REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE YAHIA FARES DE MEDEA



Faculté de **T**echnologie

Département de **Génie des Procédés et Environnement**

Mémoire de Fin d'Etudes de Master 2

Filière : Génie des Procédés

Spécialité : Génie des Matériaux

Thème :

Prédiction du comportement rhéologique d'un mélange de polymères immiscibles

Présentés par :

Bellatreche khaoula

Benyahia Ibtihel

Devant le Jury

Rahal Soufiane	Maitre de Conférences A	Président	Université de Médéa
Aliagha Hamza	Maitre de Conférences A	Examinateur	Université de Médéa
Ladeg Soufyane	Maitre de Conférences A	Encadrant	Université de Tissemsilt
Moulai-Mostefa N	Professeur Emérite	Co-encadrant	Université de Médéa

Promotion : 2024-2025

Dédicaces

Je dédie ce travail à toutes les personnes qui ont contribué, de près ou de loin, à ce chapitre important de ma vie.

À ma mère, mon pilier, mon tout, dont l'amour, les prières et les sacrifices silencieux m'ont portée jusqu'ici.

À mon frère, mon bras droit, toujours présent, toujours rassurant.

À mes amies Rania, Ibtihel, Nadia et Meriem, pour leur amitié sincère, leur écoute et leurs mots qui tombent toujours au bon moment.

À **mon allié silencieux**, pour sa présence discrète mais précieuse, et pour tout ce qui ne se dit qu'avec le cœur.

Et surtout **à moi-même**.

Pour ma patience, ma persévérance, mes nuits blanches, mes moments de doute et de silence.

Pour ne pas avoir abandonné, même quand tout semblait flou.

Merci à la version de moi qui a tenu bon.

Khaoula.

Dédicaces

À mes parents bien-aimés,

Pour votre amour inconditionnel, vos sacrifices silencieux, et votre foi en nous, même dans les moments les plus incertains. Vous êtes notre force, notre refuge, notre fierté. Ce travail est aussi le fruit de votre patience et de votre soutien inestimable.

À mes sœurs chéries,

Merci pour votre affection, votre présence rassurante et vos encouragements constants. Vous êtes un pilier discret mais essentiel.

À mes précieuses amies Khaoula, Rania et Sondoss,

Merci pour votre amitié sincère, vos sourires, vos mots d'encouragement et toutes ces petites choses qui ont rendu ce parcours plus doux et plus fort.

Et enfin, à moi-même,

Pour avoir persévéré, douté parfois, mais avancé toujours. Pour chaque pas franchi, chaque nuit blanche, chaque défi surmonté. Parce qu'il est important aussi de se remercier, d'avoir cru en nous jusqu'au bout.

Ibtihel.

Remerciements

Nous tenons à exprimer notre profonde reconnaissance à l'ensemble des enseignants et enseignantes qui nous ont accompagnés tout au long de ces cinq années d'études. Leur engagement constant, la qualité de leur enseignement et leur disponibilité ont grandement contribué à notre formation académique et à notre développement personnel. Qu'ils trouvent ici l'expression de notre sincère gratitude.

Nous adressons également nos remerciements les plus distingués à **Dr. Ladeg Soufiane**, notre encadrant, pour son accompagnement exemplaire, sa disponibilité sans faille et la qualité de ses conseils. Son encadrement rigoureux, sa bienveillance et son implication tout au long de ce travail ont été d'un soutien inestimable. Grâce à son expertise et à ses orientations précieuses, nous avons pu mener à bien ce mémoire dans les meilleures conditions.

À toutes les personnes qui ont, de près ou de loin, contribué à la réussite de ce travail, nous exprimons nos remerciements les plus sincères.

الملخص:

في هذه الدراسة، تم استخدام شبكة عصبية اصطناعية متعددة الطبقات لنمذجة السلوك الريولوجي للبولي ستيرين، والبولي بروبيلين ، و مزيجهما. ولهذا الغرض، تم التنبؤ بتغير اللزوجة و كذلك القيم المرتبطة بالخواص اللزجة المرنة، و خاصة معامل المرونة و معامل اللزوجة . تم استخدام عدة معايير كمدخلات، مثل درجة الحرارة و التردد. و قد تمت مقارنة القيم المتوقعة بواسطة الشبكة العصبية الاصطناعية مع البيانات اللتجريبية، بالاضافة الى القيم المستخرجة من نموذجين غير خطيين اخرين .تُمكن استنتاجات هذا البحث من وضع نموذج غير خطي يهدف الى تحديد الخصائص اللزجة المرنة للبوليميرات غير الممتزجة و مزيجها .

الكلمات المفتاحية : بوليميرات، عدم الامتزاج ، التوتر البيني ، اللزوجة المرنة، التنبؤ، الشبكات العصبية الصطناعية

Abstract

In this study, a multilayer artificial neural network (ANN) was used to model the rheological behavior of polystyrene (PS), polypropylene (PP3), and their blend. The aim was to predict the variation of viscosity as well as viscoelastic moduli, particularly the storage modulus (G') and the loss modulus (G''). Several parameters, including temperature and frequency, were used as input variables. The predicted values obtained from the ANN were compared with experimental data and with those derived from two other nonlinear models. The conclusions of this research contribute to the development of a nonlinear model for determining the viscoelastic properties of immiscible polymers and their blends.

Keywords: Polymers, Immiscibility, Interfacial tension, Viscoelasticity, Prediction, ANN).

Résumé

Dans cette étude on a utilisé un réseau neuronal artificiel à couches multiples (RNA) pour modéliser le comportement rhéologique du polystyrène (PS), du polypropylène (PP3) et de leur mélange. Pour cela, on a prédit la variation de la viscosité et celle des modules viscoélastiques, en particulier le module d'élasticité (G') et celui de viscosité (G''). L'effet de plusieurs paramètres (température et fréquence) sont utilisés comme entrées. Les valeurs prédites par le RNA seront comparées aux données expérimentales, ainsi qu'aux valeurs déduites par deux autres modèles non linéaires. Les conclusions de cette recherche permettront l'établissement d'un modèle non linéaire visant à déterminer les propriétés viscoélastiques des polymères immiscibles et de leurs mélanges.

Mots clés : Polymères, Immiscibilité, Tension interfaciale, Viscoélasticité, Prédiction, ANN.

PS	Polystyrène
PP3	Polypropylène (type ou grade 3)
G′	Module de stockage (comportement élastique)
G″	Module de perte (comportement visqueux)
η	Viscosité dynamique
τ	Contrainte de cisaillement
γ	Déformation angulaire (cisaillement)
ε	Déformation (traction)
σ	Contrainte (traction)
E	Module de Young
RNA	Réseau de Neurones Artificiel
ANN	Artificiel Neural Network (équivalent anglais de RNA)
MSE	Mean Squared Error (Erreur quadratique moyenne)
R	Coefficient de corrélation (ou de détermination)
TANSIG	Fonction d'activation tangente sigmoïde
LOGSIG	Fonction sigmoïde logistique
POSLIN	Fonction linéaire positive
MATLAB	Environnement de calcul numérique utilisé pour la simulation
X1, X2, X3	Entrées du modèle (température, fréquence, viscosité)
Y1, Y2	Sorties du modèle (G′ et G″)

Chapitre I

Figure I.1. Différentes propriétés étudiées par la rhéologie 4
Figure I.2. Viscosité en fonction du taux de cisaillement..... 4
Figure I.3. Expérience de la plaque mobile..... 5
Figure I.4. Solide élastique parfait 7
Figure I.5. Liquide visqueux Newtonien..... 7
Figure I.6. Modèles mécaniques du comportement viscoélastique 8
Figure I.7. Modules viscoélastiques en fonction de la fréquence..... 8
Figure I.8. Rhéomètres rotatifs cylindriques 9
Figure I.9. Rhéomètres rotatifs à cône/plateau 10
Figure I.10. Formule développée..... 11
Figure I.11. Représentations des propriétés..... 12
Figure I.12. Schéma d'obtention du polystyrène..... 13
Figure I.13. Classification des propriétés de polystyrène 13

Chapitre II

Figure II.1. Un neurone avec son arborisation dendritique..... 16
Figure II.2. Neurone biologique et neurone artificielle..... 18
Figure II.3. Réseau de neurones multicouche 21
Figure II.4. Modèle d'un neurone artificiel..... 21
Figure II.5. Exemple de réseau de neurones non bouclé..... 22
Figure II.6. Exemple de réseau de neurones bouclé..... 23
Figure II.7. Diférentes possibilités de classification des réseaux de neurones..... 23
Figure II.8. Illustration de l'apprentissage supervise 24
Figure II.9. Illustration de l'apprentissage non supervisé 25

Chapitre III

Figure III.1. Èvolution de MSE (erreur quadratique moyenne).....32
Figure III.2. Graphes de régrassion entre la sortie prédite et la cible réelle pour les ensembles d'entraînement, de validation, de test et global (Fonction TANSIG)..... 32
Figure III.3. Variation de l'erreur quadratique 34
Figure III.4. Variation de coefficient de corrélation R 35

Figure III.5. Évolution de MSE (l'erreur quadratique moyenne) 37
Figure III.6. Graphes de régression entre la sortie prédite et la cible réelle pour les ensembles d'entraînement, de validation, de teste et global pour meilleur performance 37
Figure III.7. Évolution de MSE du PS (erreur quadratique moyenne) 39
Figure III.8. Graphes de régression entre la sortie prédite et la cible réelle pour les 39
Figure III.9. Analyse de sensibilité des variables d'entrée sur les modules viscoélastiques. 41

Chapitre I

Tableau I.1. Quelques valeurs de la viscosité de substances usuelles à température ambiante 5

Tableau. I.2. Comportement viscoélastique de quelque polymère..... 6

Tableau I.3. Comparaison entre un rhéomètre et un viscosimètre 11

Chapitre II

Tableau II.1. Différentes fonctions d'activation utilisées dans les RNA..... 19

Chapitre III

Tableau III.1. Structure des données utilisées 27

Tableau III.2. Étapes de construction du réseau de neurones..... 30

Tableau III.3. Paramètres d'entraînement du réseau de neurones 30

Tableau III.4. Performances maximales selon les fonctions d'activation selon module G'... 31

Tableau III.5. Performances du modèle RNA pour G″ (à 44 neurones)..... 33

Tableau III.6. Performances du modèle RNA pour PS 36

Tableau III.7. Performances du modèle RNA pour PP3..... 38

Tableau III.8. Indices de sensibilité 40

Introduction général 1
Chapitre I 3
I.1. Introduction 3
I.2. Fondamentaux de la rhéologie des polymères 3
I.3. Différentes propriétés étudiées par la rhéologie 3
Figure I.1 : Différentes propriétés étudiées par la rhéologie 4
I.3.1. Viscosité 4
I.3.2. Viscoélasticité (comportement des matériaux complexes) 6
I.3.2.2. Mesure de la viscoélasticité 8
I.3.2.3. Principe et description des principaux rhéomètres 9
I.4. Notions sur les propriétés de quelques polymères 10
I.4.1. Présentation du Polypropylène 11
I.4.2. Présentation du polystyrène 12
I.5. Mélange de polymères 13
I.5.1. Compatibilisation des mélanges 14
I.5.2. Miscibilité : aspect thermodynamique 14
I.5.2. Morphologie des mélanges 14
I.5.3. Phénomène de coalescence 14
I.6. Conclusion 15
Chapitre II 16
II.1. Introduction 16
II.2. Structure et fonctionnement 16
II.2.1. Le Neurone 16
II.2.2 Anatomie des Neurones 17
a/ Les dendrites 17
b/ Le corps cellulaire 17
c/ L'axone 17
II.3. Les neurones formels 17
II.4. Modélisation générale 18
II.5. Description Architecturale 20
II.6. Modèles de réseaux de neurones artificiels 21
II.6.1. Réseaux Non-Boucles (feed-forword) 22
II.6.2. Réseaux boucles (récurrent) 22
II.7. Classification des réseaux de neurones 23
II.8. Apprentissage des réseaux de neurones 24
II.9. Conclusion 25

III.1. Introduction 26
III.2. Paramètres de simulation 26
III.2.1. Types et Description de données utilisée 27
III.2.2. Expérimentation et discussion 28
III.3. Interprétation et discussions des résultats 29
III.3.1. Processus d'entraînement du réseau de neurones 29
III.3.2. Analyse des résultats 30
III.3.2.1. Analyse de la performance pour le module de stockage G′ pour le mélange 30
III.3.2.2. Analyse du modèle RNA pour le module de perte G″ du mélange PP3/PS 33
III.3.2.3. Analyse du modèle RNA pour le Polystyrène 35
III.3.2.4. Analyse du modèle RNA pour le polypropylène 38
III.3.3. Analyse de sensibilité des variables d'entrée 40
III.4. Conclusion 42
Conclusion générale 44
Références 45

INTRODUCTION GENERALE

Introduction général

Les polymères ont connu un développement considérable et occupent aujourd'hui une place centrale dans de nombreux domaines industriels tels que l'emballage, l'automobile, l'électronique, le biomédical et bien d'autres. Cette omniprésence est due à leurs multiples avantages tels que la faible densité, le coût de production réduit, la résistance chimique élevée et les bonnes propriétés mécaniques.

Cependant, malgré ces qualités, un seul polymère ne suffit souvent pas à satisfaire les exigences techniques de certaines applications avancées. C'est dans cette optique que les mélanges de polymères ont été introduits, permettant de combiner les propriétés de plusieurs poly- mères en un seul matériau. Mais la majorité de ces mélanges sont immiscibles sur le plan thermodynamique, ce qui entraîne une séparation de phases, une mauvaise adhésion interfaciale et des propriétés mécaniques peu homogènes. Cette immiscibilité a un impact direct sur le comportement rhéologique du système, ce qui complique sa mise en œuvre industrielle.

La rhéologie, science qui étudie la déformation et l'écoulement des matériaux sous contrainte, constitue un outil essentiel pour analyser et comprendre ces comportements complexes. En particulier, les modules viscoélastiques (le module de stockage G′ et le module de perte G″) permettent de caractériser finement la réponse mécanique des polymères, notamment dans les mélanges hétérogènes. Traditionnellement, ces propriétés sont déterminées expérimentalement à l'aide de rhéomètres dynamiques. Mais ces essais sont souvent longs, coûteux, et nécessitent une instrumentation spécialisée. D'où l'intérêt croissant pour les approches de modélisation et de prédiction basées sur l'intelligence artificielle, en particulier les réseaux de neurones artificiels (RNA), capables de reproduire des comportements complexes à partir de données expérimentales limitées.

Dans ce cadre, le présent travail a pour objectif principal la modélisation et la prédiction du comportement rhéologique d'un mélange de polymères immiscibles. Notre choix s'est porté sur un mélange de polymères modèle formé le polypropylène (PP) et le polystyrène (PS) où des résultats expérimentaux sont disponibles et mis en notre possession par l'équipe encadrante. Pour la prédiction, nous avons utilisé une technique d'intelligence artificielle et, en particulier un réseau neuronal artificiel, en tenant compte de paramètres tels que la température, la fréquence d'excitation et la viscosité.

Pour répondre à cette problématique, le mémoire a été structuré en trois chapitres complémentaires. Le premier chapitre présente les fondements théoriques de la rhéologie des polymères. Il aborde en détail les concepts de viscosité, de viscoélasticité, ainsi que les différents

instruments de mesure (viscosimètres, rhéomètres). Il s'intéresse aussi aux propriétés spécifiques du PP et du PS, ainsi qu'aux défis liés à leur mélange. Le deuxième chapitre est dédié aux réseaux de neurones artificiels. Il traite de leur structure (neurones, couches, poids synaptiques), des fonctions d'activation, des types d'apprentissage (supervisé, non supervisé, par renforcement), et des algorithmes d'entraînement. Ce chapitre constitue le socle méthodologique du modèle prédictif développé dans cette étude. Le troisième chapitre, quant à lui, expose la démarche expérimentale et la modélisation par RNA appliquée aux données collectées. Les performances du modèle sont analysées à l'aide d'indicateurs tels que l'erreur quadratique moyenne (MSE) et le coefficient de corrélation (R^2). Une discussion approfondie est proposée pour évaluer la fiabilité du modèle et son potentiel d'application.

En somme, ce travail vise à démontrer que la synergie entre la rhéologie et l'intelligence artificielle constitue une voie prometteuse pour la caractérisation rapide, fiable et efficace des systèmes de polymères complexes, et ouvre de nouvelles perspectives pour le développement de matériaux innovants à propriétés maîtrisées.

