

Modélisation d'un Système Neuronique Intelligent pour la Classification des Anomalies d'une Machine à Induction

Nejib Khalifaoui
ISET Jendouba
LR SITI - ENIT
nejibkhalifaoui@gmail.com

Mohamed Salah Salhi
ISSAT-Mateur
LR SITI - ENIT
Msalah.salhi@gmail.com

Hamid Amiri
ENIT- Tunis
Directeur de LR SITI
Hamidlamiri@gmail.com

Résumé— Ce papier présente une modélisation d'un système neuronique intelligent en détection des anomalies pouvant survenir sur une machine à induction via une carte SOM. IL fait intervenir les méthodes hiérarchiques de détection et de classification des anomalies, le paramétrage du SOM, la structure topologique de la carte, l'algorithme d'apprentissage de Kohonen, le diagramme d'activité en UML(Unified Modeling Language), et les fréquences caractéristiques des anomalies. Une comparaison des performances de détection d'anomalies était effectuée en application de la carte neuronique SOM et de la méthode d'analyse vibratoire. Ainsi, une simulation étant faite sous Matlab pour l'apprentissage du SOM s'accompagnant d'une surveillance expérimentale par analyse vibratoire, dans le laboratoire de CND (Contrôle Non Destructif), feront l'objet d'une analyse plus synthétique.

Mots clés— Réseau de neurones carte SOM, Méthodes hiérarchiques, Machine à induction, anomalies de roulement, Analyse vibratoire.

I. INTRODUCTION

La surveillance et le diagnostic des systèmes industriels occupent une place importante en maintenance préventive. Ils permettent de cibler les types et les origines des anomalies pouvant les affecter. En effet, Les systèmes d'entraînement électrique à base de machine à induction sont largement utilisés dans les applications industrielles en raison de leur faible coût, de leurs performances et de leur robustesse. En fait, cette machine à induction est omniprésente dans de nombreuses applications et en particulier dans les secteurs de pointe comme l'aéronautique, le nucléaire, les industries chimiques, dans le transport (métro, trains, propulsion de véhicule et des navires, les ascenseurs), dans l'industrie (machines-outils, treuils).

Cependant, des modes de fonctionnement dégradés peuvent apparaître durant la vie de la machine. L'une des raisons principales de ces défaillances reste les anomalies de roulements à billes. Afin d'améliorer la sûreté de fonctionnement de ces machines, des systèmes de

surveillance et de diagnostic modernes intelligents à base de réseaux de neurones peuvent être mis en place [1] [2] [3].

De nombreux travaux de recherche publiés [4], [5], [6], [7], [8], [9], [10], [11], [15], [16], traitent les systèmes neuroniques dédiés pour la détection des anomalies, tel que la carte de Kohonen SOM qui représente un outil puissant pour les tâches de diagnostics dans divers domaines. Cette carte est capable de représenter, autant de données d'entrées, ayant des Caractéristiques multidimensionnelles, que le nombre d'unité ou d'hierarchie qui se développe. Elle agit en même temps comme classifieur et quantificateur, et c'est justement là l'objectif même de ce papier qui vise à développer davantage l'efficacité de cette méthode et de l'appliquer à la détection des anomalies de la machine à induction et de dégager par la suite les performances de la carte SOM.

En outre, l'algorithme d'apprentissage de la carte SOM de Kohonen est doté d'une rapidité d'exécution intéressante par rapport aux autres modèles, malgré son caractère non supervisé. Ainsi, la carte SOM peut être utilisée même dans le cas de données partielles, ou avec des données à composantes manquantes. L'algorithme reste statistiquement valide à moins que le nombre de composantes manquantes dans le vecteur ne soit important. En outre, le SOM est adapté au traitement de flux de données large. Comme il peut être dynamique en intégrant le facteur temps à l'aide de boucles de retour (récurrence), comme le cas du model RecSOM proposé par Thomas voegtlin en 2002.

II. METHODES DE DETECTION ET DE CLASSIFICATION DES ANOMALIES PAR SOM

Les systèmes de détection et de classification des anomalies par la carte SOM souvent utilisent deux méthodes, la première est dite non hiérarchique la deuxième hiérarchique.

