

République Algérienne Démocratique et Populaire
Ministère de l'enseignement supérieur et de la recherche scientifique
Université 8 Mai 1945 – Guelma
Faculté des sciences et de la Technologie
Département de Génie Electrotechnique et Automatique



**Mémoire de fin d'étude
pour l'obtention du diplôme de MASTER**

Domaine : **Sciences et Technologie**
Filière : **Électromécanique**
Spécialité : **Électromécanique**

**Modélisation des micromachines/capteurs en utilisant les
réseaux de neurones artificiels**

Réalisé par :

- Aissougui Iheb
- Dahemechi Tayeb Nizar

Sous la direction de :

Dr. Khalil Tamersit

Jun 2023

République Algérienne Démocratique et Populaire
Ministère de l'enseignement supérieur et de la recherche scientifique
Université 8 Mai 1945 – Guelma
Faculté des sciences et de la Technologie
Département de Génie Electrotechnique et Automatique



**Mémoire de fin d'étude
pour l'obtention du diplôme de MASTER**

Domaine : **Sciences et Technologie**
Filière : **Électromécanique**
Spécialité : **Électromécanique**

**Modélisation des micromachines/capteurs en utilisant les
réseaux de neurones artificiels**

Réalisé par :

- Aissougui Iheb
- Dahemechi Tayeb Nizar

Sous la direction de :

Dr. Khalil Tamersit

Jun 2023

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ

Dédicace

- On dédie ce modeste travail à nos chers parents, pour leurs soutiens, leurs encouragements et leurs amours.
- On dédie aussi ce modeste travail à nos familles, nos amis et nos collègues.

- Aissougui Iheb
- Dahemechi Tayeb Nizar

Remerciements

En tout premier lieu, on remercie le bon dieu pour tout. On remercie *Allah* qui nous a tout donné pour atteindre ce stade.

Nos remerciements les plus sincères vont aux membres du jury pour leur disponibilité, leur expertise et l'intérêt qu'ils ont accordé à notre travail. Leurs précieux commentaires et suggestions ont grandement contribué à l'amélioration de notre mémoire.

Nous souhaitons exprimer notre profonde gratitude à notre encadrant, le Docteur Khalil Tamersit, pour son soutien incondicional, ses précieux conseils et son accompagnement tout au long de ce travail. Son expertise et sa bienveillance ont été déterminantes dans la réussite de notre PFE.

Nous tenons également à manifester toute notre affection et nos remerciements à nos familles qui ont été un soutien indéfectible tout au long de notre parcours. Leurs amours, leurs encouragements et leurs compréhensions ont été essentiels pour surmonter les obstacles et avancer avec détermination.

Enfin, nous adressons nos remerciements chaleureux à nos amis, nos collègues et à toutes les personnes qui ont contribué, de près ou de loin, à la réalisation de ce mémoire. Leurs encouragements, leurs échanges fructueux et leur soutien moral ont été d'une importance capitale pour mener à bien ce modeste travail.

- Iheb Aissougui

- Tayeb Nizar Dahemechi

Sommaire

Introduction Générale.....	7
Chapitre 1. Technologies de récupération de faible énergie	
I.1. Introduction	9
I.2. Récupération d'énergie pour l'électronique à faible puissance.....	10
I.2.1. Cellules photovoltaïques.....	11
I.2.2. Générateurs thermoélectriques.....	12
I.2.3. Générateurs basés sur les vibrations (Vibration based Generators).....	13
I.3 Récupération d'énergie mécanique des vibrations.....	14
I.3.1 Effet piézoélectrique	15
I.3.1.a) L'effet direct piézoélectrique	16
I.3.1.b) L'effet inverse piézoélectrique	16
I.3.1.c) Capteur piézoélectrique.....	17
I.3.2 Matériaux piézoélectrique	17
I.3.3 Dispositifs piézoélectriques de récupération d'énergie (Cantilevers).....	22
I.3.3.1. Définition.....	22
I.3.3.2. Principe de fonctionnement	24
I.3.3.3. Types.....	25
I.3.3.4. Model numérique.....	26
I.4. Conclusion.....	29
Chapitre 2 : Les réseaux de neurones artificiels	
II.1. Introduction	30
II.2. Chronologie	32
II.3. Anatomie du neurone biologique	32
II.3.1. Le corps cellulaire.....	33
II.3.2 Les dendrites.....	33

II.3.3. L'axone.....	33
II.3.4. Les synapses.....	33
II.4. Le fonctionnement du neurone	34
II.5. Neurone artificiel	34
II.5.1. Le poids	35
II.5.2. Le biais	35
II.5.3. La fonction d'activation.....	35
II.6. Réseau de neurones artificiels	36
II.7. La construction des réseaux de neurones.....	37
II.7.1. Collecte et préparation des données.....	37
II.7.2. Choix de l'architecture.....	37
II.7.3. Définition des couches et des paramètres.....	37
II.7.4. Définition de la fonction de coût et de l'optimiseur.....	37
II.7.5. Entraînement du réseau.....	37
II.7.6. Validation et ajustement des hyperparamètres	37
II.7.7. Évaluation des performances.....	38
II.8. Artificiel Neural Networks.....	38
II.9. Les réseaux les plus célèbres.....	38
II.9.1. Le perceptron.....	38
II.9.2. Algorithme du perceptron.....	39
II.9.3. Réseau ADALINE (Adaptive Linear Neuron).....	39
II.10. Le perceptron multicouche (Multilayer perceptron MLP).....	40
II.10.1. Définition.....	40
II.10.2. Type de multilayer perceptron (MLP).....	41
II.11. Apprentissage du réseau de neurone.....	41
II.11.1. Définition de l'apprentissage du réseau de neurone.....	41
II.11.2. Stratégie d'apprentissage.....	41
II.11.3. Types d'apprentissage.....	42
II.11.3.1. L'apprentissage supervisé.....	42
II.11.3.2. L'apprentissage non-supervisé.....	44
II.11.3.2.1. Méthode apprentissage non supervisé.....	44

II.11.3.3. Apprentissage par renforcement.....	45
II.12. Conclusion	45
Chapitre III : Modélisation intelligente : Cas d'un moteur	
III.1. Introduction	46
III.2. Modélisation basée sur les réseaux de neurones artificiels (ANN)	47
III.3. Description de la base de données	47
III.4. Conclusion.....	50
Chapitre IV : Modélisation intelligente d'un cantilever générateur d'énergie	
IV.1. Introduction.....	51
IV.2. La description du problème	52
IV.3. Logiciels	53
IV.4. Configuration des données	53
IV.5. Les ensembles de création d'un modèle par un réseau de neurone.....	54
IV.6. Résultats et discussion.....	54
IV.6.1. La fonction de rétropropagation de Levenberg–Marquardt (trailm).....	55
IV.6.2. Entraînement et Simulation.....	55
IV.7. Teste du modèle.....	60
III.4. Conclusion.....	61
Conclusion Générale.....	62
Références.....	63

Liste des figures

Figure I.1 : Récupération d'énergie et technologies associatives.....	11
Figure I.2 : Dessin descriptif des cellules photovoltaïques.....	12
Figure I.3 : Un circuit thermoélectrique composé de matériaux de différents coefficients Seebeck.....	13
Figure I.4 : Schéma descriptif sur la récupération d'énergie vibratoire.....	13
Figure I-5 : Schématisation des effets piézoélectriques.....	16
Figure I.6 : Les capteurs piézoélectriques.....	17
Figure I.7 : différentes classes cristallines.....	18
Figure I.8 : Cantilever-based energy harvesterstructure.....	23
Figure I.9 : la géométrie du modèle, montrant les principaux composants du récupérateur d'énergie.....	27
Figure I.10 : Puissance mécanique d'entrée du récupérateur d'énergie et puissance récupérée	28
Figure I.11 : Puissance récupérée de l'appareil en fonction de la résistance de charge électrique	29
Figure I.12 : Tension CC et puissance de sortie mécanique/électrique.....	29
Figure II.1 : système du réseau de neurone	31
Figure II.2 : neurone biologique	33
Figure II.3 Schéma d'un Neurone artificiel	35
Figure II.4 Différents types de fonctions d'activations	36
Figure II.5 réseaux de neurone artificiel	36
Figure II.6 : Un perceptron multicouche contenant trois couches	40
Figure II.7 exemples d'apprentissage supervisé.....	43
Figure III.1 courbe de performance.....	48
Figure III.2 : Training state.....	48
Figure III.3 Errors histogram.....	49
Figure III.4 Courbe de Régression.....	50
Figure IV.1 (a) dispositif à modéliser. (b) schéma électrique équivalent.....	52
Figure IV.2 logo du matlab.....	53

Figure IV.3 Forme du réseau de neurone utilisé..... 55

Figure IV.4 Courbe de performance..... 55

Figure IV.5: Training state..... 56

Figure IV.6 Histogramme d'erreurs..... 58

Figure IV.7 Courbe de Régression..... 59

Figure IV.8 Courbe de tension concernant la résistance..... 60

Figure IV.9 Courbe de puissance..... 61

Liste des tableaux

Tableau I.1 : Caractéristiques de quelques sources de vibration	15
Tableau II.1: Correspondance neurone biologique/neurone artificiel.....	35

Introduction Générale

Le présent mémoire de fin d'étude se concentre sur l'application des réseaux de neurones artificiels (RNA) pour le développement d'un modèle numérique destiné à l'optimisation des cantilevers, des dispositifs électromécaniques de récupération d'énergie. Les cantilevers jouent un rôle crucial dans la conversion de l'énergie mécanique, en particulier des vibrations, en énergie électrique exploitable. L'objectif de ce travail est de créer un modèle prédictif basé sur les ANNs, capable de fournir des estimations précises de la tension crête générée par un cantilever en fonction de ses paramètres géométriques, dimensionnels et électriques.

Le mémoire est divisé en quatre chapitres qui fournissent une introduction approfondie aux concepts clés nécessaires à la compréhension et à la réalisation de cette étude. Le premier chapitre met en évidence les technologies de récupération d'énergie mécanique axées sur les vibrations, en mettant l'accent sur les matériaux piézoélectriques et les cantilevers. Différentes vibrations exploitables pour la récupération d'énergie sont également explorées, jetant ainsi les bases nécessaires pour une compréhension approfondie des mécanismes de ces technologies.

Le deuxième chapitre se concentre sur une introduction complète et détaillée aux réseaux de neurones artificiels. Les concepts clés, les principes de fonctionnement et les différents types de réseaux neuronaux sont examinés, mettant l'accent sur leur application dans divers domaines de l'apprentissage automatique. Les techniques d'entraînement, les bases de données utilisées et les aspects importants tels que la validation et les tests de performance sont également discutés. Cette compréhension approfondie des réseaux de neurones artificiels fournira les outils nécessaires pour concevoir et entraîner des modèles performants capables de résoudre des problèmes complexes.

Le troisième chapitre présente une modélisation intelligente à l'aide de réseaux de neurones artificiels multilayer perceptron (MLP) et de l'algorithme de Levenberg-Marquardt. Dans ce chapitre, une base de données préexistante appelée "engine" dans le logiciel Matlab est utilisée, avec des taux de carburant et des vitesses en tant qu'entrées, et le couple et les émissions d'oxyde nitreux en tant que sorties. Cela permet de se familiariser avec l'application pratique des réseaux de neurones dans le contexte d'un phénomène électromécanique, et prépare le terrain pour la modélisation à effectuer dans le quatrième chapitre.

Le quatrième et dernier chapitre présente la modélisation intelligente d'un cantilever générateur d'énergie. Une base de données est extraite d'un simulateur numérique avancé qui utilise des équations sophistiquées résolues à l'aide de la méthode des éléments finis. Les

paramètres d'entrée comprennent la longueur du cantilever, l'épaisseur du matériau piézoélectrique, l'épaisseur du substrat et la résistance de charge, tandis que la sortie est la tension crête générée. L'établissement de la base de données, l'entraînement, la validation et les tests sont effectués avec succès, démontrant la prédictibilité et l'excellence du modèle développé.

En conclusion, ce mémoire de fin d'étude a exploré l'application des réseaux de neurones artificiels pour le développement d'un modèle numérique visant à optimiser les cantilevers en tant que dispositifs de récupération d'énergie. Les connaissances acquises sur les technologies de récupération d'énergie mécanique, les réseaux de neurones artificiels et leur modélisation intelligente ont permis de créer un modèle prédictif précis, offrant des résultats rapides et fiables par rapport aux simulations numériques avancées existantes. Ce modèle peut être utilisé comme outil précieux pour les études de cantilevers, intégré dans les bibliothèques de simulateurs existants et combiné avec des modèles bio-inspirés pour optimiser les performances en tenant compte des contraintes vibratoires. Cette recherche contribue ainsi à l'avancement des sciences et des technologies de l'information, ouvrant la voie à de nouvelles possibilités d'utilisation de l'énergie mécanique disponible dans notre environnement.

Chapitre I

Technologies de récupération de faible énergie

I.1 Introduction

La récupération de l'énergie ambiante a suscité un intérêt croissant et est devenue un objectif majeur pour de nombreux groupes de recherche. Diverses sources d'énergie environnementales, telles que les vibrations mécaniques, le rayonnement solaire et l'énergie humaine, ont été activement étudiées en vue de créer des sources d'alimentation alternatives. Ces sources ambiantes représentent des candidats potentiels pour remplacer les batteries existantes, qui ont une capacité de stockage d'énergie et une durée de vie limitées dans certaines applications. Parmi elles, la récupération d'énergie à partir de vibrations mécaniques a particulièrement attiré l'attention, en raison des progrès substantiels réalisés dans les circuits intégrés, notamment dans les processeurs de signaux numériques à faible puissance, permettant de réduire les besoins en énergie des nœuds de capteurs sans fil. Bien que chaque mécanisme de transduction et chaque

application correspondante présentent des avantages spécifiques, la conversion d'énergie par piézoélectricité est considérée comme l'une des technologies les plus prometteuses pour les dispositifs MEMS. Les matériaux piézoélectriques génèrent une charge ou une tension électrique lorsqu'ils sont soumis à une contrainte mécanique, et vice versa. Ainsi, l'énergie vibratoire peut être directement convertie en tension, sans nécessiter de géométries complexes ni de composants supplémentaires. Cela contraste avec les dispositifs électrostatiques qui requièrent une tension d'entrée. Dans ce chapitre, nous présenterons une vue d'ensemble des différentes technologies de récupération d'énergie, suivi d'une introduction à la récupération d'énergie des vibrations mécaniques par piézoélectricité.

I.2 Récupération d'énergie pour l'électronique à faible puissance

La récupération d'énergie consiste à récupérer l'énergie environnante d'un système et à la transformer en énergie électrique utilisable. L'objectif principal de cette méthode est de fournir de l'énergie à des appareils mobiles et à des dispositifs spéciaux tels que ceux utilisés dans l'internet des objets, sans avoir à utiliser de batteries. En effet, les batteries peuvent présenter des limites en termes de durée de vie et de capacité de stockage, ce qui peut rendre leur remplacement complexe et coûteux. Les capteurs sans fil, par exemple, sont souvent utilisés dans des endroits éloignés où le remplacement des batteries peut être difficile et coûteux.

L'idée derrière la récupération d'énergie est de concevoir des dispositifs qui peuvent se fournir eux-mêmes en énergie sans avoir besoin de batteries remplaçables. En effet, en utilisant des sources externes telles que la lumière, les différences de température, le vent, l'écoulement de l'eau, les vibrations mécaniques, ou même les activités humaines ou animales, il est possible de récupérer de l'énergie ambiante dans l'environnement qui peut être utilisée pour charger ou remplacer des batteries. Cette énergie capturée peut alors être utilisée pour prolonger la durée de vie des appareils alimentés ou, dans le meilleur des cas, fournir une source d'énergie illimitée pour les dispositifs électroniques portables.

Grâce aux progrès récents de la technologie sans fil et de l'électronique à faible consommation d'énergie, tels que les systèmes MEMS, les capteurs et l'électronique sont de plus en plus petits, moins coûteux et consomment moins d'énergie.

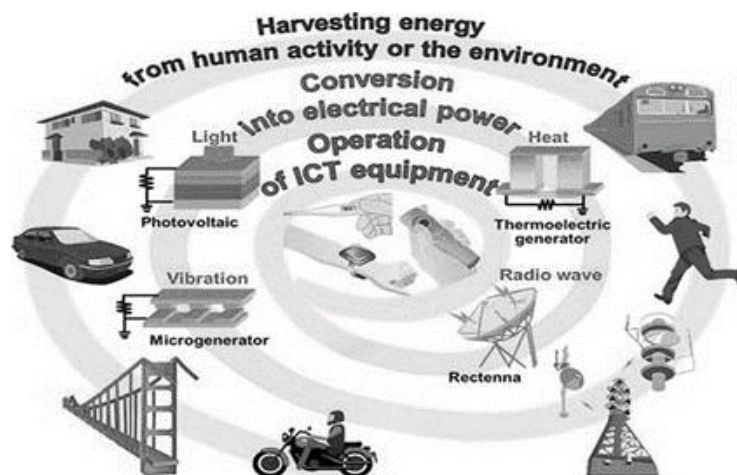


Figure I.1 : Récupération d'énergie et technologies associatives, y compris les micro-générateurs vibratoires, les cellules solaires photovoltaïques, thermoélectriques et rectenna, avec des applications potentielles dans les équipements et dispositifs d'assistance des technologies de l'information et de la communication. [1]

Cela a conduit à une augmentation de la recherche sur la récupération d'énergie pour des applications pratiques dans le monde réel. L'histoire de la récupération d'énergie remonte aux époques où le moulin à vent et la roue hydraulique étaient utilisés. Aujourd'hui, il existe de nombreuses options pour produire de l'énergie à partir de l'environnement ambiant, comme l'énergie solaire, l'énergie thermique, les dispositifs à vibrations, et même l'énergie humaine, etc. [2].

1.2.1 Cellules photovoltaïques

Lorsqu'une cellule photovoltaïque (PV), également appelée cellule solaire, est exposée à la lumière, cette dernière peut être réfléchiée, absorbée ou traverser la cellule. La cellule PV est constituée d'un matériau semi-conducteur. Ce terme signifie que ce matériau est capable de mieux conduire l'électricité qu'un isolant, mais pas aussi bien qu'un conducteur efficace comme un métal. Il existe plusieurs types de matériaux semi-conducteurs utilisés dans les cellules photovoltaïques.

Lorsqu'un semi-conducteur est exposé à la lumière, il absorbe l'énergie lumineuse et la transfère à des particules chargées négativement dans le matériau, appelées électrons. Cette énergie supplémentaire permet aux électrons de se déplacer à travers le matériau sous forme de courant électrique. Des contacts métalliques conducteurs - les lignes en forme de grille sur les cellules solaires - extraient ensuite ce courant qui peut être utilisé pour alimenter une maison ou le réseau électrique. L'efficacité d'une cellule PV est la quantité d'énergie électrique qui en sort par rapport à l'énergie lumineuse qu'elle reçoit, ce qui mesure sa capacité à convertir l'énergie d'une forme à une autre. La quantité d'électricité produite dépend de caractéristiques

telles que l'intensité et les longueurs d'onde de la lumière disponible, ainsi que de diverses caractéristiques de performance de la cellule.




Figure I.2 : Dessin descriptif des cellules photovoltaïques. [3]

La bande interdite est une caractéristique importante des semi-conducteurs photovoltaïques car elle définit les longueurs d'onde de la lumière qui peuvent être absorbées et converties en énergie électrique. Si la bande interdite du semi-conducteur correspond aux longueurs d'onde de la lumière qui atteignent la cellule PV, alors la cellule peut utiliser efficacement toute l'énergie disponible. Cependant, les cellules solaires ont des limitations dans les conditions de faible éclairage, comme dans les bureaux ou les zones sans lumière. Par conséquent, les cellules solaires ne sont pas adaptées aux applications embarquées, car il peut ne pas y avoir de lumière présente, ou les cellules peuvent être obstruées par la pollution.