Chapitre I :

RHEOLOGIE DES POLYMERES

I.1. Introduction

La rhéologie est la science qui étudie la relation entre les contraintes appliquées à un matériau et les déformations qu'il subit, notamment lors de son écoulement. Un échantillon est soumis à une sollicitation, provoquant une réponse mesurée. Lorsque ces grandeurs sont directement calculables, on parle de rhéologie fondamentale [1]. La rhéologie repose sur l'hypothèse d'un matériau continu, dont les points se déplacent de manière continue, restent voisins après déformation. Elle se divise en trois types :

- **expérimentale**, qui établit la relation contrainte–vitesse de déformation par des tests,
- **structurale**, qui relie ce comportement à la structure du matériau,
- **théorique**, qui propose des modèles mathématiques indépendamment de la microstructure [2].

Dans ce chapitre, nous proposons une introduction à la rhéologie et au procédé de transformation des polymères. Nous aborderons l'essentiel des informations et des méthodes d'étude liées à la science des mélanges de polymères et à leur modélisation.

I.2. Fondamentaux de la rhéologie des polymères

La rhéologie, terme introduit par Bingham en 1928, désigne l'étude des déformations et de l'écoulement de la matière sous l'effet de contrainte mécanique [1]. Elle étudie les relations entre contraintes et déformations, permettant, via la mécanique des milieux continus, de calculer leur répartition dans un corps soumis à des forces. En pratique, l'ingénieur utilise des disciplines appliquées comme la résistance des matériaux et l'hydraulique [3]. La rhéologie est la science de la déformation des matériaux, englobant à la fois la théorie et la pratique de la mesure. Universelle et interdisciplinaire, elle intervient dans tous les domaines, de l'industrie à la biologie, en s'appuyant sur la mécanique, la physique, la chimie et la biologie, tout en leur apportant des outils utiles pour comprendre le comportement de la matière [4].

I.3. Différentes propriétés étudiées par la rhéologie

La rhéologie étudie un ensemble de propriétés mécaniques qui décrivent le comportement des matériaux sous l'effet de contraintes externes. Parmi les principales propriétés analysées figurent la viscosité, l'élasticité, la plasticité et la viscoélasticité et, la thixotropie. La viscosité mesure la résistance à l'écoulement d'un fluide et varie en fonction de la température, de la vitesse de cisaillement et de la structure interne du matériau. L'élasticité, quant à elle, reflète la capacité d'un matériau à retrouver sa forme initiale après une déformation. La plasticité décrit le comportement irréversible d'un matériau au-delà d'une contrainte limite. D'autres

phénomènes complexes, comme la viscoélasticité qui combine les effets élastiques et visqueux ou la thixotropie caractérisée par une diminution temporaire de la viscosité sous agitation sont également étudiés. Ces propriétés sont essentielles pour comprendre et optimiser les procédés de transformation, de mise en forme et d'utilisation des matériaux, notamment dans les domaines des polymères, des aliments, des cosmétiques, et des matériaux biologiques. La rhéologie permet ainsi de relier les caractéristiques microscopiques des matériaux à leur comportement macroscopique, apportant une aide précieuse à la conception et au contrôle de produits aux performances ciblées [3].

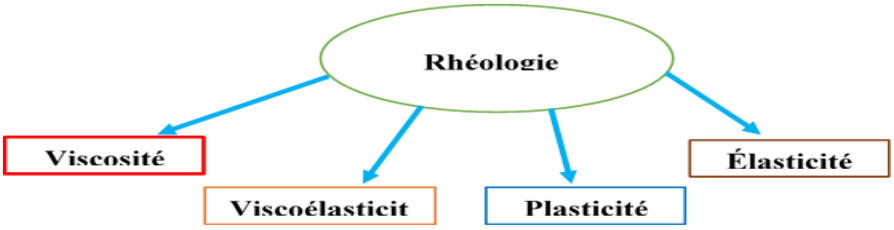


Figure I.1 **: Différentes propriétés étudiées par la rhéologie** [5]

I.3.1. Viscosité

La viscosité est la mesure de la résistance d'un fluide à l'écoulement lorsqu'il est soumis à une contrainte. Dans les matériaux non-Newtoniens, cette propriété varie en fonction du taux de cisaillement et de la température. En effet, un fluide à viscosité constante est considéré comme Newtonien, tandis qu'un fluide à viscosité variable (en fonction du cisaillement) est dit non-Newtonien. Par exemple, un matériau comme le ketchup est non-Newtonien, car sa viscosité diminue lorsqu'il est soumis à une contrainte de cisaillement, facilitant son écoulement. La viscosité est déterminée par plusieurs facteurs, dont la température, la pression et le taux de cisaillement [6].

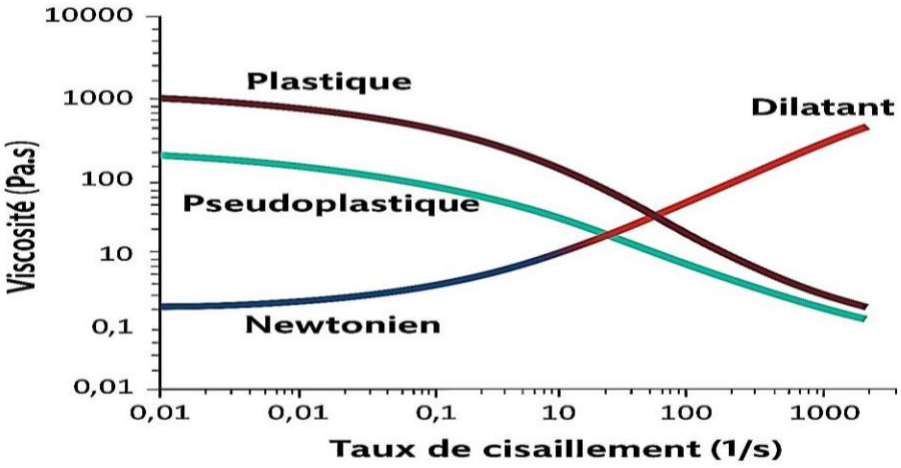


Figure I.2. Viscosité en fonction du taux de cisaillement [6]

a/ Viscosité dynamique (Loi de Newton)

Considérons deux couches contiguës distantes de dz.

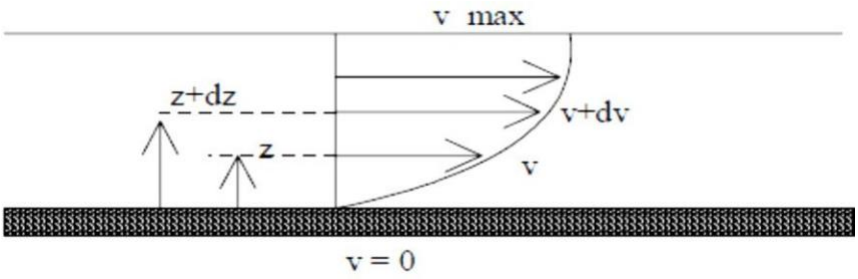


Figure I.3. Expérience de la plaque mobile [3]

La force de frottement $\vec{F}$ qui s'exerce à la surface de séparation de ces deux couches s'oppose au glissement d'une couche sur l'autre. Elle est proportionnelle à la différence de vitesse des couches soit dv, à leur surface S et inversement proportionnelle à dz :

$$\vec{F} = \eta S \frac{dv}{dz} \quad \text{(I.1)}$$

Le facteur de proportionnalité η est le coefficient de viscosité dynamique du fluide[6].

Le Tableau I.1 représente des valeurs de viscosité de quelques substances.

Tableau I.1. Quelques valeurs de la viscosité de substances usuelles à température ambiante [6]

Matériaux	Viscosité (Pa.s)
Air	10^{-5}
Eau	10^{-3}
Huile d'olive	10^{-1}
Glycérine	1
Polymères fondu	10^{3}
Bitume	10^{8}

b/ Viscosité cinématique

Le coefficient de viscosité cinématique est défini à partir du coefficient de viscosité dynamique η par la relation [6] :

$$\upsilon = \frac{\eta}{\rho} \quad \text{(I.2)}$$

Où ρ est la masse volumique du fluide.

Il existe plusieurs méthodes pour mesurer la viscosité d'un fluide, nous citons le viscosimètre d'Ubbeloh de ou d'Ostwald (loi de poiseuille), le viscosimètre rotatif ou viscosimètre de Couette et le viscosimètre à chute de bille [7].

Par ailleurs, il faut noter que la viscosité d'un fluide dépend de plusieurs paramètres tels que la température, le taux de cisaillement et la concentration de particules [6-9].

I.3.2. Viscoélasticité (comportement des matériaux complexes)

La viscoélasticité combine les propriétés visqueuses et élastiques des matériaux. Les matériaux viscoélastiques possèdent une capacité à se déformer de manière élastique et à revenir à leur forme originale sous certaines conditions. Ils présentent une résistance à l'écoulement mais aussi à l'élasticité lorsqu'ils sont soumis à des contraintes.

Tableau. I.2. Comportement viscoélastique de quelque polymère

Matériau	**Comportement fréquentiel typique**
PMMA (Plexiglas)	Transition vitreuse marquée, pic dans G′, G"
Polystyrène (PS)	Pic de G′, G" visible dans la zone de transition
Caoutchouc naturel	Comportement viscoélastique à basse fréquence
Polyuréthane	Très sensible à la température et à la fréquence

Un matériau viscoélastique linéaire présente un comportement intermédiaire entre un solide élastique, représenté par un ressort de module E (ou G), et un liquide visqueux newtonien, représenté par un amortisseur de viscosité η. Ces modèles sont utilisés pour simuler le comportement des matériaux lors de sollicitations mécaniques[10].

I.3.2.1 Modèles viscoélastiques

a/ Ressort

Le premier modèle est Le solide élastique parfait. Il est symbolisé par un ressort (Figure I.4) de module de rigidité G_0 et son équation rhéologique est décrite par la loi de Hooke [11]:

En cisaillement :

$$\tau = G^0 \cdot \gamma \quad \text{(I.3)}$$

En traction :

$$\sigma = \mathrm{E} \cdot \varepsilon \quad \text{(I.4)}$$

Où σ est la contrainte de traction (Pa), E est le module de young (Pa), ε est la déformation, τ est la contrainte de cisaillement (Pa), γ est l'angle de déformation (rad) et, G_0 est le module de rigidité (Pa).

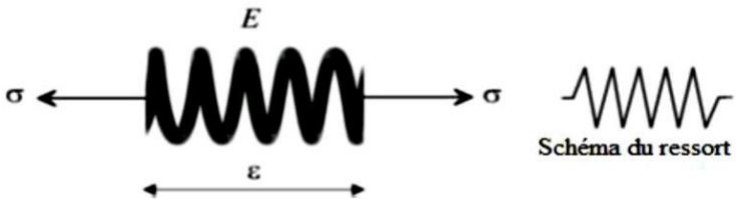


Figure I.4. Modèle du solide élastique parfait [10]

b/ Amortisseur

Ce modèle représente le fluide (liquide) newtonien (Figure I.5). Le modèle mathématique est la loi de Newton [10] :

En traction :

$$\sigma = \eta \cdot (\frac{ds}{dt}) = \eta \cdot \dot{\varepsilon} \quad \text{(I.6)}$$

En cisaillement

$$\tau = \eta \cdot (\frac{d\gamma}{dt}) = \eta \cdot \dot{\gamma} \quad \text{(I.7)}$$

Où η est la viscosité (Pa. s), $\dot{\varepsilon}$ *ou* $\dot{\gamma}$ est la vitesse de déformation (s^{-1}).

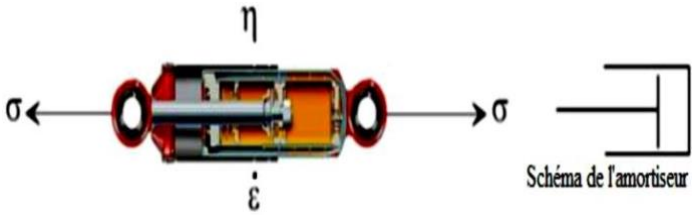


Figure I.5. Modèle de liquide visqueux Newtonien [10].

La viscoélasticité joue un rôle clé dans le comportement des polymères lors des traitements mécaniques, et comprendre ces mécanismes est crucial pour améliorer les performances des matériaux et des procédés industrielles associés.

c/ Modèles mécaniques du comportement viscoélastique

Une combinaison de ces modèles (ressorts et amortisseurs) permet de décrire le comportement des polymères. Les modèles mécaniques linéaires de base pour représenter des réponses viscoélastiques sont :

1. **Le modèle de Maxwell :** il est représenté par un amortisseur et un ressort mis en série comme l'indique le schéma de la Figure I.6-A :

2. **Le modèle de Kelvin-Voigt :** peut être représenté par un amortisseur et un ressort mis en parallèle comme l'indique le schéma de la Figure I.6-B.

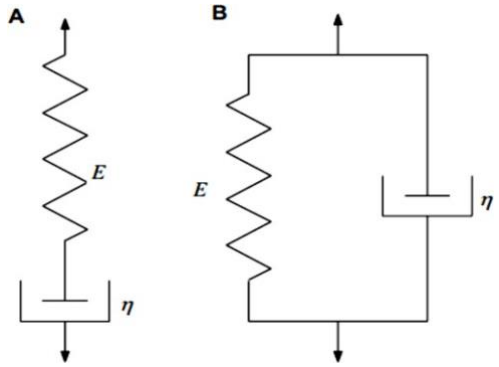


Figure I.6. Modèles mécaniques du comportement viscoélastique ;
A: Modèle de Maxwell ; B: Modèle de Kelvin-Voigt [10].

I.3.2.2. Mesure de la viscoélasticité

Les propriétés viscoélastiques des matériaux peuvent être mesurées à l'aide de rhéomètres oscillants, qui permettent d'étudier les modules de stockage (G ′) et de perte (G″) du matériau, comme le montre la Figure I.7. Le module de stockage (G′) représente l'élasticité du matériau, tandis que le module de perte (G″) décrit la viscosité du matériau.

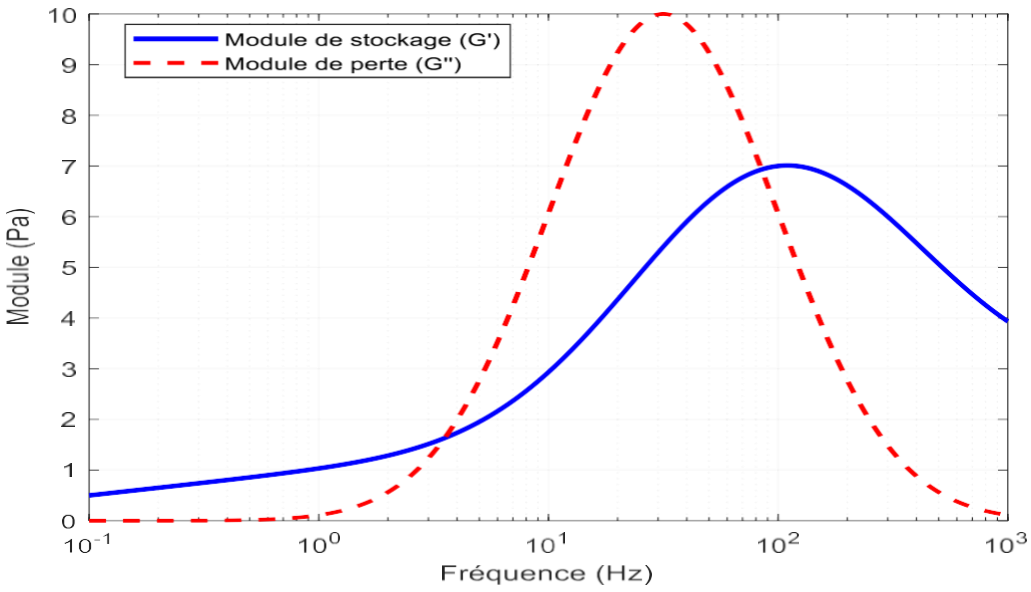


Figure I.7. Modules viscoélastiques en fonction de la fréquence.

