



# BIBLIOTHÈQUE

CÉGEP DE L'ABITIBI-TÉMISCAMINGUE  
UNIVERSITÉ DU QUÉBEC EN ABITIBI-TÉMISCAMINGUE

## Mise en garde

La bibliothèque du Cégep de l'Abitibi-Témiscamingue et de l'Université du Québec en Abitibi-Témiscamingue (UQAT) a obtenu l'autorisation de l'auteur de ce document afin de diffuser, dans un but non lucratif, une copie de son œuvre dans [Depositum](#), site d'archives numériques, gratuit et accessible à tous. L'auteur conserve néanmoins ses droits de propriété intellectuelle, dont son droit d'auteur, sur cette œuvre.

## Warning

The library of the Cégep de l'Abitibi-Témiscamingue and the Université du Québec en Abitibi-Témiscamingue (UQAT) obtained the permission of the author to use a copy of this document for nonprofit purposes in order to put it in the open archives [Depositum](#), which is free and accessible to all. The author retains ownership of the copyright on this document.



**INVESTIGATION SUR L'UTILISATION DE L'INTELLIGENCE  
ARTIFICIELLE POUR LA CARACTÉRISATION VISCOÉLASTIQUE DES  
BIO-COMPOSITES.**

MÉMOIRE  
PRÉSENTÉ  
COMME EXIGENCE PARTIELLE  
DE LA MAÎTRISE EN INGÉNIERIE

PAR  
JIHAD LEMFEDDEL

Avril 2025

## REMERCIEMENTS

Je tiens à exprimer ma profonde gratitude à **M. Fouad Erchiqui**, mon directeur de recherche, pour son accompagnement, sa disponibilité et ses conseils précieux tout au long de cette recherche. Son expertise et ses encouragements ont été essentiels à la réalisation de ce travail.

Je remercie également **M. Hassan Ezzaidi**, mon co-directeur, pour son soutien et ses conseils éclairés. Son regard critique et ses suggestions ont permis d'améliorer la qualité de ce mémoire.

Je suis reconnaissante envers **les membres du jury** pour le temps qu'ils ont consacré à évaluer ce travail, ainsi que pour leurs remarques constructives qui ont contribué à enrichir cette recherche.

Je tiens à remercier chaleureusement **mes parents et mes deux frères** pour leur amour, leur soutien inconditionnel et leur confiance en moi. Leur présence à mes côtés m'a toujours donné la force de persévérer.

Un merci tout particulier à **Mohamed**, mon mari, pour son soutien indéfectible, sa patience et sa compréhension tout au long de cette aventure. Sa présence m'a été d'un grand réconfort durant les moments difficiles.

Enfin, je remercie toutes les personnes qui, de près ou de loin, ont contribué à la réussite de cette étude.

## **AVANT-PROPOS**

La rédaction de ce mémoire marque l'aboutissement d'un travail de recherche de plusieurs mois, consacré à l'étude et à la modélisation numérique des composites à base de polyéthylène haute densité (HDPE) et de fibres végétales. Ce projet est né de mon intérêt pour la science des matériaux et de ma volonté de contribuer à une meilleure compréhension des propriétés viscoélastiques des thermoplastiques renforcés.

À travers ce mémoire, j'ai cherché à allier les connaissances théoriques acquises durant mon parcours universitaire. Ce travail m'a permis de développer des compétences en matière de modélisation numérique et d'intelligence artificielle, tout en approfondissant ma compréhension des matériaux composites, un domaine encore peu exploré.

L'objectif principal de cette recherche est de caractériser le comportement viscoélastique d'une famille de biocomposites, à base de fibres de bois et d'une matrice thermoplastique (HDPE). Pour cela, une approche hybride (à base d'un modèle de réseau de neurones, de données expérimentales et analytiques) est utilisée.

## TABLE DES MATIÈRES

REMERCIEMENTS .....	II
AVANT-PROPOS .....	III
TABLE DES MATIÈRES .....	IV
LISTE DES FIGURES.....	VII
LISTE DES TABLEAUX.....	X
LISTE DES SIGLES ET DES ABRÉVIATIONS.....	XI
LISTE DES SYMBOLES.....	XII
RÉSUMÉ .....	XIV
ABSTRACT .....	XV
1. CHAPITRE 1 : INTRODUCTION GÉNÉRALE .....	1
1.1 Contexte général .....	1
1.2 Problématique .....	2
1.3 Objectifs et hypothèses .....	3
1.3.1 Objectif général .....	3
1.3.2 Objectifs spécifiques.....	3
1.3.3 Hypothèse .....	4
1.4 Méthodologie de recherche .....	4
1.4.1 L'approche scientifique .....	4
1.4.2 La démarche suivie.....	5
1.5 Conclusion .....	6
2. CHAPITRE 2 : REVUE DE LA LITTÉRATURE SUR LES COMPOSITES À BASE DE PLASTIQUE.....	7
2.1 Introduction .....	7
2.1.1 Composites à base de fibres végétales _thermodurcissables.....	7
2.1.2 Composites à base de fibres végétales _thermoplastiques.....	8
2.2 Techniques d'élaboration des Biocomposites Plastique-Bois .....	11
2.3 Techniques de caractérisation des composites Plastique-Bois.....	13
2.4 Comportement des thermoplastiques .....	14
2.4.1 Comportement élastique (Hooke) .....	15
2.4.2 Comportement hyperélastique (Mooney-Rivlin, Ogden).....	16

2.4.2.1.	Modèle Mooney-Rivlin .....	16
2.4.2.2.	Modèle Ogden .....	17
2.4.3	Comportement viscoélastique.....	18
2.4.3.1.	Modèle de K-BKZ .....	18
2.4.3.2.	Modèle de Lodge .....	20
2.4.3.3.	Modèle de Christensen .....	20
2.4.4	Comportement Viscoélastoplastique.....	21
2.5	Techniques d'identification des constantes matérielles.....	22
2.5.1	Méthodes des moindres carrés :.....	22
2.5.2	Méthodes basées sur l'intelligence artificielle IA : .....	23
3.	CHAPITRE 3 : LES RÉSEAUX DE NEURONES ARTIFICIELS : APPROCHES ET ALGORITHMES .....	25
3.1	Introduction .....	25
3.2	Historique et Évolution des Réseaux de Neurones artificiels .....	26
3.3	Le neurone formel .....	29
3.3.1	Description de réseau de neurones artificiels .....	29
3.3.2	Réseau de neurones feedforward.....	31
3.3.1	Algorithme « error back propagation » .....	32
3.4	Fonction de transfert/activation.....	33
3.5	Apprentissage des réseaux de neurones .....	38
3.5.1	Définition .....	38
3.5.2	Protocoles d'apprentissage .....	38
3.5.3	Règles d'apprentissage .....	39
3.6	Les types d'apprentissage :.....	41
3.7	Avantages et inconvénients des réseaux de neurones :.....	43
3.7.1	Avantages des réseaux de neurones :.....	43
3.7.2	Inconvénient des réseaux de neurones : .....	43
3.8	Extraction des données :.....	44
3.9	Conclusion : .....	45

4. CHAPITRE 4 : IDENTIFICATION ET CARACTÉRISATION DE L'HDPE BRUTE PAR RNA.....	46
4.1 Introduction .....	46
4.2 Les démarches suivies .....	46
4.3 Dataset et entraînement des RNAs .....	49
4.4 Algorithme de Prédiction avec RNA.....	50
4.5 Méthode d'évaluation des modèles neuronaux.....	51
4.6 Analyses des performances du modèle neuronal .....	51
4.6.1 Entraînement du réseau de neurones pour la prédiction :.....	52
4.6.2 Validation des Modèles par les Données expérimentales : .....	57
4.7 Conclusion .....	67
5. CHAPITRE 5 : PRÉDICTION DES PROPRIÉTÉS DES BIOCOMPOSITES HDPE + SCIURE DE BOIS PAR RNA .....	68
5.1 Introduction .....	68
5.2 HDPE + 20 % Sciure de Bois .....	68
5.2.1 Processus d'entraînement pour HDPE + 20 % Sciure de Bois.....	68
5.2.2 Prédiction par RNA et comparaison des résultats .....	71
5.2.3 Conclusion.....	74
5.3 HDPE + 30 % Sciure de Bois .....	74
5.3.1 Processus d'entraînement pour HDPE + 30 % Sciure de Bois.....	74
5.3.2 Prédiction par RNA et comparaison des résultats .....	77
5.3.3 Conclusion.....	80
5.4 HDPE + 40 % Sciure de Bois .....	80
5.4.1 Processus d'entraînement pour HDPE + 40 % Sciure de Bois.....	80
5.4.2 Prédiction par RNA et comparaison des résultats .....	83
5.4.3 Conclusion.....	86
CONCLUSION.....	87
BIBLIOGRAPHIE .....	96

## LISTE DES FIGURES

Figure 2.1 : Distribution des trois composants du bois.....	10
Figure 3.1 : Schéma d'un neurone biologique .....	28
Figure 3.2 : Illustration d'un réseau de neurones feed-forward.....	30
Figure 3.3 : La structure de base d'un neurone .....	32
Figure 3.4 : Fonction binaire à seuil. ....	34
Figure 3.5 : Fonction signe .....	35
Figure 3.6 : Fonction linéaire.....	35
Figure 3.7 : Fonction linéaire à seuil ou multiseuils.....	36
Figure 3.8 : Fonction sigmoïde.....	37
Figure 3.9 : Fonction tangente sigmoïde.....	38
Figure 3.10 : Les cellules de RNA.....	39
Figure 3.11 : Schéma d'apprentissage supervisé. ....	42
Figure 3.12 : Schéma d'apprentissage non supervisé. ....	43
Figure 4.1 : Courbe de performance du réseau neuronal 3-10-10 - 10-1.....	53
Figure 4.2 : Courbe de performance du réseau neuronal 3-25-5-5-1.....	54
Figure 4.3 : Courbe de performance du réseau neuronal 3-26-5-1-1.....	55
Figure 4.4 : Courbe de performance du réseau neuronal 3-25-5-1-1.....	56
Figure 4.5 : Meilleure performance de validation du réseau neuronal 3-25-5-1-1.....	56
Figure 4.6 : Comparaison entre les $G'$ théoriques et Expérimentales utilisées pour l'Entraînement des Modèles. ....	59
Figure 4.7 : Comparaison entre les $G''$ théoriques et Expérimentales utilisées pour l'Entraînement des Modèles. ....	59
Figure 4.8 : Comparaison entre les $G'$ théoriques et Expérimentales pour le modèle 1. ....	60
Figure 4.9 : Comparaison entre les $G''$ théoriques et Expérimentales pour le modèle 1. ....	60

Figure 4.10 : Comparaison entre les G' théoriques et Expérimentales pour le modèle 2.....	61
Figure 4.11 : Comparaison entre les G'' théoriques et Expérimentales pour le modèle 2.....	62
Figure 4.12 : Comparaison entre les G' théoriques et Expérimentales pour le modèle 3.....	63
Figure 4.13 : Comparaison entre les G'' théoriques et Expérimentales pour le modèle 3.....	63
Figure 4.14 : Comparaison entre les G' théoriques et Expérimentales pour le modèle 4.....	64
Figure 4.15 : Comparaison entre les G'' théoriques et Expérimentales pour le modèle 4.....	65
Figure 4.16 : Schéma structural de réseau neuronal 3-25-5-1-1.....	65
Figure 4.17 : Comparaison entre les G' théoriques et prédits pour le modèle 4. ....	66
Figure 4.18 : Comparaison entre les G'' théoriques et prédits pour le modèle 4. ....	66
Figure 5.1 : Progression d'entraînement pour RNA -3-25-5-1-1.....	69
Figure 5.2 : Courbe de performance du réseau neuronal.....	69
Figure 5.3 : Graphe de régression pour le réseau neuronal.....	70
Figures 5.4 : Comparaison des résultats prédits et théoriques pour HDPE+20 % Bois. ....	72
Figures 5.5 : Comparaison des résultats prédits et expérimentaux pour HDPE+20 % Bois. ....	73
Figure 5.6 : Progression d'entraînement pour RNA -3-25-5-1-1.....	74
Figure 5.7 : Courbe de performance du réseau neuronal.....	75
Figure 5.8 : Graphe de régression pour le réseau neuronal.....	76
Figures 5.9 : Comparaison des résultats prédits et théoriques pour HDPE+30 % Bois. ....	78

Figures 5.10 : Comparaison des résultats prédits et expérimentaux pour HDPE+30 % Bois.....	79
Figure 5.11 : Progression d'entraînement pour RNA -3-25-5-1-1. ....	80
Figure 5.12 : Courbe de performance du réseau neuronal. ....	81
Figure 5.13 : Graphe de régression pour le réseau neuronal. ....	82
Figure 5.14 : Comparaison des résultats prédits et théoriques pour HDPE+40 % Bois.....	84
Figures 5.15 : Comparaison des résultats prédits et expérimentaux pour HDPE+40 % Bois.....	85
Figure 5.16 : Graphe de régression pour le réseau neuronal du modèle 1...	91
Figure 5.17 : Graphe de régression pour le réseau neuronal du modèle 2...	92
Figure 5.18 : Graphe de régression pour le réseau neuronal du modèle 3...	93
Figure 5.19 : Graphe de régression pour le réseau neuronal du modèle 4...	94

## **LISTE DES TABLEAUX**

Tableau 5.1 : Comparaison entre les valeurs de gi entraîné et prédites par RNA pour HDPE+20%Sciure de bois. ....	71
Tableau 5.2 : Comparaison entre les valeurs de gi entraîné et prédites par RNA + 30%Sciure de bois. ....	77
Tableau 5.3 : Comparaison entre les valeurs de gi entraîné et prédites par RNA + 40%Sciure de bois. ....	83

## LISTE DES SIGLES ET DES ABRÉVIATIONS

HDPE: Polyéthylène haute densité

PELD : Polyéthylène basse densité

PELLD : Polyéthylène basse densité linéaire

PP : Polypropylène

$T_m$  : Température de fusion

PET : Polyéthylène téréphtalate

PCL: Polycaprolactone

RNA : Réseau de Neurones artificiels

IA : Intelligence artificielle

RNN: Réseaux de Neurones récurrents

PMC : Perceptron Multi Couche

RELU : Rectified Linear Unit

LMS: Least Mean Squares

MSE : Erreur quadratique moyenne

UQAT : Université de Québec en Abitibi-Témiscamingue

## LISTE DES SYMBOLES

$G'$  : Module dynamique de stockage

$G''$  : Module dynamique de perte

$\eta$  : Viscosité complexe

$\eta'$  : Composante imaginaire de la viscosité complexe

$\eta''$  : Composante réelle de la viscosité complexe

$\omega$  : Taux de cisaillement

$\eta_0$  : Viscosité plateau newtonien

$\eta^\infty$  : Viscosité à taux de cisaillement infini

$n$  : nombre de dépendances de la viscosité pour la vitesse de cisaillement

$T_0$  : Température référence

$g_k$  et  $\tau_k$  : Module de rigidité et temps de relaxation

$m(t, \tau)$  : Fonction mémoire

$T_g$  : Température de transition vitreuse

$W$  : Fonction de l'énergie de déformation élastique

$E$  : Tenseur de déformation Green-Lagrange

$B$  : Tenseur de déformation

$C$  : Tenseur de déformation Green-Cauchy

$C_1$  et  $C_2$  : Constantes matérielles

$I_1$  et  $I_2$  : les deux premiers invariants du tenseur de déformation Green-Cauchy

$A_{IJ}$  : Constantes matérielles

$\lambda_i$  : Élongations principales selon les axes propres

$\mu_n$  et  $\alpha_n$  : Constantes matérielles

$\sigma(t)$  : Tenseurs des contraintes

$\bar{\sigma}$  : Contrainte effective

$\bar{\varepsilon}$  : Déformations effectives

$\varepsilon$  : Élongation à la rupture

## RÉSUMÉ

La modélisation numérique de la mise en forme des matériaux thermoplastiques dans l'industrie de la plasturgie exige une compréhension approfondie des lois de comportement qui régissent ces matériaux, qui présentent souvent un comportement viscoélastique.

Néanmoins, le comportement viscoélastique des thermoplastiques renforcés avec des fibres végétales reste peu exploré dans la littérature scientifique. C'est dans ce cadre que le projet est inscrit et vise la caractérisation expérimentale et numérique du comportement d'une famille de biocomposites à base de polyéthylène haute densité (HDPE) et de sciures de bois. À cet effet, cinq concentrations massiques en sucres de bois sont considérées : 0 %, 20 %, 30 %, et 40 %.

Pour la caractérisation comportementale des biocomposites, le modèle viscoélastique intégral de Lodge est utilisé. L'identification des paramètres du modèle de Lodge est réalisée à l'aide d'une approche hybride qui combine des données rhéologiques (obtenues par des essais de cisaillement dynamique), des données théoriques (issues du modèle de Lodge) et de l'intelligence artificielle (pour le déploiement d'un modèle de réseau de neurones de type feedforward).

Mots clés : Composite bois-plastique, polyéthylène haute densité, rhéologie, viscoélasticité, modèle viscoélastique de Lodge, intelligence artificielle, réseaux de neurones.

## **ABSTRACT**

The numerical modeling of thermoplastic material shaping in the plastics industry requires a deep understanding of the behavioral laws governing these materials, which often exhibit viscoelastic behavior.

However, the viscoelastic behavior of thermoplastics reinforced with plant fibers remains largely unexplored in scientific literature. This project falls within this scope and aims to experimentally and numerically characterize the behavior of a family of bio-composites based on high-density polyethylene (HDPE) and wood sawdust. Specifically, five mass concentrations of wood sugars are considered: 0%, 20%, 30%, and 40%

To characterize the behavior of bio-composites, the integral viscoelastic model of Lodge is used. The identification of the Lodge model parameters is carried out using a hybrid approach that combines rheological data (obtained from dynamic shear tests), theoretical data (from the Lodge model), and artificial intelligence (for deploying a feedforward neural network model).

Keywords: Wood-plastic composite, high-density polyethylene, rheology, viscoelasticity, Lodge viscoelastic model, artificial intelligence, neural networks.

## 1. CHAPITRE 1 : INTRODUCTION GÉNÉRALE

Les composites bois-plastique ou les biocomposites ont récemment attiré l'attention du marché mondial, surtout à l'échelle académique et industrielle. Ce genre de matériau qui est à base de plastique et de renfort en bois a rendu le marché en éveil, en effet l'innovation sur ces nouveaux matériaux se développe fortement grâce à de nombreux secteurs d'activité qui ont intégré les biocomposites dans la conception et la fabrication de leurs produits. Parmi ces secteurs on trouve : l'industrie automobile, l'industrie textile, le secteur de transport, d'agriculture, de construction et le secteur médical, Etc.

L'intérêt porté à ces nouveaux matériaux n'est pas au hasard mais c'est lié à ses propriétés mécaniques ainsi à ses multiples avantages qui le rendent capable de répondre aux exigences économiques et environnementales.

### *1.1 Contexte général*

Les biocomposites offrent des avantages intéressants et possèdent une combinaison de propriétés qui en font un choix comparatif aux autres matériaux. Cependant, la fabrication des produits à base de bois nécessite une étude approfondie pour identifier et caractériser ce genre de matériaux, ce qui coûte très cher en termes de temps et de matériaux. Dans ce contexte on voit les outils numériques en modélisation pour l'étude virtuelle des procédés qui jouent un rôle très important pour résoudre ce problème et d'éviter ces coûts élevés. Donc cette alternative justifiable pour analyser et améliorer les procédés de fabrication aide pour modéliser et simuler des tests rhéologiques qui ont un but d'identifier le comportement de thermoplastique après l'addition des particules de bois. Dans notre cas, nous allons identifier le comportement viscoélastique de HDPE (polyéthylène haute densité) et des sciures de bois en

fonction de la température et des concentrations massiques différentes de bois (0 %, 20 %, 30 %, 40 %). La caractérisation viscoélastique de cette famille de biocomposite va être réalisée à l'aide d'une approche hybride qui utilise la modélisation numérique, l'expérimentale et un algorithme des réseaux de neurones. En effet, depuis quelques années des méthodes basées sur l'intelligence artificielle ont été utilisées pour identifier les paramètres mécaniques et rhéologiques. Parmi les techniques les plus utilisées de l'intelligence artificielle, on trouve les réseaux de neurones artificiels. Parmi les techniques les plus utilisées, les réseaux de neurones se sont révélés particulièrement efficaces (Erchiqui & Kandil, 2006 ; Erchiqui et al., 2011 ; Farid et al., 2014).

## *1.2 Problématique*

L'analyse détaillée et l'évaluation des matériaux, connues sous le nom de caractérisation des matériaux, jouent un rôle déterminant dans l'appréhension de leurs propriétés comportementales. Cette compréhension est essentielle pour guider le choix des matériaux les plus adaptés aux applications spécifiques requises dans divers secteurs, tels que l'ingénierie, la construction, l'aérospatiale, l'automobile, etc. Cependant, la caractérisation classique est souvent synonyme d'une consommation élevée de ressources, notamment en ce qui concerne le temps, les coûts financiers et les matériaux, en raison de la nature intensive des méthodes classiques et expérimentales impliquées.

Dans le contexte actuel, où l'efficacité des coûts et la rapidité d'exécution sont de plus en plus demandées, il est crucial de développer et d'adopter des méthodes de caractérisation alternatives qui réduisent le besoin d'investissements lourds. L'avènement de la modélisation informatique et de l'intelligence artificielle offre de nouvelles avenues dans ce domaine. Les simulations numériques, par exemple, peuvent prédire le comportement des

matériaux sous différentes contraintes sans nécessiter d'essais physiques coûteux. De même, les algorithmes d'apprentissage machine peuvent traiter des données complexes pour identifier des modèles et des propriétés matérielles, parfois avec une précision supérieure et une rapidité inégalée par rapport aux méthodes classiques.

L'adoption de telles stratégies innovantes pour la caractérisation des matériaux pourrait non seulement accélérer le processus de développement des matériaux, mais également ouvrir la voie à des découvertes plus durables et moins coûteuses, tout en préservant les ressources naturelles et en réduisant l'impact environnemental. En résumé, la caractérisation des matériaux évolue vers un paradigme plus économe en ressources et plus aligné sur les impératifs de durabilité et d'efficacité économique de notre époque.

### *1.3 Objectifs et hypothèses*

#### 1.3.1 Objectif général

Développer un modèle basé sur l'intelligence artificielle pour caractériser le comportement viscoélastique des biocomposites HDPE + sciures de bois en utilisant le modèle intégral de Lodge.

#### 1.3.2 Objectifs spécifiques

Collecter des données théoriques et expérimentales sur les propriétés viscoélastiques des biocomposites HDPE + sciures de bois avec différentes proportions de sciure de bois (0 %, 20 %, 30 %, 40 %).

1. Analyser les données collectées et déterminer les paramètres du modèle intégral de Lodge pour chaque proportion de sciure de bois.

2. Concevoir et entraîner un réseau de neurones pour modéliser le comportement viscoélastique des biocomposites en fonction de la proportion de sciures de bois.
3. Valider et tester la performance du modèle développé en utilisant des données expérimentales indépendantes.
4. Optimiser et affiner le modèle pour identifier le comportement viscoélastique de composite bois-HDPE.

### 1.3.3 Hypothèse

Dans le cas de notre étude, plusieurs hypothèses ont été considérées sur le comportement viscoélastique du matériau :

- Le composite bois-plastique est supposé être homogène, isotrope et incompressible
- Le comportement de composite bois-plastique est viscoélastique de type intégral

## 1.4 Méthodologie de recherche

### 1.4.1 L'approche scientifique

La littérature scientifique regorge de différents modèles viscoélastiques, tous basés soit sur une approche différentielle soit sur une approche intégrale. Ces modèles établissent une relation précise entre la contrainte réelle qu'un matériau subit et l'historique de sa déformation. Ces modèles sont conçus spécifiquement pour permettre une meilleure compréhension et une meilleure approximation des comportements viscoélastiques, qui sont typiques des polymères.

Parmi les modèles intégraux, on peut citer celui de Lodge (Lodge, 1964), *Christensen* (Christensen, 1980), *K-BKZ* (Nishioka et al., 2000), *CBT* (Bloch et

al., 1978), pour n'en nommer que quelques-uns. Ces modèles sont particulièrement adaptés pour représenter les comportements des polymères à différents états de la matière. Par exemple, ils sont très efficaces pour représenter les polymères à l'état liquide, ou à un état semi-solide.

Pour l'étude qui nous occupe, nous avons choisi d'utiliser le modèle viscoélastique intégral de *Lodge* (Lodge, 1964). Ce choix a été fait dans le but de représenter de manière précise le comportement du HDPE (Polyéthylène haute densité) et des composites à base de HDPE et de bois.

#### 1.4.2 La démarche suivie

##### 1. Collecte de données :

- a. Données théoriques : Calcul des paramètres rhéologiques  $G'_{th}$  et  $G''_{th}$  à l'aide des équations.
- b. Données expérimentales : Réalisation des essais rhéologiques avec  $G'_{exp}$  et  $G''_{exp}$ .

##### 2. Préparation et entraînement du modèle

a. Utilisation des données théoriques pour l'entraînement, la validation et le test du modèle.

##### 3. Recherche de la meilleure architecture :

- a. Multiplication des tests pour trouver l'architecture optimale.
- b. Variation du nombre de couches et du nombre de neurones par couche.
- c. Construction du modèle avec la meilleure configuration.

##### 4. Validation finale avec les données expérimentales :

- a. Deuxième phase de validation : test du modèle avec des valeurs expérimentales qui n'ont pas été utilisées lors de l'entraînement.
- b. Sélection du meilleur modèle de prédiction pour le HDPE brut.

## 5. Application du modèle :

- a. Utilisation du modèle validé pour prédire les paramètres rhéologiques des composites HDPE-sciure de bois.
- b. Comparaison des valeurs théoriques et expérimentales pour valider les résultats.

### *1.5 Conclusion*

Ce chapitre a donné une introduction de sujet à traiter tout en présentant sa problématique, les objectifs fixés et la méthodologie de recherche suivie. Reste à évaluer les méthodes d'identification du comportement viscoélastique de biocomposite par l'application de réseaux neuronaux artificiels, il constituera la principale contribution de ce rapport.

