



REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE  
MINISTRE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE  
SCIENTIFIQUE

**UNIVERSITE IBN KHALDOUN - TIARET**

# MEMOIRE

Présenté à :

FACULTÉ MATHÉMATIQUES ET INFORMATIQUE  
DÉPARTEMENT D'INFORMATIQUE

Pour l'obtention du diplôme de :

**MASTER**

Spécialité : Génie Logiciel

Par :

**BOSRI Rahil**  
**HARBOUCHE Ibtissem Halima**

Sur le thème

---

## Développement d'un modèle prédictif de durée de vie des polymères

---

Soutenu publiquement le 09 /07/ 2019 à Tiaret devant le jury composé de :

Mr BEKKI Khadhir

MAA Université Ibn Khaldoun

Président

Mr LAID Lahcen

MCB Université Ibn Khaldoun

Encadreur

Mr DJAAFRI Laouni

MAA Université Ibn Khaldoun

Examineur

2018/2019

# **R**emerciement

**E**n préambule à ce mémoire nous remerciant **ALLAH** qui nous aide et nous donne la patience et le courage durant ces longues années d'étude.

Nous exprimons nos gratitudeles plus sincères aux personnes qui nous ont apporté leur aide et qui ont contribué à l'élaboration de ce mémoire et qui ont accepté de répondre à nos questions avec gentillesse.

**O**n tient à remercier sincèrement **Mr LAID Lahcen**, qui en tant qu'encadreur, s'est toujours montré à l'écoute ainsi que son précieux conseil et son aide durant toute la période du travail.

Nos vifs remerciements vont à **Mr K.BEKKI**, Professeur à l'université Ibn Khaldoune de Tiaret, qui a bien voulu accepter de présider le jury de ce mémoire.

**M**es respectueuses reconnaissances vont également à **Mr L.DJAAFRI**, Maître de conférences à l'université Ibn Khaldoune de Tiaret; de m'avoir fait l'honneur d'examiner ce travail.

**O**n n'oublie pas nos parents pour leur contribution, leur soutien et leur patience. Enfin, nous adressons nos plus sincères remerciements à tous nos proches et amis, qui nous ont toujours soutenue et encouragée au cours de la réalisation de ce mémoire. Merci à tous et à toutes.

# Dédicaces

*Je dédie mon travail à : Mon cher père que j'aime tellement et que dieu me le garde et lui accorde une longue vie, A ma mère à qui j'espère qu'elle est fière de moi.*

*à mon mari Amine Pour tout l'encouragement.*

*A mes frères, tantes et grand-mère ainsi qu'à chaque membre de la famille.*

*A ma belle-famille.*

*A toutes mes cousines et copines.*

H. I btissem

# Dédicaces

*Je dédie mon travail à mes chers parents pour leurs encouragements, leurs  
soutiens et leur patience*

*A mes frères, mes sœurs et toute ma famille*

*A mes collègues et mes amies.*

**B. Rahil**

### Liste des abréviations:

CNN :	Convolutional neural network
ConvNets :	Convolutional neural network
DBN:	Deep Belief Networks
DL:	Deep Learning
ES:	EarlyStopping.
FNNs:	Feed forward neural networks
GAN:	Generative adversarial networks
GRU:	Gate recurrent unite
GUI:	Graphical User Interface).
LDPE:	Low density polyethylene
LSM:	Long short time machine.
MLP:	Perceptron multicouche
MSE:	Mean squared error.
PE :	Polyéthylène
PEBD :	Polyéthylène Basse Densité
PEHD:	Polyéthylène Haute Densité
PMC :	Le perceptron multicouche
RBM:	Restricted Boltzmann Machines
ReLU:	Rectified Linear Units
RNA:	Réseaux de neurones artificiel
RNN:	Réseaux de neurones récurrents
UPN:	Unsupervised preformed networks
UV:	Ultra-Violets

## Table des matières

Résumé	
Abstract	
Introduction Générale .....	02

### Chapitre I: Etat de l'art

I.1.Introduction- .....	05
I.2. Définitions .....	05
I.2.1. Polymère .....	05
I.2.2. Monomères.....	05
I.3. Polymérisation de polymère .....	06
I.4. Classification des polymères .....	06
I.5. Domaines d'état .....	08
I.5.1. Etat vitreux.....	09
I.5.2. Etat caoutchoutique .....	09
I.5.3. Etat fondu.....	09
I.6. Propriétés des polymères .....	10
I.6.1. Propriétés physiques.....	10
I.6.2. Propriétés thermiques .....	11
I.6.3. Propriétés mécaniques .....	12
I.6.4. Facteurs ayant une influence sur les propriétés mécaniques des polymères : .....	12
I.7. Polyéthylène (PE).....	14
I.8. Polyéthylène(PE) : .....	14
I.8.1. Définition (PE) : .....	15
I.8.2. Types de Polyéthylène:.....	15
I.8.3. Les propriétés du polyéthylène basse densité PEbd : .....	16
I.8.4. Propriétés Physico-chimiques: .....	16
I.8.5. Propriétés mécaniques : .....	17
I.9. Vieillissement des polymères: .....	17
I.9.1. Aspects généraux du vieillissement : .....	19
I.9.2. Vieillissements artificiel et dégradation .....	19
I.9.3. Vieillissement physique : .....	19
I.9.4. Vieillissement chimique : .....	20
I.10. La Déformation des polymères solides : .....	20

I.10.1. La Déformation de la phase amorphe :	21
I.10.2. La Déformation de la phase cristalline :	21
I.11. La Fragmentation des lamelles cristallines :	22
I.12. Travaux liés aux polymères	22
I.13. Conclusion	24

## **Chapitre II: Apprentissage profond**

II.1. Introduction:	26
II.2. Apprentissage automatique.....	27
II.2.1. Apprentissage Supervisé	27
II.2.2. Apprentissage Non-Supervisé.....	27
II.2.3. Apprentissage semi-supervisé ou apprentissage par renforcement.....	28
II.3. Réseaux de neurones artificiels.....	28
II.3.1. Réseaux de neurones pour la régression non-linéaire	28
II.3.1.1. La régression non linéaire.....	28
II.3.1.2. Modèle non linéaire par rapport aux variables	29
II.3.2. Architecture des réseaux de neurones	30
II.3.2.1. Les réseaux de neurones non bouclés (réseau statique)	30
II.3.2.2. Les réseaux de neurones bouclés (réseau dynamique)	31
II.4. Perceptron multicouches	32
II.4.1. Le modèle du perceptron	32
II.4.2. Fonction d'activation	33
II.4.3. Fonction d'activation linéaire.....	34
II.4.4. Fonction d'activation sigmoïde	34
II.4.5. Fonction d'activation de la tangente hyperbolique.....	35
II.4.6. Unités linéaires rectifiées (ReLU).....	35
II.4.7. Fonction d'activation Softmax	36
II.5. Le perceptron multicouche (PMC)	36
II.5.1. Entraînement du réseau de neurones avec une rétropropagation.....	37
II.5.2. Algorithme de rétropropagation du gradient	38
II.5.2.1. Algorithme d'apprentissage	38
II.6. Du perceptron à l'apprentissage profond	39
II.7. Apprentissage profond	41

II.7.1. Architectures majeures de réseaux profonds .....	42
II.7.1.1. Auto-encodeurs .....	43
II.7.1.2. Machines Boltzmann restreintes .....	44
II.7.1.3. Réseaux de neurones récurrents.....	44
II.7.2.4. Réseaux de neurones convolutifs (CNN) .....	44
II.7.2.4.1. Aperçu du CNN.....	45
II.7.2.4.2. Evolution des connexions entre les couches.....	46
II.7.2.4.3. La structure de base d'un réseau convolutif.....	46
II.7.2.4.4. Couche convolutive (RELU layer) .....	47
II.7.2.4.5. La couche ( Pooling ).....	50
II.7.2.4.6. Couches Entièrement Connectées:.....	50
II.7.2.7.7. CNN pour la régression .....	50
II.8. Conclusion.....	51

### **Chapitre III : Implémentation**

III.1.Introduction: .....	53
III.2. Les choix techniques :.....	53
III.2.1. Python: .....	53
III.2.2.. Anaconda:.....	54
III.2.3.Pycharm:.....	54
III.2.4.Bibliothèques Supplémentaires .....	55
III.3. Source Expérimentale de la base des données .....	56
III.3. 1.Les matériaux étudiés .....	57
III.3. 2.L'essai de traction.....	57
III.3. 3. Préparation des éprouvettes.....	57
III.3. 4.Mise en place de l'essai de traction .....	57
III.3. 5. Courbe de traction .....	58
III.4.Entraînement et Paramétrage des Modèles .....	59
III.5. Architecture du model(Convnet).....	61
III.5.1.Paramètres d'Apprentissage .....	68
III.6. Les interfaces de l'application:.....	68
III.6.1.Création du Model Convnet: .....	68
III.7.Les tests:.....	70



III.8.La prédiction: .....	73
III.9.Conclusion:.....	74
Conclusion générale .....	76
Bibliographie.....	79

## Liste des figures :

Figure I.1 : Monomère d'un homopolymère.....	06
Figure I.2 : Polymérisation. ....	06
Figure I.3 : Principales contraintes mécaniques.....	13
Figure I.4 : Comportement d'un matériau soumis à une contrainte mécanique. ....	14
Figure I.5 : Schéma représentatif du polyéthylène.....	15
Figure I.6 : Schématise la pénétration d'un solvant dans un polymère.....	19
Figure I.7 : Mécanismes de déformation de la phase amorphe dans les polymères semi-cristallins a) Etat non déformé, b) Glissement inter lamellaire et c) Séparation inter lamellaire [12]. ....	21
Figure I.8 : Processus de glissements a) parallèle et b) perpendiculaire aux chaînes des lamelles cristallines [36], [45].....	22
Figure II.1 : Schéma d'un modèle supervisé. ....	27
Figure II.2 : Schéma d'un modèle non supervisé. ....	28
Figure II.3 : Courbe de régression non linéaire pour des données. ....	29
Figure II.4 : Réseaux de neurone non bouclé.....	31
Figure II.5 : Exemple d'un réseau de neurones bouclé. Les nombre dans les carrés sont les retards (exprimés en nombre de périodes d'échantillonnage) associés à chaque connexion. ....	31
Figure II.6 : Modèle d'un neurone formel.....	32
Figure II.7 : Fonction d'activation linéaire.....	34
Figure II.8 : Fonction d'activation sigmoïde. ....	34
Figure II.9 : Réseaux PMC. ....	37
Figure II.10 : Problèmes de classification à deux dimensions des classes. (a)Exemple linéairement séparable (par exemple selon la droite en pointillé). (b)Exemple non linéairement séparable. ....	39
Figure II.11 : Taxonomie de l'architecture de l'apprentissage profond. ....	43
Figure II.13 : Architecture générale de haut niveau de CNN. ....	46
Figure II.14 : Couche de convolution avec volumes d'entrée et de sortie. ....	47
Figure III.1 : Logo Python. ....	53
Figure III.2 :Logo Anaconda. ....	54
Figure III.3 : Logo Pycharm. ....	45
Figure III.4 : Géométrie de l'emporte-pièce et dimensions de l'éprouvette. [41] ....	57
Figure III.5 : Allure d'une courbe de traction classique.....	58

Figure III.6:Interface de Création du modèle CNN. ....	69
Figure III.7: interface de chargement des données.....	69
Figure III.8: Fenêtre d'apprentissage. ....	70
Figure III.9: Fenêtre test temps=120h. ....	71
Figure III.10: Fenêtre test temps=550h. ....	71
Figure III.11: Fenêtre test temps=1010h. ....	72
Figure III.12: Fenêtre test temps=2040h. ....	73
Figure III.13: Fenêtre de prédiction temps=100h.....	73
Figure III.14: Fenêtre de prédiction temps=80h. ....	73

**Résumé:**

Des travaux expérimentaux font l'objet de l'étude du comportement des films PEBD où s'accumule la température, UV et la pluie qui sont des éléments responsables du processus de vieillissement des serres agricoles. Les films multicouches ont subi différents vieillissements, artificiel durant une période de temps donnée (le multicouches Agro-film) et un vieillissement par de facteurs. Vu le cout de ces expériences en matière de temps et de moyens et la multitude des facteurs à prendre en compte, nous voulons dans ce travail utiliser la simulation informatique comme un support pour l'étude du vieillissement de ces films. Les réseaux de neurones se présentent comme l'outil adéquat pour tenir tous ces paramètres en compte. Donc, ce travail consiste à l'étude des films plastiques PEBD au vieillissement mécanique à l'aide de la simulation informatique basée sur les réseaux de neurones profonds.

**Mots clés:** LDPE, réseaux de neurones, apprentissage en profondeur, CNN, réseau de neurones convolutif.

**Abstract:**

Experimental works are being studied the behavior of LDPE films in which temperature, UV and rain are accumulating, which are responsible for the aging process of agricultural greenhouses. The multilayer films have undergone different aging, artificial during a given period of time (the multilayer Agro-film) and aging by factors. Given the cost of these experiments in terms of time and means the multitude of factors to take into account, we want in this work to use computer simulation as a support for the study of the aging of these films.

Neural networks are the appropriate tool to take all these parameters into account. So, this work consists of the study of LDPE plastic films in mechanical aging using computer simulation based on deep neural networks.

**Key words:** LDPE, neural networks, deep learning, CNN, convolutional neural network.

## *Introduction générale*

## Introduction Générale

---

### Introduction générale :

Avoir une solide compréhension des techniques d'apprentissage en profondeur donne l'impression d'acquérir un super pouvoir de nos jours. De la classification des images et de la traduction des langues à la construction d'une voiture autonome, toutes ces tâches sont effectuées par ordinateur plutôt que par un effort humain manuel. L'apprentissage en profondeur a pénétré dans des industries multiples et variées, et il continue d'innover presque chaque semaine.

Aujourd'hui, l'apprentissage profond a de nombreuses applications dans des domaines très variés : utilisés en finance, en gestion et en informatique en tant qu'outil d'aide à la décision, il a connu le plus de succès sur le terrain des industries chimiques de pulpes à papier, de processus alimentaire et La dégradation des polymères. Il est aussi rapporté que Perceptron Multi Couches été utilisée dans des domaines aussi variés qui est jugée très efficace pour aborder des problèmes de contrôle, grâce à l'habileté de prédiction donnée par le modèle encasté, ainsi que le maniement de contrainte.

La dégradation des polymères de la vie courante est un phénomène très lent à température ambiante qui s'accompagne d'une très faible émission de produits de dégradation, la durée d'utilisation de ces matériaux pastiques est relativement courte par rapport à leur durée de vie de quelques années suivant les conditions d'usage et d'environnement. La dégradation des polymères en usage externe est principalement due aux rayonnements ultraviolets du spectre solaire.

Ces produits plastiques tels que les polyoléfines sont des polymères synthétiques possédant de bonnes propriétés physiques, chimiques et mécaniques, Le polyéthylène est l'un des matériaux de plasticulture les plus utilisés. Il est un polymère thermoplastique, translucide, chimiquement inerte ,facile à manier et résistant au froid, du rayonnement solaire ultraviolet, des sollicitations mécaniques et des agents chimiques, Les deux principales familles de PE sont le PEHD (PE haute densité) et le PEBD (PE basse densité).

Les réseaux de neurones se présentent comme le formalisme adéquat pour tenir tous ces paramètres en comptes.vu que les briques élémentaires de l'apprentissage profond sont les réseaux de neurones, ce travail consiste à étudier le vieillissement des films plastique multicouches à l'aide de la simulation informatique basée sur les réseaux de neurones profonds. Ces derniers sont devenus des outils de modélisations puissantes et une source d'information fiable appliqués dans des domaines différents.

## Introduction Générale

---

Ces réseaux sont maintenant considérés comme des outils mathématiques, indépendamment de toute référence à la biologie ; permettant de résoudre, avec une grande précision, les problèmes de modélisation ou d'identification linéaires et non linéaires.

Notre travail est schématisé en trois chapitres. Le premier chapitre représente une vue générale sur les notions de base des matériaux tels que les polyéthylènes et les films PEBD, leurs utilisation et leurs dégradation. Puis en deuxième lieu, un chapitre qui contient présentant l'apprentissage profond, ses concepts et ses différentes architectures en se focalisant sur les CNN. Le troisième chapitre est sous forme d'application d'apprentissage profond à la prédiction des propriétés mécanique des films PEBD multicouches en présentant les tests utilisés et les résultats, dans cette étape de réalisation, nous avons sélectionné les technologies les plus adaptées à notre choix technique. En dernier lieu, nous présentant les différentes interfaces graphiques de notre application de prédiction des propriétés mécaniques des films PEBD multicouches.



# Chapitre I : Etat de l'art

## I.1.Introduction

Les polymères, ces dernières années, ont trouvé une utilisation dans une variété d'application. En outre, ils ont un usage intensif comme matériaux d'emballage. En termes d'application mécanique, dans certains systèmes, les roulements, les pignons, les joints sont faits de plastique. Ils sont maintenant largement utilisés pour la fabrication des tubes pour le transport des fluides. [01]

Les matériaux polymères sont généralement utilisés pour leurs propriétés mécaniques particulières et leur aptitude à être mis en œuvre. Ces qualités sont liées à leur structure et à partir d'une structure moléculaire donnée, il est possible d'imaginer la morphologie qui en découle et les propriétés qui s'y rattachent. Au cours du temps et selon les modes d'utilisation des matières plastiques, on observe souvent une altération des propriétés des polymères, altération qui peut entraîner la mise hors service de ces produits. Le vieillissement des matières plastiques se manifeste par une dégradation, souvent lente mais toujours irréversible de leurs propriétés.

Ce chapitre a pour objectif d'une présentation générale des polymères, il est consacré à la description des polymères, et plus particulièrement le polyéthylène basse densité qui nous intéresse dans le cadre de ce projet. Nous aborderons dans un premier temps la description de ce type de polymère puis nous traiterons successivement des modes de dégradation des polymères.

