

République Algérienne Démocratique et Populaire
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université de Batna -2-
Faculté de Technologie
Département d'Électronique



THÈSE

Présentée pour l'obtention du diplôme de
Doctorat 3^{ème} cycle en Électronique
Option: Micro-ondes et télécommunications

Par : HAFDAOUI Hichem

Thème

**Détection et génération des micro-ondes acoustiques de
volume dans les structures piézoélectriques**

Soutenue le 06/12/2016

Devant le jury:

| | | | |
|-----------------------|-------|----------------------------|------------|
| Dr. DIBI Zohir | Prof. | Université Batna -2- | Président |
| Dr. BENATIA Djamel | Prof. | Université Batna -2- | Rapporteur |
| Dr. FORTAKI Tarek | Prof. | Université Batna -2- | Examineur |
| Dr. BENSLAMA Malek | Prof. | Université Constantine -1- | Examineur |
| Dr. CHAABI Abdelhafid | Prof. | Université Constantine -1- | Examineur |

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Remerciements

Je tiens à exprimer ma plus grande reconnaissance à mon directeur de thèse, le Dr Benatia Djamel, Professeur au département d'électronique, Faculté de Technologie à l'université de Batna 2, pour la qualité de son encadrement, par ses conseils et sa disponibilité. Il a su m'aider pour mener à bien mes travaux de recherche. J'ai beaucoup appris de son expérience. Je le remercie pour ses conseils et pour ses qualités scientifiques et pédagogiques.

Je remercie vivement le Dr DIBI Zohir, Professeur à l'université Batna 2, de m'avoir fait l'honneur d'être président de mon jury.

Je remercie très sincèrement le Dr. Fortaki Tarek, Professeur à l'université de Batna 2, d'avoir accepté de faire partie de mon jury de thèse.

Je remercie très sincèrement le Pr. Benslama Malek, Professeur à l'université Constantine 1, d'avoir accepté de faire partie de mon jury de thèse.

Je remercie très sincèrement le Pr. Chaabi Abdelhafid, Professeur à l'université Constantine 1, d'avoir accepté de faire partie de mon jury de thèse.

Je ne pourrais terminer sans remercier mes parents et ma famille qui m'ont soutenu et encouragé pour terminer ce travail.

Hafdaoui Hichem

Dédicaces

A :

Mes chers parents

Ma chère épouse

Mes chers frères et sœurs

Toute ma famille

Tous mes collègues et amis

Je dédie cette thèse

Sommaire

Liste des figures

Introduction générale01

Chapitre 1 : Principe de la piézoélectricité et équations phénoménologiques tensorielles

1.1 Introduction05

1.2 Historique05

1.3 La piézoélectricité.....06

 1.3.1 Principe de la piézoélectricité 06

 1.3.2 Les différents matériaux piézoélectriques.....07

1.4 Equations de la piézoélectricité.....08

1.5 Equations de propagation dans les solides.....09

 1.5.1 Eléments de description des solides.....10

 1.5.2 Propagation d'ondes dans les solides non piézoélectriques.....11

 1.5.3 Propagation d'ondes dans les solides piézoélectriques.....12

1.6 Dispositifs piézoélectriques et leurs applications.....14

1.7 Conclusion.....14

Chapitre 2 : Modélisation des micro-ondes acoustiques et solution de l'équation de dispersion

2.1 Introduction15

2.2 Equations de mouvement d'une particule et du potentiel électrique15

 2.2.1 Forme générale de la solution17

 2.2.2 Comportement des racines de l'équation de dispersion18

2.3 Application sur le LiNbO3 coupe Y-X20

2.4 Application sur le LiNbO3 coupe Y-Z23

2.5 Conclusion24

Chapitre 3 : La théorie des réseaux de neurones probabilistes (PNN)

| | |
|--|----|
| 3.1. Introduction | 25 |
| 3.2. Aspect biologique | 25 |
| 3.3. Modèle mathématique | 26 |
| 3.4. Réseaux de neurones non-Bouclés | 27 |
| 3.5. Les tâches des réseaux de neurones | 28 |
| 3.6. La régression non-paramétriques..... | 28 |
| 3.7. Les réseaux de neurones et Classification | 29 |
| 3.8. Types de réseaux de neurones | 30 |
| 3.8.1. Les réseaux de neurones perceptron multicouches | 30 |
| 3.8.2. Les réseaux de neurones à fonctions radiales | 31 |
| 3.8.3. Le réseau de neurones probabiliste (PNN) | 32 |
| 3.8.3.1. Principe de réseaux de neurones probabilistes | 32 |
| 3.8.3.2. Architecture d'un réseau probabiliste | 33 |
| 3.8.3.3. Algorithme d'apprentissage standard | 33 |
| 3.9.3.4. Algorithme d'apprentissage modifié | 34 |
| 3.9. Fonctions d'activation | 35 |
| 3.10. Sélection des variables d'entrée | 36 |
| 3.11. Complexité du réseau de neurones | 37 |
| 3.12. Apprentissage des réseaux de neurones | 37 |
| 3.13. Algorithme d'Apprentissage | 37 |
| 3.13.1. Apprentissage des Réseaux de Neurones à Fonctions à Base Radiale | 37 |
| 3.14. Conclusion | 37 |

**Chapitre 4 : Détection des ondes de volume par classification
en utilisant les réseaux de neurones probabilistes (PNN)**

| | |
|--|-----------|
| 4.1. Introduction | 39 |
| L'architecture générale de la méthode proposée | 40 |
| 4.2. Application sur le LiNbO3 coupe Y-Z | 41 |
| 4.3. Identification des ondes de volume | 41 |
| 4.4. Classement par les réseaux de neurones | 43 |
| 4.5. Résultats et discussion (Pour le LiNbO3 coupe Y-Z) | 45 |
| 4.6. Application sur le LiNbO3 coupe Y-X | 51 |
| 4.7. Classement par les réseaux de neurones | 52 |
| 4.8. Résultats et discussion (Pour le LiNbO3 coupe Y-X) | 54 |
| 4.8.1 Résultats de coefficient d'atténuation (α 3) | 54 |
| 4.8.2 Résultats de coefficient d'atténuation (α 4) | 59 |
| 4.9. Conclusion | 65 |
| Conclusion générale | 66 |
| Bibliographie | |
| Annexe | |

Liste des figures

| | |
|---|----|
| Figure 1.1. Illustration des effets piézoélectriques | 05 |
| Figure 1.2. Orientation des domaines avant et après polarisation | 06 |
| Figure 2.1. Excitation du matériau piézoélectrique (de Coupe X3-X1) par un transducteur interdigité | 15 |
| Figure 2.2. Ondes de surface..... | 19 |
| Figure 2.3. Ondes de volume..... | 19 |
| Figure 2.4a. Partie imaginaire de α_1 | 20 |
| Figure 2.4b. Partie réelle de α_1 | 20 |
| Figure 2.5a. Partie imaginaire de α_2 | 21 |
| Figure 2.5b. Partie réelle de α_2 | 21 |
| Figure 2.6a. Partie imaginaire de α_3 | 21 |
| Figure 2.6b. Partie réelle de α_3 | 22 |
| Figure 2.7a. Partie imaginaire de α_4 | 22 |
| Figure 2.7b. Partie réelle de α_4 | 22 |
| Figure 2. 8. α_1 en fonction de V_s | 23 |
| Figure 2. 9. α_2 en fonction de V_s | 23 |
| Figure 2. 10. α_3 en fonction de V_s | 24 |
| Figure 2. 11. α_4 en fonction de V_s | 24 |
| Figure 3.1. Model à un seul neurone..... | 26 |
| Figure 3.2. La différence entre les modèles paramétriques et les modèles non-paramétriques..... | 28 |
| Figure 3.3. Schéma d'un réseau de neurones PMC2 | 30 |
| Figure 3.4. La différence entre PMC et RBF dans un espace à deux dimensions pour les données d'entrée..... | 31 |
| Figure 3.5. Schéma d'un réseau de neurones RBF..... | 31 |
| Figure 3.6. Architecture générale d'un réseau probabiliste..... | 33 |
| Figure 3.7. Algorithme d'apprentissage modifié..... | 34 |
| Figure 4.1. Excitation du matériau piézoélectrique (de Coupe Y-Z) par un transducteur interdigité..... | 39 |
| Figure 4.2. Architecture générale de la méthode..... | 40 |
| Figure 4. 3. α_1 en fonction de V_s | 42 |
| Figure 4. 4. α_2 en fonction de V_s | 42 |
| Figure 4. 5. α_3 en fonction de V_s | 42 |
| Figure 4. 6. α_4 en fonction de V_s | 42 |
| Figure 4. 7. Architecture générale d'un réseau probabiliste..... | 43 |
| Figure 4.8. Partie réelle α_1 en fonction de la partie imaginaire α_1 | 44 |
| Figure 4.9. Partie réelle α_2 en fonction de la partie imaginaire α_2 | 44 |

| | |
|---|----|
| Figure 4.10. Partie réelle α_3 en fonction de la partie imaginaire α_3 | 45 |
| Figure 4. 11. Partie réelle α_4 en fonction de la partie imaginaire α_4 | 45 |
| Figure 4.12. Classement par réseau de neurones probabiliste - partie réelle (V_s m/s) (2D) | 46 |
| Figure 4.13. Classement par réseau de neurones probabiliste - partie réelle (V_s m/s) (3D) | 46 |
| Figure 4.14. Classement par réseau de neurones probabiliste (graphique de surface) | 47 |
| Figure 4.15. Classement par réseau de neurones probabiliste - partie imaginaire (V_s m/s) (2D) | 47 |
| Figure 4.16. Classement par réseau de neurones probabiliste - partie imaginaire (V_s m/s) (3D) | 48 |
| Figure 4.17. Classement par réseau de neurones probabiliste (graphique de surface) | 48 |
| Figure 4.18. Classement par réseau de neurones probabiliste - Vitesse acoustique (V_s m/s) (2D) | 49 |
| Figure 4.19. Classement par réseau de neurones probabiliste - Vitesse acoustique (V_s m/s) (3D)..... | 49 |
| Figure 4.20. Classement par réseau de neurones probabiliste (graphique de surface) | 50 |
| Figure 4.21a. Partie imaginaire de α_1 | 51 |
| Figure 4.21b. Partie réelle de α_1 | 51 |
| Figure 4.22a. Partie imaginaire de α_2 | 51 |
| Figure 4.22b. Partie réelle de α_2 | 51 |
| Figure 4.23a. Partie imaginaire de α_3 | 51 |
| Figure 4.23b. Partie réelle de α_3 | 51 |
| Figure 4.24a. Partie imaginaire de α_4 | 52 |
| Figure 4.24b. Partie réelle de α_4 | 52 |
| Figure 4.25. Partie réelle α_1 en fonction de la partie imaginaire α_1 | 53 |
| Figure 4.26. Partie réelle α_2 en fonction de la partie imaginaire α_2 | 53 |
| Figure 4.27. Partie réelle α_3 en fonction de la partie imaginaire α_3 | 54 |
| Figure 4.28. Partie réelle α_4 en fonction de la partie imaginaire α_4 | 54 |
| Figure 4.29. Classement par réseau de neurones probabiliste - partie imaginaire (V_s m/s) (2D) | 55 |
| Figure 4.30. Classement par réseau de neurones probabiliste - partie imaginaire (V_s m/s) (3D) | 55 |
| Figure 4.31. Classement par réseau de neurones probabiliste (graphique de surface) | 56 |
| Figure 4.32. Classement par réseau de neurones probabiliste - partie réelle (V_s m/s) (2D) | 56 |
| Figure 4.33. Classement par réseau de neurones probabiliste - partie réelle (V_s m/s) (3D) | 57 |
| Figure 4.34. Classement par réseau de neurones probabiliste (graphique de surface) | 57 |
| Figure 4.35. Classement par réseau de neurones probabiliste - Vitesse acoustique (V_s m/s) (2D) | 58 |
| Figure 4.36. Classement par réseau de neurones probabiliste - Vitesse acoustique (V_s m/s) (3D) | 59 |
| Figure 4.37. Classement par réseau de neurones probabiliste (graphique de surface) | 59 |
| Figure 4.38. Classement par réseau de neurones probabiliste - partie imaginaire (V_s m/s) (2D) | 60 |
| Figure 4.39. Classement par réseau de neurones probabiliste - partie imaginaire (V_s m/s) (3D) | 60 |
| Figure 4.40. Classement par réseau de neurones probabiliste (graphique de surface) | 61 |
| Figure 4.41. Classement par réseau de neurones probabiliste - partie réelle (V_s m/s) (2D) | 61 |

| | |
|---|----|
| Figure 4.42. Classement par réseau de neurones probabiliste - partie réelle (V_s m/s) (3D) | 62 |
| Figure 4.43. Classement par réseau de neurones probabiliste (graphique de surface) | 62 |
| Figure 4.44. Classement par réseau de neurones probabiliste - Vitesse acoustique (V_s m/s) (2D)..... | 63 |
| Figure 4.45. Classement par réseau de neurones probabiliste - Vitesse acoustique (V_s m/s) (3D) | 64 |
| Figure 4.46. Classement par réseau de neurones probabiliste (graphique de surface) | 64 |

Résumé

Dans ce travail, nous proposons une nouvelle méthode pour la détection des micro-ondes acoustiques de volume dans un substrat piézoélectrique (Niobate de Lithium LiNbO_3). Nous avons utilisé la classification par réseaux probabilistes de neurones comme un moyen d'analyse numérique afin de classer toutes les valeurs de la partie réelle et la partie imaginaire du coefficient d'atténuation pour les différentes vitesses acoustiques en construisant ainsi un modèle de détection efficace des ondes de volume. Cette étude sera très intéressante dans la modélisation et la réalisation des dispositifs micro-ondes acoustiques tels que les dispositifs à ultrasons basé sur la propagation des micro-ondes acoustiques de volume. En plus, nous pouvons appliquer cette technique sur n'importe quelle structure piézoélectrique possédant la même classe cristallographique, il suffit juste de changer les paramètres caractéristiques du matériau considéré.

Mots clés : Micro ondes acoustiques, Ondes de volume, Substrat piézoélectrique, classification par réseau probabiliste de neurone.

Abstract

In this work, we propose a new method for detection of BAW (Bulk acoustic waves) in a piezoelectric substrate (lithium niobate LiNbO_3). We have used the classification by neural networks as a means of numerical analysis in which we classify all the values of the real part and the imaginary part of the coefficient attenuation with the acoustic velocity in order to build a model from which we note the bulk waves easily. By which we obtain accurate values for each of the coefficient attenuation and acoustic velocity for bulk waves. This study will be very interesting in modeling and realization of acoustic microwaves devices (ultrasound) based on the propagation of acoustic microwaves. In addition, we can apply this technique on anywhere piezoelectric structure having the same crystallographic class, you just need to change the parameters characteristic of the material.

Keywords: Acoustics Microwaves, Bulk Waves, Piezoelectric Material, Neural Probabilistic Network Classification, The Attenuation Coefficient.

ملخص

في هذا العمل، نقترح طريقة جديدة للكشف عن الأمواج فوق الصوتية في الركيزة الكهروضغطية نأخذ في هذه الدراسة (النيوبات ليثيوم) حيث استخدمنا التصنيف باستعمال الشبكات العصبية الاحتمالية كوسيلة للتحليل العددي لتصنيف كل قيم الجزء الحقيقي والجزء التخيلي لمعامل التوهين مع سرعة الأمواج المتغيرة. وستكون هذه الدراسة مثيرة جدا للاهتمام في النمذجة وتطبيقات وصناعة أجهزة الميكروويف الصوتية مثل أجهزة الموجات فوق الصوتية التي تستعمل في التصوير الطبي وأيضا الأجهزة التي يكون مبدأ عملها بانتشار الأمواج فوق الصوتية. بالإضافة إلى ذلك، يمكننا تطبيق هذه التقنية على جميع المواد الكهروضغطية التي لها نفس درجة البلورات، ونحتاج فقط إلى تغيير الخصائص المميزة للمادة.

الكلمات المفتاحية: الأمواج ما فوق الصوتية، المادة الكهروضغطية، التصنيف باستعمال الشبكات العصبية الاحتمالية.

Introduction générale

1. Introduction

Ce travail de thèse est consacré à la modélisation des micro-ondes acoustiques dans les structures piézoélectriques.

Tout d'abord ; c'est au début des années 50, que tous les composants électroniques ont été fabriqués sur la base des éléments semi-conducteurs permettant d'engendrer un courant électrique (porteur de l'information). Après la découverte de la piézoélectricité, une propriété très importante, elle se traduit par une polarisation électrique du matériau sous l'action d'une contrainte mécanique et réciproquement par une déformation de ce matériau lorsqu'il est excité par un champ électrique. Dans le premier cas, on reconnaît effet piézoélectrique direct découvert par les frères Pierre et Jacques Curie en 1880, et dans le deuxième cas (l'effet inverse), c'est l'effet piézoélectrique indirect établi par Gabriel Lippman sur la base de calculs thermodynamiques et confirmé par les frères Curie. En suite des travaux ont été poursuivis donnant seulement lieu à des travaux théoriques concernant les structures cristallines. En 1910, Woldemar Voigt du Lehrbuch der Kristallphysik [1] publia un article qui donne les vingt classes cristallines piézoélectriques, en mentionnant pour la première fois les constantes piézoélectriques dans le formalisme tensoriel.

La recherche des matériaux plus performants ont intéressé différents groupes de recherche un peu partout dans le monde pour le développement des matériaux ferroélectriques, tels que le titanate de Baryum, les PZT et les matériaux à haut coefficient de couplage électroélastique comme le Niobate de Lithium qui sont d'ailleurs aujourd'hui des matériaux de référence. Depuis les années 50, des applications avec les ultrasons en médecine, (échographie, effet Doppler) ou en thérapie (destruction des calculs par onde de choc) ont vu le jour.

Le matériau piézoélectrique, est un cristal qui se déforme lorsqu'il subit une tension électrique. Dans ce cas, le signal électrique est converti en un signal élastique se propageant avec des vitesses identiques à ceux des ondes supersoniques. Les ondes qui se propagent à la surface du matériau, on les appelle ondes de surface [2, 3], elles ne sont détectables que pour une seule vitesse acoustique. Pour d'autres vitesses, on peut trouver des ondes de surface dites pseudo-

ondes de surface. Ces dernières sont accompagnées par d'autres types d'ondes, dites ondes de volume et ondes de fuite [4, 5].

Dans le domaine d'application, les ondes de volume sont utilisées en échographie, il ya plusieurs travaux sur la détection et génération des micro-ondes acoustiques de volume [5-7].

2. Contribution de la thèse

Dans notre thèse, on s'intéresse à l'application des réseaux de neurones probabilistes (PNN) pour la détection et génération des micro-ondes acoustiques de volume par classification. La classification par les réseaux de neurones classiques présente beaucoup de complications alors que celle des réseaux de neurones probabilistes (PNN) qui a été introduit par D. F. Specht [8] est devenue une référence dans le domaine de la classification neuronale en raison de leurs propriétés pour les problèmes de classification. Dans les PNNs, on trouve plusieurs avantages du fait qu'ils ne souffrent pas du problème des minima locaux et que l'apprentissage est très rapide puisque le réseau est créé après un seul passage sur l'ensemble d'apprentissage [8]. D'autre part, il y a quelques inconvénients concernant le nombre de neurones cachés qui est égal au nombre d'échantillons de l'apprentissage surtout dans le cas d'un ensemble d'apprentissage très grand sans oublier le choix du paramètre de lissage qui peut affecter la généralisation du réseau.

Des travaux ont été proposés pour résoudre le problème de généralisation ainsi que celui du choix des paramètres dans les réseaux de neurones probabilistes. Ainsi, M. Kim [9] a proposé une nouvelle architecture pour améliorer la généralisation du PNN standard. Dans la littérature [10, 11], des algorithmes LVQ (Learning vector quantization) ont été utilisés pour l'apprentissage des PNNs afin de rendre la taille du réseau plus petite. D'autres variantes des PNNs sont le PNN flou et l'optimisation stochastique pour le choix des paramètres du PNN [12] ne permettent qu'une résolution partielle du problème. Les méthodes RKPNNs (PNNs avec noyau rotationnel) [13] ont de bonnes qualités de généralisation comparées aux SVM dans le cas d'un nombre réduit de classes [14, 15] mais l'apprentissage est très lent, même pour les petits ensembles d'apprentissage et le réseau ne supporte pas l'ajout de nouvelles classes des échantillons, dans ce cas tout le processus d'apprentissage doit être repris avec du nouveau ensemble. L'algorithme d'apprentissage réduit le nombre de neurones cachés, sans affecter l'architecture du réseau, ceci signifie que l'ajout de nouveaux échantillons ou de classes est possible à tout moment et sans refaire l'apprentissage du début.

Contrairement aux réseaux MLP, les réseaux de neurones probabilistes utilisent des fonctions radiales plutôt que des fonctions d'activation sigmoïdes pour construire une fonction de décision locale centrée sur un sous-ensemble de l'espace d'entrée [11]. La fonction de décision globale est la somme de toutes les fonctions locales. De cette façon, le problème des minima locaux est résolu.

Sur la base de cet état de l'art, notre contribution porte sur l'utilisation des réseaux de neurones probabilistes [8-15] pour la génération et la détection des micro-ondes acoustiques de volume dans les structures piézoélectriques. L'avantage de cette technique réside, donc, dans la précision des valeurs des vitesses acoustiques au niveau des quelles nous pouvons détecter de façon très efficace les ondes de volume, contrairement aux travaux cités dans les références [5-7] qui se basent sur une évaluation beaucoup plus graphique, donc moins précise.

3. Organisation de la thèse

Notre thèse est scindée en quatre chapitres :

Le premier chapitre est consacré aux principes de la piézoélectricité et présente aussi les caractéristiques de quelques matériaux piézoélectriques et leurs applications.

Le deuxième chapitre est consacré à la modélisation des micro-ondes acoustiques. Ces ondes sont la conséquence d'un déplacement de particules sans transport de la matière.

Le troisième chapitre porte sur les réseaux de neurones artificiels en particulier sur la théorie des réseaux de neurones probabilistes (PNN).

Le quatrième chapitre porte sur la détection des micro-ondes acoustiques de volume par classification en utilisant les réseaux de neurones probabilistes (PNN).

Et enfin une conclusion générale avec quelques perspectives terminera ce travail.

Production scientifique :

1/- Publication Internationale

H. Hafdaoui and D. Benatia : « Identification of Acoustics Microwaves (Bulk Acoustic Waves) in Piezoelectric Substrate (LiNbO₃ Cut Y –Z) by Classification Using Neural Network », *Journal of Nanoelectronics and Optoelectronics*, Vol. 10, pp. 314–319, 2015.

2/- Conférences Internationales

1- C. Mehadjebia, H. Hafdaoui, A. Mechnene and D. Benatia, Contribution to the modeling and minimizing the vibrations in laser satellites, *2nd International Congress On Telecommunication And Applications*, April 23-24 ,Bejaia Algeria , 2014.

2-A. Tafsast, M.L. Hadjili, H. Hafdaoui, A. Bouakaz, N. benoudjit, Automatic Gaussian Mixture Model (GMM) for segmenting 18F-FDG-PET images based on Akaike Information Criteria, *4th International Conference on Electrical Engineering* , December 13-15, Boumerdes Algeria 2015.

Chapitre 1 : Principe de la piézoélectricité et équations phénoménologiques tensorielles

1.1 Introduction

L'origine du mot piézoélectricité provient du mot grec "Piézo" qui signifie pression. La piézoélectricité est une propriété de certains matériaux de générer un champ électrique lorsqu'ils sont soumis à une pression mécanique externe ; on parle alors de l'effet piézoélectrique direct (Fig. 1.1). Et inversement, ces mêmes cristaux subissent une déformation sous l'action d'un champ électrique ; c'est l'effet piézoélectrique inverse.

Le déplacement des charges se fait dans une direction donnée sous les efforts de traction ou de compression dans la structure cristalline [16].

La figure suivante résume les effets piézoélectriques [16] :

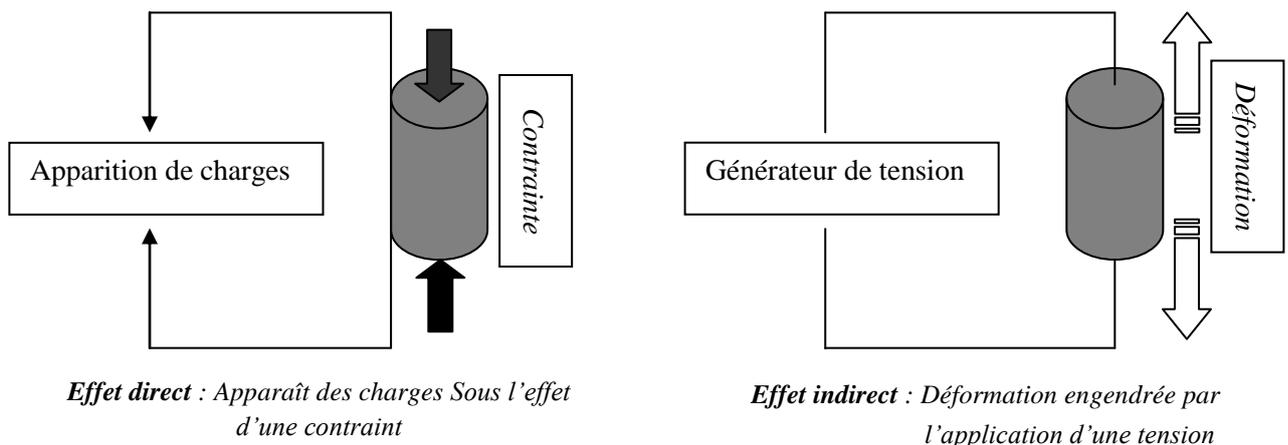


Figure 1.1 : Illustration des effets piézoélectriques [16]

1.2 Historique

L'effet piézoélectrique découvert par Pierre et Jacques Curie en 1880, afin de le distinguer d'autres phénomènes tels que l'électricité de contact (électricité statique due au frottement) et la pyroélectricité (électricité générée par les cristaux, due à leur échauffement).

Les chercheurs dans ce domaine ont établi 20 catégories de cristaux naturels dans lesquels les phénomènes piézoélectriques sont présents [16].

1.3 La piézoélectricité

La piézoélectricité est la propriété que présentent certains corps de se polariser électriquement sous l'action d'une contrainte mécanique (effet direct) et de se déformer lorsqu'ils sont soumis à un champ électrique (effet inverse), la piézo-électricité est un phénomène réciproque.

1.3.1 Principe de la piézoélectricité

Il y a tout d'abord, les matériaux ferroélectriques, ces derniers composés d'un ensemble de grains dont chacun est un cristal connu sous le nom de polycristallin. Chaque cristal possède un axe privilégié, orienté de façon aléatoire, de sorte que l'effet piézoélectrique résultant est nul. On peut cependant réorienter dans le même sens les axes des grains par l'application d'un champ électrique intense à haute température et pendant une phase de retour à la température ambiante : cette procédure est appelée « polarisation » qui permet au matériau ferroélectrique d'acquérir une piézoélectricité [17].

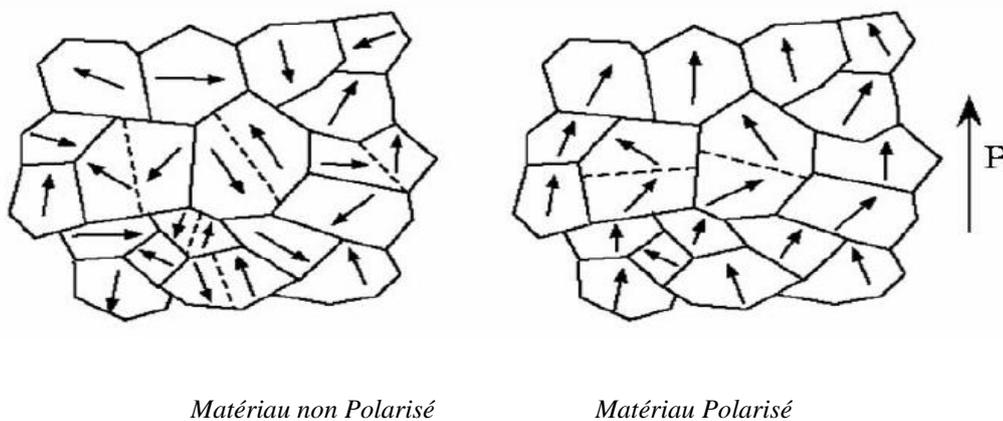


Figure 1.2 : Orientation des domaines avant et après polarisation [18]

Lorsque le matériau est chauffé au delà d'une valeur appelée température de Curie T_c , il perd sa piézoélectricité. T_c étant typiquement comprise entre 80 et 400 °C [18].