## **2. CHAPITRE 2 : REVUE DE LA LITTÉRATURE SUR LES COMPOSITES À BASE DE PLASTIQUE**

### *2.1 Introduction*

Ce chapitre est dédié à une revue de littérature concernant les composites à base de plastique ainsi que les techniques employées pour leur caractérisation. En effet, l'intégration de renforts, indépendamment de leur type (minéral, naturel, copolymère, etc.), procure une multitude de bénéfices aux polymères lorsqu'ils sont incorporés dans des matériaux plastiques. Ces renforts contribuent à accroître la rigidité et la robustesse mécanique des plastiques, tout en améliorant leur stabilité dimensionnelle et leur résistance à la chaleur (Aklonis & MacKnight, 1983). Deux catégories principales de polymères sont couramment utilisées comme matrices : les thermoplastiques et les thermodurcissables.

#### 2.1.1 Composites à base de fibres végétales \_thermodurcissables

La performance des composites à base de polymères et de renforts naturels repose principalement sur deux facteurs : les caractéristiques structurelles des composants (fibres naturelles et polymères) et les propriétés de l'interface entre les renforts et la matrice. Une quantité importante de recherches a été réalisée pour évaluer l'efficacité de ces matériaux. Avec une variété de polymères, de renforts naturels et de méthodes pour les combiner, soit en modifiant ou non l'interface, chaque composite vise un objectif spécifique de performance. Cette variété est également présente dans les publications scientifiques, qui diffèrent par les caractéristiques mesurées et les méthodologies utilisées.

Les composites à base de polymères thermodurcissables et thermoplastiques offrent des options intéressantes comme matrices. Les composites thermodurcissables se solidifient par une réaction chimique et nécessitent plusieurs composants (résine de base, catalyseurs et agents divers pour la cuisson, l'écoulement et le durcissement), ce qui peut compliquer leur mise en forme. Cependant, une fois durcis, ils forment une structure tridimensionnelle fortement réticulée, leur conférant une excellente résistance mécanique et une bonne tenue face aux solvants chimiques. L'ajout de fibres naturelles pouvant constituer jusqu'à 80 % du composite, et leur alignement pendant le processus de mise en forme peut significativement améliorer les propriétés mécaniques de ces matériaux. (Tazi, 2015)

#### 2.1.2 Composites à base de fibres végétales \_thermoplastiques

Le critère essentiel dans la sélection d'un thermoplastique pour la fabrication de biocomposites avec des renforts naturels est la température de fusion ( $T_m$ ) du polymère, qui doit être inférieure à la température à laquelle la fibre commence à se dégrader (Klesov, 2007 ; Saheb, 1999). Cela restreint le choix à des polymères tels que les polyoléfines (comme le polyéthylène haute densité (HDPE), le polyéthylène basse densité (PELD), le polyéthylène basse densité linéaire (PELLD), et le polypropylène (PP)). Parmi eux, le polyéthylène est fréquemment choisi en raison de sa résistance à la corrosion, de sa flexibilité, de mise en forme, et de sa recyclabilité. Le HDPE, avec sa structure linéaire, semi-cristalline, offre une densité de 940 à 980 kg/m<sup>3</sup> et une conductivité thermique de 0,46 à 0,51 W/(m·K), avec une température de fusion idéale pour la mise en forme de biocomposites à base de fibres naturelles, allant de 128 à 135 °C. (Klesov, 2007 ; Saheb, 1999).

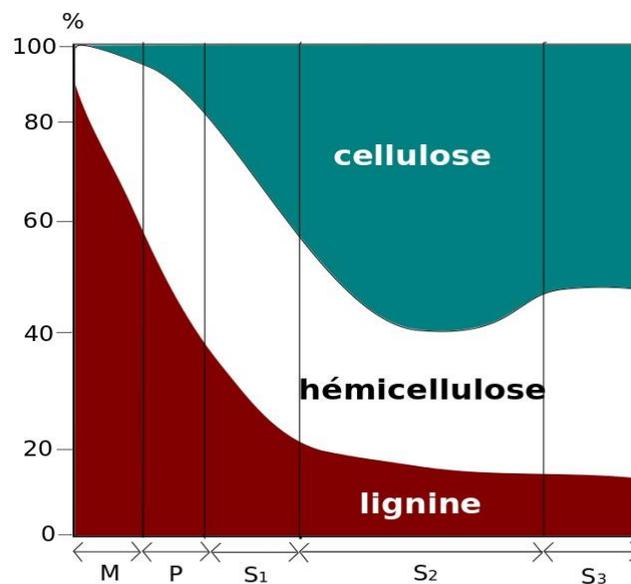
Les polyesters, notamment le polyéthylène téréphtalate (PET), sont un autre groupe de thermoplastiques pertinent dans le domaine des biocomposites. Le PET, dur et rigide, est produit par polycondensation et sa structure varie d'amorphe à semi-cristalline avec la température. Toutefois, son point de fusion élevé, entre 250 °C et 260 °C, dépasse la température de dégradation des fibres naturelles. Pour contourner ce problème, une approche consiste à copolymériser le PET avec le polycaprolactone (PCL), un polymère à basse température de fusion (~60 °C), afin de réduire la température de fusion du PET, la rendant ainsi compatible avec les biocomposites (Erchiqui et al., 2016). En outre, les fibres naturelles peuvent être chimiquement modifiées pour améliorer leur résistance thermique, par exemple, en utilisant des retardateurs de flamme pour former une couche protectrice, ou par un traitement alcalin pour augmenter leur stabilité thermique.

Les renforts naturels, issus de sources lignocellulosiques telles que le jute, le bambou, la noix de coco, la paille de riz, le lin, le sisal, et les sciures de bois, jouent un rôle crucial dans le renforcement des thermoplastiques. Ces fibres sont principalement composées de cellulose, d'hémicellulose, et de lignine, avec des proportions variables selon le type de fibre. La cellulose, un polysaccharide semi-cristallin, se distingue par sa partie cristalline extrêmement rigide, affichant un module de rigidité d'environ 136 GPa, nettement supérieur à celui de la fibre de verre (75 GPa). Cette rigidité s'explique par les liaisons hydrogène formées le long et entre les chaînes de cellulose, conférant aux fibres naturelles leur caractère hydrophile.

L'hémicellulose, quant à elle, est un polysaccharide totalement amorphe avec un poids moléculaire relativement bas par rapport à la cellulose, et sa structure amorphe la rend soluble dans l'eau et les solutions alcalines (Gáspár et al.,

2005). La lignine, un polymère amorphe composé de composés aromatiques, diffère de l'hémicellulose en ce qu'elle influe peu sur l'absorption d'eau.

Les fibres naturelles offrent des avantages significatifs pour la fabrication de composites en raison de leur coût réduit, de leur durabilité et de leur faible densité. Elles sont nettement plus légères que le verre, avec une densité estimée entre 1,15 et 1,50 g/cm<sup>3</sup>, contre 2,4 g/cm<sup>3</sup> pour le verre (Wang et al., 2006). Cette légèreté, combinée à des propriétés mécaniques supérieures, rend les fibres naturelles particulièrement attrayantes pour le renforcement des matériaux composites dans diverses applications.



**Figure 2.1**  
**Distribution des trois composants du bois**

Source :

[https://www.researchgate.net/publication/298434798\\_Etude\\_experimentale\\_et\\_numerique\\_du\\_comportement\\_hygromecanique\\_d'un\\_panneau\\_de\\_bois\\_Application\\_a\\_la\\_conservation\\_des\\_tableaux\\_peints\\_sur\\_bois\\_du\\_patrimoine](https://www.researchgate.net/publication/298434798_Etude_experimentale_et_numerique_du_comportement_hygromecanique_d'un_panneau_de_bois_Application_a_la_conservation_des_tableaux_peints_sur_bois_du_patrimoine)

La structure de la paroi cellulaire des fibres de bois est complexe et se caractérise par une alternance de zones cristallines et amorphes. Les zones cristallines sont formées par l'assemblage des chaînes de cellulose en

microfibrilles, tandis que les zones amorphes sont constituées d'hémicellulose et de lignine. Cette organisation confère aux fibres de bois leurs propriétés mécaniques et chimiques uniques.

La paroi cellulaire est structurée en différentes couches, qui peuvent être schématisées comme suit : la paroi cellulaire primaire (P) et la paroi secondaire (S), cette dernière étant elle-même subdivisée en trois sous-couches nommées S1, S2 et S3. Chacune de ces couches présente des caractéristiques distinctes en termes de structure et de composition chimique, contribuant de manière spécifique à la fonctionnalité globale de la fibre. La paroi cellulaire primaire, la plus externe, est relativement fine et flexible, permettant la croissance et l'expansion de la cellule. La paroi secondaire, située juste en dessous, est plus épaisse et rigide, fournissant la majorité de la résistance mécanique de la fibre. Les sous-couches S1, S2, et S3 de la paroi secondaire diffèrent par l'orientation des microfibrilles de cellulose, ce qui influence la résistance et la flexibilité de la fibre dans différentes directions (Tazi, 2015).

## *2.2 Techniques d'élaboration des Biocomposites Plastique-Bois*

La fabrication de matériaux composites associant des thermoplastiques et des fibres de bois constitue une phase déterminante dans la création de nouveaux matériaux. Toutefois, un défi majeur réside dans l'incompatibilité entre les deux composants. Les fibres de bois sont hydrophiles et polaires, avec une forte tendance à absorber l'eau, tandis que les polymères thermoplastiques sont généralement hydrophobes, peu polaires, et présentent une faible absorption d'eau. Cette différence de propriétés de surface conduit à une adhésion insuffisante entre les fibres et la matrice polymère, résultant en des propriétés mécaniques décevantes qui restreignent les applications industrielles du composite.

Pour surmonter cette difficulté et renforcer l'interaction chimique entre les fibres et la matrice polymère, diverses stratégies peuvent être employées, notamment la modification de la surface des fibres ou de la matrice. L'utilisation d'un agent de couplage est une approche courante ; cet agent sert de liaison entre les groupes hydroxyle des fibres et les liaisons hydrogène du polymère, améliorant ainsi l'adhésion entre les deux phases (Georgopoulos *et al.*, 2005).

D'autres méthodes peuvent également être mises en œuvre pour modifier les propriétés des fibres ou de la matrice et accroître leur réactivité mutuelle, incluant :

- Le traitement physique : modification de la surface sans altérer la composition chimique, par exemple, par plasma ou corona (Martin *et al.*, 2000 ; Ragoubi *et al.*, 2010 ; Faruk *et al.*, 2012).
- Le traitement chimique : application de substances chimiques pour modifier la surface des fibres, améliorant ainsi leur compatibilité avec la matrice polymère (Grüneberg, 2009 ; Hristov *et al.*, 2007 ; Kaddami *et al.*, 2006).
- Le traitement alcalin : traitement des fibres avec des solutions alcalines pour enlever certaines composantes de surface et augmenter la rugosité, ce qui facilite l'adhésion (Bisanda, 2000).
- Le traitement enzymatique : utilisation d'enzymes pour modifier spécifiquement certaines composantes des fibres, améliorant leur interaction avec la matrice polymère (Faruk *et al.*, 2012).

Ces techniques visent à optimiser les propriétés du matériau composite, ouvrant la voie à de nouvelles applications industrielles en exploitant au mieux les avantages des fibres naturelles et des polymères thermoplastiques.

### 2.3 Techniques de caractérisation des composites Plastique-Bois

L'un des défis majeurs dans l'utilisation des fibres naturelles comme renfort dans les composites réside dans leur variabilité significative, tant au niveau de leurs propriétés que de leur morphologie. Chaque type de fibre présente une structure et une composition chimique uniques de sa paroi cellulaire, influençant ainsi différemment l'interaction avec la matrice polymère. Cette diversité conduit à une large gamme de propriétés pour les biocomposites obtenus.

Les caractéristiques des composites plastique-bois sont influencées par plusieurs facteurs, notamment l'interaction entre les particules de bois et la matrice polymère, la résilience de la matrice thermoplastique, les caractéristiques morphologiques des particules de bois (telles que leur rapport de forme longueur/diamètre), la concentration en renfort, la présence et la concentration d'un agent couplant, ainsi que les conditions de mise en forme du composite (Wolcott *et al.*, 1999).

L'impact de ces variables, que ce soit individuellement ou en combinaison, sur les propriétés rhéologiques, mécaniques et thermophysiques des composites à base de polyéthylène haute densité (HDPE) et de bois a été largement étudié (Bouafif *et al.*, 2008 ; Migneault *et al.*, 2009). L'utilisation d'un agent couplant, par exemple, modifie la composition chimique de surface des fibres, comme le montre le changement des rapports massiques oxygène/carbone (O/C) à la surface des fibres. Ce changement résulte de la réaction entre les fonctions hydroxyle des fibres et le maléique anhydride de l'agent couplant pour former des fonctions, ester ou diester (Migneault *et al.*, 2011).

Des techniques telles que la spectroscopie à rayons X ont permis d'évaluer ces rapports O/C pour différents types de particules de bois, avant et après traitement. Les résultats ont montré que les composites affichant les rapports atomiques O/C les plus élevés présentent également les meilleures propriétés mécaniques, témoignant d'une interaction interatomique optimale entre les particules de bois et la matrice polymère. Cette interaction favorise un meilleur transfert de charge à l'interface, renforçant ainsi les propriétés mécaniques du composite.

Il a également été démontré que les particules de bois ayant un rapport de forme élevé contribuent à une meilleure résistance mécanique du composite. La matrice polymère autour de ces fibres subit un cisaillement important, ce qui améliore le transfert de charge de la matrice vers les fibres et assure une meilleure distribution des contraintes à travers l'interface. Ces découvertes soulignent l'importance de l'optimisation de l'interaction fibre-matrice pour le développement de composites plastique-bois aux propriétés mécaniques améliorées (Migneault et al., 2011).

#### *2.4 Comportement des thermoplastiques*

La relation entre la contrainte mécanique et la déformation dans les polymères est complexe et varie grandement en fonction de l'état structural du polymère et des conditions expérimentales (Tazi, 2015). Les polymères peuvent adopter plusieurs configurations structurales, allant d'une structure solide amorphe et fragile à un état thermoplastique semi-cristallin ductile, en passant par un état élastomère similaire au caoutchouc et jusqu'à un état liquide polymérique. Cette diversité structurelle rend difficile l'établissement d'une relation unique contrainte-déformation qui puisse décrire de manière globale tous les types de comportements des polymères.

Face à cette complexité, les chercheurs ont défini des modèles de comportement mécanique en se basant sur des hypothèses simplifiées, permettant ainsi d'approximer le comportement des polymères dans des contextes plus spécifiques. Ces modèles visent à fournir une compréhension plus claire et une prédiction plus précise du comportement des polymères sous différentes sollicitations mécaniques, en tenant compte de leur nature diverse et de leur réponse variable aux forces appliquées. En résumé, la modélisation du comportement des polymères nécessite une approche adaptée à leur état structural spécifique et aux conditions expérimentales particulières, reflétant la complexité inhérente à ces matériaux.

#### 2.4.1 Comportement élastique (Hooke)

La formule ci-dessous représente la loi de Hooke, qui décrit le comportement élastique des matériaux sous de petites déformations. Dans cette relation ( $\sigma$ ) qui représente la contrainte appliquée sur le matériau ( $\varepsilon$ ) est la déformation résultante, et ( $E$ ) est le module d'élasticité du matériau, aussi appelé module de Young. Le module d'élasticité est une constante de proportionnalité qui caractérise la rigidité d'un matériau : plus cette valeur est élevée, plus le matériau est considéré comme rigide (Tazi, 2015).

Le comportement élastique est donc caractérisé par une dépendance linéaire entre la contrainte et la déformation, où la déformation subie par le matériau est entièrement réversible après le retrait de la charge appliquée. Cela signifie que le matériau revient à sa forme originale sans aucune déformation permanente, et l'énergie mécanique investie pour déformer le matériau est entièrement restituée sous forme d'énergie potentielle, conformément à la première loi de la thermodynamique. Ce comportement est typique des matériaux solides sous des contraintes de faible amplitude.

$$\sigma = E \cdot \varepsilon \quad (2.1)$$

#### 2.4.2 Comportement hyperélastique (Mooney-Rivlin, Ogden)

Les matériaux hyperélastiques sont caractérisés par la fonction scalaire de l'énergie de déformation notée ( $W$ ) qui dépend de l'état de déformation. La variation de  $W$  par rapport à la déformation Green-Lagrange  $E$  est proportionnel à la contrainte selon la forme suivante :

$$\sigma = \frac{\partial W}{\partial E} \quad (2.2)$$

Le symbole  $\sigma$  symbolise la contrainte interne créée dans le matériau, également connu sous le nom de contrainte réelle de Cauchy. Établir la forme de la fonction de l'énergie de déformation pour les matériaux hyperélastiques à des températures supérieures à la température vitreuse est un défi, principalement en raison des grandes déformations subies par les polymères. Dans la littérature scientifique, on retrouve diverses versions de cette fonction ( $W$ ). Des revues complètes de ces différentes formes ont été réalisées par *Treloar* (1944), *Green et Zerna* (1954) et *Green et Adkins* (1974). Deux définitions distinctes de la fonction d'énergie ( $W$ ) sont principalement citées, utilisées dans les simulations de thermoformage : le modèle de *Mooney-Rivlin* (1940) et le modèle *Ogden* (1972) (Mooney, 1940; Ogden, 1972).

##### 2.4.2.1. Modèle Mooney-Rivlin

Dans leur modèle, Mooney-Rivlin (Mooney, 1940) a proposé d'exprimer la fonction de densité d'énergie de déformation  $W$  pour un matériau incompressible comme un polynôme en termes des variables  $I_1$  et  $I_2$ . ces

variables symbolisent les deux premiers invariants du tenseur de déformation Green-Cauchy  $\mathbf{C}$ .

$$I_1 = \text{tr}(\mathbf{C}) \text{ et } I_2 = \frac{1}{2}(\text{tr}(\mathbf{C}))^2 - \text{tr}(\mathbf{C}^2) \quad (2.3)$$

La forme générale de la fonction d'énergie de déformation est donnée par :

$$W = \sum_{i=0}^M \sum_{j=0}^N A_{ij} (I_1 - 3)^i (I_2 - 3)^j \quad (2.4)$$

$A_{ij}$  Sont des constantes déterminées expérimentalement. À l'état initial, l'énergie de déformation  $W$  d'un corps non déformé est nulle et la constante  $A_{00}=0$ . de plus, si seulement les deux premiers termes  $A_{10}$  et  $A_{01}$  sont à considérer, alors on obtient l'expression standard Mooney-Rivlin (Mooney, 1940). Quand  $A_{01}=0$ , on retrouve le modèle néoHooke.

$$W = A_{10}(I_1 - 3) + A_{01}(I_2 - 3) \quad (2.5)$$

#### 2.4.2.2. Modèle Ogden

Ogden (1972) a exprimé la fonction densité d'énergie de déformation,  $W$ , en fonction des élongations principales  $\lambda_i = 1,2,3$  au lieu des invariants  $I_1$  et  $I_2$  du tenseur de déformation  $\mathbf{C}$ . En conséquence, l'interprétation physique de la relation contrainte-déformation résultante dans ce cas est beaucoup plus facile à effectuer. La forme de la fonction d'énergie proposée dans le modèle d'Ogden est donnée par :

$$W = \sum_{n=1}^m \frac{\mu_n}{\alpha_n} (\lambda_1^{\alpha_n} + \lambda_2^{\alpha_n} + \lambda_3^{\alpha_n} - 3) \quad (2.6)$$

$\lambda_i=1,2,3$  sont les élongations principales selon les axes propres. Les constantes matérielles  $\mu_n$  et  $\alpha_n$  sont déterminées par l'ajustement du modèle

hyperélastique aux données expérimentales de la courbe contrainte-déformation, ces constantes sont des valeurs négatives. Toutefois, la fonction de densité d'énergie de déformation calculée à partir de ces constantes doit être positive.

### 2.4.3 Comportement viscoélastique

Les matériaux viscoélastiques se caractérisent par leur dépendance temporelle, ce qui se manifeste à travers les phénomènes de relaxation et de retard observés lorsque ces matériaux sont soumis à des contraintes mécaniques. Des explications approfondies et des interprétations concernant l'origine physique et structurale des propriétés viscoélastiques des polymères sont disponibles dans les travaux d'Aklonis et MacKnight (1983).

La littérature propose une variété de modèles destinés à simuler le comportement viscoélastique des polymères. Parmi ces modèles, on peut citer ceux de *Lodge* (Lodge, 1964), *Christensen* (Christensen, 1980), *K-BKZ* (Nishioka et al., 2000), *CBT* (Bloch et al., 1978), etc. Ces modèles ont été utilisés pour modéliser le comportement mécanique des matériaux thermoplastiques, considérés comme incompressibles et semi-solides à des températures supérieures à la température de transition vitreuse  $T_g$ , comme en témoignent les travaux de (Erchiqui, 2005) et (Erchiqui, 2008).

#### 2.4.3.1. Modèle de K-BKZ

Le modèle K-BKZ a été introduit par Kaye (1962) et Bernstein et al. (1963) afin d'intégrer les effets viscoélastiques non linéaires spécifiques aux polymères. Dans leur proposition, les données concernant la relation contrainte-déformation à diverses vitesses de déformation sont harmonisées avec le modèle K-BKZ, qui a été modifié en incluant une fonction d'amortissement (Wagner, 1976, 1990 ; Papanastasiou et al., 1983). Dans ce modèle, le champ

de contraintes à un moment donné  $t$  est déterminé en tenant compte de l'historique des déformations que le fluide a connues par le passé.

$$\sigma(t) = -P(t)I + \int_{-\infty}^t m(\tau, t) [c(\tau, t)]^{-1} d\tau \quad (2.7)$$

$P$  est la pression hydrostatique,  $I$  est la matrice identité,  $[c]^{-1}$  est le tenseur de Finger,  $m(\tau, t)$  est une fonction non linéaire caractéristique du matériau. La fonction mémoire est donnée par l'expression suivante :

$$m(\tau, t) = \mu(\tau, t)h(I_1, I_2) \quad (2.8)$$

La fonction  $\mu(\tau, t)$  représente la fonction mémoire du matériau, elle est donnée par :

$$h(I_1, I_2) = f \exp(-n_1 \sqrt{I-3}) + (1-f) \exp(-n_2 \sqrt{I-3})^1 \quad (2.9)$$

Avec :

$$I = \alpha I_1 + (1-\alpha)I_2 \text{ avec } 0 \leq \alpha \leq 1 \quad (2.10)$$

Le terme  $\tau_k$  représente le temps de relaxation associé à la rigidité  $g_k$ . La fonction  $h(I_1, I_2)$  représente la fonction d'amortissement du matériau (damping), dépendant des invariants du tenseur de Finger. Plusieurs modèles de la fonction d'amortissement (damping) existent dans la littérature (Wagner, 1976, 1990 ; Papanastasiou et al., 1983).

Les paramètres  $f$ ,  $n_1$  et  $n_2$  sont des constantes matérielles qui peuvent être déterminées par l'utilisation des données expérimentales et numériques d'optimisations.  $\alpha$  est un paramètre dépendant du type de déformation rencontrée dans l'écoulement.

#### 2.4.3.2. Modèle de Lodge

Ce modèle constitutif constitue la base de la plupart des modèles viscoélastiques intégraux. Il est souvent utilisé pour décrire le comportement incompressible des polymères thermoplastiques à l'état liquide. Cependant, les travaux de Erchiqui (Erchiqui et al., 2005) ont montré que ce modèle peut également être utilisé pour les matériaux semi-solides.

Selon ce modèle, la connaissance de l'historique des déformations du matériau est essentielle pour déterminer le tenseur des contraintes de Cauchy ( $\sigma$ ), décrit par l'équation (Équation 2.11) ci-dessous.

$$\boldsymbol{\sigma}(t) = -p(t)\mathbf{I} + \int_{-\infty}^t \sum_{k=1}^n \frac{g_k}{\tau_k} e^{\left(-\frac{t-\tau}{\tau_k}\right)} \mathbf{B}(t, \tau) d\tau \quad (2.11)$$

Où  $p$ ,  $\mathbf{I}$ ,  $\mathbf{B}$ ,  $t$  et  $\tau$  sont respectivement la pression hydrostatique, le tenseur d'identité, le tenseur de déformation des Finger, le temps de rigidité et le temps de relaxation. Les paramètres  $g_k$  et  $\tau_k$  sont respectivement le module de rigidité et le module de relaxation associée au mode  $k$ . Le tenseur  $\mathbf{B}$  est lié au tenseur de gradient de déformation  $\mathbf{F}$  comme indiqué dans l'équation (Équation 2.12) :

$$\mathbf{B}(t, \tau) = [\mathbf{F}^T(t, \tau) \cdot \mathbf{F}(t, \tau)]^{-1} \quad (2.12)$$

#### 2.4.3.3. Modèle de Christensen

Christensen (1980) a formulé le tenseur de contrainte  $\mathbf{S}$  (la deuxième contrainte Piola-Kirchhoff) en le reliant à l'historique du tenseur de gradient des déformations lagrangiennes  $\mathbf{E}$  ( $\tau$ ,  $t$ ) de la manière suivante :

$$S(t) = -P(t)C^{-1} + G_0I + \int_{-\infty}^t G_1(t - \tau) \frac{\partial E(\tau, t)}{\partial \tau} d\tau \quad (2.13)$$

Où :  $G_0$  est le module hyperélastique et  $G_1$  est la fonction relaxation du matériau donné par:

$$G_1 = \sum_k g_k e^{-\left(\frac{t-\tau}{\tau_k}\right)} \quad (2.14)$$

Où  $g_k$  et  $\tau_k$  représentent respectivement le module de rigidité et le temps de relaxation associés au comportement viscoélastique du matériau.