## I.2. Définitions

### I.2.1. Polymère

Les matériaux polymères (du grec *polus*, « plusieurs » et *meros*, « partie »), appelés aussi matériaux plastiques sont constitués de la répétition d'un grand nombre d'unités constitutives appelées monomères. Ces derniers sont des molécules (monomères) organiques comprenant un ou plusieurs atomes de carbone. Ces chaînes sont une répétition de motif (ou unité) constitutif (M) où  $M = -CH_2-$ . L'appellation matériau polymère est une combinaison des définitions d'un polymère et d'un plastique. En effet, le terme polymère est plutôt réservé pour définir le matériau obtenu de manière naturelle ou par synthèse organique. [02]

### I.2.2. Monomères

Ce sont les composés de base des polymères. Relevant de la chimie organique, ils associent des liaisons covalentes avec une séquence de molécules additionnelles semblables ou non (des atomes de carbone et des atomes d'hydrogène, d'oxygène, d'azote, etc.) dans les conditions de la réaction de formation de polymère adaptée utilisées pour un procédé particulier, chaque atome de carbone, tétravalent, est relié aux atomes voisins par quatre

liaisons covalentes, orientés dans l'espace vers les quatre sommets d'un tétraèdre régulier [03].




Figure I.1 : Monomère d'un homopolymère.

### I.3. Polymérisation de polymère

Le terme 'polymérisation' désigne l'ensemble des procédés de formation de chaînes à partir de molécules plus petites (monomères) ; chaque monomère est isolé, il est ensuite combiné avec d'autres monomères de même nature ou de nature différente lors d'une réaction chimique appelée réaction de Polymérisation. [04]

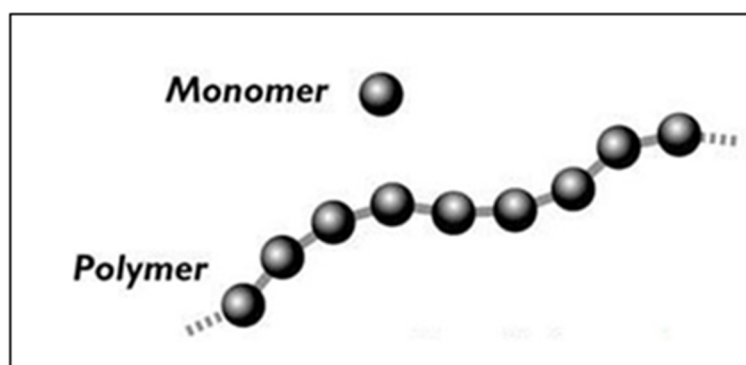


Figure I.2 : Polymérisation.

### I.4. Classification des polymères

Il existe plusieurs critères [06] permettant de classer les macromolécules tels que :

- **L'origine des polymères**

- **Naturels** : Sont issus des règnes végétal ou animal.
- **Artificiels** : Obtenus par modification chimique de polymères naturels.
- **Synthétiques** : Obtenus par polymérisation de molécules monomères.

- **Selon les unités :**

La structure chimique des motifs permet une classification des composés macromoléculaires en homopolymères et copolymères.[05]

**a. Les homopolymères:**

Sont des polymères qui ne possèdent qu'une seule unité, ces homopolymères sont des longues chaînes formées par la répétition d'un monomère, leurs propriétés mécaniques, écoulement à l'état fondu, optique, sont dues à la structure chimique des monomères et à la longueur des chaînes [07].

**b. Les copolymères:**

Sont des polymères qui possèdent plusieurs unités, comme pour les homopolymères, les copolymères peuvent se classer dans différentes familles, citons: le mode statistique, alterné, séquencé et greffé. [07]

- **Selon leur structure :**

Les polymères peuvent présenter des architectures extrêmement variables. Ils peuvent être linéaires, ramifiés ou réticulés. Le plus souvent, ils sont amorphes, parfois ils peuvent être, au moins partiellement, cristallisés [08].

**a. Les polymères linéaires :**

En plus des liaisons covalentes, les chaînes de monomères sont aussi reliées entre eux par des ponts hydrogènes. Ces liaisons secondaires assurent la stabilité du polymère et lui confèrent une certaine rigidité. Sous l'effet d'une température élevée le polymère acquiert le comportement d'un liquide visqueux, en parle alors d'une température de transition vitreuse, qui marque le passage de l'état vitreux à l'état caoutchoutique. Il faut souligner que l'appellation « polymère linéaire » ne signifie pas que les groupes unitaires de la chaîne soient alignés, en effet, ils peuvent être: en zig-zag, en hélice simple ou double ou bien en pelote.

**b. Les polymères ramifiés :**

Des chaînes homopolymériques ou copolymériques peuvent se greffer sur d'autres chaînes au cours de la polymérisation. Au-dessus de la température de transition vitreuse, ces matériaux présenteront un comportement visqueux plus marqué que les polymères linéaires [09].

**c. Les polymères réticulés**

La réticulation correspond à la formation de liaisons chimiques suivant les différentes directions de l'espace, au cours d'une polymérisation de polymères linéaires, qui conduit à la formation d'un réseau tridimensionnel [09].

**d. Polymères amorphes et polymères cristallisés:**

Les chaînes macromoléculaires peuvent être organisées de façon aléatoire dans l'espace et constituer ainsi une phase amorphe équivalente à un liquide « figé », sans ordre moléculaire à grande distance. L'étude de la diffraction des rayons X montrent que certains polymères comportent des régions où les chaînes sont ordonnées (cristallites). Les deux états ordonnés et désordonnés peuvent coexister dans un même matériau qui est alors de nature semi-cristalline. [09]

**• Selon leur comportement thermique et mécanique:****a. Polymères thermoplastiques:**

Ce sont des polymères linéaires, fusibles et soluble dans les solvants organiques et ils sont en générale recyclable, c'est-à-dire, ils permettent le chauffage et le refroidissement plusieurs fois lors du moulage des pièces [10, 11].

**b. Les polymères thermodurcissables:**

Ils durcissent au cours de la polymérisation lors de la montée en température en formant un réseau tridimensionnel de monomères liés par liaisons covalentes. La transformation est unique et donne lieu à une pièce définitive. Donc, il n'existe pour eux ni solvant, ni phase fondue. Les thermodurcissables ne sont pas recyclables et leur mise en forme est plus complexe [10, 11].

**c. Les élastomères:**

Ce sont des polymères qui peuvent être étirés à au moins deux fois de leur longueur d'origine et qui se rétractent à leur dimension initiale dès que l'arrêt de la force d'étirement. Parmi les avantages des Élastomères, il faut citer une excellente mise en œuvre, de bonnes propriétés mécaniques, un très faible échauffement interne et une très bonne tenue au froid [11,12].

**d. Les polymères thermostables**

**e.** Ce sont des polymères qui conservent leurs propriétés quelques minutes à 600°C, quelques heures à 400°C, plus de 100 heures à 300°C et plus de 30000 heures à 220°C [11].

**I.5. Domaines d'état**

Le domaine d'état exprime la variation de comportement du matériau en fonction du changement de température. Pour un matériau polymère on distingue trois domaines d'états : état vitreux, état caoutchoutique et état fondu. Entre les états vitreux et caoutchoutique il existe une zone appelée zone de transition vitreuse. Ce phénomène est défini seulement pour les polymères amorphes et les phases amorphes de thermoplastiques semi-cristallins. La température de transition vitreuse  $T_g$  trouvant dans cette zone a une grande importance, car

elle caractérise le passage du polymère d'un état dur et fragile à un état mou et souple lors d'une élévation de température. Elle dépend de :

- La rigidité de la chaîne polymère (une chaîne rigide aura une **T<sub>g</sub>** haute, et une chaîne souple aura une T<sub>g</sub> basse).
  - La **taille** des groupes latéraux (des groupes latéraux grands vont être des obstacles au glissement des chaînes et donc donner un polymère de haute **T<sub>g</sub>**).
  - La force des interactions intermoléculaires (des interactions fortes donnant une haute **T<sub>g</sub>**).
- [13,14]

### **I.5.1. Etat vitreux**

Le matériau est solide et rigide, il montre un comportement semblable au verre, les mouvements intermoléculaires c'est à dire les glissements des chaînes sont bloqués. Cet état est obtenu lorsque le matériau est refroidi à une température inférieure à T<sub>g</sub>. Lors d'une sollicitation, le polymère présente une déformation élastique, basée sur des modifications réversibles des distances atomiques et des angles de valences des liaisons chimiques. En général, les Thermodurcissables et les thermoplastiques se trouvent à l'état vitreux à température ambiante 23°C. [13,14]

### **I.5.2. Etat caoutchoutique**

Ce domaine se situe dans le sens des températures croissantes ; les mouvements de rotation et de transition des segments de chaînes sont possibles, de sorte que les macromolécules peuvent adopter une forme étirée sous l'effet d'une sollicitation. Le comportement des matériaux polymères dans ce domaine de températures étant semblable à celui du caoutchouc, cet état est également appelé état caoutchoutique. [13,14]

### **I.5.3. Etat fondu**

Avant cet état, il y a une autre zone qui se trouve entre les états caoutchoutique et fondus, elle est appelée zone de fusion, caractérisée seulement pour les polymères thermoplastiques. Pour un thermoplastique amorphe cette zone est appelée aussi zone de fluidification; pour un thermoplastique semi-cristallin il y a une température importante température de fusion T<sub>f</sub>, elle est caractérisée seulement pour ce type de polymère, elle est définie comme le passage d'une structure semi cristalline à un état liquide amorphe et elle correspond à la température de fusion des cristaux. [13,14]

Les thermoplastiques amorphes, les élastomères et les thermodurcissables ne sont pas concernés par cette température ; car T<sub>f</sub> est la conséquence de la fondation de cristallites à une

température élevé. Après cette zone le matériau passe à l'état fondu ou liquide (à très haute température) l'état d'abord est visqueux puis, l'écoulement devient plus en plus facile. [13,14]

### **I.6. Propriétés des polymères**

Les propriétés des matériaux polymères sont beaucoup plus sensibles que celles des métaux aux influences extérieures telles que la température, la dureté, l'intensité de la contrainte appliquée, les radiations UV et les agents chimiques. Leur module d'élasticité est en général inférieur de deux ordres de grandeur à celui des métaux.

Les caractéristiques de résistance peuvent différer seulement d'un ordre de grandeur. Sauf les paramètres spécifiques ou matériaux (masse molaire, taux de ramification, mobilité des chaînes, taux de réticulation,.....), et les conditions extérieures (humidité, agents chimiques, température, vitesse de sollicitation, type et intensité des contraintes appliquées).

#### **I.6.1. Propriétés physiques**

Avant tout, rappelons qu'il existe une grande variété de matières plastiques, tout comme il existe un grand nombre d'alliages métalliques, une des caractéristiques physiques générales des polymères est : [15]

- La masse volumique : La masse volumique des matières plastiques est peu élevée. La légèreté des polymères est sans aucun doute une des qualités qui a le plus largement contribué à leur diffusion. En ce qui concerne le rapport (résistance à la traction / masse volumique), certains polymères sont en fait supérieurs bien à des matériaux métalliques.

La faible masse volumique des plastiques est due au faible poids atomique des principaux atomes de leurs chaînes (principalement l'hydrogène et le carbone) [15].

- **L'état amorphe :**

A l'état amorphe, une chaîne se déploie dans l'espace pour adopter une configuration dans laquelle on ne distingue aucun ordre. L'absence d'ordre confère au polymère une structure de liquide « figé » dont les principales caractéristiques sont les suivantes :

- a. Pas de point de fusion TF.
- b. Existence d'un point de transition vitreuse TG marquant le passage de l'état liquide caoutchoutique à l'état vitreux.
- c. Transparence dans le visible. Le polystyrène « cristal » ou le poly (chlorure de vinyle) « cristal » sont transparents car ils ont une structure amorphe. [16]

- **L'état cristallin :**

L'état cristallin se caractérise par l'existence d'un ordre à grande distance. Les chaînes ayant adopté une conformation régulière en zigzag plan ou en hélice s'empaquent de façon ordonnée et compacte. On peut alors définir une maille cristalline qui se répète de façon

périodique dans les trois directions de l'espace. Les principales caractéristiques de l'état cristallin sont les suivantes :

- Compacité supérieure à celle de la phase amorphe.
- Existence d'un point de fusion TF, absence de transition vitreuse.
- Indice de réfraction supérieur à celui de la phase amorphe ( $n_c > n_a$ ).
- Imperméabilité totale à la plupart des gaz et vapeurs ou liquides.
- Rigidité supérieure à celle de la phase amorphe. [16]

A partir de l'analyse de ces deux états, on peut en déduire le comportement du polymère permet de classer généralement les polymères en différentes catégories.

Les polymères linéaires possèdent une certaine cohésion grâce à des liaisons physiques. Il existe donc pour eux des solvants. En les chauffant, on passe par une étape plastique, puis liquide (liaisons physiques rompues). Ce sont des thermoplastiques. Les thermoplastes solides sont soit semi cristallins (polyéthylène, polypropylène, polyamide,...), soit amorphes (polystyrène, polychlorure de vinyle, poly (méthacrylate de méthyle), ...) et sont fusibles à

Haute température. Les thermoplastiques sont en général recyclables et facile à mettre en œuvre sous forme liquide.

Les polymères en réseau ont leur cohésion due à des liaisons chimiques. Il n'existe donc pour eux ni solvant, ni phase fondue. Si on les chauffe, les quelques ramifications du réseau pendantes s'accrochent. Ce sont des thermodurcissables. Ils ne fondent pas mais se décomposent à température élevée. Les thermodurcissables sont des matériaux rigides, cassants et résistants à la température. Les thermodurcissables ne sont pas recyclables et leur mise en œuvre automatisée est plus complexe. Par contre, ils peuvent servir de matériaux structuraux.

### **I.6.2. Propriétés thermiques**

La température de transition vitreuse "Tg" et la température de fusion "Tf" sont les deux températures fondamentales nécessaires dans l'étude des matériaux polymères. La température de transition vitreuse est partiellement importante pour les polymères amorphes, notamment les thermoplastiques amorphes, pour lesquels, il n'existe aucune force de cohésion importante autre que l'enchevêtrement. [17].

Les températures caractéristiques d'un seul et même matériau peuvent alors être classées de la façon suivante :

- Température de transition vitreuse
- Température de cristallisation
- Température de fusion



- Température de décomposition thermique. [17]

Selon la température à laquelle il est soumis, un matériau polymère peut présenter des comportements mécaniques différents. Ceci peut se produire pour les thermoplastiques semi cristallins dans un domaine même étroit de la température. [17]

### I.6.3. Propriétés mécaniques

Le succès des polymères provient en partie de la facilité avec laquelle on peut leur donner des formes voulues; d'autant plus à l'état fondu ils sont très malléables (très plastiques, d'où leur nom). En fait, cette plasticité varie dans une large gamme, des plus rigides, durs et cassants, aux plus mous (pâtes) ou élastiques (élastomères). [18].

### I.6.4. Facteurs ayant une influence sur les propriétés mécaniques des polymères :


Différents paramètres peuvent influencer les propriétés mécaniques des polymères :

- La **crystallinité (ou taux de cristallinité)** correspond au pourcentage en poids de phase cristalline dans le matériau.
- La **température de transition vitreuse (T<sub>g</sub>)** correspond à la température à laquelle le polymère passe de l'état vitreux à l'état caoutchoutique.
- **La masse molaire** : elle correspond à la densité de liaisons pontales entre les chaînes, une valeur élevée de celle-ci signifie une longueur importante des chaînes, ce qui favorise leurs enchevêtrements dans les zones amorphes et de meilleures liaisons entre zones cristallines. Il existe ainsi une valeur seuil de la masse molaire à partir de laquelle la résistance à la rupture augmente fortement. [19]

Les propriétés mécaniques décrivent leur comportement vis à vis à des sollicitations mécaniques telles Certaines caractéristiques peuvent être déterminées par des essais mécaniques dont : la flexion, la compression, le fluage, le cisaillement, la torsion et la traction

Elles dépendent fortement du type de contrainte appliquée (FigureII.2).

Pour observer le vieillissement du matériau, il est caractérisé par le respect des propriétés mécaniques (élongation à la coupure, propriétés à la traction ou à la résistance aux chocs) et les caractéristiques visibles telles que la formation des fissures et le changement de couleur.



**Figure I.3 : Principales contraintes mécaniques.**

Les contraintes sont expliquées brièvement ci-dessous :

- **Compression** : Contrainte qui tend à écraser les matériaux.
- **Traction** : Contrainte qui tend à étirer les matériaux.
- **Torsion** : Contrainte qui tend à matériaux.
- Flexion : Contrainte qui tend à courber les matériaux.
- Cisaillement : Contrainte qui tend aux matériaux.

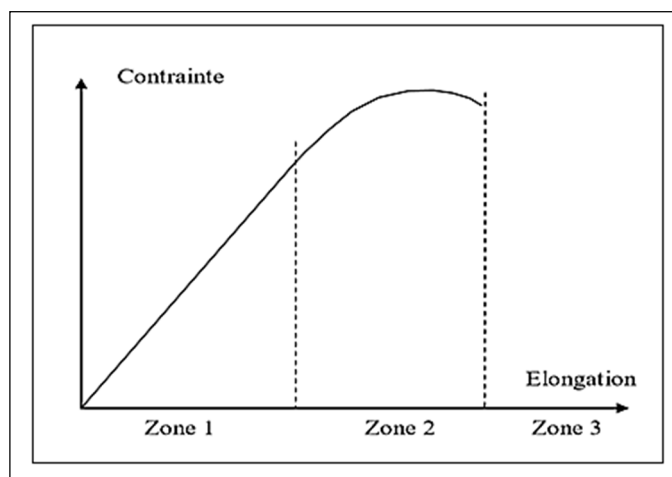
C'est la structure du réseau résultant de l'enchevêtrement des chaînes qui confère aux polymères leurs propriétés mécaniques les plus importantes, à savoir l'élasticité caoutchoutique et le comportement viscoélastique à l'état fondu d'une part, et un comportement à la fois vitreux et ductile à l'état solide d'autre part.

La Figure II.3 présente un exemple de comportement d'un matériau soumis à une contrainte de traction. On y distingue trois zones :

- La zone 1 de la courbe contrainte – élongation est linéaire et correspond à une déformation élastique. Le matériau s'allonge sous l'action de la traction et reprend sa forme et ses dimensions initiales lorsque la contrainte est interrompue. Le coefficient de proportionnalité du droit est appelé module de Young ou module d'élasticité. Celui-ci est d'environ 10<sup>-3</sup> GPa pour un caoutchouc, contre quelques unités pour le polystyrène, quelques dizaines pour les métaux et 10 000 pour le diamant.
- La zone 2 est appelée zone de déformation plastique. La déformation est toujours élastique, mais la variation contrainte-déformation n'est plus linéaire. Cette zone présente un maximum au-delà duquel le matériau subit une déformation irréversible. A l'arrêt de la contrainte, le matériau ne retrouve pas sa forme initiale : il existe une déformation résiduelle permanente.