1.3.2 Les différents matériaux piézoélectriques

Il y a quatre classes principales de matériaux piézoélectriques : les cristaux qui possèdent une piézo-électricité naturelle, les céramiques, les polymères et les composites qui doivent être polarisés. Ces différents matériaux sont caractérisés par [19]:

- Z (l'impédance acoustique) :

- k_t (Coefficient d'accouplement électromécanique) : Il permet de décrire la conversion d'énergie électrique en mécanique ou vice versa.

$$k_t^2 = \text{Énergie fournie} / \text{Énergie absorbée}$$

k_t appelé aussi le coefficient de couplage électro-acoustique. Ce paramètre, compris entre 0 et 1, caractérise l'aptitude du matériau à convertir une énergie électrique en énergie mécanique ou inversement.

Exemple :

- Le quartz dont l'impédance acoustique relativement élevée et son coefficient de couplage très faible.

- Le Niobate de Lithium (LiNbO3) ou le Tantalate de Lithium (LiTaO3) dont les valeurs de k_t sont plus élevées. Le Niobate de Lithium (LiNbO3) est utilisé en imagerie hautes fréquences.

Tableau 1.1– Coefficient de couplage électro-acoustique et impédance acoustique [19].

| Matériaux Piézoélectriques | Coefficient de couplage électroacoustique | Z : impédance Acoustique | Exemple |
|----------------------------|---|--------------------------|---|
| Ceramiques | $k_t = 0.3$ à 0.5 | 30 à 35 Mrayleigh | Titanate de Baryum, k_t faible PZT k_t élevé (233Mra) |
| Films Plastiques | k_t faible | 4 -5 Mrayleigh | PVDF (polyvinylidène Difluorure) $k_t < 0.2$ Copolymères $k_t < 0.3$ |
| Cristaux | k_t très faible | 34Mra (HF) | Quartz, k_t très faible (résonateur) NbLiO3, $k_t = 0.16$ |
| Composites | $k_t = 0.5$ à 0.7 | 12 à 30Mrayleigh | Céramiques + résine connectivité 1-3, le plus utilisé |

1.4 Equations de la piézoélectricité

Le phénomène piézoélectrique se manifeste par la conversion de l'énergie électrique en énergie mécanique et réciproquement. Le Tableau 1.2 présente les équations reliant les variables électriques (induction électrique D ou champ électrique E) aux variables mécaniques (déformation S ou contrainte T) [18]. Trois types de coefficients interviennent:

- Des coefficients purement électriques.
- Des coefficients purement mécaniques.
- Des coefficients mixtes qui traduisent le couplage entre les grandeurs électriques et les grandeurs mécaniques.

Tableau 1. 2 – Equations de la piézoélectricité [17].

| Grandeurs électriques | Grandeurs mécaniques |
|------------------------------|-----------------------|
| $D = \varepsilon^T .E + d.T$ | $S = s^E .T + d^t .E$ |
| $E = \beta^T .D - g.T$ | $S = s^D .T + g^t .D$ |
| $D = \varepsilon^S .E + e.S$ | $S = c^E .S - e^t .E$ |
| $E = \beta^S .D - h.S$ | $S = c^D .S - h^t .D$ |

Dans un solide élastique soumis à une contrainte T , la déformation S vaut :

$$S = s T \tag{1.1}$$

Où s est la souplesse (inverse du module de Young), exprimée en $[m^2 / N]$.

D'autre part, dans un diélectrique soumis à un champ électrique, on a l'équation :

$$D = \varepsilon E \tag{1.2}$$

Où ε est la constante diélectrique du milieu en $[F/m]$.

Dans un milieu piézoélectrique, l'effet piézoélectrique direct et inverse se manifeste par :

$$\frac{\partial D}{\partial T} = 0 \tag{1.3}$$

$$\frac{\partial S}{\partial E} = 0 \tag{1.4}$$

Cette dépendance est décrite par des relations linéaires entre les quatre variables D , E , S et T :

$$S = s^E \cdot T + d^t \cdot E \quad (1.5)$$

$$D = dT + e^T E \quad (1.6)$$

L'exposant t dans l'équation 2.5 indique qu'il s'agit de la matrice transposée de d .

Tableau 1.3 – Définition des termes et dimension des tenseurs utilisés en équations [20].

| Type | Signification | Unités | Dimension |
|-----------------|--|-------------------------------|-----------|
| Electrique | D Déplacement électrique ou induction | $C.m^{-2}$ | 3x1 |
| | E Champ électrique | $V.m^{-1}$ | 3x1 |
| | ϵ permittivité électrique | $F.m^{-1}$ | 3x3 |
| | β imperméabilité diélectrique | $m.F^{-1}$ | 3x3 |
| Mécaniques | S déformation relative | | 6x1 |
| | T contrainte | $N.m^{-2}$ | 6x1 |
| | s souplesse | $m^2.N^{-1}$ | 6x6 |
| | C raideur | $N.m^{-2}$ | 6x6 |
| Piézoélectrique | d constante reliant la contrainte T et l'induction D à E constant | $C.N^{-1}$ ou $m.V^{-1}$ | 3x6 |
| | e constante reliant la déformation S et l'induction D à E constant | $C.m^{-2}$ ou $N.V^{-1}$ | 3x6 |
| | g constante reliant la contrainte T et le champ E à D constant | $V.m.N^{-1}$ ou $m.C^{-1}$ | 3x6 |
| | h constante reliant la déformation S et le champ E à D constante | $V.m^{-1}$ ou $N.C^{-1}$ | 3x6 |

1.5 Equations de propagation dans les solides

Une onde élastique résulte du déplacement de particules, elle se propage dans les milieux matériels. Nous nous intéressons ici aux ondes se propageant dans les solides. Un solide est dit élastique si, après déformation, il reprend sa forme initiale.

L'étude de la propagation des ondes dans les solides permet de différencier plusieurs types d'ondes qui résultent toutes de la combinaison selon deux aspects :

- Les ondes longitudinales : Ce sont des oscillations dans la direction de propagation (Compression et dilatation).
- Les ondes transversales : Ce sont des oscillations perpendiculaires à la direction de propagation (Cisaillement) [21].

Suivant ces deux cas, On aura :

- Les ondes planes dans un milieu infini (ondes de volume)
- Les ondes guidées :
 - ✓ Par la surface libre (milieu semi-infini)
 - ✓ Dans une plaque (solide limité)
 - ✓ Dans un milieu inhomogène

1.5.1 Eléments de description des solides

La notion de tenseur a été introduite par W. Voigt à la fin du 19^{ème} siècle pour définir l'état de tension mécanique d'un solide.

Un matériau anisotrope et piézoélectrique est donc caractérisé par les tenseurs de rigidité (ou d'élasticité) C , de piézoélectricité e et de permittivité ε [21].

Les paramètres du solide peuvent être représentés par des tenseurs de rang deux : le tenseur des déformations S_{ij} et le tenseur des contraintes T_{ij} qui tient compte des différentes déformations dans les trois directions $(\vec{x}_1, \vec{x}_2, \vec{x}_3)$.

Le tenseur des déformations S_{ij} est lié au vecteur déplacement \vec{U} (déplacement des particules du solide) par la relation :

$$S_{ij} = \frac{1}{2} \left(\frac{\partial u_i}{\partial x_j} + \frac{\partial u_j}{\partial x_i} \right) \text{ avec } i, j=1, 2, 3 \quad (1.7)$$

Avec :

u_i : Déplacement de particules suivant l'axe x_i

Dans le cas d'un solide non piézoélectrique, les tenseurs des contraintes T_{ij} et des déformations S_{ij} sont liés par la loi de HOOKE :

$$T_{ij} = c_{ijkl} S_{kl} \quad (1.8)$$

Les coefficients c_{ijkl} représentent le tenseur de rang 4 appelé *tenseur de rigidité*.

Les symétries de ces différents tenseurs ($S_{ij} = S_{ji}$, $T_{ij} = T_{ji}$,...) simplifient l'écriture en utilisant la règle de Voigt (cf. Annexe B), on obtient alors :

$$T_{\alpha} = c_{\alpha\beta} S_{\beta} \quad \text{avec } \alpha, \beta = 1..6$$

On peut également simplifier l'écriture de S_{ij} [21] :

$$S = \frac{\partial u_i}{\partial x_j}$$

1.5.2 Propagation d'ondes dans les solides non piézoélectriques

La description mathématique de la propagation d'une onde plane dans un solide se base sur les équations du mouvement qui résultent de la relation fondamentale de la dynamique :

$$\frac{\partial T_{ik}}{\partial x_k} + f_i = \rho \frac{\partial^2 u_i}{\partial t^2} \quad (1.9)$$

Avec :

T_{ik} : Contraintes internes

ρ : Masse volumique

u_i : Déplacement de particules suivant l'axe x_i

f_i : Densité de force extérieure par unité de volume suivant l'axe x_i

L'équation 1.9 est l'équation fondamentale de l'élastodynamique des milieux solides.

En tenant compte de la loi de Hooke et en négligeant la pesanteur (pas de force extérieure), l'équation du mouvement dans un solide anisotrope et non piézoélectrique s'écrit [21] :

$$\rho \frac{\partial^2 u_i}{\partial t^2} = c_{ijkm} \frac{\partial^2 u_m}{\partial x_j \partial x_k} \quad \text{avec } i, j, k, m = 1, 2, 3 \quad (1.10)$$

La solution de cette équation permet de décrire les caractéristiques de l'onde élastique.

1.5.3 Propagation d'ondes dans les solides piézoélectriques

Dans le cas d'un cristal piézoélectrique il faut tenir compte, en plus des grandeurs mécaniques, des grandeurs électriques : \vec{E} le champ électrique et \vec{B} le champ magnétique.

Il y a un couplage entre les ondes élastiques et les ondes électromagnétiques. Les solutions de l'équation de propagation sont alors des ondes élastiques de vitesse de phase V_p accompagnées d'un champ électrique et des ondes électromagnétiques de vitesse $c \cong 10^5 \times V_p$ accompagnées d'une déformation mécanique [21].

Le champ magnétique associé aux ondes élastiques, créé par le champ électrique qui se déplace à la vitesse V_p très inférieure à la vitesse c des ondes électromagnétiques, est quasiment nul [9]. De plus, la vitesse des ondes électromagnétiques étant très supérieure à celle des ondes élastiques, leur interaction est faible puisque leurs vitesses sont très différentes, leur propagation se traite alors de manière indépendante. La propagation des ondes élastiques dans un cristal piézoélectrique sera donc étudiée dans l'approximation *quasi-statique* qui considère que le champ électrique est statique vis-à-vis des phénomènes de propagation électromagnétiques.

D'après l'équation de Maxwell dans l'approximation quasi-statique [21] :

$$\text{rot} \vec{E} = - \frac{\partial \vec{B}}{\partial t} \cong 0 \quad \text{Soit} \quad \vec{E} = - \text{grad} \vec{\Phi}$$

Où Φ est le potentiel électrique.

La loi de Hooke est modifiée pour tenir compte des grandeurs électriques, l'équation 1.8 devient :

$$T_{ij} = c_{ijkm} S_{km} - e_{kij} E_k$$

Où e_{kij} sont les composantes du tenseur piézoélectrique ($i, j, k = 1, 2, 3$).

En utilisant l'expression 1.7 de la déformation et l'expression du champ électrique quasi-statique $E = -\frac{\partial\Phi}{\partial x_k}$, on obtient [21] :

$$T_{ij} = c_{ijkm} \frac{\partial u_m}{\partial x_k} + e_{kij} \frac{\partial \Phi}{\partial x_k} \quad (1.11)$$

En remplaçant l'équation 1.11 dans l'équation 1.9, on obtient l'équation du mouvement :

$$\rho \frac{\partial^2 u_i}{\partial t^2} = c_{ijkm} \frac{\partial^2 u_m}{\partial x_j \partial x_k} + e_{kij} \frac{\partial^2 \Phi}{\partial x_j \partial x_k} \quad (1.12)$$

D'autre part, l'induction électrique D s'écrit :

$$D_j = e_{jkm} \frac{\partial u_m}{\partial x_k} - \varepsilon_{jkl} \frac{\partial \Phi}{\partial x_k} \quad (1.13)$$

Où ε_{jkl} sont les composantes du tenseur de permittivité.

Elle satisfait à l'équation de Poisson :

$$\frac{\partial D_j}{\partial x_j} = 0 \quad \text{Soit} \quad e_{jkm} \frac{\partial^2 u_m}{\partial x_j \partial x_k} - \varepsilon_{jkl} \frac{\partial^2 \Phi}{\partial x_j \partial x_k} = 0 \quad (1.14)$$

On obtient alors l'équation de propagation du déplacement u_i en éliminant le potentiel Φ entre les équations 1.12 et 1.14.

Pour un solide anisotrope et piézoélectrique, le système d'équation décrivant la propagation de l'onde est le suivant [21] :

$$\begin{cases} \rho \frac{\partial^2 u_i}{\partial t^2} = c_{ijkm} \frac{\partial^2 u_m}{\partial x_j \partial x_k} + e_{kij} \frac{\partial^2 \Phi}{\partial x_j \partial x_k} \\ e_{jkm} \frac{\partial^2 u_m}{\partial x_j \partial x_k} - \varepsilon_{jkl} \frac{\partial^2 \Phi}{\partial x_j \partial x_k} = 0 \end{cases} \quad (1.15)$$

Le système 1.15 comporte deux équations connues sous l'appellation « *équations phénoménologiques tensorielles piézoélectriques* ».

1.6 Dispositifs piézoélectriques et leurs applications

Le tableau 1.4 illustre les domaines d'applications des dispositifs piézoélectriques.

Tableau 1.4 – Domaines d'applications des céramiques piézoélectriques [22].

| Militaire | Commercial | Médical |
|---|--|---|
| Capteur de profondeur. Système de sécurité. Hydrophones. | Soudeuse ultrasonique. Perceuse ultrasonique. Indicateur de niveau. Détecteur de défaut. Décapants ultrasoniques. Capteurs sismiques. Microphones. Géophone. Systèmes d'alarmes. Résonateurs pour radio/TV. | Traitement ultrasonique de la cataracte. Thérapie ultrasonique. Capteurs ultrasoniques. Pompe d'insuline. Acquisition d'image ultrasonique. Débitmètres. Nébuliseurs. |
| Automobile | | Détection du battement cardiaque du fœtus. |
| Capteurs d'objets. Capteurs pour Airbag. Contrôle de vibrations. Injecteurs. | | |
| Ordinateur | Aviation | Consommateur |
| Micro-actionneur pour disque dur. Transformateur pour notebook. | Actionneurs pour flaps. | Briquet. Instruments musicaux. DéTECTEURS de fumée. |

1.7 Conclusion

Ce premier chapitre, nous a permis de retracer l'origine du phénomène de la piézoélectricité, ainsi que son évolution et son développement. La découverte des matériaux piézoélectriques, qui sont facilement réalisables avec des caractéristiques intéressantes, a eu comme conséquence le développement des dispositifs piézoélectriques.

Le prochain chapitre fera l'objet de la modélisation des micro-ondes acoustiques afin de bien comprendre le phénomène des micro-ondes acoustique en particulier les ondes de volume.

Chapitre 2 : Modélisation des micro-ondes acoustiques et solution de l'équation de dispersion

2.1 Introduction

Nous excitions le matériau piézoélectrique par un signal électrique qu'on applique aux électrodes du transducteur qui engendre à son tour des déformations (compression et dilatation), ainsi une onde électroacoustique prend naissance (génération) et se propage suivant X_1 (Figure 2.1).

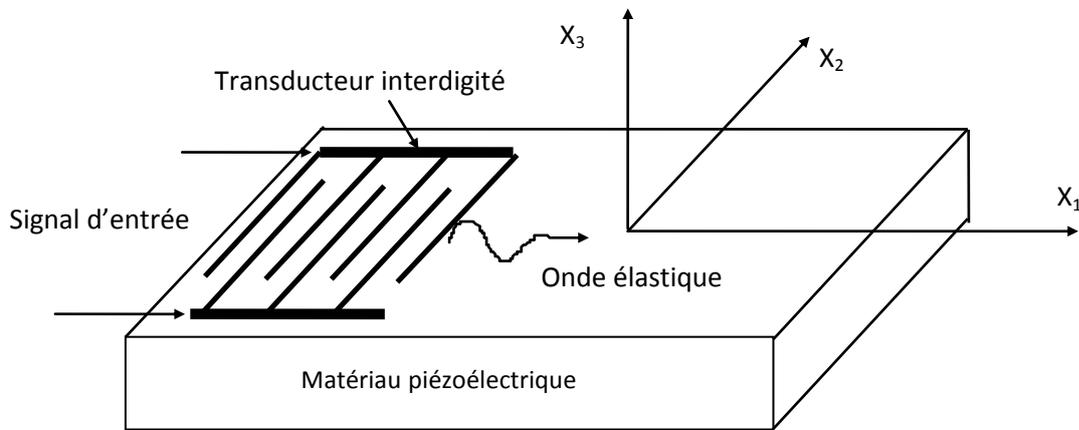


Figure 2.1 : Excitation du matériau piézoélectrique (de Coupe X_3 - X_1)

par un transducteur interdigité [3]

2.2 Equations de mouvement d'une particule et du potentiel électrique

- Le comportement mécanique du matériau est représenté par le tenseur contrainte et le tenseur déformation mécanique de composantes T_{ij} et S_{ij} ($i,j=1,2,3$)

- Les déformations S_{ij} sont liées aux déplacements mécaniques relatifs des particules \bar{U} du milieu matériel par :

$$S_{ij} = \frac{1}{2} \left(\frac{\partial U_i}{\partial X_j} + \frac{\partial U_j}{\partial X_i} \right) \quad (2.1)$$

- Le comportement électrique du milieu est défini par le champ électrique \vec{E} et le déplacement électrique \vec{D} .

- Le champ E_i dérive du potentiel électrique de composantes (approximation quasi-statique) [5 ,23 ,24] :

$$E_i = -\frac{\partial U_4}{\partial X_i} \quad (2.2)$$

Où U_4 est le potentiel électrique

- Les tenseurs de contrainte et d'induction électrique sont donnés par :

$$T_{ij} = C_{ijkl} \cdot S_{kl} - e_{kij} \cdot E_k \quad (2.3)$$

$$D_i = e_{jkl} \cdot S_{kl} + \varepsilon_{ik} \cdot E_k \quad (2.4)$$

avec $i,j,k,l = 1,2,3$

L'équation de Maxwell-Gauss électrique donne l'équation de Poisson :

$$\text{div. } \vec{D} = \frac{\partial D_i}{\partial X_i} = 0 \quad (2.5)$$

Le mouvement des particules du matériau sous l'action des contraintes, est décrit par la relation de Newton:

$$\nabla T = \rho \cdot \frac{\partial U^2}{\partial t^2} \quad (2.6)$$

Par substitution des équations (2.1) et (2.2) dans les équations (2.3) et (2.4), nous obtenons:

$$T_{ij} = C_{ijkl} \cdot \frac{1}{2} \left(\frac{\partial u_j}{\partial X_k} + \frac{\partial u_k}{\partial X_j} \right) + e_{kij} \cdot \frac{\partial u_4}{\partial X_k} \quad (2.7)$$

$$D_{ij} = e_{ikl} \cdot \frac{1}{2} \left(\frac{\partial u_j}{\partial X_k} + \frac{\partial u_k}{\partial X_j} \right) - \varepsilon_{ik} \cdot \frac{\partial u_4}{\partial X_k} \quad (2.8)$$

En substituant les équations (2.7) et (2.8) dans les équations (2.5) et (2.6), nous aurons :

$$C_{ijkl} \frac{\partial^2 U_k}{\partial X_i \partial X_j} + e_{lij} \frac{\partial^2 U_4}{\partial X_k \partial X_i} = \rho \frac{\partial^2 U_j}{\partial t^2} \quad (2.9)$$

$$e_{ikl} \frac{\partial^2 U_k}{\partial X_i \partial X_j} - \varepsilon_{ik} \frac{\partial^2 U_4}{\partial X_k \partial X_i} = 0 \quad (2.10)$$

2.2.1 Forme générale de la solution

Les équations (2.9) et (2.10) constituent le modèle mathématique de la propagation des ondes élastiques dans les milieux piézoélectriques.

La solution générale pour le déplacement et le potentiel électrique dans ce milieu suit, par analogie, les solutions qu'on donne généralement aux ondes électromagnétiques dans les structures guidées :

$$U_i = u_i \exp(j\beta \alpha_i X_3) \cdot \exp - j(\omega t - \beta(1 + j\gamma)X_1) \quad i=1,2,3,4 \quad (2.11)$$

Où u_i ($i=1,2,3$) sont les amplitudes de déplacement (m), u_i ($i=4$) c'est l'amplitude du potentiel électrique (v), β est la constante de propagation (rad/m), α_i sont les coefficients d'atténuation de l'onde à l'intérieur du cristal piézoélectrique (NP/m) (axe des X_3 (Figure 2.1)), γ est le coefficient d'atténuation longitudinale (NP/m) (axe des X_1) et ω est la fréquence angulaire (rad/s).

Les solutions, dans ce cas, correspondent à des ondes qui se propagent avec ou sans atténuation suivant la direction X_1 . Les déplacements élastiques U_i et le potentiel électrique U_4 varient suivant la direction normale à la surface plane (X_3), mais sont invariant suivant X_2 (Figure 2.1).

En remplaçant l'équation (2.11) dans l'équation (2.9) et (2.10), nous obtenons quatre équations homogènes en u_i ($i=1,2,3,4$) :

$$[A] \cdot [U] = [0] \quad (2.12)$$

Où $[A]$ est une matrice symétrique 4x4

$[U] = [u_1, u_2, u_3, u_4]^t$ Vecteur propre à déterminer

Le développement du déterminant de [A] donne, en générale, un polynôme du 8^{ème} ordre :

$$\sum_{i=0}^8 C_i \cdot \alpha^i = 0 \quad (2.13)$$

L'équation (2.13) est appelée équation de dispersion ou équation séculaire.

La solution de l'équation (2.13) donne pour chaque β ($\beta=2.\pi.f/V_s$: constante de propagation) huit racines. Ces racines sont en fonction de V_s (vitesse acoustique) et γ (constante d'atténuation longitudinale). Chaque racine engendre trois composantes déplacements de la particule et un potentiel électrique. La solution générale est une combinaison de huit racines (8 ondes partielles) donnée par cette expression [23] :

$$U_i = \sum_{n=1}^8 D_i^n \cdot \exp \{ j\beta \cdot \alpha^n \cdot X_3 + j\beta \cdot X_1 (1 + j\gamma) - j\omega \cdot t \} \quad i=1,4 \quad (2.14)$$

Où D_i^n paramètre en relation avec les composantes du vecteur propre du système (2.12) associées à la valeur propre α^n

2.2.2 Comportement des racines de l'équation de dispersion

Les racines de l'équation de dispersion dépendent de la vitesse acoustique V_s .

A une vitesse inférieure à la vitesse basse de volume dans le milieu, toutes les racines sont complexes et conjuguées deux à deux.

$$\alpha^{(1)} = \alpha_{re}^{(1)} + j\alpha_{im}^{(1)} \quad \text{et} \quad \alpha^{(2)} = \alpha_{re}^{(2)} - j\alpha_{im}^{(2)}$$

$$\text{Où } \alpha_{re}^{(j)} = \alpha_{re}^{(j+1)} \quad \text{et} \quad \alpha_{im}^{(j)} = \alpha_{im}^{(j+1)} \quad \text{avec } j=1,3,5,7$$

Cela correspond à l'onde partielle :

$$U_i^{(1)} = A_i^{(1)} \exp [j\beta \cdot \alpha_{re}^{(1)} \cdot X_3 - \beta \cdot \alpha_{im}^{(1)} \cdot X_3] \exp (j\beta \cdot X_1) \quad (2.15)$$

$$U_i^{(2)} = A_i^{(2)} \exp [j\beta \cdot \alpha_{re}^{(2)} \cdot X_3 + \beta \cdot \alpha_{im}^{(2)} \cdot X_3] \exp (j\beta \cdot X_1) \quad (2.16)$$

Après développement on aura :

$$U_i^{(1)} = A_i^{(1)} \exp [-\beta \cdot \alpha_{im}^{(1)} \cdot X_3] \exp j\beta [\alpha_{re}^{(1)} \cdot X_3 + X_1] \quad (2.17)$$

$$U_i^{(2)} = A_i^{(2)} \exp\left[+\beta \cdot \alpha_{im}^{(2)} \cdot X_3\right] \exp j\beta\left[\alpha_{re}^{(2)} \cdot X_3 + X_1\right] \quad (2.18)$$

Les ondes partielles $U_i^{(1)}$ se propagent suivant la direction donnée par le plan X_1 et X_3 et s'atténuent suivant X_3 .

Seules les racines à partie imaginaire négative sont acceptables. Ce mode correspond au mode de surface ou mode de Rayleigh (Figure 2.2)

Pour des valeurs de vitesses supérieures, certaines racines sont réelles c.-à-d. :

$$U_i^{(1)} = A_i^{(1)} \exp j\beta\left[\alpha_{re}^{(1)} \cdot X_3 + X_1\right] \quad (2.19)$$

$$U_i^{(2)} = A_i^{(2)} \exp j\beta\left[\alpha_{re}^{(2)} \cdot X_3 + X_1\right] \quad (2.20)$$

Les ondes de volume sont obtenues pour des valeurs de $\alpha_{re}^{(1)} < 0$ (Figure 2.3).

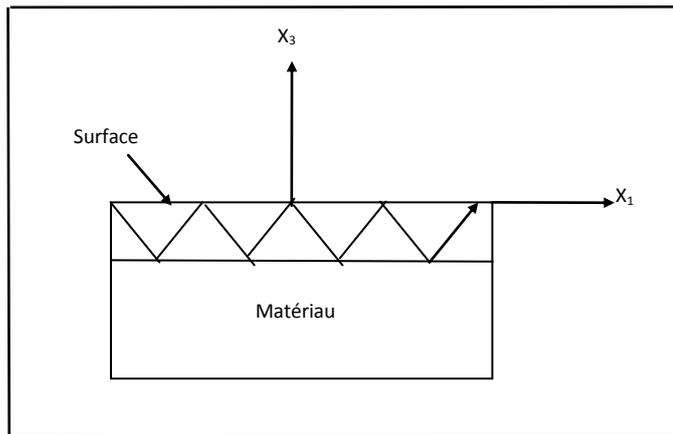


Figure 2.2 : Ondes acoustiques de surface

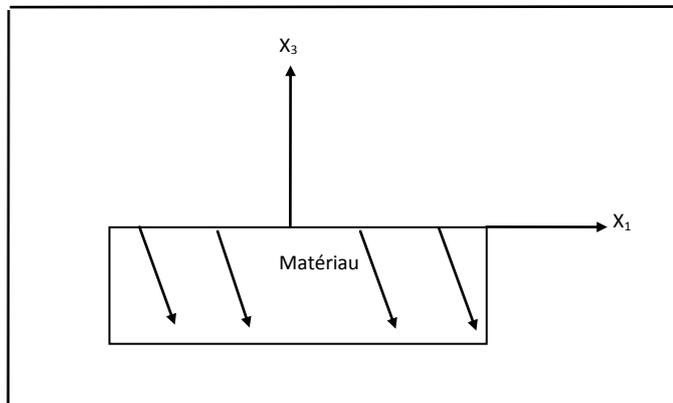


Figure 2.3 : Ondes acoustiques de volume

2.3 Application sur le LiNbO₃ de Coupe Y-X

Dans cet exemple, on montre les variations des parties réelles et imaginaires des coefficients d'atténuation en fonction de la vitesse acoustique (Figure 2.4, Figure 2.5, Figure 2.6 et Figure 2.7). Ces résultats sont conformes à ceux de la littérature [23, 24].

