fréquences.




fig. 2 : Figure FFT fenêtre

Pour la figure 3 ci-après, on peut distinguer les 3 types d'états, donc normal, défaut type 1 et défaut type 2.

On voit éventuellement que le signal A ressemble beaucoup au signal E, de même pour le signal B avec le signal D, ainsi que les signaux C et F.

L'énergie haute au niveau des basses fréquences est normal pour tous les signaux comme dit c'est la fondamentale, mais parmi les signaux affectés de défauts machines C-F et B-D, on voit effectivement qu'il y a des traces de hautes énergies dans les fréquences allant de 0 à 10 kHz, ceci montre effectivement qu'il y a des défauts mécaniques liés à la rotation de la machine.

Remarque : On peut aussi s'apercevoir qu'au cours du temps les fréquences pour lesquelles il y a une certaine énergie haute (en rouge) est constante.




fig. 3 : Figure du spectrogramme avec recouvrement de 50% (pas normalisé)

Ici, l'erreur que j'ai fais c'est de ne pas normaliser les spectrogrammes (images 2D), ce qui m'a coûté en temps de calcul et en temps de descente vers une bonne loss rapidement. J'ai donc dû observé beaucoup d'oscillations lors de l'entraînement

On voit le résultat qui n'est pas bon (pas lisse) en figure 7.

Ci-dessous le spectrogramme 2D normalisé en 0 et 1.




fig. 4 : Figure du spectrogramme avec recouvrement de 50% (normalisé)




fig. 5 : Figure Spectres normalisés des 6 signaux

Dans cette figure 4, on a normalisé entre 0 et 1 les spectres. On voit que les basses fréquences sont similaires pour les signaux A-E puis de même pour les signaux C-F affectés de défauts machines.

Question 2 : Auto Encodeur

Dans cette partie, j'ai entraîné un auto encodeur sur le signal A uniquement, et je tombe sur une bonne erreur MSE (Mean squared Error).

On peut différencier légèrement les signaux A-E sous le seuil que j'ai fixé, puis les signaux B-D qui sont plutôt en défaut machine similaires. Donc ici, on remarque qu'à cause de l'image 2D pas normalisée, on a beaucoup de variations pour chaque signal ce qui nous pousse à confondre entre les défauts type 1 ou 2 car elles sont proches. Et j'ai aussi appris que 1800 epochs étaient inutiles pour rien, donc je l'ai corrigé à 200.




fig. 6 : Figure Auto encodeur uniquement le signal A




fig. 7 : Figure entraînement Auto encodeur (pas lisse)

J'ai donc normalisé le spectrogramme 2D de la question 1, et de nouveau enregistré un fichier "spectres_2D" qui contient l'image en taille 2501 x 294.



fig. 8 : Figure entraînement Auto encodeur (bien lisse)

Ensuite, j'ai de nouveau entraîné le modèle d'auto encodeur et là, la magie opère j'ai une meilleure descente et beaucoup plus lisse, ce qui change la totalité de mes résultats en figure 9 !



fig. 9 : Figure Auto encodeur uniquement le signal A (plus nette)

Je peux maintenant mieux différencier les types de défauts, car il y a moins d'oscillations. Cependant, pour la décision binaire de l'état des signaux, on remarque quelques tâches au niveau du signal E (en vert), ceci est normal car c'est le seuil (threshold) qui touche un peu les pics du signal E. Autrement, avec un léger ajustement du seuil ceci devrait disparaître.

On voit aussi en figure 10 que les signaux sont quand-même bien répartis en terme d'erreur quadratique moyenne, les signaux sont bien comparables et nets.




fig. 10 : Distribution des erreurs de reconstruction (MSE / signal)

Daniel BAL

M1 MESI - TP B




fig. 11 : Reconstruction en 1D + erreur 1D

Donc, ici on voit la reconstruction, on peut remarquer que l'auto encodeur a un effet de filtration lors du décodage, mais on préfère quand-même observer cela en image 2D.




fig. 12 : Reconstruction des spectrogrammes 2D + erreur 2D

Après l'entraînement, je vois donc une reconstruction parfaite des fréquences dominantes, on remarque bien le lissage au cours du temps, ce qui nous facilite l'analyse. On peut aussi en déduire à partir de l'erreur 2D que le signal A et le signal E sont très ressemblants, carrément de même signatures fréquentiel, de par là dispersion des points bien homogènes.

Néanmoins, les signaux C-F sont similaires aussi, de par leurs concentrations en erreur surtout autour des fréquences entre 0 et 10 kHz, avec un petit pic à 22 kHz.

On remarque aussi que l'erreur moyenne du signal A est de 0.04, presque de moitié que celle du signal C. Ce qui est normal car, on a entraîné le modèle par rapport à ce que A soit normal.

Pour la question 3, un moment je voulais tester une sortie avec tanhLayer au lieu de sigmoidLayer, et j'ai compris qu'en fait c'est en lien avec l'entrée qui est située entre 0 et 1, vu que c'est normalisé. On ne peut donc pas rentrer au modèle une entrée entre 0 et 1, puis lui demander une sortie tanh situé entre -1 et 1, cela diminuerait la précision et rendrait le spectrogramme de reconstruction très instable.