I.3.2.3. Principe et description des principaux rhéomètres

Afin de caractériser le comportement viscoélastique des matériaux, il est essentiel de disposer d'appareils capables de le mesurer. La section suivante présente les principaux types de rhéomètres et qui peuvent être classés en trois catégories :

a) Les rhéomètres à régime permanent : utilisés comme viscosimètres, ils permettent néanmoins d'obtenir des rhéogrammes pour des liquides.

b) Les rhéomètres à régime transitoire permettent l'étude de la viscoélasticité des matériaux.

c) Les rhéomètres dynamiques qui fonctionnent en régime sinusoïdal forcé sont sûrement ceux qui fournissent le plus de renseignements des matériaux [8].

a) Rhéomètres à régime permanent

Les rhéomètres à régime permanent mesurent la réponse d'un fluide soumis à un cisaillement constant dans le temps. Ils sont adaptés aux substances liquides et permettent de tracer leur rhéogramme. Trois principaux types existent :

Rhéomètres de type Couette :

- ❖ Plans à translation : deux plaques parallèles, l'une mobile ; utilisés pour des mesures de viscosité (1 à 10^{10} Pa.s), mais peu précis.
- ❖ Rotatifs cylindriques : deux cylindres coaxiaux, l'un tournant ; les plus utilisés en laboratoire (Figure I.8).

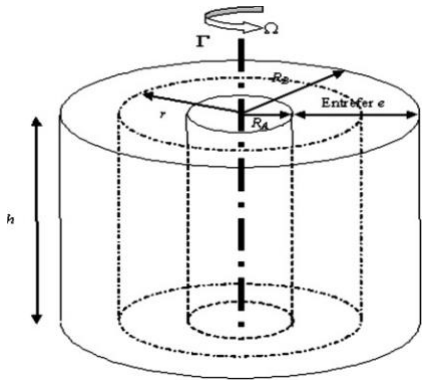


Figure I.8. Rhéomètres rotatifs cylindriques [6]

b) Rhéomètres rotatifs à cône/plateau

Moins répandu que le modèle cylindrique, le rhéomètre à cône/plateau est pourtant complémentaire et très précis. Il utilise un cône tournant à faible angle ($\Psi < 5°$) placé au-dessus d'un plateau fixe. La rotation du cône à vitesse constante ω_0 génère un cisaillement uniforme dans l'échantillon, réparti en couches coaxiales.

Deux modes de fonctionnement existent :

- Soit un couple MM est imposé, et on mesure la vitesse ω_0 ;
- Soit ω_0 est imposée, et on mesure MM.

Ce système permet de relier expérimentalement la vitesse de cisaillement $\dot{\gamma}$ et la contrainte τ à partir des grandeurs mesurées (Figure I.9).

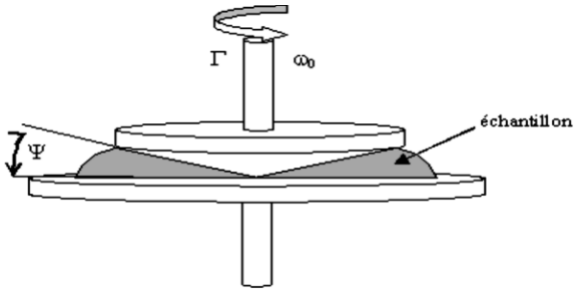


Figure I.9. Rhéomètres rotatifs à cône/plateau [6]

c) Rhéomètres à régime transitoire

Ces rhéomètres permettent d'analyser le comportement viscoélastique des matériaux en observant leur réponse à une sollicitation brusque et constante, avant l'établissement d'un régime permanent. On distingue deux types :

- Rhéomètres à fluage **:** contrainte constante, mesure de la déformation.
- Rhéomètres à relaxation **:** déformation instantanée imposée, suivi de l'évolution de la contrainte.

Les tests de relaxation permettent d'obtenir le spectre des temps de relaxation via le modèle de Maxwell généralisé. Ils nécessitent un pilotage en déformation, contrairement aux tests de fluage (pilotage en contrainte). Ils sont faciles à interpréter avec un spectre discret, mais difficiles en cas de spectre continu ou très rapproché, et peu efficaces pour les très courts temps de relaxation [6].

I.4. Notions sur les propriétés de quelques polymères

Les polymères sont de grandes molécules formées de monomères, dont les propriétés dépendent de la longueur et des connexions des chaînes. Leur comportement rhéologique (viscosité, viscoélasticité, etc.) est évalué par divers tests pour optimiser leurs performances en fonction des besoins [11]. On s'intéresse en particulier dans cette étude à deux polymères industriels et pour lesquels des données expérimentales existent sur leur caractérisation rhéologique, à savoir le Polystyrène (PS) et le Polypropylène (PP).

I.4.1. Présentation du Polypropylène

Le polypropylène (PP) est une polyoléfine saturée, thermoplastique et semi-cristalline, obtenue par polymérisation du propylène en présence de catalyseurs (Figure I.10). Ses propriétés dépendent fortement du procédé de polymérisation. Il se distingue par sa légèreté, sa résistance mécanique (traction, flexion, fatigue) et sa bonne résistance aux chocs [12].

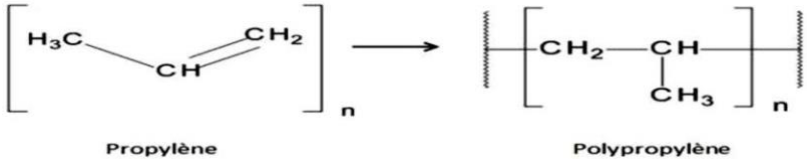
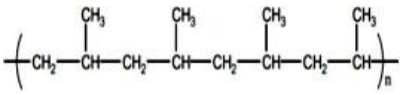
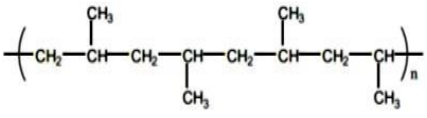
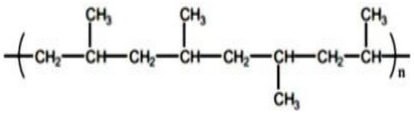


Figure I.10. Formule développée [12]

Le polypropylène est produit industriellement par polymérisation du propylène, un monomère obtenu à partir de pétrole ou de gaz naturel. Ce processus, réalisé en présence de catalyseurs métalliques à haute température et pression, forme de longues chaînes polymères. Le produit final est ensuite transformé en granulés, fibres ou films selon l'usage. Plusieurs techniques permettent d'obtenir un polypropylène de haute qualité [12].

Le polypropylène existe en trois types, selon l'arrangement des groupements CH_3 : isotactique (régulier et résistant), syndiotactique (alterné et souple), et atactique (désordonné et mou). Chaque type a des propriétés et des usages différents selon sa structure (Tableau I.3).

Tableau I.3. Tableau récapitulatif clair des trois types de polypropylène [16]

Type de PP	Structure moléculaire	Propriétés
Isotactique		Haut résistance à la chaleur ,aux UV ,à la corrosion ; bonne cristallinité
Syndiotactique		Résistance aux chocs et la chaleur ,structure régulière mais non homogène.
Atactique		Faible cristallinité ,basse de résistance mécanique et de température de fusion, structure amorphe.

Les propriétés du polypropylène sont étroitement liées à sa structure moléculaire. Elles peuvent être regroupées en propriétés thermiques, mécaniques, optiques et de surface, comme indiqué dans la Figure I.11.

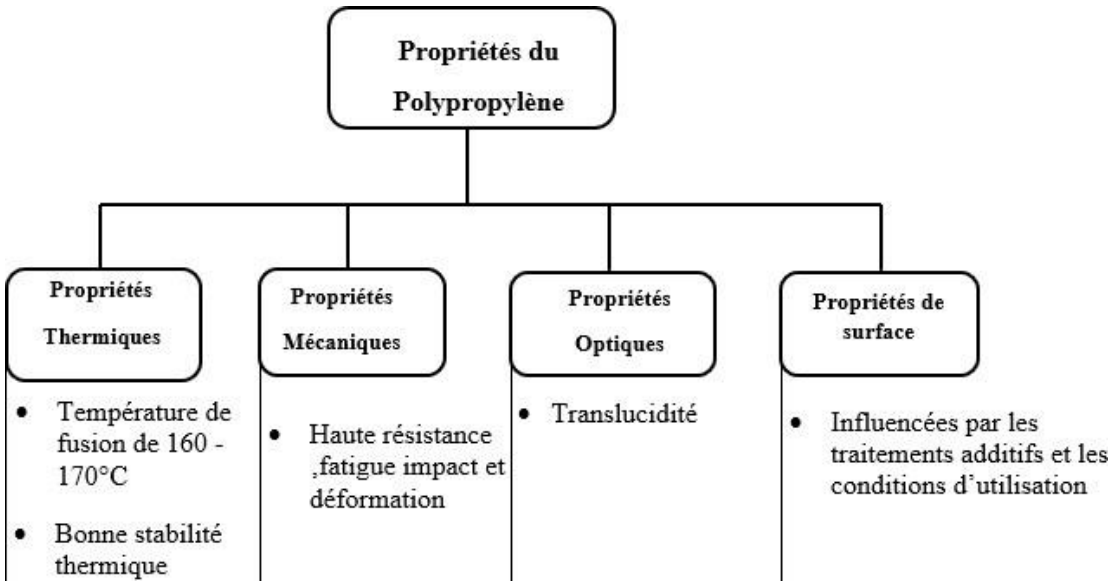


Figure I.11. Représentations des propriétés [12]

Les techniques de fabrication du polypropylène ont beaucoup évolué récemment, visant à accroître la productivité, réduire les coûts et améliorer la qualité des produits. Ces progrès incluent l'optimisation des procédés chimiques, le perfectionnement des méthodes thermiques de mise en forme, ainsi que le développement de technologies de recyclage et de purification plus efficaces et respectueuses de l'environnement [12].

I.4.2. Présentation du polystyrène

Le polystyrène est un polymère thermoplastique obtenu par polymérisation du styrène, un dérivé pétrochimique constitué d'un noyau benzénique lié au groupe $CH=CH_2$. Sa formule chimique est $(C_8H_8)_n$, composée uniquement de carbone et d'hydrogène (Figure I.12).

Le PS est un matériau dur, cassant, transparent, mais peut être rendu très léger lorsqu'il est mélangé à un gaz. Il existe en plusieurs variantes selon les applications : emballages, jouets, maquettes [13].

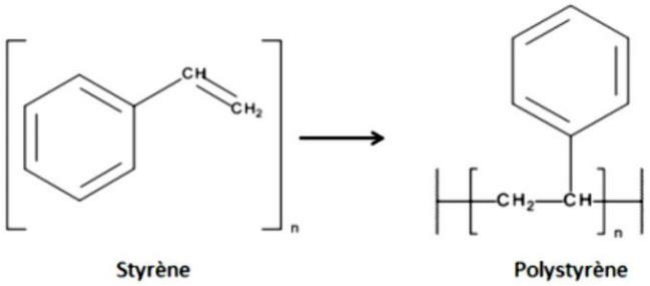


Figure I.12. Schéma d'obtention du polystyrène [13]

Le polystyrène est un polymère thermoplastique largement utilisé pour ses propriétés intéressantes tant sur le plan électrique que chimique. La Figure I.13 résume ses principales caractéristiques de manière synthétique :

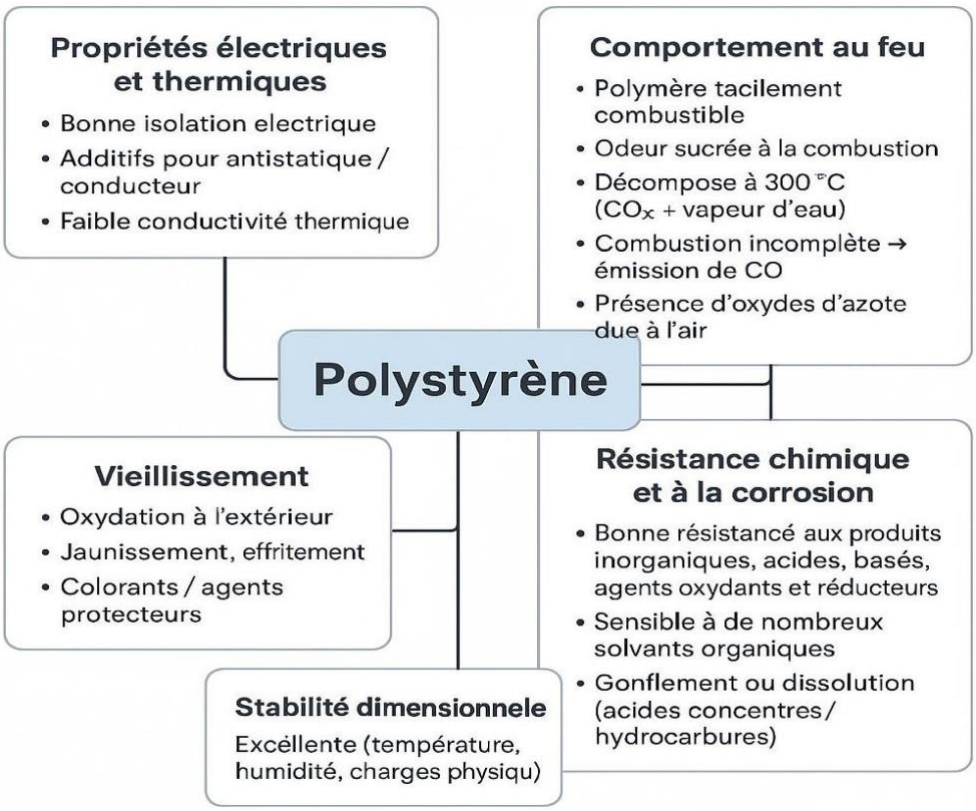


Figure I.13. Classification des propriétés de polystyrène [13]

I.5. Mélange de polymères

Les mélanges peuvent être classés selon leur compatibilité. Un mélange est dit miscible lorsqu'il forme un système monophasé à l'échelle moléculaire. Il se comporte alors comme un homopolymère, et ses propriétés varient selon une loi de mélange simple, en fonction de la composition. Les polymères miscibles sont souvent homologues ou présentent des masses

molaires similaires. À l'inverse, les mélanges non miscibles forment des systèmes hétérogènes dont les propriétés sont fortement influencées par la morphologie résultant des conditions de transformation. Le contrôle de cette morphologie est crucial mais délicat. Il existe aussi des mélanges dits compatibles, bien qu'immiscibles à l'échelle moléculaire. Ils sont homogènes à l'œil nu et présentent une amélioration notable d'au moins une propriété physique. Cette compatibilité est généralement obtenue par modification interfaciale ou morphologique.

I.5.1. Compatibilisation des mélanges

La compatibilisation désigne l'ensemble des actions menées pour améliorer les propriétés d'un mélange hétérogène. Elle implique souvent l'ajout d'un agent tiers qui réagit avec les phases présentes afin de stabiliser la morphologie et renforcer l'adhésion interfaciale. Les objectifs principaux sont la réduction de la tension interfaciale pour faciliter la dispersion, la stabilisation de la morphologie au cours de la transformation, et l'augmentation de l'adhésion à l'état solide pour améliorer le transfert de contraintes entre les phases, et donc les propriétés mécaniques du matériau.

I.5.2. Miscibilité : aspect thermodynamique

La miscibilité de deux polymères dépend de considérations thermodynamiques, notamment de l'énergie libre de mélange définie par l'équation $\Delta Gm = \Delta Hm - T\Delta Sm$. Pour qu'un mélange soit miscible, ΔGm doit être négatif. L'entropie de mélange (ΔSm) est généralement positive mais faible pour les macromolécules, ce qui rend la contribution de l'enthalpie (ΔHm) déterminante. Si les interactions entre les constituants sont répulsives, ΔHm est positive, rendant la miscibilité difficile. En revanche, si des interactions attractives existent, ΔHm peut devenir négative, favorisant la miscibilité.

I.5.2. Morphologie des mélanges

La morphologie d'un mélange de polymères décrit la répartition spatiale des phases, leur forme, leur taille et la nature de leurs interfaces. Elle influence fortement les propriétés finales du matériau. Dans le cas de mélanges incompatibles, on observe souvent une morphologie biphasée, résultant du processus de mélange.

I.5.3. Phénomène de coalescence

La coalescence se produit dans les mélanges non miscibles présentant une structure de type émulsion, où la phase minoritaire forme des gouttelettes dispersées dans une matrice continue.

Le processus de coalescence se déroule en plusieurs étapes : rapprochement des gouttelettes, déformation et évacuation de la matrice entre elles, rupture du film séparateur à une épaisseur critique, puis fusion des particules. Ce phénomène affecte fortement la stabilité et les propriétés finales du matériau[14].

I.6. Conclusion

Ce chapitre a permis de rappeler les principes fondamentaux de la rhéologie des polymères, les propriétés mesurées (viscosité, viscoélasticité), ainsi que les caractéristiques spécifiques du polypropylène et du polystyrène. Cette base est essentielle pour comprendre le comportement des mélanges immiscibles analysés dans les chapitres suivants.