#### 2.4.4 Comportement Viscoélastoplastique

Certains chercheurs, tels que Vantal et al. (1995) ont utilisé une méthodologie analogue à celle employée pour le formage des métaux. Ils ont estimé le comportement des polymères solides en dessous de la température de transition vitreuse à l'aide d'une relation constitutive de type viscoélastoplastique. Cette relation intègre l'effet viscoélastique des polymères durant le thermoformage et se présente comme suit

$$\bar{\sigma} = kp(T)(\bar{\epsilon}, \dot{\bar{\epsilon}}) \quad (2.15)$$

Où  $\bar{\sigma}$ ,  $\bar{\epsilon}$  et  $\dot{\bar{\epsilon}}$  correspondent respectivement aux contraintes effectives, aux déformations effectives et à la vitesse de déformation effective. L'influence de la température sur le comportement du matériau est représentée par la fonction  $kp(T)$ . Une fois passé à l'état caoutchouteux, au-delà de la température de transition vitreuse de  $T_g$ , le comportement du polymère est modélisé par une loi constitutive de type viscoélastique. Les constantes du matériau ont été établies en ajustant le modèle aux données expérimentales obtenues par des tests de traction uniaxiale à différentes températures et vitesses de déformation. Grâce à la méthode des éléments finis et une formulation

lagrangienne mise à jour (considérant les déformations comme petites), la simulation numérique du thermoformage a permis de prévoir efficacement la variation de l'épaisseur le long de la pièce produite (Vantal et al., 1995).

### *2.5 Techniques d'identification des constantes matérielles*

Quant au volet optimisation, en combinaison avec la modélisation et des données issues de l'expérimental, deux approches sont fréquemment utilisées pour l'identification des paramètres viscoélastiques, celle qui utilise des algorithmes des moindres carrés (Erchiqui *et al.*, 2005 ; Verron et al., 1999) et celle qui utilise des algorithmes de type neuronal (F. Erchiqui *et al.*, 2005).

#### 2.5.1 Méthodes des moindres carrés :

Cette approche vise à minimiser la différence entre les résultats de mesures expérimentales et ceux obtenus par simulation numérique. Plusieurs chercheurs l'ont utilisée pour déterminer les paramètres de la loi de comportement en soufflage libre. On cite essentiellement les travaux de Erchiqui (Erchiqui et al., 2005) et (Verron & Marckmann, 2001).

En 2010, Erchiqui et ses collaborateurs ont exploré la caractérisation biaxiale du comportement viscoélastique d'une membrane thermoplastique en matériau ABS (Acrylonitrile Butadiène Styène) en soufflage libre, en utilisant la méthode des moindres carrés.

Pour l'identification des constantes matérielles, ils ont fait appel à une version modifiée de l'algorithme de Levenberg-Marquardt, ce qui a facilité la modélisation du comportement des polymères lors de la simulation numérique en thermoformage (Erchiqui et al., 2010).

### 2.5.2 Méthodes basées sur l'intelligence artificielle IA :

L'Intelligence artificielle (IA) est une branche spécialisée de l'informatique qui cherche à reproduire les capacités de raisonnement et d'action humaines à travers des machines. L'IA englobe des processus de calcul, qu'ils soient numériques ou non numériques. Cette imitation de l'intelligence ne se limite pas à la prise de décisions logiques, mais inclut également la gestion des données incomplètes, l'adaptation aux situations changeantes et l'amélioration continue basée sur l'expérience acquise. L'IA offre un avantage considérable sur les méthodes traditionnelles, notamment dans la modélisation complexe et la prédiction précise des variables quantitatives (Merchant et al., 2023).

Dans le domaine des sciences des matériaux, l'IA a permis des avancées significatives, notamment dans la découverte de nouveaux matériaux, l'optimisation des procédés de fabrication, la modélisation des propriétés des matériaux et l'automatisation de leur caractérisation. Grâce aux algorithmes d'apprentissage automatique, les chercheurs peuvent identifier des structures chimiques et des compositions optimales à partir d'immenses bases de données. Par exemple, Merchant et al. (2023) ont démontré que l'utilisation de réseaux de neurones graphiques permettait d'analyser et de générer plus de 2,2 millions de nouvelles structures cristallines, dont 380 000 matériaux stables, surpassant les approches traditionnelles basées sur l'expérimentation manuelle (Merchant et al., 2023).

Dans la modélisation des propriétés des matériaux, des modèles d'apprentissage profond sont utilisés pour prédire le comportement mécanique, thermique et chimique des matériaux sous différentes conditions. Zhao et al. (2021) ont exploré l'utilisation des réseaux neuronaux génératifs pour simuler les propriétés structurelles des cristaux avant même leur synthèse expérimentale, ce qui réduit considérablement le temps et les coûts de

développement (Zhao et al., 2021). Cette approche est particulièrement efficace dans la science des matériaux avancés, où les tests en laboratoire peuvent être longs et coûteux.

Grâce à ces applications, l'IA joue un rôle clé dans l'innovation des matériaux de nouvelle génération, réduisant considérablement le temps et les coûts de développement tout en améliorant les performances des matériaux existants.

### **3. CHAPITRE 3 : LES RÉSEAUX DE NEURONES ARTIFICIELS : APPROCHES ET ALGORITHMES**

#### *3.1 Introduction*

Ces dernières années, un progrès technologique significatif a été réalisé dans divers secteurs, créant une demande accrue pour le contrôle et la gestion de systèmes complexes engendrant d'importants calculs et une multitude de variables. D'où l'impératif de développer de nouvelles approches permettant une gestion plus flexible et moins onéreuse en termes de temps de calcul et de manipulation des variables, dont le nombre, ne cesse de croître. Ainsi, l'intérêt s'est de plus en plus porté sur des systèmes capables d'apprendre, en utilisant des modélisations des neurones biologiques (Personnaz & Rivals, 2003).

Les réseaux de neurones artificiels ont fait l'objet de recherches pendant de nombreuses années, dans le but de reproduire les performances du cerveau des êtres vivants. Inspirés des réseaux neurobiologiques, de nombreux modèles de réseaux de neurones artificiels ont été créés, chacun étant particulièrement adapté à une application spécifique (classification, reconnaissance, contrôle, etc.). Cependant, leur utilisation demeure restreinte à certaines applications, et de nombreux domaines restent encore inexplorés par les réseaux de neurones, comme par exemple la planification. En effet, les meilleurs systèmes basés sur des réseaux de neurones sont encore loin de reproduire des performances comparables à celles de l'être humain.

### *3.2 Historique et Évolution des Réseaux de Neurones artificiels*

Dès 1890, W. James, un célèbre psychologue américain, introduit le concept de mémoire associative et propose une loi de fonctionnement pour l'apprentissage sur les réseaux de neurones, connue plus tard sous le nom de loi de Hebb.

En 1943, J. McCulloch et W. Pitts modélisent le neurone biologique en introduisant un neurone au comportement binaire. Ils démontrent pour la première fois que des réseaux de neurones formels simples peuvent réaliser des fonctions logiques, arithmétiques et symboliques complexes, du moins au niveau théorique (McCulloch & Pitts, 1943).

En 1949, D. Hebb, physiologiste américain, explique le conditionnement chez l'animal par les propriétés des neurones eux-mêmes. Par exemple, un conditionnement pavlovien, comme nourrir un chien à la même heure chaque jour, peut entraîner la sécrétion de salive chez l'animal à cette heure précise, même en l'absence de nourriture. La loi de modification des propriétés des connexions entre neurones qu'il propose explique en partie ces résultats expérimentaux (Hebb, 1949).

En 1957, F. Rosenblatt développe le modèle du Perceptron. Il construit le premier neuroordinateur basé sur ce modèle et l'applique à la reconnaissance de formes. En 1960, B. Widrow, un automaticien, développe le modèle Adaline (Linear Adaptive Element), similaire au Perceptron, mais avec une loi d'apprentissage différente (Rosenblatt, 1957).

En 1969, M. Minsky et S. Papert publient un ouvrage soulignant les limitations théoriques du Perceptron, notamment son incapacité à traiter des problèmes non linéaires. Ils généralisent ces limitations à tous les modèles de réseaux de neurones artificiels, ce qui entraîne un abandon financier des recherches dans

ce domaine, surtout aux États-Unis, au profit des systèmes à bases de règles (Minsky & Papert, 1969).

En 1982, J.J. Hopfield, un physicien reconnu, ravive l'intérêt pour les réseaux de neurones artificiels en mettant en avant l'isomorphisme de son modèle avec le modèle d'Ising (modèle des verres de spins). Cette idée attire de nombreux physiciens vers les réseaux de neurones artificiels (Hopfield, 1982).

En 1983, la machine de Boltzmann émerge comme le premier modèle capable de traiter de manière satisfaisante les limitations du Perceptron, bien que sa mise en pratique soit difficile en raison de la lenteur de la convergence de l'algorithme (Hinton & Sejnowski, 1983).

En 1985, les premières expérimentations sur la rétropropagation du gradient émergent. Cette méthode sera formalisée et popularisée l'année suivante par Rumelhart, Hinton et Williams dans un article devenu fondamental (Rumelhart, Hinton, & Williams, 1986).

Les biologistes estiment que le système nerveux comporte plus de 100 milliards de neurones interconnectés. Bien que les neurones ne soient pas tous identiques, leur morphologie et certaines caractéristiques fonctionnelles permettent de les classer en quelques grandes catégories. Il est important de noter que les neurones n'ont pas tous un comportement similaire selon leur position dans le cerveau, car ils jouent des rôles distincts en fonction de leur connectivité et de leur neurotransmission (Sigeru et al., 1996).

#### a) Dendrites

Chaque neurone possède une arborescence de dendrites autour du corps cellulaire, permettant de capter les signaux provenant de l'extérieur.

## b) Corps cellulaire

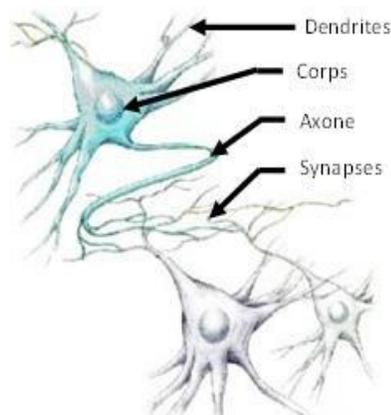
La forme du corps cellulaire varie en fonction de sa position dans le cerveau, pouvant être pyramidale ou sphérique. Il contient le noyau du neurone et réalise les transformations biochimiques nécessaires à la survie du neurone.

## c) Axone

L'axone est une fibre nerveuse qui transmet les signaux émis par le neurone. En général, un axone est plus long que les dendrites et se ramifie à son extrémité pour communiquer avec d'autres neurones.

## d) Synapses

Les synapses sont des jonctions entre deux neurones, essentielles au fonctionnement du système nerveux.



**Figure 3.1**

### **Schéma d'un neurone biologique**

Source : <https://faculty.washington.edu/chudler/neurok.html>

### 3.3 *Le neurone formel*

#### 3.3.1 Description de réseau de neurones artificiels

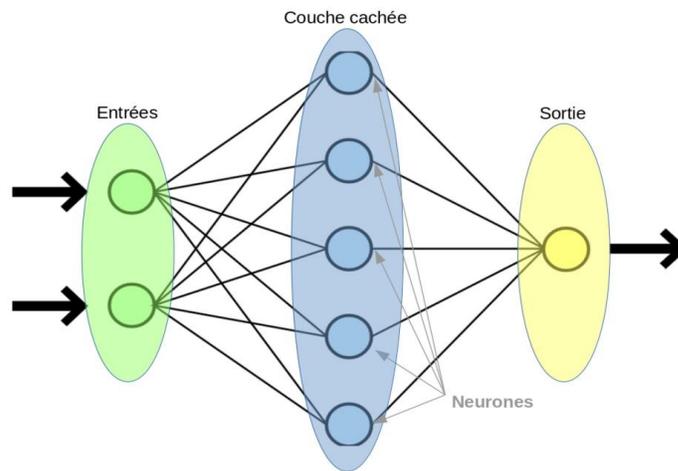
Le réseau neuronal artificiel (RNA) est un modèle mathématique s'inspirant du fonctionnement des réseaux de neurones biologiques. Conçu pour reproduire de manière intelligente la façon dont le cerveau humain traite l'information et apprend par l'expérience, il constitue un système adaptatif dont la structure évolue au fil de l'apprentissage. Cette capacité lui permet de réagir de manière appropriée à de nouvelles situations, en s'appuyant sur les connaissances acquises lors de la phase d'entraînement (Dillon & Niebur, 1996).

Les réseaux neuronaux artificiels (RNA) ne sont pas soutenus par une base de connaissances préprogrammée à la manière des systèmes experts. Au contraire, ils apprennent en adaptant leurs poids et biais de nœud en réponse à des entrées spécifiques et à la sortie requise. Ainsi, on peut dire que le RNA traite les informations en se basant sur des exemples préexistants d'apprentissage. Sous cet angle, les RNA peuvent être considérés comme les représentants les plus caractéristiques de l'intelligence artificielle.

Ces systèmes adaptatifs modifient leur structure durant l'apprentissage pour répondre aux nouvelles situations en s'appuyant sur les expériences antérieures. Leur aptitude à appréhender des relations complexes et non linéaires entre les entrées et les sorties a incité les chercheurs à les appliquer dans divers domaines pour résoudre des problèmes complexes.

Un RNA se compose de neurones interconnectés formant un graphe orienté, disposés en couches. Chaque neurone reçoit des informations de la couche précédente, les combine en utilisant des pondérations (poids) notées  $w_{i,j}(k)$ , et possède un seuil d'activation (biais)  $b_k(i)$ . La sortie d'un neurone est fortement influencée par les variations autour de ce seuil. Une description plus

détaillée est fournie par (Dillon & Niebur, 1996 ; Suzuki, 2013). La figure 3.2 montre la structure d'un RNA à propagation avant, également appelée perceptron.



**Figure 3.2**  
**Illustration d'un réseau de neurones feed-forward.**

Source : <http://www.natural-solutions.eu/>

L'un des principaux défis associés aux réseaux de neurones artificiels (RNA) réside dans le fait qu'il n'existe pas de méthode standardisée pour déterminer le nombre de couches cachées et de neurones par couche. Ils se distinguent par leur aptitude à effectuer des calculs à partir des données d'entrée observées pour créer une cartographie précise de la relation entre les entrées et les sorties.

Une avancée cruciale dans le développement des RNA a été la conception de l'algorithme pour l'apprentissage adaptatif du réseau. L'algorithme fondamental, connu sous le nom de méthode de rétropropagation de l'erreur, ajuste les poids des neurones au fil des itérations pour minimiser l'erreur globale entre la sortie actuelle et la sortie attendue du réseau.

Les RNA sont utilisés dans des applications variées telles que la reconnaissance des images, le traitement du langage naturel, les systèmes de recommandation et la prédiction des données. Malgré leur puissance, ils nécessitent de grandes quantités de données et des ressources de calcul importantes pour l'entraînement, et sont sujets à des problèmes de surajustement si le modèle est trop complexe par rapport aux données disponibles.

### 3.3.2 Réseau de neurones feedforward

Plusieurs types et architectures de réseaux neuronaux artificiels existent, parmi lesquels on peut mentionner les réseaux récurrents Elman (Ekici et al., 2009).

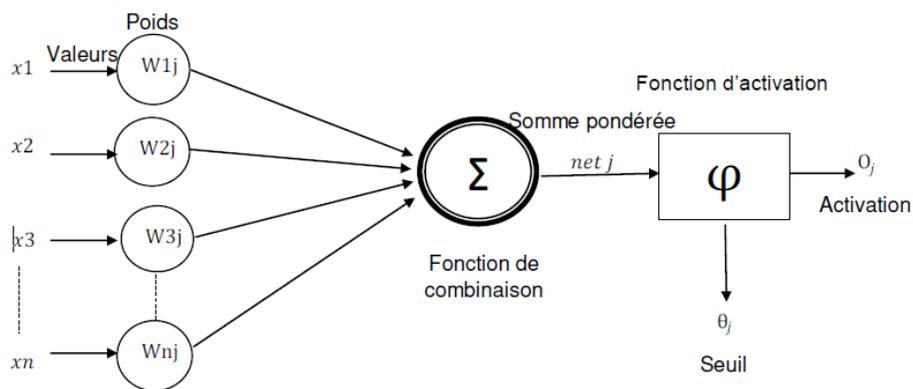
Les réseaux de neurones de type feedforward sont cependant les plus couramment utilisés en raison de leur simplicité et facilité de mise en œuvre. Dans ces réseaux, l'information circule exclusivement dans une direction : des nœuds d'entrée aux nœuds de sortie, en passant par les couches cachées. Contrairement aux réseaux récurrents, les réseaux feedforward n'ont pas de boucles ou de cycles dans leur structure, ce qui facilite leur utilisation (Toufik & Seyeddine, 2017).

Chaque neurone dans une couche est connecté à chaque neurone de la couche suivante, et ces connexions sont pondérées pour ajuster l'importance des entrées reçues. Les neurones appliquent ensuite une fonction d'activation à la somme pondérée des entrées pour produire leur sortie.

L'apprentissage dans un réseau feedforward se fait généralement par rétropropagation, où les poids des connexions sont ajustés pour minimiser l'erreur entre la sortie produite et la sortie désirée.

En plus de la sélection du type de réseau neuronal, le choix d'une fonction d'erreur et d'une fonction d'activation pour les neurones est également crucial. Ces choix sont généralement influencés par le type de données traitées par le réseau.

Grâce à leur simplicité et leur capacité à modéliser des relations complexes entre les entrées et les sorties, les réseaux feedforward sont largement utilisés dans des applications telles que la classification d'images, la reconnaissance vocale et la prédiction des résultats (Toufik & Seyeddine, 2017).



**Figure 3.3**  
**La structure de base d'un neurone**

### 3.3.1 Algorithme « error back propagation »

La technique de rétropropagation a été développée en généralisant la règle d'apprentissage de Windrow-Hoff aux réseaux de neurones multicouches et aux fonctions de transfert non linéaires différentiables. Elle utilise des vecteurs d'entrée et des vecteurs cibles correspondants pour entraîner un réseau jusqu'à ce qu'il puisse approximer une fonction qui lie des vecteurs d'entrée à des vecteurs de sortie spécifiques.

Pour chaque itération, l'erreur est calculée en commençant par la dernière étape, puis l'erreur calculée est propagée à rebours dans le réseau. Les poids initiaux du réseau neuronal sont choisis aléatoirement pour l'algorithme de rétropropagation. Après chaque étape, ces poids sont mis à jour et le processus est répété pour l'ensemble des paires d'entrées-sortie disponibles dans le jeu de données d'entraînement fourni par le développeur. Chaque couche du réseau suit ce processus dans l'ordre inverse. L'algorithme utilise la méthode de l'erreur quadratique moyenne pour calculer l'erreur à chaque étape (Dillon & Niebur, 1996).

Bien que l'algorithme de rétropropagation ait été mis en œuvre de différentes façons, l'idée fondamentale reste la même. La principale variation entre ces implémentations concerne la méthode utilisée pour calculer les poids mis à jour de manière itérative lors de la propagation inverse à travers les couches. Le nombre total d'itérations nécessaires pour obtenir une convergence satisfaisante dépend de plusieurs facteurs, notamment la taille du réseau de neurones, la structure du réseau, le problème étudié, la stratégie d'apprentissage employée et la taille du jeu de données d'entraînement.

#### *3.4 Fonction de transfert/activation*

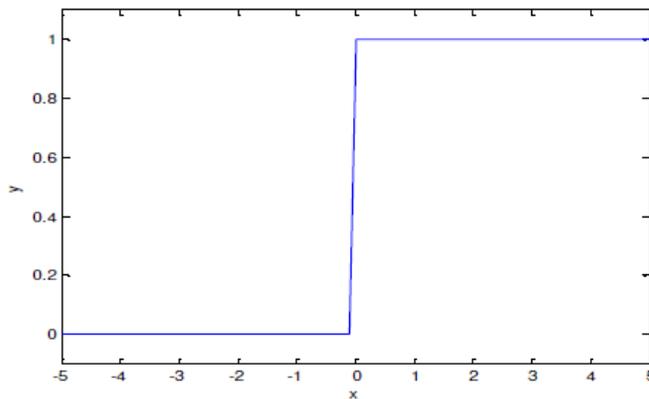
Dans le domaine des réseaux de neurones artificiels, la fonction d'activation est une fonction mathématique appliquée au signal de sortie d'un neurone artificiel. Une fois qu'un certain seuil est atteint, le neurone produit une réponse. Souvent, cette fonction d'activation est non linéaire. Il est clair que la fonction d'activation joue un rôle crucial dans le comportement du neurone, car elle retourne une valeur représentative de l'activation du neurone. Cette fonction prend en compte la somme pondérée des entrées ainsi que le seuil d'activation. La nature de cette fonction varie selon le réseau (Toufik & Seyeddine, 2017).

Il existe divers types de fonctions d'activation, parmi lesquelles :

a) Fonction binaire à seuil :

Fonction à seuil montrée par la figure 3.4 et définie par :

$$h(x) = \begin{cases} 1 & \text{si } x > 0 \\ 0 & \text{sinon} \end{cases} \quad (3.1)$$



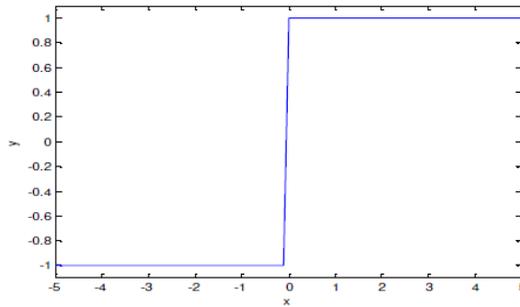
**Figure 3.4**  
**Fonction binaire à seuil.**

b) Fonction signe :

La fonction signe, montrée par la figure 3.5, et définie par :

$$sgn(x) = \begin{cases} 1 & \text{si } x > 0 \\ -1 & \text{sinon} \end{cases} \quad (3.2)$$

Le seuil introduit une non-linéarité dans le comportement du neurone, cependant, il limite la gamme des réponses possibles à deux valeurs.

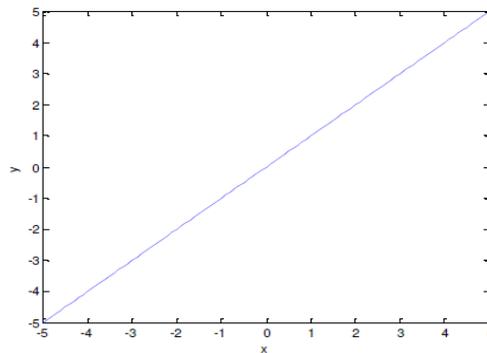


**Figure 3.5**  
**Fonction signe**

c) Fonction linéaire :

C'est l'une des fonctions d'activations les plus simples, cette fonction est représentée par la figure 3.6, sa fonction est définie par :

$$f(x) = x \quad (3.3)$$



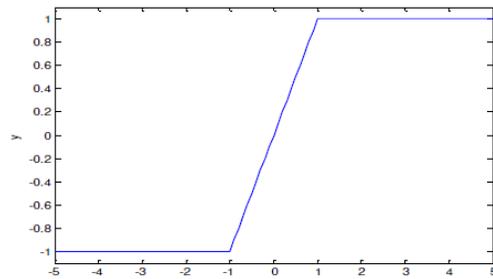
**Figure 3.6**  
**Fonction linéaire**

a) Fonction linéaire à seuil ou multiseuils :

Cette fonction représente un compromis entre la fonction linéaire et la fonction seuil.

$$h(x) = \begin{cases} x & \text{si } x \in [u, v] \\ v & \text{si } x < v \\ u & \text{si } x > v \end{cases} \quad (3.4)$$

Son graphe est illustré par la figure 3.7 : entre ses deux points de saturation, elle offre au neurone une gamme de réponses possibles. En modulant la pente de la partie linéaire, on peut ajuster l'étendue de la réponse du neurone.



**Figure 3.7**  
**Fonction linéaire à seuil ou multiseuils.**

b) Fonction sigmoïdale :

Elle est l'équivalent continu de la fonction linéaire représentée à la figure 3.8.

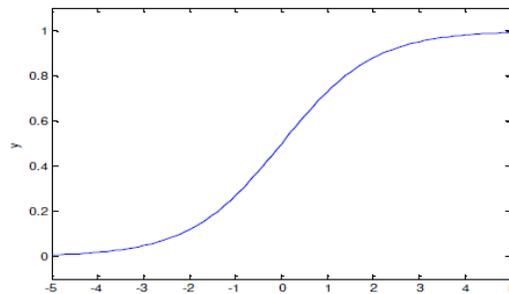
Étant continue, elle est également dérivable, avec une dérivée facile à calculer.

La fonction log sigmoïde est définie par :

$$\text{logsig}(X) = \frac{1}{1+e^{-x}} \quad (3.5)$$

Et sa dérivée est :

$$\frac{d}{dx}(\text{logsig}(X)) = \text{logsig}(X)(1 - \text{logsig}(X)) \quad (3.6)$$



**Figure 3.8**  
**Fonction sigmoïde.**

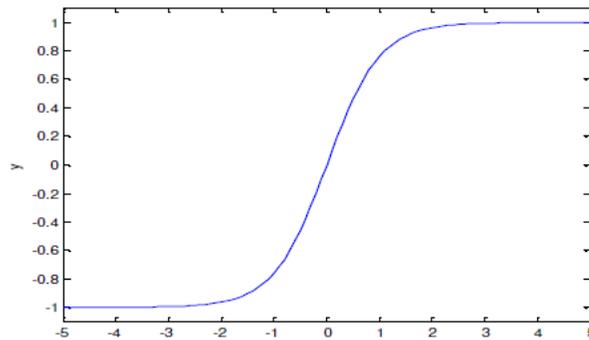
c) Fonction tangente sigmoïde :

La fonction tangente sigmoïde est celle montrée par la figure 3.9. Elle est définie par :

$$tansig(X) = \frac{2}{(1+e^{-2x})} - 1 \quad (3.7)$$

Et sa dérivée est définie comme suit :

$$\frac{d}{dx}(tansig(X)) = \frac{4e^{-2x}}{(e^{-2x}+1)^2} \quad (3.8)$$



**Figure 3.9**  
**Fonction tangente sigmoïde.**

### 3.5 Apprentissage des réseaux de neurones

#### 3.5.1 Définition

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle le comportement du réseau est ajusté jusqu'à atteindre le comportement désiré. Ce processus repose sur l'utilisation d'exemples d'apprentissage. Dans les algorithmes actuels, ce sont les poids des connexions qui sont modifiés pendant l'apprentissage (Toufik & Seyedine, 2017).