Question 3 : Transformée en ondelettes

Pour cette partie, j'ai commencé par réfléchir sur pourquoi on travaille avec la transformée en ondelette, en analysant ces résultats. J'ai donc compris qu'avec une approche telle que la FFT ou les spectrogrammes basiques, on ne peut pas avoir une précision fantastique, or ces derniers utilisent une taille de fenêtre fixe.

Contrairement aux ondelettes qui offrent une précision imbattable, or il offre une approche un peu "multi-résolution", parce qu'en fait elle est très précise en fréquence dans les basses fréquences, puis très précise en temps dans les hautes fréquences.

Pourquoi tout ça ? En fait, ça va nous permettre d'avoir accès à une longueur d'onde d'informations qu'on ne peut pas trop voir avec une FFT ou spectrogramme simple. On pourra donc voir précisément à quelle signal, il y a des chocs mécaniques ou des défauts machines !

afficher les scalogrammes de chaque signal, on remarque qu'il y a une certaine signature spécifique à chaque signal.

On voit notamment que les signaux A et E se ressemblent beaucoup avec une petite différence d'énergie dans les temps égales à 70 secondes.

On voit aussi que le signal F est très agressif entre 5 et 10 kHz.




fig. 13: Scalogramme des signaux

Question 4 : Auto Encodeur avec images scalogrammes




fig. 14 : Figure Auto Encodeur avec scalogramme

On voit très concrètement dans les signaux en entrées C et F, une sorte de signature très remarquable qui n'est pas détectée par l'auto encodeur, car on le voit se reporter entièrement presque au niveau de l'erreur (MSE). De même, pour le signal E, il ressemble beaucoup au signal A.

En général, on peut dire que l'auto encodeur n'a pas appris à reconstruire correctement le signal A car je pense que c'est dû à une faiblesse au niveau de la quantité de données, (il y en a 49). Or 49 données est très faible en termes de données pour que l'IA soit une experte.

Remarque : On remarque que oui ! Le scalogramme offre une meilleure vision des chocs mécaniques ou anomalies pour l'œil humain, mais il a quand même ses limites.

Il y a plusieurs raisons pour lesquelles l'auto encodeur n'arrive pas à détecter certains défauts, le fait qu'il y a trop de vide car les chocs sont très brefs (Pulse), vu que l'IA fait la moyenne MSE, l'erreur est noyée dans la masse.

Comparaison de résultats

Critères de comparaisons	Spectrogramme FFT	Scalogramme Ondelette
Résolution	Moyenne, impossible d'être précis dans le temps et fréquence simultanément	Haute précision temporelles pour chocs
Interprétation visuelle	Bon vue	Excellente
Taille des données	Modérée, facile à manipuler	Immense, downsample
Performance AE	Très performant	Moins performant
Avantage principal	Très robuste pour la machine	Interprétabilité physique
Inconvénient principal	Les chocs rapides sont floutés ou lissés dans le temps	Trop lourd

Conclusion


En général, pour faire une détection d'anomalies, on a beaucoup d'approches possibles.

Des approches plus ou moins précises, ou des approches dans différents domaines tels que temporels, fréquentiels ou même spatiales.

Dans ces trois TP, j'ai appris une chose, c'est que selon les approches pour la détection d'anomalies, on peut interpréter plus ou moins facilement l'information.

En résumé, une meilleure représentation visuelle ne garantit pas de meilleures performances pour l'auto encodeur (IA). En gros, le choix à faire dépend du but final, si on veut automatiser la détection d'anomalies dans une usine de production, il est préférable d'utiliser le spectrogramme FFT, tandis que le scalogramme est à utiliser seulement pour le diagnostic expert humain.

On connaît bien la courbe de l'interprétabilité d'une intelligence artificielle ci-dessous.



Je pense qu'on a commencé du plus interprétable vers le moins, tout en gagnant en précision.

Tout ce que j'ai compris, c'est qu'il faut trouver l'optimum entre la précision et l'interprétabilité.

On a testé plusieurs approches pour confirmer notre interprétation de cette anomalie. On a donc obtenu une très bonne précision pour le scalogramme, on voit très bien les chocs dans le temps. De plus, l'auto encodeur a eu beaucoup de mal à

détecter les anomalies avec les scalogrammes, il a plus de facilité avec les spectrogrammes FFT.

Remarque finale :

Le spectrogramme FFT est simple et très robuste, c'est pour moi le meilleur choix pour qu'un algorithme détecte une anomalie.

Le scalogramme c'est plus détaillé, c'est le meilleur choix pour moi en tant qu'ingénieur en mécatronique, pour comprendre le comportement mécanique ou bien pour que je puisse analyser l'origine physique de l'anomalie.

Ce qui m'aidera par exemple à savoir si je devais changer les roulements à billes, les engrenages du réducteur ou même le moteur complet, avant tout arrêt de la production.

Or, je préfère faire confiance aux résultats des diverses approches et de rapidement changer le moteur, plutôt que d'attendre un arrêt de production suite à une panne, l'un me fera perdre plus d'argent que l'autre.

Ressources

Documentation Matlab

https://fr.mathworks.com/help/?s_tid=user_nav_help

<https://learnopencv.com/understanding-convolutional-neural-networks-cnn/>

Rédaction et travail réalisés sans recours à une intelligence artificielle.

Toute imperfection éventuelle relève donc exclusivement de l'intelligence naturelle.