Chapitre II :

RESEAU NEURONAL ARTIFICIEL

II.1. Introduction

Les réseaux de neurones artificiels (RNA) sont une avancée majeure en intelligence artificielle et apprentissage automatique ; ils sont inspirés du fonctionnement du cerveau humain. Composés de neurones interconnectés, ils analysent des données complexes, reconnaissent des motifs et prennent des décisions. Grâce à l'apprentissage supervisé ou non supervisé, ils ajustent leurs connexions pour améliorer leurs performances et généraliser à de nouveaux cas. Utilisés dans des domaines variés (santé, traduction, reconnaissance vocale, conduite autonome…), les RNA confèrent aux machines une intelligence adaptative, capable d'apprendre, s'adapter et évoluer.

Depuis 1985, les réseaux de neurones connaissent une croissance continue en théorie, structure et applications [15].

II.2. Structure et fonctionnement

II.2.1. Le Neurone

Le neurone est une cellule composée d'un corps cellulaire et d'un noyau. Le corps cellulaire se ramifie pour former ce que l'on nomme les dendrites. Celles-ci sont parfois si nombreuses que l'on parle alors de chevelure dendritique ou d'arborisation dendritique. C'est par les dendrites que l'information est acheminée de l'extérieur vers le soma, corps du neurone. L'information traitée par le neurone chemine ensuite le long de l'axone (unique) pour être transmise aux autres neurones. La transmission entre deux neurones n'est pas directe. En fait, il existe un espace intercellulaire de quelques dizaines d'Angströms (10^{-9} m) entre l'axone du neurone afférent et les dendrites (on dit une dendrite) du neurone efférent (Figure II.1). La jonction entre deux neurones est appelée la synapse [16].

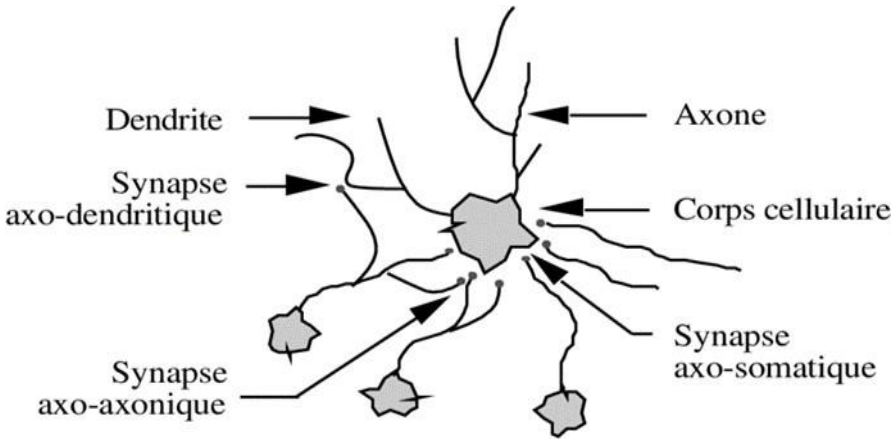


Figure II.1. Un neurone avec son arborisation dendritique [16]

II.2.2 Anatomie des Neurones

Le neurone est une cellule constituée principalement de trois parties :

- Dendrites,
- Corps cellulaire
- Axone.

a/ Les dendrites

Elles sont des fines extensions tubulaires. Elles sont ramifiées, ce qui les amène à faire une espèce d'arborescence autour du corps cellulaire. Cette partie collecte des signaux venant d'autres cellules ou de l'extérieur. La réception des signaux en provenance des autres neurones se fait par des points de contacts appelés synapses. Ces informations, qui ne sont rien d'autre que des impulsions électriques, sont par la suite acheminées vers le corps cellulaire.

b/ Le corps cellulaire

Il contient le noyau de neurone, recueille les informations reçues et en fait une sommation dite "spatio-temporelles", si le potentiel somatique dépasse un certain seuil, il émission d'un potentiel d'action appelé "spike" qui correspond à une oscillation électrique très brève.

c/ L'axone

Il sert comme moyen de transport pour les signaux émis par le neurone (l'information traitée) vers l'extérieur, et répartie sur les synapses de neurones cibles grâce à arborescence terminale que possède l'axone. Il se distingue des dendrites par sa forme et par les propriétés de sa membrane externe. En effet il est généralement plus long que les dendrites et se ramifie à son extrémité, là où il communique avec d'autres neurones [17].

II.3. Les neurones formels

Chaque neurone artificiel est un processeur élémentaire. Il reçoit un nombre variable d'entrées en provenance de neurones en amont. A chacune de ces entrées est associé un poids (paramètre) *w,* représentatif de la force de la connexion. Chaque processeur élémentaire est doté d'une sortie unique, qui se ramifie ensuite pour alimenter un nombre variable de neurones avals. Les réseaux de neurones formels sont issus d'une tentative de modélisation mathématique du cerveau humain, cette modélisation consiste à mettre en œuvre un système de réseau de neurones artificiels qu'il existe pour chaque élément composant le neurone biologique, un

élément correspondant dans le neurone artificiel [18]. Dans la Figure II.2, on présente une description comparative entre un neurone biologique et un neurone artificiel.

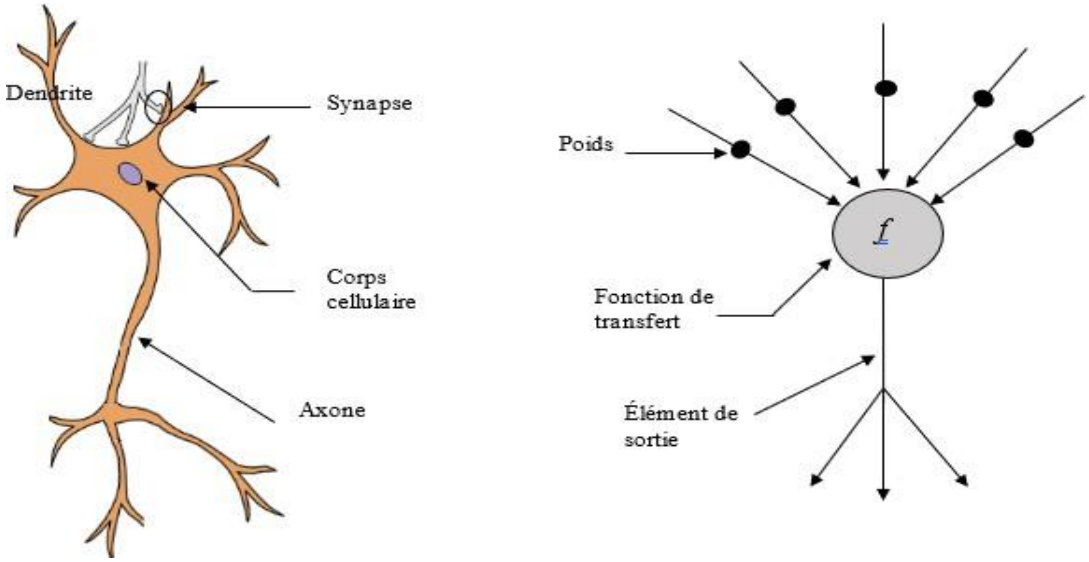


Figure II.2. Neurone biologique et neurone artificiel [18]

On comprend que le neurone artificiel est un modèle mathématique simplifié du neurone biologique. Il reçoit plusieurs signaux d'entrée, chacun étant multiplié par un poids. Ces entrées pondérées sont ensuite sommées, et cette somme est transformée par une fonction d'activation non linéaire.

$$y = f(\sum_{i=1}^{n} w_i x_i + b \qquad \text{(II.1)}$$

Où y est la sortie du neurone, w_i : sont les poids synaptiques, b : est le biais (ou seuil), et f est la fonction d'activation.

Un réseau de neurones multicouche (MLP) est constitué :

- d'une couche d'entrée (où les données entrent),
- d'une ou plusieurs couches cachées,
- d'une couche de sortie.

Chaque neurone dans une couche est connecté à tous les neurones de la couche suivante (architecture entièrement connectée). L'apprentissage du réseau consiste à ajuster les poids pour réduire l'erreur entre la sortie calculée et la cible réelle.

II.4. Modélisation générale

On peut modéliser un réseau de neurone par des élémentaires qu'il s'agit de :

- **La nature de ses entrées :** qu'ils peuvent être binaire (0 ou 1), (-1,1) ou réelles appartenant souvent à intervalle bornée [a, b].

- **Fonction des entrées :** que sa signifie qu'elle peut définir le pré traitement effectuée sur les entrées.
- **Fonction de sortie :** Cette fonction calcule la sortie du neurone en fonction de son état

D'activation.

- **Fonction d'activation ou de seuillage :** Il existe de nombreuses formes possibles pour La fonction d'activation est un élément clé des réseaux de neurones. Les plus courantes sont généralement continues, et sont présentées dans la majorité des études sur les fonctions d'activation, offrant une infinité de valeurs possibles comprises dans l'intervalle [0, +1] (ou [-1, +1]).

Toutes les fonctions d'activation utilisées doivent être différentiables, car l'architectures des réseaux de neurones l'impose pour que l'apprentissage soit possible (Tableau II.1).

Tableau II.1. Différentes fonctions d'activation utilisées dans les RNA [17]

Non de la fonction	Relation entrée/sortie	Nom sur MATLB
Seuil	$Y = 0 \quad si \quad x < 0$ $Y = 1 \quad si \quad x \geq 0$	Hardlim
Seuil symétrique	$Y = -1 \quad si \quad x < 0$ $Y = 1 \quad si \quad x \geq 0$	Hardlims
Linéaire	$Y = x$	Purelin
Linéaire saturée	$Y = 0 \quad si \quad x \leq 0$ $Y = x \quad si \quad 0 < x \leq 1$ $Y = 1 \quad si \quad x \geq 1$	Satlin
Linéaire saturée symétrique	$Y = -1 \quad si \quad x < -1$ $Y = x \quad si \quad -1 < x \leq 1$ $Y = 1 \quad si \quad x \geq 1$	Satlins
Linéaire positive	$Y = 0 \quad si \quad x \leq 0$ $Y = x \quad si \quad x \geq 0$	Poslin
Sigmoïde	$y = \frac{1}{1 + exp(-x)}$	Logsig
Tangente hyperbolique	$y = \frac{exp(x) - exp(-x)}{exp(x) + exp(-x)}$	Tansing
Compétitive	$Y = 1 \quad si \quad x \ maximum$ $Y = 0 \quad autrement$	Compet

Les fonctions d'activation jouent un rôle fondamental pour introduire la non-linéarité dans le réseau. Les plus utilisées dans ce travail sont :

- **LOGSIG** : sigmoïde logistique

$$f(x) = \frac{1}{1+e^{-x}} \quad \text{(II.2)}$$

- **TANSIG** : sigmoïde hyperbolique

$$f(x) = \frac{2}{1+e^{-2x}} - 1 \quad \text{(II.3)}$$

- **POSLIN** : fonction linéaire positive

$$f(x) = \max(0, x) \quad \text{(II.4)}$$

II.5. Description Architecturale

Les réseaux de neurones artificiels s'organisent généralement en couches, à l'image du cerveau humain. Cette organisation permet de traiter l'information de manière progressive.

II.5.1. Les couches (les briques élémentaires)

a) Couche d'entrée : Elle reçoit les données brutes à traiter. Chaque neurone de cette couche correspond à une composante de l'entrée (par exemple, un pixel d'une image).

b) Couches cachées : Elles se situent entre la couche d'entrée et la couche de sortie. Elles permettent de réaliser des traitements complexes sur les données. Le nombre de couches cachées et le nombre de neurones par couche influencent la capacité d'apprentissage du réseau.

c) Couche de sortie : Elle produit les résultats finaux du réseau. Le nombre de neurones de cette couche correspond au nombre de sorties souhaitées (par exemple, la classification d'une image en différentes catégories)[17].

II.5.2. Réseau multicouche

Les couches d'un réseau multicouche sont interconnectées, permettant à l'information de se propager de la couche d'entrée vers la couche de sortie. Chaque neurone d'une couche reçoit les informations des neurones de la couche précédente, les combine et les transforme avant de les transmettre à la couche suivante, comme le montre la Figure II.3.

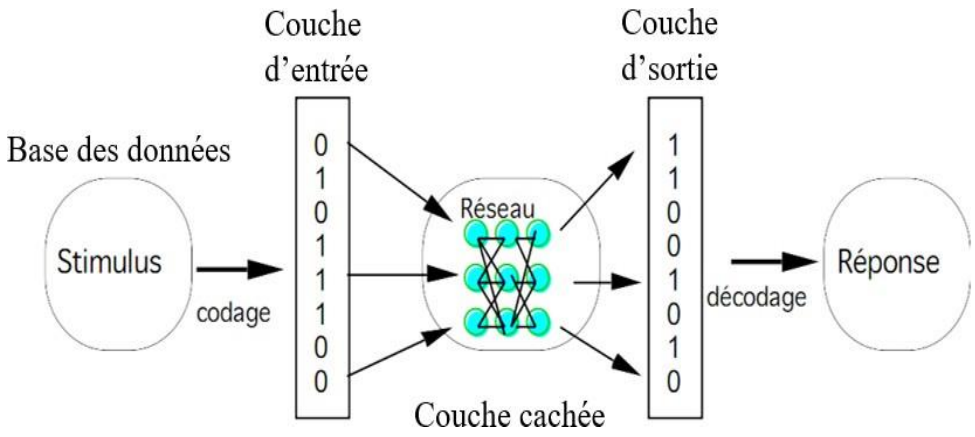


Figure II.3. Réseau de neurones multicouche [17]

II.6. Modèles de réseaux de neurones artificiels

Un réseau de neurones (RN) est un système d'opérateurs non linéaires interconnectés, inspiré du cerveau humain. Il traite l'information de manière parallèle et distribuée à travers des unités appelées neurones. Chaque neurone agit indépendamment, mais reste connecté aux autres, comme indiqué dans la Figure II.4.

L'information n'est pas stockée localement, mais répartie dans tout le réseau. Contrairement aux programmes classiques, un RN n'est pas codé pour une tâche précise : il apprend à la réaliser en s'entraînant sur des données. Ce fonctionnement rappelle celui des neurones biologiques [17].

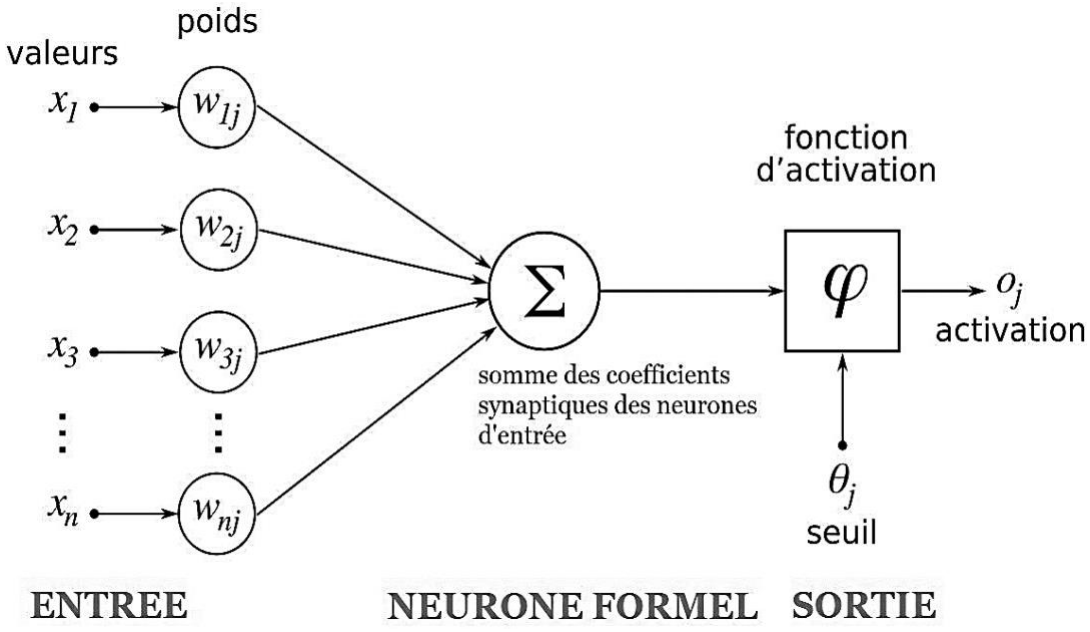


Figure II.4. Modèle d'un neurone artificiel [17]

- Les X_i représentent les vecteurs d'entrées, elles proviennent soit des sorties d'autres neurones soit de stimuli sensoriels (capteur visuel, sonore…).
- Les W_{ij} sont les poids synaptiques du neurone j. Ils correspondent à l'efficacité synaptique dans les neurones biologiques ($W_{ij} > 0$: synapse excitatrice ; $W_{ij} < 0$: synapse inhibitrice). Ces poids pondèrent les entrées et peuvent être modifiés par apprentissage.
- Biais : entrée prend souvent les valeurs -1 ou +1 qui permet d'ajouter de la flexibilité au réseau en permettant de varier le seuil de déclenchement du neurone par l'ajustement des poids et du biais lors de l'apprentissage[17].