#### 3.5.2 Protocoles d'apprentissage

Presque tous les réseaux de neurones suivent un protocole d'apprentissage commun, qui comprend quatre étapes :

1. Initialisation des poids synaptiques : Les poids sont initialisés avec de petites valeurs aléatoires.
2. Présentation de l'exemple d'entrée et propagation de l'activation des neurones : L'exemple d'entrée est présenté au réseau, et l'activation se propage à travers les neurones.

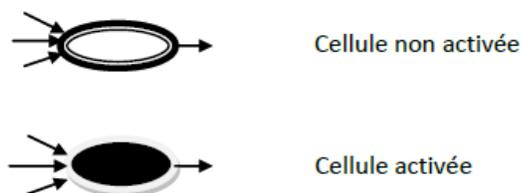
3. Calcul de l'erreur : Dans le cas d'un apprentissage supervisé, cette erreur est calculée en fonction de la différence entre l'activation des neurones et la sortie désirée.
4. Calcul du vecteur de correction : À partir des valeurs des erreurs, un vecteur de correction est calculé et utilisé pour ajuster les poids synaptiques.

### 3.5.3 Règles d'apprentissage

#### a) La règle de Hebb :

La règle de Hebb est le premier mécanisme proposé pour l'évolution des synapses. Son interprétation pour les réseaux de neurones artificiels est la suivante : lorsque deux neurones connectés sont activés simultanément, la connexion entre eux est renforcée ; sinon, elle reste inchangée. En d'autres termes, le poids  $W_{ij}$  d'une connexion entre un neurone  $i$  et un neurone  $j$  augmente lorsque les deux neurones sont activés en même temps, et il reste inchangé dans le cas contraire (Hebb, 1949).

Si nous prenons, à titre d'exemple, les conventions suivantes :



**Figure 3.10**  
**Les cellules de RNA.**

Ceci se traduit par : lorsque la cellule émettrice et la cellule réceptrice s'activent en même temps, il faut augmenter le poids de cette connexion lors de

l'apprentissage. La connexion entre ces deux cellules devient alors très forte. En revanche, si la cellule émettrice s'active sans que la cellule réceptrice ne le soit, ou si la cellule réceptrice s'active alors que la cellule émettrice ne l'était pas, cela indique que la connexion entre les deux n'est pas significative pour le comportement de la cellule réceptrice. Par conséquent, pendant la phase d'apprentissage, on peut laisser un poids faible à cette connexion (Hebb, 1949).

En se basant sur ce principe, Hebb a donné la règle d'apprentissage suivante :

$$W_{ij}(t + \delta t) = W_{ij} + \mu A_i A_j \quad (3,9)$$

b) La règle de Widrow-Hoff :

La règle d'apprentissage de Widrow-Hoff, également connue sous le nom de règle des moindres carrés (LMS, Least Mean Squares), est une méthode d'apprentissage supervisé qui se base sur la correction des erreurs observées en sortie. Son objectif est de minimiser une fonction de coût, définie par l'erreur quadratique moyenne. Pour un ensemble d'apprentissages contenant Q pair entré/sorti désiré  $\{(X^{(q)}/T^{(q)})\}, q=1\dots Q$ , où  $X^{(q)}$  et  $T^{(q)}$  représentent respectivement la  $q^{\text{ème}}$  entrée et la  $q^{\text{ème}}$  sortie désirée, l'erreur ( $e(r)$ ) à l'itération  $r$  est donnée par :

$$e(r) = T(r) - Y(r) \quad (3.10)$$

Où : est la sortie calculée du réseau. La fonction coût est :

$$f(X) = e(r^2) \quad (3.11)$$

L'apprentissage selon la règle LMS consiste à calculer le gradient à chaque présentation d'un exemple d'apprentissage.

$$\Delta W_{ij}(t) = -\eta \nabla F(X) \quad (3.12)$$

$$= \eta \frac{\partial e^2(r)}{\partial W_{ij}} \quad (3.13)$$

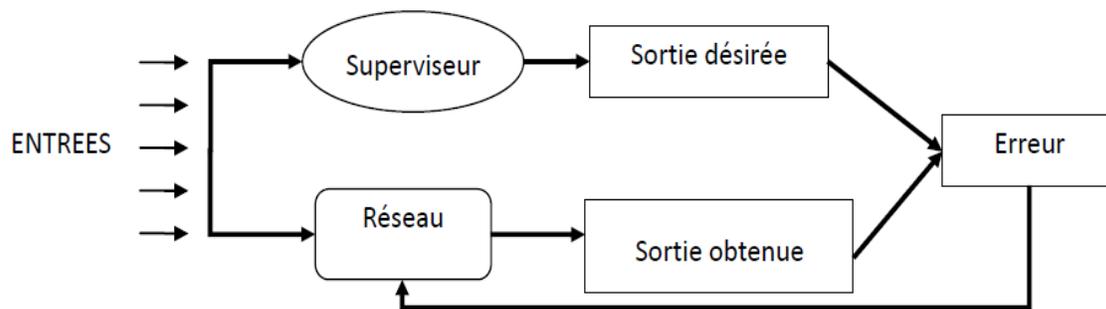
### 3.6 Les types d'apprentissage :

Les techniques d'apprentissage se subdivisent en trois grandes familles :

#### a) Apprentissage supervisé :

Pour ce type d'apprentissage (comme le perceptron, l'Adaline, etc.), le réseau doit être capable de reconnaître qu'il a commis une erreur et doit connaître la réponse qu'il aurait dû fournir. Lorsqu'un stimulus est présenté à la couche d'entrée du réseau, la réponse obtenue est comparée à la réponse désirée. Les modifications et ajustements des poids sont alors déterminés en fonction de l'erreur commise par le réseau. En général, les règles d'apprentissage supervisé reposent sur des formes de descente du gradient.

L'apprentissage supervisé nécessite donc la définition d'une base d'exemples d'apprentissage représentative. Chaque exemple présenté au réseau est un couple (entrée, sortie désirée). La minimisation de l'erreur entre la valeur de sortie et la valeur souhaitée repose sur le principe de l'erreur quadratique (Toufik & Seyeddine, 2017).



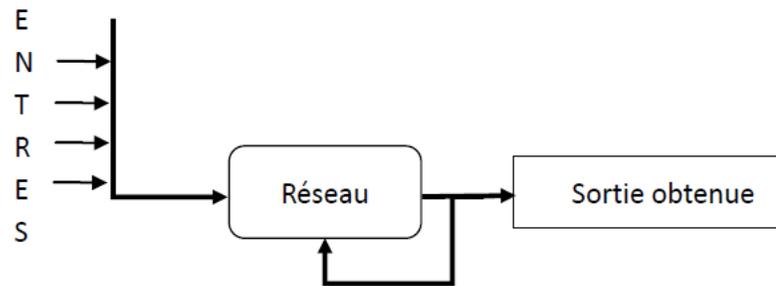
**Figure 3.11**  
**Schéma d'apprentissage supervisé.**

b) Apprentissage semi-supervisé :

L'apprentissage semi-supervisé suppose qu'un comportement de référence précis n'est pas disponible. Cependant, il est possible d'obtenir des indications qualitatives (correct/incorrect) sur les performances du réseau.

c) Apprentissage non supervisé :

Pour ce type d'apprentissage, l'objectif est d'atteindre un ensemble de poids synaptiques qui permettent un comportement optimal du réseau. Les modifications et ajustements des poids sont réalisés en fonction d'un critère interne, indépendant de la relation entre le comportement du réseau et la tâche à accomplir.



**Figure 3.12**  
Schéma d'apprentissage non supervisé.

### 3.7 Avantages et inconvénients des réseaux de neurones :

#### 3.7.1 Avantages des réseaux de neurones :

- Capacité à modéliser toute fonction, qu'elle soit linéaire ou non, simple ou complexe.
- Possibilité d'apprendre à partir d'exemples représentatifs.
- Robustesse face au bruit ou à l'absence de fiabilité des données.
- Utilisation simplifiée, nécessitant beaucoup moins d'efforts manuels que l'analyse statistique traditionnelle. Ne requiert pas de compétences avancées en mathématiques, informatique ou statistiques.
- Performance acceptable même avec une quantité limitée de données. Pour les débutants, le concept d'apprentissage est plus accessible que les complexités des statistiques multivariées.

#### 3.7.2 Inconvénient des réseaux de neurones :

- Absence de méthode systématique pour déterminer la meilleure topologie du réseau et le nombre de neurones dans la (ou les) couche(s) cachée(s).

- Sélection des valeurs initiales des poids du réseau et ajustement du taux d'apprentissage, qui influencent considérablement la vitesse de convergence.
- Problème de surapprentissage (apprentissage au détriment de la généralisation).
- La connaissance acquise par un réseau de neurones est encapsulée dans les valeurs des poids, ce qui les rend difficilement compréhensibles pour l'utilisateur.

### *3.8 Extraction des données :*

La simulation du modèle RNA pour la prédiction des résultats nécessite des données suffisantes pour l'entraînement, les tests et les vérifications. Ces données sont constituées des valeurs d'entrée et des valeurs de sortie cible.

Des données aussi volumineuses sont collectées précédemment sur les échantillons de HDPE renforcés avec des particules de sciure de bois au Laboratoire des bioplastiques de l'Université du Québec en Abitibi-Témiscamingue. En effet, des tests rhéologiques sont réalisés en utilisant le rhéomètre RS75 (PP20, Haake), équipé d'un contrôleur de température TC500. Les échantillons fondus ont été exposés à un balayage de fréquence allant de 0,1 à 100 Hz, sous contrôle de déformation dans la zone linéaire, avec un taux de déformation fixe à 0,01 % pour tous les composites. L'introduction de particules de bois dans la matrice polymère, ainsi que la modification chimique de l'interface par un agent de couplage (PE-g-MA), modifie généralement le comportement rhéologique des composés pendant leur fabrication, comme le montrent les travaux de Burgstaller (2007), Lamnawar (2008) et Zhang (2012).

Des tests dynamiques de cisaillement oscillatoire à faible amplitude ont été effectués pour caractériser les fonctions rhéologiques des biocomposites. Cette méthode a permis de mesurer les propriétés dynamiques des composites, notamment les modules dynamiques  $G'$  et  $G''$ . Le module d'élasticité dynamique  $G'$  mesure l'énergie élastique stockée dans le matériau déformé, une énergie réversible qui permet au matériau de retrouver partiellement sa forme initiale après déformation. Les modules dynamiques  $G''$  indiquent les pertes, correspondant à l'énergie dissipée par les matériaux en raison de l'interaction entre les chaînes moléculaires des polymères en cisaillement. À partir des résultats expérimentaux, on constate que les composites se comportent de manière plus visqueuse à basse fréquence et plus élastique à haute fréquence. À un certain point, appelé fréquence de croisement, ils sont aussi élastiques que visqueux. Par ailleurs, les modules dynamiques de stockage ( $G'$ ) et de perte ( $G''$ ) augmentent généralement avec la concentration en particules de bois.

### *3.9 Conclusion :*

En conclusion, les réseaux de neurones constituent une technologie à la fois puissante et polyvalente, capable de modéliser des fonctions complexes et de gérer des données bruyantes ou incomplètes. Leur aptitude à apprendre à partir d'exemples et leur simplicité d'utilisation relative les rendent accessibles même aux débutants, avec des performances satisfaisantes même en présence de données limitées. Néanmoins, ils comportent des défis importants, tels que l'absence de méthode systématique pour définir leur architecture optimale, la sensibilité aux valeurs initiales des poids et aux taux d'apprentissage, ainsi que le risque de surapprentissage. En outre, la nature opaque des poids rend difficile l'interprétation des connaissances acquises. Malgré ces limitations, les réseaux de neurones demeurent un outil précieux.

## **4. CHAPITRE 4 : IDENTIFICATION ET CARACTÉRISATION DE L'HDPE BRUTE PAR RNA**

### *4.1 Introduction*

Dans ce chapitre, nous nous concentrerons sur l'application des réseaux de neurones artificiels (RNA) feedforward pour l'identification et la caractérisation de l'HDPE brut. L'objectif est d'optimiser l'utilisation de ces réseaux pour prédire avec précision les propriétés de l'HDPE avant de les appliquer aux biocomposites contenant différents pourcentages de sciure de bois.

Pour ce faire, nous commencerons par tester diverses architectures de RNA afin de déterminer la combinaison optimale de couches cachées et de neurones par couche. Ces tests permettront d'identifier la configuration la plus efficace pour obtenir la précision souhaitée. Une fois la meilleure architecture établie, elle sera utilisée dans le chapitre suivant pour prédire directement les propriétés des biocomposites à base d'HDPE et de sciure de bois. Cette approche progressive garantit que les modèles sont rigoureusement validés et capables de fournir des résultats fiables pour des matériaux composites complexes.

### *4.2 Les démarches suivies*

Les réseaux de neurones sont une méthode de modélisation puissante qui peut être utilisée pour caractériser les biocomposites. Les biocomposites sont des matériaux qui sont fabriqués à partir de fibres naturelles, telles que la fibre de bois, et de résines synthétiques. La caractérisation de ces matériaux est importante, car elle permet de déterminer leurs propriétés physiques et mécaniques.

Pour caractériser les biocomposites à l'aide de réseaux de neurones, il est généralement nécessaire de collecter des données expérimentales. Ces

données sont ensuite utilisées pour tester un réseau de neurones après l'entraînement par les valeurs théoriques à prédire les propriétés des biocomposites à partir de leurs caractéristiques.

Le processus de modélisation à l'aide de réseaux de neurones implique généralement les étapes suivantes :

1. Collecte des données : Les données théoriques pour les paramètres rhéologiques  $G'$  (module de stockage) et  $G''$  (module de perte) seront calculées en utilisant les formules spécifiques ci-dessous :

$$G'(\omega) = \sum_{i=1}^N \frac{g_i \tau_i^2 \omega^2}{1 + \tau_i^2 \omega^2} \quad \text{et} \quad G''(\omega) = \sum_{i=1}^N \frac{g_i \tau_i \omega}{1 + \tau_i^2 \omega^2} \quad (4.1)$$

Avec :

$g_i$  : est la constante de rigidité associée au mode  $i$

$\tau_i$  : est le temps de relaxation associé au mode  $i$

$\omega$  : est la fréquence.

La partie des tests sera réalisée à partir des valeurs expérimentales de  $G'_{\text{exp}}$  et  $G''_{\text{exp}}$  collectées à partir des tests rhéologiques.

2. Préparation des données : Les données sont divisées en trois ensembles : un ensemble d'entraînement pour ajuster les paramètres du modèle, un ensemble de validation pour optimiser le modèle et prévenir le surapprentissage, et un ensemble de tests pour évaluer les performances finales du modèle.
3. Tests pour déterminer la meilleure architecture : Différentes configurations de réseaux de neurones (RNA) sont testées pour déterminer celle qui offre

la meilleure précision. Les valeurs expérimentales de  $G'_{exp}$  et  $G''_{exp}$  sont utilisées pour prédire les  $g_i$ , afin d'identifier la configuration de réseau offrant la meilleure performance en termes de prédiction des constantes de rigidité.

4. Construction du modèle de réseau de neurones : Une fois la meilleure architecture identifiée, le modèle est construit en configurant le nombre de couches cachées, le nombre de neurones par couche, ainsi que les fonctions d'activation les plus adaptées.
5. Entraînement du réseau de neurones : Le modèle de réseau de neurones est entraîné en ajustant les poids et les biais à chaque itération, en utilisant les données théoriques de  $G'$  et  $G''$ . L'objectif est de minimiser l'erreur entre les valeurs prédictives du modèle et les valeurs théoriques attendues.
6. Validation et prédiction de  $g_i$  : Une fois le modèle entraîné et validé, la meilleure architecture est utilisée pour prédire les valeurs des  $g_i$  pour les différents pourcentages de sciure de bois + HDPE à partir des données expérimentales  $G'_{exp}$  et  $G''_{exp}$ . Ces valeurs prédites de  $g_i$  sont ensuite comparées aux valeurs théoriques des  $g_i$ , issues de la base de données afin de vérifier la précision du modèle.
7. Calcul de  $G'$  et  $G''$  à partir des valeurs prédites : Les valeurs prédites de  $g_i$  sont ensuite réintroduites dans les équations de calcul de  $G'$  et  $G''$ , en maintenant les mêmes fréquences  $\omega$  et les mêmes temps de relaxation  $\tau_i$  que ceux utilisés dans la base de données. Cela permet de calculer  $G'_{th}$  et  $G''_{th}$ , les modules théoriques recalculés à partir des  $g_i$  prédits.
8. Comparaison des résultats : Les valeurs recalculées  $G'_{th}$  et  $G''_{th}$  sont comparées non seulement aux valeurs théoriques de la base de données, mais aussi aux valeurs expérimentales  $G'_{exp}$  et  $G''_{exp}$  obtenues lors des tests.

Ce processus détaillé permet de développer un modèle de réseau de neurones capable de prédire les paramètres viscoélastiques des biocomposites, en s'appuyant sur des données théoriques et expérimentales pour assurer une précision optimale. Les comparaisons finales permettent de valider le modèle et de vérifier sa capacité à être utilisé pour d'autres compositions de biocomposites, telles que l'HDPE mélangé à divers pourcentages de sciure de bois.

#### *4.3 Dataset et entraînement des RNAs*

Comme mentionné précédemment, la base de données a été élaborée à partir de calculs théoriques. Un ensemble de données comprenant 100 valeurs a été constitué et utilisé pour développer les différents modèles de réseaux de neurones. Nous avons utilisé un réseau de neurones à rétropropagation pour la prédiction des résultats, s'entraînant à partir des valeurs théoriques et ajustant les poids de la couche d'entrée jusqu'à minimiser l'erreur quadratique moyenne (MSE). L'ensemble de données a été subdivisé en trois sous-ensembles : 70 % pour l'entraînement, 15 % pour la validation, et 15 % pour le test. La phase d'entraînement permet au réseau d'apprendre à partir des données en ajustant ses poids, tandis que la phase de validation offre une évaluation non biaisée de l'ajustement du modèle tout en ajustant les hyperparamètres. L'ensemble de tests fournit une évaluation impartiale de l'ajustement final du modèle sans intervenir dans le processus d'entraînement. Pour valider et fiabiliser notre travail, nous avons ajouté une étape de test avec des valeurs expérimentales, garantissant ainsi la précision et la robustesse des prédictions du modèle.

#### 4.4 Algorithme de Prédiction avec RNA

- Entrées : Mesures théoriques des paramètres rhéologiques  $G'_{th}$ ,  $G''_{th}$  et  $\omega$
- Sorties : Prédiction des paramètres  $g_i$
- Étape 0 : Démarrer, initialisation  $t=0$ .
- Étape 1 : Prendre les valeurs d'entrée :  $G'_{th}$ ,  $G''_{th}$  et  $\omega$ .
- Étape 2 : Appliquer les prétraitements nécessaires aux valeurs d'entrée.
- Étape 3 : Diviser les données en ensembles d'entraînement, de validation et de tests.
- Étape 4 : Transmettre les caractéristiques au modèle de réseau de neurones artificiel et obtenir les prédictions des paramètres  $g_i$ .
- Étape 5 : Si les prédictions de  $g_i$  sont invalides ou incohérentes, revenir à l'étape 1 et répéter le processus. Sinon, passer à l'étape suivante.
- Étape 6 : Tester en introduisant les valeurs expérimentales  $G'_{exp}$  et  $G''_{exp}$  pour prédire  $g_i$  avec le modèle validé
- Étape 6 : Utiliser les valeurs prédites de  $g_i$  pour calculer les valeurs théoriques de  $G'$  et  $G''$  en utilisant les formules dans l'équation 4.1
- Étape 7 : Comparer les valeurs calculées de  $G'$  et  $G''$  avec les valeurs expérimentales et les valeurs théoriques initiales pour valider la précision des prédictions.
- Étape 8 : Fin.

Cet algorithme assure que les modèles RNA sont testés de manière rigoureuse en utilisant des valeurs expérimentales pour prédire les paramètres  $g_i$ , qui sont ensuite validés par des comparaisons avec les données théoriques et expérimentales initiales.

#### *4.5 Méthode d'évaluation des modèles neuronaux*

Tester le réseau neuronal développé est une étape cruciale avant son application à l'ensemble du système électrique. Cette étape permet de s'assurer que le réseau neuronal est capable de généraliser et de produire des résultats précis lorsque de nouvelles données lui sont présentées. Plusieurs techniques peuvent être utilisées pour évaluer les performances d'un réseau de neurones. Ce projet en utilise quelques-unes parmi les plus courantes.

Une de ces techniques est "plotperform", qui consiste à tracer l'erreur en fonction du nombre d'itérations. Cette méthode permet de suivre l'évolution de l'erreur quadratique moyenne et d'observer comment le réseau de neurones apprend au cours des phases d'entraînement, de validation et de test.

La deuxième technique adoptée est "plotregression", qui trace la meilleure régression linéaire entre les sorties réelles du réseau neuronal et les cibles souhaitées. L'analyse de la pente de cette droite donne des indications sur le processus d'entraînement, et le coefficient de corrélation mesure l'adéquation entre les sorties du réseau et les cibles souhaitées. Plus ce coefficient est proche de 1, la meilleure est la performance du réseau.

#### *4.6 Analyses des performances du modèle neuronal*

Pour la prédiction, diverses topologies de réseaux de neurones multicouches ont été développées et testées. Le choix de la topologie idéale dépend de plusieurs facteurs, tels que la taille du réseau, la stratégie d'apprentissage utilisée et la quantité de données d'entraînement disponibles.

La sélection de la taille appropriée du réseau est essentielle, car elle permet de réduire le temps d'apprentissage et d'améliorer la capacité du réseau à représenter le problème. Il n'existe pas de règle universelle pour déterminer le

nombre de couches cachées et le nombre de neurones par couche cachée pour un problème spécifique.

Après de nombreux essais et une étude approfondie, le réseau de neurones à rétropropagation a été identifié comme la topologie la plus adaptée. Pour optimiser les performances de l'algorithme de rétropropagation, la technique d'optimisation de Levenberg-Marquardt a été employée.

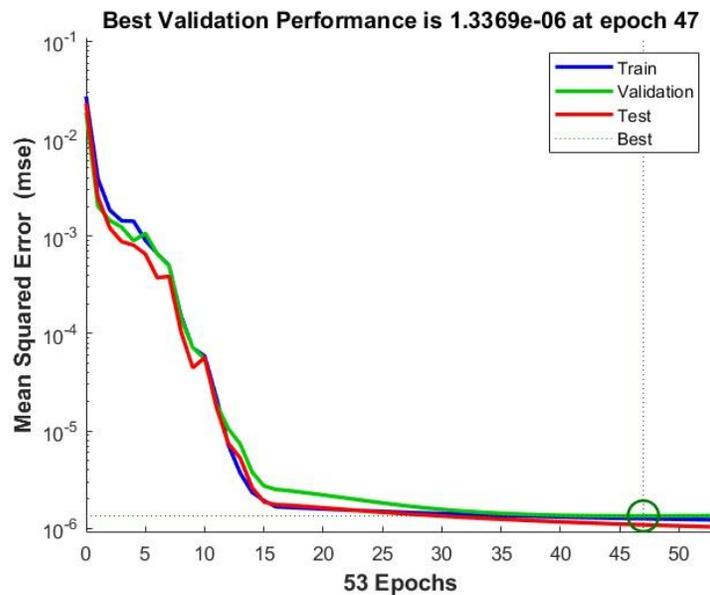
#### 4.6.1 Entraînement du réseau de neurones pour la prédiction :

Le réseau neuronal reçoit trois entrées ( $G'$ ,  $G''$  et  $\omega$ ) et génère une sortie ( $g_i$ ). La sortie du réseau est prédite en se basant sur l'historique de la base de données. Plusieurs modèles de réseaux de neurones ont été développés en variant le nombre de couches cachées, le nombre de neurones dans chaque couche cachée et les fonctions d'activation pour chaque couche. Ces modèles ont été testés afin de choisir celui qui convient.

##### – Modèle 1 :

La figure 4.1 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation.

Ce réseau se constitue de 3 neurones dans la couche d'entrée, 3 couches cachées, 10 neurones dans les trois couches cachées, et un seul neurone dans la couche de sortie, les fonctions de transfert/activation de chaque couche (caché et sortie) sont tansig-tansig-tansig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à  $1\ 336 \times 10^{-6}$ .

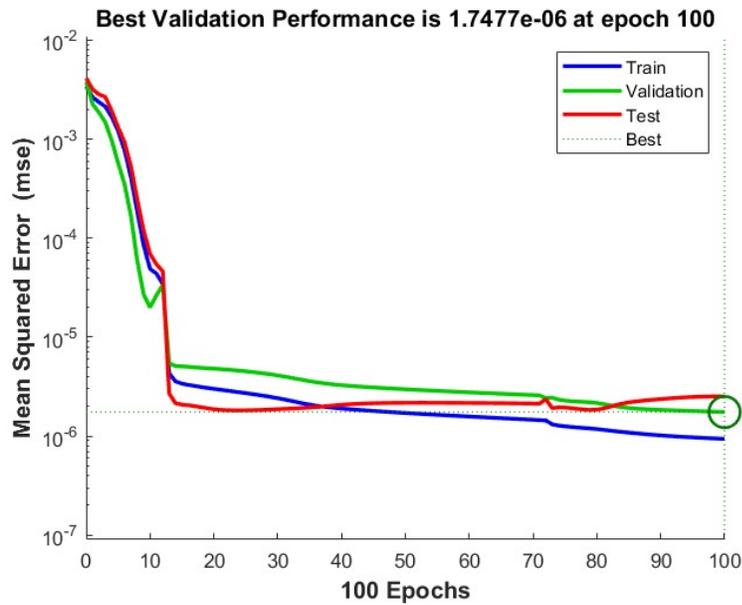


**Figure 4.1**  
**Courbe de performance du réseau neuronal 3-10-10- 10-1.**

– Modèle 2 :

La figure 4.2 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation.