Sur ces figures, nous indiquons les ondes de volume (parties réelles négatives).

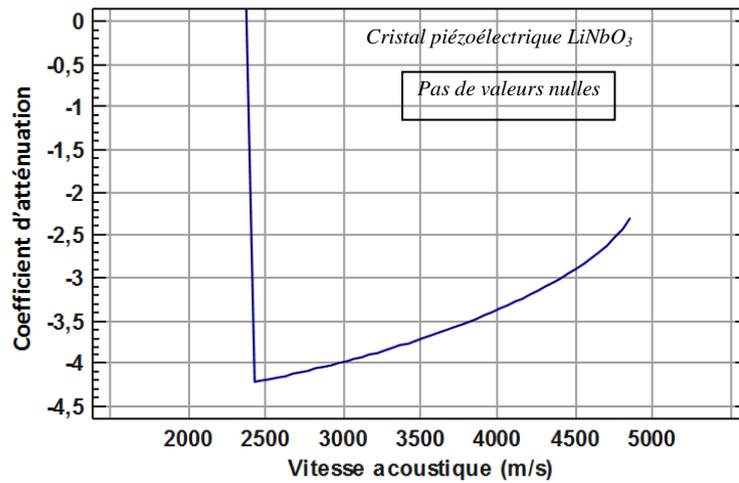


Figure 2.4a : Partie imaginaire de α_1

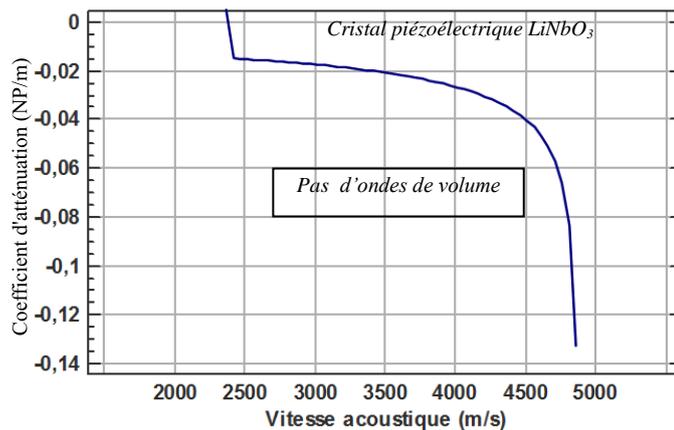


Figure 2.4b : Partie réelle de α_1

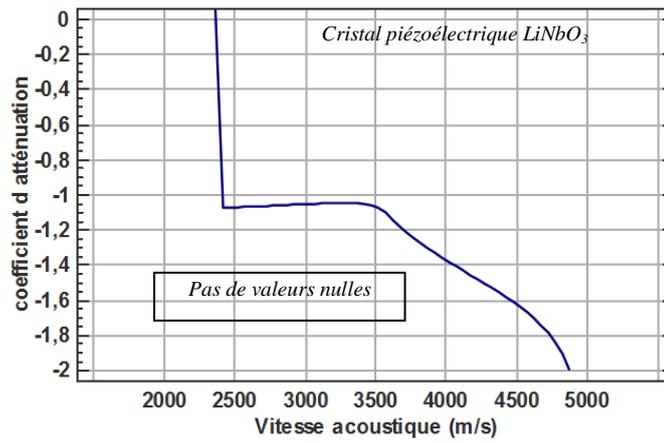


Figure 2.5a : Partie imaginaire de α_2

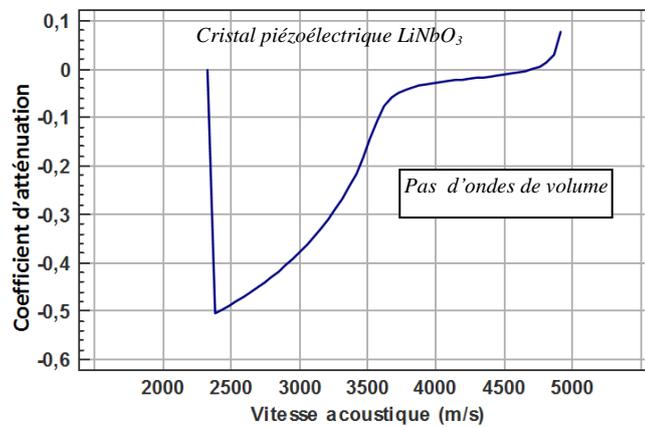


Figure 2.5b : Partie réelle de α_2

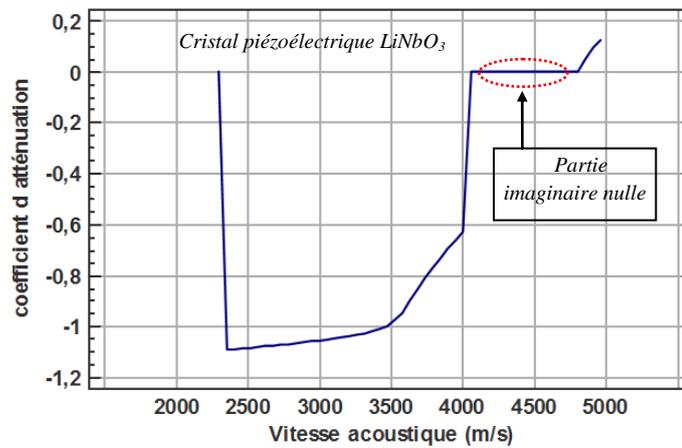


Figure 2.6a : Partie imaginaire de α_3

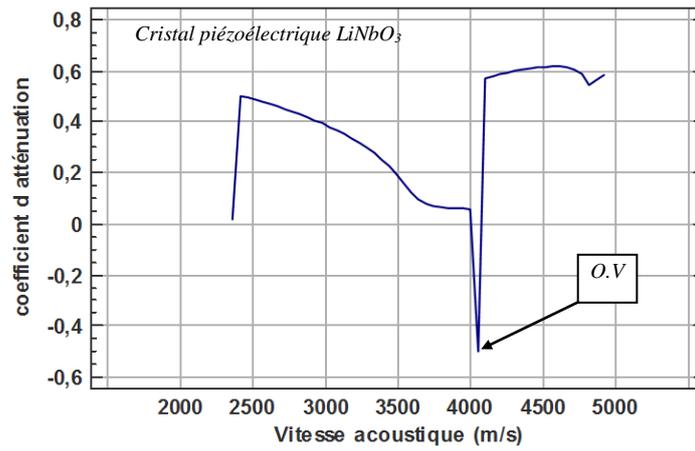


Figure 2.6b : Partie réelle de α_3

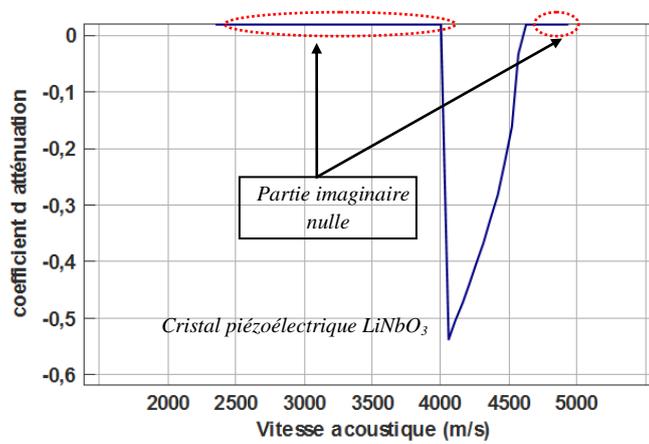


Figure 2.7a : Partie imaginaire de α_4

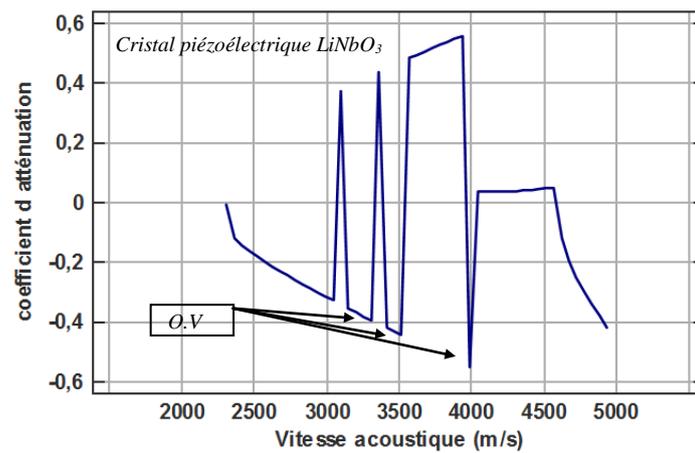


Figure 2.7b : Partie réelle de α_4

2.4 Application sur le LiNbO₃ coupe Y-Z

Les variations des parties réelles et imaginaires des coefficients d'atténuation en fonction de la vitesse acoustique dans le cas de la coupe Y-Z (Figure 2.8, Figure 2.9, Figure 2.10 et Figure 2.11).

Sur ces figures, nous allons indiquer la présence des ondes de volume (parties réelles nulles et parties imaginaires positives).

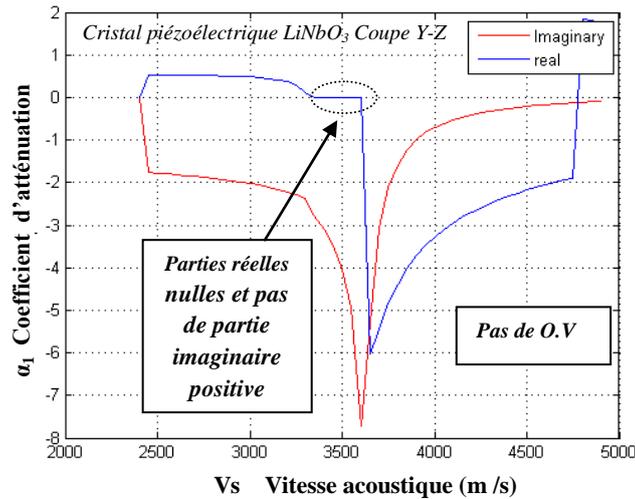


Figure 2. 8 : α_1 en fonction de V_s

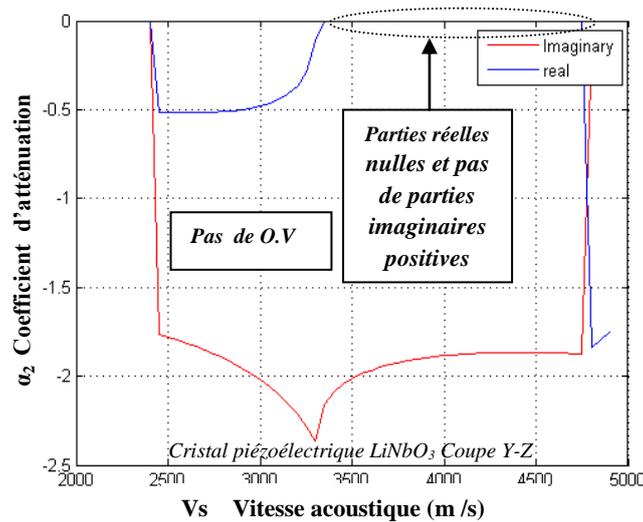


Figure 2. 9 : α_2 en fonction de V_s

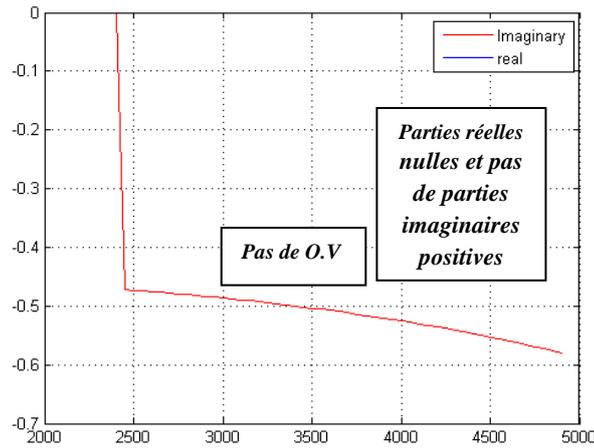


Figure 2. 10 : α_3 en fonction de V_s

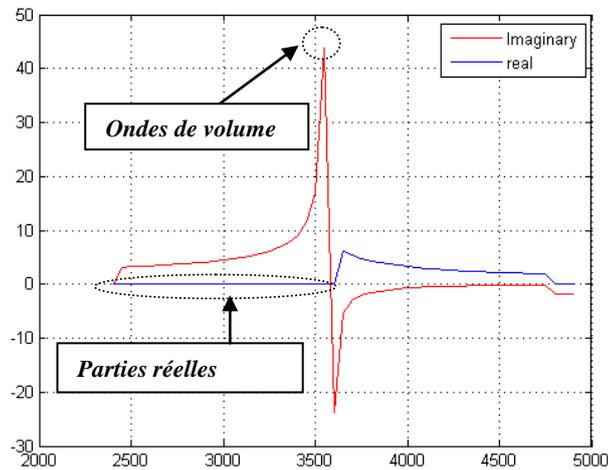


Figure 2. 11 : α_4 en fonction de V_s

2.5 Conclusion

Dans ce chapitre, nous avons expliqué le sens physique des ondes de volume (BAW) en se basant sur des résultats numériques représentés par les coefficients d'atténuations (coefficients de pénétration). Les variations de leurs parties réelles et imaginaires en fonction de la vitesse acoustique, permettent de distinguer les différents modes de propagation en particulier les ondes de volume (BAW). Ces ondes feront l'objet d'une attention très particulière dans le chapitre 4, où nous aborderons de manière extensive l'utilisation de la classification par les réseaux de neurones. Le chapitre suivant présentera la théorie de classification par les réseaux de neurones.

Chapitre 3 : La théorie des réseaux de neurones probabilistes (PNN)

3.1. Introduction

Au cours des deux dernières décennies, les réseaux de neurones ont connus à grand intérêt pour beaucoup de problématiques, et dans de domaines aussi diversifier que la finance, la médecine, la production industrielle, la géologie et la physique [25-28].

Parmi ces intérêts est l'extraction des modèles et la détection des tendances basées sur des fonctions mathématiques difficiles à modéliser par des techniques classiques sans oublier la précision des données. Les réseaux de neurones sont particulièrement bien adaptés à l'application de problématiques dans les domaines de la recherche scientifique. On va citer quelques exemples [29].

- Traitement du signal
- Maîtrise des processus
- Robotique
- Classification
- Pré-traitement des données
- Reconnaissance de formes
- Analyse de l'image et synthèse vocale
- Diagnostiques et suivi médical
- Marché boursier et prévisions
- Demande de crédits ou de prêts immobiliers

3.2. Aspect biologique

Les réseaux de neurones font partie du domaine de l'intelligence artificielle, ils ont comme but la faculté d'apprendre les systèmes biologiques de neurones, en modélisant la structure intrinsèque du cerveau [30].

Nous savons que le cerveau est constitué d'un très grand nombre de neurones connectés entre eux par plusieurs milliers d'interconnexions. Chaque neurone est une cellule spécialisée,

capable de créer, envoyer et recevoir des signaux électrochimiques. Comme les cellules biologiques, les neurones possèdent un corps cellulaire, des prolongements apportant des informations au neurone (les dendrites), et un prolongement qui communique les informations recueillies par le neurone (les axones). L'axone d'une cellule est connecté aux dendrites d'une autre par l'intermédiaire d'une synapse. Lorsqu'un neurone est activé, il envoie un signal électrochimique à travers l'axone. Cette impulsion traverse les synapses vers des milliers d'autres neurones, qui peuvent à leur tour, envoyer et propager le signal à l'ensemble du système neuronal. Un neurone ne va émettre une impulsion que si le signal transmis au corps cellulaire par les dendrites dépasse un certain seuil (déclenchement). Si un neurone n'accompli pas une tâche, les résultats peuvent devenir fabuleux alors qu'un grand nombre de neurones unissent leurs efforts. Ils peuvent créer des tâches cognitives extrêmement complexes (l'apprentissage). Par conséquent, grâce à un très grand nombre d'unités simples de traitement, le cerveau réussit à réaliser des tâches très complexes [29, 31].

3.3. Modèle mathématique

Dans le cas d'un système à un seul neurone, les entrées x envoient des impulsions au neurone qui calcule une somme pondérée des signaux transformés par une fonction mathématique f .

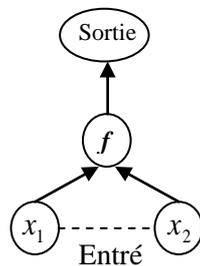


Figure 3.1 : Model à un seul neurone

La figure ci-dessus, montre la forme la plus simple des réseaux de neurones artificiels constitué d'un seul neurone avec un certain nombre d'entrées et une seule sortie.

Le neurone reçoit des signaux en provenance des différentes sources. Ces sources proviennent généralement des données connues par variables d'entrée x . Ces entrées arrivent au neurone par l'intermédiaire d'une connexion avec d'une certaine pondération, connue sous le nom de poids dont l'importance est représentée par une valeur. Plus la valeur d'un poids w est importante, plus l'intensité du signal entrant est forte et plus l'entrée correspondante est influente [25, 26].

Pendant la réception des signaux, une somme pondérée des entrées est calculée pour constituer la fonction d'activation f du neurone. L'activation du neurone est une fonction mathématique qui convertit la somme pondérée des signaux afin de produire la sortie du neurone [32].

$$\text{sortie} = f(w_1x_1 + \dots + w_dx_d) \quad (3.1)$$

La sortie d'un neurone représente la prévision du modèle à un seul neurone pour une variable du jeu de données appelée la cible t . Cependant, il existe une relation entre les entrées x et les cibles t , modélisée par le réseau de neurones par une fonction mathématique.

3.4. Réseaux de neurones non-bouclés

Un seul neurone n'est pas en mesure d'effectuer une tâche significative à lui seul. De nombreux neurones interconnectés ont la possibilité de faire beaucoup mieux.

Un réseau doit posséder des entrées et des sorties. Les entrées et les sorties correspondent aux nerfs moteurs et sensoriels comme ceux qui relient les yeux aux mains. Il peut exister des neurones cachés qui vont jouer un rôle interne dans le réseau. Il est donc nécessaire que les neurones d'entrée, les neurones cachés et les neurones de sortie soient connectés [29, 30].

Les réseaux de neurones les plus simples possèdent une structure feed-forward (ou non-bouclée) c'est-à-dire une structure dans laquelle les neurones ne sont connectés que dans un sens : les signaux provenant des entrées traversent les unités cachées pour atteindre les unités de sortie. Une telle structure possède un comportement stable et une tolérance à la faute.

Les réseaux de neurones non bouclés (feed-forward) sont de loin les plus efficaces pour aborder les problématiques concrètes et ils sont les plus utilisés [26].

Un réseau feed-forward type possède des neurones organisés dans des couches distinctes. Dans ce cas, la couche d'entrée sert à introduire les valeurs des variables d'entrée. Les neurones de la couche cachée et de la couche de sortie sont connectés à toutes les unités de la couche précédente.

3.5. Les tâches des réseaux de neurones

Les réseaux de neurones ont pour tâches d'effectuer différentes fonctions, notamment la régression et classification. Les tâches de régression permettent de mettre en relation un certain nombre de variables d'entrée x avec un ensemble de résultats continus t (*cible*). Alors que les tâches de classification visent à affecter des observations aux classes d'une variable cible catégorielle en fonction d'un ensemble de valeurs d'entrée.

3.6. Régression non-paramétriques

L'approche la plus directe, consiste à modéliser les données en utilisant une forme fermée de fonction pouvant contenir un certain nombre de paramètres (poids) ajustables pour que le modèle donne la meilleure explication possible de nos données. La fonction mathématique utilisée pour modéliser ces relations est donnée par une transformation linéaire f à deux paramètres, connus sous le nom d'ordonnées à l'origine a et de pente b .

$$t = f(x) = a + bx \tag{3.2}$$

Dans la relation (3.2), on cherche les valeurs de a et b permettant de faire le lien entre l'entrée x et la variable t . Cette problématique est connue sous le nom de régression linéaire.

Un autre exemple de régression paramétrique est le problème quadratique où la relation entrées-sorties s'exprime par une forme quadratique [33,34] :

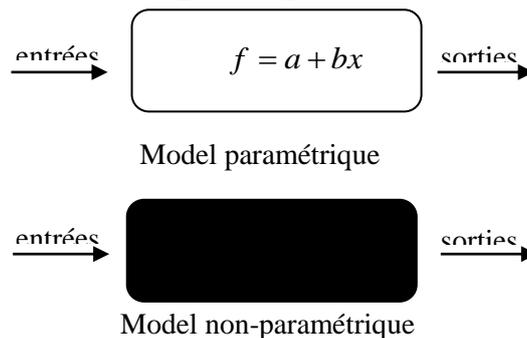


Figure 3.2 : La différence entre les modèles paramétriques et les modèles non-paramétriques

Donc, la relation entre les entrées et les sorties s'exprime par une fonction mathématique de forme fermée. Par contre, dans les modèles non-paramétriques, la relation entre les entrées et les sorties est pilotée par un approximateur (comme un réseau de neurones) qu'on ne peut pas représenter par une fonction mathématique standard.

La catégorie des méthodes paramétriques repose sur l'hypothèse de la relation connue a priori entre x et t par une forme linéaire ou quadratique [33].

Dans la catégorie des modèles non-paramétriques, il n'est y a aucune hypothèse dans la relation entre x et t . Ces modèles supposent que la relation entre x et t n'est pas connue a priori (boîte noire). Il faut chercher une fonction mathématique dont la forme n'est pas fermée susceptible d'approcher convenablement la représentation de x et de t . Les fonctions les plus courantes de modèles non-paramétriques sont les fonctions polynomiales avec des paramètres adaptables et les réseaux de neurones.

Donc, les modèles paramétriques sont très simples à utiliser avec des résultats faciles à interpréter par contre, ils sont moins flexibles [33].

3.7. Les réseaux de neurones et classification

Les réseaux de neurones, peuvent être utilisés pour résoudre les problématiques de classification concernant l'appartenance des individus aux classes, à une entrée x .

Soit un fichier de données avec trois catégories $\{A, B, C\}$.

- Un réseau de neurones affecte chacune des entrées à l'une de ces trois classes.
- L'information relative à l'appartenance des individus aux différentes classes est transmise à la variable t .

Dans une analyse de classification, la variable cible doit toujours être catégorielle [33, 34].

Une variable est dite catégorielle si :

- 1- elle ne comporte que des valeurs discrètes
- 2- ne peuvent être classées dans un ordre hiérarchique

3.8. Types de réseaux de neurones

3.8.1. Les réseaux de neurones perceptron multicouches

Le schéma d'un réseau de neurones PMC2 connecté à trois entrées, quatre unités cachées (neurones), et trois sorties. La couche cachée et la couche de sortie possèdent un terme de biais. Le biais est un neurone qui émet un signal d'intensité 1 [33, 34].

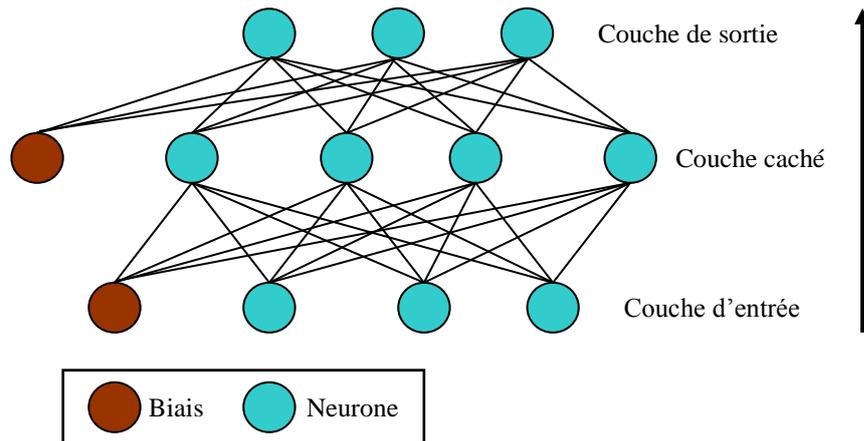


Figure 3.3 : Schéma d'un réseau de neurones PMC2

Les Perceptrons multicouches (PMC) constituent l'architecture la plus utilisée dans le domaine de l'intelligence artificielle [26, 35]. La conception des Perceptrons Multicouches dépend du nombre de couches cachées ainsi que du nombre d'unités dans ces couches.

Dans ce cas, Chaque neurone calcule une somme pondérée de ses entrées qu'il va transmettre à une fonction de transfert pour créer ses sorties. Pour chaque couche du réseau de neurones dans un réseau PMC, il existe un terme de biais dont le rôle est de se connecter aux neurones de la couche précédente par l'intermédiaire d'un poids. Les neurones et les biais sont organisés dans une structure de couches non-bouclées (feed-forward). Le réseau peut être considéré comme un modèle entrée-sortie, les poids et les seuils étant les paramètres libres du modèle. Ces réseaux sont en mesure de modéliser des fonctions très complexes, où le nombre de couches et le nombre d'unités dans chaque couche détermine la complexité de la fonction [26].

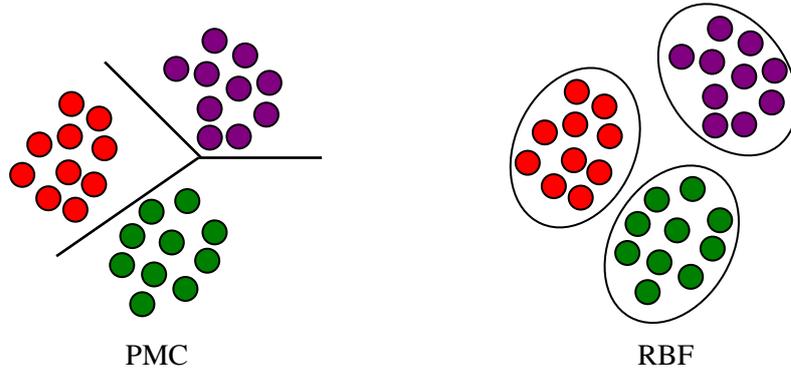


Figure 3.4 : La différence entre des réseaux de neurones PMC et RBF dans un espace à deux dimensions pour les données d'entrée

Le schéma ci-dessus représente la différence entre des réseaux de neurones PMC et RBF dans un espace à deux dimensions pour les données d'entrée [33, 36].

3.8.2. Les réseaux de neurones à fonctions radiales

Soit la structure suivante :

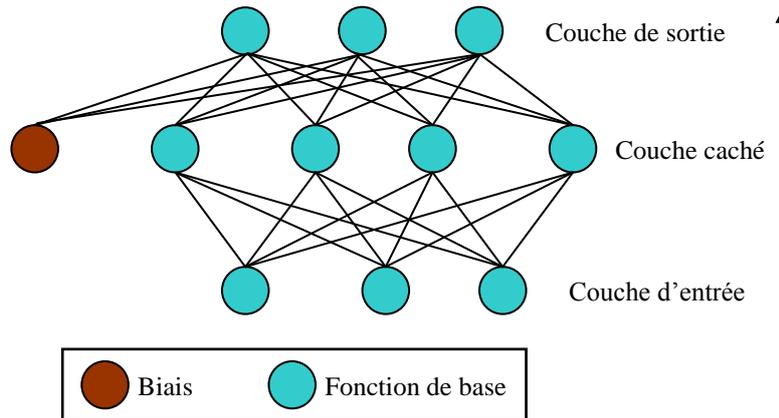


Figure 3.5 : Schéma d'un réseau de neurones RBF

Le schéma d'un réseau de neurones RBF à trois entrées, quatre fonctions à base radiale et trois sorties.

Dans ce cas, seules les unités de sortie possèdent un terme de biais (contrairement aux réseaux PMC).

Le réseau RBF va effectuer l'opération d'apprentissage en deux étapes :

- Dans la première étape, les réseaux RBF vont modéliser la distribution de probabilités des données d'entrée grâce aux neurones de la couche cachée (fonctions à base radiale).
- Dans la deuxième étape, le réseau RBF va effectuer la mise en relation des données d'entrée x à une variable cible t [35].