I.2.2 Générateurs thermoélectriques

Un générateur thermoélectrique (TEG) est un dispositif semi-conducteur qui transforme directement l'énergie thermique (différences de température) en énergie électrique, grâce à l'effet Seebeck. Contrairement aux moteurs thermiques, les TEG n'ont pas de pièces mobiles et sont moins encombrants. Toutefois, ils sont plus coûteux et moins efficaces.

Les générateurs thermoélectriques ont plusieurs applications potentielles telles que la conversion de la chaleur perdue dans les centrales électriques en énergie électrique supplémentaire, l'augmentation de l'efficacité énergétique des automobiles grâce à des générateurs thermoélectriques automobiles (ATG) et l'alimentation de sondes spatiales grâce aux générateurs thermoélectriques à radio-isotopes qui utilisent des radio-isotopes pour générer la différence de température nécessaire. [4].




Figure I.3 : Un circuit thermoélectrique composé de matériaux de différents coefficients Seebeck (semi-conducteurs dopés p et dopés n), configuré comme un générateur thermoélectrique. [4]

I.2.3 Générateurs basés sur les vibrations (Vibration-based Generators)

Les générateurs électriques alimentés par vibration sont des dispositifs qui convertissent l'énergie cinétique des vibrations en énergie électrique. Ces vibrations peuvent provenir d'ondes acoustiques ou d'autres sources de vibrations environnementales. Ils sont composés d'un résonateur qui amplifie la source de vibration et d'un transducteur qui convertit l'énergie vibratoire en énergie électrique. Les transducteurs sont souvent composés d'un aimant et d'une bobine ou d'un cristal piézoélectrique. Par exemple, les générateurs électromagnétiques utilisent la loi d'induction de Faraday pour convertir l'énergie cinétique des vibrations en énergie électrique. Ils comportent des aimants fixés à une membrane souple ou à une poutre en porte-à-faux et une bobine.

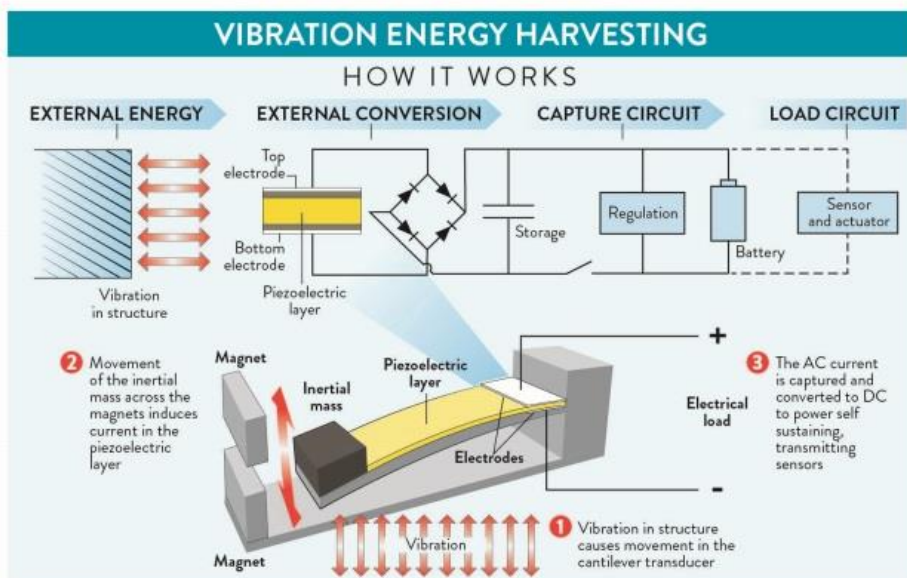


Figure I.4 : Schéma descriptif sur la récupération d'énergie vibratoire. [6]

Les vibrations entraînent une variation de la distance entre l'aimant et la bobine, ce qui modifie le flux magnétique et produit une force électromotrice. En général, la bobine est conçue à partir d'un matériau diamagnétique car ces matériaux ont des interactions plus faibles avec l'aimant, ce qui atténue les vibrations. Le principal bénéfice de ce type de générateur est qu'il peut générer plus de puissance que les générateurs piézoélectriques [5].

I.3 Récupération d'énergie mécanique des vibrations

Avec l'essor des applications telles que l'Internet des Objets (IoT), les capteurs sans fil et les réseaux de capteurs sans fil sont de plus en plus demandés. La façon de fournir de l'énergie à ces capteurs sans fil suscite une attention particulière.

Bien que les batteries soient couramment utilisées comme source d'énergie, elles ont des limites en raison de leur durée de vie limitée et de leur capacité de stockage d'énergie, ce qui nécessite un rechargement ou un remplacement régulier. Dans certains cas, comme dans les environnements extérieurs et inaccessibles, l'entretien des batteries est coûteux et peu pratique. Ainsi, la collecte d'énergie à partir de sources environnementales telles que l'énergie éolienne, hydraulique, solaire, mécanique, etc. pour recharger ou remplacer automatiquement les batteries est considérée comme une application prometteuse ne nécessitant pas de maintenance.

Des chercheurs ont montré un grand intérêt pour les dispositifs de récupération d'énergie, qui permettent de convertir les vibrations mécaniques en énergie électrique grâce à des matériaux piézoélectriques. Ces dispositifs, également appelés dispositifs de récupération d'énergie piézoélectrique, peuvent produire une puissance de sortie satisfaisante lorsqu'ils sont excités à des fréquences proches de la fréquence de résonance, en utilisant les vibrations ambiantes. [6].

La principale qualité de l'énergie mécanique est qu'elle est largement disponible dans l'environnement sous forme de vibrations dans les structures telles que les bâtiments, les ponts, les équipements industriels et les véhicules de transport, ainsi que sous forme de mouvements tels que ceux du corps humain, du vent et des courants marins. Ces sources d'énergie ont des caractéristiques spécifiques, telles que la bande spectrale, l'amplitude et la durée d'excitation, ainsi que les directions spatiales des sollicitations. [5].

Le tableau I.1 nous présente les Caractéristiques de quelques sources de vibration :

Source de vibration	Pic d'accélération (m/s^2)	Fréquence d'accélération (Hz)
Machine-outil à trois axes	10	70
Four à micro-ondes	2.25	121
Réfrigérateur	0.1	240
Marche sur terrasse en bois	1.3	385
Sèche-linge	3.5	121
Moteur à combustion	12	50 à 200

Tableau I.1 : Caractéristiques de quelques sources de vibration

I.3.1 Effet piézoélectrique

L'effet piézoélectrique est un phénomène électromécanique dans lequel la déformation mécanique d'un matériau produit une polarisation électrique, et inversement, l'application d'un champ électrique sur un matériau piézoélectrique provoque une déformation mécanique.

Certains matériaux tels que les cristaux de quartz, de tourmaline, de topaze, les céramiques piézoélectriques et certains polymères ont une symétrie cristalline particulière qui leur permet de présenter l'effet piézoélectrique. Ce phénomène est dû à la déformation des liaisons ioniques entre les atomes du cristal qui se produit en réponse à une contrainte mécanique. Cette déformation de la structure cristalline entraîne un déplacement des ions dans le matériau et une séparation des charges électriques positives et négatives.

Lorsqu'une contrainte mécanique est appliquée au matériau, le réseau se déplace, ce qui crée une polarisation des charges et génère un champ électrique. Inversement, un champ électrique appliqué au matériau peut entraîner une déformation du réseau cristallin et un changement de forme. [7]

L'effet piézoélectrique peut être décrit par l'équation : $S = d * T$

Où S est la polarisation électrique, d est le coefficient de piézoélectricité du matériau et T est la contrainte mécanique appliquée.

Inversement, lorsque l'on applique un champ électrique à un matériau piézoélectrique, les charges électriques dans le matériau sont déplacées, provoquant une déformation mécanique. Cet effet est appelé effet inverse piézoélectrique et peut être décrit par l'équation : $D = e * E$

Où D est la déformation mécanique, e est le coefficient de piézoélectricité du matériau et E est le champ électrique appliqué. [8]

L'effet piézoélectrique peut être divisé en deux catégories : l'effet direct piézoélectrique et l'effet inverse piézoélectrique.

I.3.1.a) L'effet direct piézoélectrique :

Se produit lorsqu'un matériau piézoélectrique est soumis à une contrainte mécanique, telle qu'une pression ou une tension. Cette contrainte provoque une déformation dans la structure cristalline du matériau, entraînant une séparation des charges électriques. Cela génère une tension électrique mesurable entre les deux faces du matériau.

I.3.1.b) L'effet inverse piézoélectrique :

Se produit lorsque l'on applique un champ électrique sur un matériau piézoélectrique, provoquant une déformation mécanique dans la structure cristalline du matériau. Cela peut être utilisé pour contrôler les vibrations ou les mouvements de matériaux piézoélectriques, ce qui les rend utiles dans les dispositifs d'actuation. [8]




Figure I-5 : Schématisation des effets piézoélectriques [26]

Il existe une grande variété d'applications pour l'effet piézoélectrique, allant des capteurs de pression et de température jusqu'aux dispositifs ultrasoniques employés en médecine ou en contrôle non destructif. Les matériaux piézoélectriques sont également couramment utilisés dans la conception de haut-parleurs, de microphones, d'actionneurs et de moteurs piézoélectriques.

I.3.1.c) capteur piézoélectrique

Un capteur piézoélectrique est un dispositif qui utilise l'effet piézoélectrique pour mesurer une grandeur physique, telle que la pression, la force, l'accélération ou la température. Le capteur se compose d'un matériau piézoélectrique, qui convertit la grandeur physique en une charge électrique. Cette charge électrique est ensuite mesurée par un circuit électronique et converti en une valeur numérique pour être traitée ou affichée.

Les capteurs qui utilisent l'effet piézoélectrique sont couramment utilisés dans divers domaines, tels que la médecine, l'industrie, l'aérospatiale et l'automobile, pour mesurer divers paramètres physiques tels que la pression artérielle, la force de freinage, l'accélération de la voiture ou la température du moteur.

Les capteurs piézoélectriques ont de nombreux atouts, notamment une excellente sensibilité, une réponse rapide, une grande plage de mesure, une faible consommation d'énergie et une bonne résistance à la corrosion. Néanmoins, ils ont également des inconvénients tels qu'une susceptibilité aux vibrations et aux chocs, une dérive de la mesure en raison des variations de température et une vulnérabilité aux interférences électromagnétiques. [9]




Figure I.6 : Les capteurs piézoélectriques.[27]

I.3.2 Matériaux piézoélectrique

L'effet piézoélectrique découle principalement de la présence de dipôles électriques internes dans un cristal. Ces dipôles sont formés par une séparation des centres de charge positive et négative de la structure cristalline. Par conséquent, la piézoélectricité dépend fortement de la symétrie cristalline, de sorte qu'une maille « centrosymétrique » (c'est-à-dire ayant un centre de symétrie) ne peut pas donner lieu à un cristal piézoélectrique.

La propriété piézoélectrique ne peut être observée que dans certains types de géométries cristallines. Sur les 32 types de géométrie cristalline existants, seules 21 sont non

centrosymétriques, et parmi ces 21, 20 présentent des propriétés piézoélectriques. Sur ces 20 classes cristallines piézoélectriques, 10 d'entre elles possèdent une polarisation électrique spontanée en l'absence de contrainte ou de champ extérieur, ce qui les qualifie de pyroélectriques. Leurs moments dipolaires varient en fonction de la température. Un schéma représentant ces 32 classes cristallines est montré dans la figure I-6.

* **La pyroélectricité** : est la propriété d'un matériau dans lequel un changement de température entraîne une variation de polarisation électrique. Cette variation de polarisation crée une différence de potentiel.

* **La ferroélectricité** : est la propriété de certains matériaux de posséder une polarisation électrique à l'état spontané, naturel : « une polarisation spontanée ». Cela est dû au fait que le centre de gravité des charges positives est distinct de celui des charges négatives. Cette polarisation peut être renversée en appliquant un champ électrique extérieur [10]. Après suppression du champ électrique, ces matériaux conservent une polarisation rémanente et c'est la variation de cette polarisation rémanente avec la température qui permet la libération d'un courant électrique dans une charge fermée dans la céramique.

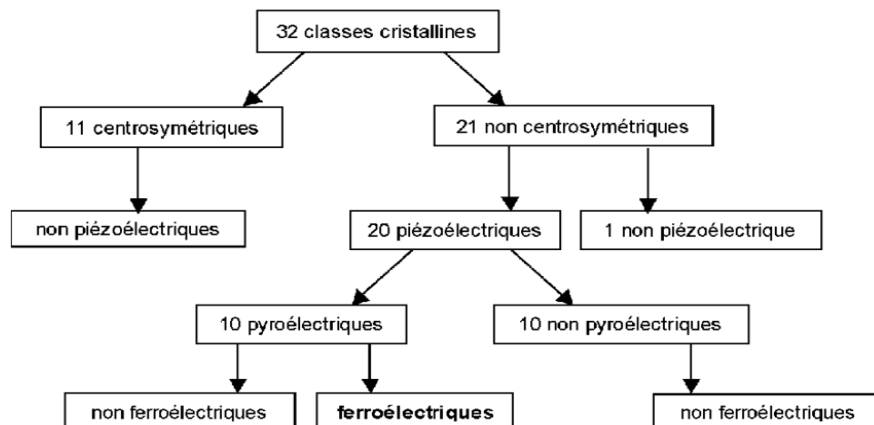


Figure I.7 : différentes classes cristallines.[28]

Les matériaux piézoélectriques sont des matériaux qui peuvent produire une charge électrique en réponse à une contrainte mécanique et vice versa. Ces matériaux sont largement utilisés dans de nombreuses applications, telles que les transducteurs acoustiques, les capteurs, les actionneurs et les dispositifs électroniques. Voici une liste de matériaux piézoélectriques couramment utilisés :

a) Quartz : Le quartz est un minéral cristallin composé de dioxyde de silicium (SiO_2). C'est l'un des minéraux les plus abondants sur terre et se trouve dans de nombreuses roches ignées, métamorphiques et sédimentaires. Le quartz est également largement utilisé dans l'industrie, en

particulier pour la fabrication de montres, de capteurs et d'autres dispositifs électroniques en raison de ses propriétés physiques uniques.

Sur le plan cristallographique, le quartz appartient au groupe des silicates tétraédriques, qui se caractérisent par la présence de tétraèdres de SiO_4 liés entre eux. Les cristaux de quartz sont souvent hexagonaux et peuvent avoir différentes couleurs, notamment le blanc, le rose, le violet, le jaune, le brun et le noir. La couleur du quartz dépend souvent des impuretés présentes dans le cristal.

Le quartz est également un matériau piézoélectrique, ce qui signifie qu'il peut produire une charge électrique lorsqu'il est soumis à une contrainte mécanique et vice versa. Cette propriété est due à sa structure cristalline spécifique, qui permet aux charges électriques de se déplacer facilement dans le cristal. En raison de sa stabilité thermique élevée, de sa faible perte et de sa réponse rapide, le quartz est largement utilisé dans les oscillateurs, les filtres et les capteurs de pression. [11]

b) Tourmaline : La tourmaline est un minéral silicaté complexe qui peut contenir une grande variété d'éléments chimiques, notamment le sodium, le calcium, le lithium, le magnésium, l'aluminium, le fer, le cuivre et le vanadium. La formule chimique générale de la tourmaline est $(\text{Ca, Na, K, Mg, Fe, Li, Al})_3(\text{Al, Fe, Cr})_6[(\text{OH, F})_4(\text{BO}_3)_3\text{Si}_6\text{O}_{18}]$. Le nom "tourmaline" vient du mot cingalais "turмали", qui signifie "pierre de couleurs mélangées".

La tourmaline est un minéral qui se caractérise par sa structure cristalline et appartient au groupe des silicates cyclosilicates. Les cristaux de tourmaline ont une forme allongée de type prismatique et leur couleur peut varier considérablement, allant du noir au blanc, en passant par une gamme de nuances telles que le rouge, le rose, le vert, le bleu, le jaune et le violet. La coloration du cristal est déterminée par sa composition chimique.

La tourmaline est un minéral qui, comme le quartz, possède la propriété de piézoélectricité et peut générer une charge électrique sous l'effet d'une contrainte mécanique. Cette caractéristique rend la tourmaline utile dans la production de dispositifs électroniques comme les microphones, les haut-parleurs et les capteurs de pression. [12]

c) Le PZT (zirconate de plomb titanate) : Est un matériau céramique piézoélectrique largement utilisé dans l'industrie pour ses propriétés électriques et mécaniques uniques. Le PZT est un composé de plomb, de zirconium et de titane, avec une formule chimique générale de $\text{Pb}(\text{Zr}_x\text{Ti}_{1-x})\text{O}_3$, où x peut varier entre 0 et 1.

Le PZT est une céramique pérovskite cristalline qui peut présenter une structure cubique ou tétragonale, en fonction de sa composition chimique et du traitement qu'il subit. Le PZT est classé comme un matériau ferroélectrique, ce qui signifie que les dipôles électriques du matériau peuvent être alignés électriquement. Cette polarisation électrique peut être inversée en appliquant un champ électrique inverse.

Le PZT est un matériau qui possède des propriétés piézoélectriques, ce qui implique qu'il peut convertir une contrainte mécanique en charge électrique et vice versa. Cette propriété découle de sa structure cristalline particulière, qui facilite le déplacement des charges électriques à travers le matériau. Le PZT est très apprécié pour sa grande piézoactivité, sa stabilité thermique élevée et sa réponse rapide, ce qui lui permet d'être largement utilisé dans les transducteurs, les actionneurs, les capteurs de pression et de force, les systèmes de positionnement et autres applications où la conversion d'énergie électrique en énergie mécanique est requise. [11]

En plus de ses propriétés électriques et mécaniques, le PZT est également connu pour sa biocompatibilité, ce qui le rend adapté à certaines applications biomédicales, telles que les implants auditifs et les stimulateurs cardiaques

d) Le PVDF (fluorure de polyvinylidène) : Est un polymère fluoré thermoplastique qui présente des propriétés électriques et mécaniques uniques. Le PVDF est un polymère semi-cristallin, qui est synthétisé à partir de la monomère de la vinylidène difluorure (VDF) avec une formule chimique de $(CF_2-CF_2)_n$, où n représente le nombre de répétitions de la chaîne.

Le PVDF est un matériau qui possède la propriété de piézoélectricité, ce qui implique qu'il peut convertir une contrainte mécanique en une charge électrique, ou inversement, une déformation mécanique en un champ électrique. Cette propriété est due à la polarisation des molécules de PVDF, qui ont des charges électriques inhomogènes réparties sur leur chaîne moléculaire.

Le PVDF est un matériau qui peut résister aux produits chimiques, à la corrosion et à la chaleur élevée. Il est couramment utilisé dans diverses industries pour fabriquer des tuyaux, des vannes, des réservoirs, des câbles et des revêtements. En outre, le PVDF est un matériau de choix pour les membranes des piles à combustible en raison de sa haute conductivité ionique et de sa résistance aux produits chimiques.

Le PVDF est un matériau qui convient pour certaines utilisations dans le domaine médical, car il est biocompatible et résistant à la corrosion. Il est employé pour produire divers dispositifs médicaux, comme les cathéters, les implants et les prothèses, en raison de ces propriétés. [12]

e) Le nitrure d'aluminium (AlN) : Est un matériau céramique de couleur gris-blanc composé d'aluminium et d'azote. Il est caractérisé par ses propriétés physiques, mécaniques et électriques uniques, qui en font un matériau très intéressant pour de nombreuses applications.