Ce réseau se constitue de 3 neurones dans la couche d'entrée, 3 couches cachées, 25 neurones dans la première couche cachée, 5 neurones dans la deuxième, 5 neurones dans la troisième et un seul neurone dans la couche de sortie, les fonctions de transfert/activation de chaque couche (caché et sortie) sont tansig-tansig-tansig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à  $1,74 \cdot 10^{-6}$ .

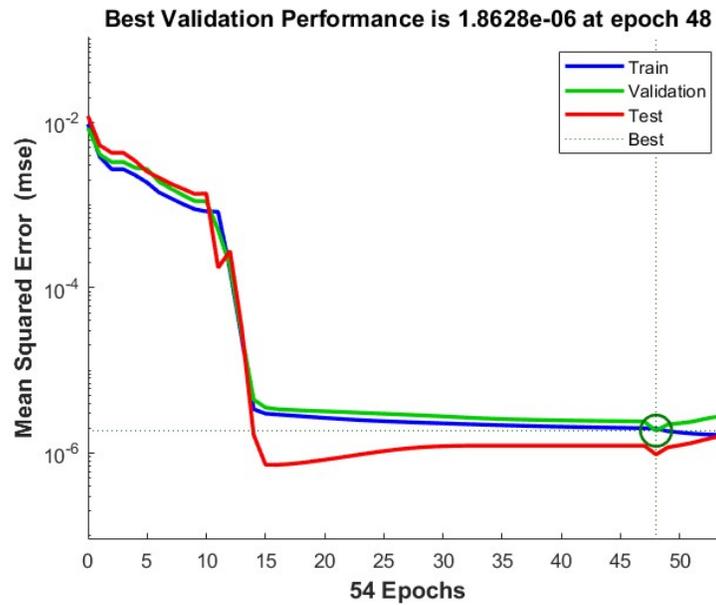


**Figure 4.2**  
**Courbe de performance du réseau neuronal 3-25-5-5-1.**

– Modèle 3 :

La figure 4.3 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation.

Ce réseau se constitue de 3 neurones dans la couche d'entrée, 3 couches cachées, 26 neurones dans la première couche cachée, 5 neurones dans la deuxième, un seul neurone dans la troisième et un seul neurone dans la couche de sortie, les fonctions de transfert/activation de chaque couche (caché et sortie) tansig-tansig-tansig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à  $1,86 \times 10^{-6}$ .

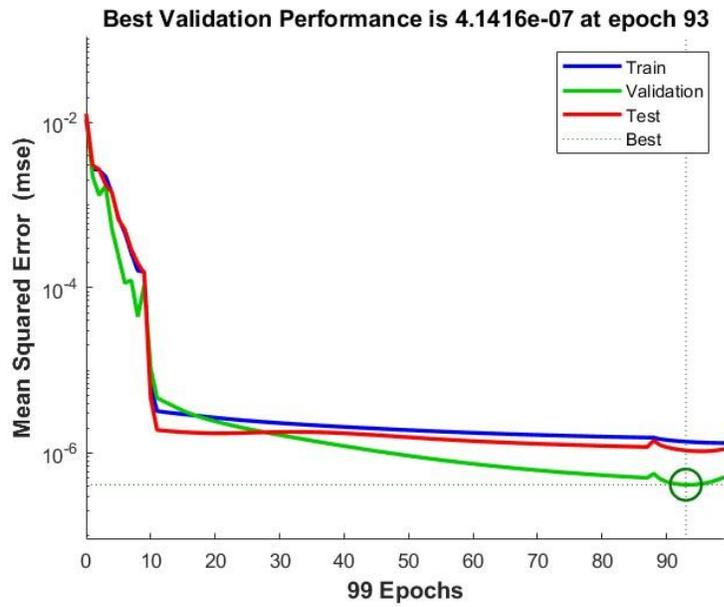


**Figure 4.3**  
**Courbe de performance du réseau neuronal 3-26-5-1-1.**

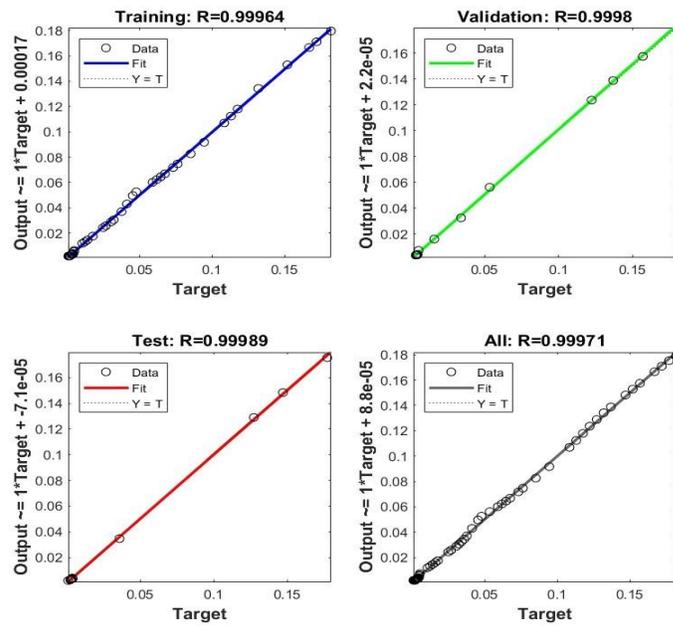
– Modèle 4 :

La figure 4.4 suivante présente les courbes d'évolution de performance du réseau pendant les 3 phases d'entraînement, validation et test. Elle indique aussi l'erreur atteinte pendant la meilleure performance de validation.

Ce réseau se constitue de 3 neurones dans la couche d'entrée, 3 couches cachées, 25 neurones dans la première couche cachée, 5 neurones dans la deuxième, un seul neurone dans la troisième et un seul neurone dans la couche de sortie, les fonctions de transfert/activation pour chaque couche (caché et sortie) tansig-tansig-tansig-purelin respectivement. L'erreur quadratique moyenne atteinte à la fin du processus d'entraînement est égale à  $4,14 \times 10^{-7}$ .



**Figure 4.4**  
 Courbe de performance du réseau neuronal 3-25-5-1-1.



**Figure 4.5**  
 Meilleure performance de validation du réseau neuronal 3-25-5-1-1.

Les quatre modèles développés démontrent des performances satisfaisantes, les erreurs obtenues à la fin du processus d'apprentissage étant proches de la valeur  $10^{-6}$ . D'après les graphiques ci-dessus, il convient de noter que le modèle 4 montre la meilleure performance pendant la phase d'apprentissage. Il est crucial d'obtenir la meilleure performance pendant la phase de test également, en utilisant les valeurs expérimentales. Pour cela, nous prédisons  $g_i$  à partir des valeurs expérimentales de  $G'_{exp}$  et  $G''_{exp}$  pour les cinq modèles afin de pouvoir valider le meilleur modèle en se basant sur les deux.

#### 4.6.2 Validation des Modèles par les Données expérimentales :

Pour valider la performance des modèles développés, il est essentiel de ne pas se contenter des résultats obtenus pendant la phase d'apprentissage, mais aussi de s'assurer que les modèles fonctionnent bien lors de la phase de test. Cette validation repose sur la comparaison des prédictions des modèles avec les données expérimentales.

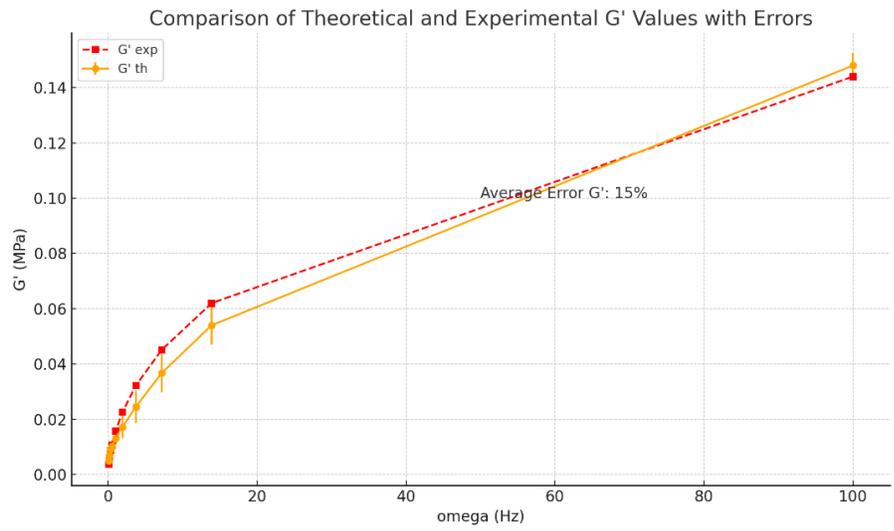
Dans cette optique, nous avons prédit  $g_i$  à partir des valeurs expérimentales de  $G'_{exp}$  et  $G''_{exp}$ . Les valeurs de  $g_i$  ainsi prédites sont ensuite introduites dans les équations théoriques pour calculer les  $G'$  et  $G''$  théoriques. Cela nous permet de comparer les  $G'_{th}$  et  $G''_{th}$  calculés à partir des  $g_i$  prédits avec les valeurs expérimentales. Cette démarche nous permet d'évaluer et de comparer la précision des cinq modèles développés en fonction des données expérimentales. En procédant ainsi, nous pourrions déterminer le modèle offrant la meilleure performance globale, tant pendant la phase d'apprentissage que durant la phase de test, assurant ainsi une validation rigoureuse et complète de notre approche.

- Base de données :

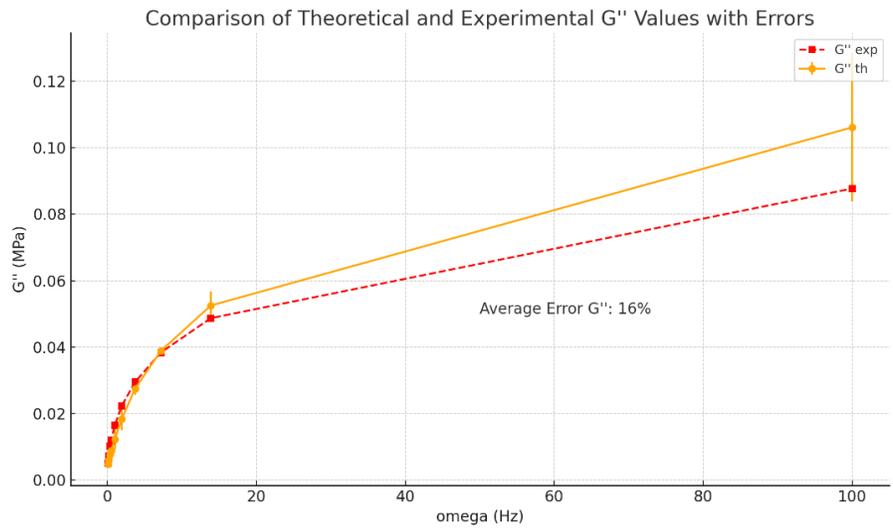
Avant d'analyser les résultats des tests, il est crucial de comparer les valeurs théoriques, utilisées pour l'entraînement des modèles, avec les valeurs expérimentales. Cette comparaison permet de vérifier la qualité et la pertinence des données d'entraînement. Une bonne concordance entre les valeurs théoriques et expérimentales indique que les modèles ont été entraînés sur des données représentatives des phénomènes réels, augmentant ainsi la fiabilité des prédictions des modèles.

Les graphiques ci-dessous montrent la comparaison entre les valeurs théoriques ( $G'_{th}$  et  $G''_{th}$ ) et les valeurs expérimentales ( $G'_{exp}$  et  $G''_{exp}$ ) utilisées pour l'entraînement des modèles. Les courbes représentent les variations de  $G'$  et  $G''$  en fonction de la fréquence ( $\omega$ ). Les erreurs moyennes sont également indiquées pour fournir une mesure quantitative de la précision des valeurs théoriques par rapport aux valeurs expérimentales.

Il est important de noter qu'il y a une erreur moyenne de 15 % entre  $G'_{th}$  et  $G'_{exp}$  (figure 4.6), ainsi qu'une erreur moyenne de 16 % entre  $G''_{th}$  et  $G''_{exp}$  (figure 4.7). Ces erreurs doivent être prises en considération lors de l'évaluation des performances des modèles pendant les tests. Une prise en compte de ces erreurs moyennes permettra une évaluation plus réaliste et nuancée de la précision des modèles lors de la phase de test.

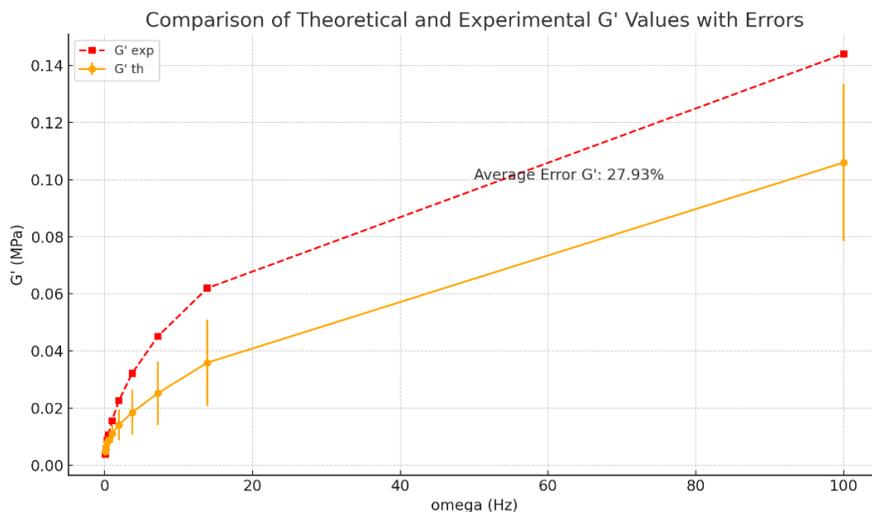


**Figure 4.6**  
**Comparaison entre les  $G'$  théoriques et Expérimentales utilisées pour l'Entraînement des Modèles.**

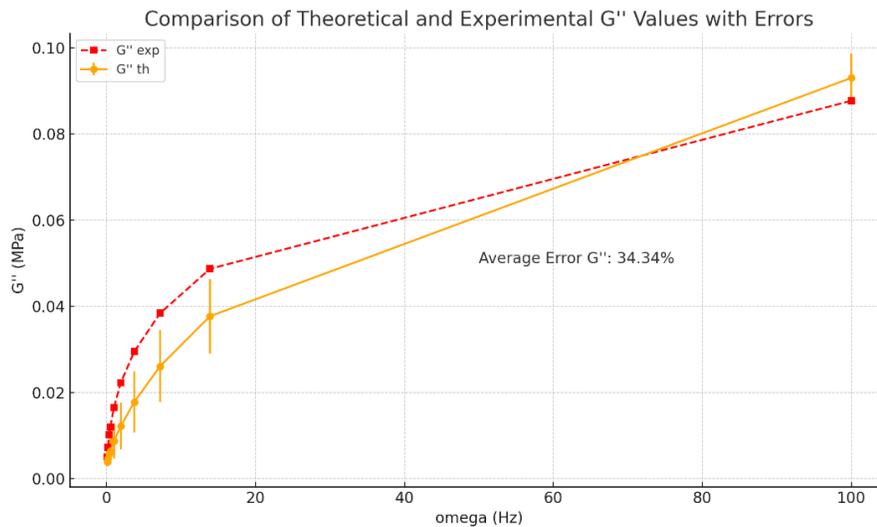


**Figure 4.7**  
**Comparaison entre les  $G''$  théoriques et Expérimentales utilisées pour l'Entraînement des Modèles.**

- Modèle 1 : Réseau neuronal 3-10-10- 10-1.



**Figure 4.8**  
**Comparaison entre les G' théoriques et Expérimentales pour le modèle 1.**

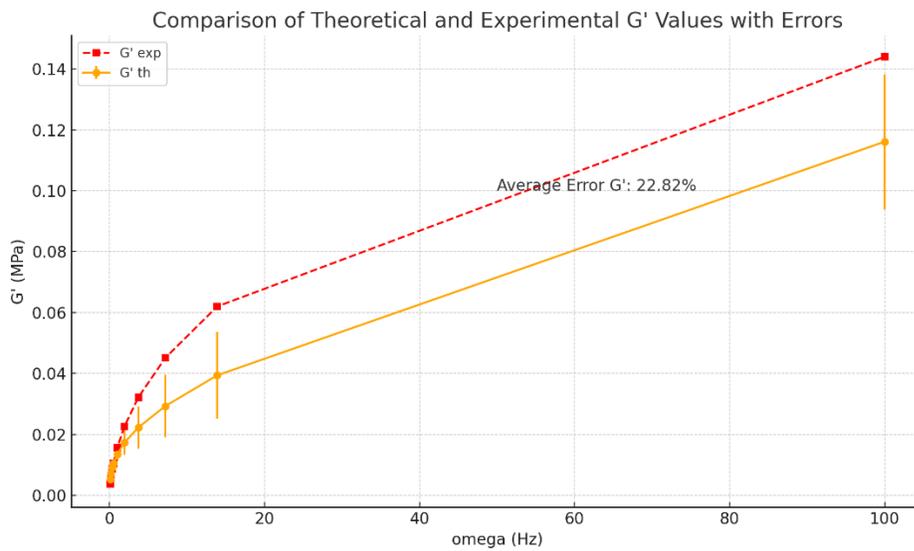


**Figure 4.9**  
**Comparaison entre les G'' théoriques et Expérimentales pour le modèle 1.**

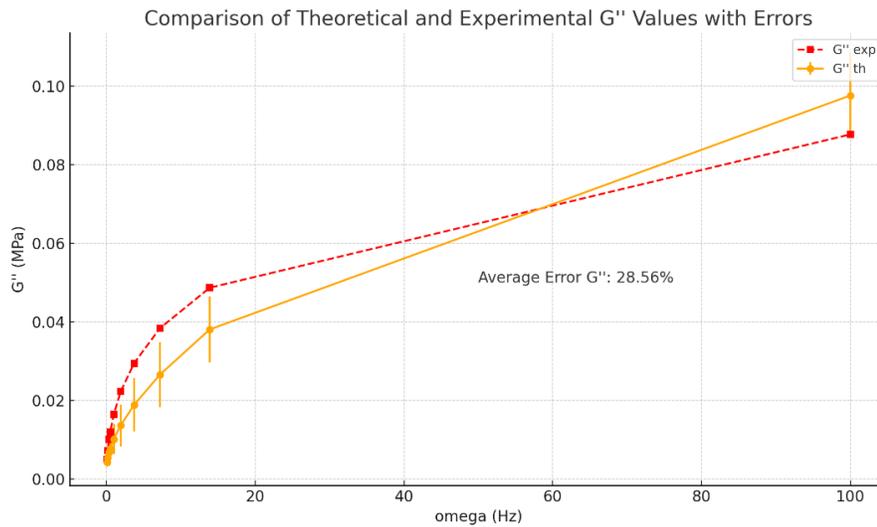
Le Modèle 1 présente une erreur moyenne de 25,10 % pour G' et de 34,34 % pour G'' lorsqu'on compare les valeurs théoriques avec les valeurs expérimentales. Cette

différence est significative souligne l'importance de prendre en compte ces erreurs lors de l'évaluation des performances de ce modèle. Les graphiques ci-dessus illustrent ces écarts pour le Modèle 1, mettant en évidence les divergences entre les valeurs théoriques et expérimentales.

- Modèle 2 : Réseau neuronal 3-25-5-5-1.



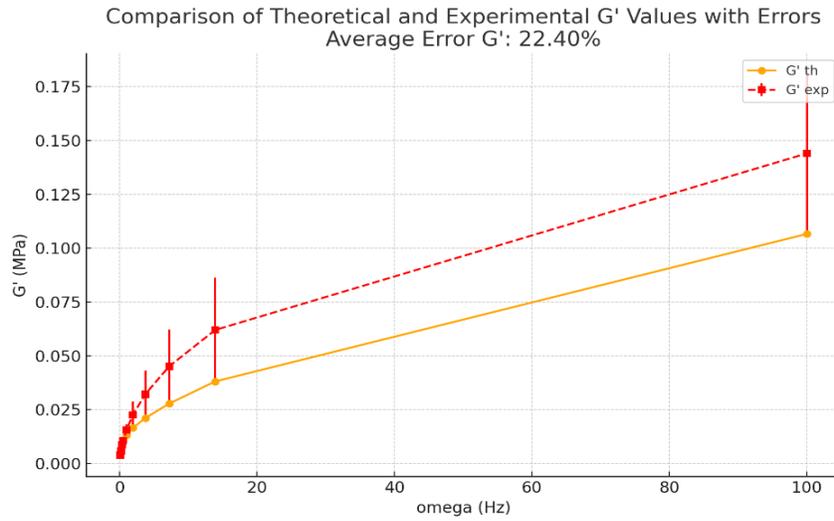
**Figure 4.10**  
**Comparaison entre les G' théoriques et Expérimentales pour le modèle 2.**



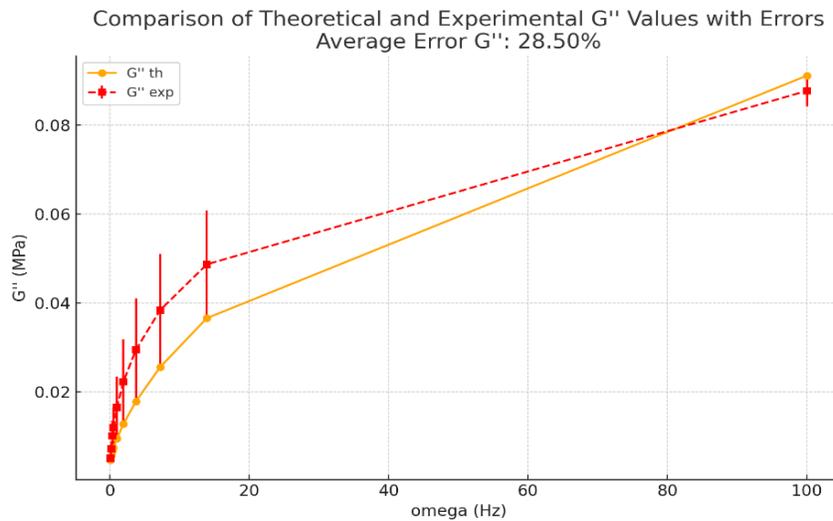
**Figure 4.11**  
**Comparaison entre les  $G''$  théoriques et Expérimentales pour le modèle 2.**

Le Modèle 2 présente une erreur moyenne de 22,82 % pour  $G'$  et de 28,56 % pour  $G''$  lorsqu'on compare les valeurs théoriques avec les valeurs expérimentales. Cette différence est significative et souligne l'importance de prendre en compte ces erreurs lors de l'évaluation des performances de ce modèle. Les graphiques ci-dessus illustrent ces écarts pour le Modèle 2, mettant en évidence les divergences entre les valeurs théoriques et expérimentales.

- Modèle 3 : Réseau neuronal 3-26-5-1-1.



**Figure 4.12**  
**Comparaison entre les  $G'$  théoriques et Expérimentales pour le modèle 3.**

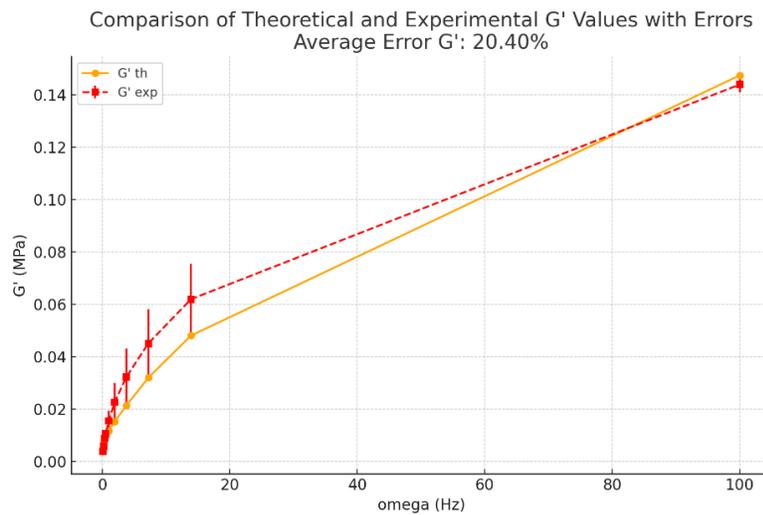


**Figure 4.13**  
**Comparaison entre les  $G''$  théoriques et Expérimentales pour le modèle 3.**

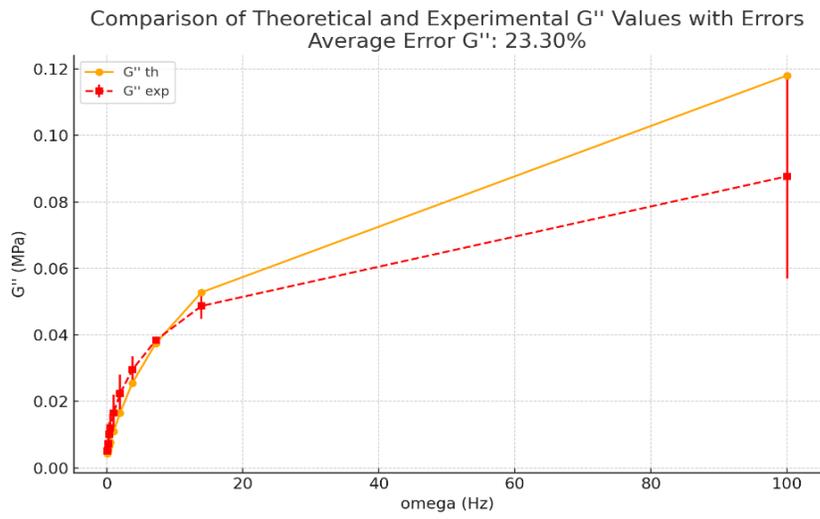
Le Modèle 3 présente une erreur moyenne de 22,4 % pour  $G'$  et de 28,5 % pour  $G''$  lorsqu'on compare les valeurs théoriques avec les valeurs expérimentales.