A. Méthodes non hiérarchiques

Les méthodes non hiérarchiques de SOM peuvent être classées en différentes catégories. Certaines traitent l'information temporelle à l'extérieur de la carte ; elles sont dites cartes à mémoire externe. D'autres traitent l'information temporelle de façon interne au niveau des neurones ou des connexions ; elles sont dites cartes à mémoire interne.

B. Méthodes hiérarchiques

Les méthodes hiérarchiques sont souvent employées dans des domaines d'application où il convient de décomposer une tâche complexe en sous-tâches plus simples à des niveaux multiples telle que la décomposition d'un signal vibratoire en des classes d'anomalies puis en anomalies pour avoir des résultats détaillés de détection.

Chaque niveau comprend une ou plusieurs cartes SOM, généralement construites à différentes échelles de temps. La différence principale entre les méthodes existantes se situe dans le type de codification des résultats des cartes SOM d'un niveau à un autre. Elles diffèrent également par le nombre de niveaux utilisés, le nombre de cartes SOM à chaque niveau, et les interconnexions entre les différents niveaux. Actuellement, il y a différentes méthodes hiérarchiques. Les plus importantes sont :

- Le GHSOM (Growing Hierarchical SOM).
- Le H2SOM (Hierarchically Growing Hyperbolic SOM).

Au cours de la construction de la hiérarchie, une erreur de quantification est utilisée comme étant une mesure qui guide automatiquement le processus d'apprentissage pour la détermination à la fois de la dimension des cartes SOM et du nombre de niveaux hiérarchiques. Le principe du GHSOM consiste à élaborer une structure hiérarchique de plusieurs niveaux. Chaque niveau de la hiérarchie est constitué d'un certain nombre de cartes SOM indépendantes. Tout neurone d'une carte supérieure dans la structure hiérarchique va guider une carte entière du niveau le plus bas. L'algorithme d'apprentissage commence dès la racine par la création d'une couche zéro constituée d'un seul neurone virtuel dont le vecteur poids est initialisé par la moyenne de tous les vecteurs d'entrées [4].

Le GHSOM représente une amélioration de la capacité de la carte SOM de deux façons. D'une part, il consiste à l'utilisation d'une version de plus en plus croissante du SOM. D'autre part, il adapte la carte SOM à des données structurées en arborescence [5].

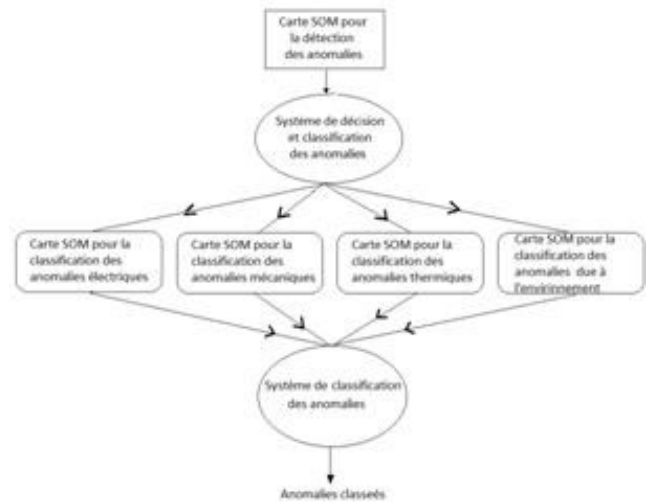


Figure 1 : Représentation de variante SOM hiérarchique

III. PROCEDURE DE DETECTION D'ANOMALIES PAR LA CARTE SOM

En se basant sur une modélisation d'un réseau d'inspiration biologique, Teuvo Kohonen a réalisé une carte de réseau de neurones particulier, appelée SOM. La mise en œuvre d'un certain nombre de neurones formels fonctionnant en parallèle et massivement interconnectés entre eux, leur donne des capacités d'apprentissage et de prise de décision à la détection d'anomalies. La fonction d'activation est généralement non linéaire. Chaque fonction est appropriée à une application bien définie [6]. On dit que le réseau constitué s'enrichit d'une forme de généralisation suite à son apprentissage par une base de données bien déterminée.