Le nitrure d'aluminium est caractérisé par sa conductivité thermique et électrique élevée, ainsi que sa forte résistance mécanique, sa dureté considérable et sa faible densité. En outre, il est piézoélectrique, ce qui indique qu'il peut créer une charge électrique en réponse à une tension mécanique.

On utilise le nitrure d'aluminium dans de nombreux domaines, notamment dans la fabrication de LED, de transistors de puissance, de capteurs de pression, de circuits intégrés haute fréquence et de substrats pour l'électronique de puissance. De plus, il est souvent utilisé comme revêtement pour les outils de coupe et les moules d'injection en raison de sa dureté et de sa résistance à l'usure.

De plus, le nitrure d'aluminium est un matériau bio-inerte, ce qui signifie qu'il est compatible avec les tissus biologiques, ce qui en fait un matériau intéressant pour les applications médicales telles que les implants dentaires et les prothèses. [13]

f) Le niobate de lithium (LiNbO₃) : Est un matériau cristallin inorganique utilisé pour sa propriété optique non linéaire, ce qui le rend utile pour la fabrication de dispositifs optiques tels que les modulateurs, les commutateurs et les oscillateurs.

Le LiNbO₃ appartient à la classe des matériaux ferroélectriques, ce qui signifie qu'il possède une polarisation électrique réversible qui peut être modifiée en appliquant un champ électrique externe. Cette propriété lui confère des propriétés piézoélectriques, pyroélectriques et électro-optiques. [13]

Le LiNbO₃ est un matériau couramment employé dans l'industrie des télécommunications pour produire des équipements optiques, comme les modulateurs optiques, les filtres optiques et les détecteurs optiques. Il sert également à créer des dispositifs pour le traitement de signaux optiques, comme les oscillateurs, les amplificateurs et les commutateurs.

Le LiNbO_3 est employé non seulement dans le domaine des télécommunications, mais également dans d'autres domaines tels que la spectroscopie, l'optique quantique, la photonique intégrée et les sciences des matériaux. Il peut être utilisé comme substrat pour la croissance de cristaux et pour la fabrication de capteurs dans les applications de science des matériaux. [14]

Ces matériaux piézoélectriques ont des propriétés uniques qui les rendent adaptés à différentes applications. Il est important de choisir le matériau piézoélectrique approprié en fonction des besoins spécifiques de l'application.

I.3.3 Dispositifs piézoélectriques de récupération d'énergie (Cantilevers)

I.3.3.1. Définition

L'histoire des convertisseurs piézoélectriques de type cantilever remonte aux années 1950, lorsque les premiers capteurs piézoélectriques ont été développés pour mesurer les vibrations dans les structures mécaniques. Cependant, il faut attendre les années 1990 pour que les premiers convertisseurs de type cantilever soient développés pour la production d'énergie

En 1997, J. R. Friend et ses collègues de l'Université de Melbourne ont présenté une méthode pour produire de l'électricité à partir de vibrations à l'aide d'un convertisseur piézoélectrique de type cantilever. Le dispositif consistait en une poutre en aluminium recouverte d'un matériau piézoélectrique. Les vibrations de la poutre provoquaient des déformations dans le matériau piézoélectrique, ce qui générait une tension électrique.

Depuis lors, des convertisseurs de type cantilever basés sur la piézoélectricité ont été conçus pour diverses applications, notamment la surveillance des vibrations, la production d'énergie, la mesure de la force, la détection de gaz, la mesure de la température et la génération d'ondes sonores. Des matériaux piézoélectriques récents ont été mis au point pour améliorer les performances de ces convertisseurs.[15]

Un cantilever piézoélectrique est un capteur miniature utilisé en nanotechnologie et en microscopie à force atomique pour mesurer les propriétés de surface des matériaux à l'échelle atomique et moléculaire.

Le cantilever piézoélectrique est fabriqué à partir d'un matériau piézoélectrique tel que le quartz, le silicium ou l'AlN (nitrure d'aluminium). Il se compose d'une fine poutre fixée à une extrémité (appelée la base) et se terminant à l'autre extrémité par une pointe très fine (quelques nanomètres).

Le cantilever est couramment équipé d'un revêtement fonctionnel afin de permettre la mesure de la grandeur à analyser. Lorsque la pointe du cantilever est soumise à une force, la

poutre se plie et entraîne une modification de la résistance électrique, de la capacité ou de la fréquence de résonance de l'appareil. Ces changements peuvent être mesurés à l'aide de techniques électriques, optiques ou mécaniques.[16]

Lorsque le cantilever s'approche de la surface de l'échantillon, les forces d'interaction entre la pointe et la surface entraînent une modification de la fréquence de résonance de la poutre. Cette modification est détectée par un détecteur de force sensible, tel qu'un faisceau laser ou une cellule photodiode, qui enregistre les vibrations de la poutre. En mesurant la variation de la fréquence de résonance, il est possible de déterminer les propriétés mécaniques de la surface, telles que la topographie, la dureté et l'élasticité.

Le cantilever piézoélectrique peut servir à mesurer des propriétés différentes de la surface, en plus de ses capacités à mesurer la topographie, la dureté et l'élasticité. Il est possible d'utiliser une pointe spéciale pour appliquer un signal électrique ou thermique à la surface, tandis que la poutre piézoélectrique détecte la réponse électrique ou thermique de la surface. Les propriétés qui peuvent être mesurées de cette manière comprennent la conductivité électrique, la capacitance et la résistance thermique de la surface. [16]




Figure I.8: Cantilever-based energy harvester structure. [17]

Le dispositif PVEH typique est composé de couches piézoélectriques, de couches structurales, de couches d'électrodes et d'une masse d'épreuve d'électrodes et d'une masse d'épreuve. Les poutres en porte-à-faux ou les électrodes sont la configuration géométrique la plus courante car elles sont compatibles avec les processus de fabrication des MEMS et ont été efficaces pour collecter l'énergie piézoélectrique provenant des vibrations ambiantes.

Le cantilever est une structure flexible qui peut offrir des fréquences de résonance basses, qui peuvent être encore réduites en ajoutant une masse à l'extrémité de la poutre ou de la plaque.

En outre, cette structure est capable de produire une déformation élevée, ce qui se traduit par une plus grande production d'énergie par rapport à d'autres configurations structurelles. [17].

I.3.3.2. Principe de fonctionnement

Le cantilever électromécanique fonctionne en mesurant la déformation mécanique d'une poutre fine (le cantilever) intégrée à un élément électrique, tel qu'un capteur de déformation. Lorsqu'une force est appliquée, le cantilever se plie proportionnellement à la force. L'élément électrique intégré dans le cantilever détecte cette flexion et la convertit en une variation électrique proportionnelle.

Il est possible de mesurer la flexion mécanique du cantilever à l'aide d'un élément électrique intégré qui convertit la déformation mécanique en une variation électrique proportionnelle. Cette variation électrique peut être détectée à l'aide de techniques de détection sensibles telles que l'amplification et l'analyse du signal électrique. En utilisant cette méthode, il est possible de déterminer la magnitude et la direction de la force appliquée. [18]

Le principe de fonctionnement du Cantilever-based energy harvester peut être décrit en plusieurs étapes :

***Génération de l'énergie mécanique :** Le dispositif de récupération d'énergie basé sur un cantilever est conçu pour être installé dans un environnement qui présente des vibrations ou des secousses. Lorsqu'une force est appliquée à l'extrémité libre du cantilever, celui-ci commence à osciller et à vibrer.

***Conversion de l'énergie mécanique en énergie électrique :** Le cantilever produit des oscillations qui induisent une contrainte dans le matériau piézoélectrique, ce qui à son tour génère une tension électrique via l'effet piézoélectrique. Les électrodes disposées sur le cantilever captent cette tension électrique.

***Amplification et rectification du signal électrique :** En raison de la faiblesse du signal électrique produit par le dispositif de récupération d'énergie basé sur le cantilever, il est nécessaire de l'amplifier pour qu'il puisse être utilisé. En outre, le signal doit subir un processus de rectification pour être utilisé dans des circuits électroniques. Cette opération est généralement réalisée par un circuit électronique incorporé dans le dispositif.

***Stockage de l'énergie électrique :** La quantité d'énergie électrique produite par le Cantilever-based energy harvester peut être stockée dans une batterie ou directement utilisée pour alimenter un appareil électronique. [19]

I.3.3.3. Types

Il existe plusieurs types de Cantilever-based energy harvester, qui diffèrent selon leur géométrie, leur matériau piézoélectrique et leur mode de fonctionnement. Voici quelques exemples de types de Cantilever-based energy harvester :

a) Cantilever piezoelectric energy harvester : c'est le type le plus couramment utilisé. Il est fabriqué à partir d'un matériau piézoélectrique qui est fixé à un support rigide à une extrémité et libre à l'autre extrémité. Lorsque le cantilever est soumis à des vibrations, il se met à osciller et génère une tension électrique grâce à l'effet piézoélectrique.

b) Cantilever electromagnetic energy harvester : ce type de Cantilever-based energy harvester utilise le principe de l'induction électromagnétique pour générer de l'électricité. Il est constitué d'un aimant fixé à une extrémité d'un cantilever et d'une bobine de fil conducteur fixée à l'autre extrémité. Lorsque le cantilever est soumis à des vibrations, l'aimant se déplace dans la bobine, ce qui génère une tension électrique.

c) Cantilever electrostatic energy harvester : ce type de Cantilever-based energy harvester utilise le principe de l'effet capacitif pour générer de l'électricité. Il est constitué de deux électrodes, une fixe et un mobile, qui sont séparées par une petite distance. Lorsque le cantilever est soumis à des vibrations, l'électrode mobile se déplace par rapport à l'électrode fixe, ce qui modifie la capacité électrique entre les deux électrodes et génère une tension électrique.

d) Cantilever thermoelectric energy harvester : ce type de Cantilever-based energy harvester utilise le principe de l'effet Seebeck pour générer de l'électricité à partir de différences de température. Il est constitué d'un matériau piézoélectrique qui est exposé à des sources de chaleur différentes. La différence de température entre les deux sources génère une tension électrique grâce à l'effet Seebeck.[20]

Il existe différents types de générateurs d'énergie piézoélectrique basés sur des cantilevers, chacun ayant ses propres caractéristiques et applications spécifiques. Voici une brève description de quelques-uns des types de générateurs d'énergie piézoélectrique les plus courants :

e) Cantilever en une seule couche : Le Cantilever en une seule couche est un générateur d'énergie piézoélectrique simple, qui consiste en une couche unique de matériau piézoélectrique fixée à une extrémité, et une masse mobile fixée à l'autre extrémité. Lorsque la masse se déplace, la poutre se plie, ce qui crée une charge électrique dans le matériau piézoélectrique. Ce type de générateur est souvent utilisé pour les applications à faible puissance, telles que les capteurs de vibrations.

f) Cantilever en deux couches : Le Cantilever en deux couches est composé de deux couches de matériaux piézoélectriques de polarité opposée, fixées à une extrémité et d'une masse mobile fixée à l'autre extrémité. Lorsque la masse se déplace, elle provoque une flexion de la poutre qui génère une différence de potentiel entre les deux couches de piézoélectriques, ce qui crée une charge électrique. Ce type de générateur peut produire une tension de sortie plus élevée que le Cantilever en une seule couche, et est souvent utilisé dans des applications nécessitant une puissance plus élevée.

g) Cantilever en sandwich : Le Cantilever en sandwich est un type de générateur d'énergie piézoélectrique qui est constitué de plusieurs couches de matériaux piézoélectriques et diélectriques alternées fixées à une extrémité et d'une masse mobile fixée à l'autre extrémité. Lorsque la masse se déplace, elle cause une flexion de la poutre qui crée une différence de potentiel entre les différentes couches de matériaux piézoélectriques et diélectriques, ce qui produit une charge électrique. Ce type de générateur est capable de produire une tension de sortie encore plus élevée que le Cantilever en deux couches.[21]

h) Cantilever plié : Le Cantilever plié est un générateur d'énergie piézoélectrique qui se caractérise par une poutre pliée à angle droit. Lorsque la masse se déplace, la poutre subit une flexion dans deux directions, ce qui génère une charge électrique dans le matériau piézoélectrique. Ce type de générateur peut générer une puissance de sortie plus élevée que les autres types de générateurs de cantilever.

Ces différents types de générateurs d'énergie piézoélectrique basés sur des cantilevers ont des avantages et des inconvénients spécifiques en termes de puissance de sortie, de rendement, de fréquence de fonctionnement et de coût. Le choix du type de générateur dépendra des exigences spécifiques de chaque application.[22]

I.3.3.4. Model numérique

Une micro-générateur d'énergie piézoélectrique est capable de produire de l'énergie en réponse aux vibrations de son environnement. Pour que cela fonctionne, il est important que la fréquence de la micro-générateur d'énergie piézoélectrique soit en adéquation avec les vibrations environnementales. De plus, la structure doit être facile à fabriquer et sensible aux vibrations.

Trois structures de générateurs piézoélectriques à faisceau cantilever sont disponibles : la structure en double couche hétérogène, la structure en sandwich, et la structure représentée dans la Figure I-6 qui répond aux exigences de fabrication MEMS. Cette dernière est constituée d'une

couche piézoélectrique avec une couche d'électrode supérieure et inférieure pour collecter la charge générée. Une couche isolante est présente pour éviter toute perte de charge. La masse sismique permet de diminuer la fréquence naturelle du cantilever pour se rapprocher de la fréquence des vibrations environnementales. Elle augmente également la force d'inertie et la déformation, ce qui augmente l'énergie mécanique d'entrée et la puissance de sortie en conséquence. [23]

Le capteur de puissance est constitué d'un matériau piézoélectrique de forme biomorphe fixé à une extrémité et d'une masse d'essai fixée à l'autre extrémité. Le biomorphe a des électrodes de sortie intégrées et des électrodes de masse sur ses surfaces extérieures pour garantir une tension induite égale sur les électrodes de sortie, même si la contrainte au-dessus et en dessous de la couche neutre est de signe opposé. L'appareil est monté sur une machine vibrante pour être analysé dans un environnement de vibrations et la figure I-7 montre sa géométrie.

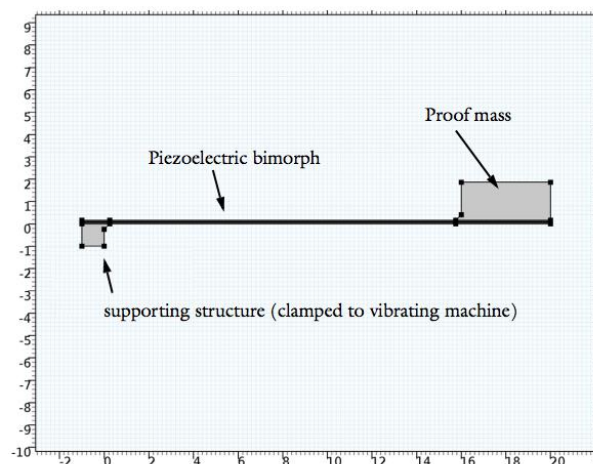


Figure I.9 : la géométrie du modèle, montrant les principaux composants du récupérateur d'énergie, y compris le biomorphe piézoélectrique, la masse d'épreuve et la structure de support.[24]

Le modèle effectue trois analyses de la partie mécanique du système de récupération d'énergie. Tout d'abord, la puissance de sortie est analysée en fonction de la fréquence de vibration, avec une charge électrique. Ensuite, la puissance de sortie en fonction de la charge électrique est explorée. Enfin la sortie de tension continue, en fonction de l'accélération, s'avère linéaire.[24]

Le modèle numérique d'un cantilever piézoélectrique peut être représenté par un système d'équations qui décrivent les interactions entre les propriétés mécaniques et électriques du matériau. Les équations sont généralement basées sur la théorie de la plaque et prennent en

compte la déformation mécanique et la polarisation électrique induites par une charge électrique appliquée. La modélisation peut être effectuée à l'aide de méthodes numériques telles que la méthode des éléments finis (MEF) ou la méthode des différences finies (MDF). Les équations du modèle peuvent être résolues numériquement pour déterminer les déformations et les contraintes mécaniques ainsi que les champs électriques et les charges dans le matériau.

Le modèle numérique peut être utilisé pour prédire le comportement du cantilever piézoélectrique sous différentes conditions, telles que des charges électriques ou mécaniques appliquées, et pour optimiser la conception du dispositif pour une application spécifique.[24]

Les équations qui décrivent le comportement d'un cantilever piézoélectrique dépendent des propriétés du matériau utilisé ainsi que de la géométrie du dispositif.

La figure I-8 indique la puissance mécanique d'entrée et la puissance récupérée (en mW) ainsi que la tension crête induite aux bornes du bimorphe piézoélectrique (en V) en fonction de la fréquence lorsque le récupérateur d'énergie est excité par une accélération sinusoïdale qui a été fait par le groupe du COMSOL. La charge électrique est de 12 k Ω . La réponse du système montre un pic à 76 Hz, proche de la résonance calculée fréquence du porte-à-faux à 73 Hz (à partir d'une analyse de fréquence propre séparée de cet appareil).[24]

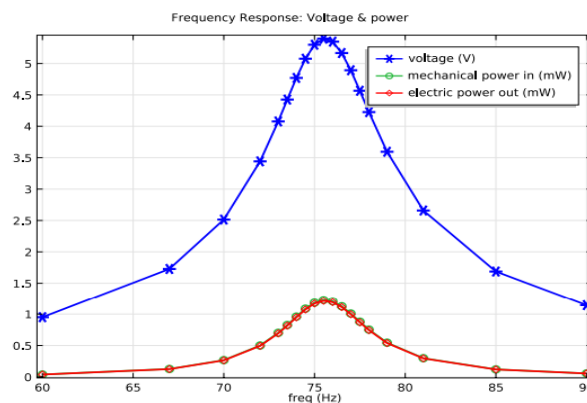


Figure I.10 : Puissance mécanique d'entrée du récupérateur d'énergie et puissance récupérée (en mW) comme la tension de crête induite aux bornes du bimorphe piézoélectrique (en V) en fonction de la fréquence d'excitation. L'impédance de charge est de 12 k Ω et l'amplitude de l'accélération est de 1 g. [24]

La figure I-9 montre la puissance récupérée de l'appareil en fonction de la charge électrique résistance à une accélération de 1 g oscillant à 75,5 Hz. Le pic d'énergie récupérée correspond à une charge électrique de 6 k Ω .




Figure I.11 : Puissance récupérée de l'appareil en fonction de la résistance de charge électrique à un accélération de 1 g oscillant à 75,5 Hz. [24]

Aussi on a la figure I-10 qui montre la tension continue et la puissance de sortie mécanique/électrique par rapport à l'amplitude de l'accélération mécanique à une fréquence fixe de 75,5 Hz avec une charge impédance de 12 k Ω . La tension augmente linéairement avec la charge, tandis que la puissance augmente de façon quadratique

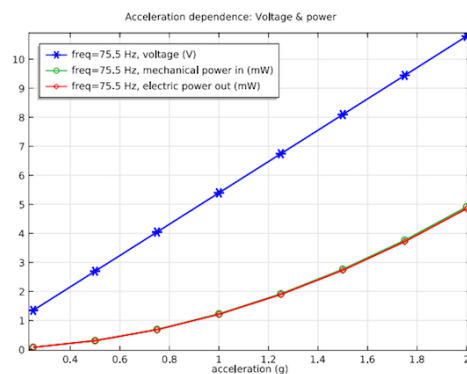


Figure I.12 : Tension CC et puissance de sortie mécanique/électrique par rapport à l'amplitude de l'accélération mécanique à une fréquence fixe de 75,5 Hz avec une impédance de charge de 12 k Ω . [24]

I.4 Conclusion

En conclusion, ce premier chapitre a fourni une introduction approfondie aux technologies de récupération d'énergie mécanique axées sur les vibrations. Nous avons discuté des matériaux piézoélectriques et des cantilevers, en mettant en évidence leurs principes de fonctionnement et leurs propriétés essentielles. De plus, nous avons exploré les différentes vibrations pertinentes qui peuvent être exploitées pour la récupération d'énergie mécanique. Ce chapitre a jeté les bases nécessaires pour comprendre les mécanismes de base de ces technologies, ce qui permettra d'aborder les développements futurs de manière plus informée. Grâce à cette compréhension approfondie, nous serons en mesure d'explorer de nouvelles voies de recherche et de proposer des solutions innovantes pour exploiter efficacement l'énergie mécanique disponible dans notre environnement.