Cette différence est significative et souligne l'importance de prendre en compte ces erreurs lors de l'évaluation des performances de ce modèle. Les graphiques ci-dessus illustrent ces écarts pour le Modèle 3, mettant en évidence les divergences entre les valeurs théoriques et expérimentales.

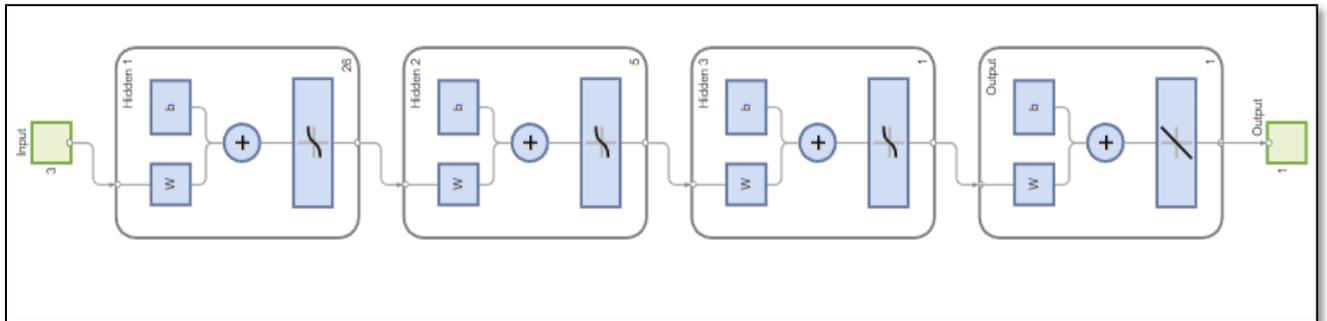
- Modèle 4 : Réseau neuronal 3-25-5-1-1.



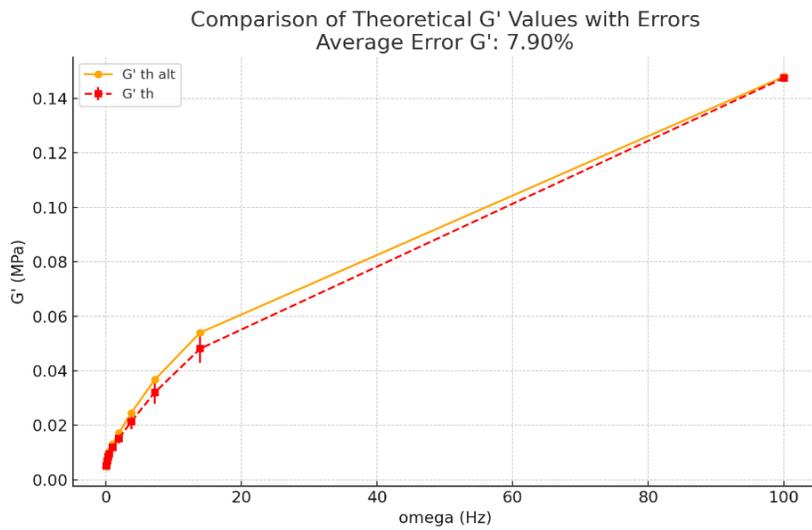
**Figure 4.14**  
**Comparaison entre les  $G'$  théoriques et Expérimentales pour le modèle 4.**



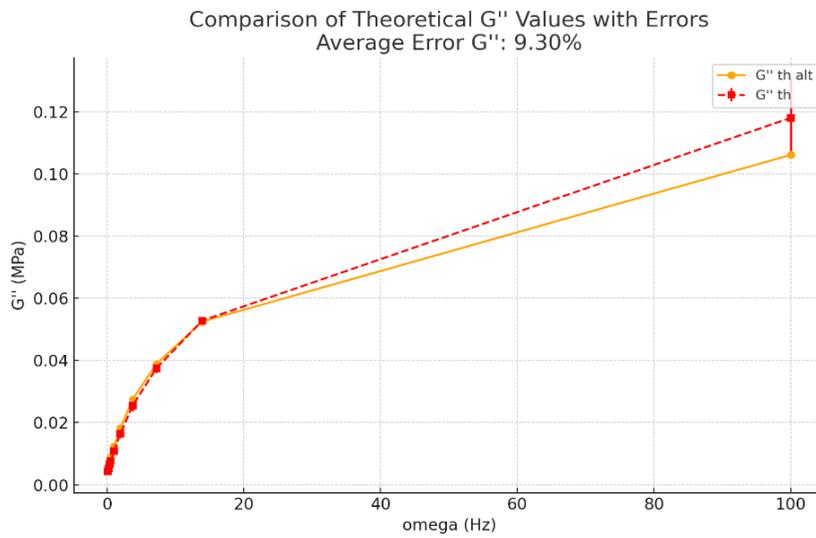
**Figure 4.15**  
**Comparaison entre les  $G''$  théoriques et Expérimentales pour le modèle 4.**



**Figure 4.16**  
**Schéma structural de réseau neuronal 3-25-5-1-1.**



**Figure 4.17**  
**Comparaison entre les G' théoriques et prédits pour le modèle 4.**



**Figure 4.18**  
**Comparaison entre les G'' théoriques et prédits pour le modèle 4.**

#### *4.7 Conclusion*

Ce chapitre a présenté l'identification du comportement viscoélastique du HDPE à l'aide de réseaux de neurones artificiels. Après avoir testé plusieurs architectures, la meilleure configuration a été sélectionnée pour prédire les paramètres  $g_i$ . Les tests avec des données expérimentales ont validé la précision et la robustesse du modèle, montrant sa capacité à reproduire le comportement observé. Les ajustements effectués ont permis de surmonter les défis liés à la complexité de la modélisation et à la disponibilité des données.

## **5. CHAPITRE 5 : PRÉDICTION DES PROPRIÉTÉS DES BIOCOSITES HDPE + SCIURE DE BOIS PAR RNA**

### *5.1 Introduction*

Dans ce chapitre, nous nous concentrerons sur l'application des réseaux de neurones artificiels (RNA) feedforward pour l'identification et la caractérisation des biocomposites à base d'HDPE et de sciure de bois. L'objectif est d'optimiser l'utilisation de ces réseaux pour prédire avec précision les propriétés des biocomposites en fonction de différents pourcentages de sciure de bois intégrée à l'HDPE.

Pour ce faire, après avoir testé diverses architectures de RNA afin de déterminer la combinaison optimale de couches cachées et de neurones par couche, nous avons identifié la configuration la plus efficace pour obtenir la précision souhaitée. Désormais, nous utiliserons le modèle de RNA validé pour prédire les propriétés des biocomposites contenant 20 %, 30 %, et 40 % de sciure de bois. Cette approche progressive garantit que les modèles sont rigoureusement validés et capables de fournir des résultats fiables pour des matériaux composites complexes.

### *5.2 HDPE + 20 % Sciure de Bois*

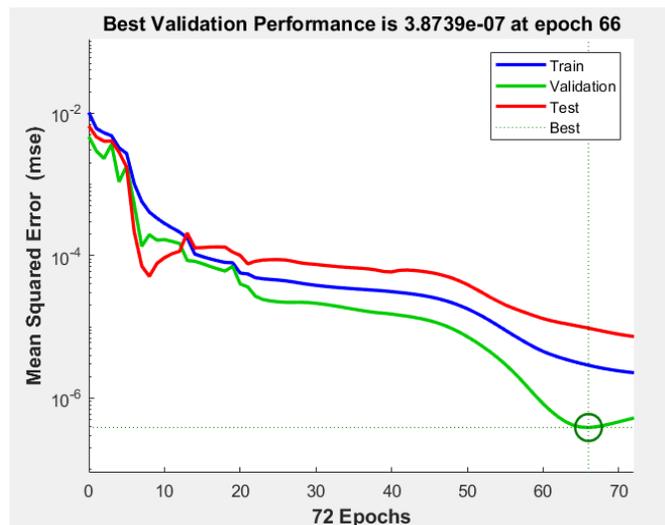
#### **5.2.1 Processus d'entraînement pour HDPE + 20 % Sciure de Bois**

À partir de l'architecture de RNA validée et présentée dans le chapitre précédent, nous avons appliqué ce modèle pour prédire les propriétés des biocomposites composés de 20 % de sciure de bois intégrée à l'HDPE.

Training Progress			
Unit	Initial Value	Stopped Value	Target Value
Epoch	0	72	100
Elapsed Time	-	00:00:01	-
Performance	0.0102	2.27e-06	0
Gradient	0.0261	0.000192	1e-07
Mu	0.001	1e-06	1e+10
Validation Checks	0	6	6

**Figure 5.1**  
**Progression d'entraînement pour RNA -3-25-5-1-1.**

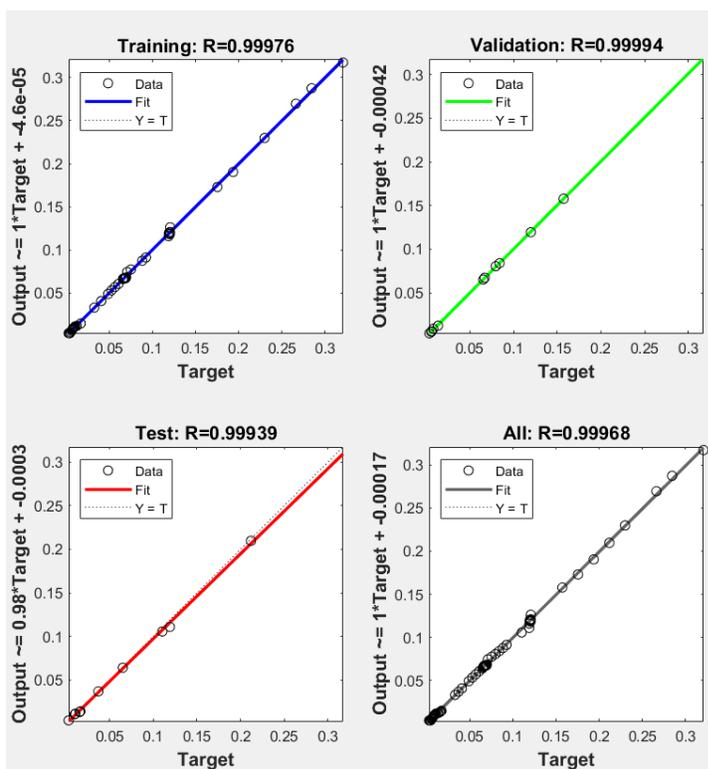
Le modèle a atteint un arrêt à l'époque 72, avec une performance de 2,27 e-06, indiquant une excellente convergence vers les valeurs cibles. Les vérifications de validation ont été satisfaites à 6 reprises, ce qui renforce la fiabilité et la robustesse du modèle.



**Figure 5.2**  
**Courbe de performance du réseau neuronal.**

Le graphe de la meilleure performance de validation permet d'observer comment le modèle se comporte sur l'ensemble de validation pendant le processus d'apprentissage.

La précision de validation donne une indication de la proportion de prédictions correctes que le modèle fait sur l'ensemble de validation. En général, on s'attend à ce que la précision de validation augmente au fur et à mesure de l'apprentissage.



**Figure 5.3**  
**Graphe de régression pour le réseau neuronal.**

La courbe de performance du réseau neuronal (figure 5.3) montre une excellente précision dans les prédictions. La meilleure performance de

validation, avec une MSE de  $3,8739 \times 10^{-7}$ , a été atteinte à l'époque 66, indiquant une précision optimale du modèle. Les courbes d'erreur quadratique moyennes (MSE) pour l'entraînement (bleue), la validation (verte) et le test (rouge) diminuent régulièrement, montrant une convergence rapide vers des valeurs très faibles après environ 50 époques. La courbe de validation suit une tendance similaire à celle de l'entraînement, confirmant que le modèle ne surapprend pas. Bien que la courbe de test présente des erreurs légèrement plus élevées, elles restent dans une plage acceptable, indiquant une bonne généralisation du modèle. En somme, cette courbe valide l'efficacité de l'architecture de RNA et des paramètres d'entraînement choisis pour prédire les propriétés des biocomposites HDPE + 20 % de sciure de bois.

Ces résultats montrent que l'architecture RNA choisie est très efficace pour prédire les propriétés des biocomposites contenant 20 % de sciure de bois, offrant ainsi une base solide pour les analyses des autres compositions de biocomposites.

### 5.2.2 Prédiction par RNA et comparaison des résultats

- Comparaison entre les valeurs de  $g_i$  entraîné et prédites par RNA :

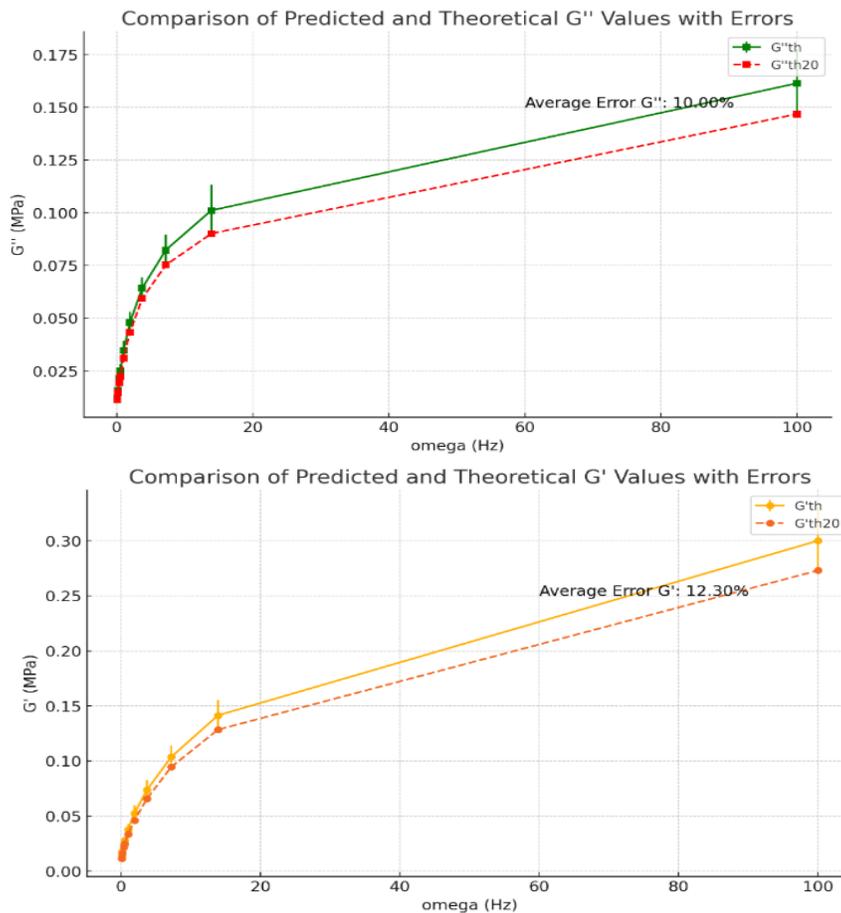
**Tableau 5.1**

**Comparaison entre les valeurs de  $g_i$  entraîné et prédites par RNA pour HDPE+20%Sciure de bois.**

<b>gk théorique</b>	<b>gk prédit</b>	<b>Erreur (%)</b>
0,35	0,34	2,86
0,30	0,29	3,33
0,25	0,24	4,00
0,18	0,17	5,56
0,12	0,11	8,33
0,08	0,08	0,00
0,04	0,04	0,00

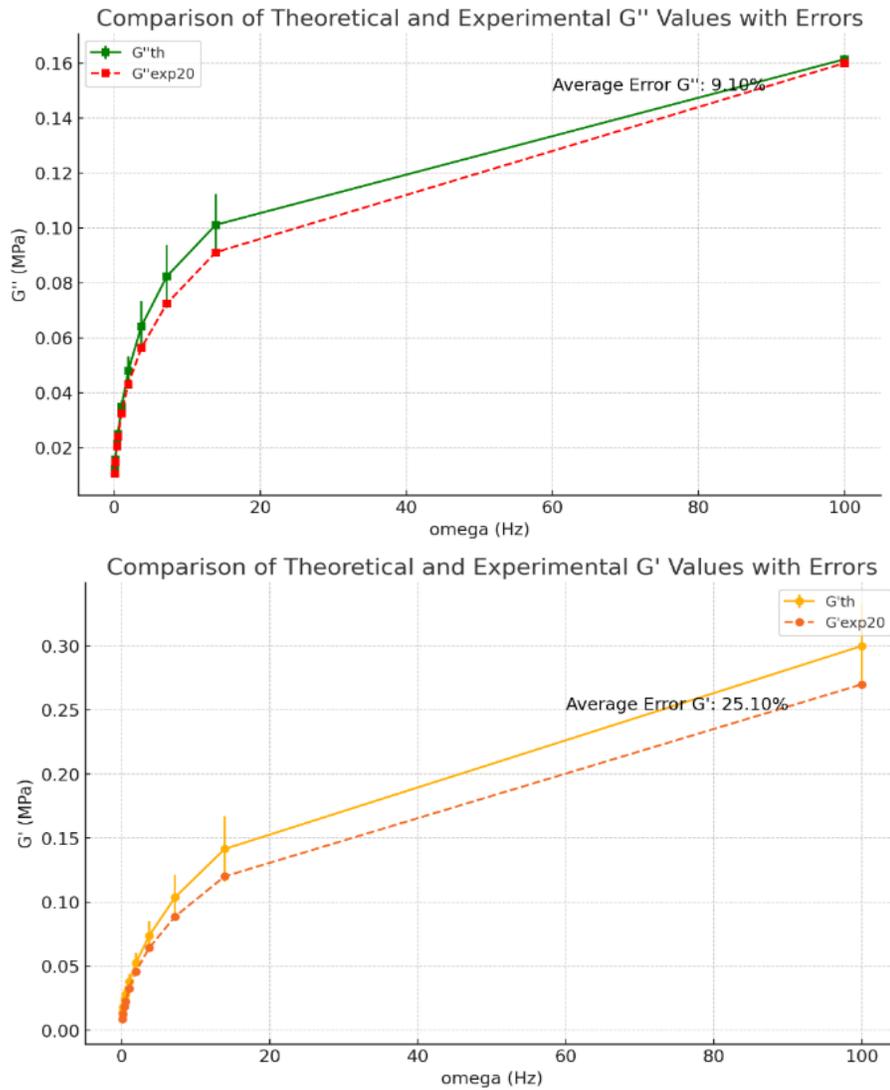
Le tableau 5.1 présente une comparaison entre les valeurs théoriques de  $g_k$  et celles prédites par le réseau de neurones artificiels (RNA). Les colonnes montrent les valeurs théoriques de  $g_k$ , les valeurs prédites, ainsi que le pourcentage d'erreur. On peut observer que les erreurs sont généralement faibles, avec des valeurs ne dépassant pas 8,33 %. Cela suggère que le modèle RNA a une bonne capacité à prédire les valeurs de  $g_k$  avec une précision raisonnable.

- Comparaison entre  $G'$  et  $G''$  prédits et  $G'$  et  $G''$  théoriques :



**Figure 5,4 Comparaisons des résultats prédites et théoriques pour HDPE+20 % Bois.**

– Comparaison entre  $G'$  et  $G''$  prédits et  $G'$  et  $G''$  expérimentaux :



**Figure 5.5**  
Comparaison des résultats prédits et expérimentaux pour HDPE+20 % Bois.

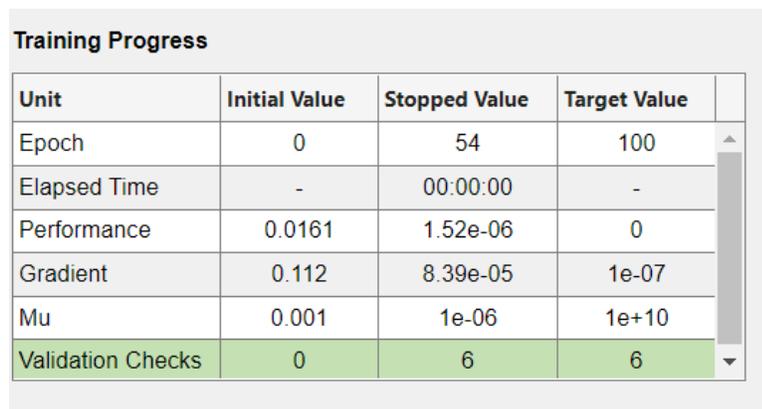
### 5.2.1 Conclusion

Le modèle RNA prédit efficacement les propriétés des biocomposites composés de HDPE et de 20 % de sciure de bois. Avec une forte corrélation entre les valeurs théoriques et prédites ( $R^2 > 0,99$ ) et de faibles erreurs quadratiques moyennes, le modèle montre une grande précision. Les comparaisons montrent des erreurs moyennes de 12,30 % pour  $G'$  et 10,06 % pour  $G''$  dans les prédictions théoriques, ainsi que 25,10 % pour  $G'$  et 9,10 % pour  $G''$  par rapport aux données expérimentales. Il ne faut pas oublier que les valeurs théoriques utilisées pour l'entraînement des modèles montrent une différence de 15 à 16 % lorsqu'on les compare aux valeurs expérimentales. Cela confirme la fiabilité du modèle pour prédire le comportement mécanique de ces biocomposites et ouvre la voie à des travaux futurs.

### 5.3 HDPE + 30 % Sciure de Bois

#### 5.3.1 Processus d'entraînement pour HDPE + 30 % Sciure de Bois

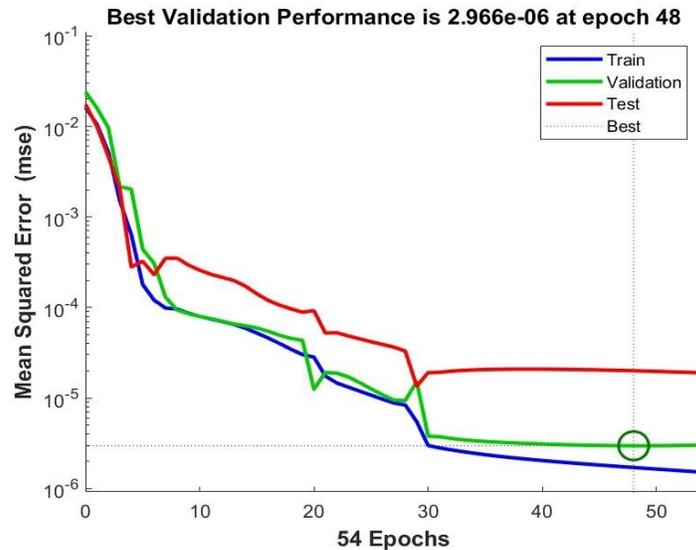
Nous avons appliqué le modèle RNA -3-25-5-1-1 pour prédire les propriétés des biocomposites composés de 30 % de sciure de bois intégrée à l'HDPE.



Unit	Initial Value	Stopped Value	Target Value
Epoch	0	54	100
Elapsed Time	-	00:00:00	-
Performance	0.0161	1.52e-06	0
Gradient	0.112	8.39e-05	1e-07
Mu	0.001	1e-06	1e+10
Validation Checks	0	6	6

**Figure 5.6**  
**Progression d'entraînement pour RNA -3-25-5-1-1.**

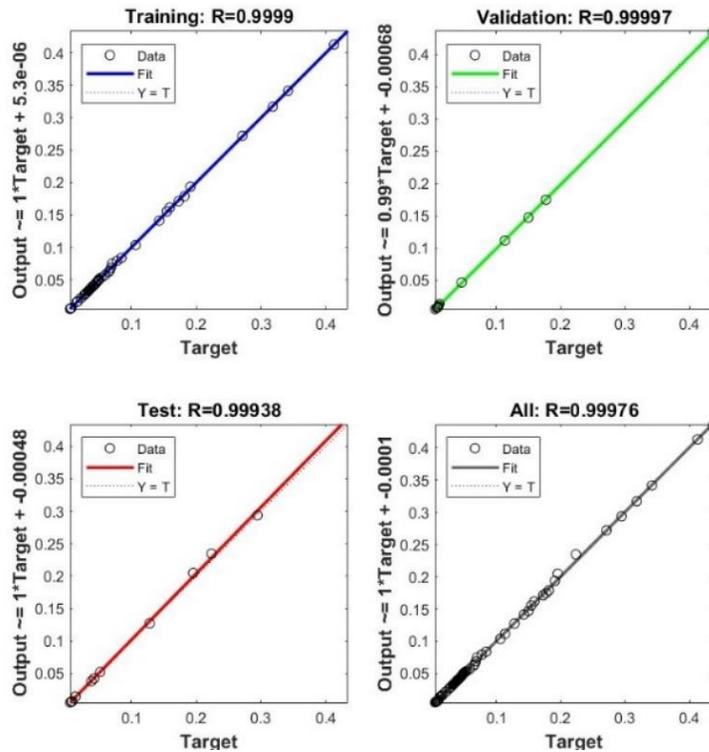
Le modèle a atteint un arrêt à l'époque 54, avec une performance de  $1,52 \times 10^{-6}$ , indiquant une excellente convergence vers les valeurs cibles. Les vérifications de validation ont été satisfaites à 6 reprises, ce qui renforce la fiabilité et la robustesse du modèle.



**Figure 5.7**  
**Courbe de performance du réseau neuronal.**

Le graphe de la meilleure performance de validation permet d'observer comment le modèle se comporte sur l'ensemble de validation pendant le processus d'apprentissage.

La précision de validation donne une indication de la proportion de prédictions correctes que le modèle fait sur l'ensemble de validation. En général, on s'attend à ce que la précision de validation augmente au fur et à mesure de l'apprentissage.



**Figure 5.8**  
**Graphe de régression pour le réseau neuronal.**

La courbe de performance du réseau neuronal (figure 5.7) montre une excellente précision dans les prédictions. La meilleure performance de validation, avec une MSE de 2.966e-06, a été atteinte à l'époque 48, indiquant une précision optimale du modèle. Les courbes d'erreur quadratique moyenne (MSE) pour l'entraînement (bleue), la validation (verte) et le test (rouge) diminuent régulièrement, montrant une convergence rapide vers des valeurs très faibles après environ 50 époques. La courbe de validation suit une tendance similaire à celle de l'entraînement, confirmant que le modèle ne surapprend pas. Bien que la courbe de test présente des erreurs légèrement plus élevées, elles restent dans une plage acceptable, indiquant une bonne généralisation du modèle. En somme, cette courbe valide l'efficacité de

l'architecture de RNA et des paramètres d'entraînement choisis pour prédire les propriétés des biocomposites HDPE + 30 % de sciure de bois.