- Au-delà d'une déformation critique, une contraction du matériau s'opère en un point donné jusqu'à rupture. On aborde alors la zone 3 de la courbe, dite zone de rupture. [20]

Si un matériau se casse dans son domaine élastique, c'est-à-dire sans subir de déformation plastique avant sa rupture, il est considéré comme fragile. Par contre, il sera considéré comme ductile s'il peut subir de grandes déformations plastiques avant sa rupture.



**Figure I.4 :** Comportement d'un matériau soumis à une contrainte mécanique.

Les essais de traction permettent de déterminer qualitativement si un matériau est fragile ou ductile, rigide ou souple. Ils permettent aussi de quantifier certaines propriétés mécaniques telles que le module d'élasticité, la résistance maximale ou la contrainte et l'allongement à la rupture en traction. [21]

### **I.7. Polyéthylène (PE)**

Les polyéthylènes constituent aujourd'hui une grande famille de produits présentant des caractéristiques très variées. Le polyéthylène utilisé dans l'industrie gazière est une matière thermoplastique fabriquée par synthèse chimique à partir de l'éthylène. Le produit fini employé est un mélange assez complexe de divers produits tels que le noir de carbone qui lui donne sa couleur définitive, chacun apportant une amélioration et une protection à l'ensemble. En fait, la particularité qui caractérise le PE par rapport aux autres matériaux métalliques est son évolution avec le temps. Afin d'assurer sa fiabilité, il faut éviter tout erreur au niveau de la fabrication, le stockage – manutention et la mise en œuvre notamment.

### **I.8. Polyéthylène(PE) :**

Les polyéthylènes constituent aujourd'hui une grande famille de produits présentant des caractéristiques très variées. Le polyéthylène utilisé dans l'industrie gazière est une matière thermoplastique fabriquée par synthèse chimique à partir de l'éthylène. Le produit fini

employé est un mélange assez complexe de divers produits tels que le noir de carbone qui lui donne sa couleur définitive, chacun apportant une amélioration et une protection à l'ensemble.

En fait, la particularité qui caractérise le PE par rapport aux autres matériaux métalliques est son évolution avec le temps. Afin d'assurer sa fiabilité, il faut éviter toute erreur au niveau de la fabrication, le stockage – manutention et la mise en œuvre notamment.

### I.8.1. Définition (PE) :

Une molécule de polyéthylène n'est rien de plus qu'une longue chaîne d'atomes de carbone, avec deux atomes d'hydrogène attachés à chaque atome de carbone. Son nom vient du fait qu'il est le polymère obtenu par la polymérisation des monomères d'éthylène ( $\text{CH}_2 = \text{CH}_2$ ) en une structure complexe de formule générique :  $[\text{CH}_2 - \text{CH}_2]_n$ . Il est peut-être plus simple de le dessiner, simplement avec les chaînes d'atomes de carbone longue de plusieurs milliers d'atomes:




Figure I.5 : Schéma représentatif du polyéthylène.

Le polyéthylène est translucide, facile à manier et résistant au froid. Le polyéthylène est thermoplastique. Cette matière plastique représente environ un tiers de la production totale des matières synthétiques et constitue la moitié des emballages plastiques. Le polyéthylène prime sur la plupart des autres matériaux car il peut être réutilisé. [23].

### I.8.2. Types de Polyéthylène:

Les PE (polyéthylène) font partie des thermoplastiques, Il existe différents types de polyéthylène Les polyéthylènes sont classés en fonction de leur densité qui dépend du nombre et de la longueur des ramifications présentes sur les chaînes moléculaires. [24]

- Le PEHD, polyéthylène haute densité synthétisé sous faible pression par le procédé Ziegler. Il se présente sous la forme d'une chaîne macromoléculaire linéaire régulière. Quelques irrégularités restent présentes (1%0carbone) et se manifestent sous la forme de courtes ramifications. Sa masse volumique est la plus importante de tous les polyéthylènes et varie entre 0.955 et 0.970 g/cm<sup>3</sup>.
- Le PEBD, polyéthylène basse densité synthétisé sous forte pression par polymérisation radicalaire. Contrairement au PEHD, le PEBD présente un nombre élevé de ramifications

relativement importantes (de l'ordre de 60% de carbone) directement responsables de sa faible masse volumique (de 0.915 et 0.935 g/cm<sup>3</sup>) [24]

### **I.8.3. Les propriétés du polyéthylène basse densité PEbd :**

En général, les méthodes industrielles ne conduisent pas un édifice architectural parfaitement régulier, constitué de motifs structuraux indiques. Certains actes chimiques qui font parties intégrantes du mécanisme de polymérisation sont à l'origine de structure irrégulière, introduite selon le cas dans la chaîne ou à ses extrémités

Ces irrégularités peuvent influencer, directement ou indirectement, les propriétés physiques ou chimiques du polymère. En effet la résistance à la rupture est directement liée à la concentration en bout de chaînes.

Elles représentent des amorces certaines au phénomène de rupture. En plus elles s'opposent à la cristallisation. Par conséquent, les extrémités de chaînes jouent un rôle fondamental dans les propriétés mécaniques. [13]

### **I.8.4. Propriétés Physico-chimiques:**

Le mode de cristallisation du polyéthylène conduit à des taux de cristallisation plus ou moins faible. Il sera d'autant plus difficile à cristalliser que le polymère est ramifié. Les ramifications empêchent les réarrangements macromoléculaires.

Les propriétés physiques dépendent, de la cristallinité et de la masse moléculaire. L'aspect des polyoléfinés en général et du polyéthylène en particulier, est blanc laiteux, cireux au touché. Ils sont opaques en fortes épaisseurs et transparents en film. Ils sont assez perméables à l'hydrocarbure set aux essences.

Le polyéthylène présente une stabilité chimique, en d'autres termes une très bonne résistance aux acides faibles, aux bases faibles et fortes, une résistance moyenne pour les acides non oxydants et les solvants organiques. Il est insoluble dans l'eau et particulièrement adaptable à l'utilisation alimentaire. Par contre, il est très sensible aux radiations Ultraviolet. Ses propriétés électriques sont excellentes.

Récapitulatifs des principales caractéristiques [25, 26]:

- Couleur Blanchâtre.
- Densité (%) 0,910 à 0,935.
- Aspect extérieur Rappelant la paraffine.
- Température de fusion 105 à 115 °C.
- Tenue à la chaleur Max à 90 °C
- Tenue au froid Min -50 °C.

- Tg - 110 °C.
- Il possède également des propriétés de flexibilité et de résistance au choc.
- Il est caractérisé par une grande facilité de mise en oeuvre.
- Il brûle sans dégagement de fumée toxique.

#### **I.8.5. Propriétés mécaniques :**

Comme la structure du matériau PE se compose de Zones cristallines sous forme de plans lamellaires dans lesquels les chaînes moléculaires sont orientées perpendiculairement à ces plans, sous forme de replis, elles sont séparées entre elles par les zones amorphes. Des molécules liens intercrystallites passant à travers les zones amorphes, les relie entre elles [27].

Ces molécules liens jouent un rôle prépondérant dans les caractéristiques mécaniques de PE, car elles sont ancrées en zones cristallines. Elles transfèrent les efforts entre les parties cristallines adjacentes. Elles supportent des niveaux de contraintes élevés et peuvent se rompre durant la déformation.

L'extensibilité des polymères semi-cristallins en général, et celle du polyéthylène en particulier, est reliée au nombre de chaînes moléculaires repliées dans la zone cristalline, car seules les chaînes fortement repliées sont capables de subir de grandes déformations [28]. Les déformations plastiques qui en résultent impliquent la déformation, le déplacement et la réorientation des différents éléments structuraux tels que les segments de chaînes [29].

Les caractéristiques mécaniques de ce matériau sont intéressantes et peuvent même rivaliser avec les matériaux dits classiques [30] :

- Caractéristiques mécaniques en traction 200 à 400 MPa.
- Caractéristiques mécaniques en compression 150 à 200 MPa.
- Caractéristiques mécaniques en flexion 100 à 150 MPa.
- Allongement 200 à 650 %.
- Bonnes résistances aux chocs.

Enfin le PEBD présente une grande variété au niveau de la structure moléculaire et de la morphologie cristalline.

#### **I.9. Vieillessement des polymères:**

Le vieillissement décrit un ensemble de mécanismes complexes qui se traduisent par une évolution lente et irréversible des propriétés intrinsèques des matériaux. Ainsi exposés aux intempéries les films de polyéthylène se dégradent assez rapidement. Les facteurs

responsables sont les radiations solaires, les variations de la température, l'humidité, Vent, grêle, sable, l'oxygène de l'air et les pollutions atmosphériques. [31]

### **I.9.1. Aspects généraux du vieillissement :**

Les différents types de vieillissement sont généralement classifiés en fonction de la cause externe. Ainsi la température élevée est à l'origine du vieillissement thermique les rayements UV ou ionisants provoquent le vieillissement photochimique etc....

IL existe cependant un certain nombre d'aspect communs à tous les types de vieillissement (coupures de chaînes, réticulation etc.) dont les méthodes d'études et la conséquence sur les propriétés physiques des polymères ne varient pas d'un type à l'autre de vieillissement. [32]

#### **– Réactions de coupure statistiques :**

C'est le processus le plus important. Une grande variété de mécanismes peuvent conduire à des coupures « statistique » c'est-à-dire réparties de façon aléatoire sur les chaînes macromoléculaires par des mécanismes qui contribuent à cette opération.

La rupture de la continuité des liaisons covalentes se traduit par la détérioration des propriétés mécanisme, entraînant ainsi une diminution de la contrainte à la rupture.

#### **– Réactions de dépolymérisations:**

C'est l'inverse des réactions de polymérisation. Elles font intervenir une élimination séquentielle de molécules de monomères, à partir d'un site particulièrement instable préexistant (par exemple la fin de la chaîne).

Dans ce cas, la variation de masse molaire du polymère est beaucoup plus élevée car chaque acte chimique de dépolymérisation conduit au dégagement d'une molécule de monomères gazeux.

#### **– Réactions de réticulation :**

Ce sont des réactions qui aboutissent à la création d'un réseau bi ou tridimensionnel par certaines propriétés élastiques et plastiques du polymère. Elle renforce la résistance à la décomposition. Les réactions de réticulation peuvent se faire par voie exclusivement thermique. Bien que la plupart du temps un agent chimique (oxygène par exemple) intervienne.


## I.9.2. Vieillissements artificiel et dégradation [13]

### I.9.3. Vieillissement physique :

Le vieillissement physique se traduit de plusieurs manières différentes que nous allons aborder:

#### – La plastification

La plastification apparaît lorsque les molécules de solvant s'introduisent dans le réseau macromoléculaire. Ceci produit des désordres qui affaiblissent, voir même détruit, les liaisons secondaires entre chaînes, responsables de la cohésion du matériau. Ainsi, en détruisant les liaisons secondaires du polymère, l'eau diminue la cohésion mécanique et augmente la mobilité moléculaire.



**Figure I.6 : Schématise la pénétration d'un solvant dans un polymère.**

La plastification est caractérisée par une modification des propriétés mécaniques du matériau, qui se traduit par une baisse de la température de transition vitreuse ( $T_g$ ), transition entre le domaine caoutchoutique et le domaine viscoplastique.

#### – Le gonflement:

La pénétration de solvant au sein du matériau polymère peut induire un gonflement susceptible de provoquer des modifications de structure interne lorsqu'il existe des hétérogénéités qui induisent des contraintes entre zones plus ou moins gonflées. Ces zones peuvent être amorphes (relativement accessibles), ou cristallines (relativement impénétrables).

Ce gonflement peut aussi intervenir lorsque la cinétique de diffusion du solvant crée des gradients de concentration. Enfin, il existe lorsque le matériau subit des cycles successifs de vieillissement.

#### – L'endommagement:

L'endommagement sous contraintes peut produire des craquelures ou des fissures dans le matériau. Le craquelage (crazing) concerne les zones constituées de vide et de fibrilles très



orientées dans le polymère. La fissuration (cracking) est issue de craquelure qui peut conduire à la formation d'une microfissure puis d'une fissure.

#### **I.9.4. Vieillissement chimique :**

Le vieillissement chimique regroupe plusieurs phénomènes qui peuvent parfois être complémentaires entre eux, ce qui complique considérablement l'analyse. Ils se traduisent principalement par des phénomènes d'hydrolyse, d'oxydation, de lessivage ou de diffusion et peuvent conduire à une altération du squelette macromoléculaire suivant trois mécanismes distincts :

- Les coupures du squelette peuvent induire une baisse de la masse molaire du polymère, ce qui entraîne une chute des propriétés mécaniques.
- Une ou des réactions de réticulation peuvent se produire, notamment sur les polymères qui possèdent des doubles liaisons dans la chaîne ou des groupements réactifs n'ayant pas encore réagis auparavant.
- Une ou des réactions sur les groupements latéraux peuvent intervenir par substitution d'un groupe sur un autre, par élimination des groupes au profit d'une double liaison ou d'une cyclisation. Ils sont généralement classifiés suivant la cause externe qui les provoque : vieillissement thermochimique, photochimique, biologique..

Il existe aussi un autre vieillissement de type hydrolytique qui implique principalement les polymères dont la chaîne comporte des hétéro atomes [33].

Il faut noter que la plupart des phénomènes de vieillissement sont thermoactives, et que la présence de défauts dans le matériau accélère ces processus.

#### **I.10. La Déformation des polymères solides :**

Le développement des polymères structuraux est lié à leurs propriétés mécaniques, qui dépendent elles-mêmes de la microstructure. C'est ainsi que les polymères semi-cristallins ont pour la plupart une ténacité élevée qui répond aux exigences de produits devant résister à des conditions d'utilisation sévères (**impact, fluage, fatigue**). Les mécanismes de déformation des polymères en tant que réponse aux contraintes élevées auxquelles ils sont soumis, peuvent être à grande ou à petite échelle [34].


Les mécanismes à grande échelle ou macroscopiques engendrent une déformation initialement homogène de la zone impliquée dans les déformations. Ils sont en général très dissipatifs et conduisent à une modification de la géométrie, aisément observable, de la structure déformée. Dans cette partie, nous nous intéressons au comportement mécanique des polymères solides en nous appuyant sur la compréhension des micro mécanismes de déformations.

### I.10.1. La Déformation de la phase amorphe :

La phase amorphe du matériau est caractérisée par une partie libre contenant des enchevêtrements et par une partie liée aux lamelles cristallines. Le rôle mécanique de cette phase est la transmission des contraintes d'une cristallite à une autre par l'intermédiaire de molécules de lien. Ces connexions inter lamellaires sont des points de réticulation physiques qui confèrent à la phase amorphe une certaine résistance mécanique [35]. En outre, le glissement des chaînes au niveau des enchevêtrements est une source de déformation irréversible. Il existe deux modes de déformation de la phase amorphe impliquant les molécules et les empilements de lamelles : le glissement inter lamellaire et la séparation inter lamellaire. Le glissement inter lamellaire correspond au cisaillement parallèle de deux lamelles cristallines l'une par rapport à l'autre sous l'effet d'une contrainte de cisaillement [36]

La séparation inter lamellaire se traduit par une variation de la distance entre deux lamelles lorsqu'une contrainte est appliquée perpendiculairement à ces lamelles (Figure II.7).

Cette déformation a pour conséquence une diminution de la densité de phase amorphe et une création de microcavités [37], [38]. Ces deux mécanismes provoquent uniquement la déformation de la phase amorphe.



**Figure I.7 : Mécanismes de déformation de la phase amorphe dans les polymères semi-cristallins a) Etat non déformé, b) Glissement inter lamellaire et c) Séparation inter lamellaire [12].**

### I.10.2. La Déformation de la phase cristalline :

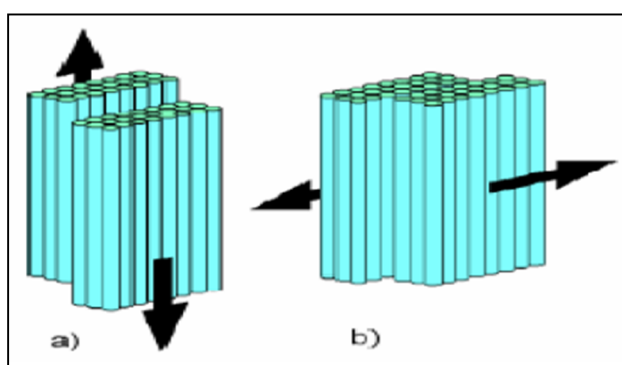
Dans un cristal métallique, le glissement consiste en un déplacement de blocs cristallins le long d'un plan atomique dense bien défini. Ce dernier est appelé plan de glissement, tandis que la direction de ce processus est qualifiée de direction de glissement. En réalité, le glissement ne se produit pas en bloc mais progressivement, de proche en proche, grâce aux mouvements de dislocations. Les cristallites des polymères se déforment également par un mécanisme de glissement. Cependant, contrairement aux métaux, seuls sont actifs les systèmes de glissement dont le plan contient l'axe des chaînes. Cette restriction est due à la

présence des liaisons covalentes le long des chaînes. Ainsi, dans un cristal de polymère, le plan de glissement doit contenir la direction des macromolécules [39]. Les cissions critiques résolues des systèmes de glissement dans les cristaux de polymères dépendent des liaisons de van der Waals entre les chaînes macromoléculaires [40].

### I.11. La Fragmentation des lamelles cristallines :

Lors d'un effort de traction, les lamelles cristallines et les zones amorphes sont soumises à des déformations en traction, en cisaillement, en flexion ou en compression selon leur orientation au sein du sphéroïde [41], [42].

Les mécanismes de déformation de la phase amorphe et de la phase cristalline interagissent pendant la destruction de la morphologie semi-cristalline [43].



**Figure I.8 :** Processus de glissements a) parallèle et b) perpendiculaire aux chaînes des lamelles cristallines [36], [44].