Chapitre II

Les réseaux de neurones artificiels

II.1 Introduction

Le système nerveux est l'ensemble des structures qui coordonnent les fonctions d'un individu et permettent ses relations avec le milieu extérieur. Le tissu nerveux comporte deux grandes catégories cellulaires représentées d'une part par des cellules nerveuses spécialisées, les neurones, qui sont des cellules fonctionnellement capables de recevoir et d'intégrer des messages reçus, d'autre part par les cellules gliales regroupent divers types cellulaires assurant au sein du tissu nerveux des rôles de soutien, de partenariat dans les interactions inter neurales et de sécrétion. Les fonctions du système nerveux sont basées sur deux propriétés fondamentales, l'irritabilité (excitabilité) et la conductibilité, particulièrement développées dans les neurones. Son excitabilité est sa capacité de réagir aux variations du milieu extracellulaire en modifiant les propriétés électriques de sa membrane plasmique. La

conductibilité d'un neurone est sa capacité de transmettre l'influx nerveux très rapidement et sur longues distances. Le tissu nerveux se définit par la fonction de communication, du fait de sa propriété de percevoir, de conduire et de transmettre une excitation d'un point à un autre de l'organisme grâce à des structures spécialisées : les synapses (zone de contact entre 2 neurones). Les neurones sont des éléments dont la durée de vie est longue. Ils ne multiplient plus après la naissance.

Le domaine de l'intelligence artificielle connaît de nos jours une évolution majeure. Il est en train de bouleverser plusieurs domaines, tel que la santé, le transport, le multimédia, l'industrie automobile avec les voitures autonomes, l'industrie aérospatiale, l'industrie biomécanique, les secteurs de finance, d'économie et de marketing, l'éducation, et même le domaine de la justice est touché par l'intelligence artificiel ou un jour les logiciels ou les robots pourront remplacer les juges et les avocats. Comme son nom l'indique l'intelligence artificielle est une intelligence acquise par des machines dans le but de reproduire les comportements des humains.

Le domaine de recherche des réseaux de neurones est très vaste, commencé dans le XXe siècle, inspiré de la biologie par un neurophysiologiste et développé par les mathématiciens et les informaticiens dans le but d'atteindre le niveau de l'intelligence humaine, notamment au niveau de la perception, la mémorisation et même le raisonnement afin de nous facilite la résolution de déferent problème scientifique. Les efforts qui ont été fait par les chercheurs ces dernières décennies rendent les réseaux de neurones un atout très puissant, de nos jours les réseaux de neurones occupent la grande partie de l'intelligence artificielle.



Figure II.1 : système du réseau de neurone

II.2. Chronologie

L'étude de l'intelligence humaine a commencée avant des milliers d'années, avec l'essor massif dans le domaine de l'électronique programmable, les ambitions de réaliser une machine qui simule le système nerveux humain a augmenté, la première tentative vers les réseaux de neurones artificiels c'étaient en 1943, par le neurophysiologiste Warren Mc Culloch et le mathématicien Walter Pitts ont pu modéliser le tout premier réseau de neurones artificiels par circuits électriques. En 1949, le psychologue Donald O. Hebb a présenté dans son livre "The Organization of Behavior" une règle d'apprentissage permettant de définir les coefficients synaptiques cette règle fait la suite des travaux des deux chercheurs Mc Culloch et Pitts connue par "Règle de Hebb" cette règle est encore utilisée jusqu'à nos jours. En 1957, l'apparition d'un nouveau concept connue par le perceptron inventé par Frank Rosenblatt dans le laboratoire d'aéronautique de l'université Cornell c'est le premier système apte à apprendre.

Plus de dix ans après exactement en 1969, les deux chercheurs Marvin Lee Minsky et Seymour Papert ont découvert des insuffisances dans le perceptron par exemple l'incapacité de représenter des problèmes essentielles comme le problème XOR et la séparation linéaire, Ces critiques ont conduit à une stagnation de la recherche dans ce domaine, jusqu'à l'arrivée de l'année 1972 le chercheur T.Kohonen à introduire un modèle d'une mémoire associative. En 1982, le physicien John Joseph Hopfield donna un nouveau souffle au neuronal en publiant un article introduisant un nouveau modèle de réseau de neurones (complètement récurrent). Mais le problème de non linéarité reste toujours non résolu et, il faudra attendre 1984 pour obtenir un modèle de réseaux de neurones qualifié de multicouches et ne possédant pas les défauts démontrés par Minsky et Papert, ce modèle proposé par Paul J. Werbos et mis en œuvre par David Rumelhart en 1986 repose sur la rétro propagation du gradient de l'erreur dans des systèmes à plusieurs couches [28].

Depuis ; la recherche dans les réseaux de neurones se sont multipliés et l'application de cette technologie dans les différents domaines ne cesse d'augmenter tel que la classification, le contrôle l'optimisation, la reconnaissance de caractères et de signatures, la reconnaissance de formes et de motifs, l'industrie, les jeux vidéo, grâce à sa capacité d'apprentissage.

II.3. Anatomie du neurone biologique

Le neurone est l'unité de base du travail du cerveau, une cellule spéciale conçue pour transmettre de l'information à d'autres cellules nerveuses, musculaires et glandulaires. Les propriétés structurelles et fonctionnelles des connexions entre les neurones sont cruciales pour les caractéristiques du cerveau. Selon l'espèce, le cerveau des mammifères peut contenir entre

100 millions et 100 milliards de neurones. Chaque neurone de mammifère est constitué d'un corps cellulaire, de dendrites et d'un axone. Le corps cellulaire contient le noyau et le cytoplasme, tandis que l'axone, qui peut mesurer de moins d'un centimètre à plus d'un mètre de long, part du corps cellulaire et se ramifie souvent avant de se terminer en terminaisons nerveuses. Les dendrites, quant à elles, reçoivent des informations provenant d'autres neurones. [29].

II.3.1. Le corps cellulaire :

C'est l'élément qui contient le noyau du neurone et l'organe biochimique nécessaire pour la production des enzymes, il est de forme pyramidale ou sphérique sa fonction est de faire la somme des influx entrant et envoie lui-même un influx lorsque la somme dépasse un seuil précis via l'axone.

II.3.2 Les dendrites :

Ils se prolongent du corps cellulaire, et ils se ramifient autour du neurone et forment une sorte de vaste arborescence leur fonction est de capter les signaux envoyés au neurone.

II.3.3. L'axone :

Il conduit les signaux émis par le corps cellulaire, sa taille peut varier de quelques millimètres jusqu' à plus d'un mètre, il peut se ramifier à son extrémité comme il peut se connecter aux dendrites des autres neurones.

II.3.4. Les synapses :

Ils sont les points de communication entre les neurones, en général entre l'axone d'un neurone émetteur et les dendrites d'un neurone récepteur [29].




Figure II.2: neurone biologique

II.4. Le fonctionnement du neurone

Le processus de fonctionnement d'un neurone implique la transmission de signaux électrochimiques entre ses différentes parties. Lorsque ces signaux électriques atteignent le bouton terminal du neurone, cela déclenche la libération de neurotransmetteurs qui se déplacent à travers l'espace synaptique et activent les récepteurs du neurone suivant, créant ainsi une série de signaux électrochimiques.

Plus précisément, le fonctionnement d'un neurone peut être divisé en trois étapes principales : la transmission de l'influx nerveux, la transmission synaptique et l'intégration des signaux.

* Le début de la transmission de l'information nerveuse consiste en un signal électrique nommé potentiel d'action, qui se propage le long de l'axone du neurone. Ce processus est permis grâce à une différence de charge électrique entre l'intérieur et l'extérieur de la cellule nerveuse, ainsi que grâce à la présence de canaux ioniques particuliers qui permettent aux ions de traverser la membrane cellulaire.

* La deuxième étape du processus est la transmission synaptique, où les neurotransmetteurs sont libérés dans l'espace synaptique entre deux neurones et se lient aux récepteurs de la membrane du neurone suivant, déclenchant ainsi un potentiel d'action.

* La troisième étape est l'intégration des signaux, où le neurone reçoit et fusionne les différents signaux électrochimiques provenant de différents neurones, avant de prendre une décision quant à la transmission ou non d'un potentiel d'action. [29].

II.5. Neurone artificiel

Appelé aussi neurone formel est un modèle mathématique inspiré d'un neurone biologique, le neurone artificiel possède plusieurs entrées qui correspondent aux dendrites où il recueille l'information et une sortie qui correspond au cône d'émergence (point de départ de l'axone) d'où il envoie un signal électrique. Les actions excitatrices et inhibitrices des synapses sont représentées, la plupart du temps, par des coefficients numériques (les poids synaptiques) associés aux entrées. Les valeurs numériques de ces coefficients sont ajustées dans une phase d'apprentissage. Dans sa version la plus simple, un neurone formel calcule la somme pondérée des entrées reçues et ajoute un biais, puis applique à cette valeur une fonction d'activation, généralement non linéaire. La valeur finale obtenue est la sortie du neurone [30], comme montré dans l'équation suivante.

$$y_i = f(a_j) = \varphi(\sum_{i=0}^n (w_i * x_i) + b_j)$$

Eq. II.1

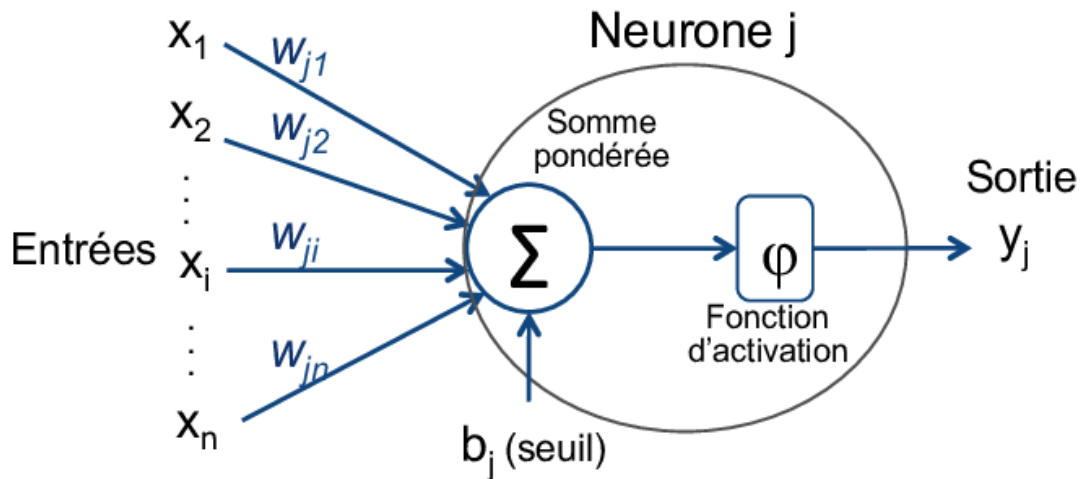


Figure II.3 Schéma d'un Neurone artificiel

Neurone biologique	Neurone artificiel (formel)
Axones	Signal d'entrée
Synapses	Poids de la connexion
Dendrites	Signal de sortie

Tableau II.1: Correspondance neurone biologique/neurone artificiel

II.5.1. Le poids :

Le poids est le coefficient qui control le signal d'entrée (la force de connexion), en d'autres termes le poids décide l'influence de l'entrée sur la sortie.

II.5.2 Le biais :

Le biais dans un réseau neuronal est un paramètre supplémentaire qui se connecte aux neurones de la couche précédente via un poids, souvent appelé seuil. C'est similaire à l'ajout d'une constante dans une équation linéaire pour ajuster la sortie en fonction de la somme pondérée des entrées du neurone. En ajustant le biais, le modèle peut mieux s'adapter aux données. [31]

II.5.3. La fonction d'activation

Est une fonction mathématique responsable du type de l'information émise par le neurone, elle intervient après le calcul de la somme pondérée et l'ajout du biais, elle possède un influe profond sur les performances du réseau. D'où il est préférable de bien choisir le type de cette fonction dans chaque couche du réseau, notons que les neurones d'entrées ne possèdent pas de fonction d'activation, ils utilisent la fonction identité.










Nom de la fonction	Relation d'entrée/sortie	Icône
seuil	$a = 0$ si $n < 0$ $a = 1$ si $n \geq 0$	
seuil symétrique	$a = -1$ si $n < 0$ $a = 1$ si $n \geq 0$	
linéaire	$a = n$	
linéaire saturée	$a = 0$ si $n < 0$ $a = n$ si $0 \leq n \leq 1$ $a = 1$ si $n > 1$	
linéaire saturée symétrique	$a = -1$ si $n < -1$ $a = n$ si $-1 \leq n \leq 1$ $a = 1$ si $n > 1$	
linéaire positive	$a = 0$ si $n < 0$ $a = n$ si $n \geq 0$	
sigmoïde	$a = \frac{1}{1+\exp^{-n}}$	
tangente hyperbolique	$a = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	
compétitive	$a = 1$ si n maximum $a = 0$ autrement	

Figure II.4 Différents types de fonctions d'activations

II.6. Réseau de neurones artificiels

Un réseau de neurones artificiels, également appelé réseau neuronal artificiel, est un système conçu à l'origine pour imiter le fonctionnement des neurones biologiques, mais qui a depuis été développé en utilisant des méthodes statistiques.

Les réseaux de neurones sont généralement optimisés à l'aide de méthodes d'apprentissage probabilistes, en particulier bayésiennes. Ils font partie de la famille des applications statistiques, apportant des paradigmes permettant des classifications rapides (comme les réseaux de Kohonen), et des méthodes d'intelligence artificielle qui fournissent un mécanisme perceptif indépendant de l'implémentation et des informations d'entrée pour le raisonnement logique formel.

En modélisation des circuits biologiques, ils permettent de tester quelques hypothèses fonctionnelles issues de la neurophysiologie, ou encore les conséquences de ces hypothèses pour les comparer au réel [32].




Figure II.5 réseaux de neurone artificiel

II.7. La construction des réseaux de neurones

La construction détaillée d'un réseau de neurones artificiels peut varier en fonction de la tâche à accomplir et de l'architecture du réseau choisi. Cependant, voici les étapes générales à suivre :

II.7.1. Collecte et préparation des données

Pour commencer l'apprentissage d'un réseau de neurones, il est nécessaire de collecter les données requises. Ces données doivent être préparées pour accomplir la tâche souhaitée et doivent être divisées en trois ensembles : l'ensemble d'apprentissage, l'ensemble de validation et l'ensemble de test. L'ensemble d'apprentissage est utilisé pour entraîner le réseau, l'ensemble de validation est utilisé pour ajuster les hyperparamètres du réseau, tandis que l'ensemble de test est utilisé pour évaluer les performances du réseau. [33]

II.7.2. Choix de l'architecture

Il existe différents types d'architectures de réseaux de neurones, chacune ayant ses propres avantages et inconvénients. Il est crucial de choisir l'architecture la plus appropriée pour la tâche à réaliser. Les architectures populaires comprennent les réseaux de neurones à couches denses, les réseaux de neurones convolutifs, les réseaux de neurones récurrents et les réseaux de neurones avec attention.

II.7.3. Définition des couches et des paramètres

Une fois l'architecture choisie, il faut définir les différentes couches du réseau, qui sont des unités de traitement de l'information. Les paramètres de chaque couche sont également définis, comme le nombre de neurones et la fonction d'activation.

II.7.4. Définition de la fonction de coût et de l'optimiseur

Pour évaluer la différence entre la sortie prédite par le réseau et la sortie réelle, une fonction de coût est appliquée. Pour réduire cette différence, l'optimiseur est utilisé pour ajuster les paramètres du réseau. L'objectif de l'optimiseur est de minimiser la fonction de coût.

II.7.5. Entraînement du réseau

L'entraînement du réseau de neurones débute avec l'initialisation aléatoire de ses poids et biais. Les données d'apprentissage sont ensuite utilisées pour ajuster les paramètres du réseau en se basant sur la fonction de coût. Le processus d'entraînement continue jusqu'à ce que la fonction de coût soit réduite au minimum, ou lorsque le réseau ne parvient plus à s'améliorer davantage.

II.7.6. Validation et ajustement des hyperparamètres

Une fois l'entraînement terminé, le réseau est évalué sur les données de validation pour déterminer s'il est surajusté (overfitting) ou sous-ajusté (underfitting). Les hyperparamètres du réseau peuvent alors être ajustés pour améliorer les performances.[33]

II.7.7. Évaluation des performances :

Une fois que les hyperparamètres ont été ajustés, le réseau est évalué sur les données de test pour déterminer ses performances sur des données non vues auparavant.

II.8. Artificiel Neural Networks

Les réseaux de neurones artificiels (ou "Artificial Neural Networks" en anglais) sont un type de modèle d'apprentissage automatique inspiré par le fonctionnement du cerveau humain. Les réseaux de neurones sont utilisés pour résoudre des problèmes de classification, de régression, de reconnaissance de formes, de traitement de signal, de traitement du langage naturel, etc.

Un réseau de neurones artificiels est composé de plusieurs couches de neurones interconnectés. Chaque neurone reçoit des entrées, effectue un calcul pondéré de ces entrées, applique une fonction d'activation non-linéaire sur la somme pondérée, et produit une sortie qui est propagée aux neurones de la couche suivante. Le processus de propagation avant de l'entrée aux sorties est appelé "feedforward". Les poids des connexions entre les neurones sont ajustés pendant l'entraînement du réseau pour minimiser une fonction de coût qui mesure l'écart entre les sorties du réseau et les sorties attendues.

Les réseaux de neurones peuvent avoir différentes architectures, y compris les réseaux de neurones à propagation avant (ou "feedforward neural networks" en anglais), les réseaux de neurones récurrents (ou "recurrent neural networks" en anglais) et les réseaux de neurones convolutifs (ou "convolutional neural networks" en anglais). Chacune de ces architectures a ses propres avantages et est adaptée à des tâches spécifiques.

Les réseaux de neurones ont connu un grand succès dans de nombreux domaines, notamment dans la reconnaissance d'image, la reconnaissance de la parole, la traduction automatique et les jeux vidéo [34].

II.9. Les réseaux les plus célèbres

II.9.1. Le perceptron :

Le perceptron est un modèle de réseau de neurones artificiels à une seule couche de neurones, utilisé pour la classification binaire supervisée. Il a été développé par Frank Rosenblatt en 1957. Le perceptron est un classificateur linéaire, qui utilise une fonction d'activation en escalier (généralement la fonction de Heaviside) pour produire une sortie binaire.

Le fonctionnement du perceptron est simple : les entrées sont pondérées et sommées, puis la somme est comparée à un seuil de décision. Si la somme dépasse le seuil, la sortie est 1, sinon elle est 0. Les poids des entrées sont ajustés en fonction des erreurs de classification, en utilisant un algorithme d'apprentissage supervisé basé sur la descente de gradient stochastique.

Le perceptron est limité aux problèmes de classification linéairement séparables, c'est-à-dire que les données doivent pouvoir être séparées par une frontière de décision linéaire. Cependant, il peut être combiné avec d'autres modèles pour résoudre des problèmes plus complexes. Le perceptron multicouche, par exemple, est un modèle de réseau de neurones à plusieurs couches qui utilise des fonctions d'activation non linéaires pour résoudre des problèmes de classification non linéairement séparables.