II.6.1. Réseaux Non-Boucles (feed-forword)

Les réseaux non bouclés, aussi appelés réseaux *feedforward* ou à propagation directe, sont des architectures dans lesquelles l'information circule uniquement des entrées vers les sorties, sans retour en arrière. Contrairement aux réseaux neuronaux récurrents, ils ne possèdent pas de rétroactions internes. Le traitement des données s'effectue de manière linéaire et statique, couche après couche. Chaque couche applique une transformation mathématique aux données reçues, jusqu'à générer les résultats en sortie. L'ensemble du réseau peut être représenté par une fonction algébrique complexe, résultant de la composition des transformations successives (Figure II.5).

Cette fonction établit une correspondance directe entre les données d'entrée et les sorties souhaitées [17].

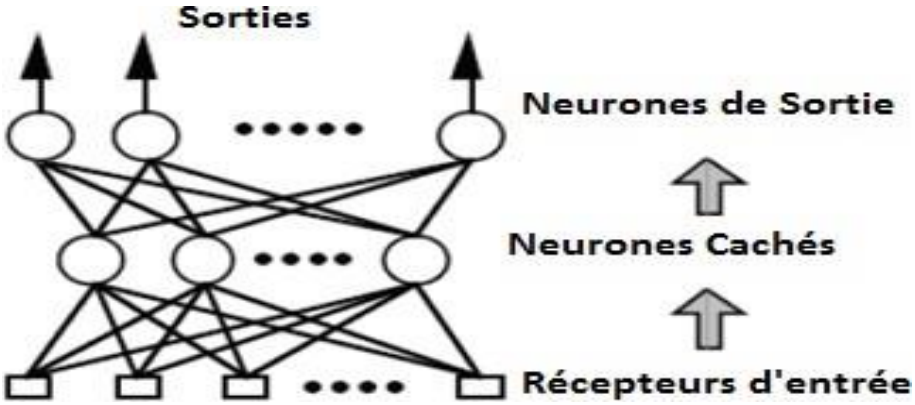


Figure II.5. Exemple de réseau de neurones non bouclé [17]

II.6.2. Réseaux boucles (récurrent)

Un réseau à boucles se caractérise par la présence de cycles (boucles) dans son graphe de connexions, comme illustré dans la Figure II.6. Ces réseaux dynamiques sont utilisés dans

divers domaines, notamment comme filtres non linéaires et pour la modélisation et la commande de processus. Le fonctionnement d'un réseau à boucles est régi par un ensemble d'équations aux différences couplées. Ces équations décrivent l'évolution des signaux au sein du réseau, en tenant compte des interactions entre les différents nœuds. Cette structure permet de réaliser des opérations complexes, telles que le filtrage non linéaire ou la modélisation de systèmes dynamiques [17].

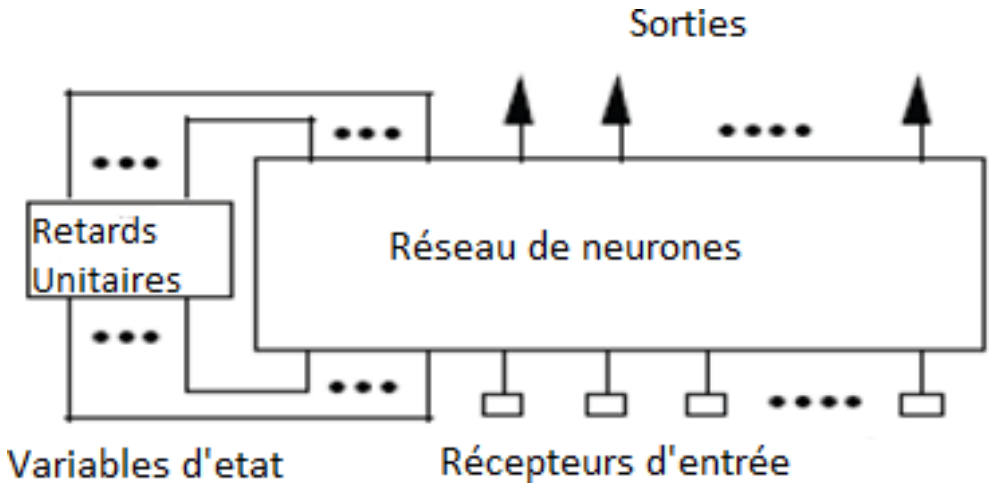


Figure II.6. Exemple de réseau de neurones bouclé [17]

II.7. Classification des réseaux de neurones

La Figure II.7 résume les trois différentes possibilités suivantes lesquelles on peut classer les réseaux de neurones [17].

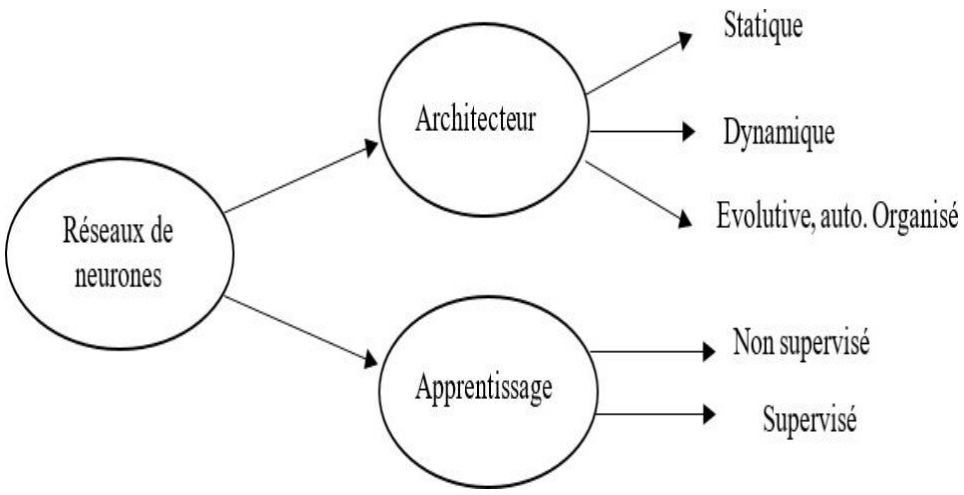


Figure II.7. Différentes possibilités de classification des réseaux de neurones

II.8. Apprentissage des réseaux de neurones

L'idée de conférer aux réseaux de neurones la capacité d'apprendre s'inspire des travaux pionniers de Donald Hebb. L'apprentissage, étape cruciale dans le développement d'un réseau neuronal, consiste à ajuster les poids des connexions entre les neurones afin d'obtenir des sorties aussi proches que possible des résultats attendus. Pour ce faire, le réseau s'appuie sur des exemples concrets illustrant le comportement du système qu'il vise à modéliser. On distingue trois grandes catégories d'apprentissage [17].

- **Apprentissage supervisé :** L'apprentissage supervisé suppose l'existence d'un expert (ou éducateurs) qui possède une connaissance innée de l'environnement. Le rôle d l'expert est de fournir les informations relatives à l'environnement nécessaires à l'apprentissage de réseau, sous forme d'un ensemble D'exemples composés de stimuli auxquels sont associées des réponses désirées (ou comportement souhaités), Dans ce mode d'apprentissage, les réponses désirées fournies par l'expert décrivent la fonction de réseau. Au cours de l'apprentissage, on présente une entrée et on compare la sortie obtenue à la sortie désirée fournie par l'expert (Figure II.8). La différence entre la réponse désirée et la réponse du réseau est alors utilisée pour adapter les paramètres du réseau de façon à corriger son comportement ce processus est ainsi répété jusqu'à émulation de l'expert par le réseau de neurones artificiels [17].

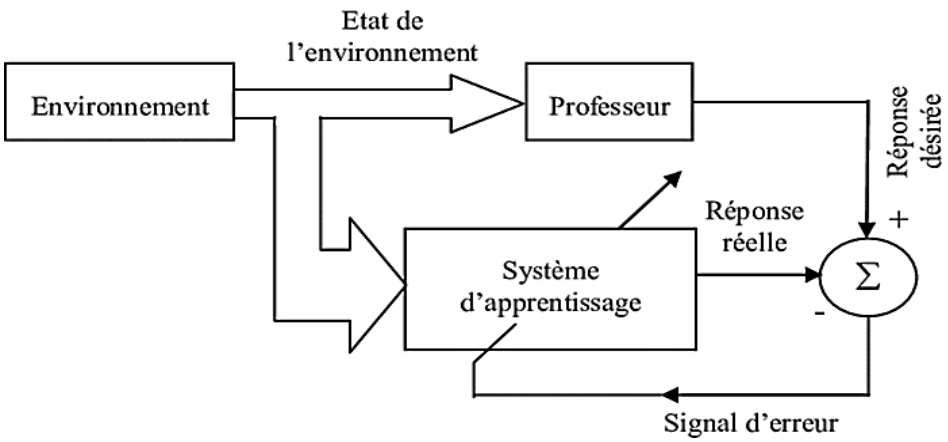


Figure II.8. Illustration de l'apprentissage supervise [17].

Apprentissage non supervisé : Contrairement à l'apprentissage supervisé effectué sous contrôle d'un expert, l'apprentissage non supervisé est autodidacte. L'ensemble des exemples d'apprentissages ne comprend que des stimuli. Aucune réponse désirée n'est associée, Cet apprentissage consiste à détecter automatiquement des régularités qui figurent dans les exemples présentés et modifier les poids des connexions pour que les exemples ayant les mêmes

caractéristiques de régularités provoquent la même sortie. Ce type d'apprentissages est représenté schématiquement dans la Figure II.9.

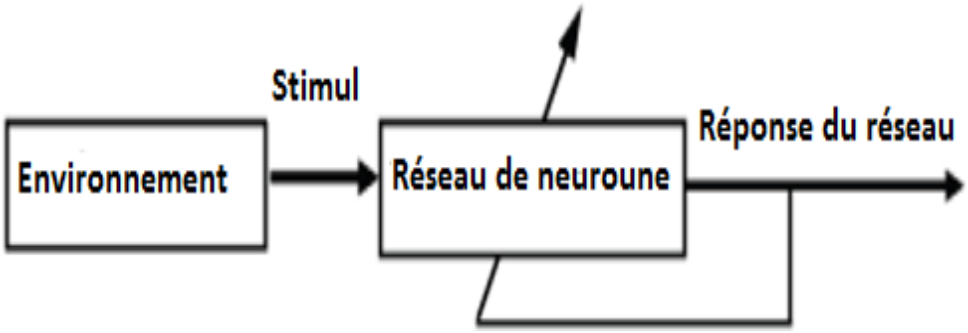


Figure II.9. Illustration de l'apprentissage non supervisé [17]

Apprentissage par renforcement : Ici, le réseau apprend par interaction avec son environnement. Il reçoit des récompenses ou des pénalités en fonction de ses actions, ce qui lui permet d'affiner progressivement son comportement [17].

II.9. Conclusion

Ce chapitre a permis de comprendre les bases des réseaux de neurones artificiels, leur architecture, les types d'apprentissage et les paramètres de configuration. Ces éléments sont essentiels pour la mise en œuvre du modèle prédictif présenté dans le chapitre suivant, dédié aux résultats et à leur analyse.

Chapitre III :

RESULTATS ET DISCUSSIONS

III.1. Introduction

Ce chapitre présente l'utilisation des réseaux de neurones artificiels (RNA) pour modéliser les modules viscoélastiques de stockage (G') et de perte (G") de deux polymères purs, le polypropylène (PP3) et le polystyrène (PS), ainsi que de leur mélange binaire (PP3/PS). L'étude vise à comprendre le comportement mécanique et la structure interne des polymères à travers ces modules, influencés par des paramètres comme la température, la fréquence ou la composition. En raison de la complexité des modèles théoriques classiques pour les systèmes multiphases, les RNA offrent une alternative efficace en capturant les relations non linéaires entre variables physico-chimiques et propriétés rhéologiques. L'objectif est d'évaluer leur capacité prédictive et d'analyser la sensibilité du système viscoélastique aux conditions opératoires.

III.2. Paramètres de simulation

Dans cette étude, les données utilisées pour entraîner le réseau de neurones proviennent d'essais rhéologiques réalisés sur un mélange polymère constitué de polypropylène (PP3) et de polystyrène (PS), avec une proportion massique de 30% de PP3 et 70% de PS. Chaque échantillon dans ce mélange est caractérisé par deux paramètres d'entrée : la température (°C), la fréquence d'excitation (rad/s). Ces variables influencent fortement le comportement viscoélastique du mélange. Les sorties à prédire sont constituées de deux grandeurs physiques fondamentales : le module de stockage (G′), qui reflète le caractère élastique du matériau, et le module de perte (G″), associé à la dissipation visqueuse de l'énergie. Les données ont été normalisées à l'aide d'un code sur MATLAB, afin de garantir une convergence optimale de l'algorithme d'apprentissage. Ensuite, elles ont été divisées en trois sous-ensembles: apprentissage, validation et test, selon une méthode glissante sur les échantillons, garantissant une représentativité équilibrée des données.

- ✓ 70% pour l'apprentissage
- ✓ 30% pour (15% tests et 15% validation)

Le réseau de neurones utilisé est un réseau à propagation avant (feedforward neural network) comprenant une seule couche cachée, composée de 12 neurones. La fonction d'activation choisie est de type log-sigmoïde pour la couche cachée, et linéaire pour la couche de sortie. L'algorithme d'apprentissage utilisé est celui de Levenberg-Marquardt, reconnu pour son efficacité dans les problèmes de régression non linéaire. L'évaluation des performances du modèle s'est basée sur deux indicateurs : l'erreur quadratique moyenne (MSE) et le coefficient de détermination (R), calculés pour les ensembles d'apprentissage, de test et de validation.

III.2.1. Types et Description de données utilisée

Les données utilisées dans cette étude sont de nature expérimentale et numérique continue. Elles ont été obtenues à partir d'essais rhéologiques réalisés sur trois systèmes distincts : i) le mélange immiscible PP3/PS (30%/70 %), ii) le polypropylène pur (PP3) et, iii) le polystyrène pur (PS).

- **Données sur le mélange PP3/PS**

Pour ce système, chaque échantillon est décrit par deux variables d'entrée, à savoir la température (°C), la fréquence d'excitation (rad/s). Les variables de sortie sont le module de stockage G′ (comportement élastique) et le module de perte G″ (comportement visqueux).

- **Données sur les polymères purs**

Pour les polymères purs (PP3 et PS), une troisième variable d'entrée est prise en compte en plus de la température et de la fréquence ; il s'agit de la viscosité dynamique (η), exprimée en Pa.s ; elle influence fortement les modules viscoélastiques. Ainsi, chaque échantillon PP3 ou PS est caractérisé par la température (°C), la fréquence (rad/s) et la viscosité η (Pa·s). Par contre, les sorties restent identiques, à savoir *G′ et G″*. Toutes ces données ont été structurées sous forme de matrices pour être compatibles avec le traitement automatique par réseau de neurones. Dans le Tableau III.1, on présente la structure des données utilisées.

Tableau III.1. Structure des données utilisées

Variable	Type	Unité	Rôle	Description
Température	Numérique	°C	Entrée (X_1)	Température à laquelle la mesure est effectuée
Fréquence	Numérique	Rad/s	Entrée (X_2)	Fréquence d'excitation du test rhéologique
Viscosité	Numérique	Pa.s	Entrée (X_3)	Influençant la viscoélastique
Module de stockage G'	Numérique	Pa	Sortie (Y_1)	Réponse élastique du mélange
Module de perte G''	Numérique	Pa	Sortie (Y_2)	Réponse visqueuse du mélange

III.2.2. Expérimentation et discussion

III.2.2.1. Environnement de simulation

Toutes les étapes de traitement, de normalisation, d'apprentissage et de simulation ont été réalisées à l'aide du logiciel MATLAB, qui est un environnement de calcul numérique performant. Un code de calcul a été utilisé pour créer, entraîner et évaluer un réseau de neurones à propagation avant.