3.8.3. Le réseau de neurones probabiliste (PNN)

Les PNNs possèdent des propriétés très intéressantes pour les problèmes de classification, ils ont comme avantage pas de minima locaux et comme inconvénient, le nombre de neurones cachés est le même que le nombre d'échantillons de l'apprentissage.

3.8.3.1. Principe de réseaux de neurones probabilistes

Dans ce cas, chaque vecteur observé x (de dimension d) est placé dans une des classes de cluster C_i , $i=1, 2, \dots, m$ prédéfini; où m est le nombre de classes possibles.

L'action du classificateur est limitée par d et m . Le classificateur de Bayes met en œuvre le modèle de la règle de Bayes de probabilité conditionnelle que la probabilité $P(C_i/x)$ pour x d'appartenir à la classe C_i . Cette probabilité est donnée par [25,37] :

$$P(C_i|x) = \frac{P(x|C_i)P(C_i)}{\sum_{j=1}^m P(x|C_j)P(C_j)} \quad (3.3)$$

Où $P(C_i/x)$ est la fonction de densité de probabilité conditionnelle de x sachant C_i et $P(C_j)$ est la probabilité de choisir un échantillon de la classe C_j .

Un vecteur en entrée x est classifié comme appartenant à C_i si [25, 37] :

$$P(C_i|x) > P(C_j|x); \forall j = 1, 2, \dots, m; j \neq i \quad (3.4)$$

L'estimation de ces probabilités à partir de l'ensemble d'apprentissage est réalisée en utilisant la technique de fenêtrage de Parzen pour l'estimation des fonctions de densités [33].

L'estimateur utilisé pour les réseaux PNN est [25] :

$$f_A(x) = \frac{1}{2\pi^{p/2}\sigma^p} \frac{1}{m} \exp\left[-\frac{(X - X_{ai})^t (X - X_x)}{2\sigma^2}\right] \quad (3.5)$$

X_{ai} est le $i^{\text{ème}}$ échantillon appartenant à la classe C_A et σ est un paramètre de lissage.

3.8.3.2. Architecture d'un réseau probabiliste

Donnée par cette structure :

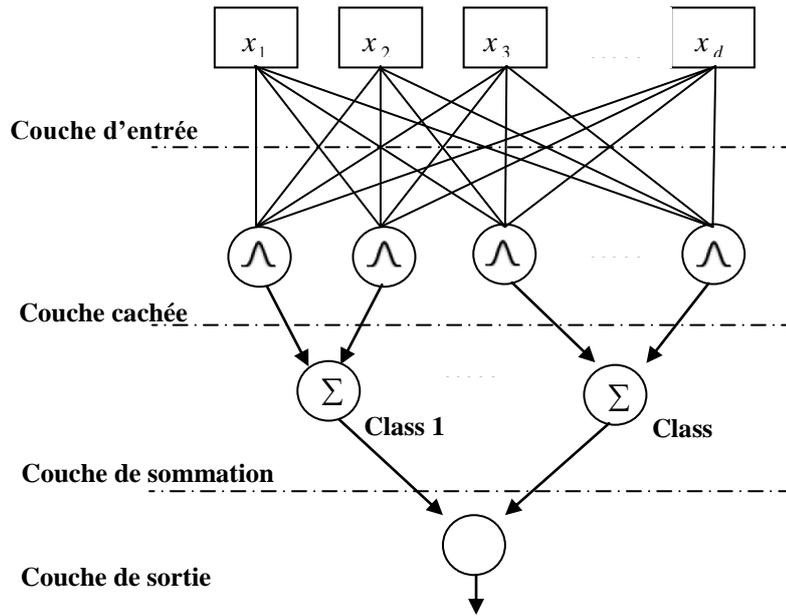


Figure 3.6 : Architecture générale d'un réseau probabiliste.

3.8.3.3. Algorithme d'apprentissage standard

Pour l'apprentissage d'un réseau probabiliste, chaque vecteur x en entrée doit être normalisé comme suit [25, 26] :

$$\sum_{i=1}^n x_i^2 = 1 \tag{3.6}$$

Le nombre de neurones d'entrée est égal au nombre des paramètres (variables) de la forme à classifier [18, 30].

Chaque échantillon de la base d'apprentissage doit correspondre à un neurone dans la couche cachée (couche de motifs) avec les connexions correspondantes avec les neurones d'entrée de façon que $w_k = x_k$ pour $k=1, 2, \dots, n$. La connexion ainsi créée vers le neurone de la couche de classification doit correspondre à la classe de l'échantillon [14] selon l'algorithme suivant :

Début

Initialisation

$j=0$; n =nombre d'échantillons ;

Faire

$j \leftarrow j+1$;

Normalisation : $x_{jk} \leftarrow \frac{x_{jk}}{\sqrt{\sum_i^d x_{jk}^2}}$;

Apprentissage : $w_{jk} \leftarrow x_{jk}$;

Si $x \in w_j$ **alors** $a_{ic} \leftarrow 1$;

Jusqu'à $j=n$;

Fin

3.8.3.4. Algorithme d'apprentissage modifié

Dans ce cas, un apprentissage standard du réseau est réalisé avec l'algorithme modifié d'apprentissage des PNNs dans le but de supprimer les neurones qui sont assez similaires dans leurs. Dans cet algorithme, il est possible d'ajouter ou de supprimer des unités cachées en ajoutant des neurones cachés et leurs connexions respectives. Un autre passage est nécessaire pour supprimer les neurones de faible importance. Ainsi le nouvel algorithme devient :

1ère étape (Construction du PNN initial) : Utilisation de l'algorithme standard d'apprentissage des réseaux probabilistes (Figure 3.6), pour construire un premier PNN initial. Dans ce réseau, le nombre de neurones cachés est égal au nombre d'échantillons d'apprentissage.

2ème étape (Réduction de la taille du réseau) : Le réseau initial de la première étape est transformé en un réseau modifié PNN* (Figure 3.7) [25].

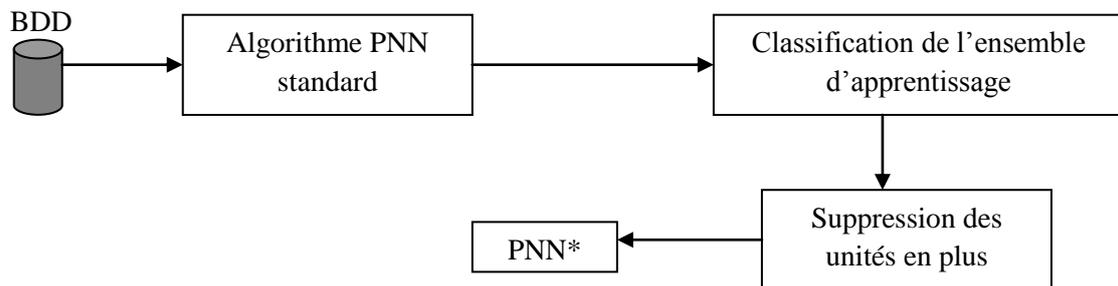


Figure 3.7 : Algorithme d'apprentissage modifié

Début

Initialisation

$k=0$; x =premier échantillon d'apprentissage ;

Faire

$k \leftarrow k+1$;

Suppression du $k^{\text{ème}}$ neurone de la couche cachée ;

Classifier le $k^{\text{ème}}$ échantillon dans le nouveau réseau (PNN*) ;

Si la classification est bonne **alors** Garder le nouveau réseau ;

Sinon Reprendre le PNN de l'étape $k-1$;

Jusqu'à $k=n$;

Fin

3.9. Fonctions d'activation

Les neurones d'un réseau possèdent des fonctions d'activation qui vont transformer les signaux émis par les neurones de la couche précédente à l'aide d'une fonction mathématique appelée fonction d'activation qui va influencer sur la performance du réseau.

Par exemple, pour des problématiques de classification, nous utilisons la fonction softmax [26] alors qu'en régression, nous utilisons la fonction identité (avec une fonction tanh pour les neurones cachés).

STATISTICA Réseaux de Neurones Automatisés propose les fonctions d'activation de neurones (Tableau 3.1). Pour les neurones cachés et les neurones de sortie :

Tableau 3.1– Fonctions d'activation de neurones [33].

| Fonction | Définition | Description | Intervalle de définition |
|-----------------------|---|---|--------------------------|
| Identité | a | L'activation du neurone est transmise directement en sortie | $(-\infty + \infty)$ |
| Sigmoïde logistique | $\frac{1}{1 + e^{-a}}$ | Une courbe en "S" | $(0,1)$ |
| Tangente hyperbolique | $\frac{e^a - e^{-a}}{e^a + e^{-a}}$ | Une courbe sigmoïdale similaire à la fonction logistique. Produit généralement de meilleurs résultats que la fonction logistique en raison de sa symétrie. Idéale pour les perceptrons multicouches, en particulier, pour les couches cachées | $(-1,+1)$ |
| Exponentielle | e^{-a} | La fonction exponentielle négative | $(0,+\infty)$ |
| Sinus | $\sin(a)$ | S'utilise éventuellement si les données sont distribuées radialement. N'est pas utilisé par défaut | $[0,1]$ |
| Softmax | $\frac{\exp(a_i)}{\sum \exp(a_i)}$ | Essentiellement utilisé (mais pas uniquement) pour des tâches de classification. Permet de construire des réseaux de neurones avec plusieurs sorties normalisées ce qui le rend particulièrement adapté à la création de classifications par les réseaux de neurones avec des sorties probabilistes. | $[0,1]$ |
| Gaussienne | $\frac{1}{\sqrt{2\pi\sigma}} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right]$ | Ce type de fonction d'activation isotropique Gaussienne n'est utilisé que par les unités cachées d'un réseau de neurones RBF également connu sous le nom de fonctions à base radiale. Les paramètres de position (également connus sous le nom de vecteurs de prototypes) et de dispersion sont équivalents aux poids de la couche entrée-cachée d'un réseau de neurones PMC. | |

3.10. Sélection des variables d'entrée

Dans cette section, nous adoptons les entrées qui n'ont pas de lien avec la variable cible, nous pouvons détériorer sans nous en rendre compte la performance du réseau et le fichier de données comportant un nombre insuffisant d'entrées ne peut être modélisé de façon précise par un réseau de neurones [33].

3.11. Complexité du réseau de neurones

La complexité des réseaux de neurones réside dans le nombre de neurones dans la couche cachée. Plus un réseau de neurones comporte de neurones, plus le système sera flexible mais complexe. Les réseaux de neurones flexibles permettent d'approcher des fonctions complexes entre les variables d'entrée et les variables cibles [33,38].

3.12. Apprentissage des réseaux de neurones

L'apprentissage des réseaux de neurones, utilise des algorithmes numériques qui sont en mesure d'effectuer la tâche au cours d'un nombre fini d'itérations. Un algorithme d'apprentissage itératif va ajuster graduellement les poids du réseau de neurones de telle manière que pour toute entrée x , le réseau de neurones produit une sortie proche de t .

3.13. Algorithme d'apprentissage

Les algorithmes les plus utilisés pour l'apprentissage des réseaux de neurones sont les algorithmes BFGS (Broyden-Fletcher-Goldfarb-Shanno) et Scaled Conjugate Gradient --une amélioration subtile des gradients conjugués, permettant de supprimer la minimisation unidimensionnelle [26,39]. Ces algorithmes offrent de meilleurs résultats que les algorithmes classiques comme la Descente de Gradient.

3.13.1. L'apprentissage des réseaux de neurones à fonctions radiales

Les méthodes utilisées pour l'apprentissage des réseaux à fonctions à base radiale sont différentes de celles utilisées pour les PMC [26,40]. Pour les réseaux RBF avec des fonctions d'activation linéaires, le processus d'apprentissage s'effectue en deux étapes dont la première, la position et la dispersion radiale des fonctions de base utilise les données d'entrée et dans la deuxième étape, les poids connectant les fonctions radiales aux neurones de sortie [33-36].

3.14. Conclusion

Dans ce chapitre, on a présenté le principe de l'algorithme de construction des réseaux probabilistes dont le l'avantage est la réduction de la taille avec un taux de classification similaires à un algorithme d'apprentissage standard de PNN. Dans ce cas, le nombre de neurones cachés dans la deuxième couche est très réduit et dépend surtout de la nature de la base de données mais présentant beaucoup de redondances. Les bases de données ont besoin donc, de

moins d'unités cachées pour représenter tous les échantillons d'apprentissage. En réduisant ainsi le nombre de neurones cachés, la rapidité de classification augmente.

Dans le chapitre suivant, nous allons présenter l'application des PNNs pour détecter les ondes de volume dans les structures piézoélectriques.

Chapitre 4 : Détection des ondes de volume par classification en utilisant les réseaux de neurones probabilistes (PNN)

4.1. Introduction

Dans ce chapitre, nous appliquons les réseaux de neurones probabilistes (PNNs) pour détecter les ondes de volume. Pour cela, nous proposons une nouvelle méthode de détection des ondes acoustiques de volume obtenues lors de la propagation des micro-ondes acoustiques dans un substrat piézoélectrique (Niobate de Lithium LiNbO_3). Nous avons utilisé la classification par réseaux de neurones probabilistes comme un moyen d'analyse numérique dans laquelle nous classons toutes les valeurs de la partie réelle et la partie imaginaire de coefficient d'atténuation pour la vitesse acoustique afin de construire un modèle à partir duquel nous détectons les ondes de volume facilement avec des valeurs précises pour chacun des coefficients d'atténuation et de la vitesse acoustique.

Soit la structure piézoélectrique ci-dessous à laquelle nous appliquons un signal sur les électrodes du transducteur qui engendre à son tour des déformations (compression et dilatation), ainsi une onde piézoélectrique prend naissance et se propage dans la direction Z (Figure 4.1).

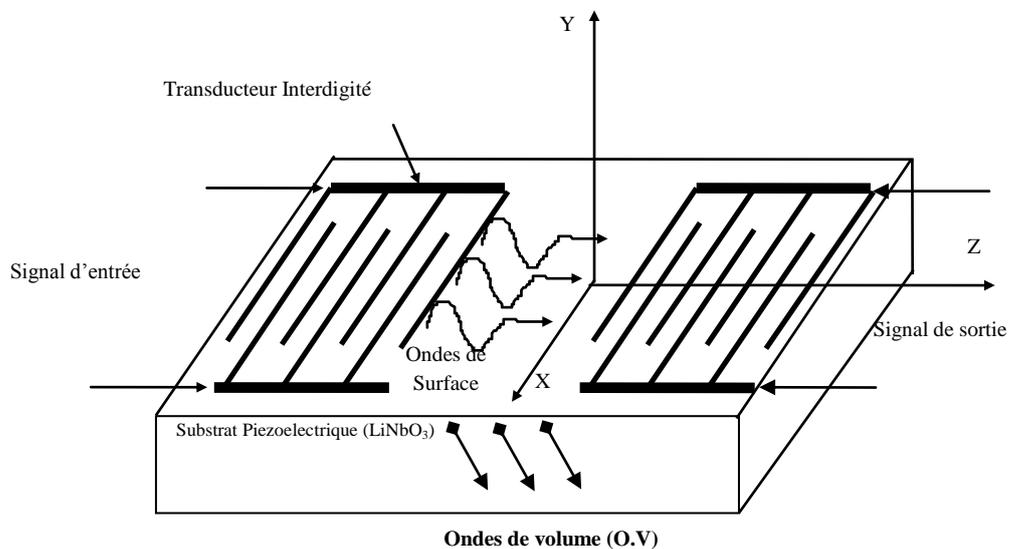


Figure 4.1 : Excitation du matériau piézoélectrique (de Coupe Y-Z) par un transducteur interdigité.

La figure 4.2 représente l'architecture générale de la méthode proposée :

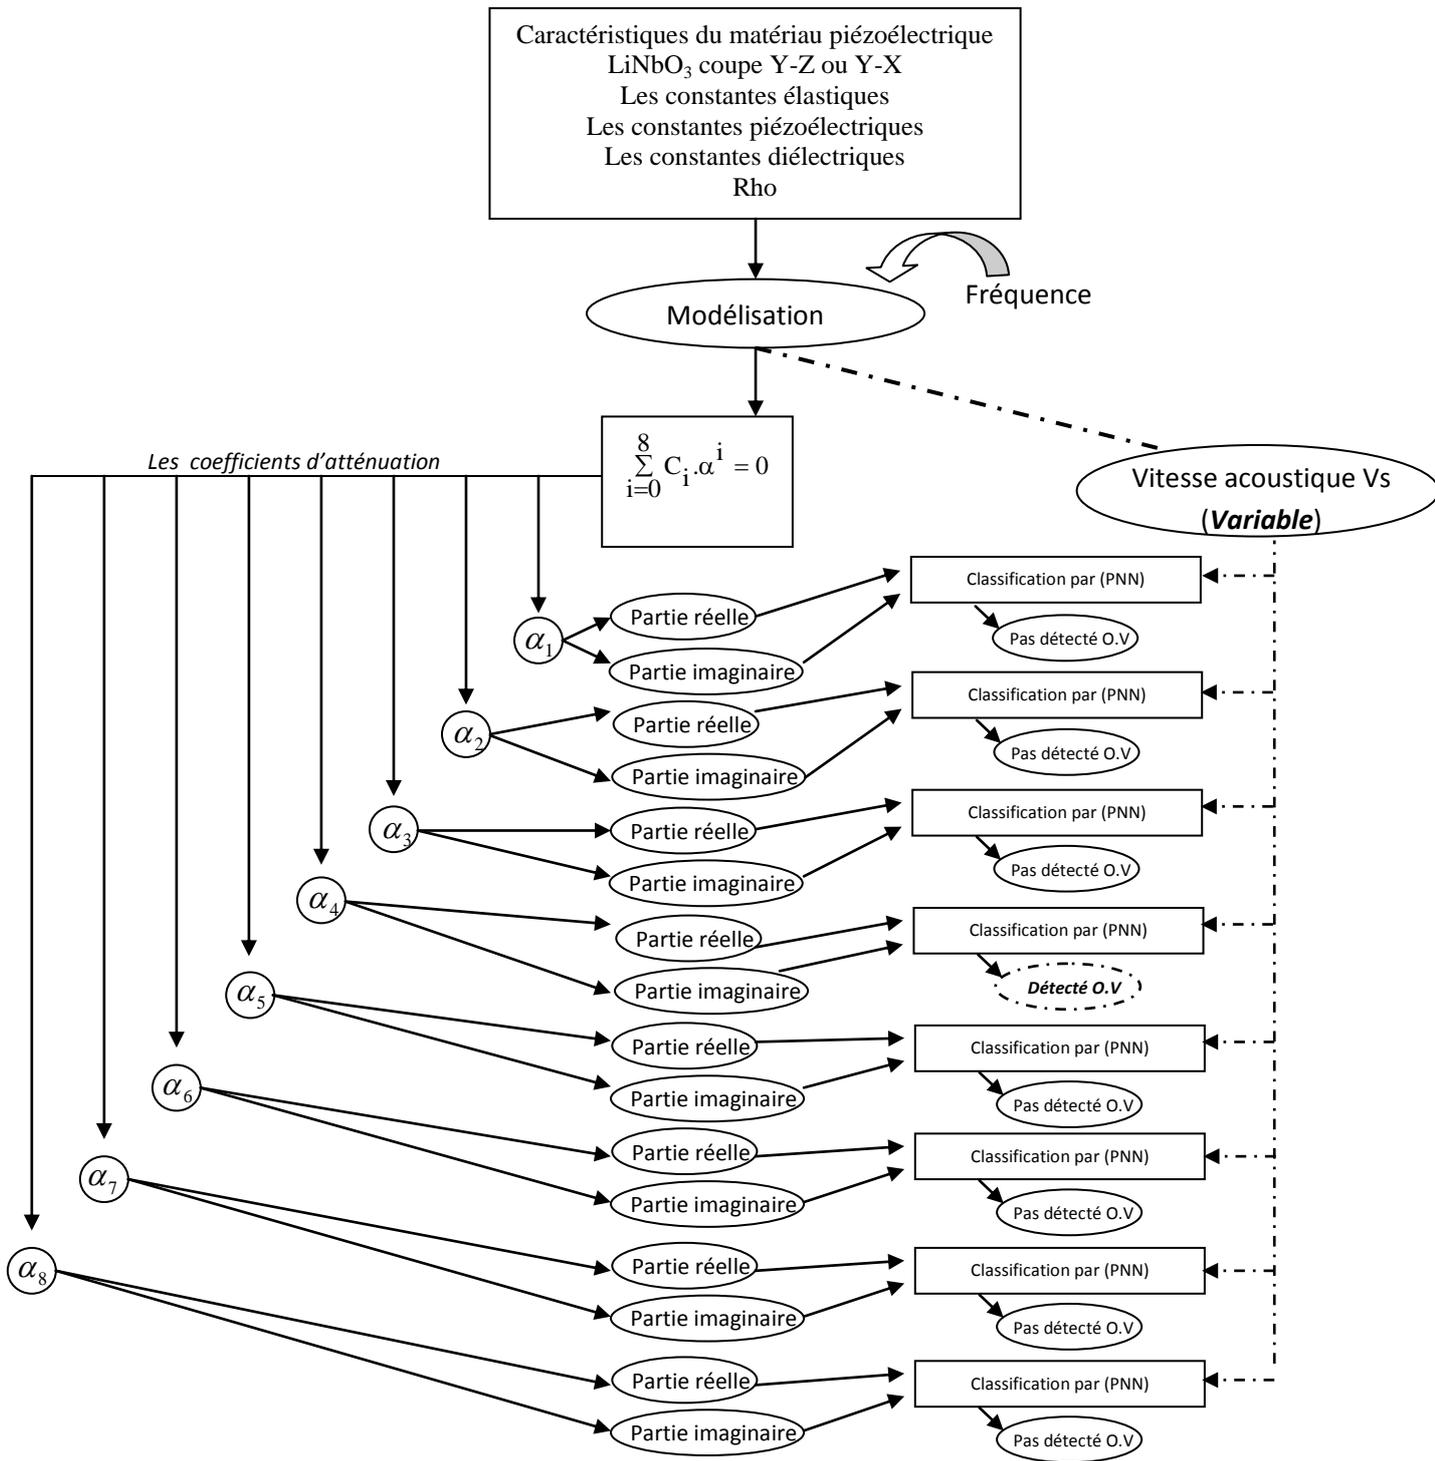


Figure 4.2 : Architecture générale de la méthode.

4.2. Application sur le LiNbO₃ coupe Y-Z

Pour le cas de la coupe Y-Z, les ondes de volume correspondent aux parties imaginaires positives (dans le cas où les parties réelles sont nulles).

Dans ce cas, l'équation séculaire sera sous la forme d'un polynôme du 8^{ème} ordre :

$$\sum_{i=0}^8 C_i \cdot \alpha^i = 0 \quad (4.1)$$

Alors l'onde électroacoustique peut être considérée comme la combinaison linéaire de huit solutions élémentaires (n = 8) :

$$U_j = \sum_{n=1}^8 A_j^{(n)} \cdot \exp [\alpha_n \beta X_3] x \exp [j(\omega t - \beta X_1)] \quad (4.2)$$

$$E_j = \sum_{n=1}^8 a_j^{(n)} \cdot \exp [\alpha_n \beta X_3] x \exp [j(\omega t - \beta X_1)] \quad (4.3)$$

j=2,3 (2, 3 correspondent respectivement à Y=X₃ et Z=X₁ avec E_X=0, U_X=0)

Où a_j⁽ⁿ⁾ : facteurs d'amplitudes électriques

A_j⁽ⁿ⁾ : facteurs d'amplitudes élastiques.

4.3. Identification des ondes de volume

La variation de la vitesse acoustique permet la détection des ondes volume dans le LiNbO₃.

Le coefficient d'atténuation α est donné par :

$$\alpha = a + j b \quad \text{ou} \quad \alpha = - a + j b \quad (4.4)$$

- a et b étant respectivement la partie réelle et imaginaire de α

- (j α) représente deux racines conjuguées deux à deux

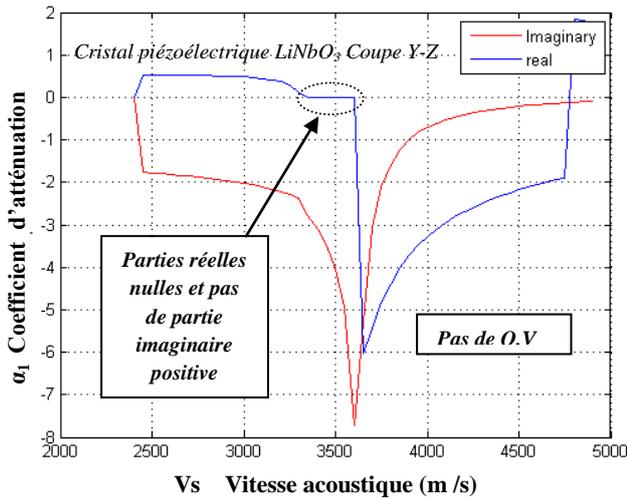


Figure 4. 3 : α_1 en fonction de V_s

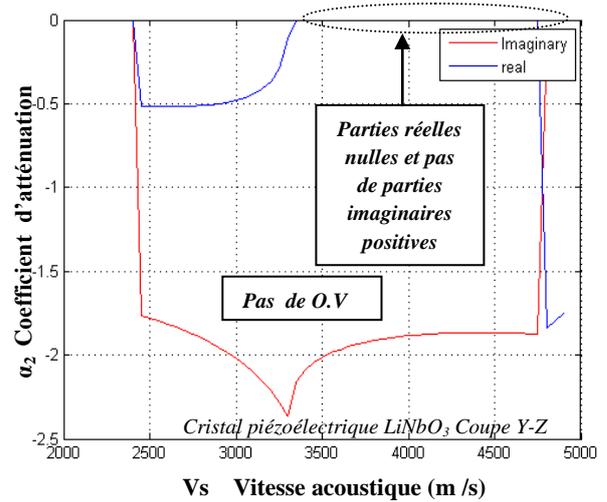


Figure 4. 4 : α_2 en fonction de V_s

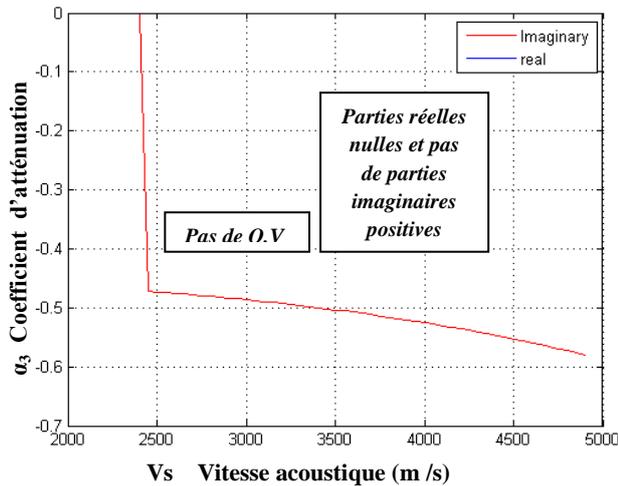


Figure 4. 5 : α_3 en fonction de V_s

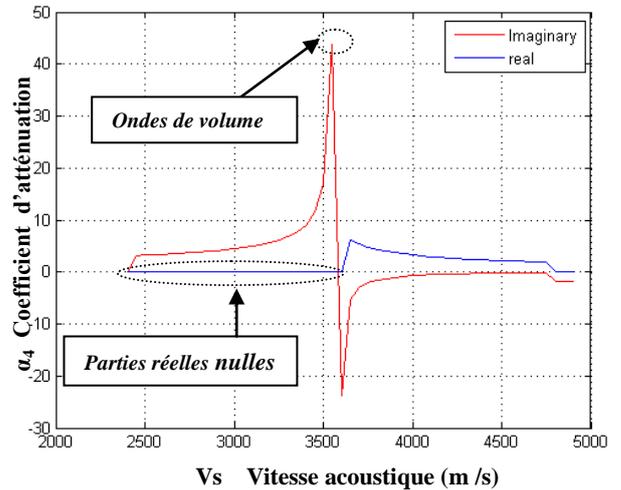


Figure 4. 6 : α_4 en fonction de V_s

Dans cet exemple, nous examinons les variations des parties réelles et imaginaires des coefficients d'atténuation (α_1 , α_2 , α_3 et α_4) en fonction de la vitesse acoustique V_s (figure 4.3, figure 4.4, figure 4.5 et figure 4.6). Nous indiquons, ici, la présence des ondes de volume (partie réelle nulle et partie imaginaire positive) et pour une bonne détection, nous prendrons comme valeur de référence la valeur positive maximale de la partie imaginaire (PIC), cette condition nous permet de tracer un nuage de points des parties réelles par rapport aux parties imaginaires.