Dans le modèle de Kohonen, il est possible de dire que les cartes auto organisatrices apprennent à classer des vecteurs d'entrée selon la façon dont ils sont groupés dans cet espace. Ceci diffère des réseaux compétitifs où les neurones et leurs voisins apprennent à reconnaître des groupements dans l'espace d'entrée. En effet, la règle d'évolution des poids des neurones suit la règle de Kohonen sauf qu'au lieu d'activer l'unique neurone vainqueur, tous les neurones se trouvant au voisinage, et placés à une certaine distance seront aussi activés (figure2). Ces réseaux sont aussi très utilisés pour l'analyse de données. Toutefois, le fait d'activer tout un voisinage à la fois rend ce type de réseau moins sélectif en terme de classification [7], [8].




Figure 2: Représentation de la carte SOM ; (a) en 2D et (b) en chaîne

Le vecteur poids d'une unité de neurone n° i, désignée par v_{pi} est représenté, pour j données d'entrée, comme suit:

$$V_{pij} = \{w_{i1}; w_{i2}; w_{i3}; \dots; w_{ij}\} \quad (1)$$

Chaque neurone va recevoir des éléments caractérisant le vecteur d'entrée. Le neurone le plus proche en représentation, par minimisation d'une distance euclidienne, du vecteur d'entrée s'appelle : le BMU _Best matching Unit_. A la fin de chaque itération -cycle d'apprentissage ou de test de la carte- chaque neurone possède un vecteur poids, qui sera comparé par calcul de distance au vecteur d'entrée pour donner un seul neurone vainqueur. C'est celui qui est le plus proche distance du vecteur d'entrée.

Le BMU est donc l'unité de neurone pouvant joindre le mieux le vecteur d'entrée selon un critère d'une distance euclidienne déterminée à chaque itération. L'erreur de quantification associée au neurone i est donnée par la distance Euclidienne suivante : $E_i = \|x(t) - w_i\|$ (2)

Ainsi, pour un vecteur d'entrée de donnée, le neurone vainqueur "v" est l'unité qui minimise l'erreur de quantification à partir de laquelle on aura:

$$E_v = \min E_i ; i \in N \quad (3)$$

Pour chaque itération d'apprentissage ou de test, un seul neurone est activé ; c'est le BMU; c'est le neurone dont le vecteur prototype (vecteur poids) représente le mieux le vecteur d'entrée. Cette activation se propage le long de la carte SOM en suivant la forme d'un chapeau Mexicain (figure.3) ; ceci est décrit dans l'algorithme de Kohonen par une équation de mise à jour des poids synaptiques des neurones. La règle d'apprentissage met à jour les poids de neurones situés au voisinage du neurone activé _le vainqueur_, en les ramenant proche du vecteur d'entrée :

$$\Delta w_i = \gamma \cdot h_{iv}(x(t) - w_i) \quad (4)$$

Avec : γ est un rapport d'apprentissage et h_{iv} est une fonction de voisinage, qui décroît par la distance entre les unités i et v sur la carte.




Figure 3: Chapeau Mexicain décrivant les règles d'activation du neurone vainqueur et de son voisinage dans un SOM compétitif

PARAMETRES DU SOM EN DETECTION D'ANOMALIES
La carte de Kohonen présente de multiples paramètres qui

peuvent influencer les taux de détection comme par exemple :

- La dimension du vecteur de données à reconnaître
- La dimension de la carte
- Le nombre de neurones de la carte SOM. Un choix judicieux de la taille de la carte SOM doit se faire en fonction du nombre d'anomalies en question et du nombre de neurones de la carte. Le nombre total de neurones N_n de la carte est approximé par $N_n = 2,5C$. Où, C correspond au nombre d'individus utilisés dans l'apprentissage.
- La structure topologique de la carte : Le maillage à la base du réseau de neurones est le plus souvent carré, rectangulaire ou hexagonale. Un maillage hexagonal est particulièrement adapté pour la visualisation de classes.