III.2.2.2. Outils et fonctions MATLAB exploités

Plusieurs fonctions spécifiques de MATLAB ont été utilisées pour le traitement des données, la conception du réseau, son apprentissage et l'évaluation des résultats. Les principales fonctions utilisées sont les suivantes :

Xlsread : utilisée pour importer les données expérimentales à partir du fichier Excel ps.xlsx.

Premnmx : applique une normalisation min-max aux données d'entrée et de sortie, les ramenant dans l'intervalle [−1, +1], ce qui facilite la convergence lors de l'entraînement.

Feedforwardnet : permet de créer un réseau de neurones à propagation avant avec une ou plusieurs couches cachées personnalisables.

Postmnmx : inverse l'effet de la normalisation appliquée par premnmx, en reconvertissant les données prédictives normalisées à leur échelle physique d'origine (ex. : Pascal).

Ces fonctions ont été intégrées dans un script MATLAB complet permettant d'automatiser toutes les étapes de la modélisation, depuis le prétraitement jusqu'à l'évaluation finale.

III.2.3. Architecture du réseau de neurones

Le réseau utilisé est un réseau à propagation avant (feedforward), composé d'une seule couche cachée contenant 12 neurones. Afin d'optimiser la prédiction, plusieurs fonctions d'activation ont été testées dans la couche cachée :

- Logsig (fonction sigmoïde logarithmique).
- Tansig (fonction sigmoïde tangente hyperbolique).
- Poslin (fonction linéaire positive, ou ReLU simplifiée).

Ces variantes ont permis de comparer les performances en termes d'erreur quadratique moyenne (MSE) et de coefficient de corrélation (R), générés automatiquement par le logiciel sous forme de graphes a interprété. La fonction d'activation de la couche de sortie est restée linéaire (purelin), afin d'assurer une sortie continue adaptée à la régression.

III.3. Interprétation et discussions des résultats

Dans cette étude, les modules viscoélastiques G′ et G″ ont été prédits à l'aide de réseaux de neurones artificiels (RNA) utilisant les données expérimentales des polymères PS, PP3, et de leur mélange. L'approche est basée sur un réseau feedforward entraîné avec l'algorithme Levenberg-Marquardt dans MATLAB.

III.3.1. Processus d'entraînement du réseau de neurones

Le processus d'entraînement du RNA comprend les étapes suivantes :

a/ Chargement des données

Les données sont importées depuis les fichiers Excel contenant les mesures rhéologiques (PS.xlsx, PP3.xlsx, etc.). Chaque échantillon est défini par :

Entrées (X) : température (°C), fréquence (rad/s) + viscosité pour PS et PP3.

Sorties (Y) : module de stockage (G′) et module de perte (G″).

b/ Prétraitement / Normalisation

Les données ont été normalisées avec premnmx pour mettre toutes les variables sur la même échelle, ce qui : Accélère la convergence de l'apprentissage, améliore la précision et évite les biais liés à l'échelle des variables.

c/ Division des données

Les données ont été divisées en trois sous-ensembles :

- 70% pour l'apprentissage,
- 15% pour la validation,
- 15% pour le test.

Cela assure un bon équilibre et évite le surapprentissage.

d/ Architecture du réseau de neurones

Le réseau utilisé est à propagation avant. Les différentes étapes de sa conception sont résumées dans le Tableau III.2.

Tableau III.2. Étapes de construction du réseau de neurones

Couche	Détail
Couche d'entrée	Température, fréquence (+ viscosité si nécessaire)
Couche cachée unique	12 neurones
Fonction d'activation cachée	Logsig, tansig ou poslin
Couche de sortie	2 neurones (G′et G″) avec fonction de purelin
Algorithme d'apprentissage	Levenberg-Marquardt (trainlm)

e/ Paramètres d'entraînement

Le Tableau III.3 regroupe l'ensemble des paramètres d'entraînement utilisés pour l'apprentissage des réseaux de neurones artificiels (RNA), tels que le taux d'apprentissage, le nombre d'itérations, et la taille du lot.

Tableau III.3. Paramètres d'entraînement du réseau de neurones

Paramètres	**Valeur**	**Description**
Algorithme	Trainlm	Optimisation des poids
MaxEpoche	1000	Nombre maximal d'itérations
Learning rate	0.01	Taux d'apprentissage
Min Gard	1e -20	Seuil d'arrêt sur gradient
Max Fail	100	Arrêt anticipé si pas d'amélioration

f/ Entraînement et évaluation

L'entraînement a été réalisé via la fonction train, et les performances évaluées via les paramètres statistiques et en particulier le coefficient de corrélation (R) et, l'erreur moyenne quadratique (MSE).

III.3.2. Analyse des résultats

III.3.2.1. Analyse de la performance pour le module de stockage G′ pour le mélange

Le module de stockage G' reflète le comportement élastique d'un matériau viscoélastique. Dans cette étude, un réseau de neurones à propagation avant a été utilisé pour prédire les valeurs de G′ à partir de la température et de la fréquence, pour un mélange polymère immiscible

PP3/PS (30/70). Les performances du réseau ont été évaluées pour différentes fonctions d'activation (TANSIG, LOGSIG, POSLIN) et pour un nombre variable de neurones (de 4 à 60). (Tableau III.4).

Tableau III.4. Performances maximales selon les fonctions d'activation selon module G'

Nbre de Neurones	TANSIG		LOGSIG		POSLIN	
	R	MSE	R	MSE	R	MSE
4	0.980	0.0111	0.965	0.009	0.9589	0.0088
8	0.979	0.0083	0.982	0.010	0.9737	0.0114
12	0.966	0.0086	0.982	0.0093	0.983	0.0041
16	0.981	0.007	0.984	0.0052	0.9686	0.013
20	0.991	0.0036	0.982	0.0073	0.992	0.0028
24	0.992	0.0039	0.971	0.0095	0.993	0.0025
28	0.978	0.0069	0.979	0.0068	0.990	0.0063
32	0.960	0.014	0.981	0.0074	0.970	0.0090
36	**0.998**	**0.0013**	0.992	0.0021	0.987	0.0054
40	0.979	0.0094	**0.994**	**0.0015**	0.984	0.0044
44	0.991	0.0016	0.975	0.0083	**0.995**	**0.0014**
48	0.975	0.0082	0.985	0.0047	0.981	0.0073
52	0.975	0.010	0.994	0.0028	0.972	0.0076
56	0.986	0.0048	0.985	0.0099	0.994	0.0016
60	0.979	0.004	0.985	0.0058	0.988	0.0049

Parmi les différentes configurations testées, la fonction d'activation TANSIG, associée à 36 neurones dans la couche cachée, a permis d'obtenir les meilleures performances, avec un coefficient de corrélation et une erreur quadratique moyenne MSE = 0.0013. Cette fonction s'est avérée particulièrement efficace pour capturer la nature non linéaire du comportement viscoélastique du mélange.la fonction LOGSIG a également fourni de bons résultats avec 40 neurones, atteignant et un MSE de 0.0015, tandis que POSLIN (fonction linéaire positive), avec 44 neurones, a affiché des performances légèrement inférieures, bien qu'acceptables, avec et MSE = 0.0014. Ces résultats confirment l'importance du choix de la fonction d'activation dans la qualité de l'apprentissage et de la généralisation du modèle. Dans l'ensemble, les faibles valeurs d'erreur quadratique et les coefficients de corrélation élevés confirment la capacité du réseau de neurones à modéliser avec une grande précision le module de stockage. Parmi les fonctions d'activation testées, TANSIG se distingue nettement comme la plus performante, offrant le meilleur compromis entre exactitude de prédiction et stabilité du modèle (Figure III.1 et Figure III.2). Ces résultats mettent en évidence l'efficacité de cette fonction dans la capture du comportement élastique complexe d'un mélange polymère immiscible, là où les approches analytiques classiques montrent leurs limites.

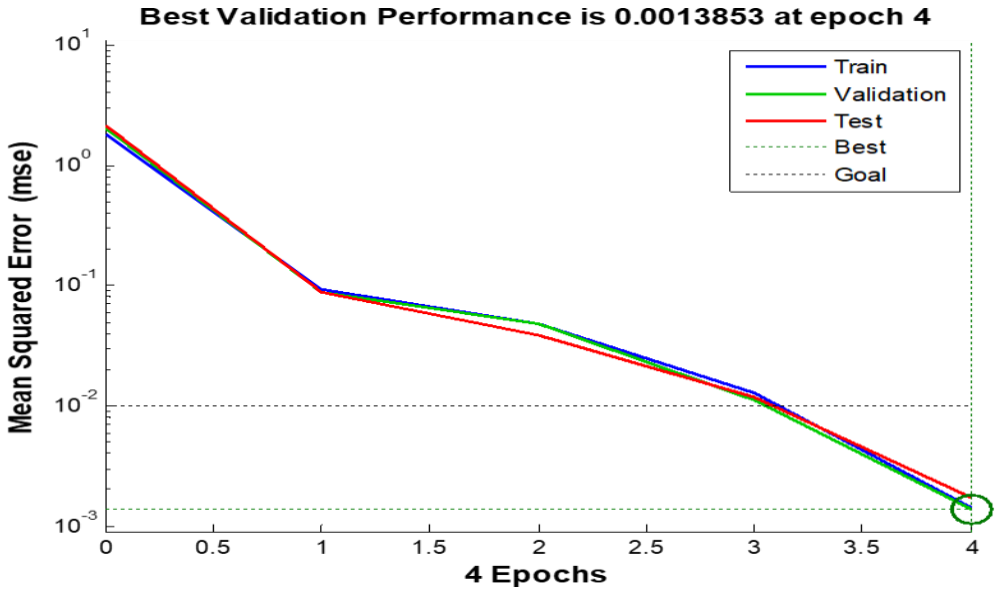


Figure III.1. Évolution de MSE pour G′ du mélange

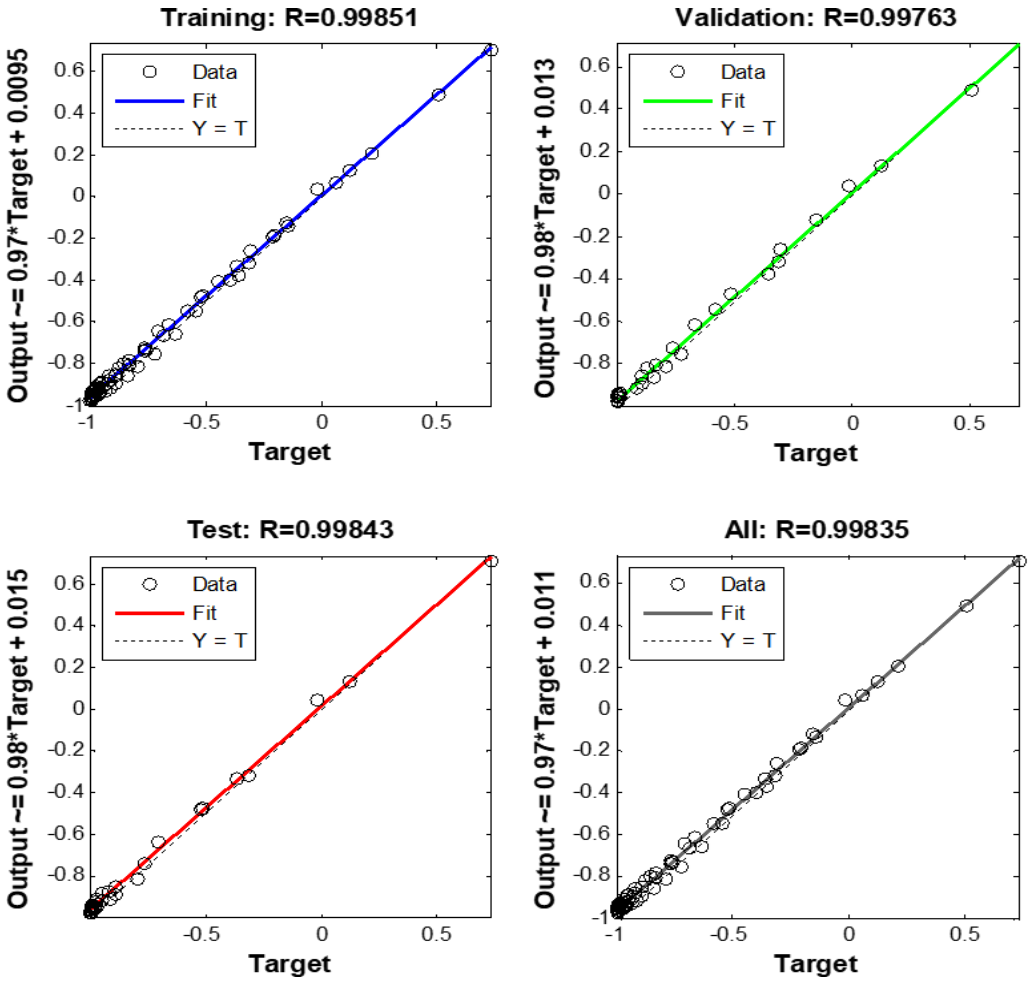


Figure III.2. Courbes de coefficient de corrélation R de G′ du mélange

III.3.2.2. Analyse du modèle RNA pour le module de perte G″ du mélange PP3/PS

L'évaluation du modèle RNA appliqué à la prédiction du module de perte du mélange PP3/PS (30%/70%) met en évidence une excellente capacité de généralisation (Tableau III.5). Ce paramètre, qui traduit le comportement visqueux du matériau, a été modélisé à partir des mêmes variables d'entrée que précédemment : température et fréquence d'excitation

Tableau III.5. Performances du modèle RNA pour G″.

Nbre de Neurones	TANSIG		POSLIN		LOGSIG	
	R	MSE	R	MSE	R	MSE
4	0.980	0.0098	0.978	0.0090	0.983	0.0086
8	0.982	0.0117	0.998	0.0064	0.983	0.0049
12	0.984	0.0102	0.985	0.0067	0.983	0.0089
16	0.987	0.0123	0.987	0.0076	0.986	0.0059
20	0.981	0.0073	0.991	0.0087	0.990	0.0041
24	0.988	0.0073	0.984	0.0080	0.989	0.0082
28	0.984	0.009	0.977	0.0074	0.985	0.0078
32	0.985	0.0082	0.991	0.004	0.982	0.0070
36	0.988	0.0035	0.993	0.0040	0.992	0.005
40	0.991	0.0035	0.993	0.0049	0.991	0.0082
44	**0.997**	**0.002**	**0.997**	**0.0025**	**0.996**	**0.0025**
48	0.984	0.004	0.991	0.004	0.992	0.0035
52	0.987	0.005	0.989	0.007	0.989	0.0094
56	0.991	0.0053	0.993	0.0049	0.988	0.004
60	0.988	0.0089	0.989	0.007	0.987	0.007

Différentes fonctions d'activation ont été testées, à savoir TANSIG, LOGSIG et POSLIN, tout en faisant varier le nombre de neurones dans la couche cachée. L'analyse des performances du modèle a été principalement centrée sur la configuration à 44 neurones, où les trois fonctions d'activation ont montré des résultats très proches. Plus précisément, TANSIG a permis d'atteindre un coefficient de corrélation R = 0.997 et une erreur quadratique moyenne MSE = 0.002, offrant ainsi le meilleur équilibre entre précision et stabilité. LOGSIG a obtenu le même R =

0.997 avec un MSE légèrement plus élevé (0.0025), tandis que POSLIN, malgré sa nature linéaire, a donné un R = 0.996 avec un MSE = 0.002. Ces performances très proches indiquent que la nature du signal associé à G″ est suffisamment régulière pour être efficacement apprise par des architectures neuronales de complexité modérée, à condition que le nombre de neurones soit adéquatement choisi. D'un point de vue technique, le module de perte G″ présente un comportement plus lisse et moins non linéaire que G′, ce qui facilite sa modélisation. Cette hypothèse est appuyée par la convergence rapide observée à partir de 36 à 44 neurones, la faible dispersion entre les fonctions d'activation, ainsi que l'absence de surapprentissage dans les courbes de performance. Ainsi, la robustesse du modèle RNA dans la modélisation de G″ s'explique autant par la qualité des données expérimentales que par la cohérence du comportement rhéologique visqueux du mélange. En conclusion, le modèle RNA appliqué à G″ se révèle à la fois précis et stable, avec une légère supériorité de la fonction TANSIG à 44 neurones (figures III.3 et III.4). Toutefois, le faible écart de performance entre les fonctions confirme la flexibilité et la robustesse du modèle, ce qui en facilite l'utilisation pratique pour la prédiction des propriétés rhéologiques des mélanges polymères.