4.4. Classement par les réseaux de neurones

Cette procédure utilise les réseaux de neurones probabilistes (PNN) pour classer des sujets dans les différents groupes définis par la vitesse acoustique en se basant sur deux variables en entrée. Parmi les 51 sujets du jeu d'apprentissage 100,0% ont été correctement classés par le réseau (Figure 4.7).

Pourcentage des sujets du jeu d'apprentissage bien classés : 100,00%

Pour connaître les valeurs exactes de la partie réelle et la partie imaginaire du coefficient d'atténuation et la vitesse acoustique, nous devons définir comme :

- ✓ Variable de sélection : La vitesse acoustique.
- ✓ Facteurs en entrée : Partie imaginaire α_4 et Partie réelle α_4 .
- ✓ Changer le facteur de classification.
- ✓ Nombre de sujets dans le jeu d'apprentissage : 51

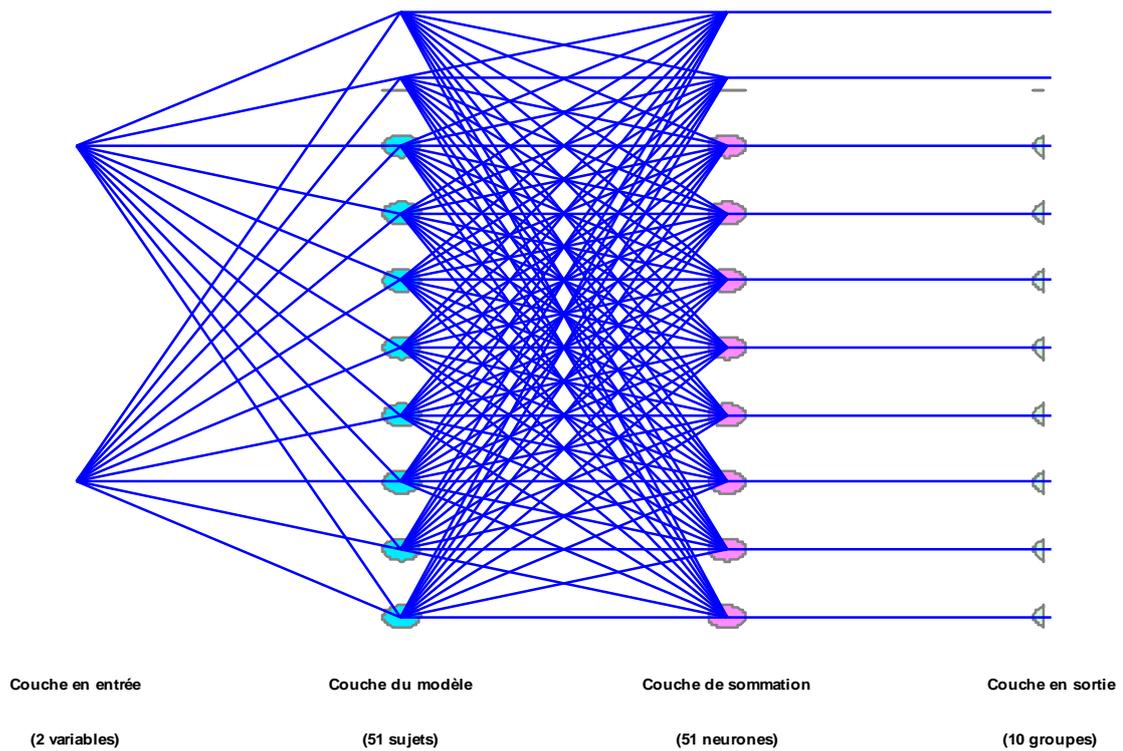


Figure 4. 7 : Architecture générale d'un réseau de neurones probabiliste.

Nous définissons la valeur de la partie imaginaire que nous allons chercher dans la Classification (Figure 4.11).

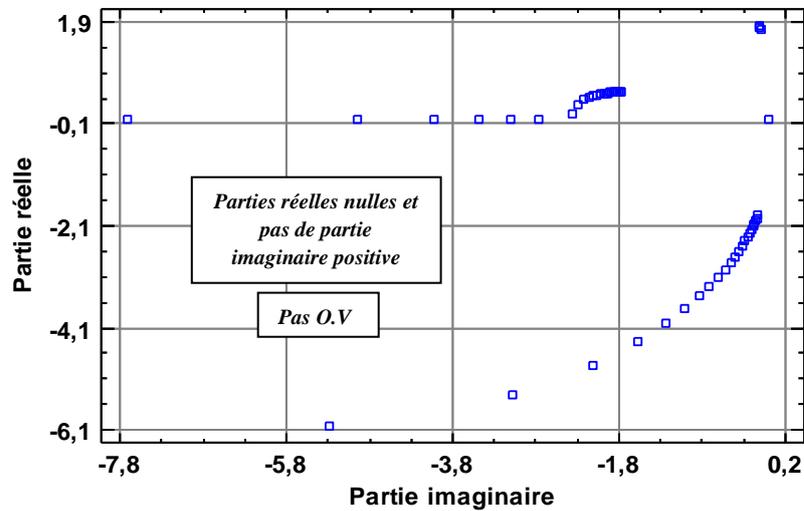


Figure 4.8 : Partie réelle α_1 en fonction de la partie imaginaire α_1

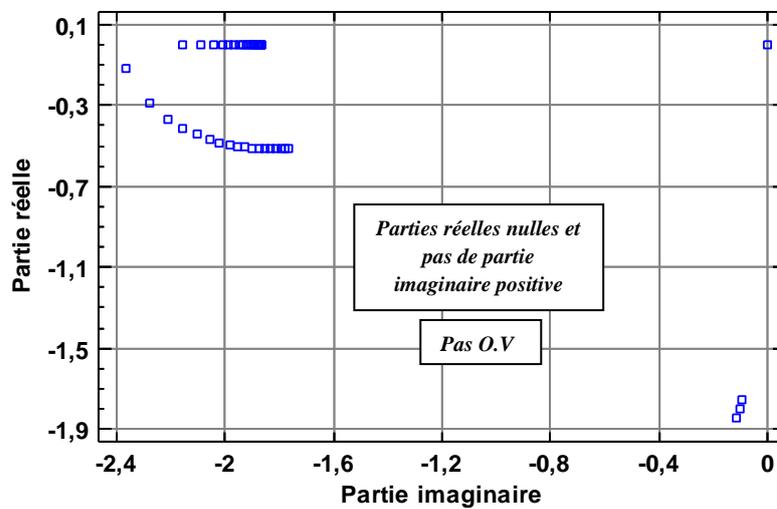


Figure 4.9 : Partie réelle α_2 en fonction de la partie imaginaire α_2

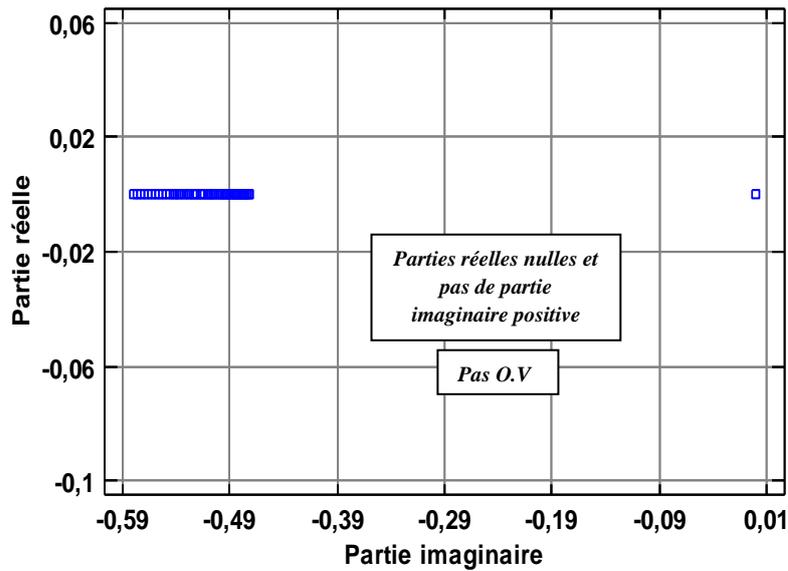


Figure 4.10 : Partie réelle α_3 en fonction de la partie imaginaire α_3

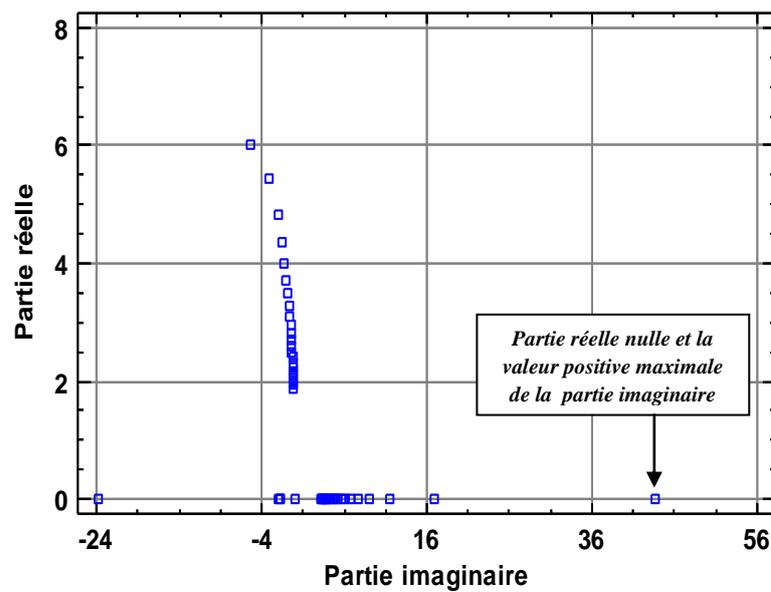


Figure 4.11 : Partie réelle α_4 en fonction de la partie imaginaire α_4

4.5. Résultats et discussion (Pour le LiNbO₃ coupe Y-Z)

1^{ère} étape : Facteur de classement/ partie réelle

La figure 4.12 et la figure 4.13 présente une classification par (PNN) où :

Le facteur de classement est la partie réelle, la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

Nous cherchons la valeur positive maximale de la partie imaginaire avec la partie réelle nulle.

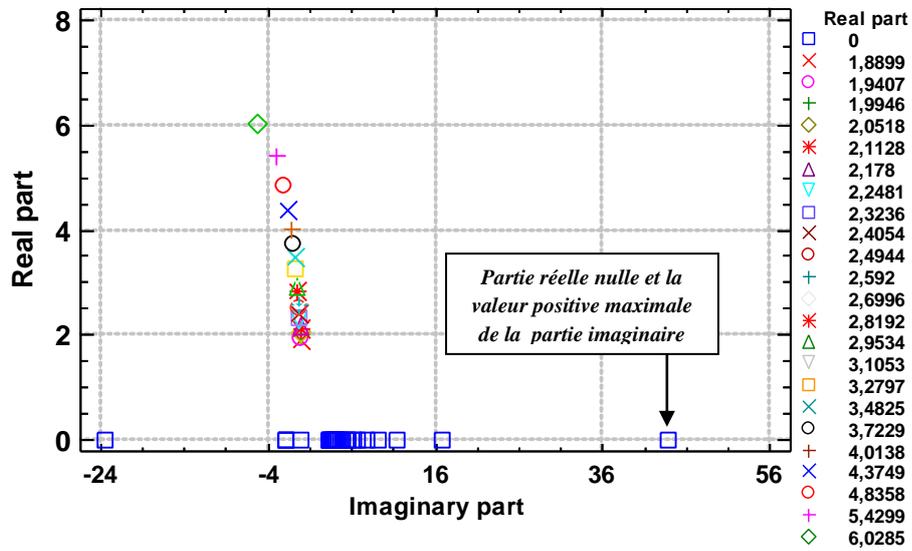


Figure 4.12 : Classement par réseau de neurones probabiliste - partie réelle (Vitesse acoustique m/s) (2D)

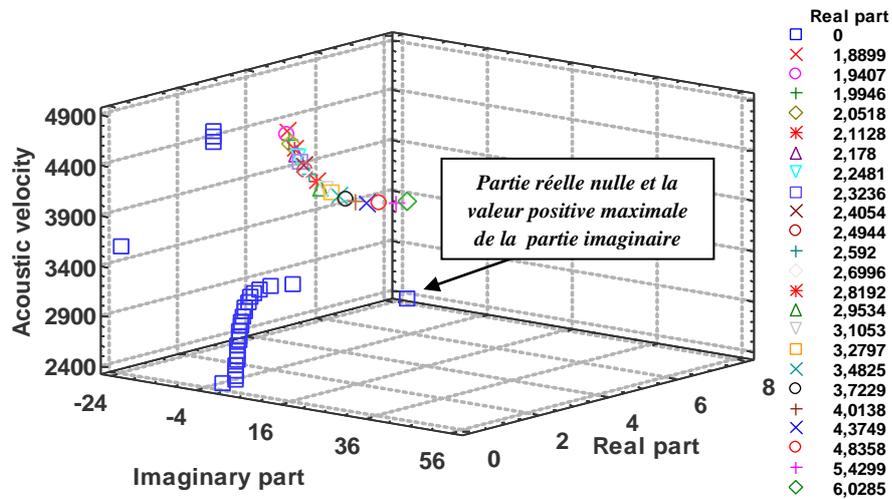


Figure 4.13 : Classement par réseau de neurones probabiliste - partie réelle (Vitesse acoustique m/s) (3D)

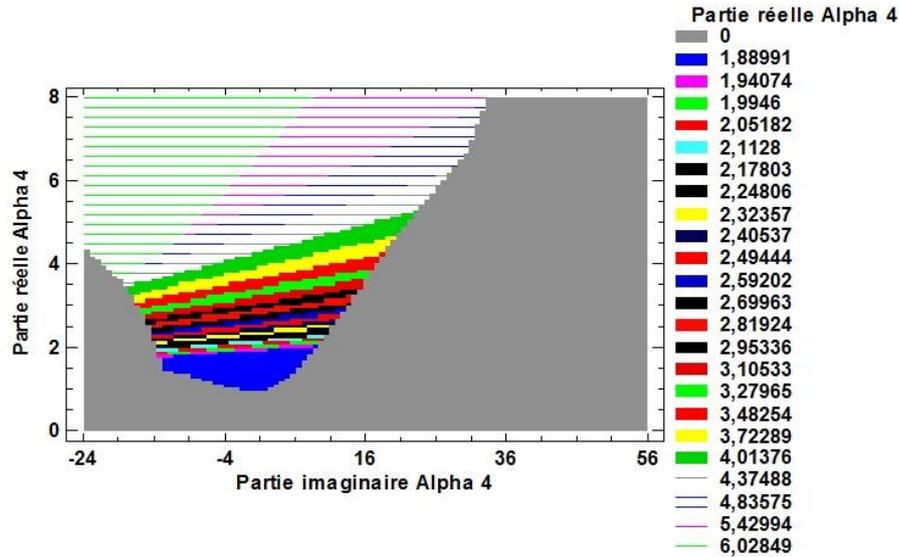


Figure 4.14 : Classement par réseau de neurones probabiliste (graphique de surface)

2^{ème} étape : Facteur de classement/ partie imaginaire

La figure 4.15 et la figure 4.16 présente une classification par (PNN) où :

Le facteur de classement est la partie imaginaire, la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

Nous constatons que la valeur maximale positive de la partie imaginaire égale à 43,7084.

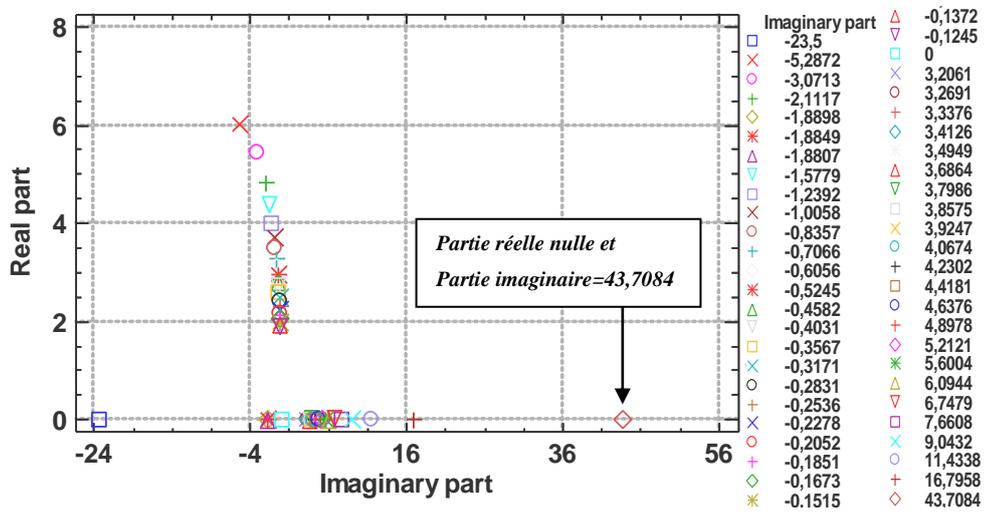


Figure 4.15 : Classement par réseau de neurones probabiliste - partie imaginaire

(Vitesse acoustique) (2D)

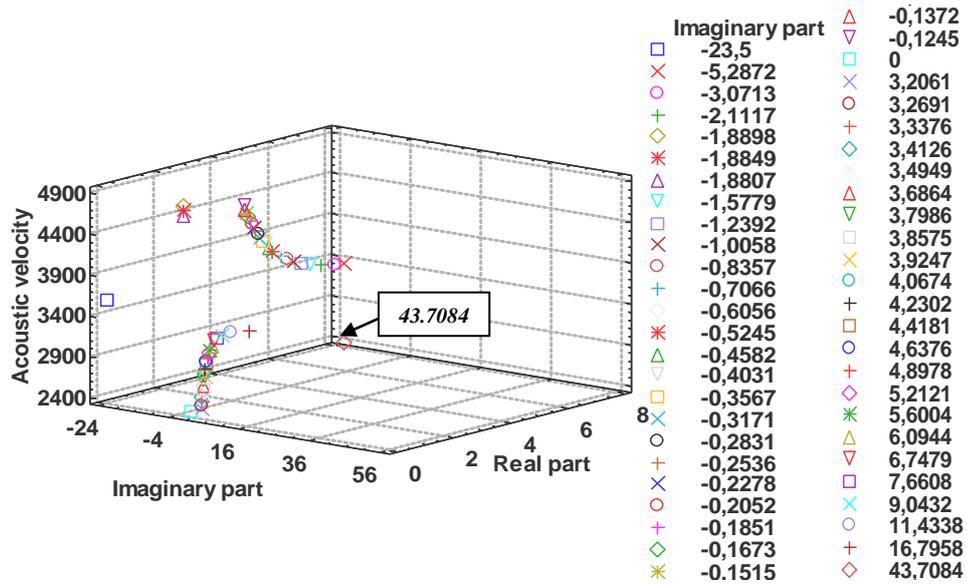


Figure 4.16 : Classement par réseau de neurones probabiliste - partie imaginaire

(Vitesse acoustique m/s) (3D)

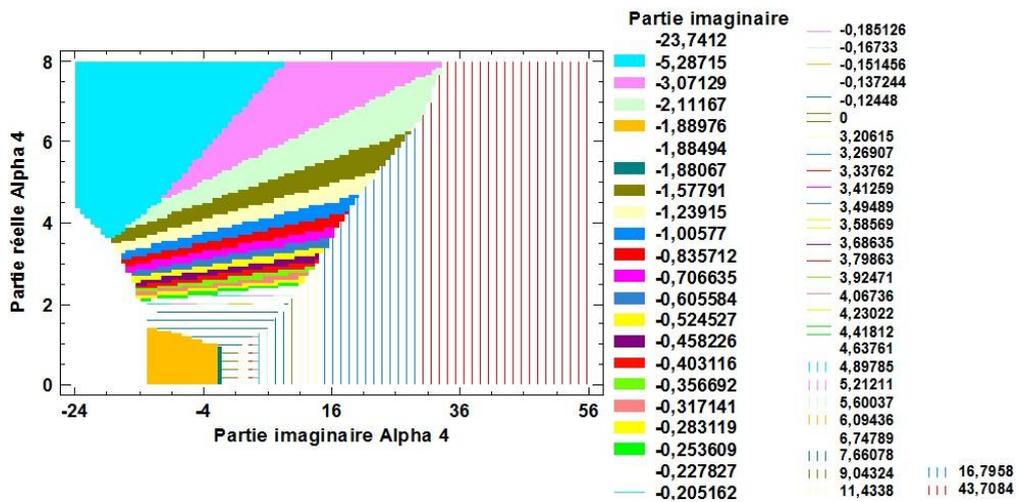


Figure 4.17 : Classement par réseau de neurones probabiliste (graphique de surface)

3^{ème} étape : Facteur de classement/ vitesse acoustique

La figure 4.18 et la figure 4.19 présente une classification par (PNN) où :

Le facteur de classement et la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

La valeur positive maximale de la partie imaginaire (43,7084). Nous constatons que la vitesse acoustique est égale à 3550 m / s.

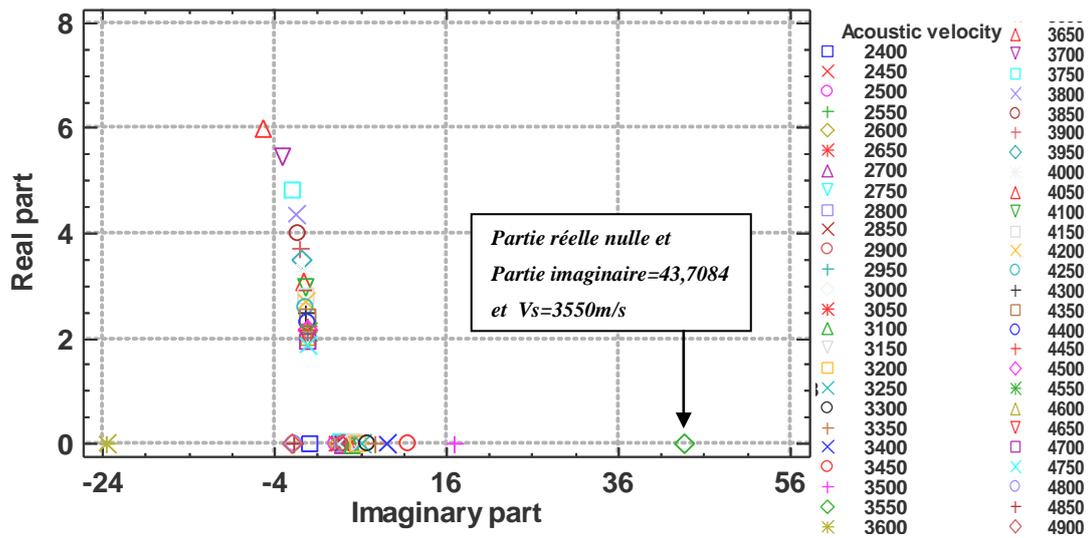


Figure 4.18 : Classement par réseau de neurones probabiliste - Vitesse acoustique

(Vitesse acoustique m/s) (2D)

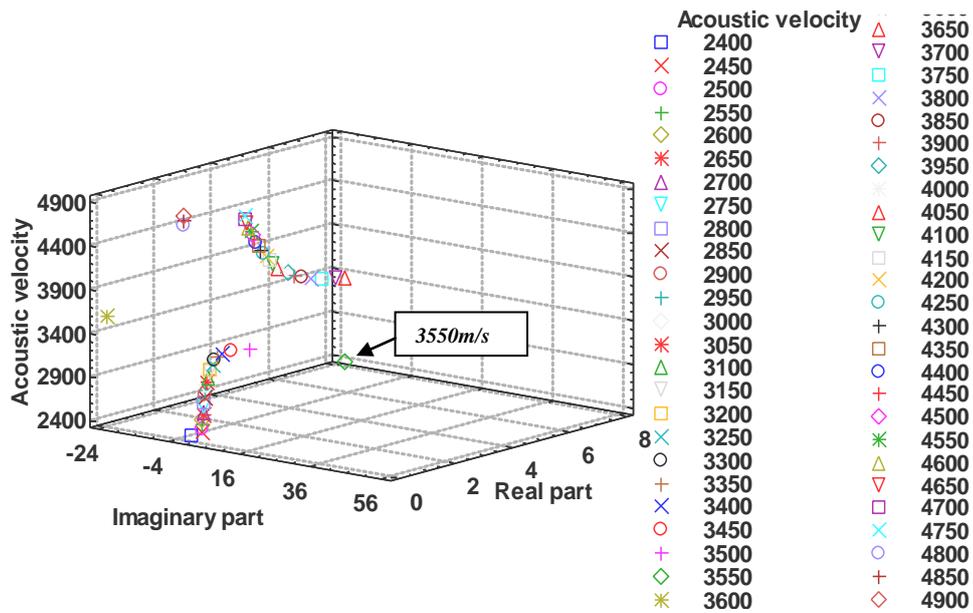


Figure 4.19 : Classement par réseau de neurones probabiliste - Vitesse acoustique

(Vitesse acoustique m/s) (3D)

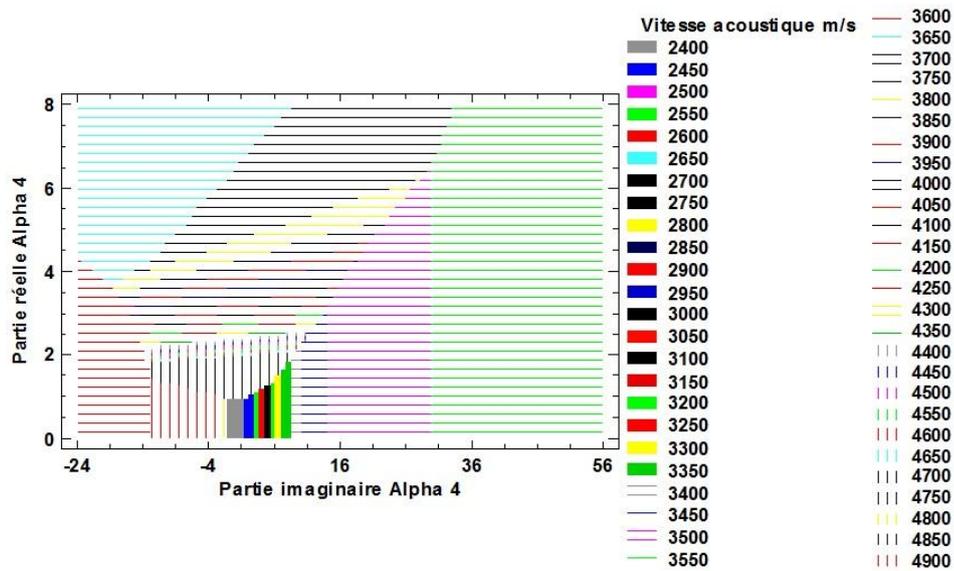


Figure 4.20 : Classement par réseau de neurones probabiliste (graphique de surface)

Le tableau .4.1 résume les résultats obtenus pour la détection des ondes de volume dans le cas de LiNbO_3 coupe Y-Z.

| Coefficient d'atténuation | partie imaginaire | partie réelle | Vitesse acoustique | Les ondes de volume |
|---------------------------|--------------------|--------------------|--------------------|------------------------|
| α_1 | Toutes les valeurs | Toutes les valeurs | Toutes les valeurs | Pas détection |
| α_2 | Toutes les valeurs | Toutes les valeurs | Toutes les valeurs | Pas détection |
| α_3 | Toutes les valeurs | Toutes les valeurs | Toutes les valeurs | Pas détection |
| α_4 | 43,7043 | 0 | 3550 m/s | Bonne détection |
| α_5 | Toutes les valeurs | Toutes les valeurs | Toutes les valeurs | Pas détection |
| α_6 | Toutes les valeurs | Toutes les valeurs | Toutes les valeurs | Pas détection |
| α_7 | Toutes les valeurs | Toutes les valeurs | Toutes les valeurs | Pas détection |
| α_8 | Toutes les valeurs | Toutes les valeurs | Toutes les valeurs | Pas détection |

4.6. Application sur le LiNbO₃ coupe Y-X

Pour le cas de la coupe Y-X, les ondes de volume correspondent aux parties réelles négatives (il faut que les parties imaginaires soient nulles). Des résultats conformes à ceux de la littérature [23, 24].