Figure 4: illustration de la topologie de la carte SOM après apprentissage

- Le type d'apprentissage est séquentiel ou parallèle.
Les variables visualisées par la carte SOM constituent des indicateurs d'anomalies. Ces derniers sont représentés par leur fréquence appropriée, mentionnée comme suit:

- h: saine
- fr est la fréquence de rotation du rotor
- fs est la fréquence du réseau électrique
- fb est la fréquence de rotation de la bille
- fc est la fréquence de rotation de la cage
- fbi est la fréquence de rotation de la bague intérieure
- fbe est la fréquence de rotation de la bague extérieure
- fes est la fréquence de l'excentricité statique

- fed est la fréquence de l'excentricité dynamique
- feg est la fréquence de l'excentricité générale
- fco est la fréquence de commutation
- fbg est la fréquence du palier
- fbr est la fréquence de la barre cassée rotor
- fsb est la fréquence de court-circuit de barre du rotor
- fic est la fréquence de court-circuit d'une partie de l'anneau du rotor
- fsc est la fréquence de court-circuit de la bobine
- fps est la fréquence de court-circuit d'une phase
- fim est la fréquence de déséquilibre (balourd)
- fsa est la fréquence de court-circuit entre phase et bâtie
- fre est la fréquence de résonances

- L'étendue de voisinage
- Le nombre d'itérations de l'algorithme d'apprentissage
- La mode d'initialisation de la carte SOM. Trois modes d'initialisation des vecteurs poids (références) de la carte SOM peuvent être adoptés : aléatoire, linéaire et à l'aide des échantillons choisis à partir de la base d'apprentissage. Les études faites en 2003, ont montré que les cartes générées convergent vers des performances identiques quel que soit la procédure d'initialisation suivie.
- La règle de mise à jour des vecteurs poids (prototypes).

IV. ALGORITHME D'APPRENTISSAGE DE KOHONEN.

L'algorithme de Kohonen poursuit simultanément deux buts [6], [7], [8] :

- trouver les meilleurs prototypes représentant le jeu de données du signal. Cette opération est appelée la quantification vectorielle.
- trouver une configuration telle que deux prototypes proches dans l'espace des données soient associés à des neurones voisins sur la carte, cette proximité étant généralement vue au sens d'une métrique euclidienne, ou encore à ce que des neurones typologiquement proches sur la carte réagissent à des données d'entrée similaires.

Cet algorithme est qualifié de compétitif : lors de la présentation d'un individu au réseau, les neurones entrent en compétition, de telle sorte qu'un seul d'entre eux, le « vainqueur », soit finalement actif. Dans l'algorithme de Kohonen, le vainqueur est le neurone dont le prototype présente la plus faible distance, au sens d'une métrique euclidienne, avec l'individu présenté au réseau. Le principe de l'apprentissage compétitif consiste à récompenser le vainqueur, c'est à dire à rendre ce dernier encore plus sensible à une présentation ultérieure du même individu. Pour cela, on renforce les poids des connexions avec les entrées. Les neurones d'un réseau à apprentissage compétitif se comportent à terme comme de véritables détecteurs de traits de fréquences caractéristiques d'anomalies présentes au sein des données

d'entrée, chaque neurone se spécialisant dans la reconnaissance d'un trait particulier caractérise une anomalie.

Le neurone ayant remporté la compétition détermine le centre d'une zone de la carte appelée voisinage, zone dont l'étendue (rayon) varie au cours du temps. La phase suivante, dite de mise à jour ou adaptation, modifie la position des prototypes de façon à les rapprocher de l'individu présenté au réseau. Les prototypes sont d'autant plus rapprochés de l'individu en question qu'ils sont proches sur la carte du neurone vainqueur. La pondération permettant de déterminer l'importance des modifications de position dans l'espace est ainsi la fonction de la distance sur la carte entre le neurone vainqueur et le neurone considéré.