Ces résultats montrent que l'architecture RNA choisie est très efficace pour prédire les propriétés des biocomposites contenant 30 % de sciure de bois, offrant ainsi une base solide pour les analyses des autres compositions de biocomposites.

### 5.3.2 Prédiction par RNA et comparaison des résultats

- Comparaison entre les valeurs de  $g_i$  entraîné et prédites par RNA :

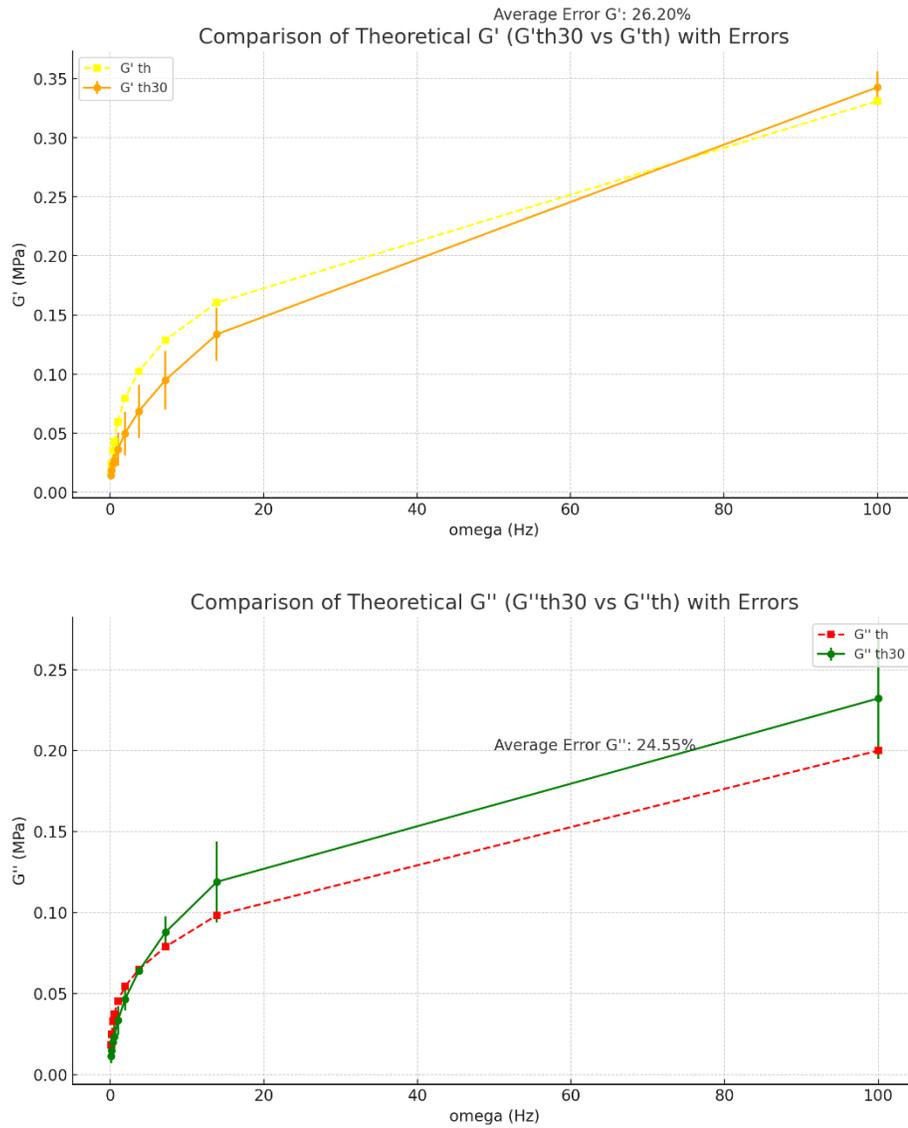
**Tableau 5.2**

**Comparaison entre les valeurs de  $g_k$  entraîné et prédites par RNA + 30%Sciure de bois.**

$g_k$ Théorique	$g_k$ Prédit	Erreur (%)
0,40	0,39	2,50
0,32	0,31	3,12
0,24	0,23	4,17
0,15	0,14	6,67
0,10	0,09	10,00
0,05	0,05	0,00
0,02	0,02	0,00

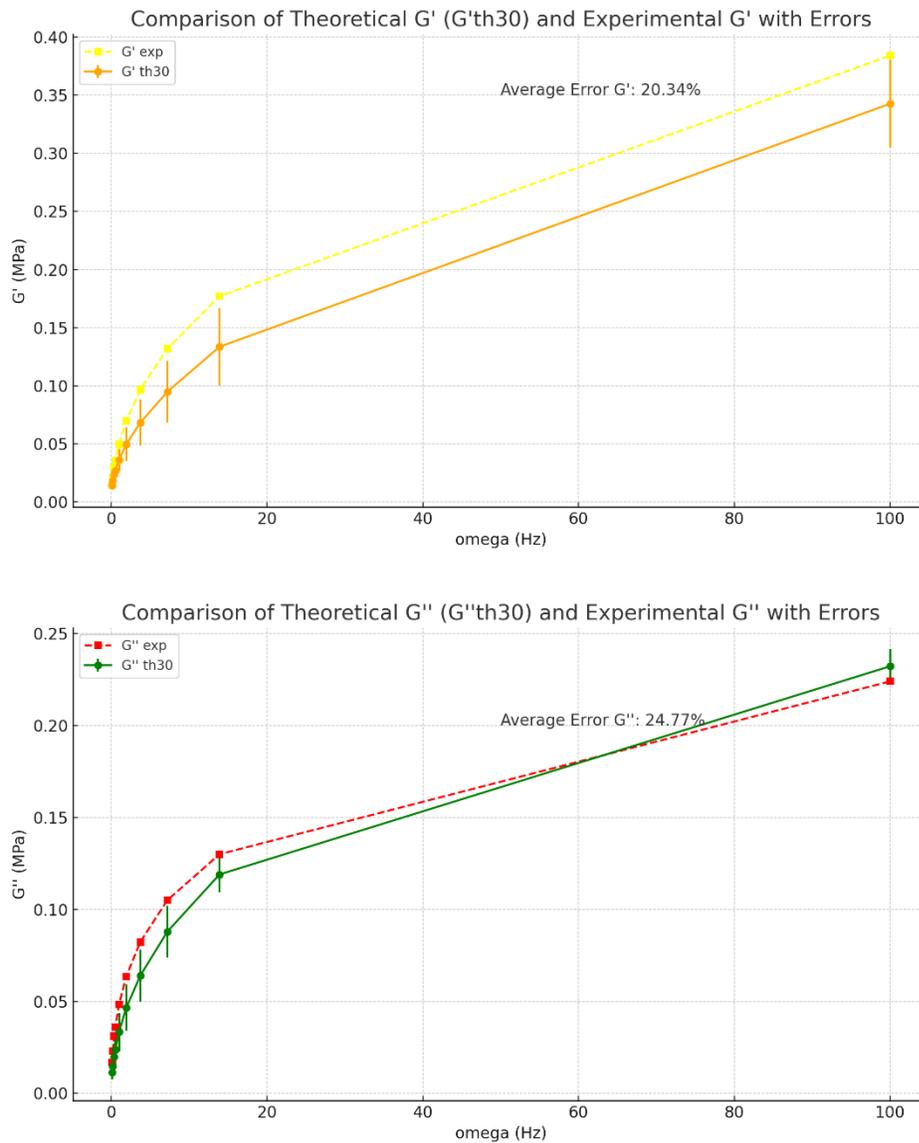
Le tableau 5.2 présente une comparaison entre les valeurs théoriques et prédites de  $g_k$ , ainsi que le pourcentage d'erreur. Les résultats montrent que les erreurs sont faibles, ne dépassant pas 10 % pour la plupart des valeurs. Les plus grandes différences sont observées pour les valeurs théoriques élevées, notamment avec une erreur de 10 % pour  $g_k=0,10$ . Les petites valeurs de  $g_k$  sont, quant à elles, prédites avec une précision parfaite, avec des erreurs nulles pour  $g_k=0,05$  et  $g_k=0,02$ .

- Comparaison entre  $G'$  et  $G''$  prédits et  $G'$  et  $G''$  théoriques :



**Figure 5.9**  
**Comparaison des résultats prédits et théoriques pour HDPE+30 % Bois.**

– Comparaison entre  $G'$  et  $G''$  prédits et  $G'$  et  $G''$  expérimentaux :



**Figure 5.10**  
Comparaison des résultats prédits et expérimentaux pour HDPE+30 % Bois.

### 5.3.3 Conclusion

La modélisation RNA appliquée aux biocomposites composés de 30 % de sciure de bois intégrée à l'HDPE a montré des performances solides. Les erreurs moyennes obtenues lors de la comparaison des valeurs théoriques et prédites pour  $G'$  et  $G''$  sont respectivement de 26,20 % et 24,55 %. En ce qui concerne la comparaison entre les valeurs prédites et expérimentales, les erreurs sont de 20,34 % pour  $G'$  et 24,77 % pour  $G''$ . Ces résultats valident l'efficacité de l'architecture du modèle RNA pour prédire les propriétés de ces biocomposites.

## 5.4 HDPE + 40 % Sciure de Bois

### 5.4.1 Processus d'entraînement pour HDPE + 40 % Sciure de Bois

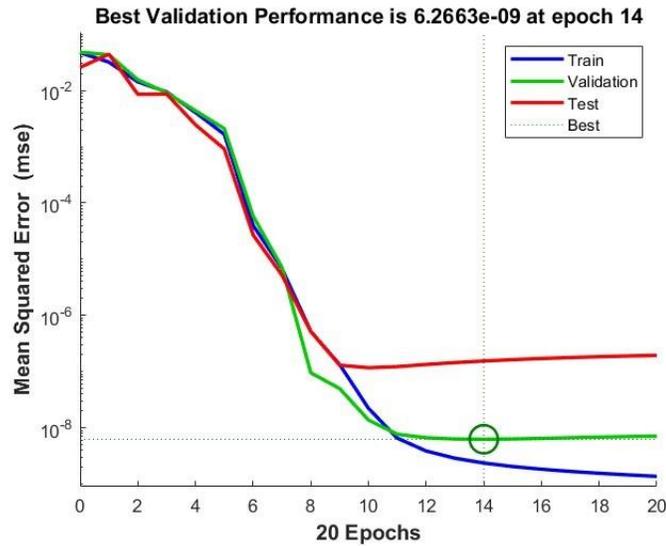
Nous avons appliqué le modèle RNA -3-25-5-1-1 pour prédire les propriétés des biocomposites composés de 40 % de sciure de bois intégrée à l'HDPE.

Training Progress			
Unit	Initial Value	Stopped Value	Target Value
Epoch	0	20	100
Elapsed Time	-	00:00:00	-
Performance	0.047	1.37e-09	0
Gradient	0.0632	2.39e-06	1e-07
Mu	0.001	1e-08	1e+10
Validation Checks	0	6	6

**Figure 5.11**  
**Progression d'entraînement pour RNA -3-25-5-1-1.**

Le modèle a atteint un arrêt à l'époque 14, avec une performance de  $6,2663 \times 10^{-9}$ , indiquant une excellente convergence vers les valeurs cibles. Les

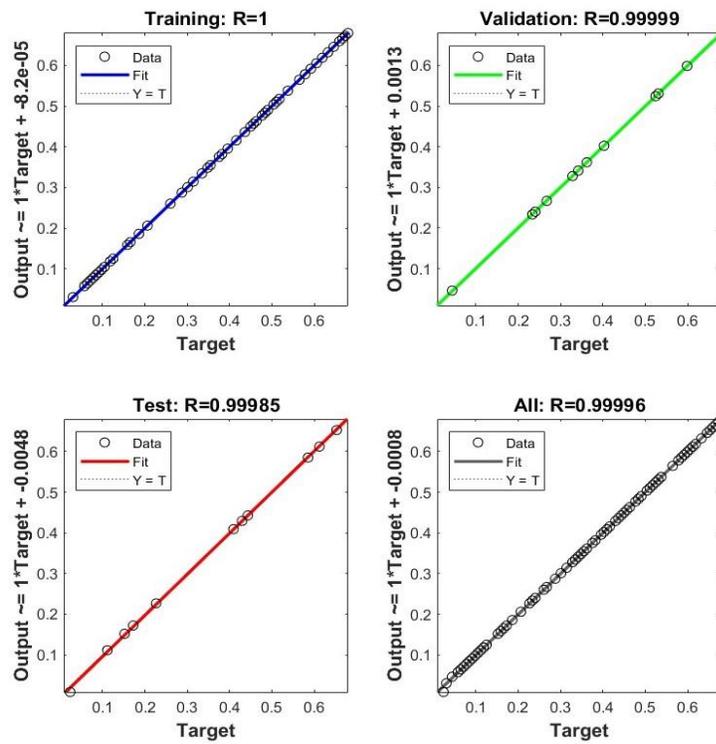
vérifications de validation ont été satisfaites à 6 reprises, ce qui renforce la fiabilité et la robustesse du modèle.



**Figure 5.12**  
**Courbe de performance du réseau neuronal.**

Le graphe de la meilleure performance de validation permet d'observer comment le modèle se comporte sur l'ensemble de validation pendant le processus d'apprentissage.

La précision de validation donne une indication de la proportion de prédictions correctes que le modèle fait sur l'ensemble de validation. En général, on s'attend à ce que la précision de validation augmente au fur et à mesure de l'apprentissage.



**Figure 5.13**  
**Graphe de régression pour le réseau neuronal.**

La courbe de performance du réseau neuronal (figure 5.12) montre une excellente précision dans les prédictions. La meilleure performance de validation, avec une MSE de  $3,8739 \times 10^{-7}$ , a été atteinte à l'époque 66, indiquant une précision optimale du modèle. Les courbes d'erreur quadratique moyenne (MSE) pour l'entraînement (bleue), la validation (verte) et le test (rouge) diminuent régulièrement, montrant une convergence rapide vers des valeurs très faibles après environ 50 époques. La courbe de validation suit une tendance similaire à celle de l'entraînement, confirmant que le modèle ne surapprend pas. Bien que la courbe de test présente des erreurs légèrement plus élevées, elles restent dans une plage acceptable, indiquant une bonne généralisation du modèle. En somme, cette courbe valide l'efficacité de

l'architecture de RNA et des paramètres d'entraînement choisis pour prédire les propriétés des biocomposites HDPE + 40 % de sciure de bois.

Ces résultats montrent que l'architecture RNA choisie est très efficace pour prédire les propriétés des biocomposites contenant 40 % de sciure de bois, offrant ainsi une base solide pour les analyses des autres compositions de biocomposites.

#### 5.4.2 Prédiction par RNA et comparaison des résultats

- Comparaison entre les valeurs entraînées  $g_i$  et prédites par RNA :

**Tableau 5.3**

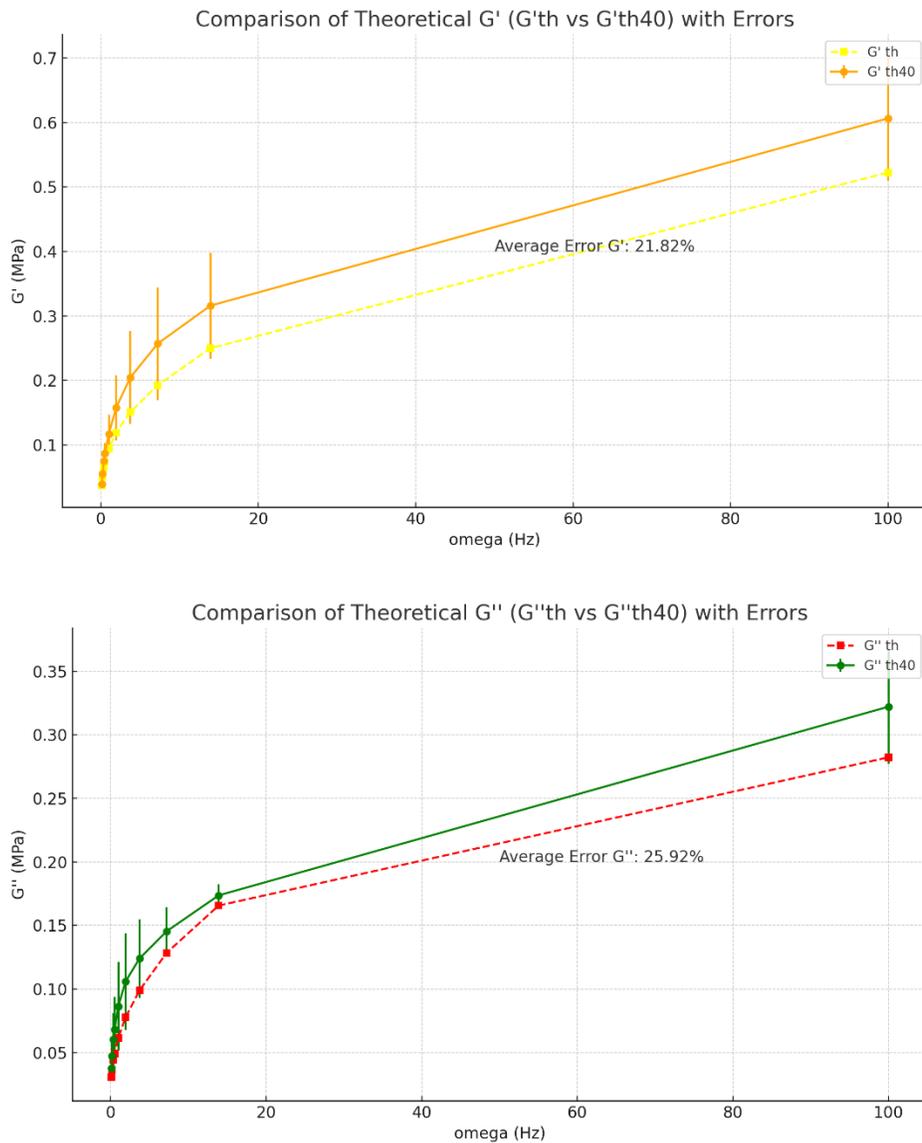
**Comparaison entre les valeurs de  $g_k$  Entraîné et prédites par RNA + 40%Sciure de bois.**

$g_k$ Théorique	$g_k$ Prédit	Erreur (%)
0,70	0,69	1,43
0,65	0,64	1,54
0,60	0,59	1,67
0,55	0,54	1,82
0,50	0,49	2,00
0,45	0,44	2,22
0,40	0,39	2,50
0,35	0,34	2,86
0,30	0,29	3,33
0,25	0,24	4,00

Le tableau 5.3 présente une comparaison entre les valeurs théoriques et prédites de  $g_k$  ainsi que le pourcentage d'erreur correspondant. Les erreurs observées sont faibles, avec des pourcentages variant de 1,43 % à 4,00 %. Ces résultats indiquent une bonne précision du modèle RNA pour prédire les valeurs de  $g_k$ , surtout pour les valeurs plus élevées où l'erreur reste proche de 1,43 % à 2,50 %. Pour les valeurs plus faibles de  $g_k$ , l'erreur augmente

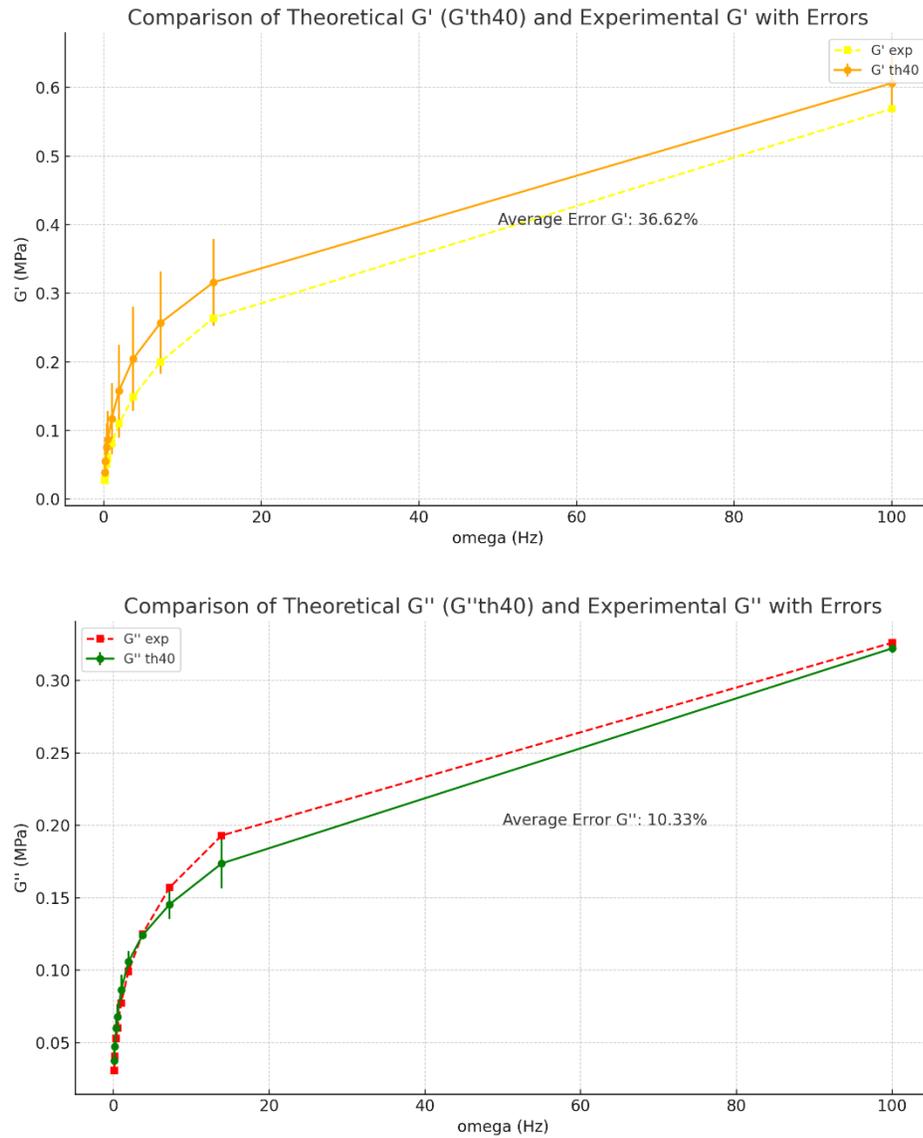
légèrement, atteignant 4,00 % pour  $g_k=0,25$ , mais cela reste dans une marge d'erreur acceptable.

- Comparaison entre  $G'$  et  $G''$  prédits et  $G'$  et  $G''$  théoriques :



**Figure 5.14**  
**Comparaison des résultats prédits et théoriques pour HDPE+40 % Bois.**

- Comparaison entre  $G'$  et  $G''$  prédits et  $G'$  et  $G''$  expérimentaux :



**Figure 5.15**  
Comparaison des résultats prédits et expérimentaux pour HDPE+40 % Bois.

### 5.4.3 Conclusion

Le modèle RNA prédit efficacement les propriétés des biocomposites composés de HDPE et de 40 % de sciure de bois. Avec une forte corrélation entre les valeurs théoriques et prédites ( $R^2 > 0,99$ ) et de faibles erreurs quadratiques moyennes, le modèle montre une grande précision. Les comparaisons montrent des erreurs moyennes de 21,82 % pour  $G'$  et 25,92 % pour  $G''$  dans les prédictions théoriques, ainsi que 36,33 % pour  $G'$  et 10,33 % pour  $G''$  par rapport aux données expérimentales. Il ne faut pas oublier que les valeurs théoriques utilisées pour l'entraînement des modèles montrent une différence de 15 à 16 % lorsqu'on les compare aux valeurs expérimentales. Cela confirme la fiabilité du modèle pour prédire le comportement mécanique de ces biocomposites et ouvre la voie à des travaux futurs.

## CONCLUSION

Ce mémoire a abordé l'utilisation de l'intelligence artificielle, en particulier les réseaux de neurones artificiels (RNA), pour la caractérisation viscoélastique de biocomposites à base de polyéthylène haute densité (HDPE) et de sciure de bois. L'objectif principal était de développer un modèle prédictif capable de caractériser le comportement viscoélastique des composites en fonction de la proportion de sciure de bois. Ce travail s'inscrit dans une perspective de développement durable, en explorant des alternatives aux matériaux traditionnels à base de polymères, tout en favorisant l'intégration de fibres naturelles.

### Résumé des Étapes et Résultats obtenus :

1. Étude bibliographique et Conception de la Méthodologie :
  - Une revue de la littérature a été réalisée pour comprendre les propriétés des matériaux composites renforcés par des fibres naturelles et les modèles viscoélastiques disponibles. Le modèle intégral de Lodge a été sélectionné pour sa pertinence dans la description du comportement viscoélastique des thermoplastiques.
  - La méthodologie a été conçue autour de l'utilisation de réseaux de neurones de type feedforward, permettant de prédire les propriétés du composite à partir des données expérimentales.
2. Collecte et analyse des Données expérimentales :
  - Des échantillons de HDPE et de biocomposites HDPE + sciure de bois ont été fabriqués avec différentes proportions de sciure (0 %, 20 %, 30 %, et 40 %). Des tests rhéologiques ont été menés pour mesurer les propriétés viscoélastiques de ces échantillons.

- Les données expérimentales ont permis de déterminer les paramètres spécifiques au modèle de Lodge pour chaque proportion de sciure de bois, fournissant une base solide pour l'entraînement des RNA.

### 3. Développement et Entraînement des Modèles neuronaux :

- Le réseau de neurones a été entraîné à partir des valeurs théoriques calculées en utilisant les formules spécifiques pour les modules de stockage et de perte. Plusieurs architectures ont été testées pour identifier la configuration optimale, en ajustant le nombre de couches cachées et de neurones par couche.
- Après la phase d'entraînement, le modèle neuronal a été testé à l'aide des valeurs expérimentales collectées lors des tests rhéologiques. Le modèle a démontré une bonne capacité à prédire le comportement viscoélastique des composites, avec une corrélation élevée entre les prédictions du modèle et les données expérimentales, et des erreurs moyennes faibles sur les tests de validation.