### I.12. Travaux liés aux polymères

Le film de polyéthylène basse densité (LDPE) est actuellement le matériau de revêtement de serre le plus utilisés comme couverture pour les serres dans les pays. Exposition du film de LDPE aux conditions climatiques, en particulier au rayonnement solaire

Récemment, peu de tentatives ont été faites sur l'étude des performances et la durabilité de ce matériau composant la structure dans différentes conditions de vieillissement conduit à optimiser les paramètres de processus de ces films et sa structure. En effet, cela améliorera l'efficacité des performances et la durée de vie des films et, par conséquent, leur impact sur l'économie, le film de couverture est produit sous forme d'une monocouche de polyéthylène basse densité.

– Gruenwald (1992) et Vishu (1995) ont montré que l'orientation moléculaire lors du soufflage du film influe sur les propriétés de traction; plus haut dans la direction de la chaîne

carbone-carbone liée par covalence que dans la direction transversale dominée par des liaisons de van der Waals plus faibles. Les conditions climatiques, telles que l'irradiation solaire, la température, l'humidité, la pluie, le vent et la pollution, influencent le vieillissement et les propriétés mécaniques des couvertures de serre en polyéthylène basse densité (PEBD).

– Hassini et al. (2002) ont étudié l'effet d'un vent de sable simulé pendant quatre heures sur un film de polyéthylène. Salem (2001) a examiné l'effet du rayonnement UV sur les propriétés mécaniques des films de PEBD contenant de l'oxyde de titane et du carbone noir. Le rayonnement UV a modifié l'allongement et la contrainte de cisaillement des échantillons.

– Pacini (2001) a souligné l'importance de maintenir la couverture de serre en plastique dans de bonnes conditions et a examiné les propriétés de la couverture, notamment la perméabilité totale au rayonnement solaire, les propriétés mécaniques, la durée de conservation, les effets du climat et l'homogénéité de l'épaisseur et de la largeur du film.

– Mourad et al. (Mourad, 2010; Mourad et al. 2005,2009a, b; Fouad et al. 2008) ont étudié les propriétés mécaniques, thermiques et stabilité chimique des différentes qualités de polyéthylène dans différentes conditions de vieillissement.

– Dehbi et al. (Youssef et al. 2008a, b, Dehbi et al. 2010). Ils ont étudié l'effet de différentes conditions arides sous longue durée (jusqu'à 5400 h) de vieillissement naturel et artificiel sur le comportement des films de LDPE en couverture de serre. Les films ont été produits en Algérie par Agrofilm Company en utilisant un processus de co-extrusion avec certains additifs tels que l'anti UV et des agents anti-oxydants. En général, la couverture de serre doit être durable, suffisamment solide pour résister aux charges dues à la neige, vent, récoltes et installation et avec une durée de vie acceptable. Les propriétés mécaniques des revêtements de serre sont très importantes en ce qui concerne leur comportement mécanique sous divers conditions de chargement et comportement structurel global de la serre. Par conséquent, le point central de ce travail est de mener une étude comparative entre les deux monocouches et des films tri-couches en termes de dégradation de leurs performances mécaniques sous différents vieillissement naturel conditions.

– (M.I. Babaghayoua , Abdel-Hamid I. Mouradb,\*,1 , Vicente Lorenzoc , S.F. Chabiraa , M. Sebaaa.2018) ont étudié l'effet du photo vieillissement sur la durée de vie utile sur l'anisotropie des propriétés des films de revêtement de serre en polyéthylène basse densité ,ils ont été exposés des films monocouches extrudés soufflés non stabilisés et stabilisés à une altération naturelle pendant plusieurs mois.L'évolution chimique des produits de photo oxydation a été évaluée par spectroscopie infrarouge, l'évolution de la structure a été contrôlée

par diffraction des rayons X et par des techniques optiques, et les propriétés mécaniques ont été mesurées dans les directions machine, transversale et intermédiaire. Les résultats qu'ils ont été trouvés indiquent que le photovieillissement augmente de manière significative la cristallinité du film, l'épaisseur du cristal et la biréfringence optique. Ces modifications structurelles n'affectent pas seulement les propriétés mécaniques du film mais aussi l'anisotropie mécanique.

– (Abdelkader Dehbi, Abdelhamid. Mourad, Khaled Djakhdane, Ali Hilal-Alnaqbi.2015)  
L'objectif principal de leur travail est d'étudier l'impact de la dégradation des films multicouches de polyéthylène basse densité, utilisés en couverture de serres, dans des conditions climatiques simulées, sur leur comportement mécanique, leur stabilité thermique et leur durée de vie. Les résultats ont révélé que les conditions de vieillissement étaient affectées négativement par la détérioration remarquable des performances du film et de ses fonctionnalités. Le comportement mécanique du film et le rayonnement solaire étaient le principal facteur de dégradation des enveloppes de serre.

### **I.13. Conclusion**

Dans ce chapitre on a présenté le vieillissement des matériaux polymères tels que les polyéthylènes qui sont commercialisés sous la dénomination PEBD, et les notions liées au polyéthylène et au vieillissement.

Le polyéthylène est très facile à employer, il est résistant aux variations de température. Il peut être traité de différentes manières : anti UV, alimentaire, etc.

Ses propriétés et son faible coût d'exploitation en font la principale cause de l'utiliser dans cette présente étude relier l'influence des différentes conditions sur la structure et le comportement des polyéthylènes basse densité et de remontre par la suite au comportement à long terme de ce type de polymère.

---

# Chapitre II:

## Apprentissage profond

### II.1. Introduction:

Lors de l'émergence d'une nouvelle technique, l'ingénieur se demande naturellement en quoi elle peut lui être utile. Ce qui est évidemment le cas pour les réseaux de neurones, dont le nom est lié fortement à la biologie. Alors techniquement parlant, Le réseau de neurones artificiel est un algorithme d'apprentissage automatique. Il est modélisé mathématiquement par un réseau dans un graphe, plus ou moins complexe, hiérarchique sous forme de couches dont les nœuds élémentaires sont appelés neurones. Leurs deux grands domaines d'application sont d'une part la modélisation biologique, et d'autre part, la réalisation de machines destinées à effectuer des tâches auxquelles les ordinateurs et les outils traditionnels semblent moins bien adaptés que les êtres vivants.

Par conséquent, l'apprentissage profond est apparu comme une nouvelle zone de recherche de l'apprentissage automatique, ses briques élémentaires sont les réseaux de neurones, il a été introduit dans le but de rapprocher l'apprentissage par machine de son objectif principal : l'intelligence artificielle. Au cours des dernières années, les techniques développées dans l'apprentissage profond ont déjà eu un impact sur les travaux de traitement des signaux et de l'information, y compris les aspects de l'apprentissage automatique et l'intelligence artificielle.

L'apprentissage profond est une classe qui modélise avec un haut niveau d'abstraction des données grâce à des architectures multiples niveaux. Les caractéristiques et les concepts de niveau supérieur sont donc définis en termes de niveaux inférieurs, et une telle hiérarchie est appelée architecture profonde. Un modèle d'apprentissage profond a la capacité d'extraire des caractéristiques à partir des données brutes grâce aux multiples couches de traitement composé de multiples transformations linéaires et non linéaires et apprendre sur ces caractéristiques petit à petit à travers chaque couche avec une intervention humaine minimale

Le développement de l'apprentissage profond a été influencé par les échecs des autres algorithmes à apprendre un niveau de représentation élevé et à bien généraliser une forme d'intelligence artificielle. Par exemple les autres algorithmes d'apprentissage automatique ne parvenaient pas à avoir des résultats convenables dans le domaine de l'intelligence artificielle comme la reconnaissance d'objets, la segmentation d'images ou la reconnaissance des voix.

Nous commençons donc ce chapitre, en premier lieu, par la présentation de tous les notions en relation avec

L'apprentissage profond, nous expliquons ce qu'est un apprentissage automatique (nous précisons notamment les différences entre l'apprentissage supervisé et l'apprentissage non supervisé).

## II.2. Apprentissage automatique

L'apprentissage est un concept pour définir l'acquisition de connaissance et réutiliser ces nouvelles connaissances. Nous apprenons à partir de perception de l'environnement avec les cinq sens, les expériences de la vie, de répétition des événements avec la mémoire. Pour les machines, comme elles ne sont pas dotées de sens ni de jugement dynamique, elles obéissent aux instructions dans un programme avec des données d'entrée et une donnée de sortie ou réponse du programme. [45]

Tom Mitchell quant à lui a défini l'apprentissage comme un programme informatique qui apprend à partir d'une donnée d'expérience  $E$  une tâche spécifique  $T$  avec une mesure de performance  $P$ . Ces algorithmes d'apprentissage sont classés en trois catégories :

### II.2.1. Apprentissage Supervisé

Cette approche a pour objectif la conception d'un modèle reliant des données d'apprentissage à un ensemble de valeurs de sortie (un comportement) [46]. Un expert est employé pour étiqueter correctement des exemples. L'apprenant doit alors trouver ou approximer la fonction qui permet d'affecter la bonne étiquette à ces exemples.

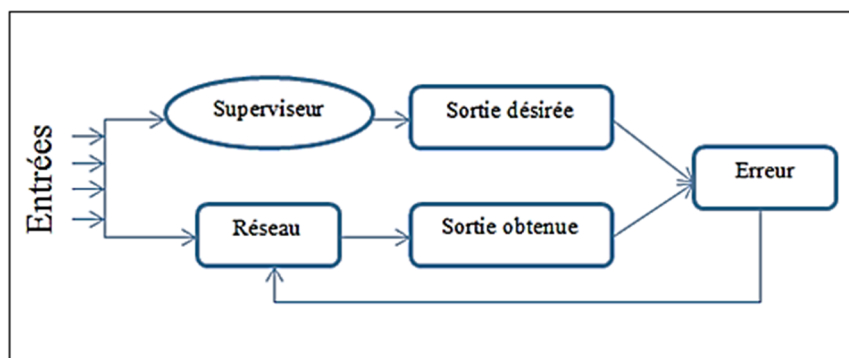


Figure II.1 : Schéma d'un modèle supervisé.

### II.2.2. Apprentissage Non-Supervisé

Aucun expert n'est disponible. Il vise à concevoir un modèle structurant l'information. La différence ici est que les comportements (ou catégories ou encore les classes) des données d'apprentissage ne sont pas connus, c'est ce que l'on cherche à trouver. [45]



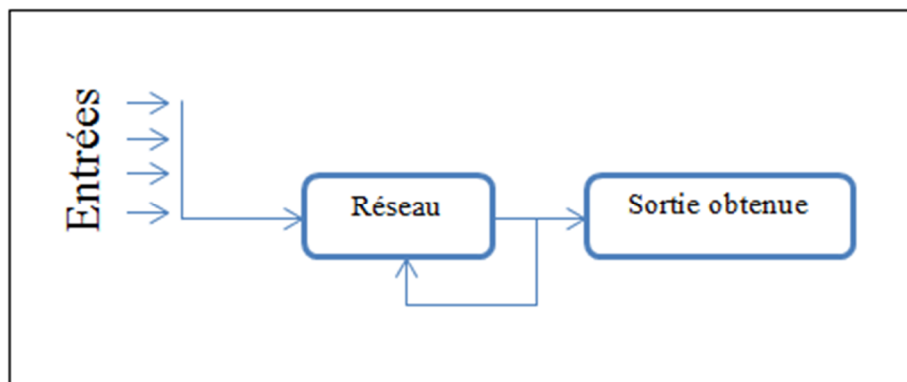


Figure II.2 : Schéma d'un modèle non supervisé.

### II.2.3. Apprentissage semi-supervisé ou apprentissage par renforcement

Ce mode d'apprentissage, suppose qu'un comportement de référence n'est pas possible, mais permet d'obtenir des indications qualitatives (vrai, faux, ...) sur les performances du réseau. [45]

### II.3. Réseaux de neurones artificiels

Les réseaux de neurones artificiels ou réseaux connexionnistes sont fondés sur des modèles qui tentent de modéliser les neurones biologiques et leurs interconnexions. Le but, d'un point de vue global, est d'exécuter des calculs complexes et de trouver par apprentissage une relation non linéaire entre des données numériques et les paramètres.

Les réseaux de neurones fonctionnent en répartissant les valeurs des variables dans les neurones. Ces unités sont chargées de combiner entre elles leurs informations pour déterminer la valeur du paramètre de discrimination.

Chaque neurone reçoit des informations numériques en provenance de neurones voisins, à chacune de ces valeurs est associé un poids représentatif de la force de la connexion. Chaque neurone effectue localement un calcul dont le résultat est transmis ensuite aux neurones avals. [46]

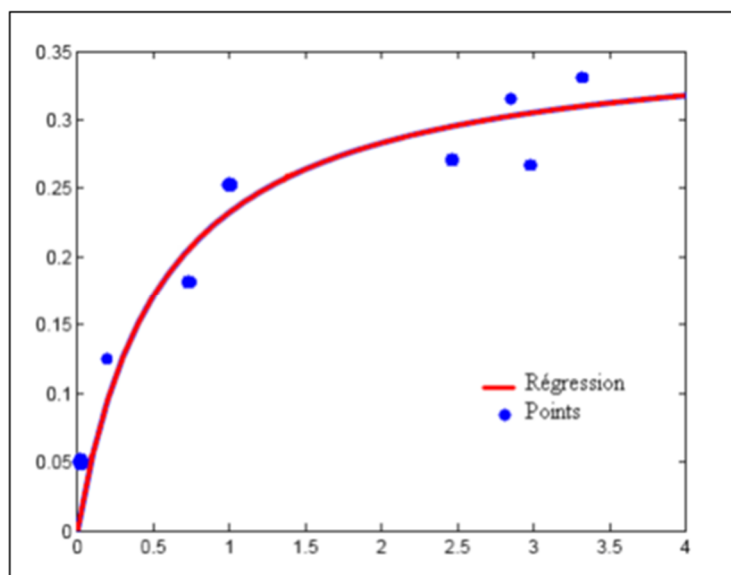
#### II.3.1. Réseaux de neurones pour la régression non-linéaire

##### II.3.1.1. La régression non linéaire

La technique des réseaux de neurones apparaît comme une méthode puissante de régression non linéaire, ce n'est donc rien d'autre qu'une extension des méthodes de régression linéaire proposées par tous les logiciels qui permettent de faire de la modélisation de données.[47]

La régression non linéaire est une des méthodes classiques de la statistique largement utilisée dans le traitement des données. Son objectif principal est d'aider à la détermination d'une fonction univoque permettant de relier deux variables distinctes pour lesquels on fait l'hypothèse qu'il existe une relation de dépendance fonctionnelle. On se référera au livre de Bates [70] pour plus de détails.

Considérons une grandeur mesurable  $yp$ , dépendant d'un ensemble de facteurs mesurés qui constituent les composantes d'un vecteur  $x$ . On considère les résultats des mesures  $yp$  comme des réalisations d'une variable aléatoire  $Y$ , et les valeurs des grandeurs d'entrée comme des réalisations d'un vecteur aléatoire  $X$ . On cherche donc à estimer l'espérance mathématique de la variable aléatoire  $Y$  pour une réalisation donnée  $x$  du vecteur aléatoire  $X$ , on la note  $EY(x)$ . Cette quantité est donc une fonction de  $x$ , elle est appelée fonction de régression de la variable aléatoire  $Y$ .



**Figure II.3 : Courbe de régression non linéaire pour des données.**

### II.3.1.2. Modèle non linéaire par rapport aux variables

La régression comprend de nombreuses techniques de modélisation et d'analyse de plusieurs variables, lorsque l'accent est mis sur la relation entre une variable dépendante et une ou plusieurs variables indépendantes (ou "prédicteurs"). Plus précisément :

Soit  $g(x,w)$  un modèle dont le vecteur des variable est  $x$  et le vecteur des paramètres est  $w$ . s'il existe un vecteur de paramètres  $w_p$  tel que le modèle soit identique à la fonction de régression  $EY(x)$  :  $g(x,w_p) \equiv EY(x)$ , on dit que la famille des fonctions  $g(x,w)$  contient la régression, ou encore le modèle  $g(x,w)$  est vrai. Si ce n'est pas le cas, on se contentera de

chercher un modèle aussi proche que possible de la fonction de régression  $EY(\mathbf{x})$ . Or, un réseau de neurone est un modèle non linéaire par rapport aux variables, et la recherche d'un modèle proche de la fonction  $EY(\mathbf{x})$  n'est que l'apprentissage. [48]

Notre intérêt pour la régression concerne les réseaux de neurones convolutifs (CNN) que nous allons discuter dans la section **II.9.3.7**.

### **II.3.2. Architecture des réseaux de neurones**

Un réseau de neurones est représenté par un graphe dont les nœuds sont les neurones et les arrêtes sont les connexions entre ceux-ci. Pour décrire l'architecture de réseau on emploie la matrice de poids de connexions  $W = [w_{ij}]$ , où  $w_{ij}$  dénote le poids de connexion du nœud  $j$  (ou de l'entrée  $j$ ) au nœud  $i$ . quand  $w_{ij}=0$ , il n'y a pas de connexion entre le nœud  $j$  et le nœud  $i$ . En général, les structures des réseaux sont divisées en deux grandes familles : les réseaux de neurone non bouclés et les réseaux de neurones bouclés. [49]

#### **II.3.2.1. Les réseaux de neurones non bouclés (réseau statique)**

Sont des réseaux à propagation vers l'avant (FNNs, feedforward neural networks). Le réseau est organisé en couche successive, l'information est ainsi transmise de manière unidirectionnelle du neurone  $j$  vers le neurone  $i$ . la connexion entre deux couches successive peut être totale ou partielle. Voici le rôle de chacune des couches dans un perceptron à trois couches:

- **La première couche** est appelée couche d'entrée. Elle recevra les données source que l'on veut utiliser pour l'analyse. Sa taille est donc directement déterminée par le nombre de variables d'entrées.
- **La deuxième couche** est la couche cachée. Dans cette couche, les fonctions d'activation sont en général non linéaires. Le choix de sa taille (nombre de neurones) n'est pas automatique et doit être ajusté. Il sera souvent préférable pour obtenir la taille optimale, d'essayer le plus de tailles possibles.
- **La troisième couche** est appelée couche de sortie. Elle donne le résultat obtenu après la compilation par le réseau des données entrée dans la première couche. Sa taille est directement déterminée par le nombre de variables dont on a besoin en sortie. Les réseaux de neurones non bouclés sont souvent appelés réseau statique et cela au fait que : le temps ne joue aucun rôle fonctionnel dans un réseau de neurones non bouclé si les entrées sont constantes, les sorties le sont également. Le temps nécessaire pour le calcul de fonction réalisée par chaque neurone est négligeable, et fonctionnellement, on peut considérer ce calcul comme instantané. [49,50]

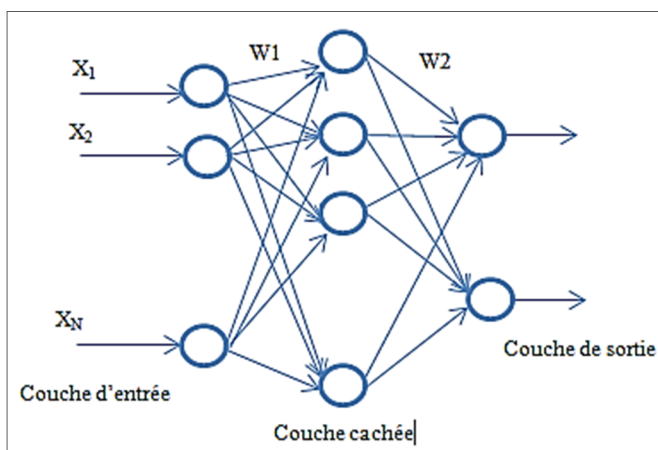


Figure II.4 : Réseaux de neurone non bouclé.