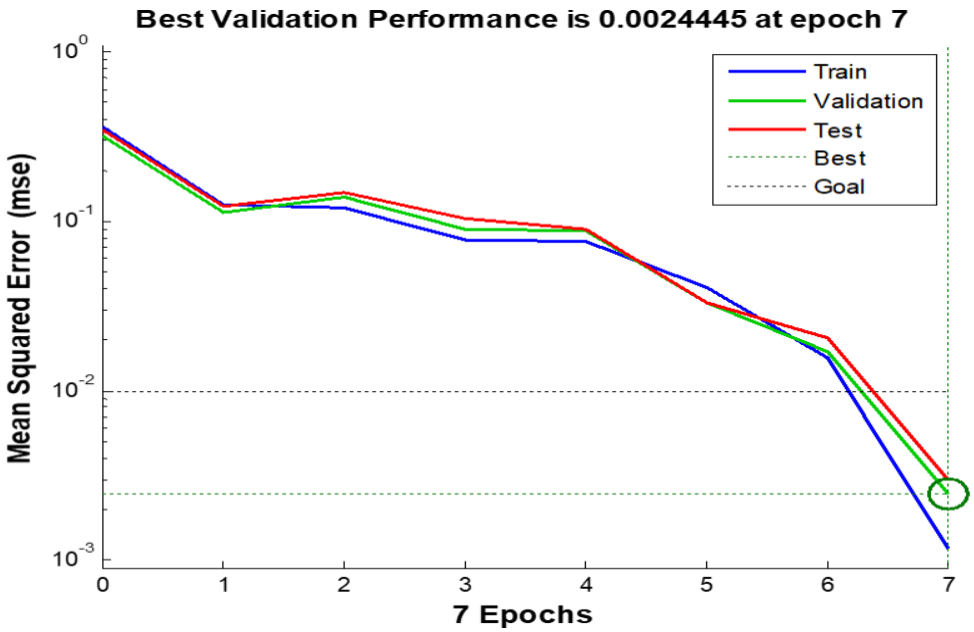


Figure III.3. Évolution de MSE pour G″ du mélange

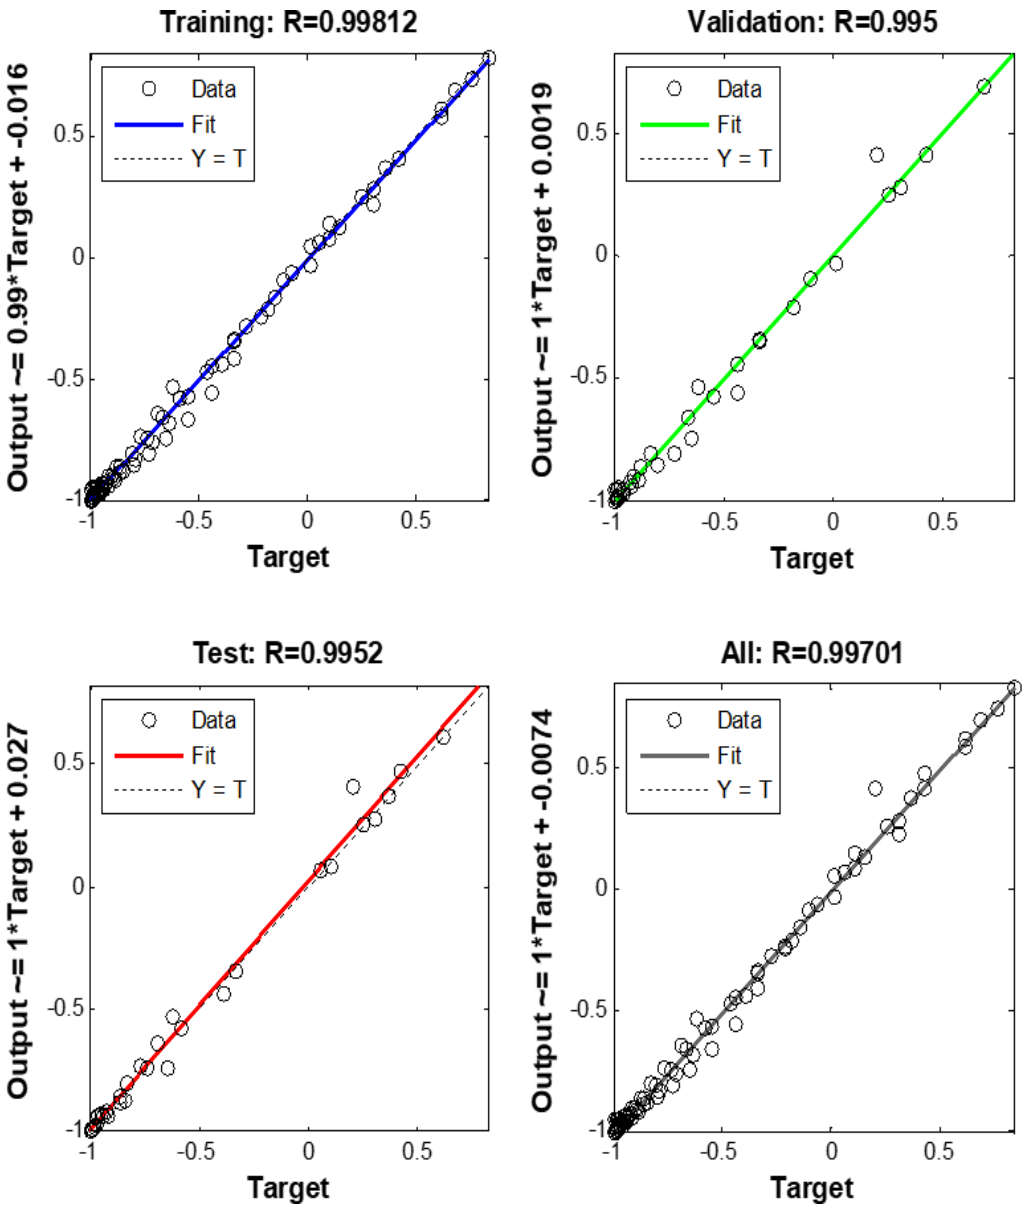


Figure III.4. Graphes de régression pour G″ (Fonction TANSIG) du mélange

III.3.2.3. Analyse du modèle RNA pour le Polystyrène

Le polystyrène (PS), polymère thermoplastique rigide et amorphe, possède des caractéristiques rhéologiques spécifiques qui le rendent intéressant à modéliser. L'objectif ici est d'évaluer la capacité du réseau de neurones artificiels (RNA) à prédire ses propriétés mécaniques, en fonction de plusieurs fonctions d'activation : TANSIG, POSLIN, et LOGSIG. Les performances sont analysées à travers les indicateurs R (coefficient de corrélation) et MSE (erreur quadratique moyenne). Les résultats sont rassemblés dans le Tableau III.6.

Les résultats montrent que la fonction TANSIG, associée à 20 neurones, fournit la meilleure performance, avec un coefficient de corrélation R = 0.989 et une erreur quadratique moyenne MSE = 0.0020, indiquant une très bonne précision dans la prédiction des valeurs expérimentales. La fonction LOGSIG, avec 28 neurones, a donné un R = 0.986 et un MSE légèrement supérieur de 0.0039, tandis que POSLIN, bien que reposant sur une architecture plus simple (8 neurones), a atteint un R = 0.985 avec un MSE = 0.0038.

Tableau III.6. Performances du modèle RNA pour PS

Nobre de noreunes	TANSIG		POSLIN		LOGSIG	
	R	MSE	R	MSE	R	MSE
4	0.984	0.0059	0.979	0.0066	0.978	0.0095
8	0.984	0.0059	**0.985**	**0.0038**	0.986	0.0071
12	0.984	0.0059	0.982	0.0066	0.977	0.0073
16	0.986	0.0030	0.979	0.0068	0.977	0.0073
20	**0.989**	**0.0020**	0.984	0.0069	0.985	0.0054
24	0.982	0.004	0.981	0.0068	0.981	0.0069
28	0.983	0.005	0.984	0.0098	**0.986**	**0.0039**
32	0.983	0.006	0.985	0.0071	0.982	0.0048
36	0.989	0.004	0.982	0.0087	0.985	0.0067
40	0.989	0.0036	0.983	0.0042	0.979	0.0086
44	0.984	0.009	0.984	0.0062	0.986	0.00744
48	0.985	0.005	0.979	0.0076	0.984	0.0065
52	0.987	0.0059	0.982	0.0093	0.980	0.0073
56	0.981	0.006	0.980	0.0083	0.984	0.0061
60	0.979	0.007	0.980	0.0048	0.983	0.0059

Ces performances globalement élevées montrent une bonne. Généralisation du modèle pour le PS, bien que les écarts entre fonctions soient ici plus marqués que dans le cas du mélange PP3/PS. Cette différence peut être due à une plus grande sensibilité du PS aux conditions expérimentales ou à une variabilité intrinsèque plus importante dans les données. En outre, la fonction POSLIN, bien que moins performante, se distingue par sa faible complexité, ce qui pourrait être avantageux pour des applications embarquées ou temps réel.

Enfin, les courbes de régression et d'erreur associées (Figure III.5 et Figure III.6) confirment que la fonction TANSIG offre le meilleur compromis entre précision, simplicité et stabilité pour la modélisation des propriétés rhéologiques du polystyrène.

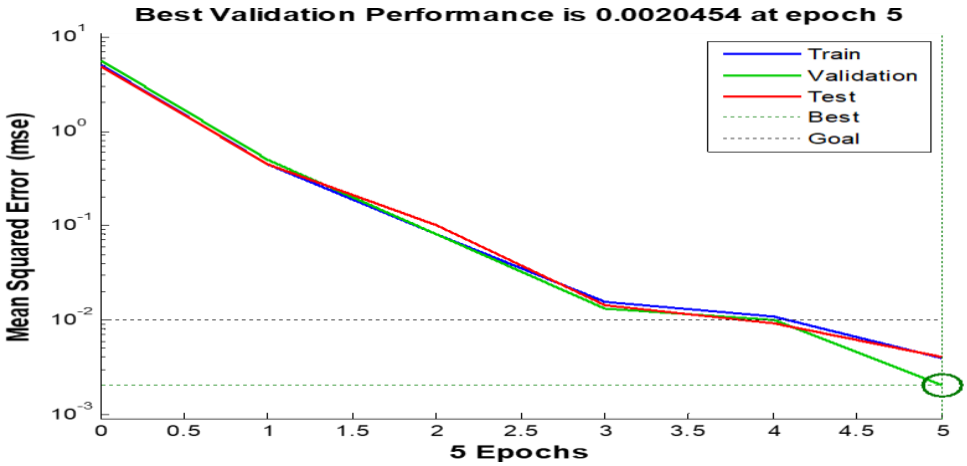


Figure III.5. Évolution de MSE de PS (Fonction TANSIG)

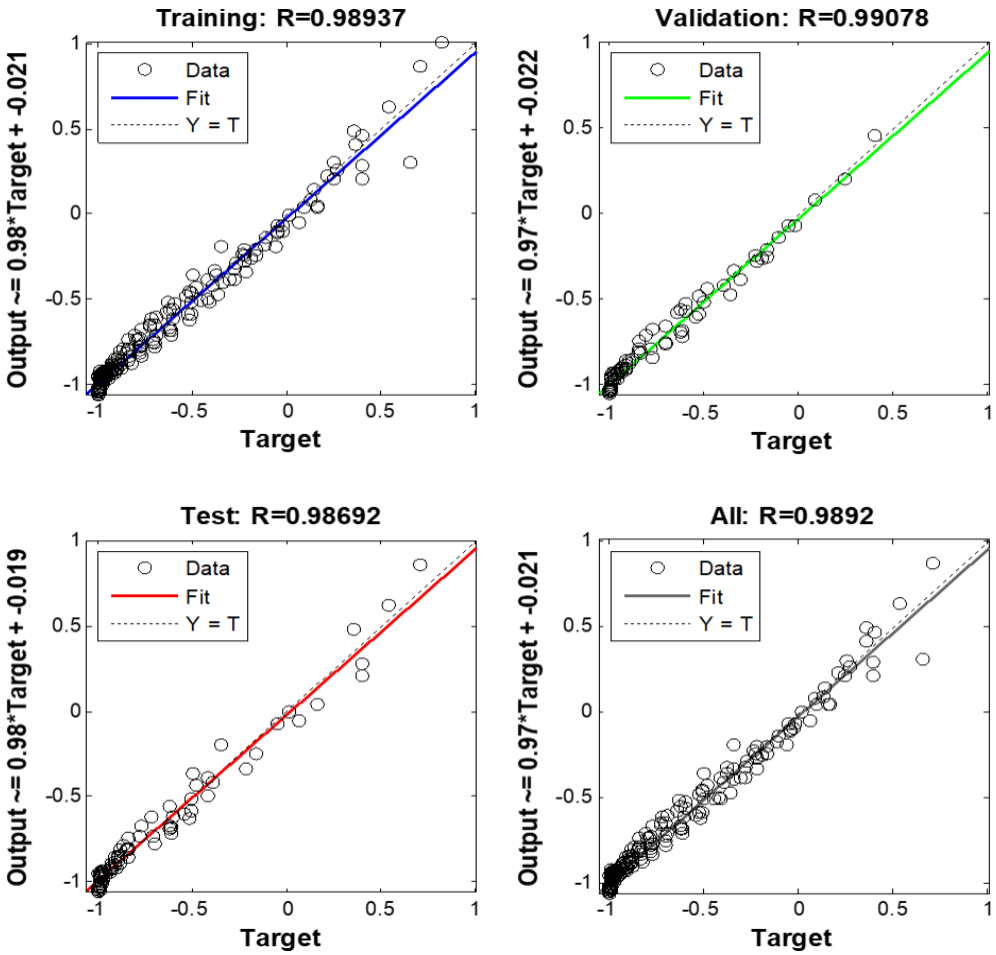


Figure III.6. Graphes de régression du PS

III.3.2.4. Analyse du modèle RNA pour le polypropylène

Le polypropylène (PP3), en tant que matériau polymère semi-cristallin, présente des propriétés mécaniques et viscoélastiques complexes. L'objectif de cette section est d'évaluer l'efficacité d'un réseau de neurones artificiels (RNA) dans la prédiction du comportement du PP3 à partir des données expérimentales. Trois fonctions d'activation ont été comparées : TANSIG, POSLIN, et LOGSIG, en utilisant des architectures différentes, et les performances du modèle sont analysées selon les indicateurs statistiques R (coefficient de corrélation) et MSE (erreur quadratique moyenne). Les résultats obtenus sont rassemblés dans le Tableau III.7.

Tableau III.7. Performances du modèle RNA pour PP3

Nbre de Neurones	TANSIG		POSLIN		LOGSIG	
	R	MSE	R	MSE	R	MSE
4	0.991	0.0048	0.991	0.0040	0.991	0.0044
8	0.991	0.0054	0.986	0.0061	0.989	0.005
12	0.987	0.0077	0.911	0.0038	0.9911	0.0044
16	0.990	0.0051	0.990	0.0071	0.990	0.0051
20	0.990	0.0037	0.988	0.0061	0.991	0.0059
24	0.991	0.0056	0.988	0.0075	0.984	0.0066
28	0.990	0.0058	**0.993**	**0.0029**	0.991	0.005
32	0.990	0.0068	0.991	0.0038	0.992	0.0040
36	0.986	0.0094	0.991	0.0066	0.992	0.005
40	0.993	0.0041	0.993	0.0046	0.992	0.0025
44	0.992	0.0028	0.992	0.0037	0.993	0.0028
48	0.992	0.0047	0.992	0.0044	0.993	0.0044
52	0.993	0.0036	0.989	0.0065	0.992	0.0046
56	**0.993**	**0.0029**	0.985	0.0066	0.992	0.0048
60	0.992	0.0051	0.989	0.0035	**0.993**	**0.0024**

De manière remarquable, les trois configurations ont atteint le même niveau de corrélation élevé (R = 0.993), témoignant d'une grande robustesse du modèle. Toutefois, les différences de MSE permettent de distinguer la précision de chaque architecture. La fonction LOGSIG, avec 60 neurones, a montré la meilleure performance globale avec un MSE minimal de 0.0024, traduisant une excellente adéquation entre les sorties du modèle et les données expérimentales. TANSIG (56 neurones) et POSLIN (28 neurones) ont toutes deux atteint le même R = 0.993, mais avec un MSE légèrement supérieur de 0.0029. Les résultats, illustrés dans la Figure III.7 et la Figure III.8, indiquent que le choix du nombre de neurones joue un rôle déterminant, parfois plus que la fonction d'activation elle-même, dans l'optimisation du modèle. Le fait que

même une fonction linéaire comme POSLIN puisse atteindre un tel niveau de corrélation démontre la régularité des données du PP3 et la capacité du réseau à capturer ses variations internes.