Le perceptron a été l'un des premiers modèles de réseau de neurones et a jeté les bases de la théorie des réseaux de neurones. Il est encore utilisé aujourd'hui pour des tâches simples de classification binaire [35].

II.9.2. Algorithme du perceptron

Voici l'algorithme de base du perceptron :

- 1) Initialiser les poids w et le biais b à des valeurs aléatoires ou à 0.
- 2) Pour chaque exemple d'entraînement x dans le jeu de données :
 - a. Calculer l'activation pondérée : $z = w \cdot x + b$
 - b. Appliquer la fonction d'activation $f(z)$ pour obtenir la sortie $y_{\text{pred}} : y_{\text{pred}} = f(z)$
 - c. Calculer l'erreur de prédiction : $\text{err} = y - y_{\text{pred}}$
 - d. Mettre à jour les poids : $w = w + \alpha * \text{err} * x$, où α est le taux d'apprentissage
 - e. Mettre à jour le biais : $b = b + \alpha * \text{err}$

Répéter l'étape 2 pour un nombre fixe d'itérations (époques) ou jusqu'à ce que la classification soit correcte pour tous les exemples d'entraînement.

Cet algorithme est un exemple d'apprentissage supervisé car il utilise des exemples d'entraînements étiquetés pour ajuster les poids et le biais du modèle. Il utilise également une fonction d'activation, qui introduit une non-linéarité dans le modèle, lui permettant ainsi de modéliser des relations plus complexes entre les entrées et les sorties [35].

II.9.3. Réseau ADALINE (Adaptive Linear Neuron)

Le réseau ADALINE ressemble au perceptron, mais utilise une fonction d'activation linéaire plutôt qu'une fonction échelon. Cette différence permet aux réseaux ADALINE de réduire les interférences entrantes grâce à l'utilisation de la méthode des moindres carrés. Les réseaux de

neurones ADALINE sont souvent utilisés pour la réduction de bruit en télécommunication. [31].

Le réseau de type ADALINE fait la somme pondéré des entrées qu'il reçoit et ajoute un biais (seuil), et afin d'activer le neurone il utilise une fonction linéaire.

II.10. Le perceptron multicouche (Multilayer perceptron MLP)

II.10.1. Définition

Le multilayer perceptron (MLP) est un type de réseau de neurones artificiels (RNA) largement utilisé dans l'apprentissage automatique (machine learning) pour effectuer des tâches telles que la classification et la régression.

Le MLP est un réseau de neurones qui se compose de plusieurs couches de neurones reliées entre elles. Chaque couche est composée de plusieurs neurones. La première couche est appelée la couche d'entrée, qui reçoit les données en entrée. Les couches intermédiaires sont connues sous le nom de couches cachées, car leurs valeurs ne sont pas directement observées. Enfin, la dernière couche est la couche de sortie, qui génère la sortie finale du réseau.

Le MLP utilise une fonction d'activation non linéaire pour chaque neurone. Les fonctions d'activation les plus couramment utilisées sont la fonction sigmoïde, la fonction ReLU (rectified linear unit), la fonction tanh (tangente hyperbolique), et la fonction softmax (pour la classification).

Le MLP apprend en ajustant les poids des connexions entre les neurones, utilisant des algorithmes d'optimisation tels que la descente de gradient. L'objectif est de minimiser la fonction de coût du réseau, qui évalue la différence entre la sortie du réseau et la sortie attendue pour un exemple spécifique. Le MLP est souvent entraîné sur un ensemble de données d'entraînement et testé sur un ensemble de données de test distinct pour évaluer sa performance.[36]

Le MLP a été introduit dans les années 1980 et est toujours largement utilisé aujourd'hui en raison de sa simplicité, de sa capacité à modéliser des relations non linéaires complexes, et de sa bonne performance sur de nombreuses tâches d'apprentissage automatique.




Figure II.6: Un perceptron multicouche contenant trois couches

II.10.2. Type de multilayer perceptron (MLP)

Il existe plusieurs types de multilayer perceptron (MLP) qui se distinguent principalement par le nombre de couches cachées et le nombre de neurones dans chaque couche. Voici quelques-uns des types de MLP les plus courants :

MLP à une couche cachée : il s'agit du type le plus simple de MLP, avec une seule couche cachée entre la couche d'entrée et la couche de sortie.

MLP à deux couches cachées : ce type de MLP a deux couches cachées intermédiaires entre la couche d'entrée et la couche de sortie. Ce modèle est plus complexe que le MLP à une couche cachée et peut capturer des relations plus complexes entre les entrées et les sorties.

MLP profond : il s'agit d'un type de MLP qui a plus de deux couches cachées. Les réseaux profonds sont utilisés pour résoudre des problèmes très complexes tels que la reconnaissance d'images et la traduction automatique.

MLP à convolution : ce type de MLP utilise des couches de convolution pour extraire des caractéristiques à partir des entrées. Les MLP à convolution sont couramment utilisés dans la reconnaissance d'images et la vision par ordinateur.

MLP récurrent : ce type de MLP est conçu pour traiter des données séquentielles, telles que des séquences de temps ou des séquences de mots. Les MLP récurrents ont des connexions récurrentes qui leur permettent de prendre en compte l'historique des entrées.

Ces différents types de MLP peuvent être combinés et adaptés pour répondre aux besoins spécifiques des différentes tâches d'apprentissage automatique [37].

II.11. Apprentissage du réseau de neurone

II.11.1. Définition de l'apprentissage du réseau de neurone

L'apprentissage est une phase de développement d'un réseau de neurones durant laquelle une modification du comportement du réseau se fait jusqu'à l'obtention d'un comportement désiré. L'apprentissage neuronal fait appel à des exemples de comportement (sortie désirée). Durant cette phase les poids synaptiques seront modifiés, donc d'une manière plus simple, on peut dire que l'apprentissage est une action de mise à jour des poids des connexions dans le but d'atteindre la sortie du réseau pour les exemples présentés en entrée [38].

II.11.2. Stratégie d'apprentissage

En générale, l'apprentissage se réalise sur un intervalle long, pendant laquelle chaque prototype d'entrée (et éventuellement de sortie désirée), est présenté au réseau, plusieurs fois. L'apprentissage se fait en quatre étapes, ces étapes sont répétées jusqu'à la fin de l'apprentissage selon le schéma suivant [39] :

Etape 1 : Initialisation des poids du réseau a des petites valeurs aléatoires.

Etape 2 : Présentation du prototype d'entrée au RNA. Des valeurs de sortie correspondante sont ensuite calculées après propagation d'activation.

Etape 3 : Calcul de l'erreur : ce terme s'emploi plus volontiers pour un apprentissage supervise ou l'erreur tient compte de la différence entre l'activation des neurones de sortie et de la sortie désiré (lie au prototype d'entrée).

Etape 4 : Calcul du vecteur de correction : à partir des valeurs d'erreurs, on détermine alors la correction à apporter aux poids des connexions et au seuils des neurones.

II.11.3. Types d'apprentissage

L'apprentissage est l'étape la plus importante dans le fonctionnement d'un réseau de neurones, c'est un processus dynamique et itératif permettant de modifier les paramètres d'un réseau en réaction avec le stimulus qu'il reçoit de son environnement. Il existe plusieurs types d'apprentissage, nous présentons les deux plus importants et les plus utilisés [40] :

II.11.3.1. L'apprentissage supervisé

Dans ce type, une information précise sur la sortie désirée est disponible. Le réseau apprend par présentation de pair d'entrée / sortie. Durant l'apprentissage, les valeurs de sorties désirées sont comparées à celles produites par le réseau, l'erreur résultante est alors utilisée pour l'ajustement des poids des connexions. La règle du delta en méthode rétropropagation est utilisée telle qu'elle dans les réseaux multicouches que nous détaillerons par la suite [40]. Avec l'apprentissage supervisé, la machine peut apprendre à faire une certaine tâche en étudiant des exemples de cette tâche. Par exemple, elle peut apprendre à reconnaître une photo de chien après qu'on lui ait montré des millions de photos de chiens. Ou bien, elle peut apprendre à traduire le français en chinois après avoir vu des millions d'exemples de traduction français-chinois.

D'une manière générale, la machine peut apprendre une **relation** $f : x \rightarrow y$ qui relie x à y en ayant **analysé** des millions d'exemples d'associations.

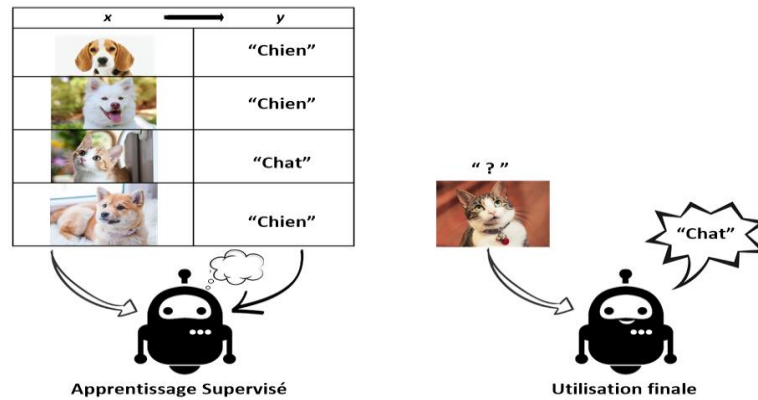


Figure II.7 exemple d'apprentissage supervisé

L'apprentissage supervisé fonctionne en 4 étapes :

- 1_ Importer un Dataset (x, y) qui contient nos exemples.
- 2_ Développer un Modèle aux paramètres aléatoires.
- 3_ Développer une Fonction Coût qui mesure les erreurs entre le modèle et le Dataset.
- 4_ Développer un Algorithme d'apprentissage pour trouver les paramètres du modèle qui minimisent la Fonction Coût.

a) Le Dataset

La première étape d'un algorithme de Supervised Learning consiste donc à importer un Dataset qui contient les exemples que la machine doit étudier.[41]

Ce Dataset inclut toujours 2 types de variables :

- 1) Une variable objective (target) y.
- 2) Une ou plusieurs variables caractéristiques (features) x.

b) Le modèle : le cœur de programme

Le modèle est en quelque sorte le cœur de programme, c'est lui qui va effectuer la tâche que vous cherchez à accomplir, par exemple reconnaître un animal sur une photo ou prédire le prix d'un appartement.

c) La Fonction coût

Mesure de la performance Pour que la machine trouve le meilleur modèle, il faut déjà qu'elle puisse **mesurer la performance** d'un modèle donné [41].

d) L'Algorithme d'apprentissage

Parlons peu, parlons bien. Avoir un bon modèle, c'est avoir un modèle qui de petites erreurs. Logique ?

Ainsi, en Supervised Learning, la machine cherche les **paramètres** de modèle qui **minimisent** la **Fonction Coût**. C'est ça qu'on appelle l'apprentissage. Cette phrase est **très importante**. C'est l'essentiel de ce qu'il faut comprendre en Machine Learning.

Pour trouver les paramètres qui minimisent la fonction Coût, il existe un paquet de stratégies. On pourrait par exemple développer un algorithme qui tente au hasard plusieurs combinaisons de paramètres, et qui retient la combinaison avec la Fonction Coût la plus faible. C'est un peu comme organiser un concours d'archers pour ne garder que le meilleur. Cette stratégie est cependant assez inefficace la plupart du temps. Une autre stratégie, **très populaire** en Machine Learning, est de considérer la Fonction Coût comme une fonction **convexe**, c'est-à-dire une fonction qui n'a qu'un seul minimum, et de chercher ce minimum avec un algorithme de minimisation appelé **Gradient Descente** [41].

II.11.3.2. L'apprentissage non-supervisé

L'apprentissage non supervisé est un type d'apprentissage où le réseau ne dispose d'aucune information sur la sortie désirée. Le réseau cherche à extraire des propriétés à partir des données d'entrée, en fonction de la règle d'apprentissage utilisée. Ce type d'apprentissage permet aux systèmes d'IA de trier des informations non classées en fonction de leurs similitudes et différences, sans catégorie spécifique. Il est souvent associé à des modèles d'apprentissage génératifs et peut être utilisé dans divers domaines tels que les chatbots, les véhicules autonomes, la reconnaissance faciale, les systèmes experts et les robots. Dans l'apprentissage non supervisé, les données ne sont ni étiquetées ni classées, et la sortie dépend des algorithmes programmés.

II.11.3.2.1. Méthode apprentissage non supervisé

Il existe plusieurs approches différentes à l'apprentissage non supervisé, mais les deux méthodes les plus couramment utilisées sont la classification non supervisée et la réduction de dimensionnalité [43].

a) La classification non supervisée

Le clustering, également connu sous le nom de regroupement, implique de rassembler des données ayant des caractéristiques similaires sans connaître les catégories ou les étiquettes préalables. Les algorithmes de clustering les plus populaires comprennent le clustering k-means, le clustering hiérarchique et le clustering de densité.

b) La réduction de dimensionnalité

La réduction de dimensionnalité est une méthode utilisée pour éliminer les variables redondantes ou peu informatives dans le but de réduire la quantité de données. Elle peut

également aider à visualiser les données en les réduisant à deux ou trois dimensions pour faciliter leur compréhension. Les méthodes les plus courantes de réduction de dimensionnalité sont l'analyse en composantes principales (PCA), la factorisation de matrices non négatives (NMF) et la t-SNE.

II.11.3.3. Apprentissage par renforcement

L'apprentissage par renforcement est une méthode d'apprentissage automatique où un agent interagit avec l'environnement pour maximiser une récompense cumulative à long terme. Cette approche est largement utilisée dans divers domaines tels que la robotique, l'automatisation industrielle, les jeux vidéo, la gestion de portefeuille et la reconnaissance de la parole. Le processus d'apprentissage comprend l'observation de l'état de l'environnement, l'action de l'agent en réponse à cet état, et la réception d'une récompense associée à cette action. L'objectif est de trouver une politique d'action optimale pour maximiser la récompense cumulée. Différentes techniques, y compris la programmation dynamique, la méthode de Monte Carlo, la méthode de différence temporelle et l'apprentissage profond par renforcement, sont utilisées pour atteindre cet objectif. L'évaluation des algorithmes se fait à travers des métriques telles que le taux de réussite, le temps d'apprentissage et la stabilité de la politique d'action apprise.

II.12. Conclusion

En conclusion, ce chapitre a fourni une introduction complète et détaillée aux réseaux de neurones artificiels. Nous avons exploré les concepts clés, les principes de fonctionnement et les différents types de réseaux neuronaux, en mettant l'accent sur leur application dans divers domaines de l'apprentissage automatique. De plus, nous avons examiné les techniques d'entraînement, les bases de données utilisées et les aspects importants tels que la répartition des données, la validation croisée et les tests de performance. Grâce à cette compréhension approfondie des réseaux de neurones artificiels, nous serons en mesure de concevoir et d'entraîner des modèles performants pour résoudre une variété de problèmes complexes. Les réseaux de neurones offrent un potentiel énorme pour l'apprentissage automatique et continuent d'être une zone de recherche active et passionnante. En utilisant les connaissances acquises dans ce chapitre, nous serons en mesure de tirer pleinement parti de ces puissants outils pour résoudre des défis réels et contribuer à l'avancement des sciences et des technologies de l'information.

Chapitre III

Modélisation intelligente : Cas d'un moteur

III.1 Introduction

Le troisième chapitre de ce mémoire de fin d'études se concentre sur la modélisation basée sur les réseaux de neurones artificiels (ANN). Plus précisément, nous avons utilisé un ensemble de données sur le comportement d'un moteur fourni par MATLAB [<https://hagan.okstate.edu>] pour effectuer l'ajustement d'une fonction à l'aide d'un réseau neuronal. L'objectif est d'estimer le couple et les émissions d'oxyde nitreux du moteur en fonction de sa consommation de carburant et de sa vitesse. Dans ce chapitre, nous décrirons en détail le processus de modélisation basé sur les ANN, ainsi que les résultats obtenus grâce à l'entraînement du réseau neuronal. Ce chapitre pave la route à la modélisation intelligente d'un cantilever (problème principal) qui sera traité dans le chapitre suivant.

III.2 Modélisation basée sur les réseaux de neurones artificiels (ANN)

La modélisation basée sur les réseaux de neurones artificiels (ANN) est un processus de formation d'un réseau neuronal sur un ensemble de données d'entrée afin de produire des sorties cibles correspondantes. Dans notre étude, nous avons utilisé un ensemble de données sur le comportement du moteur, comprenant des mesures de débit de carburant et de vitesse en tant qu'entrées, et des mesures de couple et d'émissions d'oxyde nitreux en tant que sorties cibles. Notre objectif était de former un réseau neuronal capable d'estimer ces attributs du moteur.

Pour la modélisation, nous avons utilisé une architecture de réseau neuronal composée de 20 neurones dans une couche cachée avec une fonction d'activation de tangente hyperbolique. La couche de sortie contenait deux neurones avec une fonction d'activation linéaire. Nous avons utilisé l'interface de `nstart` de MATLAB pour extraire les courbes de régression, d'histogramme, d'état d'entraînement et d'erreur MSE du modèle.

III.3 Description de la base de données

La base de données utilisée dans cette étude est fournie par MATLAB [<https://hagan.okstate.edu>] et se concentre sur le comportement d'un moteur. Elle est composée de deux matrices : `engineInputs` et `engineTargets`.

La matrice `engineInputs` est une matrice 2×1199 qui définit deux attributs de l'activité du moteur dans différentes conditions. Le premier attribut est le débit de carburant, qui représente la quantité de carburant consommée par le moteur. Le deuxième attribut est la vitesse, qui indique la vitesse à laquelle le moteur fonctionne.

D'autre part, la matrice `engineTargets` est également une matrice 2×1199 qui contient deux attributs à estimer en fonction des entrées. Le premier attribut est le couple du moteur, qui représente la force de rotation exercée par le moteur. Le deuxième attribut est les émissions d'oxyde nitreux, qui indiquent la quantité de ce gaz polluant émis par le moteur.

Ces données sont essentielles pour entraîner le réseau neuronal à estimer avec précision le couple et les émissions d'oxyde nitreux du moteur en fonction de la consommation de carburant et de la vitesse. La taille de l'ensemble de données, avec 1199 échantillons, offre une variété suffisante pour capturer différentes conditions et comportements du moteur.

En utilisant cette base de données, nous avons pu construire et entraîner notre modèle ANN pour établir une relation entre les entrées (débit de carburant et vitesse) et les sorties cibles (couple et émissions d'oxyde nitreux). Cette modélisation basée sur les données réelles nous permet d'obtenir des estimations précises et fiables des performances du moteur dans différentes situations, contribuant ainsi à une meilleure compréhension et optimisation des performances

électromécaniques. Il est important d'indiquer que la base de donnée a été répartie comme suit : 70% pour l'entraînement, 15% pour la validation, et 15% pour le test.




Figure III.1 courbe de performance.

L'erreur quadratique moyenne (MSE) mesure l'écart moyen au carré entre les valeurs prédites et les valeurs réelles. Une faible valeur d'erreur MSE indique une précision élevée du modèle. Le critère d'arrêt de l'entraînement est clairement visible par la ligne discontinue.




Figure III.2: Training state.

Le gradient représente la pente de la fonction de coût par rapport aux poids et aux biais du réseau neuronal. Cette courbe indique comment le gradient évolue au fil des époques pendant l'entraînement. Nous observons une diminution progressive du gradient, ce qui signifie que le modèle se rapproche d'un minimum global de la fonction de coût. Notant que les fluctuations du gradient peuvent indiquer des problèmes de convergence ou de surapprentissage.

Mu, également connu sous le nom de taux d'apprentissage, contrôle la vitesse à laquelle les poids et les biais du réseau neuronal sont ajustés lors de l'apprentissage. Cette courbe indique comment la valeur de μ varie au cours des époques. Une valeur élevée de μ peut entraîner des ajustements brusques des poids, ce qui peut conduire à une instabilité ou un dépassement de l'optimum global. Une valeur faible de μ peut rendre l'apprentissage lent et peut nécessiter plus d'époques pour atteindre une performance satisfaisante. Il est important de trouver un équilibre approprié pour μ afin de garantir une convergence stable et rapide du modèle.