II.3.2.2. Les réseaux de neurones bouclés (réseau dynamique)

Le deuxième type de réseaux de neurones est les réseaux de neurones bouclés ou récurrents (RNNs, Recurrent Neural Networks), dont l'architecture est plus générale, le graphe des connexions est cyclique lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ. La fonction de neurone peut être d'elle-même ; pour cela, la notion de temps est explicitement prise en considération. Ainsi, à chaque connexion d'un réseau de neurones bouclé est attaché outre que le poids, un retard, multiple entier de l'unité de temps choisis.

Un réseau de neurones bouclé à temps discret réalise une (ou plusieurs) équations aux différences non linéaires, par composition des fonctions réalisées par chacun des neurones et des retards associés à chacune des connexions. [50]

RNNs sont une partie de réseaux de neurones pour le traitement de données séquentielles. Elles sont spécialisées pour traiter une séquence de valeurs tout comme CNN (Convolution neural network) qui peut facilement évoluer vers des images de grande largeur et hauteur [51] [52].


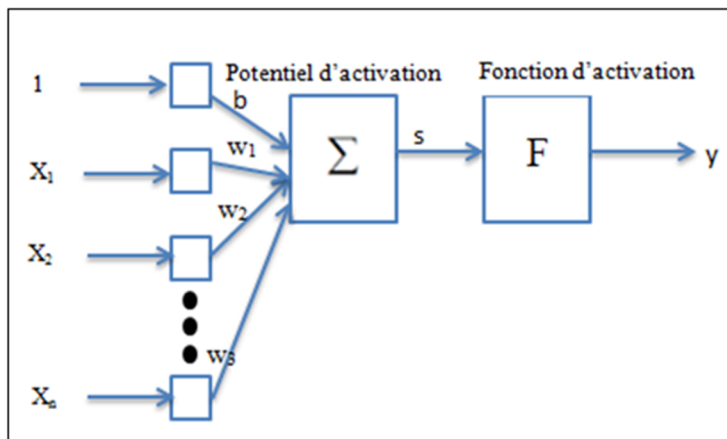


Figure II.5 : Exemple d'un réseau de neurones bouclé. Les nombre dans les carrés sont les retards (exprimés en nombre de périodes d'échantillonnage) associés à chaque connexion.

## II.4. Perceptron multicouches

### II.4.1. Le modèle du perceptron

Le perceptron est un neurone. Dans sa version la plus simple, le perceptron n'a qu'une seule sortie  $y$  à laquelle toutes les entrées  $x_i$  sont connectées (voir Figure suivante). [51]



**Figure II.6 :** Modèle d'un neurone formel.

La somme pondérée des entrées par les poids  $w_i$  associés aux entrées est appelée potentiel

$$P = \sum w_i x_i.$$

Ce potentiel est alors soumis à une fonction seuil de type Heaviside:

$$Y = \begin{cases} 0 & \text{si } s < 0 \\ 1 & \text{si } s \geq 0 \end{cases}$$

De nombreuses variantes ont été développées, notamment la version la plus couramment utilisée où les entrées et sorties sont des nombres flottants. Les valeurs de sortie -1 et 1 remplacent fréquemment la valeur 0 et 1. Une valeur particulière, appelée biais a également été introduite. Ce biais peut être vu comme une entrée  $X_0$  supplémentaire dont la valeur est toujours de 1. Celui-ci a notamment été introduit pour un ajustement automatique du seuil, ou encore afin de pouvoir classer facilement un vecteur d'entrée dont toutes les composantes seraient nulles. Le principal obstacle de ce modèle est la détermination des poids.

Pour pallier ce problème, l'algorithme de rétro propagation du gradient a été mis au point. Soient  $S_0$  et  $S_1$  deux sous-ensembles de RNA représentant les exemples négatifs et positifs de l'échantillon à apprendre.

L'algorithme consiste à présenter successivement les éléments de  $S_0$  et  $S_1$  et de mettre à jour les poids pour que la sortie se rapproche de la sortie désirée.

Cet algorithme repose sur le calcul du gradient de sortie puis sur la rétro propagation de celui-ci à travers la fonction de seuil puis des poids. La fonction d'activation de Heaviside est donc remplacée par des fonctions d'activation lui ressemblant et qui sont dérivables. Les principales fonctions d'activation  $\Phi$  sont : la fonction linéaire, la fonction sigmoïde et la fonction tangente hyperbolique. [53]

La propagation d'un vecteur d'entrée ( $\mathbf{X}_i$ ) à travers un perceptron s'écrit donc :

$$\mathbf{p} = \sum \mathbf{W}_i \mathbf{X}_i ; \mathbf{y} = \Phi(\mathbf{p}).$$

L'apprentissage classique d'un perceptron est la régression où la fonction de Coût est de la forme :

$$L = \frac{1}{2} \|\mathbf{o} - \mathbf{d}\|^2$$

Où  $\mathbf{o}$  est la sortie obtenue pour un échantillon et  $\mathbf{d}$  est la sortie désirée (ou label).

- Le gradient de l'erreur en sortie est donc exprimé par :  $\frac{\sigma L}{\sigma y} = \mathbf{o} - \mathbf{d}$
- Le gradient de l'erreur pour le potentiel est :

$$\frac{\sigma L}{\sigma p} = \frac{\sigma L}{\sigma y} \frac{\sigma y}{\sigma p} = \frac{\sigma L}{\sigma y} \Phi'(\mathbf{p}).$$

- Le gradient de l'erreur pour un poids  $\mathbf{W}_i$  est :

$$\frac{\sigma L}{\sigma x_i} = \frac{\sigma L}{\sigma y} \frac{\sigma p}{\sigma x_i} = \frac{\sigma L}{\sigma y} \mathbf{W}_i$$

#### II.4.2. Fonction d'activation


Dans la programmation de réseaux neuronaux, les fonctions d'activation établissent des limites pour la sortie des neurones. La fonction d'activation (ou fonction de seuillage, ou encore fonction de transfert) sert à introduire une non linéarité dans le fonctionnement du neurone. Les fonctions de seuillage présentent généralement trois intervalles:

- En dessous du seuil, le neurone est non actif (souvent dans ce cas, sa sortie vaut 0 ou -1).
- Aux alentours du seuil, une phase de transition
- Au-dessus du seuil, le neurone est actif (souvent dans ce cas, sa sortie vaut 1).

Les réseaux de neurones peuvent utiliser de nombreuses fonctions d'activation différentes. Nous aborderons les fonctions d'activation les plus courantes:

### II.4.3. Fonction d'activation linéaire

La fonction d'activation la plus élémentaire est la fonction linéaire car elle ne modifie pas du tout la sortie du neurone. L'équation  $y = \mathbf{W}\mathbf{x}$  montre comment le programme implémente généralement une fonction d'activation linéaire. Cette fonction d'activation renvoie simplement la valeur que les entrées de neurones lui ont transmise. La figure suivante illustre le graphique d'une fonction d'activation linéaire:[54]




**Figure II.7 :** Fonction d'activation linéaire.

Les réseaux de neurones pour la régression, ceux qui apprennent à fournir des valeurs numériques, utilisent généralement une fonction d'activation linéaire sur leur couche de sortie.

Les réseaux de neurones de classification, ceux qui déterminent une classe appropriée pour leur entrée, utilisent généralement une fonction d'activation softmax pour leur couche de sortie.

### II.4.4. Fonction d'activation sigmoïde

La fonction d'activation sigmoïde ou logistique  $\Phi(\mathbf{x}) = \frac{1}{1+e^{-x}}$  est un choix très courant pour les réseaux de neurones à action directe qui ne doivent produire que des nombres positifs.



**Figure II.8 :** Fonction d'activation sigmoïde.

Comme vous pouvez le constater sur le graphique ci-dessus, les valeurs supérieures ou inférieures à 0 sont compressées pour se situer dans une plage approximative comprise entre 0 et 1. [54]

#### II.4.5. Fonction d'activation de la tangente hyperbolique

La fonction de tangente hyperbolique est également une fonction d'activation très courante pour les réseaux de neurones qui doivent émettre des valeurs comprises entre -1 et 1.

Cette fonction d'activation est simplement la fonction de tangente hyperbolique ( $\tanh$ ), comme le montre l'équation :  $\Phi(x) = \tanh(x)$ .

Le graphique de la fonction tangente hyperbolique a une forme similaire à celle de la fonction d'activation sigmoïde. [54]

#### II.4.6. Unités linéaires rectifiées (ReLU)

L'unité linéaire rectifiée (ReLU) a été adoptée très rapidement au cours des dernières années. Avant la fonction d'activation ReLU, la tangente hyperbolique était généralement acceptée comme fonction d'activation de choix.

La plupart des recherches actuelles recommandent maintenant le ReLU en raison des résultats d'entraînement supérieurs. Par conséquent, la plupart des réseaux de neurones devraient utiliser le ReLU sur les couches cachées et softmax ou linéaire sur la couche de sortie. L'équation suivante montre la fonction très simple de ReLU:  $\Phi(x) = \max(0, x)$ .

Nous allons maintenant examiner pourquoi ReLU fonctionne généralement mieux que d'autres fonctions d'activation pour les couches masquées. Une partie des performances accrues est due au fait que la fonction d'activation ReLU est une fonction linéaire non saturante. Contrairement aux fonctions d'activation sigmoïde (logistique) ou à la tangente hyperbolique, le ReLU ne sature pas à -1, 0 ou 1. Une fonction d'activation saturante se déplace vers et atteint éventuellement une valeur. La fonction de tangente hyperbolique, par exemple, sature à -1 lorsque  $x$  diminue et à 1 lorsque  $x$  augmente. L'unité linéaire rectifiée (ReLU) est devenue la fonction d'activation standard des couches cachées d'un réseau neuronal profond. Outre les fonctions d'activation ReLU pour les couches cachées, les réseaux de neurones profonds utiliseront une fonction d'activation linéaire ou softmax pour la couche de sortie, selon que le réseau de neurones prend en charge la régression ou la classification. [54]



### II.4.7. Fonction d'activation Softmax

La fonction d'activation finale que nous examinerons est la fonction d'activation softmax. Cette dernière est utilisée sur un réseau de neurones de classification. Le neurone qui a la valeur la plus élevée revendique l'entrée en tant que membre de sa classe. Comme il s'agit d'une méthode préférable, la fonction d'activation de softmax force la sortie du réseau de neurones à représenter la probabilité que l'entrée tombe dans chacune des classes. Sans softmax, les sorties du neurone sont simplement des valeurs numériques, la plus haute indiquant la classe gagnante.

$$\Phi_i = \frac{e^{z_i}}{\sum_{j \in \text{group}} e^{z_j}}$$

Dans l'équation ci-dessus,  $i$  représente l'indice du neurone de sortie ( $o$ ) en cours de calcul et  $j$  représente les indices de tous les neurones du groupe (niveau). La variable  $z$  désigne la matrice de neurones de sortie. Il est important de noter que l'activation de softmax est calculée différemment des autres fonctions d'activation décrites dans ce chapitre.

Lorsque softmax est la fonction d'activation, la sortie d'un seul neurone dépend des autres neurones de sortie. [54]

### II.5. Le perceptron multicouche (PMC)


Les réseaux de neurones multicouches contiennent plus d'une couche de calcul. Le perceptron contient une couche d'entrée et une couche de sortie, dont la couche de sortie est la seule couche de calcul.

La couche d'entrée transmet les données à la couche de sortie et tous les calculs sont complètement visibles pour l'utilisateur. Les réseaux de neurones multicouches contiennent plusieurs couches de calcul; les couches intermédiaires supplémentaires (entre entrée et sortie) sont appelées couches masquées, car les calculs effectués ne sont pas visibles pour l'utilisateur.

L'architecture spécifique des réseaux de neurones multicouches s'appelle des réseaux à anticipation, car les couches successives se transmettent les unes aux autres dans le sens aller, d'entrée à sortie. L'architecture par défaut des réseaux à feed-forward part du principe que tous les nœuds d'une couche sont connectés à ceux de la couche suivante. Par conséquent, l'architecture du réseau de neurones est presque entièrement définie, une fois définis le nombre de couches et le nombre (type) de nœuds dans chaque couche.

Le seul détail restant est la fonction de perte optimisée dans la couche de sortie.

Il est extrêmement courant d'utiliser des sorties softmax avec une perte d'entropie croisée pour une prédiction discrète et des sorties linéaires avec une perte au carré pour une prédiction à valeur réelle. [53,54]



**Figure II.9 :** Réseaux PMC.

Les PMCs utilisent un algorithme de rétropropagation du gradient, l'objectif étant de minimiser l'erreur quadratique. La modification des poids est propagée de la couche de sortie jusqu'à la couche d'entrée.

### II.5.1. Entraînement du réseau de neurones avec une rétropropagation

Dans le réseau neuronal monocouche, le processus d'apprentissage est relativement simple, car l'erreur (ou la fonction de perte) peut être calculée directement en fonction des poids, ce qui facilite le calcul du gradient. Dans le cas des réseaux multicouches, le problème est que la perte est une fonction de composition compliquée des poids dans les couches précédentes. Le gradient d'une fonction de composition est calculé à l'aide de l'algorithme de rétropropagation. L'algorithme de rétropropagation exploite la règle de la chaîne du calcul différentiel, qui calcule les gradients d'erreur en termes de sommation des produits de gradients locaux sur les différents trajets allant d'un nœud à la sortie. Bien que cette somme ait un nombre exponentiel de composants (chemins), on peut la calculer efficacement en utilisant la programmation dynamique. [55]

L'algorithme de rétropropagation est une application directe de la programmation dynamique. Il contient deux phases principales, appelées phases avant et arrière, respectivement. La phase suivante est nécessaire pour calculer les valeurs de sortie et les dérivées locales au niveau de divers nœuds, et la phase précédente est nécessaire pour accumuler les produits de ces valeurs locales sur tous les chemins allant du nœud à la sortie:

- **phases avant (Propagation):** Dans cette phase, les entrées d'une instance de formation sont introduites dans le réseau de neurones. Il en résulte une séquence de calculs en aval sur les couches, en utilisant le jeu de pondérations actuel. La sortie prédite finale peut être comparée à celle de l'instance d'apprentissage et la dérivée de la fonction de perte par rapport à la sortie calculée. La dérivée de cette perte doit maintenant être calculée en tenant compte des poids dans toutes les couches de la phase .

- **Phases arrière (Rétro-propagation):** L'objectif principal de la phase arrière est d'apprendre le Gradient de la fonction de perte en fonction des différents poids en utilisant la règle de la chaîne du calcul différentiel. Ces gradients sont utilisés pour mettre à jour les poids. Etant donné que ces gradients sont appris dans la direction arrière, à partir du nœud de sortie, ce processus d'apprentissage est appelé phase arrière.(pour l'algorithme voir Annexe3)

### II.5.2. Algorithme de rétropropagation du gradient[56]

L'objectif de cet algorithme est de présenter au réseau un vecteur d'entrées, de procéder au calcul de la sortie par propagation à travers les couches, de la couche d'entrées vers la couche de sortie en passant par les couches intermédiaires. Une erreur est obtenue par comparaison entre la sortie trouvée et la sortie désirée.

A partir de cette erreur, le gradient de l'erreur est calculé lequel est à son tour propagé de la couche de sortie vers la couche d'entrée, d'où le terme de rétro-propagation. Cela permet la modification des poids du réseau et donc l'apprentissage. L'opération est recommencée pour chaque vecteur d'entrée et cela jusqu'à ce que le critère d'arrêt soit vérifié.

#### II.5.2.1. Algorithme d'apprentissage:

L'algorithme du rétropropagation du gradient de l'erreur passe par les étapes suivantes:

- Initialisation des poids  $[q]$  à des petites valeurs aléatoires.
- Présentation d'une entrée  $\mathbf{X}_k$  et de la sortie désirée  $\mathbf{d}_k$ .
- Calcul de la sortie actuelle par propagation à travers les couches :

$[q] = (\sum W_{ij} [q].y_i [q-1])$  où  $\mathbf{F}$  est la fonction de transfert du neurone et  $[q]$  la  $q$ ème couche du réseau.

- Accumulation des erreurs en sortie :=  $\sum (\mathbf{d}_k - [\mathbf{s}])^2$

Où :

$\mathbf{d}_k$  est la sortie désirée associée au vecteur d'entrée  $\mathbf{X}_k$ .

$[\mathbf{s}]$  est la sortie obtenue sur la dernière couche au temps t.

$\epsilon$  est l'erreur.

- Rétro-propagation du gradient de l'erreur ( $\delta$ ) depuis la dernière couche vers la première couche :

Pour chaque cellule de sortie :

$$\delta_i[s] = -(d_i - y_i[s]) \cdot F'(P_i[s]).$$

Pour chaque cellule cachée :

$$[q] = \sum [q+1]k \cdot w_{ki} \cdot F'(P_i[s]).$$

Mise à jour des poids selon la règle :

$$\Delta [q] = \alpha \cdot (\delta_i[q] \cdot x_i[q]).$$

Où : est le coefficient d'apprentissage compris dans l'intervalle [0,1].

Retour à l'étape 2 tant qu'il y a un nouveau couple.