### 4. Validation et Optimisation du Modèle :

- Les performances du modèle ont été validées en comparant les prédictions avec des données expérimentales non utilisées lors de l'entraînement, confirmant la robustesse et la fiabilité de la méthode.

### **Contraintes rencontrées :**

- Disponibilité des Données : L'une des principales contraintes a été la limitation de la base de données expérimentale, restreinte aux échantillons fabriqués et aux conditions de test spécifiques. Cette limitation a restreint la capacité du modèle à généraliser les prédictions pour des proportions de sciure de bois différentes ou des conditions de test variées.
- Complexité de la Modélisation : Entraîner le réseau de neurones sur des valeurs théoriques et le tester avec des valeurs expérimentales a nécessité de nombreuses itérations pour ajuster le modèle. Cela a augmenté le temps de calcul et la complexité de la procédure d'entraînement.

### **Recommandations pour les Travaux futurs :**

1. Augmentation de la Base de Données expérimentale : Il serait bénéfique de collecter des données sur une gamme plus étendue de proportions de sciure de bois et de réaliser des tests dans diverses conditions de température et d'humidité pour renforcer la robustesse et la généralisation des modèles neuronaux.
2. Exploration de Modèles avancés : Les futurs travaux devraient se concentrer sur l'intégration de réseaux de neurones plus complexes, tels que les réseaux récurrents (RNN) ou d'autres modèles, afin de favoriser une approche basée sur l'exploration plutôt que sur l'interpolation. Ces modèles sont capables de capturer les relations complexes et les variations au sein des données, ce qui permet de mieux comprendre les comportements des matériaux sous différentes conditions. Cette approche d'exploration peut ainsi améliorer la

précision des prédictions, en offrant une vision plus détaillée et complète des phénomènes étudiés, au-delà des limites imposées par une simple interpolation des données.

3. Analyse environnementale: Il serait pertinent d'évaluer l'impact environnemental global des biocomposites étudiés en intégrant une analyse de cycle de vie, afin de quantifier les bénéfices écologiques de l'intégration des fibres naturelles.

En résumé, cette recherche a montré le potentiel des réseaux de neurones artificiels pour la caractérisation viscoélastique des biocomposites.

## ANNEXE A : COURBES DES PERFORMANCES ET PARAMÈTRES

- Courbe d'évaluation des modèles neuronaux conçus.

### a. Modèle 1 : 3-10-10 - 10-1

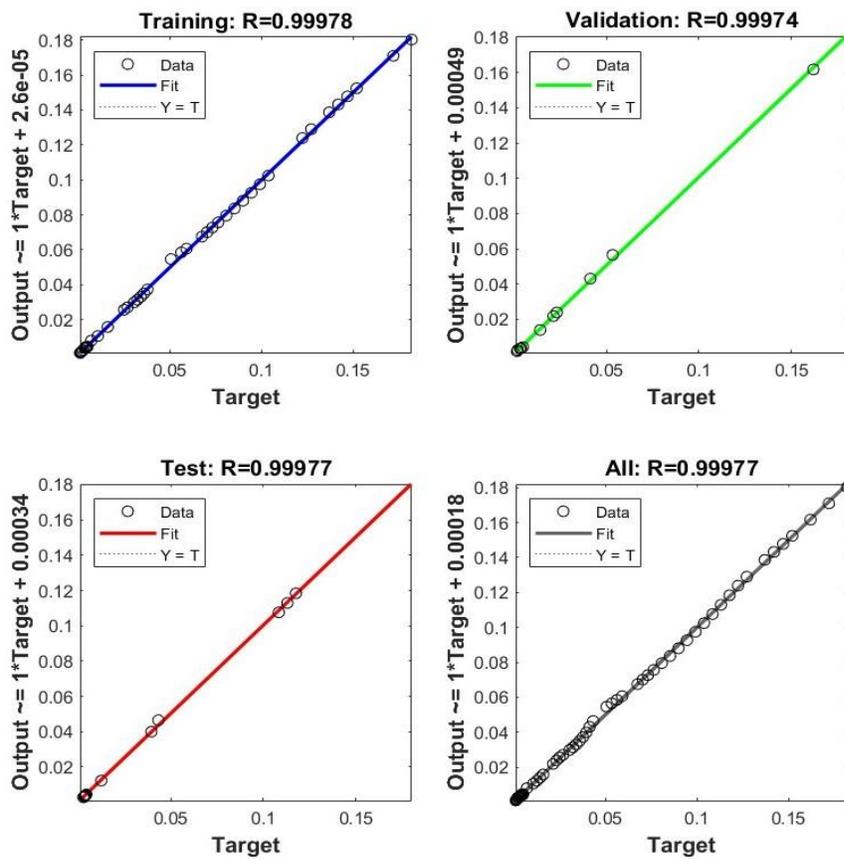
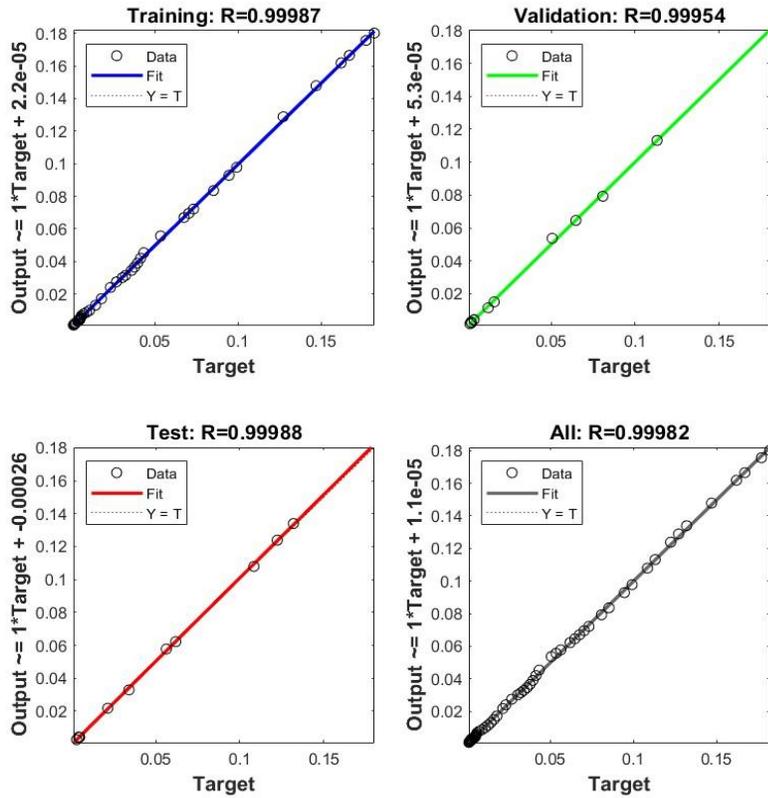


Figure 5.16  
Graphe de régression pour le réseau neuronal du modèle 1.

**b. Modèle 2 : 3-25-5-5-1**



**Figure 5.17**  
**Graphe de régression pour le réseau neuronal du modèle 2.**

c. Modèle 3 : 3-26-5-1-1

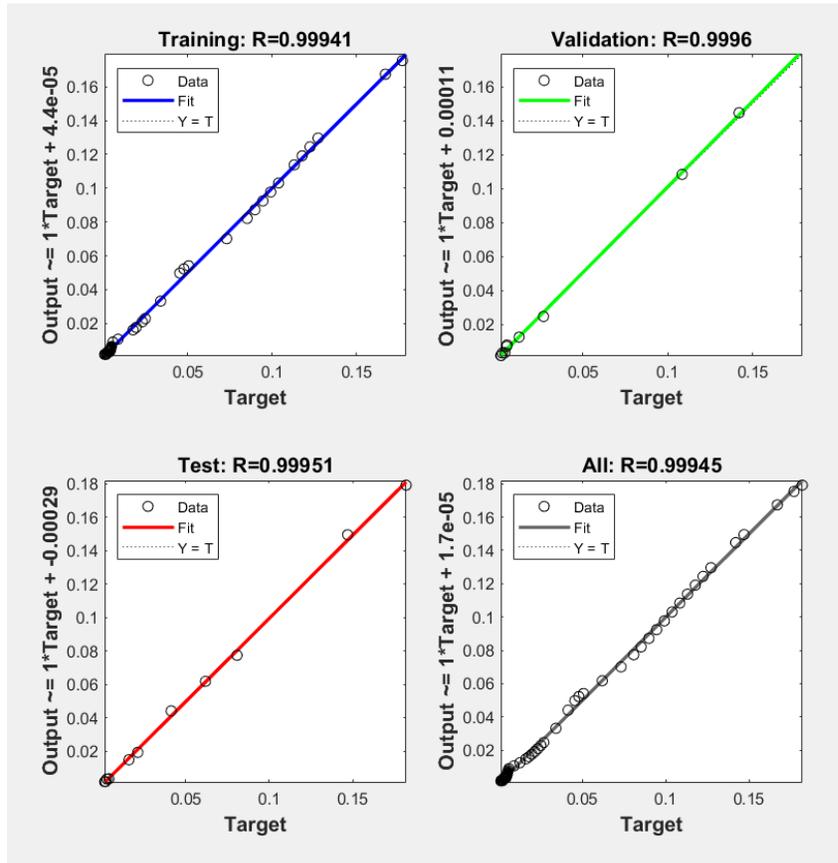


Figure 5.18  
Graphe de régression pour le réseau neuronal du modèle 3.

d. Modèle 4 : 3-25-5-1-1

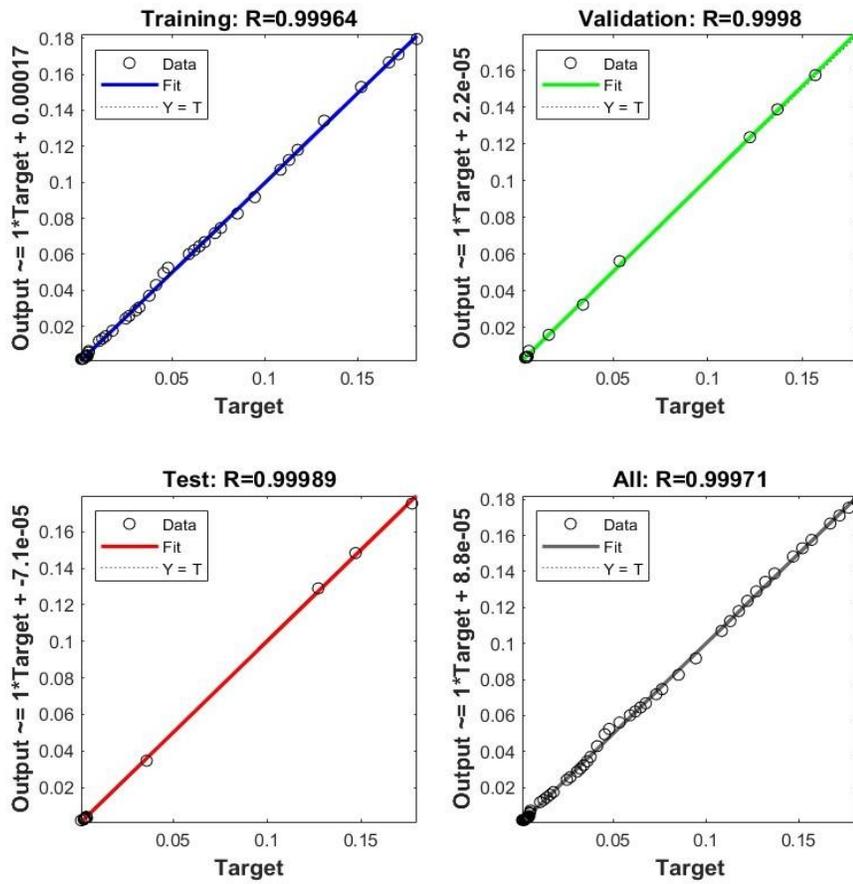


Figure 5.19  
Graphe de régression pour le réseau neuronal du modèle 4.

## ANNEXE B : EXPLOITATION DE LA BASE DES DONNÉES

La base de données générée à partir des simulations est organisée dans un fichier Excel. La figure ci-dessous présente une capture d'écran d'une partie de cette base de données.

	A	B	C	D	E	F
1	<b>omega</b>	<b>G'th</b>	<b>G''th</b>	<b>gk</b>	<b>G'exp</b>	<b>G''exp</b>
2	0,1	0,0049	0,0048	0,182	0,00379	0,00507
3	0,193	0,0069	0,006	0,127	0,00579	0,00726
4	0,373	0,0091	0,0076	0,076	0,00871	0,0102
5	0,518	0,0103	0,0088	0,045	0,0106	0,012
6	1	0,0131	0,0123	0,025	0,0156	0,0165
7	1,93	0,0172	0,0183	0,0053	0,0226	0,0223
8	3,73	0,0245	0,0275	0,0042	0,0322	0,0295
9	7,2	0,0367	0,0389	0,004	0,0451	0,0384
10	13,9	0,054	0,0525	0,0025	0,062	0,0487
11	100	0,148	0,1061	0,001	0,144	0,0877
12	0,1	0,0114	0,0114	0,321	0,00845	0,0105
13	0,193	0,016	0,0147	0,121	0,0126	0,0147
14	0,373	0,0216	0,0193	0,119	0,0185	0,0204
15	0,518	0,0249	0,0224	0,071	0,0224	0,0239
16	1	0,0334	0,0309	0,065	0,0322	0,0324
17	1,93	0,0461	0,0433	0,021	0,0458	0,0431
18	3,73	0,0658	0,0592	0,011	0,0643	0,0563
19	7,2	0,0945	0,0752	0,009	0,0886	0,0724
20	13,9	0,1284	0,0901	0,005	0,12	0,0911
21	100	0,273	0,1468	0,003	0,27	0,16

Pour importer ces données dans l'espace de travail ("workspace") de MATLAB, il suffit de cliquer sur "Import Data" dans l'onglet "Home" et de sélectionner le fichier Excel à importer, ainsi que le type de données, en choisissant "Matrice numérique". Une fois les données importées dans l'espace de travail de MATLAB, il est nécessaire de créer les matrices pour les données d'entrée et les données de sortie souhaitées. Ces matrices seront ensuite utilisées comme entrées et sorties pour les réseaux de neurones développés.

## BIBLIOGRAPHIE

- Aklonis, J. J., & MacKnight, W. J. (1983). *Introduction to polymer viscoelasticity* (2nd ed.). Wiley-Interscience.
- Bengio, Y., et al., “Learning Deep Architectures for AI”, *Foundations and Trends in Machine Learning*, vol. 2, no. 1, pp. 1–127, 2009.
- Bernstein, B., Kearsley, E. A., & Zapas, L. J., “A Study of Stress Relaxation with Finite Strain”, *Transactions of the Society of Rheology*. VII, 391-410 (1963).
- Bisanda, E. (2000). The effect of alkali treatment on the adhesion characteristics of sisal fibres. *Applied Composite Materials*, 7(5), 331–339.
- Bloch, R., Chang, W. & Tschoegl, N. (1978). The behavior of rubberlike materials in moderately large deformations. *Journal of Rheology* (1978-present), 22(1), 1–32.
- Bouafif, H., Koubaa, A., Perré, P., Cloutier, A. & Riedl, B. (2008). Analysis of Among-Species Variability in Wood Fiber Surface Using DRIFTS and XPS: Effects on Esterification Efficiency. *Journal of Wood Chemistry and Technology*, 28(4), 296–315.
- Burgstaller, C. (2007). Processing of thermal sensitive materials—a case study for wood plastic composites. *Monatshefte für Chemie-Chemical Monthly*, 138(4), 343-346.
- Christensen, R. (1980). A non-linear theory of viscoelasticity for application to elastomers. *Journal of Applied Mechanics*, 47(4), 762–768.
- Dillon, T. S., & Niebur, D. (1996). *Neural networks applications in power systems*. Springer.
- Dubey, R., Samantaray, S., and Panigrahi, B. (2015). An Extreme Learning Machine based Fast and Accurate Adaptive Distance Relaying Scheme. *International Journal of Electrical Power & Energy Systems*, 73, 1002–1014.

Ekici, S., Yildirim, S., & Poyraz, M. (2009). A transmission line fault locator based on Elman recurrent networks. *Applied Soft Computing*, 9(1), 341–347.

Erchiqui, F. (2005). Thermodynamic approach of inflation process of K-BKZ polymer sheet with respect to thermoforming. *Polymer Engineering & Science*, 45(10), 1319–1335.

Erchiqui, F. (2008). Finite Element Analysis of Non-linear Isotropic Hyperelastic and Viscoelastic Materials for Thermoforming Applications.

Erchiqui, F., Imad, A., Mouloudi, A. & Hasnaoui, F. S. (2010). Caractérisation viscoélastique du comportement d'une membrane thermoplastique et modélisation numérique de thermoformage. *The Canadian Journal of Chemical Engineering*, 88(1), 116–125.

Erchiqui F.; N. Kandil. (2006). Neuronal Networks Application for Characterization of Softened Polymers. *Journal of Reinforced Plastics and Composites*. 25(5): 463–473.

Erchiqui F.; Ozdemir Z.; Souli M.; Ezaidi H.; Dituba-Ngoma G. (2011). Neuronal networks approach for characterization of viscoelastic polymers. *The Canadian Journal of Chemical Engineering*. 89(5): 1303–1310.

Erchiqui F., Fotso Talla\* A. S, Kaddami H. (2016). A Numerical Investigation of the Use of Novel Melt Processed PET-Hemp Fiber Composites for Thermoforming Applications. *Polymer Engineering & Science*. 56(9): 1021–1030.

Farid H.; Erchiqui F.; Elghorba M.; Ezzaidi H. (2014). Neural networks approach for hyperelastic behavior characterization of ABS under uniaxial solicitation. *British Journal of Mathematics & Computer Science*. 4(32): 4480–4493.

Faruk, O., Bledzki, A. K., Fink, H. P. & Sain, M. (2012). Biocomposites Reinforced with Natural Fibers: 2000–2010. *Progress in Polymer Science*.

Ferry, J. D. (1980). *Viscoelastic properties of polymers*: John Wiley & Sons.

Gáspár, M., Benkő, Z., Dogossy, G., Réczey, K. & Czigány, T. (2005). Reducing water absorption in compostable starch-based plastics. *Polymer Degradation and Stability*, 90(3), 563–569.

Georgopoulos, S. T., Tarantili, P. A., Avgerinos, E., Andreopoulos, A. G. & Koukios, E. G. (2005). Thermoplastic polymers reinforced with fibrous agricultural residues. *Polymer Degradation and Stability*, 90(2), 303–312.

Green, A. & Zerna, W. (1954). *Theoretical elasticity*: Clarendon Press, Oxford.

Green & Adkins, J. E. (1970). *Large elastic deformations (Vol. 2)*: Clarendon Press Oxford.

Grüneberg, T. (2009). Wood polymer composites (WPC)-processing technologies, chemical modification of wood and natural fiber components and improvement of selected properties. *Universitätsverlag Göttingen*, 55–69.

Hebb, D. O. (1949). *The Organization of Behavior: A Neuropsychological Theory*, Wiley.

Hinton, G. E., & Sejnowski, T. J., “Learning and Relearning in Boltzmann Machines”, MIT Press, 1983.

Hooke, R. (1678). *Lectures de Potentia Restitutiva, or Of Spring: Explaining the Power of Springing Bodies*. John Martyn, London.

Hopfield, J. J., “Neural Networks and Physical Systems with Emergent Collective Computational Abilities”, *PNAS*, 79(8), 2554–2558, 1982.

Hristov, V. & Vlachopoulos, J. (2007). Influence of coupling agents on melt flow behavior of natural fiber composites. *Macromolecular Materials and Engineering*, 292 (5), 608–619.

Kaddami, H., Dufresne, A., Khelifi, B., Bendahou, A., Taourirte, M., Raihane, M., Issartel, N., Sautereau, H., Gérard, J. -F. & Sami, N. (2006). Short palm tree fibers—Thermoset matrices composites. *Composites part A : Applied Science and Manufacturing*, 37(9), 1413–1422.

Kaye, A. (1962). *A contribution to the non-Newtonian fluid mechanics* (Doctoral dissertation, University of London).

Karkaria, V., Goeckner, A., Zha, R., Chen, J., Zhang, J., Zhu, Q., Cao, J., Gao, R. X., & Chen, W. (2024). *Towards a Digital Twin Framework in Additive Manufacturing: Machine Learning and Bayesian Optimization for Time Series Process Optimization*. arXiv preprint arXiv:2402.17718.

Klesov, A. A. (2007). *Wood-plastic composites*. Hoboken, N.J.: Wiley-Interscience.

Kohonen, T., "Self-Organized Formation of Topologically Correct Feature Maps", *Biological Cybernetics*, 43(1), 59–69, 1982.

Lamnawar, K. & Maazouz, A. (2008). Rheology and morphology of multi-layer reactive polymers: effect of interfacial area in interdiffusion/reaction phenomena. *Rheologica Acta*, 47(4), 383–397.

LeCun, Y., Bengio, Y., & Hinton, G., "Deep Learning", *Nature*, 521 (7553), 436–444, 2015.

Levenberg, K. (1944). A method for the solution of certain non-linear problems in least squares.

Lodge, A. S. (1964). *Elastic liquids*: Academic Press New York.

Martin, A., Manolache, S., Mattoso, L., Rowell, R. & Denes, F. (2000). *Plasma modification of sisal on high density polyethylene composites: effect on mechanical properties*. *Compte-rendu*.

McCulloch, W. S., & Pitts, W., "A Logical Calculus of the Ideas Immanent in Nervous Activity", *Bulletin of Mathematical Biophysics*, 5(4), 115–133, 1943.

Merchant, A., Batzner, S., Schoenholz, S. S., Aykol, M., & Cheon, G. (2023). *Scaling deep learning for materials discovery*. *Nature*, 615 (7952), 531-538.

Migneault, S., Koubaa, A., Erchiqui, F., Chaala, A., Englund, K. & Wolcott, M. P. (2009). Effects of processing method and fiber size on the structure and properties of wood-plastic composites. *Composites part A : Applied Science and Manufacturing*, 40(1), 80–85.

Migneault, S., et al. (2011). Application of micromechanical models to tensile properties of wood-plastic composites. *Wood Science and Technology*, 45(3), 521–532.

Minsky, M., & Papert, S. (1969). *Perceptrons: An introduction to computational geometry* (1st ed., pp. 1–153).

Mooney, M. (1940). A theory of large elastic deformation. *Journal of applied physics*, 11(9), 582–592.

Nishioka, A., Takahashi, T., Masubuchi, Y., Takimoto, J.-i. & Koyama, K. (2000). Description of uniaxial, biaxial, and planar elongational viscosities of polystyrene melt by the K-BKZ model. *Journal of non-newtonian fluid mechanics*, 89(3), 287–301.

Ogden, 1972. Large deformation isotropic elasticity—on the correlation of Theory and experiment for incompressible rubberlike solids. *School of Mathematics and Physics University of East Anglia, Norwich*.

Papanastasiou, A., Scriven, L. & Macosko, C. (1983). An integral constitutive equation for mixed flows: viscoelastic characterization. *Journal of Rheology*, 27(4), 387–410.

Personnaz, L. & Rivals, I. (2003). Réseaux de neurones formels pour la modélisation, la commande et la classification. CNRS, édition, Paris.

Ragoubi, M., et al. (2010). Impact of corona treated hemp fibres onto mechanical properties of polypropylene composites made thereof. *Industrial Crops and Products*, 31(2), 344–349.

Rosenblatt, F., “The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain”, *Psychological Review*, 65(6), 386, 1957.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323 (6088), 533–536.

Russell, S. J., & Norvig, P., *Artificial Intelligence: A Modern Approach* (4th ed.), Pearson, 2020.

Saheb, D. N. & Jog, J. (1999). Natural fiber polymer composites: a review. *Advances in Polymer Technology*, 18(4), 351–363.

Sigeru O., Marzuki K. & Rubiyah Y. (1996). *Neuro-Control and its Applications*. Springer-Verlag, London.

Suzuki, K. (2013). *Artificial Neural Networks—Architectures and Applications*.

Tazi, M. (2015). *Valorisation des Sciures de Bois dans des Composites thermoplastiques (HDPE-Bois) : Élaboration, Caractérisation et Modélisation en Soufflage libre*. UQAC.

Toufik, L. (2017). *Commande neuronale directe avec modèle inverse en utilisant le perceptron multicouche*.

Treloar, L. (1944). Stress-strain data for vulcanised rubber under various types of deformation. *Transactions of the Faraday Society*, 40, 59–70.

Vantal, M.-H., Monasse, B. & Bellet, M. (1995). Numerical simulation of the thermoforming of multi-layer polymer sheets. *Simulation of Materials Processing: Theory, Methods and Applications*.

Verron, E., Marckmann, G. & Peseux, B. (2001). Dynamic inflation of non-linear elastic and viscoelastic rubber-like membranes. *International Journal for Numerical Methods in Engineering*, 50(5), 1233–1251.

Wang, W., Sain, M. & Cooper, P. (2006). Study of moisture absorption in natural fiber plastic composites. *Composites Science and Technology*, 66(3), 379–386.

Wagner, M. H. (1976). Analysis of time-dependent non-linear stress growth experiments. *Journal of Rheology*, 20(2), 97–112.

Widrow, B., & Hoff, M. E. (1960). Adaptive Switching Circuits. IRE WESCON Convention Record, 4, 96–104.

Wolcott, M. P. & Englund, K. (1999). A technology review of wood-plastic composites. Proc. Wood Fiber-Plastic Composites, Forest Products Society, Madison, WI, 103–111.

Zhang, H., Lamnawar, K. & Maazouz, A. (2012). Rheological modeling of the diffusion process and the interphase of symmetrical bilayers based on PVDF and PMMA with varying molecular weights. *Rheologica Acta*, 51(8), 691–711.

Zhao, Y., et al. (2021). High-throughput discovery of novel cubic crystal materials using deep generative neural networks. *Advanced Science*, 8(15), 2,100,566.