Les étapes de l'algorithme de Kohonen sont les suivantes :

1. Initialisation des prototypes
2. Sélection d'un individu
3. Détermination du neurone vainqueur pour cet individu ; c'est la phase de compétition.
4. Modification de la totalité des prototypes de la carte : phase d'adaptation et de mise à jour.
5. Reprise à l'étape 2 si la condition d'arrêt est non satisfaite.

Les différentes étapes de détection des anomalies par la carte SOM sont données par le diagramme suivant :

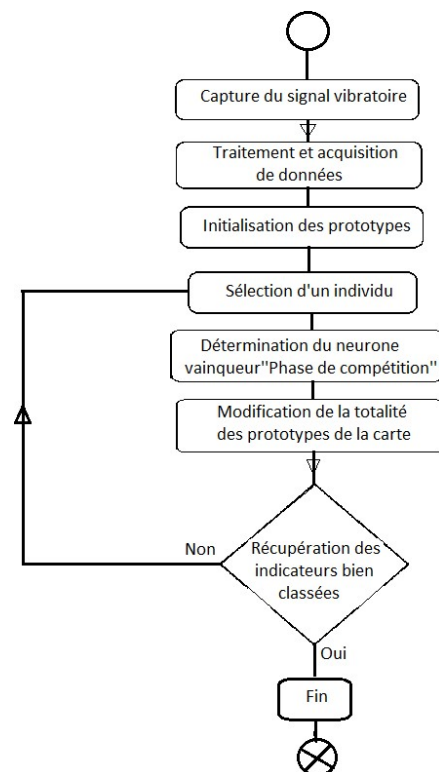


Figure 5: diagramme d'activité en UML

V. RÉSULTATS EXPERIMENTAUX

A. Anomalie sur la bague intérieure

Les résultats suivants montrent les vibrations de la bille roulant en raison d'une anomalie " indentation " sur la bague intérieure d'un roulement d'une machine à induction tournante à la vitesse 1480 tr / min, le mode de zoom autour de 680.2Hz figure6, (caractérisant l'anomalie par le cinquième harmonique de la fréquence f_{bin} en raison d'une indentation sur la bague intérieure) montre des bandes latérales espacées à la fréquence de rotation (25 Hz) concernant une modulation d'amplitude.

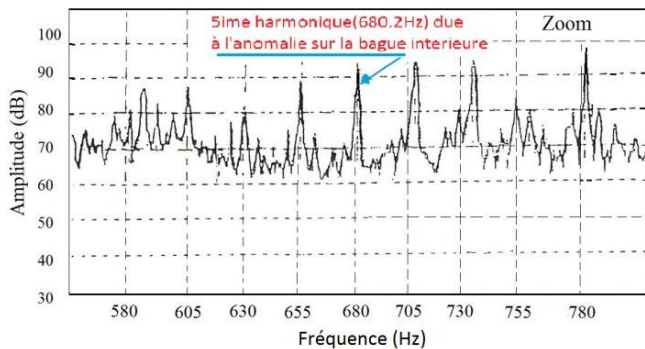


Figure 6 : Mode zoom du spectre de vibration du palier en présence d'une anomalie sur la bague intérieure

Le spectre de la figure.7 en mode zoom montre la résonance de la structure qui apparaît autour de 780 Hz et peut être attribué à la résonance représentée par le 31^{ème} harmonique de la rotation, $780,2 / 25 = 31,2$.

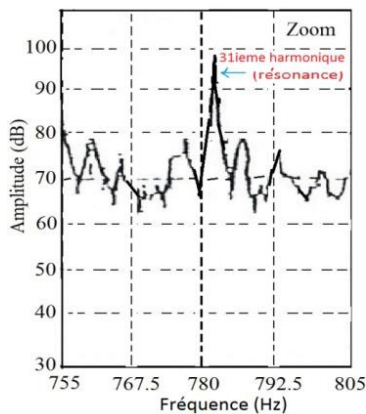


Figure 7 : Mode zoom du spectre de résonance du palier

1) Interprétations :

- l'évolution des amplitudes des composantes harmoniques à $(605 + k25)$ Hz, $k = 0, 1, 2, 3, \dots$, en raison de la fréquence de passage des billes sur l'indentation.
- L'évolution de l'amplitude près de 100dB autour de 780 Hz qui représentent des résonances de la structure.
- En outre, quel que soit le type d'anomalie ou de l'emplacement, les études expérimentales montrent que l'amplitude des variations de couple provoquées par des défauts augmente avec la vitesse de rotation mécanique.