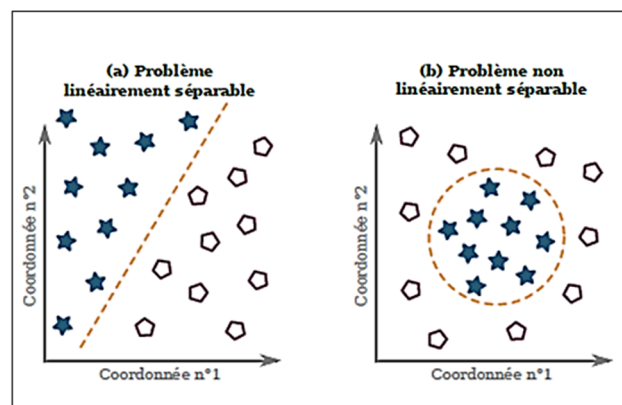
## II.6. Du perceptron à l'apprentissage profond

- **Le perceptron:**

Comme nous avons entamé dans le perceptron multicouche le perceptron est un neurone formel avec une règle d'apprentissage. Il s'agit d'un classifieur linéaire à une couche et une sortie (binaire également), permettant de séparer en deux classes les éléments présentés en entrée, au moyen d'un hyperplan dont l'orientation est définie par les poids synaptiques. Ces poids sont ajustés lors de l'apprentissage en cas d'erreur de prédiction.

- **Vers des réseaux à plusieurs couches:**

Si les perceptrons sont capables d'apprendre à classifier des problèmes linéairement séparables (figure suivante a), cette approche montre ses limites dans ce cas des problèmes non linéairement séparables (figure suivante b). Une solution possible à cette limitation est d'associer des couches successives, ce qui permet de délimiter l'espace des classes de façon plus complexe qu'avec un unique hyperplan. Le cercle en pointillé de l'exemple (b) pourrait ainsi être approximé par une combinaison de droites.



**Figure II.10 :** Problèmes de classification à deux dimensions des classes.  
 (a) Exemple linéairement séparable (par exemple selon la droite en pointillé).  
 (b) Exemple non linéairement séparable.

- **Le défi de l'apprentissage à plusieurs couches:**

L'algorithme de rétropropagation du gradient présenté dans II.5.2 souffre néanmoins d'un inconvénient intrinsèque,

Connu sous le nom de « problème de l'affaiblissement du gradient ».

L'affaiblissement de la valeur numérique du gradient lors de la diffusion rétropropagation de ce dernier tend en effet à rendre particulièrement lent l'apprentissage des couches les plus éloignées de la sortie, c'est-à-dire les premières. Ceci est d'autant plus problématique que les couches initiales sont à priori celles qui extraient les caractéristiques (simples) de plus bas niveaux, sur lesquelles reposent les motifs de plus haut niveaux assemblés par les couches ultérieures. Jusqu'à il y a désormais une dizaine d'années, ce phénomène a empêché l'apparition de réseaux de neurones entièrement connectés comportant davantage que quelques couches.

- **Apprentissage initial non supervisé : vers des réseaux réellement profonds:**

Le problème de l'affaiblissement du gradient ne faisant que ralentir la convergence de l'apprentissage par rétropropagation de ce dernier, une solution naturelle est d'augmenter le nombre d'exemples étiquetés utilisés. La présentation d'une grande quantité d'exemples est également utile pour limiter le sur apprentissage et accroître les capacités de généralisation du réseau entraîné.

Les premières apparitions de l'apprentissage profond étaient entre 1943-1986 où ils ont proposé le modèle neuronal McCulloch-Pitts et découvert l'algorithme d'apprentissage de « backpropagation » pour les perceptrons multicouches. Des démonstrations d'apprentissage sur des réseaux de neurones artificiels véritablement profonds (c'est-à-dire comportant un grand nombre de couches intermédiaires) sont présentées à partir de 2006 dans la littérature, date à laquelle l'apprentissage profond a commencé de se présenter, puis en 2012 où il commence à percer de nombreuses applications tels que la traduction en langage naturel, maintenance prédictive ...etc [57], [58]. L'innovation est le recours à un apprentissage initial non supervisé et réalisé couche par couche, permettant de placer le réseau dans une position de départ plus favorable à l'apprentissage supervisé qui vient ensuite (par exemple par rétropropagation du gradient). L'intérêt pour les réseaux profonds s'en trouve relancé, l'accélération de l'apprentissage supervisé atténuant par ailleurs la nécessité de disposer d'une grande base d'exemples étiquetés, coûteuse à établir.

L'émergence spontanée de cartes de fonctions à l'issue de l'étape de « pré-entraînement » n'est pas sans rappeler celles du cortex visuel du chat [59] ou du singe [60] rapportées en biologie, qui apparaissent suite à l'observation répétée de certaines formes et orientations après la naissance.

Dans cette partie, nous allons nous appuyer sur ces fondements pour vous présenter les concepts de base des réseaux profonds. A présent que nous avons précisé comment fonctionnent les réseaux de neurones de manière générale, nous allons aborder le domaine de l'apprentissage profond (Deep Learning).

## II.7. Apprentissage profond

L'apprentissage profond est un sous-domaine spécifique de l'apprentissage automatique qui tente d'apprendre à plusieurs niveaux, correspondant à différents niveaux d'abstraction. Il utilise généralement des réseaux de neurones artificiels. Les niveaux de ces modèles statistiques appris correspondent à des niveaux distincts de concepts, où les concepts de niveau supérieur sont définis à partir des concepts de niveau inférieur, et les mêmes concepts de niveau inférieur peuvent aider à définir de nombreux concepts de niveau supérieur. L'apprentissage profond est basé sur les

« réseaux de neurones artificiels », ils sont composés de milliers d'unités (les neurones) qui effectuent chacune de petites opérations simples. Les résultats d'une première couche de neurones servent d'entrée aux calculs d'une deuxième couche et ainsi de suite.

Parmi les facettes qui différencient les réseaux d'apprentissage en profondeur des réseaux multicouches on cite les suivantes:

- Plus de neurones que les réseaux précédents.
- Manières plus complexes de connecter des couches.
- Explosion de la puissance de calcul pour s'entraîner.
- Extraction automatique des fonctionnalités.

Lorsque nous disons « plus de neurones », nous entendons que le nombre de neurones a augmenté au fil des années pour exprimer des modèles plus complexes. Les couches ont également évolué, chaque couche étant entièrement connectée dans des réseaux multicouches à des patches de neurones connectés localement entre des couches dans des réseaux de neurones convolutifs (CNN) et des connexions récurrentes au même neurone dans des réseaux de neurones récurrents (en plus des connexions de la couche précédente).

Plus de connexions signifie que nos réseaux ont plus de paramètres à optimiser, ce qui a nécessité l'explosion de la puissance de calcul qui s'est produite au cours des 20 dernières années. Toutes ces avancées ont été à la base de la création de réseaux de neurones de

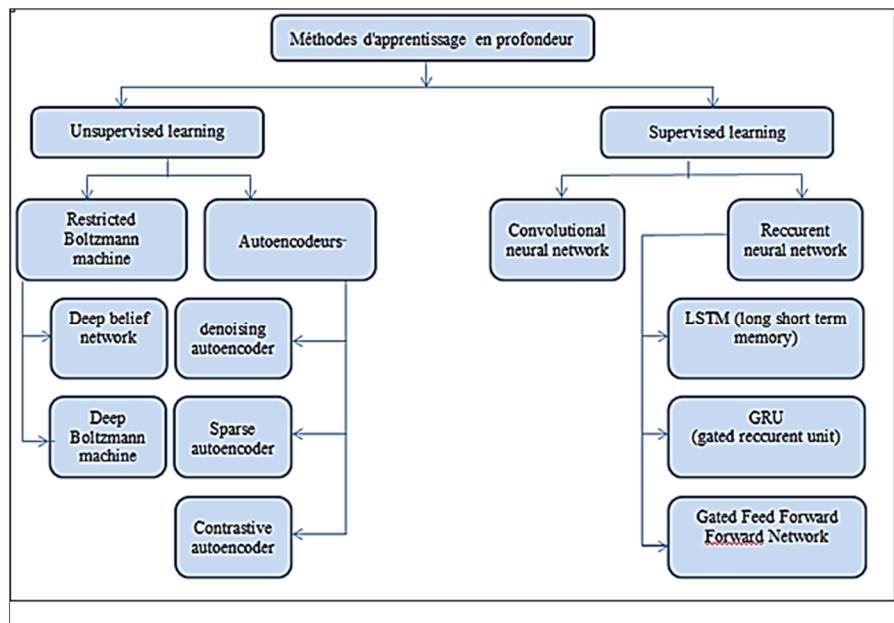
nouvelle génération capables d'extraire des fonctionnalités de manière plus intelligente. Cela a permis aux réseaux profonds de modéliser des problèmes plus complexes que précédemment possible. Alors que les demandes de l'industrie changent et atteignent de plus en plus, les capacités des réseaux de neurones ont dû évoluer. [61, 62,63].

L'apprentissage en profondeur a joué un rôle très important dans le domaine de la vision par ordinateur au cours des dernières années. De nombreuses méthodes ont été proposées pour des tâches difficiles, telles que la classification d'images ou la détection d'objets [64].

Des résultats de pointe dans ces tâches dont été obtenus avec l'utilisation de réseaux de neurones convolutifs (ConvNets) dont nous allons parler plus tard, formés pour minimiser une fonction de perte sur la sortie d'une couche softmax. Nous nous concentrons sur les problèmes de régression en utilisant des approches d'apprentissage en profondeur afin de réaliser ces tâches de reconnaissance élémentaires requises. [64]

**II.7.1. Architectures majeures de réseaux profonds [63]**

Il existe un grand nombre de variantes d'architectures profondes. La plupart d'entre elles sont dérivées de certaines architectures parentales originales. Il n'est pas toujours possible de comparer les performances de toutes les architectures, car elles ne sont pas toutes évaluées sur les mêmes ensembles de données. Dans a figure suivante nous avons introduit la taxonomie qui englobe les différentes architectures des algorithmes d'apprentissage en profondeur:



**Figure II.11 :** Taxonomie de l'architecture de l'apprentissage profond.


Le but de cette taxonomie est de fournir une revue et une base sur différentes architectures d'apprentissage profond, comme la figure nous illustre il y a 4 architectures largement utilisées dans l'apprentissage en profondeur

- Réseaux de neurones récurrents.
- Auto-encodeurs.
- Machines boltzmann restreintes.
- Réseaux de neurones convolutifs (CNN).

Nous allons procéder à chacune des architectures représentées sur la taxonomie.

### II.7.1.1. Auto-encodeurs [63]

Nous utilisons des auto-encodeurs pour apprendre les représentations compressées des jeux de données. Nous les utilisons généralement pour réduire la dimensionnalité d'un jeu de données. La sortie du réseau auto-codeur est une reconstruction des données d'entrée sous la forme la plus efficace. Les Autoencoders partagent une forte ressemblance avec les réseaux de neurones de perceptrons multicouches en ce sens qu'ils ont une couche d'entrée, des couches cachées de neurones, puis une couche de sortie. La différence essentielle à noter entre un diagramme de réseau multicouche de perceptron et un diagramme de codage automatique est la couche de sortie dans un codeur automatique a le même nombre d'unités que la couche d'entrée.(



**FigureI.12: Architecture des réseaux Autoencodeur.**

Diverses techniques existent pour empêcher les auto-encodeurs d'apprendre la fonction d'identité et pour améliorer leur capacité à capturer des informations importantes et à acquérir des représentations plus riches:

- L'Autoencoder débruiteur (Denoising).
- L'Autoencoder épars (Sparse Autoencoder).



- Les Autoencodeurs Contractifs (Contractive Autoencoders)

### II.7.1.2. Machines Boltzmann restreintes

Les machines Boltzmann restreintes (RBM) sont un type de réseau neuronal utilisé pour apprendre les entités à partir d'ensembles de données de manière non supervisée, en mappant les données d'entrée à un état caché, puis en tentant de reconstruire l'entrée à partir de l'état caché. À cet égard, ils ressemblent à d'autres modèles d'entraînement non supervisé, tels que les autoencodeurs (débruitage, compression et variantes variationnelles), bien que la procédure d'entraînement pour les RBM (divergence contrastive) soit assez différente de celle des autoencodeurs. (Voir Annexe 2)

Comme la taxonomie montre, voici les architectures spécifiques à ce type :

- Réseaux de croyances profondes (pour l'algorithme voir Annexe 1)
- Machine de Boltzmann profonde

### II.7.1.3. Réseaux de neurones récurrents.

Ce type de modèle s'est avéré extrêmement performant pour les données temporelles. Pour des illustrations plus détaillées sur les réseaux de neurones récurrents (voir section II.3.2.2).

Il a plusieurs architectures correspondantes à ce modèle, y compris :

- Longue Mémoire A Court Terme (LSTM).
- Les unités récurrentes gated (GRU).
- Les réseaux de neurones feedforward gated.

### II.7.2.4. Réseaux de neurones convolutifs (CNN)

Le réseau de neurones convolutifs (en anglais CNN ou ConvNet pour Convolutional Neural Networks) est un type de réseau de neurones artificiels acycliques [63]. Les CNN sont un sous-type de l'architecture profonde discriminante et ont montré des performances satisfaisantes dans le traitement en deux dimensions données avec topologie en forme de grille. L'architecture de CNN est inspirée de l'organisation du cortex visuel animal. Dans les années 1960, Hubel et Wisel ont proposé un concept appelé champs réceptifs. Ils ont constaté que les agencements complexes de cellules étaient contenus dans le cortex visuel de l'animal chargé de la détection de la lumière dans des sous-régions chevauchantes et petites du champ visuel. [21] ils sont très similaires à un réseau de neurones du type perceptron multicouche de ceux que nous avons évoqué précédemment. [63]

Il convient de noter que les CNN constituent la première architecture d'apprentissage en profondeur véritablement réussie en raison de la formation réussie des couches hiérarchiques. La topologie CNN exploite les relations spatiales afin de réduire le nombre de

paramètres dans le réseau. Les performances sont donc améliorées à l'aide des algorithmes standard de rétropropagation. Un autre avantage du modèle CNN est qu'il nécessite un minimum de prétraitement.[21]

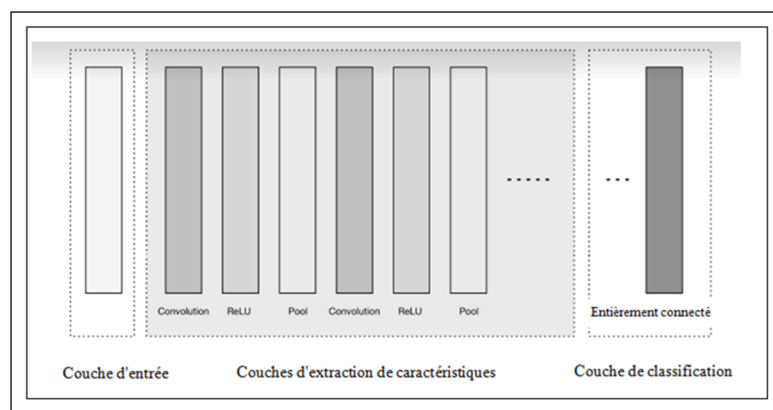
Avec le développement rapide des techniques de calcul, les techniques de calcul accélérées par GPU ont été exploitées pour former les CNN plus efficacement. On note que le terme "convolutional" vient de l'opération de convolution. La convolution a remplacé la multiplication de matrice générale dans les RNs standard. De cette manière, le nombre de poids est réduit, réduisant ainsi la complexité du réseau, évitant ainsi la procédure d'extraction de caractéristiques dans les algorithmes d'apprentissage standard.[21] Ainsi

L'idée de base du partage de paramètres est qu'au lieu d'apprendre un ensemble séparé de paramètres à chaque emplacement, nous n'avons besoin d'en apprendre qu'un seul ensemble, ce qui implique une meilleure performance du CNN. Le partage de paramètres a également doté le CNN d'une propriété attrayante appelée équivariance, ce qui signifie que chaque fois que l'entrée change, la sortie change de la même manière. Par conséquent, moins de paramètres sont nécessaires pour CNN par rapport aux autres algorithmes NN traditionnels, ce qui entraîne une réduction de la mémoire et une amélioration de l'efficacité. [21]

Dans les convNet, 2 nouveaux types de couche ont été ajoutés dans le réseau : la couche convolution (convolutional layer) et la couche de mise en commun (pool layer). Nous les décrivons dans les parties suivantes.(Voir Annexe 4)

#### **II.7.2.4.1. Aperçu du CNN**

Les CNN transforment les données d'entrée de la couche d'entrée à travers toutes les couches connectées en un ensemble de scores de classe donnés par la couche de sortie. Il existe de nombreuses variantes de l'architecture CNN, mais elles sont basées sur le motif des couches, comme illustré à la figure suivante:[63]



**Figure II.13** : Architecture générale de haut niveau de CNN.

La figure ci-dessus décrit trois groupes principaux:

- Couche d'entrée.
- Couches d'extraction de fonctionnalités (apprentissage).
- couches de classification/Régression.

La couche d'entrée accepte une entrée. Les couches d'extraction de caractéristiques ont un motif répété de la séquence, enfin, nous avons les couches de classification/régression, dans lesquelles nous avons une ou plusieurs couches entièrement connectées pour prendre les entités d'ordre supérieur et produire des probabilités de classe ou des scores. Ces couches sont entièrement connectées à tous les neurones de la couche précédente.

Concernant les autres couches d'extraction de fonctionnalités nous les expliquerons leurs rôles ultérieurement dans La structure de base d'un réseau convolutif.

#### II.7.2.4.2. Evolution des connexions entre les couches

Un autre changement concerne la manière de la connexion des couches dans une architecture convolutif. Les neurones d'une couche ne sont connectés qu'à une petite région de neurones de la couche la précédant. Les CNN conservent une architecture orientée couche, comme dans les réseaux multicouches traditionnels, mais ont différents types de couches. Chaque couche transforme le volume d'entrée de la couche précédente en un volume de sortie d'activations de neurones avec une fonction différentiable qui peut ou non avoir des paramètres. [63]

#### II.7.2.4.3. La structure de base d'un réseau convolutif

Dans les réseaux de neurones à convolution, les états de chaque couche sont disposés selon une structure de grille spatiale. Ces relations spatiales sont héritées d'une couche à

l'autre car chaque valeur d'entité est basée sur une petite région spatiale locale de la couche précédente.


Il est important de maintenir ces relations spatiales entre les cellules de la grille, car l'opération de convolution et la transformation vers la couche suivante dépendent de manière critique de ces relations.