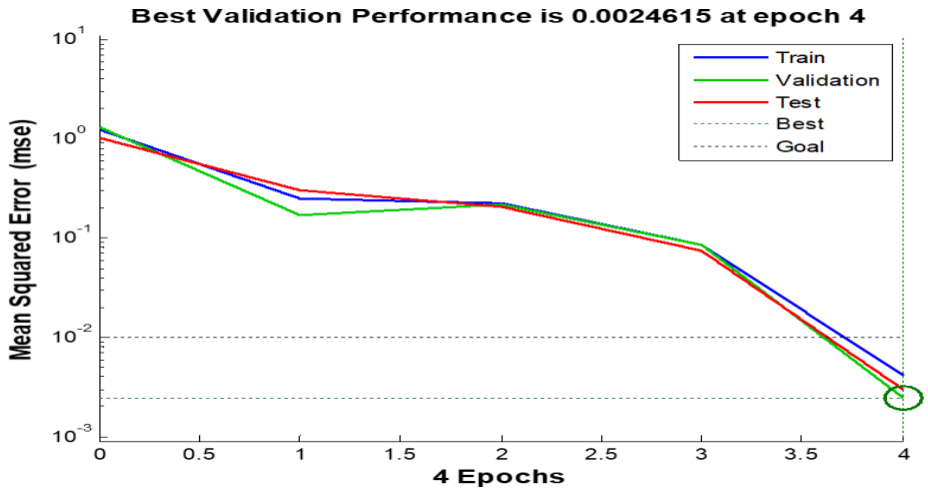


Figure III.7. Évolution de MSE de PP3 (Fonction LOGSIG)

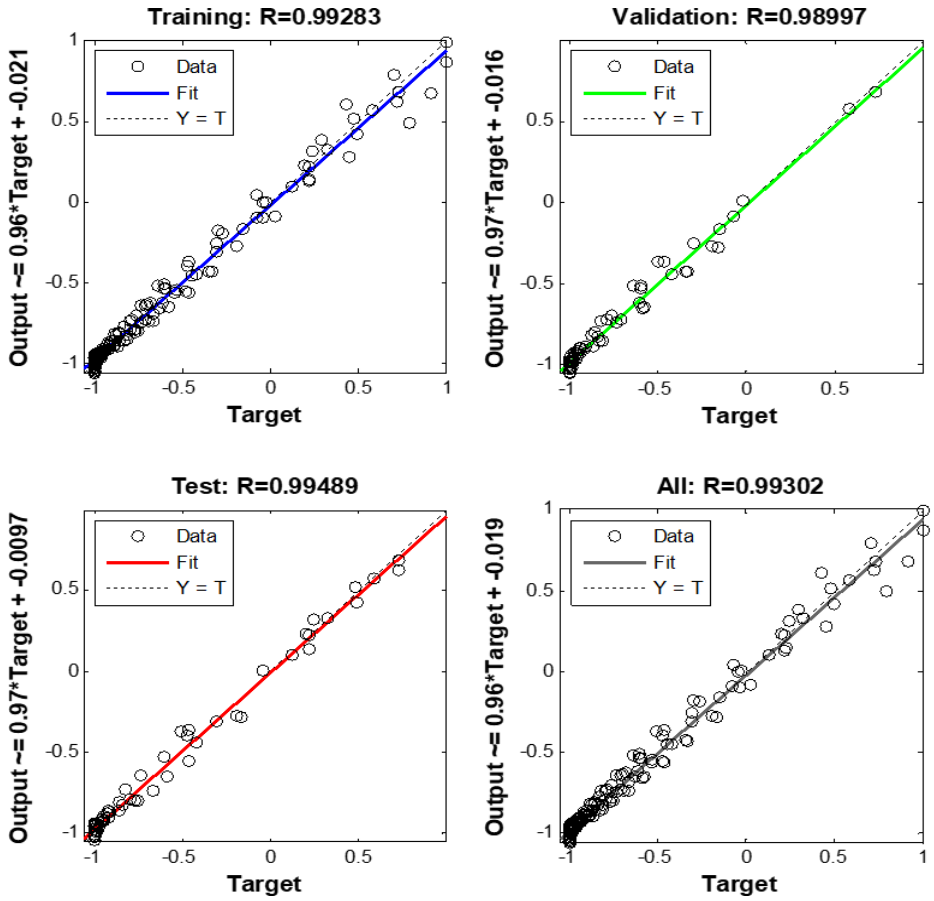


Figure III.8. Graphes de régression du PS

En somme, cette étude confirme l'efficacité du RNA dans la modélisation des propriétés rhéologiques du PP3, avec une légère préférence pour l'architecture LOGSIG à 60 neurones, tout en mettant en évidence la stabilité et la généralisation du réseau, quelles que soient les fonctions d'activation utilisées.

III.3.3. Analyse de sensibilité des variables d'entrée

L'analyse de sensibilité constitue une étape complémentaire essentielle dans la validation des modèles de réseaux de neurones artificiels (RNA), en permettant d'identifier l'influence relative de chaque variable d'entrée sur la réponse prédite. Dans ce contexte, un facteur de pertinence, compris entre −1 et +1, a été utilisé pour quantifier la corrélation entre chaque variable d'entrée et la variable de sortie du modèle. La formulation mathématique de ce coefficient est la suivante :

$$r = \frac{\sum_{i=1}^{n} (X_{k,i} - X_k)(Y_i - Y)}{\sqrt{\sum_{i=1}^{n} (X_{k,i} - X_k)^2} \cdot \sqrt{\sum_{i=1}^{n} (Y_i - \bar{Y})^2}}$$

Où $X_{k,i}$ désigne la i^e valeur de la variable d'entrée, $\bar{X}_k$ sa moyenne, Y_i la sortie correspondante, et $\bar{Y}$ la moyenne des sorties.

Les résultats issus de l'analyse de sensibilité présentée dans le Tableau III.8 confirment la robustesse du modèle RNA appliqué à l'étude des propriétés viscoélastiques des polymères purs et en mélange, comme le montre également la Figure III.11.

Tableau III.8. Indices de sensibilité

Échantillon	Indice 1	Indice 2	Interprétation
Mélange G'	0.99997	0.99999	Très forte sensibilité : les variables influencent fortement G'.
Mélange G''	0.99647	0.99834	Sensibilité très élevée de G'' aux entrées.
PS	0.99481	0.98521	Grande dépendance du PS aux variables d'entrée.
	0.99755	0.99017	
	0.99954	0.99500	
PP3	0.97680	0.96321	Sensibilité élevée, légèrement inférieure à celle du PS.
	0.99052	0.98109	
	0.99759	0.99196	

En effet, les indices de sensibilité obtenus pour le module de stockage G′ et le module de perte G″ du mélange PP3/PS sont extrêmement proches de 1, traduisant une forte influence des variables d'entrée, telles que la température et la fréquence, sur la réponse du système. Cette forte corrélation témoigne de la capacité du modèle à capturer efficacement les relations complexes entre les paramètres d'entrée et les propriétés mécaniques observées. Pour le polystyrène (PS), les indices atteignent également des valeurs très élevées, notamment jusqu'à 0,9995, ce qui révèle une sensibilité marquée de ce matériau aux variations de conditions. Cette réactivité peut être attribuée à sa structure amorphe, qui le rend plus sensible aux changements de formulation ou de sollicitation. En comparaison, le polypropylène (PP3), bien que présentant des indices légèrement inférieurs, reste dans une plage élevée (≥ 0,96), soulignant lui aussi une dépendance significative aux variables d'entrée. Ces différences entre PS et PP3 peuvent s'expliquer par la structure semi-cristalline du PP3, qui pourrait atténuer certains effets liés à la température ou à la fréquence, ou encore par une compatibilité interfaciale différente avec les autres composants du mélange. De manière générale, le PS semble réagir de façon plus prononcée que le PP3 aux variations expérimentales, ce qui traduit une sensibilité intrinsèque plus élevée.

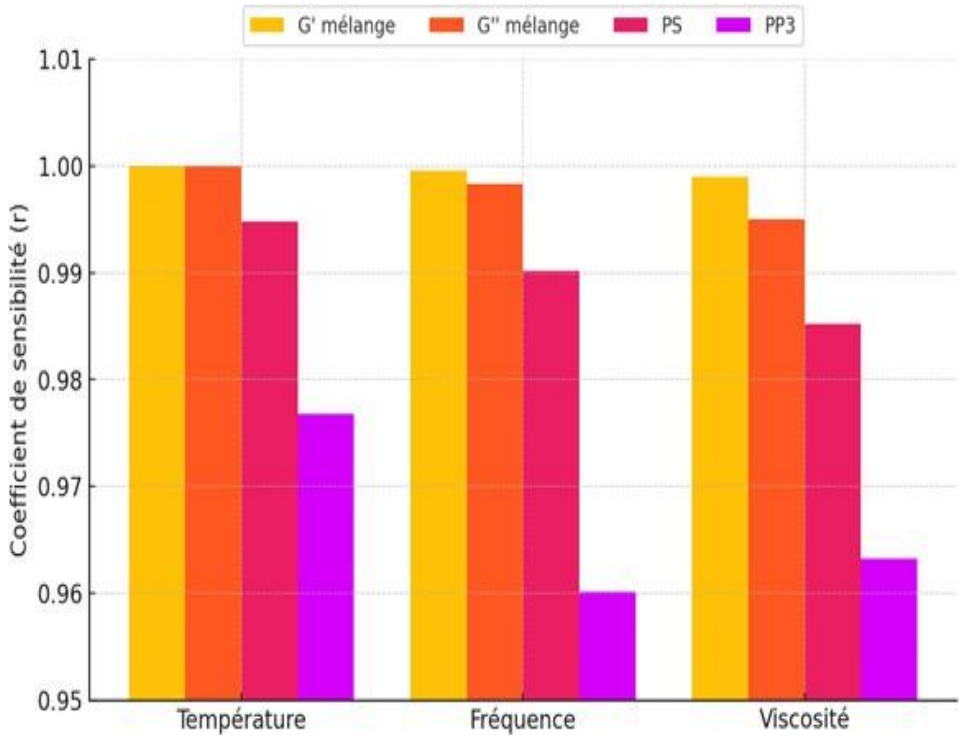


Figure III.9. Analyse de sensibilité des variables d'entrée sur les modules viscoélastiques

III.4. Conclusion

Ce chapitre a confirmé que l'ensemble des modèles RNA développés ont montré une excellente précision pour prédire les modules G′ et G″, avec des performances très proches de l'expérimental. Le polystyrène (PS) s'est révélé légèrement plus sensible aux variables d'entrée que le polypropylène (PP3), ce qui a été confirmé par l'analyse de sensibilité. Celle-ci a mis en évidence l'importance dominante de la température, de la fréquence et de la viscosité dans la réponse du système, validant ainsi la cohérence physique des modèles proposés.

CONCLUSION GENERALE

Conclusion générale

Ce travail s'est inscrit dans une démarche scientifique visant à modéliser et prédire le comportement rhéologique d'un mélange de polymères immiscibles, en l'occurrence le polypropylène (PP3) et le polystyrène (PS), à l'aide des réseaux de neurones artificiels (RNA). Cette approche innovante s'inscrit dans une volonté d'optimiser les procédés industriels en réduisant le recours à des méthodes expérimentales longues et coûteuses.

Dans un premier temps, une base solide a été posée à travers l'étude approfondie des fondements de la rhéologie, avec un accent particulier sur la viscosité et la viscoélasticité deux propriétés cruciales pour comprendre le comportement des matériaux polymères. Les spécificités des deux polymères étudiés, ainsi que les défis liés à leur mélange, notamment leur immiscibilité thermodynamique et les phénomènes interfaciaux, ont été clairement identifiés.

Ensuite, un état de l'art détaillé sur les réseaux de neurones artificiels a permis d'appréhender les principes de fonctionnement de ces outils d'intelligence artificielle, leur architecture, leurs fonctions d'activation, ainsi que les différentes méthodes d'apprentissage. Cette partie a constitué le socle méthodologique de notre approche de modélisation.

Enfin, la dernière étape du travail a consisté en la mise en œuvre et l'évaluation du modèle RNA. Celui-ci a été entraîné à partir de données expérimentales incluant des paramètres d'entrée tels que la température, la fréquence et la viscosité. Les sorties ciblées étaient les modules viscoélastiques G′ (stockage) et G″ (perte). L'analyse des performances a révélé une bonne concordance entre les prédictions du modèle et les valeurs expérimentales, avec des indicateurs statistiques tels que l'erreur quadratique moyenne (MSE) et le coefficient de corrélation (R), témoignant de la fiabilité du réseau neuronal utilisé.

Ainsi, ce travail démontre que l'association entre la science des matériaux et l'intelligence artificielle ouvre de nouvelles perspectives pour la compréhension et la prédiction des comportements complexes des systèmes polymères. Il suggère également la possibilité d'intégrer ces modèles dans des systèmes de contrôle en ligne pour les procédés de fabrication, réduisant ainsi le besoin en essais expérimentaux et permettant une optimisation en temps réel.

En perspective, des améliorations pourraient être apportées au modèle RNA, notamment par l'intégration d'un plus grand nombre de paramètres, l'élargissement de la base de données, ou encore l'exploration d'architectures neuronales plus avancées comme les réseaux convolutifs ou récurrents. Le travail réalisé constitue une première étape encourageante vers une exploitation plus large des outils d'intelligence artificielle dans le domaine du génie des matériaux.

Références

[1] Patrice Estellé, Camille Michon, Christophe Lanos, J.L. Grossiord. De l'intérêt d'une caractérisation rhéologique empirique et relative (chapitre 7). Déposé on 21 Jan 2015.

[2] DJOUDI Tarek. Etude De l'écoulement Du Polymère Fondu Dans Les Moules Résolution. Masters thésis, Université Mohamed Khider Biskra. (2005).

[3] A. DERARDJA. Comportement mécanique des Matériaux Polymères. Université Batna 2

[4] Mohammed Hennous. Cours De Rhéologie Des Polymères. Université Se Science Et De La Technologie d'Oran Mohamed Boudiaf. 2020/2021.

[5] Jeulin. Guide viscosité. https://jeulin.com/lelaborantin_fr/.

[6] MEKROUSSI Fatima Zohra et SALEM Amina. Étude expérimentale du comportement rhéologique des liquides ioniques. Mémoire de master, Université Ibn Khaldoun Tiaret,2021.

[7] Cours Biophysique 2 -ème année SNV. Étude de l'évolution des caractéristiques physiques. Chapitre V.

[8] Krasnobrizha, A. Modélisation des mécanismes d'hystérésis des composites tissés à l'aide d'un modèle collaboratif élasto-plastique en dommageable à dérivées fractionnaires. Thèse de doctorat. (2018).

[9] Shear stress in physics. https://www.tuofa-cncmachining.com/fr/tuofa- blog/.

[10] Dr YOUCEFI Sarra. Rhéologie des fluides complexes. Université d'Oran des Sciences et de la Technologie Mohamed Boudiaf.

[11] Mesures des caractéristiques rhéologiques des polymères thermoplastiques.

[12] DJERIOU Houssam et BENAOUN Badreddine.Étude de la recyclabilité du polypropylène : impacts économiques et environnementaux. Mémoire de master, Université Kasdi Merbah Ouargla. (2023).

[13] Hawaii, H., & Duhamel, I. Effet de l'incorporation d'un déchet. Mémoire de master, Université 8 Mai 1945 Guelma. (2022).

[14] École Nationale Polytechnique. (2007).

[15] Touzet, C. Introduction au connexionnisme : les réseaux de neurones artificiels. (2016).

[16] Rheonics. Viscosité. https://fr.rheonics.com/.

[17] AMOURA Karima. Réseaux de neurones et espace d'état pour l'identification et la prédiction, Mémoire de master, Université Mouloud Mammeri de Tizi-Ouzou.

[18] Rezgane, A., & Bedda, M. R. Détection et classification des défauts dans les réseaux électriques par les réseaux de neurones, Mémoire de master, Université Kasdi Merbah Ouargla.