La courbe de val failles représente l'évolution de l'erreur de validation du modèle au cours des époques. Elle mesure l'erreur entre les valeurs prédites par le modèle et les valeurs réelles sur un ensemble de données de validation distinct. Cette courbe est essentielle pour évaluer la capacité du modèle à généraliser et à s'adapter à de nouvelles données. Une diminution régulière de l'erreur de validation indique que le modèle apprend efficacement et est capable de généraliser ses connaissances pour des données inconnues. Cependant, si l'erreur de validation augmente, cela peut indiquer un surapprentissage ou une mauvaise généralisation.




Figure III.3 Errors histogram.

L'histogramme montre la répartition des erreurs de prédiction du modèle. Une distribution centrée autour de zéro et avec une faible dispersion indique une bonne précision de prédiction du modèle.

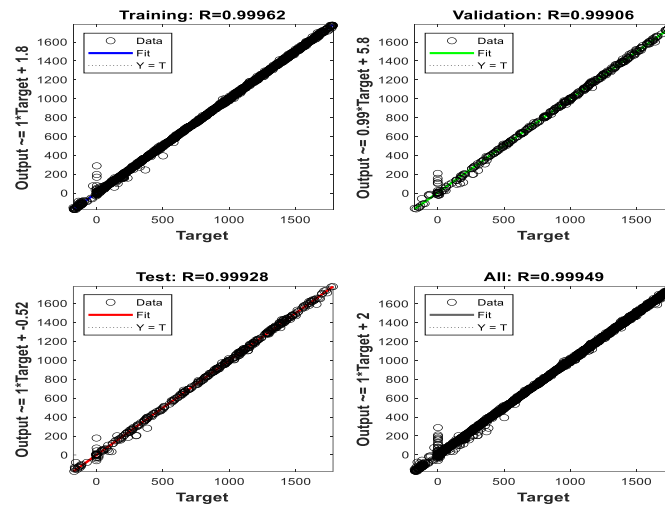


Figure III.4 Courbe de Régression.

Cette courbe représente la relation entre les valeurs prédites et les valeurs réelles du couple et des émissions d'oxyde nitreux du moteur. Une corrélation étroite entre les valeurs prédites et réelles indique une bonne performance du modèle, comme nous pouvons remarquer clairement dans les 4 figures.

III.4 Conclusion

Ce chapitre nous a permis de nous familiariser avec l'application des réseaux de neurones artificiels (ANN) sur des problèmes électromécaniques réels, en utilisant le logiciel MATLAB. Nous avons utilisé un ensemble de données sur le comportement d'un moteur pour former un modèle ANN capable d'estimer le couple et les émissions d'oxyde nitreux en fonction de la consommation de carburant et de la vitesse. Grâce à une architecture ANN bien définie, composée de 20 neurones dans une couche cachée et une couche de sortie avec des fonctions d'activation appropriées, nous avons réussi à obtenir des résultats prometteurs. Les courbes de régression ont montré une corrélation étroite entre les valeurs prédites et réelles, indiquant une bonne performance du modèle. De plus, l'histogramme des erreurs de prédiction a révélé une distribution centrée autour de zéro, confirmant la précision du modèle. L'analyse de l'état d'entraînement a démontré que le modèle convergeait vers une meilleure performance au fil des itérations, tandis que l'erreur MSE a confirmé une faible valeur d'erreur, ce qui témoigne de la précision élevée de notre modèle ANN.

En conclusion, ce chapitre nous a permis d'appliquer avec succès les ANN à un problème électromécanique réel, en utilisant MATLAB comme outil de développement. Ces résultats encourageants ouvrent la voie à l'utilisation des ANN pour résoudre des problèmes similaires dans le domaine de l'électromécanique à savoir le problème principal de notre mémoire (modélisation intelligente d'un cantilever) qui sera traité dans le chapitre suivant.

Chapitre IV

Modélisation intelligente d'un cantilever générateur d'énergie

IV.1 Introduction

Le quatrième chapitre de ce mémoire se concentre sur la modélisation intelligente d'un cantilever générateur d'énergie à l'aide de réseaux de neurones artificiels. Dans ce chapitre, nous exploitons une base de données provenant d'un simulateur numérique avancé utilisant la méthode des éléments finis pour résoudre des équations sophistiquées. Les paramètres d'entrée du modèle comprennent la longueur du cantilever, l'épaisseur du matériau piézoélectrique, l'épaisseur du substrat et la résistance de charge, tandis que la sortie est la tension crête générée par le cantilever.

Cette modélisation intelligente vise à développer un modèle prédictif précis et fiable pour estimer la tension crête générée par un cantilever en fonction de ses paramètres géométriques,

dimensionnels et électriques. Les techniques d'entraînement, de validation et de test des réseaux de neurones artificiels seront utilisées pour développer et évaluer le modèle.

IV.2. La description du problème :

Notre base de données du cantilever est traitée après un mois de prise des résultats du travail effectué via un simulateur numérique tout en extrayant les paramètres suivants :

- La résistance de charge électrique.
- Epaisseur du matériau piézoélectrique.
- Epaisseur du substrat.
- La longueur du cantilever.
- La tension crête de sortie (V)

La fréquence d'accélération égale à la fréquence de réfrigérateur de qui est de 240 Hz et la capacité extrinsèque est fixée à $1\mu\text{F}$. La largeur du cantilever a été fixée à 1 mm.




Figure IV.1 (a) dispositif à modéliser. (b) schéma électrique équivalent.

Dans le cadre de la modélisation intelligente, il a été décidé de maintenir la longueur du cantilever à 15 mm pour établir la base de données. En raison de la taille importante de cette base de données, nécessitant un temps considérable pour sa mise en place, une approche a été adoptée pour extraire une partie de la base en fixant la longueur à 15 mm tout en variant les autres paramètres, tels que l'épaisseur du matériau piézoélectrique, l'épaisseur du substrat et la résistance de charge.

Il convient de noter que la variation de la longueur pourrait également être prise en compte si la base de données était enrichie ultérieurement. Cela permettrait d'explorer l'impact de cette variation sur les performances du cantilever. Toutefois, compte tenu des contraintes de temps et des ressources disponibles, il a été décidé de se concentrer initialement sur les autres

paramètres tout en maintenant une longueur constante de 15 mm. Cette approche permettra néanmoins d'obtenir des résultats significatifs et pertinents pour l'analyse et la modélisation du cantilever.

IV.3. Logiciels

Le MATLAB est un langage de programmation et de simulation de haut niveau créé par Cleve Moler à la fin des années 1970 et développé par la société The MathWorks. Sa première version a été lancée en 1984. MATLAB offre des constructions qui permettent une programmation claire à petite et à grande échelle. Il prend en charge plusieurs paradigmes de programmation, notamment les approches orientées objet, impératives, fonctionnelles et procédurales. L'utilisation d'un ensemble de fonctions prédéfinies appelées boîtes à outils, ainsi que des fonctions et programmes définis par l'utilisateur, est également possible.

La Neural Network Toolbox de MATLAB fournit à l'utilisateur des outils pour la conception, la mise en œuvre, la visualisation et la simulation de réseaux de neurones dans le cadre de diverses applications.



Figure IV.2 logo du matlab

IV.4. Configuration des données

Les paramètres constituant (et ses bornes) de notre base de données sont:

$R = [100 \quad 200 \quad 400 \quad 600 \quad 800 \quad 1000 \quad 1500 \quad 2000 \quad 2500 \quad 3000 \quad 3500 \quad 4000$
 $4500 \quad 5000 \quad 6000 \quad 7000] [\Omega]$.

$ThP = [50 \quad 100 \quad 150 \quad 200 \quad 250 \quad 300] [\mu m]$.

$ThS = [50 \quad 100 \quad 150 \quad 200 \quad 250 \quad 300] [\mu m]$.

$L = 15 [mm]$

Sortie= variables [mV]

IV.4.1 Inputs 1344 × 4 : 4 lignes par 576 colonnes chaque ligne contient 4 attributs qui représentent les valeurs du cantilever : la résistance, la longueur, l'épaisseur du matériau piézoélectrique, La longueur. [Voir annexe].

IV.4.2. Outputs1 x 1344 : 1 ligne par 576 colonnes contiennent la valeur de tension. [Voir annexe].

IV.5 Les ensembles de création d'un modèle par un réseau de neurone :

La création d'un modèle de fitting par réseau de neurone provient généralement de plusieurs ensembles de données. En particulier, trois ensembles sont couramment recommandés, training set, validation set et test set, chaque un de ces ensembles joue un rôle important pour l'obtention d'un modèle de fitting finale, apte à prédire des résultats les plus juste possible, c'est trois ensembles sont décrits comme suit :

IV.5.1 Ensemble d'entraînement : Celui-ci va absorber la grande quantité de données. En effet, c'est sur cette ensemble que le réseau va itérer pour adapter les paramètres des réseaux (poids et biais) et les ajuster au mieux, certaines règles préconisent qu'il soit composé de 80% des données.

IV.5.2 Ensemble de validation : Cette phase est appelée à la fin de chaque itération d'entraînement pour une seule fois, elle est composée de 10% à 15% des données, afin de nous permettre d'équilibrer le modèle. c-a-d affiner les paramètres du modèle, lors de la phase d'ajustement de modèle sur l'ensemble de données d'entraînement

IV.5.3 Ensemble de test : Ce dernier est composé 10% à 15% des données, il a un rôle qui est différent des autres phases, puisqu'il ne servira pas à ajuster les données, En effet, il va avoir pour rôle d'évaluer le réseau sous sa forme finale, et de voir comment il arrive à prédire.

IV.6 Résultats et discussion

Toutes les simulations ont été réalisées grâce au logiciel MATLAB 2019 b, sur un PC de système d'exploitation Windows 10 (64 bits) avec un processeur de type i5-6200 CPU @ 2.30 GHz ayant 4 Go de RAM.

Le Matlab contient des algorithmes d'entraînement et des fonctions d'activation prête à l'utilisation, ce qui à faciliter grandement notre tâche.

Afin d'appliquer notre ajustement neuronal avec succès à notre base de données nous avons en premier lieu optés pour le choix d'un perceptron multicouche possédant quatre entrées, deux couche caché contenant 5 neurones pour chaque et utilise la fonction tangente hyperbolique. Et une couche de sortie.




Figure IV.3 Forme du réseau de neurone utilisé.

Deuxièmement, les données ont été divisées en trois ensembles : le premier utilisé pour la phase d'entraînement (70%), le second pour la phase de validation (15%) et le dernier pour la phase de tests (15%), les paramètres d'entraînement de base du système sont le nombre maximum d'itérations qui est de 4000, et le taux d'apprentissage qui est de 0.001.

IV.6.1 La fonction de rétropropagation de Levenberg–Marquardt (trainlm)

Il s'agit d'une fonction d'entraînement basé sur l'algorithme de quasi newton elle est considérée comme la plus rapide dans les réseaux de taille moyenne, elle localise le minimum d'une fonction multivariée qui peut être exprimée comme la somme des carrés de fonctions réelles non linéaires. C'est une technique itérative qui fonctionne de telle manière que la fonction de performance sera toujours réduite à chaque itération de l'algorithme.

IV.6.2 Entraînement et Simulation




Figure IV.4 Courbe de performance.

En analysant la courbe de performance du modèle ANN entraîné, il a été observé que lors de la première époque, la valeur de l'erreur était élevée. Cependant, au fur et à mesure de

l'augmentation des époques, l'erreur a commencé à diminuer de manière significative, atteignant finalement une valeur de $9.5444e-9$ après 35 époques.

Cette évolution de l'erreur est encourageante et indique une convergence du modèle vers une performance plus précise. Plusieurs observations soutiennent cette interprétation :

1. L'erreur quadratique moyenne finale, qui est une mesure de l'écart entre les prédictions du modèle et les résultats réels, est très faible. Cela suggère que le modèle a réussi à capturer les schémas et les relations sous-jacentes des données, permettant ainsi des prédictions précises.
2. L'erreur sur l'ensemble de test et l'erreur sur l'ensemble de validation présentent des caractéristiques similaires. Cela indique que le modèle généralise correctement et n'est pas simplement adapté aux données d'entraînement spécifiques, ce qui est crucial pour assurer une performance fiable sur de nouvelles données.
3. Aucun sur-ajustement significatif n'a été observé jusqu'à l'époque 35, qui correspond également à la période où les meilleures performances de validation sont atteintes. Cela suggère que le modèle a réussi à éviter le sur-ajustement, c'est-à-dire qu'il ne s'est pas trop adapté aux données d'entraînement au détriment de sa capacité à généraliser.

Ces observations cumulatives confirment la validité du modèle ANN entraîné et soulignent sa capacité à fournir des prédictions précises. L'analyse de la courbe de performance démontre le succès du modèle dans la capture des relations complexes présentes dans les données, et confirme sa robustesse face à de nouvelles observations.




Figure IV.5: Training state.

En analysant les courbes de l'état d'entraînement (training state) comprenant la courbe du gradient, la courbe de mu et la courbe de val fail, plusieurs observations ont été faites :

IV.6.3 Courbe du gradient vs époque

Il a été observé que le gradient diminuait au fur et à mesure de l'évolution des époques. Cette diminution du gradient indique que le modèle ANN s'ajuste progressivement aux données d'entraînement en minimisant l'écart entre les prédictions du modèle et les résultats réels. Une diminution du gradient est généralement souhaitée, car cela signifie que le modèle se rapproche d'une convergence optimale.

IV.6.4 Courbe de mu vs époque

Au cours des cinq premières époques, la valeur de mu a montré une dégradation significative, passant de 10^{-5} à 10^{-10} . Cela suggère que des ajustements importants ont été nécessaires pour régler les paramètres du modèle. Cependant, après cette période initiale, la valeur de mu s'est stabilisée autour de $10e^{-10}$. Cette stabilisation indique que les ajustements ultérieurs n'ont pas été aussi importants, ce qui peut être interprété comme une indication que le modèle s'est rapproché d'une configuration optimale.

IV.6.5 Courbe de val fail vs époque

Pour cette courbe, deux valeurs spécifiques ont été observées, val fail = 1 pour l'époque 5 et val fail = 2 pour l'époque 6. Les autres valeurs de val fail étaient de 0 tout au long de l'évolution des époques jusqu'à la dernière époque, qui est l'époque 35. Ces valeurs de val fail différentes de zéro indiquent que le modèle a rencontré des échecs de validation à ces époques spécifiques. Cependant, le fait que la valeur de val fail revienne à 0 après ces époques suggère que le modèle a réussi à surmonter ces difficultés et à améliorer ses performances pour obtenir des prédictions plus précises.

En résumé, les résultats indiquent que le modèle ANN a montré une convergence progressive vers une configuration optimale. La diminution du gradient et la stabilisation de la valeur de mu témoignent de l'amélioration de la performance du modèle au fil des époques. Bien que des échecs de validation aient été observés à certaines époques, le modèle a réussi à les surmonter et à atteindre des performances globalement précises. Ces observations confirment l'efficacité du processus d'entraînement et la capacité du modèle à ajuster ses paramètres pour obtenir de meilleures prédictions.




Figure IV.6 Histogramme d'erreurs.

L'observation de l'histogramme a révélé que la majorité des erreurs se sont produites dans la plage de valeurs entre -4.2 et 3.47. Cette information fournit une indication importante sur la distribution des erreurs du modèle de fitting.

L'histogramme représente la répartition des erreurs en fonction de leur valeur. Dans ce cas, la concentration des erreurs dans la plage de valeurs entre -4.2 et 3.47 suggère que le modèle a généralement tendance à produire des erreurs relativement faibles. Cela signifie que les prédictions du modèle sont généralement proches des valeurs réelles, avec un écart relativement limité.

La distribution des erreurs peut fournir des informations précieuses sur les performances du modèle et peut être utilisée pour évaluer sa précision. Dans ce cas, l'histogramme indique que le modèle présente de bonnes performances globales, avec la majorité des erreurs se situant dans une plage relativement étroite. Cela peut être considéré comme une indication de la capacité du modèle à capturer les schémas et les relations dans les données, et à fournir des prédictions cohérentes.

Cependant, il est également important de prendre en compte d'autres aspects lors de l'interprétation de l'histogramme, tels que la présence de valeurs aberrantes ou la répartition spécifique des erreurs. Il peut être utile de comparer l'histogramme des erreurs avec d'autres métriques d'évaluation pour obtenir une image plus complète de la performance du modèle.

Dans l'ensemble, l'observation de l'histogramme indique que le modèle a produit des erreurs principalement concentrées dans une plage relativement étroite, ce qui suggère une performance satisfaisante dans la prédiction des valeurs cibles.

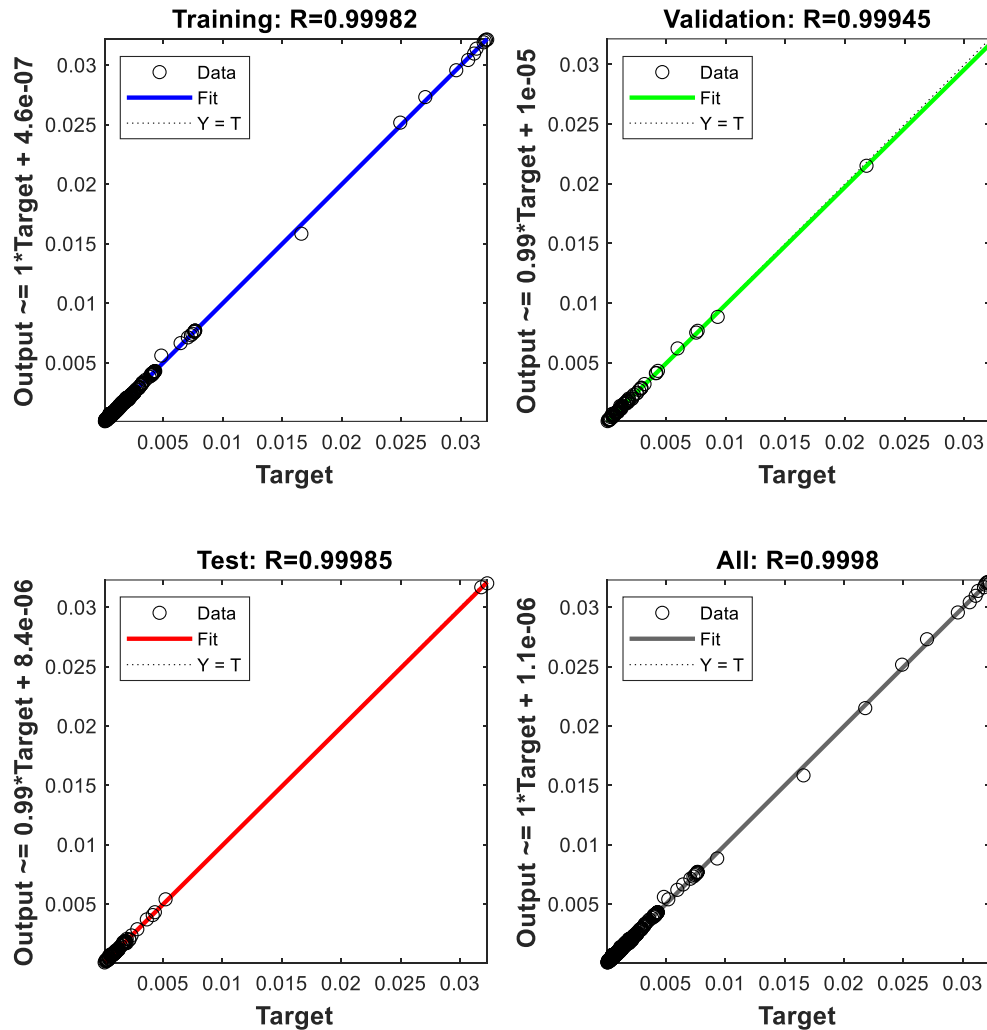


Figure IV.7 Courbe de Régression.