La profondeur d'une couche dans un réseau de neurones de convolution ne doit pas être confondue avec la profondeur du réseau lui-même. L'utilisation du mot «profondeur» pour désigner à la fois le nombre de cartes de caractéristiques dans chaque couche ainsi que le nombre de couches est une surcharge regrettable de la terminologie utilisée dans les réseaux convolutifs, mais nous ferons preuve de prudence lorsque nous utiliserons ce terme. cela ressort clairement de son contexte. [65]

Le réseau de neurones à convolution fonctionne un peu comme un réseau de neurones à feed-forward traditionnel, à la différence que les opérations dans ses couches sont organisées dans l'espace avec des connexions rares entre les couches. Les trois types de couches couramment présents dans un réseau de neurones de convolution sont la convolution, le pooling et le ReLU. L'activation ReLU n'est pas différente d'un réseau de neurones traditionnel. En outre, un ensemble final de couches est souvent entièrement connecté et mappé de manière spécifique à l'application sur un ensemble de nœuds de sortie. [65]

#### II.7.2.4.4. Couche convolutive (RELU layer)

Les couches convolutives sont considérées comme les blocs de construction de base des architectures CNN. Comme l'illustre la figure suivante, les couches convolutives transforment les données d'entrée en utilisant un patch de neurones se connectant localement à partir de la couche précédente. La couche calculera un produit scalaire entre la région des neurones de la couche d'entrée et les poids auxquels ils sont connectés localement dans la couche de sortie. [63]



**Figure II.14 :** Couche de convolution avec volumes d'entrée et de sortie.

Examinons de plus près un concept clé de ces couches, appelé convolution.

- **Convolution:**

Une convolution est définie comme une opération mathématique décrivant une règle permettant de fusionner deux ensembles d'informations, en mathématiques le produit de convolution est un opérateur bilinéaire commutatif, généralement noté « \* », qui, à deux fonctions  $f$  et  $g$  sur un même domaine infini, fait correspondre une autre fonction «  $f * g$  » sur ce domaine, qui en tout point de celui-ci est égale à l'intégrale sur l'entière du domaine, d'une des deux fonctions autour de ce point, pondérée par l'autre fonction autour de l'origine les deux fonctions étant parcourues en sens contraire l'une de l'autre (nécessaire pour garantir la commutativité).[66]

Le produit de convolution de deux fonctions réelles ou complexes  $f$  et  $g$ , est une autre fonction, qui se note généralement «  $f * g$  » et qui est définie par :

$$(f * g)(x) = \int_{-\infty}^{+\infty} f(x-t)g(t) dt = \int_{-\infty}^{+\infty} f(t)g(x-t) dt$$

- **Rembourrage(Padding):**

Une observation est que l'opération de convolution réduit la taille de la (q 1) ème couche par rapport à la taille de la qème couche. Ce type de réduction de taille n'est généralement pas souhaitable, car il a tendance à perdre certaines informations sur les entrées.

Ce problème peut être résolu en utilisant un remplissage. En un sens, le remplissage consiste à autoriser l'opération de convolution avec une partie du filtre «dépassant» des bords du calque, puis en produisant le produit scalaire uniquement sur la partie du calque où les valeurs sont définies. Ce type de remplissage est appelé demi-remplissage car (presque) la moitié du filtre dépasse de tous les côtés de l'entrée spatiale dans le cas où le filtre est placé dans sa position spatiale extrême le long des bords. Le demi-rembourrage est conçu pour maintenir exactement l'empreinte spatiale. [65]

Lorsque le remplissage n'est pas utilisé, le «remplissage» résultant est également appelé un remplissage valide.

Un remplissage valide ne fonctionne généralement pas bien d'un point de vue expérimental. L'utilisation d'un demi-remplissage garantit que certaines des informations critiques aux limites de la couche sont représentées de manière autonome. Dans le cas d'un remplissage correct, les contributions des pixels sur les bords du calque seront sous-représentées par rapport aux pixels centraux du calque masqué suivant, ce qui n'est pas souhaitable. De plus, cette sous-représentation sera composée de plusieurs couches. Par conséquent, le remplissage est généralement effectué dans toutes les couches, et pas

seulement dans la première couche où les emplacements spatiaux correspondent aux valeurs d'entrée.

- **Utilisation de biais**

Comme dans tous les réseaux de neurones, il est également possible d'ajouter des biais aux opérations en aval. Chaque filtre unique dans une couche est associé à son propre biais. Par conséquent, le filtre  $P$  dans la quatrième couche a une polarisation  $b(p, q)$ . Lorsqu'une convolution est effectuée avec le filtre  $P$  dans la quatrième couche,

La valeur de  $b(p, q)$  est ajoutée au produit scalaire. L'utilisation du biais augmente simplement le nombre de paramètres dans chaque filtre de 1, ce qui ne représente donc pas une surcharge significative. Comme tous les autres paramètres, le biais est appris lors de la propagation arrière. [60]

On peut traiter le biais comme le poids d'une connexion dont l'entrée est toujours définie sur  $+1$ . Cette entrée spéciale est utilisée dans toutes les convolutions, indépendamment de la localisation spatiale de la convolution. Par conséquent, le nombre d'entités en entrée dans la quatrième couche est  $1 + L_q \times B_q \times d_q$ .

Il s'agit d'une astuce d'ingénierie de fonctionnalités standard utilisée pour gérer les biais dans toutes les formes d'apprentissage automatique.[60]

L'activation du ReLU n'est pas très différente de la façon dont elle est appliquée dans un réseau de neurones traditionnel. Pour chacune des valeurs  $L_q \times B_q \times d_q$  d'une couche, la fonction d'activation ReLU lui est appliquée pour créer  $L_q \times B_q \times d_q$  valeurs seuillées. Ces valeurs sont ensuite transmises à la couche suivante.

Par conséquent, l'application de ReLU ne modifie pas les dimensions d'une couche, car il s'agit d'un simple mappage univoque des valeurs d'activation. [65]

Dans les réseaux de neurones traditionnels, la fonction d'activation est combinée à une transformation linéaire avec une matrice de pondérations afin de créer la couche d'activation suivante. De même, une ReLU suit généralement une opération de convolution (qui est à peu près l'équivalent de la transformation linéaire dans les réseaux de neurones traditionnels) et la couche ReLU n'est souvent pas explicitement illustrée dans les illustrations illustrées des architectures de réseau de neurones à convolution, Il est à noter que l'utilisation de la fonction d'activation ReLU est une évolution récente de la conception du réseau de neurones. L'augmentation de la vitesse est également liée à la précision, car elle permet d'utiliser des modèles plus profonds et de les entraîner plus longtemps. Ces dernières années, l'utilisation de la fonction d'activation ReLU a remplacé les autres fonctions d'activation dans la conception d'un réseau de neurones à convolution. [65]

#### II.7.2.4.5. La couche ( Pooling )

Les couches de regroupement sont généralement insérées entre des couches de convolution successives. Les couches de regroupement réduisent progressivement la représentation des données sur le réseau et aident à contrôler le surajustement. La couche de regroupement fonctionne indépendamment sur chaque tranche de profondeur de l'entrée. Elle utilise l'opération max () pour redimensionner les données d'entrée dans l'espace, cette opération est appelée Pooling maximum.

Les couches de regroupement utilisent des filtres pour effectuer le processus de sous-échantillonnage sur le volume d'entrée. Les couches de regroupement n'ont pas de paramètres pour la couche, mais des hyperparamètres supplémentaires. Cette couche n'implique pas de paramètres, car elle calcule une fonction fixe du volume d'entrée. [63]

#### II.7.2.4.6. Couches Entièrement Connectées:

Chaque entité de la couche spatiale finale est connectée à chaque état masqué de la première couche entièrement connectée. Cette couche fonctionne exactement de la même manière qu'un réseau PMC ( voir paragraphe II.5)

. Dans la plupart des cas, on peut utiliser plusieurs couches entièrement connectées pour augmenter la puissance des calculs vers la fin. Les connexions entre ces couches sont structurées exactement comme un réseau à feed-forward traditionnel. Etant donné que les couches entièrement connectées sont entièrement connectées. [65]

La couche de sortie d'un réseau de neurones à convolution est conçue de manière spécifique à l'application, on peut utiliser l'activation logistique, softmax ou linéaire en fonction de la nature de l'application (par exemple, classification ou régression). [63]

#### II.7.2.7.7. CNN pour la régression

Les techniques de régression sont largement utilisées pour résoudre des tâches dont l'objectif est de prédire des valeurs continues.

En vision par ordinateur, les techniques de régression couvrent un large ensemble de scénarios applicatifs, tels que: estimation de la position de la tête [67], détection des repères faciaux [68], estimation de l'âge ou estimation de l'enregistrement des images. [69].

Au cours de la dernière décennie, les architectures d'apprentissage en profondeur ont largement dépassé l'état de la technique dans de nombreuses questions de vision informatique traditionnelles telles que la classification des images ou la détection d'objets, et ont également été appliquées à de nouvelles tâches telles que l'analyse de la viralité des images. En gros, ces architectures se composent de plusieurs couches convolutives,

généralement suivies de quelques couches entièrement connectées, et d'une couche de classification softmax avec, par exemple, une perte d'entropie croisée; l'architecture globale est appelée réseau de neurones à convolution (ConvNet). Outre la classification, les ConvNets sont également utilisés pour résoudre des problèmes de régression. Dans ce cas, la couche softmax est généralement remplacée par une couche de régression entièrement connectée avec des activations linéaires ou sigmoïdes. [64]

**II.8. Conclusion**

Dans ce chapitre nous avons introduit la technique révolutionnaire de l'apprentissage profond ainsi que ses architectures et méthodes. Nous avons entamé l'étude conceptuelle de l'architecture des réseaux de neurones convolutifs qu'on a utilisés et ses différentes étapes plus de son utilité dans la régression.



## Chapitre III Implémentation.

### III.1.Introduction:

Nous allons entamer dans ce chapitre la partie réalisation et implémentation de notre solution. Nous commençons tout d'abord, par présenter les logiciels et les bibliothèques externes utilisés. Ensuite nous décrivons l'architecteur du modèle de l'apprentissage profond (réseaux de neurones convolutionnel) que nous avons utilisé pour prédire les courbes de traction.

Notre travail a pour but de faire la caractérisation et la prédiction et la simulation du comportement des films PEBD multicouches au vieillissement mécanique avec l'apprentissage profond(CNN).

Avant de présenter notre implémentation, nous allons présenter les outils nécessaires utilisés.

### III.2. Les choix techniques :

Afin de mener à bien notre projet nous avons utilisé comme outils de développement l'IDE Pycharm pour développer notre application avec le langage python.

#### III.2.1. Python:

Pour développer notre application, nous avons opté pour le langage de programmation Python v3.6.4. 64-bit. Python est un interpréteur, orienté objet, langage de programmation de haut niveau avec un sémantique dynamique. Est un langage simple, facile à apprendre et permet une bonne réduction du cout de la maintenance des codes, Les bibliothèques (packages) python encouragent la modularité et la réutilisabilité des codes. Contrairement à de nombreux autres langages, il n'utilise pas les accolades pour délimiter les blocs, et les points-virgules après sont facultatifs. Il a moins d'exceptions syntaxiques et de cas spéciaux que C ou Pascal.[72]



Figure III.1 : Logo Python.

### III.2.2.. Anaconda:

Anaconda est une distribution gratuite et à source ouverte des langages de programmation Python et R pour l'informatique scientifique (informatique des données, applications d'apprentissage automatique et d'apprentissage en profondeur avec scikit-learn, TensorFlow et Theano, traitement de données à grande échelle et performance avec Dask, NumPy, pandas et Numba., analyse prédictive, etc.), qui vise à simplifier la gestion et le déploiement de packages. Les versions de paquet sont gérées par le système de gestion de paquet conda. La distribution Anaconda 1400 packages de données informatiques populaires adaptés à Windows, Linux et MacOS .[73]



**Figure III.2 :Logo Anaconda.**

### III.2.3.Pycharm:

Est un environnement de développement intégré (IDE) utilisé en programmation informatique, spécialement pour le langage Python. Il fournit une analyse de code, un débogueur graphique, un testeur unitaire intégré, et prend en charge le développement Web avec Django ainsi que Data Science avec Anaconda. PyCharm est multi-plateforme, avec les versions Windows, macOS et Linux. Community Edition est distribué sous la licence Apache.[74]



**Figure III.3 : Logo Pycharm.**

Dans les prochaines sections nous allons présenter les bibliothèques et les principaux outils utilisés dans ce développement.

### III.2.4. Bibliothèques Supplémentaires

Afin d'atteindre les objectifs de ce projet, nous avons utilisé d'autres bibliothèques externes pour effectuer certaines tâches spécifiques. Dans cette partie, nous allons présenter les principales bibliothèques utilisées. en plus de celles fournies par la bibliothèque standard de Python.

- **Scikit-Learn**

Scikit-learn [75] est une bibliothèque libre open-source pour Python dédiée à l'apprentissage automatique, cet outil est simple et efficace pour l'exploration de données (Data Mining) et l'analyse de données (Data Analysis). Elle comporte notamment divers algorithmes de classification, de régression et de clustering , y compris les machines à vecteurs de support (SVM :support vector machines), random decision forests classifier, gradient boosting classifier, k-means etc. . . . et plusieurs d'autres fonctions utiles pour l'analyse et le prétraitement de données. Cette Bibliothèque est conçue pour s'harmoniser avec les bibliothèques numériques et scientifiques de Python à savoir NumPy et SciPy.

Nous avons utilisé pour diviser l'ensemble de données en deux parties, une dédiée à l'apprentissage et l'autre aux tests.

- **Python DeepLearning Library Keras**

Keras [76] est une API de réseaux de neurones de haut niveau, écrite en Python et capable de fonctionner sur un backend TensorFlow pour simplifier le processus de construction d'applications d'apprentissage profonds. il est Conçu pour permettre une expérimentation facile et rapide avec des réseaux neurones profonds, il se concentre sur la modularité , l'extensibilité et une conception conviviale des applications. Keras offre des API simples et cohérentes, et minimise le nombre d'actions de l'utilisateur nécessaires pour les cas d'utilisation commune, et il fournit un retour d'information clair et pratique sur les erreurs de l'utilisateur. Il a été développé dans le cadre du projet ONEIROS(Open-ended Neuro-Electronic Intelligent Robot Operating System) à Google.[77]

Nous avons utilisé Keras pour créer le réseau de neurones convolutifs, et entraîner ce modèle sur un environnement ayant un support CPU.

- **Bibliothèque PyQt**

PyQt5 [78] est un module libre qui permet de faire le lien le langage Python avec la bibliothèque Qt [79] distribué sous deux licences, une licence libre open-source[80] et une autre commerciale selon le besoin. Il permet ainsi de créer des interfaces graphiques en Python. Nous avons utilisé ce module pour créer l'interface graphique GUI (Graphical User Interface) pour notre application.

Un certain nombre de données est nécessaire pour développer un modèle de réseaux de neurone convolutionnel performant, incluant son architecture (Nombre de couche CNN, de regroupement, le nombre de neurones des couche à connexion totale ), les fonctions d'apprentissage, l'algorithme d'apprentissage et les autres paramètres du réseau.

Le processus de mise au point du réseau de neurones convolutionnel comporte les quatre étapes suivantes :

- a. préparation de données : analyse et traitement de données.
- b. Apprentissage du réseau : ceci inclut le choix de l'architecture, les fonctions d'apprentissage et les paramètres du réseau.
- c. Test du réseau entraîné, pour évaluer les performances du réseau.
- d. Utilisation du réseau entraîné pour la simulation et la prédiction. Les entrées du système sont la déformation et le temps, et la sortie du système est la contrainte. Des essais expérimentaux ont été menés pour déterminer les propriétés de traction d'un film Agro-film vieillie durant sept mois à  $10^{\circ}\text{C}$  à 120heures-550 heures -1010 heures-2040heures-4000 heures.

### III.3. Source Expérimentale de la base des données

#### III.3. 1. Les matériaux étudiés

Ce film, est composé de trois couches de polyéthylène (PE. Les différents additifs du film sont des anti condensations, anti UV, anti parasites, antivirus, anti poussières, anti gouttes, etc. La nature exacte des additifs n'est pas fournie par la société. Lors de l'extrusion, il est formé un film d'une épaisseur de 180  $\mu\text{m}$ . Ce film est étudié, lorsque celui-ci est vierge, après avoir subit des vieillissements artificiels durant 7 mois à Température  $10^{\circ}\text{C}$ , Des précautions ont été également prises pour éviter un étirement du film pouvant modifier certaines de ses propriétés mécaniques et/ou optiques et lui assurer une bonne fixation. Ce dernier point est particulièrement important ; une mauvaise fixation étant la cause la plus fréquente des déchirures. La déchirure des films plastiques en général constitue l'une de leur principale faiblesse. En effet, après qu'une entaille, souvent accidentelle, ait été faite, la déchirure se propage lentement sous l'action de forces très faibles.[81]

- **Polyéthylène vierge**

Le matériau utilisé est un film fourni par la société AGROFILM à l'industrie de Sétif (Multinational).

- **Polyéthylène vieillie**


Des échantillons de polyéthylène basse densité et vieillie à  $10^{\circ}\text{C}$ . [81]

### III.3. 2.L'essai de traction

L'essai de traction uni axiale est un essai « simple » à mettre en oeuvre. Il consiste à soumettre une éprouvette du matériau à étudier à une traction et à mesurer l'allongement  $\Delta l$  correspondant à une force  $F$  appliquée. En raison de son dépouillement simple, il permet d'établir des lois de comportement fiables. En outre, il présente une reproductibilité remarquable [82], [83].

### III.3. 3. Préparation des éprouvettes

Les essais de traction uni axiale sont réalisés sur des éprouvettes découpées directement à partir des films à l'aide d'un emporte-pièce de dimensions normalisées (éprouvette du type 1 de la norme ISO/R 527). La photo de l'emporte-pièce ainsi que les dimensions de l'éprouvette sont représentées dans la **Figure III.5**. Même si les éprouvettes ainsi obtenues ne sont pas normalisées, l'objectif recherché est la compréhension de l'effet du vieillissement sur le polymère. Après la découpe, les éprouvettes provenant de film de polyéthylène vierge sont mises au vieillissement physique pendant 4000h à  $T=10^{\circ}\text{C}$ . [81]



**Figure III.4 : Géométrie de l'emporte-pièce et dimensions de l'éprouvette. [41]**

### III.3. 4.Mise en place de l'essai de traction

Suite à l'étape de vieillissement, l'éprouvette est essuyée et séchée. Elle est ensuite fixée à ses deux extrémités par des mors. L'un de ces mors, mobile, est relié pour la mesure des efforts, à un système dynamométrique par une rotule, de telle sorte que l'axe des efforts appliqués soit confondu vitesse de déplacement contrôlable. L'autre mors, fixe, est lié au bâti de la machine de traction de type INSTRON 4240 pilotée par un ordinateur (voir **Figure III.5**). Pour chaque échantillon, nous avons le phénomène de striction qui se produit dans de nombreux polymères [81].