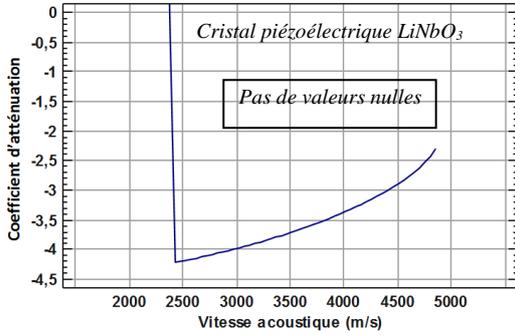


Figure 4.21a : Partie imaginaire de α_1

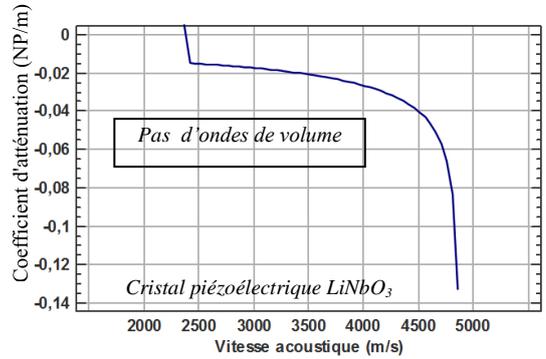


Figure 4.21b : Partie réelle de α_1

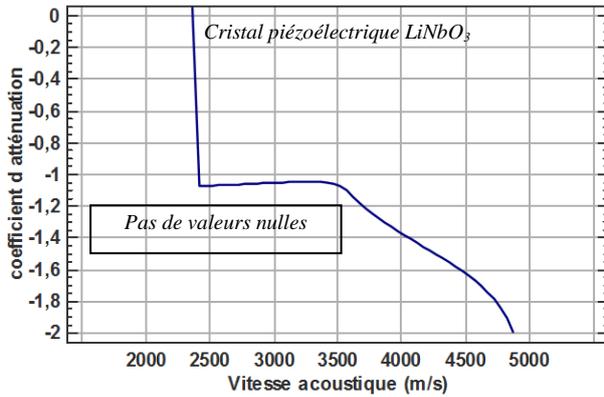


Figure 4.22a : Partie imaginaire de α_2

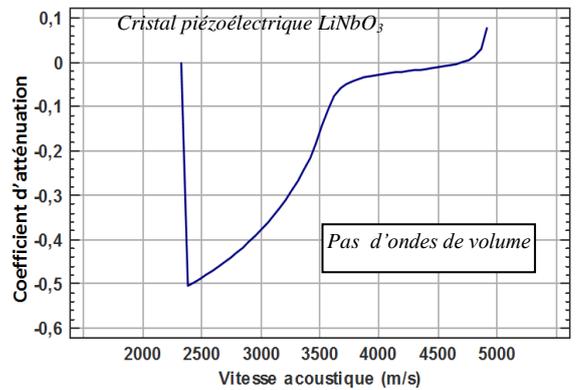


Figure 4.22b : Partie réelle de α_2

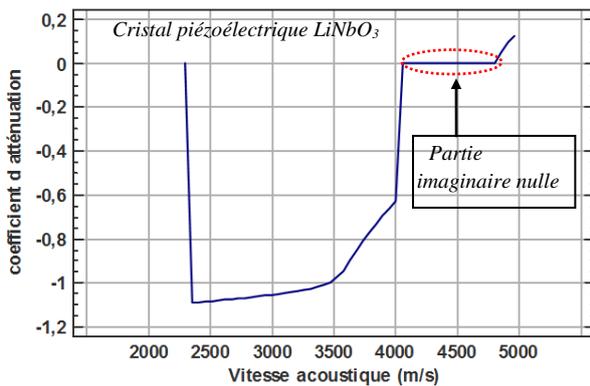


Figure 4.23a : Partie imaginaire de α_3

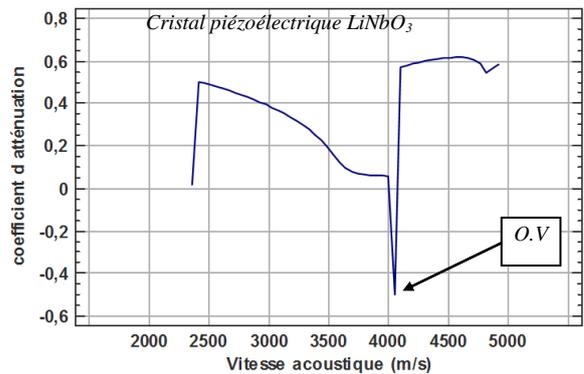


Figure 4.23b : Partie réelle de α_3

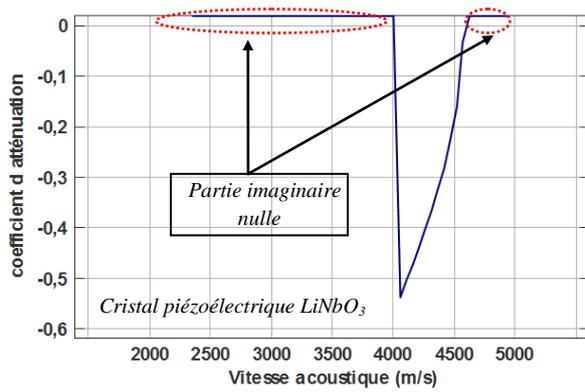


Figure 4.24a : Partie imaginaire de α_4

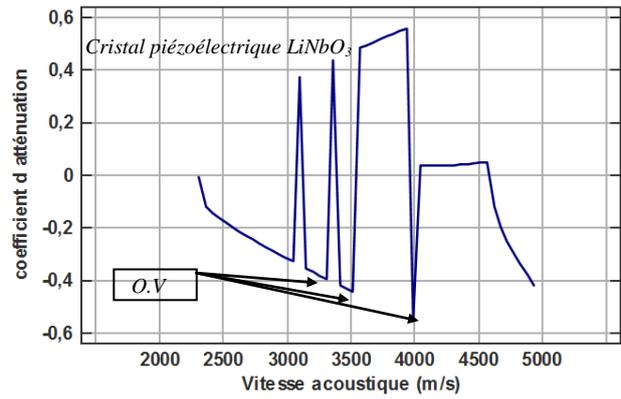


Figure 4.24b : Partie réelle de α_4

Dans cet exemple, nous montrons les variations des parties réelles et imaginaires des coefficients d'atténuation (α_1 , α_2 , α_3 et α_4) en fonction de la vitesse acoustique V_s (figure 4.21, figure 4.22, figure 4.23 et figure 4.24), et nous indiquons la présence des ondes de volume (partie imaginaire nulle et partie réelle négative).

4.7. Classement par les réseaux de neurones

Pourcentage des sujets du jeu d'apprentissage bien classés : 100,00%

Pour connaître les valeurs exactes de la partie réelle et la partie imaginaire du coefficient d'atténuation et la vitesse acoustique, nous devons définir comme :

- ✓ Variable de sélection : La vitesse acoustique.
- ✓ Facteurs en entrée : Partie imaginaire et Partie réelle.
- ✓ Changer le facteur de classification.
- ✓ Nombre de sujets dans le jeu d'apprentissage : 51

Nous définissons les valeurs de la partie imaginaire, que nous allons chercher dans la Classification (Figure 4.27) et (Figure 4.28).

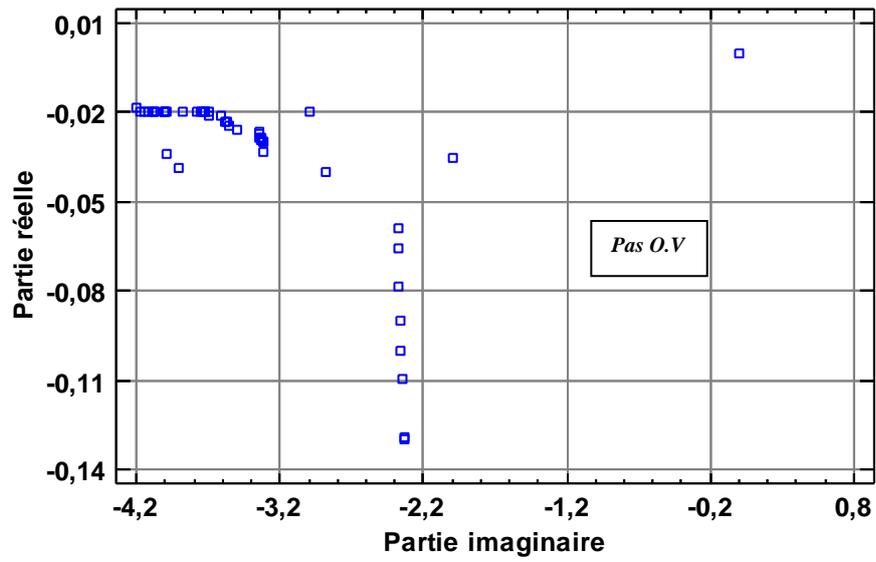


Figure 4.25: Partie réelle α_1 en fonction de la partie imaginaire α_1

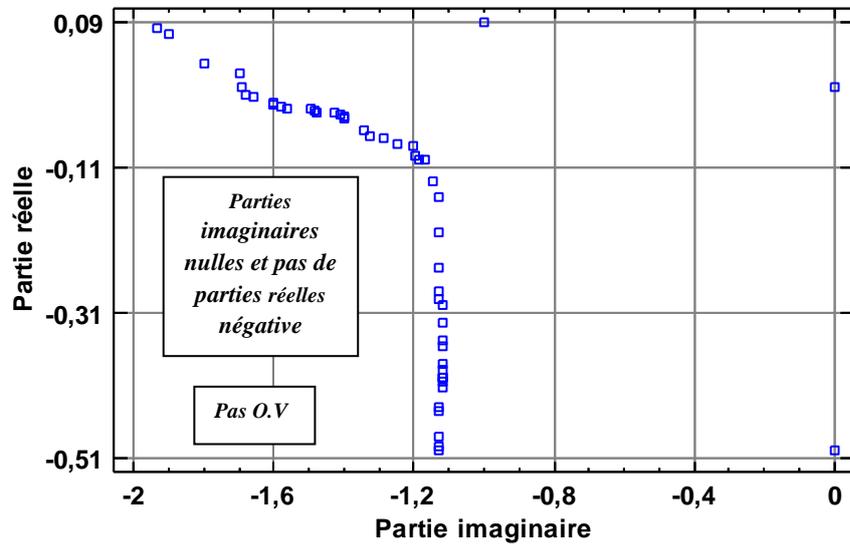


Figure 4.26: Partie réelle α_2 en fonction de la partie imaginaire α_2

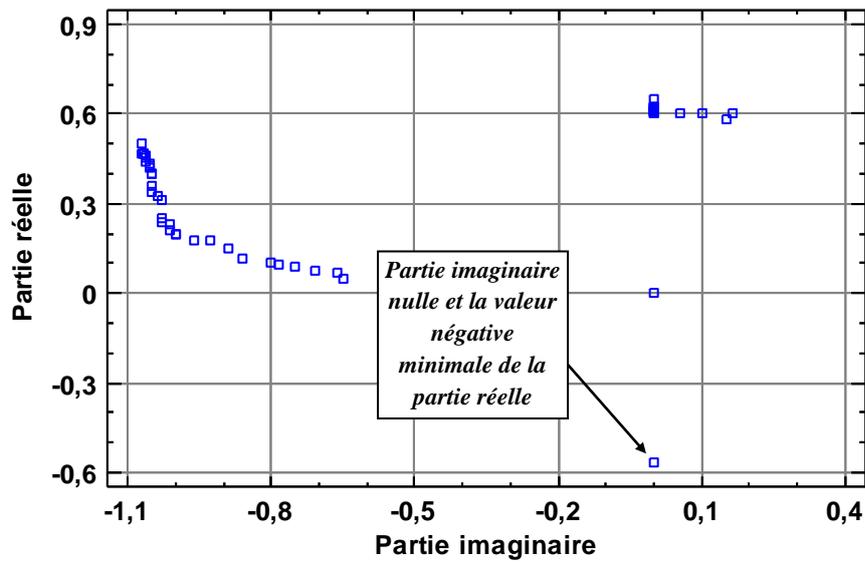


Figure 4.27: Partie réelle α_3 en fonction de la partie imaginaire α_3

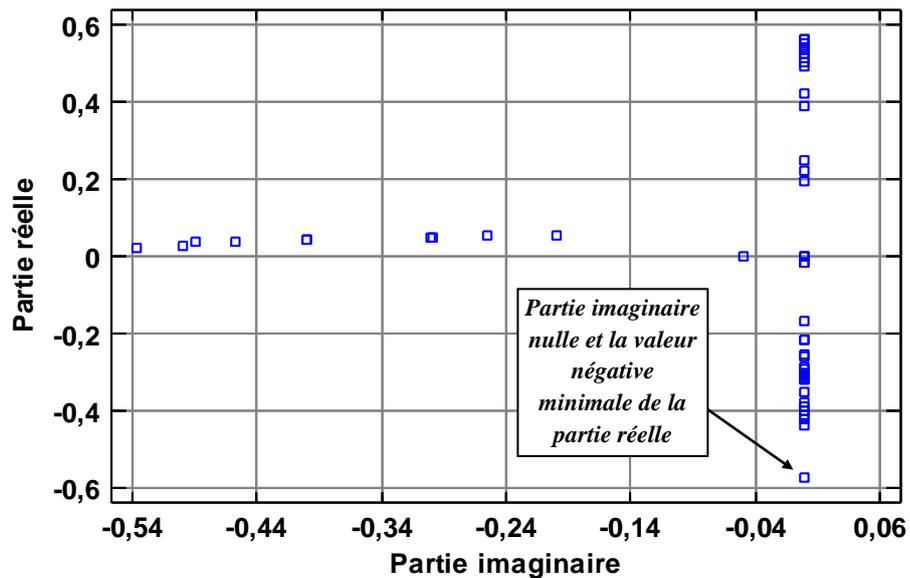


Figure 4.28: Partie réelle α_4 en fonction de la partie imaginaire α_4

4.8. Résultats et discussion (Pour le LiNbO₃ coupe Y-X)

4.8.1 Résultats du coefficient d'atténuation (α_3)

1^{ère} étape : Facteur de classement/ partie imaginaire

La figure 4.29 et la figure 4.30 présente une classification par (PNN) où :

Le facteur de classement est la partie imaginaire, la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

Nous cherchons la valeur négative minimale de la partie réelle avec la partie imaginaire nulle.

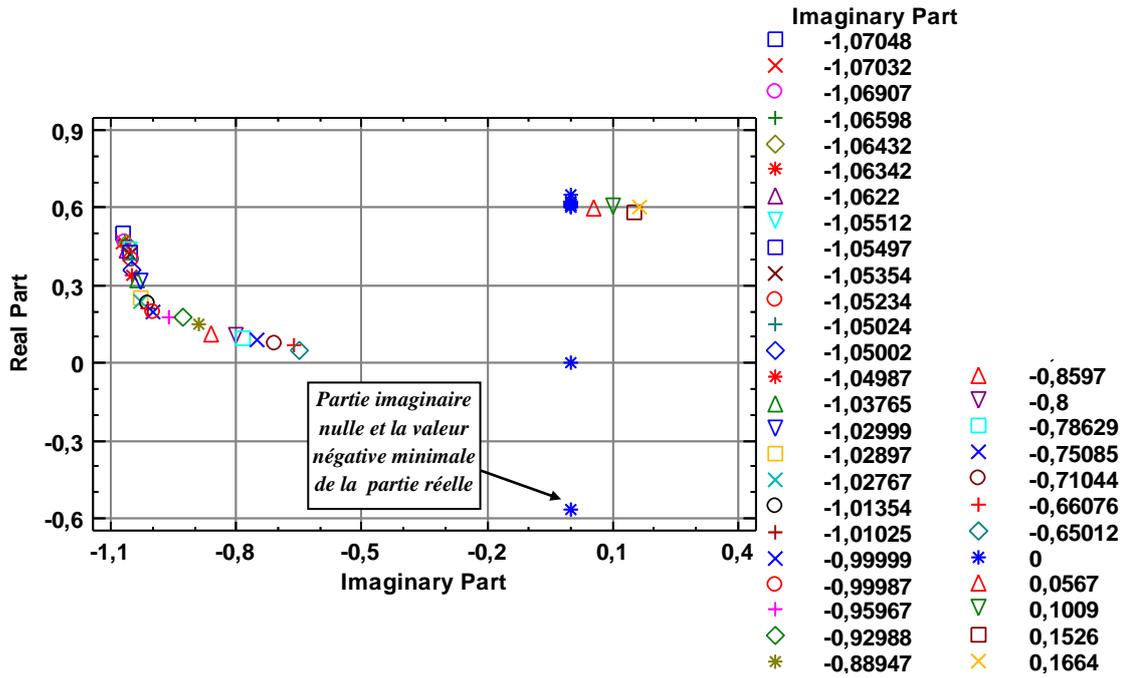


Figure 4.29: Classement par réseau de neurones probabiliste - partie imaginaire (Vitesse acoustique m/s) (2D)

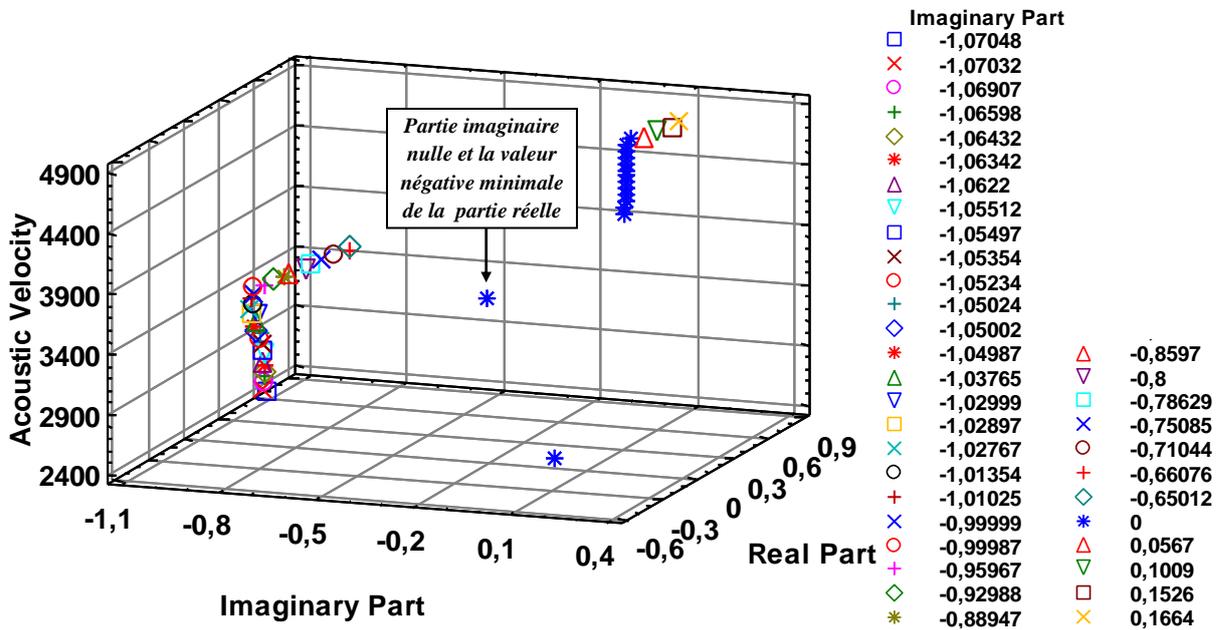


Figure 4.30: Classement par réseau de neurones probabiliste - partie imaginaire (Vitesse acoustique m/s) (3D)

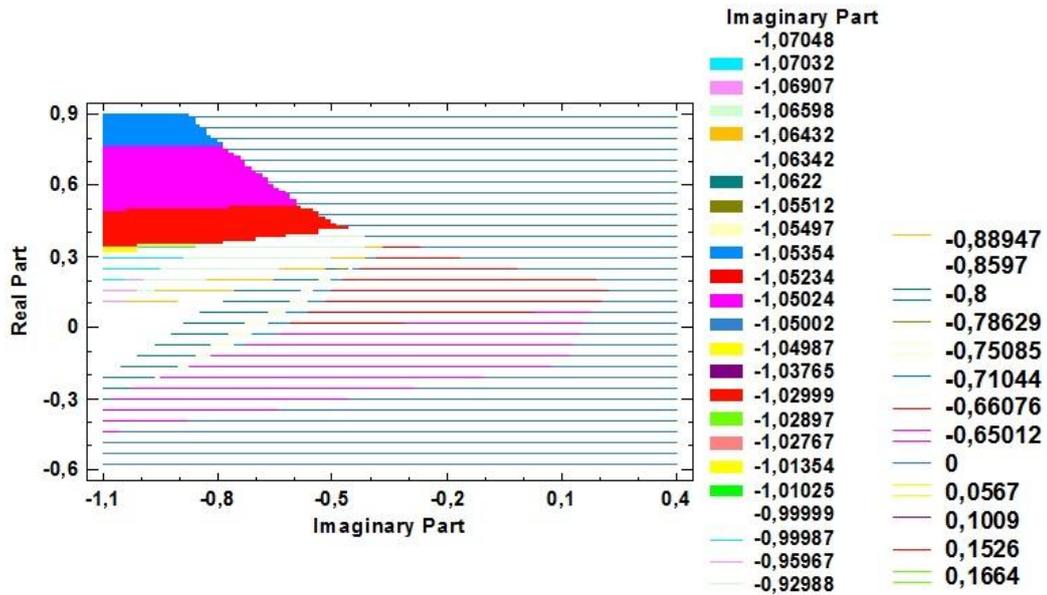


Figure 4.31 : Classement par réseau de neurones probabiliste (graphique de surface)

2^{ème} étape : Facteur de classement/ partie réelle

La figure 4.32 et la figure 4.33 présente une classification par (PNN) où :

Le facteur de classement est la partie réelle, la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

Nous constatons que la valeur minimale négative de la partie réelle est de -0,5654.

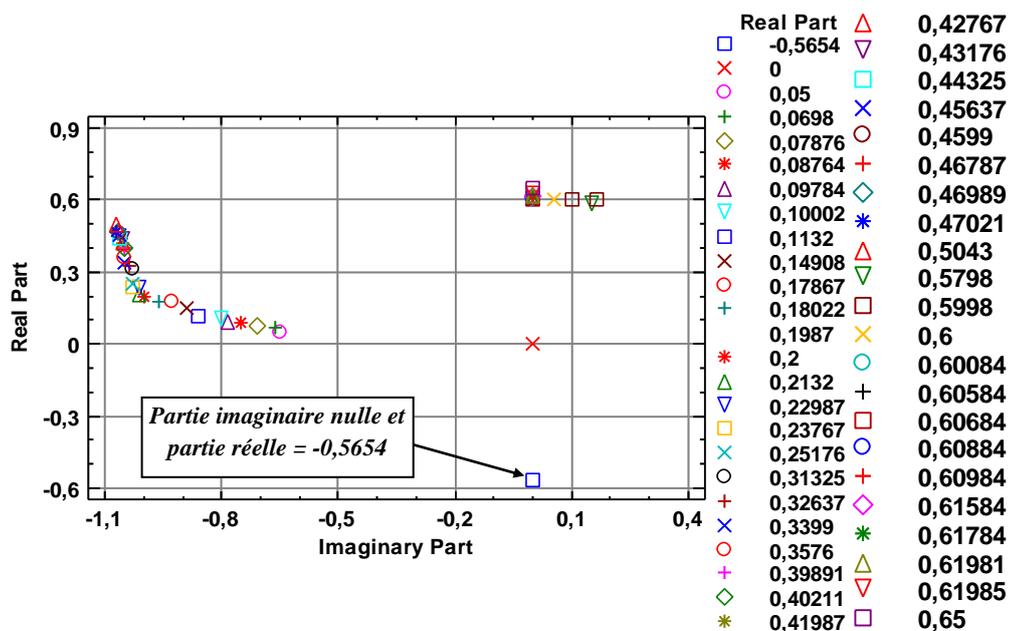


Figure 4.32 : Classement par réseau de neurones probabiliste - partie réelle

(Vitesse acoustique) (2D)

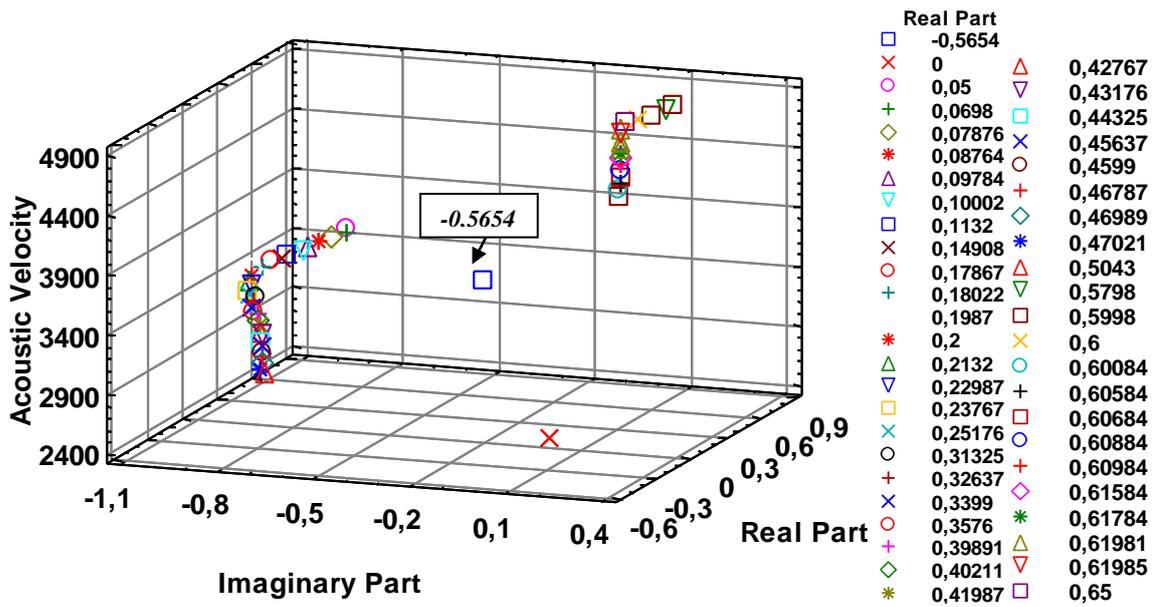


Figure 4.33 : Classement par réseau de neurones probabiliste - partie réelle

(Vitesse acoustique m/s) (3D)

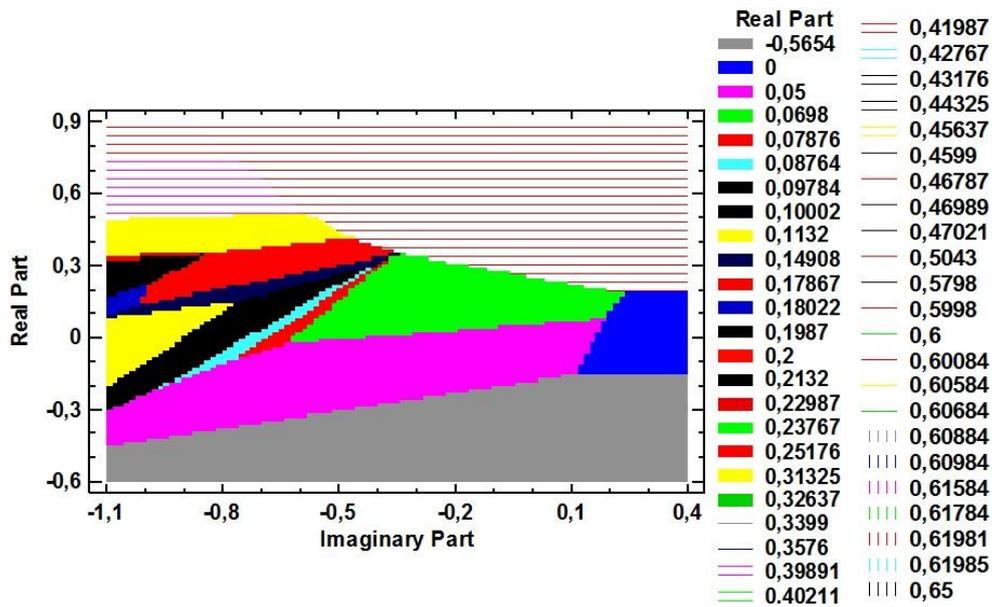


Figure 4.34 : Classement par réseau de neurones probabiliste (graphique de surface)

3^{ème} étape : Facteur de classement/ vitesse acoustique

La figure 4.35 et la figure 4.36 présente une classification par (PNN) où :

Le facteur de classement est la vitesse acoustique, la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

La valeur négative minimale de la partie réelle (-0,5654). Nous constatons que la vitesse acoustique est égale à 4050 m / s.