L'observation de la courbe de régression révèle plusieurs éléments significatifs. Tout d'abord, les données sont alignées le long d'une ligne à 45 degrés, ce qui indique un ajustement parfait entre les sorties prédites par le réseau et les réponses réelles. Cela suggère que le modèle de régression est extrêmement précis dans sa capacité à prédire les valeurs cibles.

De plus, il est important de noter que cette correspondance entre les sorties du réseau et les réponses réelles est observée non seulement pour l'ensemble de formation, mais également pour les ensembles de test et de validation. Cela indique que le modèle généralise bien ses prédictions au-delà des données d'entraînement et est capable de fournir des résultats précis sur de nouvelles observations.

La valeur R supérieure à 0,9998 pour l'ensemble de données total renforce ces observations. Le coefficient de corrélation R est une mesure statistique de la relation linéaire entre deux variables, dans ce cas les sorties prédites par le modèle et les réponses réelles. Une valeur proche

de 1 pour R indique une corrélation très forte entre les deux variables, ce qui confirme l'ajustement précis du modèle de régression.

En résumé, les observations de la courbe de régression montrent un ajustement parfait entre les sorties prédites par le modèle de régression et les réponses réelles. La correspondance entre les prédictions du modèle et les valeurs cibles est observée à la fois pour l'ensemble de formation, de test et de validation, ce qui confirme la capacité du modèle à généraliser ses prédictions. La valeur élevée de R pour l'ensemble de données total renforce encore davantage la précision du modèle. Ces observations témoignent de la robustesse et de la performance exceptionnelle du modèle de régression dans la prédiction précise des valeurs cibles.

IV.7 Teste du modèle :

Après l'entraînement de notre modèle, nous avons procédé à des tests pour évaluer sa capacité à fournir les valeurs attendues. Nous lui avons fourni des valeurs qui n'étaient pas présentes dans notre base de données initiale, comme indiqué ci-dessous:

$$R = [80 \ 120 \ 200 \ 300 \ 500 \ 650 \ 700 \ 850 \ 1100 \ 1200 \ 1600 \ 2200 \ 3300 \ 4500] \ \Omega$$

$$\text{ThP} = 120 \ \mu\text{m}$$

$$\text{ThS} = 120 \ \mu\text{m}$$

Nous avons reçu les courbes suivantes :




Figure IV.8 Courbe de tension concernant la résistance. X : R[Ω] Y : V_{OUT} [mV]
Ligne : notre modèle intelligent, cercle : les sorties de simulateur.

La tension de sortie aux bornes du cantilever a augmenté progressivement jusqu'à atteindre une valeur de saturation lorsque la résistance de charge était fixée à 2000. La deuxième figure

présente un pic entre les valeurs de résistance 700 et 1200, ce qui est logique considérant la relation de la puissance $P=U^2/R$.




Figure IV.9 Courbe de puissance. X : R[Ω] Y : P_{OUT} [μW]

En comparant les résultats issus du model avec ceux du simulateur, on peut constater que nous avons obtenu des résultats très proches.

IV.8 Conclusion

En conclusion, ce chapitre a présenté la modélisation intelligente d'un cantilever générateur d'énergie à l'aide de réseaux de neurones artificiels. Nous avons extrait une base de données d'un simulateur numérique avancé, puis nous avons entraîné, validé et testé avec succès notre modèle prédictif.

La modélisation intelligente du cantilever a permis d'obtenir des résultats précis et rapides par rapport aux simulations numériques avancées existantes. Ce modèle représente un outil précieux pour l'optimisation des performances des cantilevers, en tenant compte des contraintes vibratoires et en maximisant la récupération d'énergie mécanique.

Grâce à cette recherche, nous avons avancé dans la compréhension et l'application des réseaux de neurones artificiels dans le domaine de la récupération d'énergie mécanique. Ce travail ouvre la voie à de nouvelles possibilités d'utilisation de l'énergie disponible dans notre environnement, contribuant ainsi à l'avancement des sciences et des technologies de l'information.

Conclusion générale

Ce mémoire de fin d'étude apporte une contribution significative à la recherche sur la récupération d'énergie mécanique à travers l'application des réseaux de neurones artificiels aux cantilevers. En utilisant des modèles numériques intelligents, il est possible de prédire avec précision les performances des cantilevers et d'optimiser leurs paramètres pour des applications spécifiques. Les résultats obtenus démontrent la faisabilité et l'efficacité de cette approche, ouvrant ainsi de nouvelles perspectives de recherche et d'application pratique.

À l'avenir, il serait intéressant d'explorer davantage l'intégration des modèles prédictifs développés dans des environnements réels. En intégrant ces modèles dans des bibliothèques de simulateurs ou des outils de conception assistée par ordinateur, les ingénieurs et les concepteurs pourraient bénéficier d'un moyen rapide et précis d'évaluer les performances des cantilevers dans différentes conditions. De plus, la combinaison de modèles bio-inspirés avec les modèles prédictifs basés sur les ANN pourrait ouvrir de nouvelles voies pour l'optimisation des performances et la découverte de paramètres optimaux pour des cantilevers plus performants.

En conclusion, ce mémoire de fin d'étude offre une contribution pertinente et innovante à la recherche sur la récupération d'énergie mécanique à travers l'utilisation des réseaux de neurones artificiels. Les résultats obtenus démontrent le potentiel des modèles prédictifs basés sur les ANN pour optimiser les cantilevers et améliorer leur efficacité énergétique. Ces avancées ouvrent la voie à de nouvelles possibilités d'utilisation de l'énergie mécanique disponible dans notre environnement et contribuent à l'avancement des sciences et des technologies de l'information.

Il est important de noter que ce projet de fin d'études est susceptible de produire des résultats significatifs qui pourraient être présentés lors d'une future conférence nationale ou internationale. Les avancées et les découvertes réalisées dans le cadre de cette recherche pourraient ainsi être partagées avec la communauté scientifique, contribuant ainsi à l'échange d'idées et à la diffusion des connaissances dans le domaine de la récupération d'énergie mécanique et de l'application des réseaux de neurones artificiels aux cantilevers. La présentation de ces résultats lors d'une conférence future démontrerait la pertinence et l'impact de ce projet de recherche, ouvrant la voie à d'éventuelles collaborations et discussions avec d'autres chercheurs et experts dans le domaine.

Références

- [1] https://www.scipedia.com/public/Bhatnagar_Owende_2015a
- [2] Kim, Miso, "Materials and device design for MEMS piezoelectric mechanical vibration energy harvesters", Thesis: Ph. D., Massachusetts Institute of Technology, Department of Materials Science and Engineering, 2012
- [3] <https://www.eia.gov/energyexplained/solar/photovoltaics-and-electricity.php>
- [4] https://en.wikipedia.org/wiki/Thermoelectric_generator
- [5] S.-G. Kim, S. Priya, et I. Kanno, « Piezoelectric MEMS for energy harvesting », MRS Bull., vol. 37, no 11, p. 1039–1050, 2012.
- [6] <https://www.newcivilengineer.com/archive/smart-infrastructure-vibration-energy-08-07-2016/>
- [7] M. Landau, L. D. Lifshitz, and E. M. Lifshitz, Theory of Elasticity (Pergamon Press, 1986).
- [8] R. E. Newnham, Properties of Materials: Anisotropy, Symmetry, Structure (Oxford University Press, 2005).
- [9] G. W. Rehfild, "Piezoelectric Transducers," in Handbook of Modern Sensors: Physics, Designs, and Applications, (Springer, 2010), pp. 125-149.
- [10] Jean- Philippe Manceau. Étude de phénomène de relaxation diélectrique dans les Capacités Métal-Isolant-Métal. Micro et nanotechnologie/Microélectronique. Université Joseph-Fourier-Grenoble I, (2008).
- [11] "Piezoelectricity: Evolution and Future of a Technology" by Agnieszka Gajewicz-Jaromin and Roman Jaromin (2018)
- [12] "Piezoelectric Transducers and Applications" edited by A. G. Ruzzante and A. Ceruti (2012)
- [13] M. Fujimura, "Lithium Niobate: Summary of Physical Properties and Crystal Structure", Applied Physics A, Vol. 31, pp. 1-11, 1983.
- [14] J. Webjörn, "Nonlinear Optics in Lithium Niobate", Journal of Nonlinear Optical Physics & Materials, Vol. 22, pp. 1330003-1-1330003-27, 2013.
- [15] Albrecht, T. R., Grütter, P., Horne, D., & Rugar, D. (1991). Frequency modulation detection using high-Q cantilevers for enhanced force microscope sensitivity. Journal of Applied Physics, 69(2), 668–673. Doit: 10.1063/1.347347.
- [16] J. R. Sandercock and R. G. Egdell, "Electromechanical Cantilevers: An Introduction to Theory and Applications," Springer Science & Business Media, 2012.
- [17] J. Kymissis, C. Kendall, J. Paradiso, and N. Gershenfeld Parasitic Power Harvesting in Shoes Proceedings of the 2nd IEEE International Symposium on Wearable Computers October 19-20, Pittsburg, PA, 132-139, 1998.
- [18] D. Sarid, "Scanning Force Microscopy with Applications to Electric, Magnetic, and Atomic Forces," Oxford University Press, 1994.
- [19] <https://hal.science/tel-03216575/document>
- [20] Sodano, H. A., Inman, D. J. et Park, G. (2004). A review of power harvesting from vibration using piezoelectric materials. Shock and Vibration Digest, 36(3), 197-205. <https://doi.org/10.1177/0583102404043094>
- [21] Halim, M. A., Alghamdi, A., Almutairi, M. et Zu, J. (2020). Design and analysis of a cantilever piezoelectric energy harvester for low frequency vibrations (Conception et analyse d'un capteur d'énergie piézoélectrique en porte-à-faux pour les vibrations à basse fréquence). Journal of Physics: Conference Series, 1606(1), 012029. <https://doi.org/10.1088/1742-6596/1606/1/012029>
- [22] Kim, H. J., Hong, S. A., Kim, Y. H., & Choi, H. R. (2021). A piezoelectric cantilever energy harvester with an asymmetric resonator for broadband energy harvesting. Sensors and Actuators A: Physical, 324, 112607. <https://doi.org/10.1016/j.sna.2020.112607>

- [23] ARMAN H, SANG-GOOK K. Ultra-wide bandwidth piezoelectric energy harvesting. Applied Physics Letters, Vol.99, no.8,2011, pp. 083105 -0831008.
- [24] Created in COMSOL Multiphysics 6.1
- [25] <https://www.comsol.com/blogs/optimizing-the-power-of-a-piezoelectric-energy-harvester/>
- [26] <https://www.hbm.com/fr/7318/comment-fonctionne-un-capteur-de-force-piezoelectrique/>
- [27] https://www.researchgate.net/figure/Les-32-classes-cristallines_fig1_37813444
- [28] Fabien Tschirhart, « RESEAUX DE NEURONES FORMELS APPLIQUES A L'INTELLIGENCE ARTIFICIELLE ET AU JEU », mémoire de recherche, sous la direction de M. Alain Lioret, ECOLE SUPERIEURE DE GENIE INFORMATIQUE, paris, 2009, p.10
- [29] Kandel, E. R., Schwartz, J. H., Jessell, T. M., Siegelbaum, S. A., & Hudspeth, A. J. (2013). Principles of neural science (5th ed.). New York: McGraw-Hill.
- [30] https://fr.wikipedia.org/wiki/Neurone_formel (visité au 10/04/2020)
- [31] Adrien Verger (2009), Réseaux de neurones artificiels
- [32] Chollet, F. (2018). Deep learning with Python. Manning Publications.
- [33] Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep learning. MIT press.
- [34] Haykin, S. (1994). Neural Networks: A Comprehensive Foundation. Prentice Hall.
- [35] Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. Psychological Review, 65(6), 386-408.
- [36] "Multilayer feedforward networks are universal approximators" de Kurt Hornik, Maxwell Stinchcombe et Halbert White (article scientifique)
- [37] "Deep Learning with Python" de François Chollet
- [38] G. Dreyfus, Les Réseaux de Neurones, Mécanique Industrielle et Matériaux, No.51, septembre 1998.
- [39] "Recurrent Neural Networks for Language Understanding" de Richard Socher
- [40] "Convolutional Neural Networks for Visual Recognition" de Fei-Fei Li, Justin Johnson et Serena Yeung
- [41] "Deep Learning with Python" de François Chollet
- [42] Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning: Data Mining, Inference, and Prediction. Springer.
- [43] Bishop, C. M. (2006). Pattern Recognition and Machine Learning. Springer.
- [44] Sutton, R. S., & Barto, A. G. (2018). Reinforcement Learning: An Introduction. MIT Press.

تركز هذه الرسالة على تطبيق الشبكات العصبية الاصطناعية (ANN) لتطوير نموذج رقمي لتحسين الكونتيفر ، وهي أجهزة حصاد الطاقة الكهروميكانيكية. تمتد الدراسة على أربعة فصول ، وتتعمق في تقنيات حصاد الطاقة الميكانيكية التي تركز على الاهتزازات ، وتكشف المفاهيم الرئيسية للشبكات العصبية الاصطناعية ، وتجري النمذجة الذكية باستخدام ANN ، وتطور نموذجًا تنبؤيًا للنوازل المولدة للطاقة. تظهر النتائج دقة النموذج المطور ، وتنفيذه الأسرع مقارنة بالمحاكاة العددية المتقدمة ، وإمكانية تكامله في مكتبات المحاكاة. يساهم هذا المشروع في تقدم تقنيات المعلومات من خلال تسخير الطاقة الميكانيكية المتاحة وتقديم آفاق واعدة لتحسين أداء الكونتيفر.

الكلمات الأساسية: الكابولي ، الشبكات العصبية الاصطناعية (ANN) ، حصاد الطاقة الميكانيكية ، النمذجة التنبؤية ، الأجهزة الكهروميكانيكية ، تحسين الطاقة ، الاهتزازات ، مكتبات المحاكاة.

Abstract

This dissertation focuses on the application of artificial neural networks (ANN) for the development of a numerical model to optimize cantilevers, which are electromechanical energy harvesting devices. Spanning four chapters, the study delves into mechanical energy harvesting technologies centered on vibrations, explores key concepts of artificial neural networks, conducts intelligent modeling using ANN, and develops a predictive model for energy-generating cantilevers. The results demonstrate the accuracy of the developed model, its faster execution compared to advanced numerical simulators, and its potential for integration into simulation libraries. This project contributes to the advancement of science and information technologies by harnessing available mechanical energy and offering promising prospects for optimizing cantilever performance.

Key words: Cantilevers, Artificial Neural Networks (ANN), Mechanical energy harvesting, Predictive modeling, Electromechanical devices, Energy optimization, Vibrations, Simulation libraries.

Résumé

Ce mémoire de fin d'étude se concentre sur l'application des réseaux de neurones artificiels (RNA) pour le développement d'un modèle numérique visant à optimiser les cantilevers, des dispositifs électromécaniques de récupération d'énergie. À travers quatre chapitres, l'étude aborde les technologies de récupération d'énergie mécanique axées sur les vibrations, explore les concepts clés des réseaux de neurones artificiels, effectue une modélisation intelligente via les RNA, et développe un modèle prédictif pour les cantilevers générateurs d'énergie. Les résultats obtenus démontrent la précision du modèle développé, sa rapidité d'exécution par rapport aux simulateurs numériques avancés, et son potentiel d'intégration dans des bibliothèques de simulateurs. Ce projet contribue à l'avancement des sciences et des technologies de l'information en exploitant l'énergie mécanique disponible et en offrant des perspectives prometteuses pour l'optimisation des performances des cantilevers.

Mots clés : Cantilevers, Réseaux de Neurones Artificiels (RNA), Récupération d'énergie mécanique, Modélisation prédictive, Dispositifs électromécaniques, Optimisation énergétique, Vibrations, Bibliothèques de simulation.