B. Résultat de détection par Carte SOM

L'entrée de la carte SOM est le vecteur du signal vibratoire de l'essai expérimental après traitement et acquisition des données, le résultat est donné par la topologie suivante :




Figure8: Résultat de détection d'anomalie par la carte SOM

1) Interprétation

- le signal vibratoire est traité pour extraire les indicateurs qui sont utilisés pour classer les fréquences caractéristiques des anomalies.
- l'anomalie détectée par la carte SOM est sur la bague intérieure caractérisée par la fréquence f_{bi} signalée par le neurone vainqueur et la fréquence f_{re} due à la résonance de la structure.
- d'autre part, les neurones voisins indiquent les fréquences f_{n1} et f_{n2} qui représentent respectivement $f_{bi}+f_c$ et $f_{bi}-f_c$.
- le résultat obtenu suite à un apprentissage étant de 97 %

VI. BANC EXPERIMENTAL

Le banc expérimental est composé de:

- Une machine à induction triphasé, la machine est commandée par un onduleur " OMRON ", l'arbre du rotor est couplé à un générateur de courant continu qui alimente un rhéostat pour contrôler la charge. Caractéristiques de la machine à induction :
 - Puissance nominale 4 Kw
 - Vitesse nominale 1480tr / min
 - Moment d'inertie $J = 0.013\text{kgm}^2$
 - Nombre de paire de poêle $P = 2$
 - Type de roulement à billes SKF 6208, à une fréquence de rotation mécanique de $f_r = 25\text{Hz}$, les fréquences bague extérieure, la bague intérieure et la cage à billes sont respectivement $f_{\text{bext}} = 89.4\text{Hz}$, $f_{\text{bint}} = 136\text{Hz}$, $f_c = 9.94\text{Hz}$ et $f_b = 58.4\text{Hz}$.
- Un terminal portable Microlog d'acquisition et de stockage à partir des mesures de capteurs.

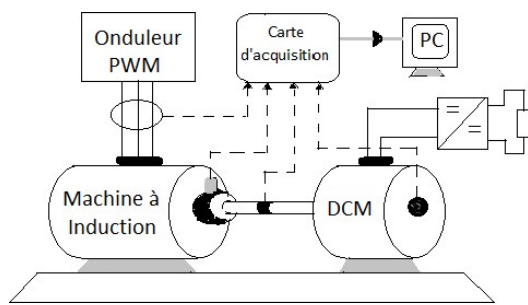


Figure 9: Schéma -bloc du banc expérimental




Figure 10: Photographie des Machines du banc expérimental

VII. CONCLUSION

L'algorithme de Kohonen organisant les règles de fonctionnement de la carte SOM est un algorithme non supervisé qui peut aussi être itératif, auto organisateur et non linéaire ce qui prouve que la carte SOM occupe une position très avancée, en terme de robustesse en milieux adverses et en reconnaissance universelle des données statiques.

Les résultats expérimentaux montrent que la carte SOM est plus précise que l'analyse vibratoire qui présente des rais erronés sous l'effet de résonance de la structure venant des chocs produits par le passage des billes sur l'échancrure. Ces chocs excitent les structures qui répondent par leurs fréquences propres qui sont particulièrement élevées. Mais l'efficacité de la reconnaissance des anomalies, est fortement liée à la qualité d'apprentissage du système développé. La segmentation, du signal vibratoire, courant statorique, couple, et vitesse, en atomes stationnaires est un facteur très important permettant de rehausser les taux de reconnaissance des fréquences caractéristiques des anomalies. Plusieurs approches et modèles ont été proposés pour le diagnostic. Chaque modèle suggère diverses solutions, néanmoins, ils présentent des limites. Un outil qui demeure puissant dans ce domaine est celui de la carte auto-organisatrice de Kohonen SOM. Plusieurs variantes du SOM ont été évoquées. Le caractère non supervisé de l'algorithme du modèle SOM, lui confère des propriétés qui conviennent pour la reconnaissance en présence d'un grand volume de données. L'expérimentation du modèle SOM, a montré qu'il est performant dans la représentation des données statiques. Cette réalité nous a conduit à penser à la conception de modèles auto-organiseurs récurrents intégrant le temps en cohérence avec les variations temporelles des signaux captés issu du système.