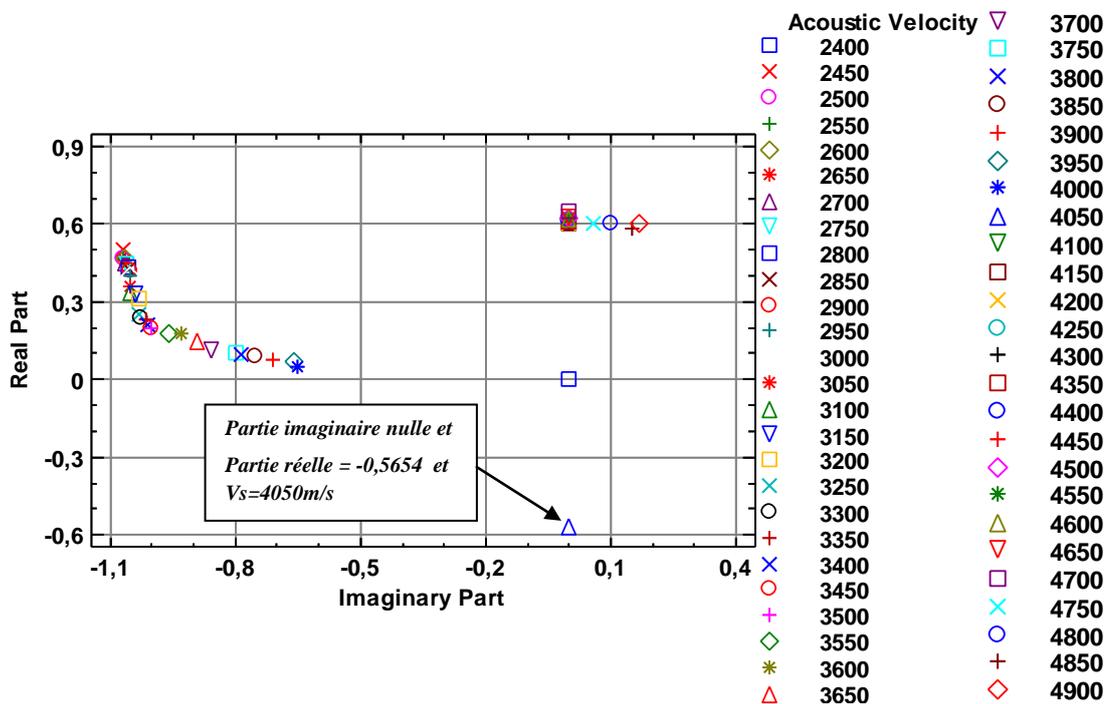


Figure 4.35 : Classement par réseau de neurones probabiliste - Vitesse acoustique

(Vitesse acoustique m/s) (2D)

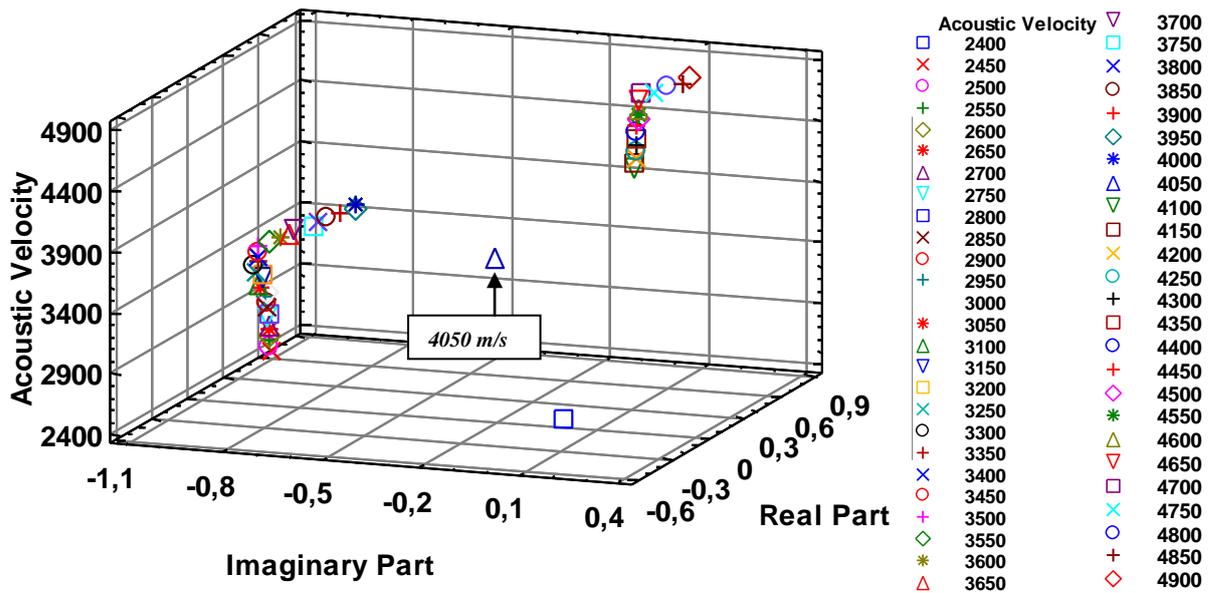


Figure 4.36 : Classement par réseau de neurones probabiliste - Vitesse acoustique

(Vitesse acoustique m/s) (3D)

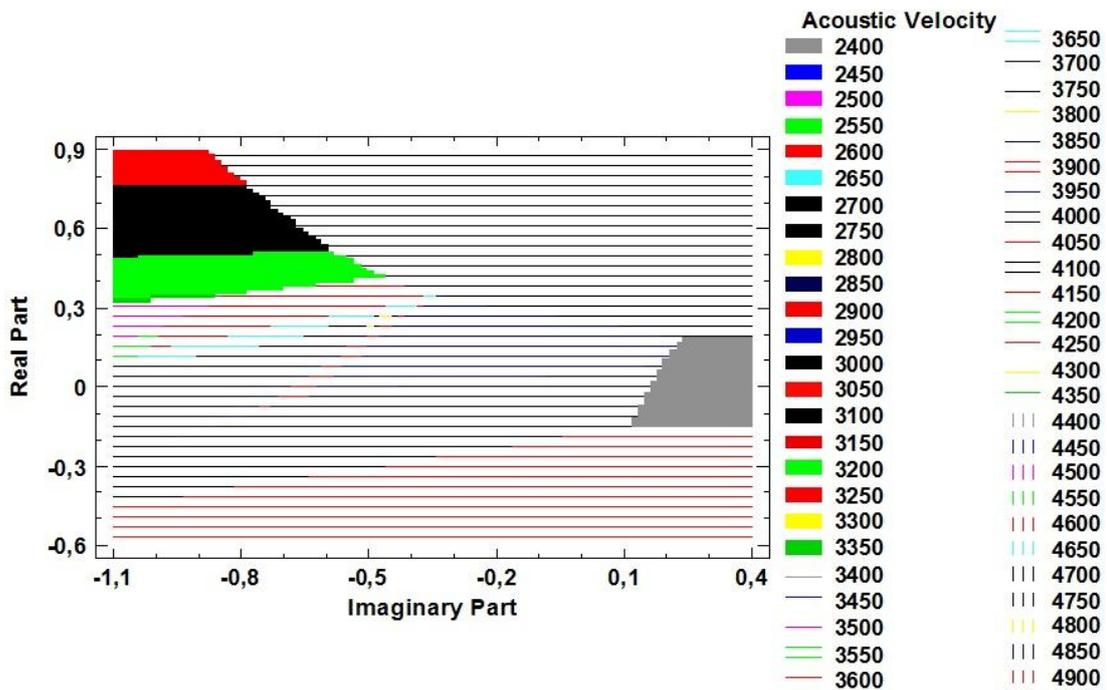


Figure 4.37 : Classement par réseau de neurones probabiliste (graphique de surface)

4.8.2 Résultats du coefficient d'atténuation (α_4)

1^{ère} étape : Facteur de classement/ partie imaginaire

La figure 4.38 et la figure 4.39 présente une classification par (PNN) où :

Le facteur de classement est la partie imaginaire, la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

Nous cherchons la valeur minimale négative de la partie réelle avec la partie imaginaire nulle.

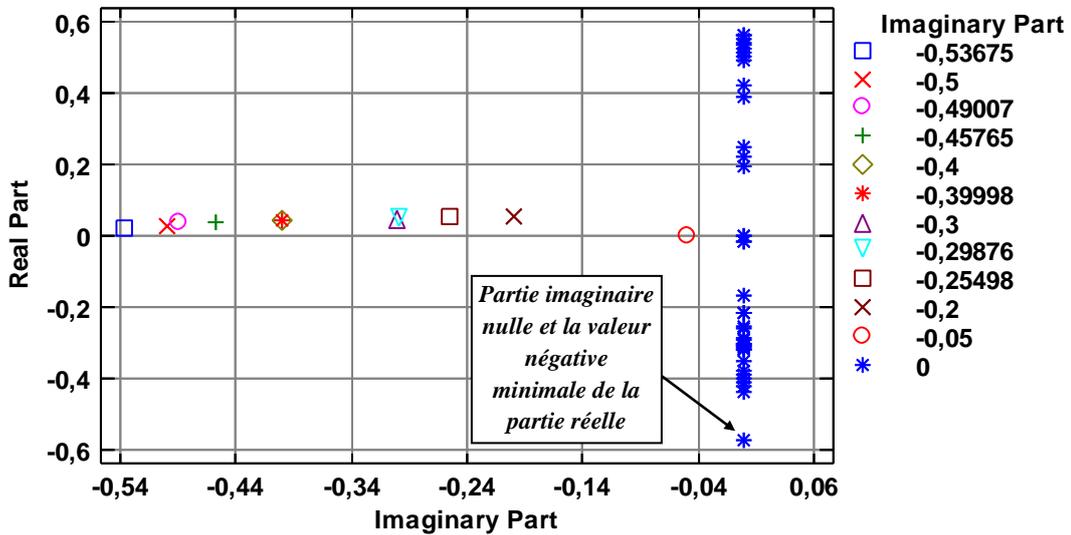


Figure 4.38 : Classement par réseau de neurones probabiliste - partie imaginaire (Vitesse acoustique m/s) (2D)

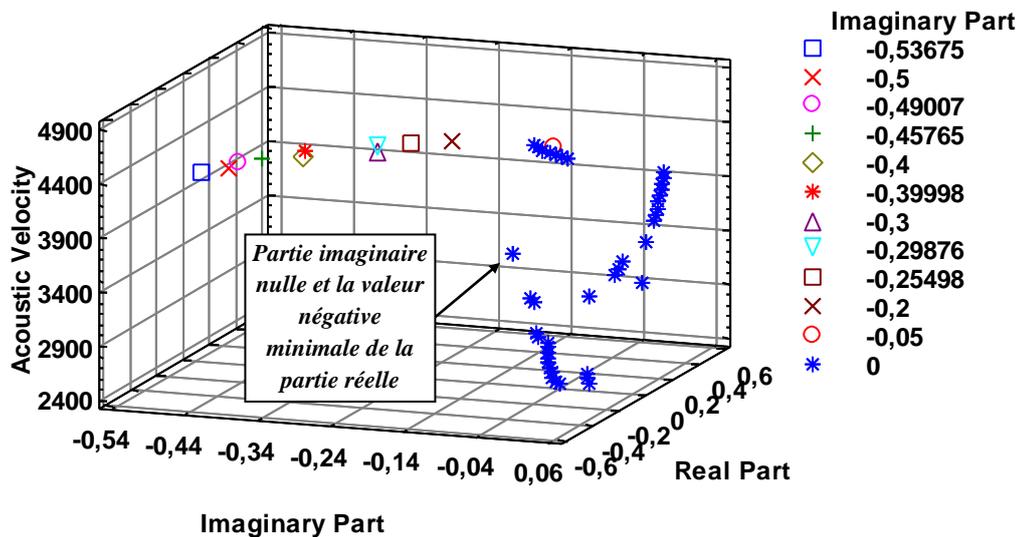


Figure 4.39 : Classement par réseau de neurones probabiliste - partie imaginaire (Vitesse acoustique m/s) (3D)

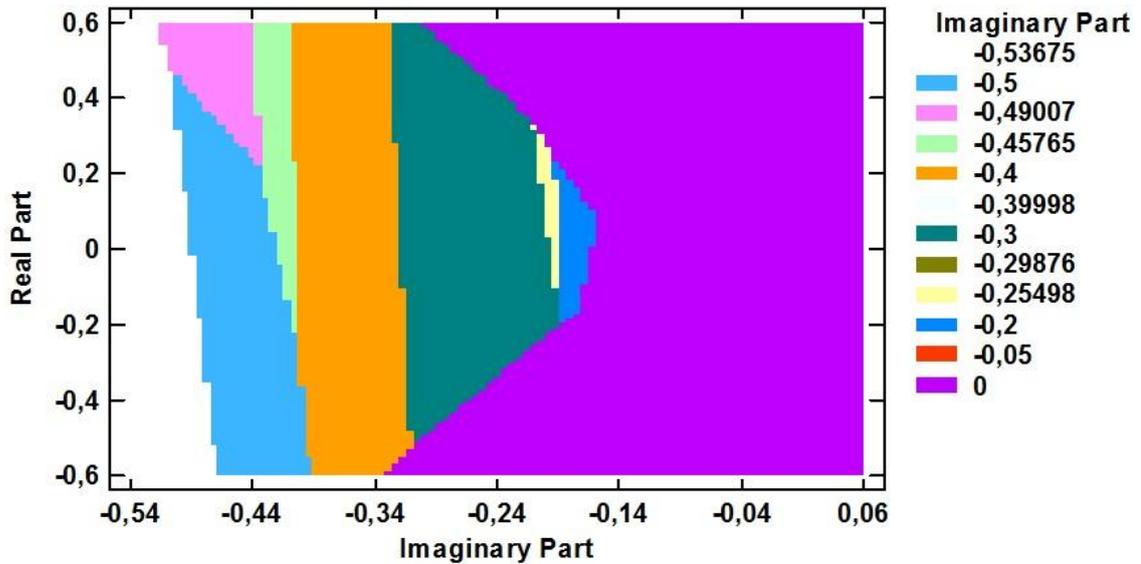


Figure 4.40 : Classement par réseau de neurones probabiliste (graphique de surface)

2^{ème} étape : Facteur de classement/ partie réelle

La figure 4.41 et la figure 4.42 présente une classification par (PNN) où :

Le facteur de classement est la partie réelle, la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

Nous constatons que la valeur minimale négative de la partie réelle est de - 0,57212.

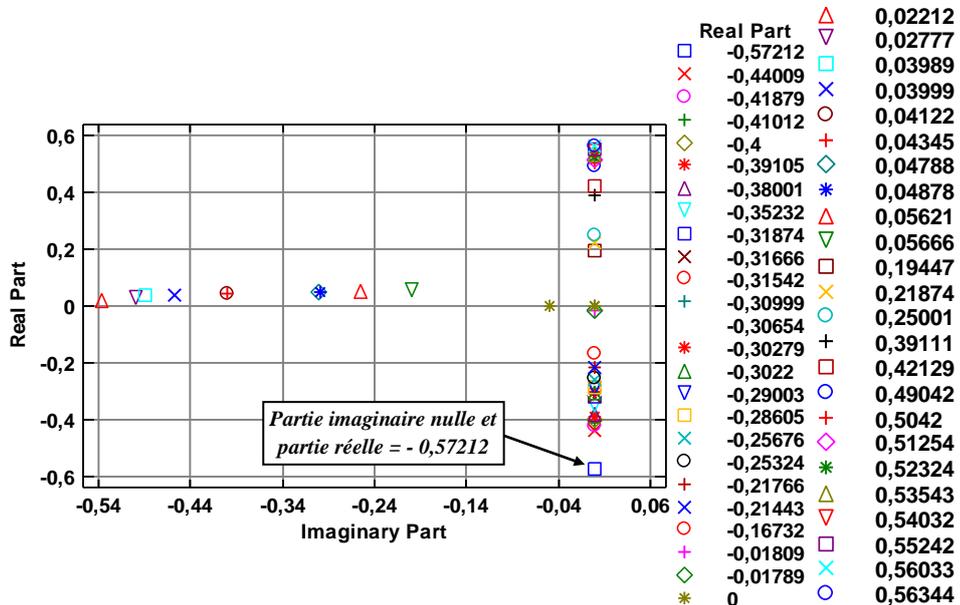


Figure 4.41 : Classement par réseau de neurones probabiliste - partie réelle (Vitesse acoustique m/s) (2D)

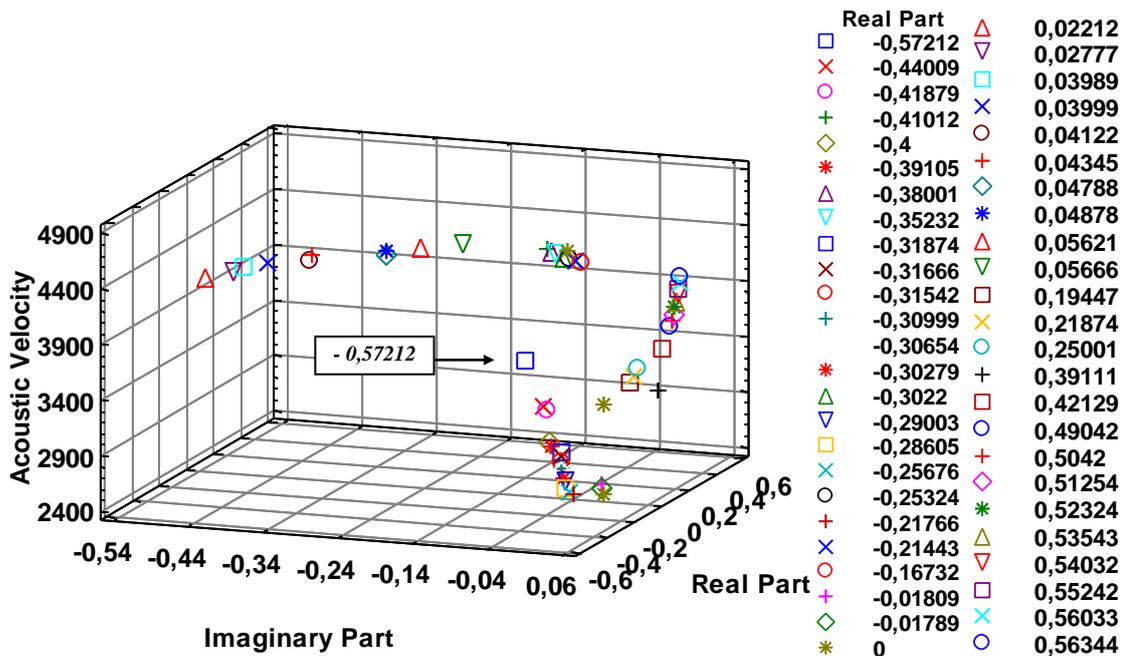


Figure 4.42 : Classement par réseau de neurones probabiliste - partie réelle
(Vitesse acoustique m/s) (3D)

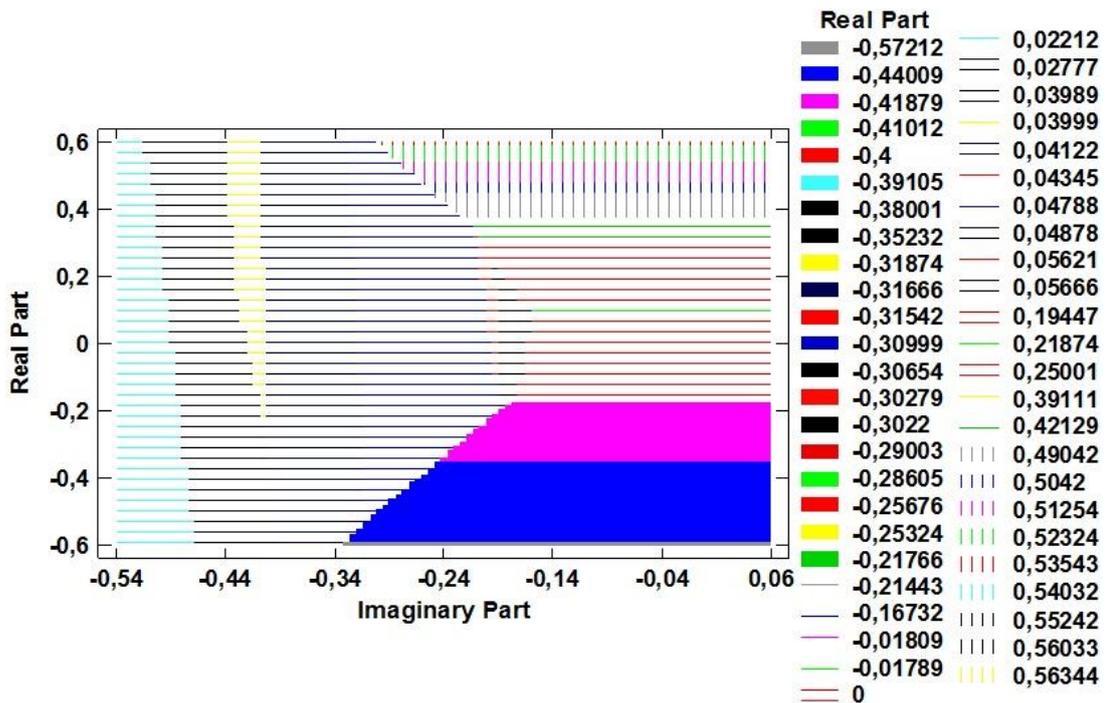


Figure 4.43 : Classement par réseau de neurones probabiliste (graphique de surface)

3^{ème} étape : Facteur de classement/ vitesse acoustique

La figure 4.44 et la figure 4.45 présente une classification par (PNN) où :

Le facteur de classement et la variable de sélection est la vitesse acoustique et le nombre de sujets dans le jeu d'apprentissage est de 51.

La valeur négative minimale de la partie réelle est de -0,57212. Nous constatons que la vitesse acoustique est égale à 4000 m / s.

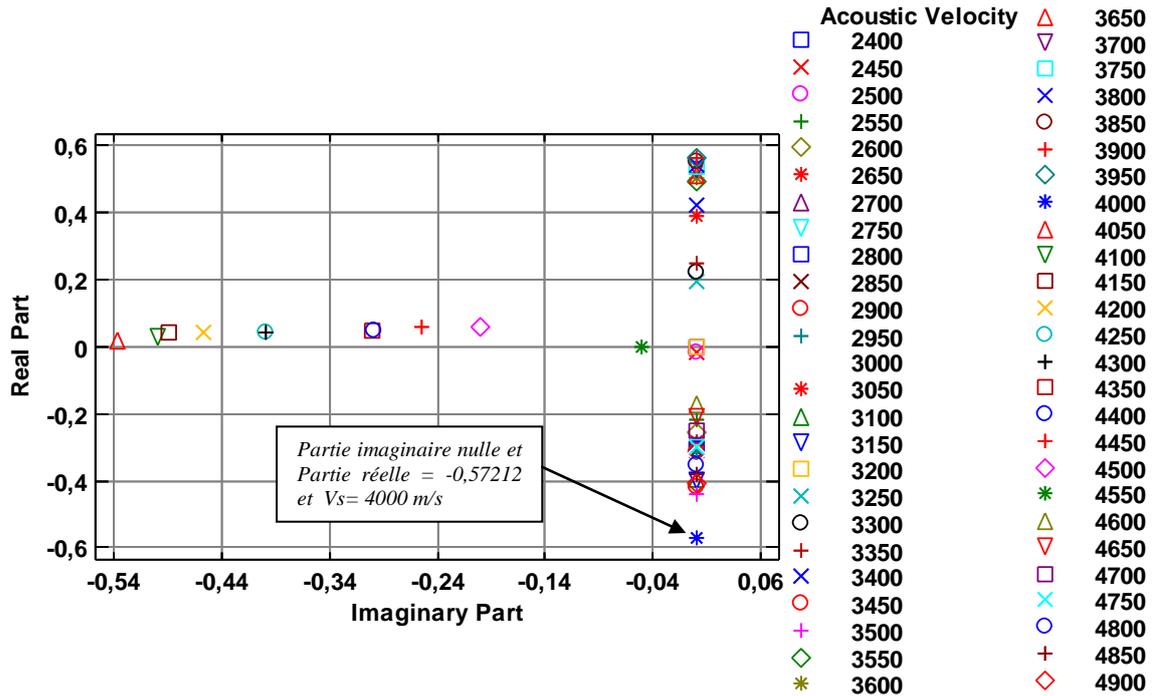


Figure 4.44 : Classement par réseau de neurones probabiliste - Vitesse acoustique

(Vitesse acoustique m/s) (2D)

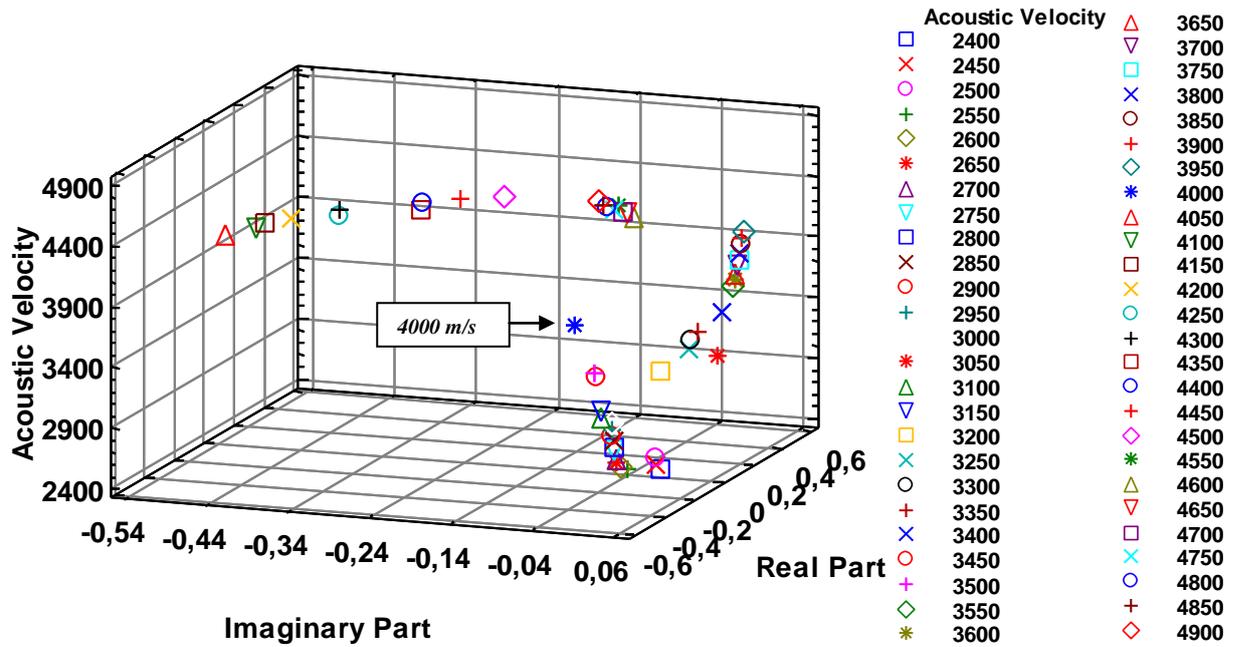


Figure 4.45 : Classement par réseau de neurones probabiliste - Vitesse acoustique
(Vitesse acoustique m/s) (3D)

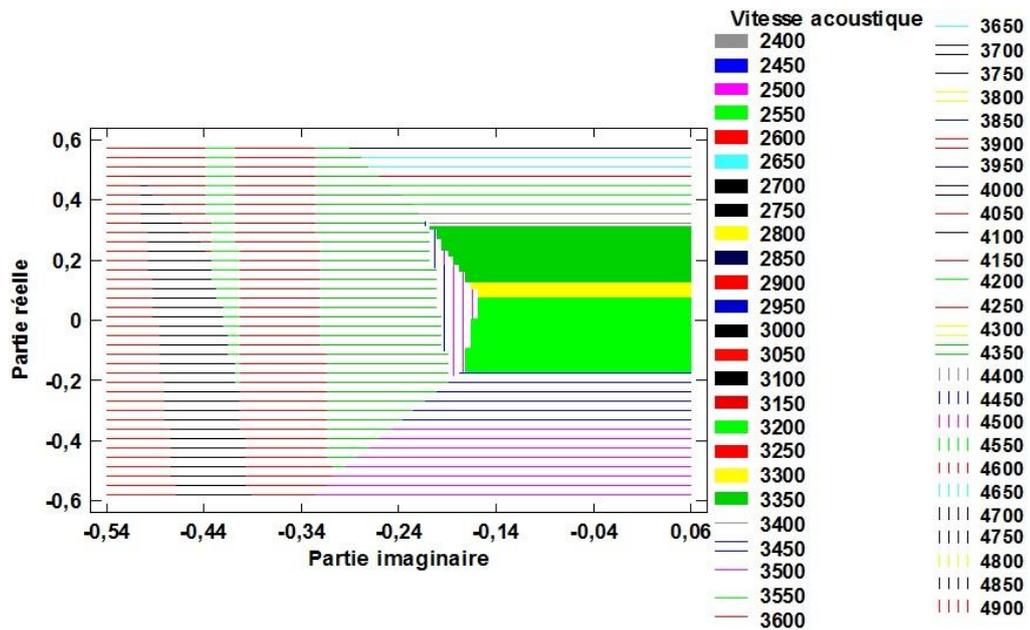


Figure 4.46 : Classement par réseau de neurones probabiliste (graphique de surface)

Le tableau 4.2 résume les résultats obtenus pour la détection des ondes de volume dans le cas de LiNbO₃ coupe Y-X.

| <i>Coefficient d'atténuation</i> | <i>partie imaginaire</i> | <i>partie réelle</i> | <i>Vitesse acoustique</i> | <i>Les ondes de volume</i> |
|----------------------------------|---------------------------|---------------------------|---------------------------|----------------------------|
| α_1 | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Pas détection</i> |
| α_2 | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Pas détection</i> |
| α_3 | 0 | -0,5654 | 4050 m/s | Détection |
| α_4 | 0 | -0,57212 | 4000 m/s | Bonne détection |
| α_5 | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Pas détection</i> |
| α_6 | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Pas détection</i> |
| α_7 | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Pas détection</i> |
| α_8 | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Toutes les valeurs</i> | <i>Pas détection</i> |

4.9. Conclusion

Dans ce chapitre, nous avons montré l'efficacité de la technique des réseaux de neurones probabilistes expliquant ainsi le phénomène des ondes de volume au niveau des coefficients d'atténuation. (Pour plus de détails numériques voir Annexe)

Notre méthode est applicable pour n'importe qu'elle matériau piézoélectrique, il suffit juste de changer les paramètres caractéristiques du matériau considéré.