Annexe

Les entrées

100 50 50 15 ;	1000 250 50 15 ;	3500 150 100 15 ;	7000 50 150 15 ;	800 300 150 15 ;
200 50 50 15 ;	1500 250 50 15 ;	4000 150 100 15 ;	100 100 150 15 ;	1000 300 150 15 ;
400 50 50 15 ;	2000 250 50 15 ;	4500 150 100 15 ;	200 100 150 15 ;	1500 300 150 15 ;
600 50 50 15 ;	2500 250 50 15 ;	5000 150 100 15 ;	400 100 150 15 ;	2000 300 150 15 ;
800 50 50 15 ;	3000 250 50 15 ;	6000 150 100 15 ;	600 100 150 15 ;	2500 300 150 15 ;
1000 50 50 15 ;	3500 250 50 15 ;	7000 150 100 15 ;	800 100 150 15 ;	3000 300 150 15 ;
1500 50 50 15 ;	4000 250 50 15 ;	100 200 100 15 ;	1000 100 150 15 ;	3500 300 150 15 ;
2000 50 50 15 ;	4500 250 50 15 ;	200 200 100 15 ;	1500 100 150 15 ;	4000 300 150 15 ;
2500 50 50 15 ;	5000 250 50 15 ;	400 200 100 15 ;	2000 100 150 15 ;	4500 300 150 15 ;
3000 50 50 15 ;	6000 250 50 15 ;	600 200 100 15 ;	2500 100 150 15 ;	5000 300 150 15 ;
3500 50 50 15 ;	7000 250 50 15 ;	800 200 100 15 ;	3000 100 150 15 ;	6000 300 150 15 ;
4000 50 50 15 ;	100 300 50 15 ;	1000 200 100 15 ;	3500 100 150 15 ;	7000 300 150 15 ;
4500 50 50 15 ;	200 300 50 15 ;	1500 200 100 15 ;	4000 100 150 15 ;	1000 50 200 15 ;
5000 50 50 15 ;	400 300 50 15 ;	2000 200 100 15 ;	4500 100 150 15 ;	200 50 200 15 ;
6000 50 50 15 ;	600 300 50 15 ;	2500 200 100 15 ;	5000 100 150 15 ;	400 50 200 15 ;
7000 50 50 15 ;	800 300 50 15 ;	3000 200 100 15 ;	6000 100 150 15 ;	600 50 200 15 ;
100 100 50 15 ;	1000 300 50 15 ;	3500 200 100 15 ;	7000 100 150 15 ;	800 50 200 15 ;
200 100 50 15 ;	1500 300 50 15 ;	4000 200 100 15 ;	100 150 150 15 ;	1000 50 200 15 ;
400 100 50 15 ;	2000 300 50 15 ;	4500 200 100 15 ;	200 150 150 15 ;	1500 50 200 15 ;
600 100 50 15 ;	2500 300 50 15 ;	5000 200 100 15 ;	400 150 150 15 ;	2000 50 200 15 ;
800 100 50 15 ;	3000 300 50 15 ;	6000 200 100 15 ;	600 150 150 15 ;	2500 50 200 15 ;
1000 100 50 15 ;	3500 300 50 15 ;	7000 200 100 15 ;	800 150 150 15 ;	3000 50 200 15 ;
1500 100 50 15 ;	4000 300 50 15 ;	100 250 100 15 ;	1000 150 150 15 ;	3500 50 200 15 ;
2000 100 50 15 ;	4500 300 50 15 ;	200 250 100 15 ;	1500 150 150 15 ;	4000 50 200 15 ;
2500 100 50 15 ;	5000 300 50 15 ;	400 250 100 15 ;	2000 150 150 15 ;	4500 50 200 15 ;
3000 100 50 15 ;	6000 300 50 15 ;	600 250 100 15 ;	2500 150 150 15 ;	5000 50 200 15 ;
3500 100 50 15 ;	7000 300 50 15 ;	800 250 100 15 ;	3000 150 150 15 ;	6000 50 200 15 ;
4000 100 50 15 ;	100 50 100 15 ;	1000 250 100 15 ;	3500 150 150 15 ;	7000 50 200 15 ;
4500 100 50 15 ;	200 50 100 15 ;	1500 250 100 15 ;	4000 150 150 15 ;	100 100 200 15 ;
5000 100 50 15 ;	400 50 100 15 ;	2000 250 100 15 ;	4500 150 150 15 ;	200 100 200 15 ;
6000 100 50 15 ;	600 50 100 15 ;	2500 250 100 15 ;	5000 150 150 15 ;	400 100 200 15 ;
7000 100 50 15 ;	800 50 100 15 ;	3000 250 100 15 ;	6000 150 150 15 ;	600 100 200 15 ;
100 150 50 15 ;	1000 50 100 15 ;	3500 250 100 15 ;	7000 150 150 15 ;	800 100 200 15 ;
200 150 50 15 ;	1500 50 100 15 ;	4000 250 100 15 ;	100 200 150 15 ;	1000 100 200 15 ;
400 150 50 15 ;	2000 50 100 15 ;	4500 250 100 15 ;	200 200 150 15 ;	1500 100 200 15 ;
600 150 50 15 ;	2500 50 100 15 ;	5000 250 100 15 ;	400 200 150 15 ;	2000 100 200 15 ;
800 150 50 15 ;	3000 50 100 15 ;	6000 250 100 15 ;	600 200 150 15 ;	2500 100 200 15 ;
1000 150 50 15 ;	3500 50 100 15 ;	7000 250 100 15 ;	800 200 150 15 ;	3000 100 200 15 ;
1500 150 50 15 ;	4000 50 100 15 ;	100 300 100 15 ;	1000 200 150 15 ;	3500 100 200 15 ;
2000 150 50 15 ;	4500 50 100 15 ;	200 300 100 15 ;	1500 200 150 15 ;	4000 100 200 15 ;
2500 150 50 15 ;	5000 50 100 15 ;	400 300 100 15 ;	2000 200 150 15 ;	4500 100 200 15 ;
3000 150 50 15 ;	6000 50 100 15 ;	600 300 100 15 ;	2500 200 150 15 ;	5000 100 200 15 ;
3500 150 50 15 ;	7000 50 100 15 ;	800 300 100 15 ;	3000 200 150 15 ;	6000 100 200 15 ;
4000 150 50 15 ;	100 100 100 15 ;	1000 300 100 15 ;	3500 200 150 15 ;	7000 100 200 15 ;
4500 150 50 15 ;	200 100 100 15 ;	1500 300 100 15 ;	4000 200 150 15 ;	100 150 200 15 ;
5000 150 50 15 ;	400 100 100 15 ;	2000 300 100 15 ;	4500 200 150 15 ;	200 150 200 15 ;
6000 150 50 15 ;	600 100 100 15 ;	2500 300 100 15 ;	5000 200 150 15 ;	400 150 200 15 ;
7000 150 50 15 ;	800 100 100 15 ;	3000 300 100 15 ;	6000 200 150 15 ;	600 150 200 15 ;
100 200 50 15 ;	1000 100 100 15 ;	3500 300 100 15 ;	7000 200 150 15 ;	800 150 200 15 ;
200 200 50 15 ;	1500 100 100 15 ;	4000 300 100 15 ;	100 250 150 15 ;	1000 150 200 15 ;
400 200 50 15 ;	2000 100 100 15 ;	4500 300 100 15 ;	200 250 150 15 ;	1500 150 200 15 ;
600 200 50 15 ;	2500 100 100 15 ;	5000 300 100 15 ;	400 250 150 15 ;	2000 150 200 15 ;
800 200 50 15 ;	3000 100 100 15 ;	6000 300 100 15 ;	600 250 150 15 ;	2500 150 200 15 ;
1000 200 50 15 ;	3500 100 100 15 ;	7000 300 100 15 ;	800 250 150 15 ;	3000 150 200 15 ;
1500 200 50 15 ;	4000 100 100 15 ;	100 50 150 15 ;	1000 250 150 15 ;	3500 150 200 15 ;
2000 200 50 15 ;	4500 100 100 15 ;	200 50 150 15 ;	1500 250 150 15 ;	4000 150 200 15 ;
2500 200 50 15 ;	5000 100 100 15 ;	400 50 150 15 ;	2000 250 150 15 ;	4500 150 200 15 ;
3000 200 50 15 ;	6000 100 100 15 ;	600 50 150 15 ;	2500 250 150 15 ;	5000 150 200 15 ;
3500 200 50 15 ;	7000 100 100 15 ;	800 50 150 15 ;	3000 250 150 15 ;	6000 150 200 15 ;
4000 200 50 15 ;	100 150 100 15 ;	1000 50 150 15 ;	3500 250 150 15 ;	7000 150 200 15 ;
4500 200 50 15 ;	200 150 100 15 ;	1500 50 150 15 ;	4000 250 150 15 ;	100 200 200 15 ;
5000 200 50 15 ;	400 150 100 15 ;	2000 50 150 15 ;	4500 250 150 15 ;	200 200 200 15 ;
6000 200 50 15 ;	600 150 100 15 ;	2500 50 150 15 ;	5000 250 150 15 ;	400 200 200 15 ;
7000 200 50 15 ;	800 150 100 15 ;	3000 50 150 15 ;	6000 250 150 15 ;	600 200 200 15 ;
100 250 50 15 ;	1000 150 100 15 ;	3500 50 150 15 ;	7000 250 150 15 ;	800 200 200 15 ;
200 250 50 15 ;	1500 150 100 15 ;	4000 50 150 15 ;	100 300 150 15 ;	1000 200 200 15 ;
400 250 50 15 ;	2000 150 100 15 ;	4500 50 150 15 ;	200 300 150 15 ;	1500 200 200 15 ;
600 250 50 15 ;	2500 150 100 15 ;	5000 50 150 15 ;	400 300 150 15 ;	2000 200 200 15 ;
800 250 50 15 ;	3000 150 100 15 ;	6000 50 150 15 ;	600 300 150 15 ;	2500 200 200 15 ;

3000 200 200 15 ;	6000 100 250 15 ;	600 50 300 15 ;	2500 250 300 15 ;
3500 200 200 15 ;	7000 100 250 15 ;	800 50 300 15 ;	3000 250 300 15 ;
4000 200 200 15 ;	100 150 250 15 ;	1000 50 300 15 ;	3500 250 300 15 ;
4500 200 200 15 ;	200 150 250 15 ;	1500 50 300 15 ;	4000 250 300 15 ;
5000 200 200 15 ;	400 150 250 15 ;	2000 50 300 15 ;	4500 250 300 15 ;
6000 200 200 15 ;	600 150 250 15 ;	2500 50 300 15 ;	5000 250 300 15 ;
7000 200 200 15 ;	800 150 250 15 ;	3000 50 300 15 ;	6000 250 300 15 ;
100 250 200 15 ;	1000 150 250 15 ;	3500 50 300 15 ;	7000 250 300 15 ;
200 250 200 15 ;	1500 150 250 15 ;	4000 50 300 15 ;	100 300 300 15 ;
400 250 200 15 ;	2000 150 250 15 ;	4500 50 300 15 ;	200 300 300 15 ;
600 250 200 15 ;	2500 150 250 15 ;	5000 50 300 15 ;	400 300 300 15 ;
800 250 200 15 ;	3000 150 250 15 ;	6000 50 300 15 ;	600 300 300 15 ;
1000 250 200 15 ;	3500 150 250 15 ;	7000 50 300 15 ;	800 300 300 15 ;
1500 250 200 15 ;	4000 150 250 15 ;	100 100 300 15 ;	1000 300 300 15 ;
2000 250 200 15 ;	4500 150 250 15 ;	200 100 300 15 ;	1500 300 300 15 ;
2500 250 200 15 ;	5000 150 250 15 ;	400 100 300 15 ;	2000 300 300 15 ;
3000 250 200 15 ;	6000 150 250 15 ;	600 100 300 15 ;	2500 300 300 15 ;
3500 250 200 15 ;	7000 150 250 15 ;	800 100 300 15 ;	3000 300 300 15 ;
4000 250 200 15 ;	100 200 250 15 ;	1000 100 300 15 ;	3500 300 300 15 ;
4500 250 200 15 ;	200 200 250 15 ;	1500 100 300 15 ;	4000 300 300 15 ;
5000 250 200 15 ;	400 200 250 15 ;	2000 100 300 15 ;	4500 300 300 15 ;
6000 250 200 15 ;	600 200 250 15 ;	2500 100 300 15 ;	5000 300 300 15 ;
7000 250 200 15 ;	800 200 250 15 ;	3000 100 300 15 ;	6000 300 300 15 ;
100 300 200 15 ;	1000 200 250 15 ;	3500 100 300 15 ;	7000 300 300 15 ;
200 300 200 15 ;	1500 200 250 15 ;	4000 100 300 15 ;	
400 300 200 15 ;	2000 200 250 15 ;	4500 100 300 15 ;	
600 300 200 15 ;	2500 200 250 15 ;	5000 100 300 15 ;	
800 300 200 15 ;	3000 200 250 15 ;	6000 100 300 15 ;	
1000 300 200 15 ;	3500 200 250 15 ;	7000 100 300 15 ;	
1500 300 200 15 ;	4000 200 250 15 ;	100 150 300 15 ;	
2000 300 200 15 ;	4500 200 250 15 ;	200 150 300 15 ;	
2500 300 200 15 ;	5000 200 250 15 ;	400 150 300 15 ;	
3000 300 200 15 ;	6000 200 250 15 ;	600 150 300 15 ;	
3500 300 200 15 ;	7000 200 250 15 ;	800 150 300 15 ;	
4000 300 200 15 ;	100 250 250 15 ;	1000 150 300 15 ;	
4500 300 200 15 ;	200 250 250 15 ;	1500 150 300 15 ;	
5000 300 200 15 ;	400 250 250 15 ;	2000 150 300 15 ;	
6000 300 200 15 ;	600 250 250 15 ;	2500 150 300 15 ;	
7000 300 200 15 ;	800 250 250 15 ;	3000 150 300 15 ;	
100 50 250 15 ;	1000 250 250 15 ;	3500 150 300 15 ;	
200 50 250 15 ;	1500 250 250 15 ;	4000 150 300 15 ;	
400 50 250 15 ;	2000 250 250 15 ;	4500 150 300 15 ;	
600 50 250 15 ;	2500 250 250 15 ;	5000 150 300 15 ;	
800 50 250 15 ;	3000 250 250 15 ;	6000 150 300 15 ;	
1000 50 250 15 ;	3500 250 250 15 ;	7000 150 300 15 ;	
1500 50 250 15 ;	4000 250 250 15 ;	100 200 300 15 ;	
2000 50 250 15 ;	4500 250 250 15 ;	200 200 300 15 ;	
2500 50 250 15 ;	5000 250 250 15 ;	400 200 300 15 ;	
3000 50 250 15 ;	6000 250 250 15 ;	600 200 300 15 ;	
3500 50 250 15 ;	7000 250 250 15 ;	800 200 300 15 ;	
4000 50 250 15 ;	100 300 250 15 ;	1000 200 300 15 ;	
4500 50 250 15 ;	200 300 250 15 ;	1500 200 300 15 ;	
5000 50 250 15 ;	400 300 250 15 ;	2000 200 300 15 ;	
6000 50 250 15 ;	600 300 250 15 ;	2500 200 300 15 ;	
7000 50 250 15 ;	800 300 250 15 ;	3000 200 300 15 ;	
100 100 250 15 ;	1000 300 250 15 ;	3500 200 300 15 ;	
200 100 250 15 ;	1500 300 250 15 ;	4000 200 300 15 ;	
400 100 250 15 ;	2000 300 250 15 ;	4500 200 300 15 ;	
600 100 250 15 ;	2500 300 250 15 ;	5000 200 300 15 ;	
800 100 250 15 ;	3000 300 250 15 ;	6000 200 300 15 ;	
1000 100 250 15 ;	3500 300 250 15 ;	7000 200 300 15 ;	
1500 100 250 15 ;	4000 300 250 15 ;	100 250 300 15 ;	
2000 100 250 15 ;	4500 300 250 15 ;	200 250 300 15 ;	
2500 100 250 15 ;	5000 300 250 15 ;	400 250 300 15 ;	
3000 100 250 15 ;	6000 300 250 15 ;	600 250 300 15 ;	
3500 100 250 15 ;	7000 300 250 15 ;	800 250 300 15 ;	
4000 100 250 15 ;	100 50 300 15 ;	1000 250 300 15 ;	
4500 100 250 15 ;	200 50 300 15 ;	1500 250 300 15 ;	
5000 100 250 15 ;	400 50 300 15 ;	2000 250 300 15 ;	

Les sorties

0.000653	0.000434	0.00124	0.00262	0.00231
0.00126	0.000476	0.00125	0.000267	0.00250
0.002248	0.000494	0.001252	0.000516	0.00274
0.00292	0.000502	0.001255	0.000926	0.00284
0.00335	0.000508	0.00126	0.00120	0.0029
0.00363	0.000511	0.001263	0.00138	0.00293
0.00396	0.000513	0.000137	0.00149	0.00294
0.00413	0.000514	0.000266	0.00163	0.00295
0.00420	0.000515	0.000476	0.00169	0.00296
0.00422	0.000517	0.000618	0.00172	0.00297
0.00426	0.000518	0.000710	0.00174	0.00298
0.00428	0.00116	0.000767	0.00175	0.00299
0.0043	0.00225	0.000843	0.00176	0.000329
0.00431	0.00402	0.000874	0.00177	0.000637
0.00432	0.00521	0.000891	0.001766	0.0011375
0.00433	0.00597	0.000899	0.00177	0.00147
0.000269	0.00646	0.000903	0.00178	0.00169
0.000523	0.00707	0.000908	0.000193	0.00193
0.000933	0.00733	0.000911	0.000376	0.00201
0.00121	0.00745	0.000913	0.000671	0.00209
0.00139	0.00753	0.000916	0.000872	0.00212
0.0015	0.00760	0.000917	0.00100	0.00214
0.00165	0.00763	0.000105	0.00108	0.00216
0.00171	0.00765	0.000204	0.00118	0.002167
0.00174	0.00766	0.000364	0.00123	0.002173
0.00176	0.00768	0.000473	0.00125	0.00218
0.00177	0.00768	0.000543	0.00127	0.00218
0.001777	0.000490	0.000588	0.001277	0.00219
0.00178	0.000947	0.000645	0.001281	0.000244
0.001789	0.00169	0.000669	0.001285	0.000475
0.00179	0.00219	0.000682	0.001288	0.00085
0.001799	0.00252	0.000688	0.001286	0.00110
0.000158	0.00272	0.000693	0.00129	0.00126
0.000306	0.00298	0.000695	0.000148	0.00136
0.000548	0.00310	0.000697	0.000286	0.00150
0.000711	0.00314	0.000698	0.000512	0.00155
0.000815	0.00318	0.000701	0.000666	0.00158
0.000884	0.00320	0.000702	0.000762	0.00160
0.000970	0.00321	0.000633	0.000827	0.00160
0.0010	0.00323	0.001224	0.000908	0.00162
0.00102	0.003237	0.00218	0.000941	0.001625
0.00103	0.00324	0.00283	0.000959	0.001627
0.00104	0.00325	0.00324	0.000968	0.00163
0.001046	0.000283	0.00351	0.000975	0.001634
0.001049	0.000549	0.00385	0.000979	0.000188
0.00105	0.000981	0.00399	0.000980	0.000365
0.001052	0.00127	0.00405	0.000983	0.000654
0.001054	0.00146	0.00411	0.000985	0.000848
0.000106	0.00158	0.00413	0.000986	0.000974
0.000206	0.00173	0.00415	0.000116	0.00105
0.000369	0.00179	0.00415	0.000227	0.00115
0.000480	0.00183	0.00417	0.000406	0.00120
0.000549	0.00185	0.00418	0.000527	0.00122
0.000596	0.00186	0.00419	0.000605	0.00123
0.000652	0.001868	0.000395	0.000655	0.00124
0.000676	0.001871	0.000757	0.000719	0.001246
0.000690	0.00187	0.00136	0.000746	0.00125
0.000697	0.00188	0.00177	0.000760	0.001253
0.000702	0.001887	0.00203	0.000766	0.001257
0.000705	0.000189	0.00220	0.000772	0.001259
0.000707	0.000367	0.00241	0.000775	0.000149
0.000707	0.000654	0.00250	0.000777	0.000290
0.000710	0.000852	0.00254	0.000779	0.000519
0.000711	0.000977	0.00257	0.000780	0.000670
7.77e-5	0.00105	0.00259	0.000782	0.000773
0.000150	0.00116	0.00260	0.000437	0.000835
0.000269	0.00120	0.00260	0.000874	0.000918
0.000349	0.00122	0.00261	0.00156	0.000952
0.000400	0.00123	0.00261	0.00201	0.000968

0.000979	0.001485	0.0011	0.000782
0.000986	0.001488	0.00126	0.000790
0.000989	0.000178	0.00136	0.000795
0.000992	0.000347	0.00150	0.000798
0.000995	0.000622	0.00155	0.000800
0.000997	0.000807	0.00158	0.000802
0.000999	0.000926	0.00160	0.000804
0.000122	0.00100	0.00161	0.000806
0.000236	0.0011	0.001618	
0.000422	0.00114	0.00162	
0.000548	0.00116	0.00162	
0.000629	0.00117	0.00163	
0.000681	0.00118	0.001633	
0.000747	0.001186	0.000201	
0.000775	0.00119	0.000394	
0.000790	0.001192	0.000704	
0.000798	0.001195	0.000914	
0.000803	0.001197	0.00104	
0.000806	0.000147	0.00113	
0.000808	0.000285	0.00124	
0.000810	0.000509	0.00129	
0.000812	0.000661	0.00131	
0.000813	0.000758	0.00132	
0.000351	0.000819	0.00133	
0.000685	0.000901	0.00134	
0.001226	0.000935	0.00135	
0.00159	0.000952	0.001351	
0.00181	0.000961	0.001352	
0.00196	0.000968	0.001353	
0.00215	0.000971	0.000169	
0.00223	0.000973	0.000327	
0.00228	0.000976	0.000586	
0.00230	0.000978	0.000761	
0.00231	0.000980	0.000873	
0.00232	0.000122	0.000944	
0.00233	0.000237	0.00103	
0.00234	0.000424	0.00107	
0.002345	0.000551	0.00109	
0.002347	0.000632	0.00110	
0.000282	0.000684	0.00111	
0.000545	0.000750	0.001117	
0.000975	0.000777	0.001118	
0.001266	0.000793	0.001119	
0.00145	0.000802	0.00112	
0.00157	0.000806	0.001125	
0.00172	0.000807	0.000142	
0.00178	0.000812	0.000275	
0.00182	0.000814	0.000492	
0.00183	0.000816	0.000639	
0.00185	0.000817	0.000733	
0.00185	0.000291	0.000794	
0.00186	0.000568	0.000870	
0.001865	0.00101	0.000903	
0.00187	0.00131	0.000919	
0.001873	0.00150	0.000928	
0.000221	0.00163	0.000935	
0.000432	0.00178	0.000939	
0.000771	0.00185	0.000942	
0.00100	0.00188	0.000943	
0.00115	0.00190	0.000946	
0.00124	0.00191	0.000947	
0.00136	0.00192	0.000120	
0.00141	0.00193	0.000234	
0.00144	0.001936	0.000418	
0.00145	0.001939	0.000543	
0.00146	0.00194	0.000622	
0.00147	0.000245	0.000675	
0.001478	0.000474	0.000740	
0.00148	0.000850	0.000768	