REFERENCES

- [1] N. Khalfaoui, M. S Salhi, H Amiri "Anomaly Detection in Induction Machines" 2nd International Conference on Automation, Control, Engineering and Computer Science; ACECS-2015 Sousse, Tunisia.
- [2] N. Khalfaoui, M. S Salhi, H Amiri " Modeling and effect of the anomaly of a ball rolling on the stability of the induction machine operating" IOSR Journal of Electrical and Electronics Engineering, Volume 10 Issue 3 pp 16-30 May-June. 2015.
- [3] B. Trajin, J. Regnier, J. Faucher, Indicator for bearing fault detection in asynchronous motors using stator current spectral analysis, International Symposium on Industrial Electronics, Juin-Juillet 2008, pp. 570-575.
- [4] A. Rauber, D. Merkl, and M. Dittenbach: -The growing hierarchical selforganizing map: Exploratory analysis of high-dimensional data, IEEE Transactions on Neural Networks, vol. 13, no. 6, pp. 1331-1341, 2002
- [5] M. Dittenbach, A. Rauber, and D. Merkl: -Uncovering hierarchical structure in data using the growing hierarchical self-organizing map, Neurocomputing, vol. 48, pp. 199-216, 2002.
- [6] Mohamed Salah Salhi, Najet Arous, and Nouredine Ellouze Principal temporal extensions of SOM: Overview" International Journal of Signal Processing, Image Processing and Pattern Recognition Vol. 2, No. 4, December, 2009.
- [7] Marc Strickert, Barbara Hammer: Merge SOM for temporal data, Institute of Plant Genetics and Crop Plant Research Gatersleben and Technical University of Clausthal Preprint submitted to Elsevier Science 19 October 2004.
- [8] Ozge Yeloglu, Student Member, IEEE, A. Nur Zincir-Heywood, Member, IEEE, Malcolm I. Heywood, Senior Member, IEEE: -Growing Recurrent Self Organizing Mapll, 2007.
- [9] Heni Ben Amor and Achim Rettinger: -Intelligent Exploration for Genetic Algorithms Using Self-organizing Maps in Evolutionary Computationl, February 4, 2005.
- [10] Kohonen, T.: -The self-organizing mapll, Proceedings of the IEEE, 78 (9), 1464-1480, 1990
- [11] Kohonen, T.: -Self-organizing mapsll, Springer, Berlin, 1995
- [12] Boucher, A., Seto, K.C., Journel, A.G.: -A novel method for mapping land cover changes: incorporating time and space with geostatisticsl, IEEE Transactions on Geoscience and Remote Sensing, 44 (11), 3427-3435, 2006
- [13] M.Cottrell, S. Ibbou & P. Letrémy: -SOM-based algorithms for qualitative variablesl, Neural Networks, vol. 17, p.1149-1167, 2004.
- [14] F. Immovilli, C. Bianchini, M. Cocconcelli, A. Bellini, R. Rubini, "Bearing Fault Model for Induction Motor With Externally Induced Vibration," IEEE Trans. ind. Electron., vol.160, no. S, pp. 340S-341S, Aug. 2013. ,
- [15] B. Trajin, Détection automatique et diagnostic des défauts de roulements dans une machine asynchrone par analyse spectrale des courants statoriques, Conférence des jeunes chercheurs en génie électrique (JCGE), Décembre 2008, pp. 220-225.
- [16] M. Amar, I. Gondal, and C. Wilson, "Vibration Spectrum Imaging: A Bearing Fault Classification Approach," IEEE Trans. ind. Electron., vol. no.99, pp. 1, doi: 10.1109/TIE.2014.2327555. 2014.