L'importance de trouver avec précision les paramètres caractéristiques des ondes de volume réside dans le faite de pouvoir modéliser les dispositifs piézoélectriques pour une fonction donnée, par exemple la vitesse acoustique permet de fixer la distance entre les doigts du transducteur d'excitation du matériau en ondes de volume utilisées dans les dispositifs à ultrasons (Echographe).

Conclusion générale

Notre thèse a fait l'objet d'une modélisation de la propagation des micro-ondes acoustiques dans les structures piézoélectriques, en premier lieu au niveau de la détection des ondes partielles de volume par le comportement des coefficients d'atténuation (résultats graphiques) et en second lieu par l'association des réseaux probabilistes de neurones en vue d'une meilleure précision.

Dans notre travail nous avons expliqué le phénomène des ondes de volume (BAW) en nous appuyons sur deux modèles :

- Le premier s'appuie sur des résultats numériques au niveau des coefficients d'atténuations, à savoir les variations de leurs parties réelles et imaginaires en fonction de la vitesse acoustique, nous renseignent sur la présence des micro-ondes partielles, permettant ainsi de distinguer facilement les différents modes de propagation en particulier les ondes de volume (BAW).
- Le deuxième modèle est basé sur l'application des réseaux probabilistes de neurones (PNN) dans le but de détecter avec précision les ondes de volume lors de la propagation des micro-ondes acoustiques dans un substrat piézoélectrique (exemple : LiNbO₃). Nous avons utilisé la classification par réseaux probabilistes de neurones comme un moyen d'analyse numérique dans laquelle nous avons classé toutes les valeurs de la partie réelle et partie imaginaire du coefficient d'atténuation en fonction de la vitesse acoustique menant ainsi à la construction d'un modèle très précis pour la détection et génération des ondes de volume. Notre méthode (deuxième modèle) est applicable pour n'importe qu'elle matériau piézoélectrique de même classe cristallographique, il suffit juste de changer les paramètres caractéristiques du matériau considéré (tenseur élastique, tenseur piézoélectrique et tenseur diélectrique).

L'intérêt de détecter le mode de volume réside dans son exploitation dans le domaine médical (images à ultrasons), donc les échographes.

Le mode des ondes de volume rampantes sous la surface SSBW (Skimming Surface Bulk Waves) : Cas particulier des ondes de volume relatifs aux petites valeurs positives des parties

réelles), permet de réaliser des oscillateurs très stables et qui développent des performances supérieures du point de vue puissance par rapport aux composants réalisés à base d'ondes de surface.

Comme perspectives, cette étude sera très intéressante dans la modélisation des différentes applications dans d'autres domaines. Par exemple, le mode de surface permet la réalisation des dispositifs amplificateurs, Filtres, etc..., quant au mode de fuite, on pourra réaliser des antennes piézoélectriques à ondes de fuite et de biocapteurs de proximité.

Bibliographie

- [1] N. i Fan : "Analyse et simulation de résonateurs piézoélectriques pour des applications de filtrage", *Thèse de Doctorat*, Université de Limoges, 2009.
- [2] D. Royer et E. Dieulesaint : "Ondes élastiques dans les solides", Tome 1, "*propagation libre et guidée*", Ed. Masson, Paris, 1996.
- [3] D. Benatia : "Modélisation des ondes de volume rampantes sous la surface (SSBW) par une technique mixte ondelettes et fractales", *Thèse de Doctorat d'Etat*. Université de Constantine, institut d'électronique, Décembre 1999.
- [4] E. Dieulesant et D. Royer : "Ondes élastiques dans les solides", (*Edition Masson et compagnie*, 1974)
- [5] D. Benatia and M. Benslama: "Analysis of Leaky and Bulk Acoustic Microwaves by Wavelet Technique," *Journal of Communications in Numerical Methods in Engineering*, 2000, Vol. 16, pp. 165-175.
- [6] K. H. Yen, K. F. Lau and R. S. Kagiwada : "Recent advances in shallow bulk acoustic wave devices", *Proc. IEEE Ultrasonics Symposium*, 1979, pp. 776-785
- [7] M. Planat : "Propagation non linéaire des ondes acoustique dans les solide –*applications aux dispositifs électroacoustiques*", *Thèse de Doctorat*, Université de FRANCHE-COMTE, (Mars 1984).
- [8] D. F. Specht : "Probabilistic neural networks", *Neural networks*, 1990, Vol. 3, No. 1, pp. 109–118.
- [9] M. W. Kim and M. Arozullah: "Generalized probabilistic neural network based classifiers", *International Joint Conference on*, 2002, Vol. 3, pp. 648–653.
- [10] V. Georgiou, P. Alevizos, and M. Vrahatis: "Fuzzy Evolutionary Probabilistic Neural Networks", *Artificial Neural Networks in Pattern Recognition*, 2008, pp. 113–124.
- [11] P. Burrascano: "Learning vector quantization for the probabilistic neural network", *IEEE Transactions on Neural Networks / a Publication of the IEEE Neural Networks Council*, 1991, Vol. 2, No. 4, pp. 458-461.

- [12] I. De Falco, A. Della Cioppa and E. Tarantino: "Facing classification problems with Particle Swarm Optimization", *Applied Soft Computing*, Juin 2007, Vol. 7, pp. 652–658.
- [13] I. Gallecke and J. Castellanos : "A rotated kernel probabilistic neural network (RKPNN) for multi-class classification", in *Proceedings of the Artificial and natural neural networks 7th international conference on Computational methods in neural modeling – Vol. 1*, Berlin, Heidelberg, 2003, pp. 152–157.
- [14] I. Gallecke and J. Castellanos: "A rotated kernel probabilistic neural network (RKPNN) for multi-class classification", *Computational Methods in Neural Modeling*, 2003, pp. 1040–1045.
- [15] D. K. Kim, D. H. Kim, S. K. Chang and S. K. Chang: "Modified probabilistic neural network considering heterogeneous probabilistic density functions in the design of breakwater", *KSCE Journal of Civil Engineering*, Mars 2007 , Vol. 11, No. 2, pp. 65-71.
- [16] M. Bullo: "Modélisation et commande du moteur piézoélectrique à onde progressive", *MAGELEC 98*, Avril 1998, pp.15-28.
- [17] Z. Ghalmi : "Contribution au développement d'un capteur ultrasonique pour mesurer l'épaisseur de la glace", *Thèse en doctorat* présenté à l'université du Québec à Chicoutimi, Mars 2006.
- [18] H. Frayssignes : "Etude des effets non-linéaires et des pertes dans les moteurs ultrasonores Introduction au problème de couplage mécanique entre les voies", *Thèse de Doctorat* de l'INSA, Lyon, 2001.
- [19] F. Patat : "Elaboration et caractérisation de céramique ferroélectrique de type PZT", *Thèse de Doctorat* de l'INSA, Lyon, 1999.
- [20] N. Rizet : "Contrôle actif de vibrations utilisant des matériaux piézo-actifs", *Thèse de Doctorat*, INSA Lyon, 1999.
- [21] C. Zimmermann : "Conception, réalisation et étude de micro-capteurs a ondes de love pour applications en milieu gazeux. Cas de la détection de composés organophosphorés",. *Thèse de Doctorat* de école doctorale de sciences physiques et de l'ingénieur, l'université bordeaux 1, 2002.
- [22] M. Bullo : "Modélisation et commande du moteur piézoélectrique à onde progressive", *Thèse doctorat* de Ecole Polytechnique Fédérale de Lausanne, 2005.

- [23] D. Benatia et M. Benslama : "Identification des Ondes de fuite et de volume dans les Matériaux piézoélectriques. Cas du Niobate de Lithium (LiNbO₃ Coupe Y-Z)", *3rd International conference: Sciences of electronic, technologies of Information and telecommunications*, Tunisia, March 27-31, 2005.
- [24] D. Benatia, T. Fortaki et M. Benslama : "Détection des ondes de fuite dans les matériaux piézoélectriques", *4th International conference: Sciences of electronic, technologies of information and telecommunications*, Tunisia, March 25-29, 2007.
- [25] A. Lotfi, R. Tlemsani et A. Benyettou : "Un Nouvel Algorithme d'Apprentissage pour les Réseaux Probabilistes", *Vers une Réduction des PNN*. CARI 2012.
- [26] C. Bishop: "Neural Networks for Pattern Recognition", Oxford: *University Press*. (1995).
- [27] A. Carling: "Introducing Neural Networks", Wilmslow, UK: *Sigma Press*. (1992).
- [28] B. D. Ripley: "*Pattern Recognition and Neural Networks*", *Cambridge University Press*. (1996).
- [29] L. Fausett: "*Fundamentals of Neural Networks*", New York: *Prentice Hall*. (1994).
- [30] D. Patterson: "*Artificial Neural Networks*", Singapore: *Prentice Hall*. (1996).
- [31] S. Haykin: "*Neural Networks: A Comprehensive Foundation*". New York: *Macmillan Publishing*. (1994).
- [32] T. Kohonen: "Self-organized formation of topologically correct feature maps". *Biological Cybernetics*, 1982, Vol. 43, pp. 59-69.
- [33] <http://www.statsoft.fr/concepts-statistiques/reseaux-de-neurones-automatisees/>
- [34] Y. K. Jain and M. Jain, "Skin cancer detection and classification using Wavelet Transform and Probabilistic Neural Network," *Communication and Computing (ARTCom2012), Fourth International Conference on Advances in Recent Technologies in*, Bangalore, India, 2012, pp. 250-252.

- [35] W. Qinghua, Y. Hongtao and D. Donghua, "Automatic recognition for mechanical images based on Sparse non-negative matrix factorization and Probabilistic Neural Networks," *2015 IEEE International Conference on Mechatronics and Automation (ICMA)*, Beijing, 2015, pp. 2408-2413.
- [36] D. F. Specht: "Probabilistic neural networks", *Neural networks*, 1990, Vol. 3, No. 1, pp. 109–118.
- [37] Y.-qun Deng and P.-ming Wang: "Predicting the shrinkage of thermal insulation mortar by probabilistic neural networks", *Journal of Zhejiang University SCIENCE A*, févr. 2010, Vol. 11, No.3, pp. 212-222.
- [38] S. Patil, V. R. Udupi and P. Bhogale, "An efficient CAD system for detection and classification of tumors in mammographic images using variety features and Probabilistic Neural Network," *Confluence 2013: The Next Generation Information Technology Summit (4th International Conference)*, Noida, 2013, pp. 115-119.
- [39] R. Sharma, A. Singh, A. Joshi and A. Gangwar, "Robust Iris Classification through a Combination of Kernel Discriminant Analysis and Parzen Based Probabilistic Neural Networks," *Emerging Applications of Information Technology (EAIT), 2014 Fourth International Conference of*, Kolkata, 2014, pp. 268-272.
- [40] R. Ghongade, M. Deshmukh and D. Joshi, "Arrhythmia classification using morphological features and probabilistic neural networks," *Computational Intelligence on Power, Energy and Controls with their impact on Humanity (CIPECH), 2014 Innovative Applications of*, Ghaziabad, 2014, pp. 80-84.

Annexe :

Les tableaux de Classement par réseaux de neurones probabilistes (PNN)

A .1. Classement par réseau de neurones - Partie réelle (α 4) (Vitesse acoustique m/s)

Facteur de classement: Partie réelle (α 4)

Facteurs en entrée:

Partie imaginaire (α 4)

Partie réelle (α 4)

Probabilités a priori: les mêmes pour tous les groupes

Coûts des erreurs: égaux pour toutes les classes

Variable de sélection: Vitesse acoustique m/s

Nombre de sujets dans le jeu d'apprentissage: 51

Nombre de sujets dans le jeu de validation: 0

Tableau.A .1 : Jeu d'apprentissage Partie réelle (α 4)

| | | Pourcentage de |
|-----------------------------|---------|----------------|
| Partie réelle (α 4) | Membres | bien classés |
| 0 | 28 | 100,0 |
| 1,88991 | 1 | 100,0 |
| 1,94074 | 1 | 100,0 |
| 1,9946 | 1 | 100,0 |
| 2,05182 | 1 | 100,0 |
| 2,1128 | 1 | 100,0 |
| 2,17803 | 1 | 100,0 |
| 2,24806 | 1 | 100,0 |
| 2,32357 | 1 | 100,0 |
| 2,40537 | 1 | 100,0 |
| 2,49444 | 1 | 100,0 |
| 2,59202 | 1 | 100,0 |
| 2,69963 | 1 | 100,0 |
| 2,81924 | 1 | 100,0 |
| 2,95336 | 1 | 100,0 |
| 3,10533 | 1 | 100,0 |
| 3,27965 | 1 | 100,0 |

| | | |
|---------|----|-------|
| 3,48254 | 1 | 100,0 |
| 3,72289 | 1 | 100,0 |
| 4,01376 | 1 | 100,0 |
| 4,37488 | 1 | 100,0 |
| 4,83575 | 1 | 100,0 |
| 5,42994 | 1 | 100,0 |
| 6,02849 | 1 | 100,0 |
| Total | 51 | 100,0 |

Cette procédure utilise un réseau de neurones probabiliste (PNN) pour classer des sujets dans les différents groupes définis par Partie réelle (α 4) en se basant sur 2 variables en entrée. Parmi les 51 sujets du jeu d'apprentissage, 100,0% ont été correctement classés par le réseau.

Tableau.A .2 : Tableau de classement

| Observé | Taille | Prévu | | | | | |
|-----------------------------|-----------|-------|---------|---------|--------|---------|--------|
| Partie réelle (α 4) | du groupe | 0 | 1,88991 | 1,94074 | 1,9946 | 2,05182 | 2,1128 |
| 0 | 28 | 28 | 0 | 0 | 0 | 0 | 0 |
| | | 100% | 0% | 0% | 0% | 0% | 0% |
| 1,88991 | 1 | 0 | 1 | 0 | 0 | 0 | 0 |
| | | 0% | 100% | 0% | 0% | 0% | 0% |
| 1,94074 | 1 | 0 | 0 | 1 | 0 | 0 | 0 |
| | | 0% | 0% | 100% | 0% | 0% | 0% |
| 1,9946 | 1 | 0 | 0 | 0 | 1 | 0 | 0 |
| | | 0% | 0% | 0% | 100% | 0% | 0% |
| 2,05182 | 1 | 0 | 0 | 0 | 0 | 1 | 0 |
| | | 0% | 0% | 0% | 0% | 100% | 0% |
| 2,1128 | 1 | 0 | 0 | 0 | 0 | 0 | 1 |
| | | 0% | 0% | 0% | 0% | 0% | 100% |
| 2,17803 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 2,24806 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |

| | | | | | | | |
|---------|---|----|----|----|----|----|----|
| 2,32357 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 2,40537 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 2,49444 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 2,59202 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 2,69963 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 2,81924 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 2,95336 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 3,10533 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 3,27965 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 3,48254 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 3,72289 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 4,01376 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 4,37488 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 4,83575 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 5,42994 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |
| 6,02849 | 1 | 0 | 0 | 0 | 0 | 0 | 0 |
| | | 0% | 0% | 0% | 0% | 0% | 0% |

Ce tableau affiche les résultats obtenus en utilisant le réseau après apprentissage pour classer les sujets. Il dénombrement les Partie réelle ($\alpha 4$) qui correspondent aux deux voisins les plus proches pour chaque sujet. Parmi les 51 sujets utilisés pour l'apprentissage du modèle, 100,0% sont correctement classés. On pourra prévoir des sujets additionnels en ajoutant des lignes dans le fichier des données et en saisissant des valeurs pour toutes les variables en entrée mais en laissant à vide les cellules de Partie réelle ($\alpha 4$).

A.2. Classement par réseau de neurones - Partie imaginaire ($\alpha 4$) (Vitesse acoustique m/s)

Facteur de classement: Partie imaginaire ($\alpha 4$)

Facteurs en entrée: Partie imaginaire ($\alpha 4$) et Partie réelle ($\alpha 4$)

Probabilités a priori: les mêmes pour tous les groupes

Coûts des erreurs: égaux pour toutes les classes

Variable de sélection: Vitesse acoustique m/s

Nombre de sujets dans le jeu d'apprentissage: 51

Nombre de sujets dans le jeu de validation: 0

Tableau.A . 3 : Jeu d'apprentissage Partie imaginaire ($\alpha 4$)

| | | <i>Pourcentage de</i> |
|--|----------------|-----------------------|
| <i>Partie imaginaire ($\alpha 4$)</i> | <i>Membres</i> | <i>bien classés</i> |
| -23,7412 | 1 | 100,0 |
| -5,28715 | 1 | 100,0 |
| -3,07129 | 1 | 100,0 |
| -2,11167 | 1 | 100,0 |
| -1,88976 | 1 | 100,0 |
| -1,88494 | 1 | 100,0 |
| -1,88067 | 1 | 100,0 |
| -1,57791 | 1 | 100,0 |
| -1,23915 | 1 | 100,0 |
| -1,00577 | 1 | 100,0 |
| -0,835712 | 1 | 100,0 |
| -0,706635 | 1 | 100,0 |

| | | |
|-----------|---|-------|
| -0,605584 | 1 | 100,0 |
| -0,524527 | 1 | 100,0 |
| -0,458226 | 1 | 100,0 |
| -0,403116 | 1 | 100,0 |
| -0,356692 | 1 | 100,0 |
| -0,317141 | 1 | 100,0 |
| -0,283119 | 1 | 100,0 |
| -0,253609 | 1 | 100,0 |
| -0,227827 | 1 | 100,0 |
| -0,205162 | 1 | 100,0 |
| -0,185126 | 1 | 100,0 |
| -0,16733 | 1 | 100,0 |
| -0,151456 | 1 | 100,0 |
| -0,137244 | 1 | 100,0 |
| -0,12448 | 1 | 100,0 |
| 0 | 1 | 100,0 |
| 3,20615 | 1 | 100,0 |
| 3,26907 | 1 | 100,0 |
| 3,33762 | 1 | 100,0 |
| 3,41259 | 1 | 100,0 |
| 3,49489 | 1 | 100,0 |
| 3,58569 | 1 | 100,0 |
| 3,68635 | 1 | 100,0 |
| 3,79863 | 1 | 100,0 |
| 3,92471 | 1 | 100,0 |
| 4,06736 | 1 | 100,0 |
| 4,23022 | 1 | 100,0 |
| 4,41812 | 1 | 100,0 |
| 4,63761 | 1 | 100,0 |
| 4,89785 | 1 | 100,0 |
| 5,21211 | 1 | 100,0 |
| 5,60037 | 1 | 100,0 |

| | | |
|---------|----|-------|
| 6,09436 | 1 | 100,0 |
| 6,74789 | 1 | 100,0 |
| 7,66078 | 1 | 100,0 |
| 9,04324 | 1 | 100,0 |
| 11,4338 | 1 | 100,0 |
| 16,7958 | 1 | 100,0 |
| 43,7084 | 1 | 100,0 |
| Total | 51 | 100,0 |

Cette procédure utilise un réseau de neurones probabiliste (PNN) pour classer des sujets dans les différents groupes définis par Partie imaginaire ($\alpha 4$) en se basant sur 2 variables en entrée. Parmi les 51 sujets du jeu d'apprentissage, 100,0% ont été correctement classés par le réseau.

Pourcentage des sujets du jeu d'apprentissage bien classés: 100,00%

| | <i>Groupe</i> | <i>Premier plus proche</i> | <i>Première plus proche</i> | <i>Second plus proche</i> | <i>Seconde plus proche</i> |
|--------------|----------------|----------------------------|-----------------------------|---------------------------|----------------------------|
| <i>Ligne</i> | <i>observé</i> | <i>Voisin</i> | <i>distance</i> | <i>voisin</i> | <i>distance</i> |

Ce tableau affiche les résultats obtenus en utilisant le réseau après apprentissage pour classer les sujets. Il dénombrement les Partie imaginaire ($\alpha 4$) qui correspondent aux deux voisins les plus proches pour chaque sujet. Parmi les 51 sujets utilisés pour l'apprentissage du modèle, 100,0% sont correctement classés. Dans ce cas aussi, on pourra prédire des sujets additionnels en ajoutant des lignes dans le fichier des données et en saisissant des valeurs pour toutes les variables en entrée mais en laissant à vide les cellules de Partie imaginaire ($\alpha 4$).

A.3. Classement par réseau de neurones - Vitesse acoustique m/s (Vitesse acoustique m/s)

Facteur de classement: Vitesse acoustique m/s (V_s)

Facteurs en entrée:

Partie imaginaire ($\alpha 4$)

Partie réelle ($\alpha 4$)

Probabilités a priori: les mêmes pour tous les groupes

Coûts des erreurs: égaux pour toutes les classes

Variable de sélection: Vitesse acoustique (m/s)

Nombre de sujets dans le jeu d'apprentissage: 51

Nombre de sujets dans le jeu de validation: 0

Tableau.A . 3 : Jeu d'apprentissage Vitesse acoustique (m/s)

| | | <i>Pourcentage de</i> |
|-------------------------------|----------------|-----------------------|
| <i>Vitesse acoustique m/s</i> | <i>Membres</i> | <i>bien classés</i> |
| 2400 | 1 | 100,0 |
| 2450 | 1 | 100,0 |
| 2500 | 1 | 100,0 |
| 2550 | 1 | 100,0 |
| 2600 | 1 | 100,0 |
| 2650 | 1 | 100,0 |
| 2700 | 1 | 100,0 |
| 2750 | 1 | 100,0 |
| 2800 | 1 | 100,0 |
| 2850 | 1 | 100,0 |
| 2900 | 1 | 100,0 |
| 2950 | 1 | 100,0 |
| 3000 | 1 | 100,0 |
| 3050 | 1 | 100,0 |
| 3100 | 1 | 100,0 |
| 3150 | 1 | 100,0 |
| 3200 | 1 | 100,0 |
| 3250 | 1 | 100,0 |
| 3300 | 1 | 100,0 |
| 3350 | 1 | 100,0 |
| 3400 | 1 | 100,0 |
| 3450 | 1 | 100,0 |
| 3500 | 1 | 100,0 |
| 3550 | 1 | 100,0 |
| 3600 | 1 | 100,0 |
| 3650 | 1 | 100,0 |
| 3700 | 1 | 100,0 |

| | | |
|-------|----|-------|
| 3750 | 1 | 100,0 |
| 3800 | 1 | 100,0 |
| 3850 | 1 | 100,0 |
| 3900 | 1 | 100,0 |
| 3950 | 1 | 100,0 |
| 4000 | 1 | 100,0 |
| 4050 | 1 | 100,0 |
| 4100 | 1 | 100,0 |
| 4150 | 1 | 100,0 |
| 4200 | 1 | 100,0 |
| 4250 | 1 | 100,0 |
| 4300 | 1 | 100,0 |
| 4350 | 1 | 100,0 |
| 4400 | 1 | 100,0 |
| 4450 | 1 | 100,0 |
| 4500 | 1 | 100,0 |
| 4550 | 1 | 100,0 |
| 4600 | 1 | 100,0 |
| 4650 | 1 | 100,0 |
| 4700 | 1 | 100,0 |
| 4750 | 1 | 100,0 |
| 4800 | 1 | 100,0 |
| 4850 | 1 | 100,0 |
| 4900 | 1 | 100,0 |
| Total | 51 | 100,0 |

Cette procédure utilise un réseau de neurones probabiliste (PNN) pour classer des sujets dans les différents groupes définis par Vitesse acoustique m/s en se basant sur 2 variables en entrée. Parmi les 51 sujets du jeu d'apprentissage, 100,0% ont été correctement classés par le réseau.

Pourcentage des sujets du jeu d'apprentissage bien classés: 100,00%

| | <i>Groupe</i> | <i>Premier plus proche</i> | <i>Première plus proche</i> | <i>Second plus proche</i> | <i>Seconde plus proche</i> |
|--------------|----------------|----------------------------|-----------------------------|---------------------------|----------------------------|
| <i>Ligne</i> | <i>observé</i> | <i>Voisin</i> | <i>Distance</i> | <i>voisin</i> | <i>distance</i> |

Ce tableau affiche les résultats obtenus en utilisant le réseau après apprentissage pour classer les sujets. Il dénombre également les Vitesse acoustique m/s qui correspondent aux deux voisins les plus proches pour chaque sujet. Parmi les 51 sujets utilisés pour l'apprentissage du modèle, 100,0% sont correctement classés. Là aussi, on pourra prévoir des sujets additionnels en ajoutant des lignes dans le fichier des données et en saisissant des valeurs pour toutes les variables en entrée mais en laissant à vide les cellules de Vitesse acoustique (m/s).