A la limite élastique, lorsque la contrainte nominale  $\sigma_n = F/S_0$  passe par son maximum, la striction apparaît au niveau d'un défaut géométrique (de tels défauts existent toujours dans les éprouvettes). La striction correspond à une déformation hétérogène : la déformation et la vitesse de déformation étant plus grandes dans la striction lorsqu'elle se

forme. Notons aussi que les éprouvettes obtenues à partir des films à l'aide de l'emporte-pièce ne sont rigoureusement pas planes, mais légèrement incurvées. Ceci rend les essais de traction sur cette forme d'éprouvette délicats à analyser à cause notamment de l'apparition éventuelle du phénomène de flexion au cours de l'essai de traction, si les mors sont fortement serrés.

### III.3. 5. Courbe de traction

- La courbe de la **figure III.6** est la courbe typique montrant le comportement en traction d'un matériau ductile Elle met en évidence les caractéristiques suivantes :
- La partie initiale de la déformation est élastique .l'éprouvette reprend sa forme et sa dimension initiales lorsque la sollicitation cesse .il y a réversibilité totale et instantanée de la déformation.
- Lorsqu'on dépasse la limite d'élasticité on constate que la longueur de l'échantillon a augmenté de façon permanente lorsqu'on relâche la contrainte .on est en présence d'une déformation irréversible  $\epsilon_p$  (déformation permanente).
- Lorsque la rupture se produit l'éprouvette se contracte rapidement de manière brutale en restituant l'énergie stockée. Cette contraction s'accompagne d'une émission sonore qui a pour origine la transformation de l'anergie élastique en énergie cinétique. [84].

Etant donné la forme de la courbe de traction c'est l'allongement à la rupture qui est le plus affecté par le vieillissement. Les autres caractéristiques telles que le module et les seuils d'écoulement ne renseignent généralement pas sur l'évolution de la dégradation.



**Figure III.6 : Allure d'une courbe de traction classique.**

Cette courbe permet de déterminer les quatre grandeurs caractéristiques suivantes :

- **Le module d'élasticité E:** (ou module de Young) donné par la pente de la partie élastique de la courbe contrainte  $\sigma$  -déformation  $\epsilon$  .ce module élastique est fonction de l'énergie des liaisons entre les atomes ou molécules constituant matériau.

- **La limite d'élasticité  $R_e$**  : qui donne la valeur de la contrainte nominale théorique à partir de laquelle le matériau commence à se déformer plastiquement .comme la déformation plastique apparait souvent

progressivement, la limite d'élasticité est difficile à déterminer avec précision, et on adopte en générale une limite conventionnelle d'élasticité  **$R_{0.2}$**  qui est la contrainte nominale correspondant à une déformation

permanaient de 0.2%.

- **La résistance à la traction  $R_m$** : qui est définie par la contrainte nominale maximale supportée par l'éprouvette.

- **La déformation à la rupture ( $\epsilon_R$ )**: qui correspond à la déformation plastique nominale à la rupture en traction de l'éprouvette .la valeur de la déformation à la rupture ( **$\epsilon_R$** ) représente une des grandeurs caractéristiques

de la ductilité. [84]

#### III.4.Entraînement et Paramétrage des Modèles

Après plusieurs exécutions, nous avons fini par identifier les paramètres qui retournent la meilleure précision pour chaque réseaux convolutionnel. Dans ce qui suit, nous allons argumenter nos choix par rapport aux paramètres d'apprentissage :

- **Fonction d'Optimisation** : Adam Algorithme d'optimisation "Adam" est une extension de la descente de gradient stochastique présenté par Diederik Kingma et Jimmy Ba en 2015 dans leur article « Adam : A Method for Stochastic Optimization» [85].

Nous avons choisi Adam car c'est l'algorithme d'optimisation le plus utilisé dans les implémentations des réseaux de neurones profonds. Et aussi pour ses remarquables avantages:

- Calcul efficace.
- Simple à implémenter.
- Non gourmand en espace mémoire.
- Approprié pour les problèmes avec beaucoup de bruit.
- Bien adapté aux problèmes qui ont un nombre important de données et de paramètres.

**`model.compile(loss='mse', optimizer='adam', metrics=['mse'])`**.

- **Fonction d'Erreurs** : Squared Error est donnée par l'expression

$$P = \sum (y_i - \hat{y}_i)^2$$

Nous avons opté pour cette fonction car les valeurs retournées par les modèles sont des valeurs continues. Alors que notre prédiction ressemble à un problème de régression et la



fonction Squared Error est le bon choix dans ces cas. MSE est la somme des distances au carré entre notre variable cible et les valeurs prédites.

```
model.compile(loss='mean_squared_error')
```

- **Fonction d'Activation** : Unités linéaires rectifiées (ReLU)(voir section II.4.2) ReLU est utilisée dans tous les couches de réseaux .
- **Nombre d'Itérations (Epochs)** : Une itération correspond à une passe en avant à travers tout le réseau de neurone plus une passe en arrière (Backpropagation) pour modifier les poids. Nous étions contraint à limiter le nombre d'itérations à 3000 à cause des ressources matérielles disponibles. Mais ce nombre d'itérations étaient largement suffisant pour entraîner un modèle et avoisiner a un erreur égale à 0.014453906476305081.
- **Taille de Batch (Batch Size)** : La taille du Batch correspond au nombre total d'exemples d'entraînements présents dans un seul paquet. Pour concevoir notre modèle, nous avons un ensemble de données de 3662 instances (Temps\_Déformation,Contrainte), nous divisons l'ensemble de données en paquets de 100 instances chacun appelé Batch. La division de dataset en mini-Batches permet au réseau de neurones de faire un apprentissage plus rapide et nécessite moins de mémoire pour stocker les résultats (exemples d'apprentissage).
- **Force arrêt "early stopping"** :est une forme de régularisation utilisée pour éviter le sur-apprentissage lors de la formation d'un apprenant avec une méthode itérative, telle que la descente de gradient. Ces méthodes mettent à jour l'apprenant afin qu'il s'adapte mieux aux données de formation à chaque itération. Jusqu'à un certain point, cela améliore les performances de l'apprenant sur des données extérieures à l'ensemble de formation. Au-delà de ce point, toutefois, l'amélioration de l'ajustement des données de formation des apprenants se fait au détriment d'une erreur de généralisation accrue. Les règles du force d'arrêt fournissent des indications sur le nombre d'itérations pouvant être exécutées avant que l'apprenant ne commence à se surdimensionner.[76]

```
es = EarlyStopping(monitor='mse', mode='min', patience =100)
```

- **Moniteur**: quantité à surveiller.
- **Patience**: nombre d'époques sans amélioration après lesquelles l'entraînement sera arrêté.
- **Mode**: un de {auto, min, max}. En mode min, l'entraînement s'arrête lorsque la quantité surveillée a cessé de diminuer; en mode max, il s'arrête lorsque la quantité contrôlée a cessé d'augmenter; en mode auto, la direction est automatiquement déduite du nom de la quantité contrôlée.

• **L'abandon** "Dropout" consiste à définir de manière aléatoire un taux de fractions d'unités d'entrée égal à 0 à chaque mise à jour pendant la période d'entraînement, ce qui permet d'éviter les sur-ajustements. Le taux est une valeur réel entre 0 et 1 correspond à fraction des unités d'entrée à déposer.[76]

**cnn1=Dropout(0.1)(cnn1)**

**cnn2=Dropout(0.1)(cnn2)**

• **Un rappel** "callbacks" est une fonctions à appliquer à des étapes données de la procédure de formation. pour obtenir une vue sur les états internes et les statistiques du modèle pendant la formation on a implémenter la méthode Callback

**chk=ModelCheckpoint('Model.h5',save\_best\_only=True,monitor='val\_loss',  
verbose=1)**

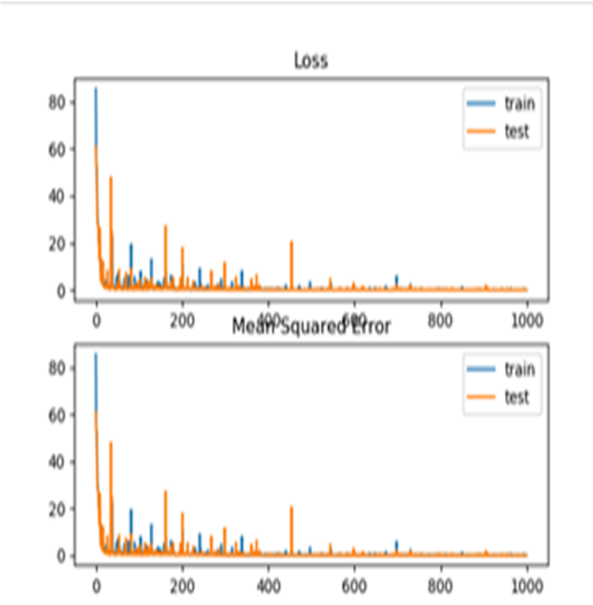
### III.5. Architecture du model(Convnet)

Un model Convnet était prêt à simuler la relation contrainte-déformation pour le PEbd vieillis durant :(120; 550 ; 1010; 2040; 4000 heures) . Afin d'atteindre cet objectif, 80% des données de chacun des mélanges sont utilisés pour entrainer le réseau sur la relation contrainte-déformation réelle, puis 20% des données ont été utilisés pour valider le model.

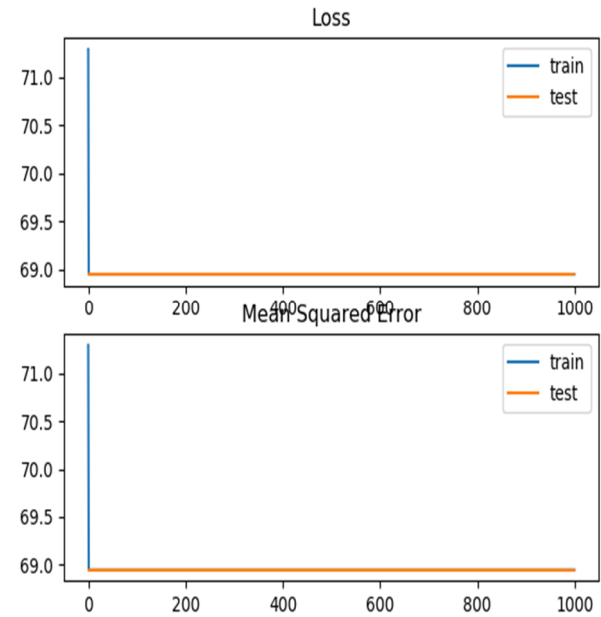
Au cours de la phase d'apprentissage, les entrées principales du model sont le temps et la déformation, et est la sortie correspondante, qui est la contrainte. Alors l'algorithme d'apprentissage est exécuté jusqu'à ce que l'erreur de système atteint la valeur minimum. pour avoir un architecture optimale on a testée plusieurs architectures. Avec une ou plusieurs couches cachées. et de prendre l'architecture qui à L'erreur minimum. -Pratiquement l'architecture se construit de la façon suivante:

- On a commencé par une architecture contient 2 couche CNN 2 séparer par une couche Pooling , et terminer par une couche Dropout (ratio =10%,20%,50%),avec des itération égale à 100,150,170...etc
- On a met le processus de l'apprentissage en marche.
- On a modifié les paramètres(filtre, le nombre de couche cachés,les fonction d'activation,les nombre de couche CNN, Pooling, Dropout) du model.
- On a augmenté le nombre de neurones dans la couche cachée.
- On a répète la même démarche. Et à chaque fois on compare l'erreur avec l'erreur précédente.

Le tableau ci-dessous représente quelque architecteur, et l'erreur d'apprentissage de quelque model qu'on essayer durant la phase d'implémentation.

<i>Architecteur du Model</i>	<i>Graph d'erreur</i>	<b>L'erreur/itération /Fonction d'activation</b>
<pre> Visible1 = Input(shape=(1, 1)) cnn1 = Conv1D(filters=1, kernel_size=1, activation='relu')(visible1) cnn1=Dropout(0.1)(cnn1) cnn1 = MaxPooling1D(pool_size=1)(cnn1) cnn1 = Flatten()(cnn1) # second input model visible2 = Input(shape=(1, 1)) cnn2 = Conv1D(filters=1, kernel_size=1, activation='relu')(visible2) cnn2=Dropout(0.1)(cnn2) cnn2 = MaxPooling1D(pool_size=1)(cnn2) cnn2 = Flatten()(cnn2) # merge input models merge = concatenate([cnn1, cnn2]) dense = Dense(50, activation='relu')(merge) output = Dense(1, activation='relu')(dense) model1 = Model(inputs=[visible1, visible2], outputs=output)                     </pre>		<p>0.07047289756 /1000itération /F</p>

```
model = Sequential()
model.add(Conv1D(filters=8, kernel_size=2, activation='relu',
input_shape=(2, 1)))
# model.add(Conv1D(filters=64, kernel_size=2, activation='relu'))
# model.add(Dropout(0.5))
model.add(MaxPooling1D(pool_size=1))
model.add(Flatten())
model.add(Dense(50, activation='relu'))
model.add(Dense(1,activation='sigmoid'))
```




7.978184115175-944  
/1000itération

```

visible1 = Input(shape=(1, 1))
cnn1 = Conv1D(filters=16, kernel_size=1, activation='relu')(visible1)
cnn1 = Dropout(0.5)(cnn1)
cnn1 = MaxPooling1D(pool_size=1)(cnn1)
cnn1 = Flatten()(cnn1)

# second input model
visible2 = Input(shape=(1, 1))
cnn2 = Conv1D(filters=6, kernel_size=1, activation='relu')(visible2)
cnn2 = Dropout(0.5)(cnn2)
cnn2 = MaxPooling1D(pool_size=1)(cnn2)
cnn2 = Flatten()(cnn2)

# merge input models
merge = concatenate([cnn1, cnn2])
dense = Dense(30, activation='relu')(merge)
output = Dense(1, activation='relu')(dense)
model1 = Model(inputs=[visible1, visible2], outputs=output)
    
```



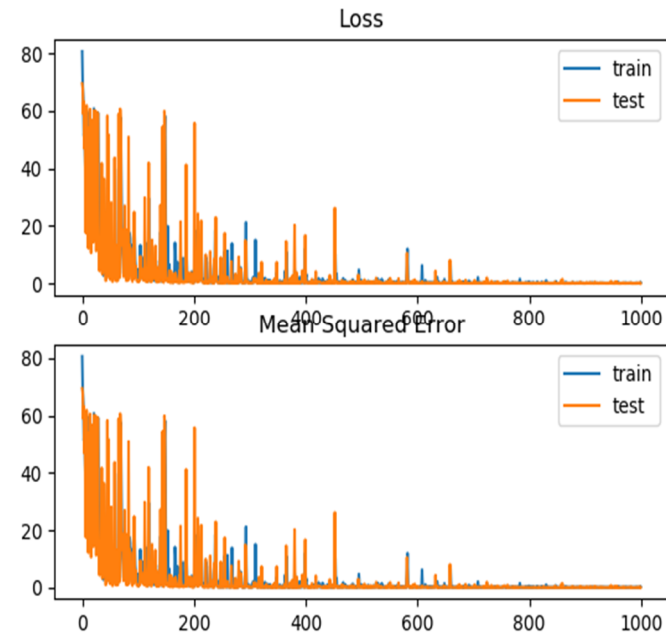
0.40843262-  
 8614166  
 179 itérations  
 /Fa=Relu

```

visible1 = Input(shape=(1, 1))
cnn1 = Conv1D(filters=8, kernel_size=1, activation='relu')(visible1)
cnn1 = Dropout(0.5)(cnn1)
cnn1 = MaxPooling1D(pool_size=1)(cnn1)
cnn1 = Flatten()(cnn1)

# second input model
visible2 = Input(shape=(1, 1))
cnn2 = Conv1D(filters=8, kernel_size=1, activation='relu')(visible2)
cnn2 = Dropout(0.5)(cnn2)
cnn2 = MaxPooling1D(pool_size=1)(cnn2)
cnn2 = Flatten()(cnn2)

# merge input models
merge = concatenate([cnn1, cnn2])
dense = Dense(50, activation='relu')(merge)
output = Dense(1, activation='relu')(dense)
model1 = Model(inputs=[visible1, visible2], outputs=output)
    
```



0.166037204-  
17060  
1000 itération

```

visible1 = Input(shape=(1, 1))
cnn1 = Conv1D(filters=64, kernel_size=1, activation='relu')(visible1)
cnn1 = Dropout(0.5)(cnn1)
cnn1 = MaxPooling1D(pool_size=1)(cnn1)
cnn1 = Flatten()(cnn1)

```

# second input model

```

visible2 = Input(shape=(1, 1))
cnn2 = Conv1D(filters=64, kernel_size=1, activation='relu')(visible2)
cnn2 = Dropout(0.5)(cnn2)
cnn2 = MaxPooling1D(pool_size=1)(cnn2)
cnn2 = Flatten()(cnn2)


```

# merge input models

```

merge = concatenate([cnn1, cnn2])
dense = Dense(50, activation='relu')(merge)
output = Dense(1, activation='relu')(dense)
model1 = Model(inputs=[visible1, visible2], outputs=output)

```



0.014453906476305081  
/1750 itération

<pre> visible1 = Input(shape=(1, 1)) cnn1 = Conv1D(filters=64, kernel_size=1, activation='relu')(visible1) cnn1 = Dropout(0.5)(cnn1) cnn1 = MaxPooling1D(pool_size=1)(cnn1) cnn1 = Flatten()(cnn1) # second input model visible2 = Input(shape=(1, 1)) cnn2 = Conv1D(filters=64, kernel_size=1, activation='relu')(visible2) cnn2 = Dropout(0.5)(cnn2) cnn2 = MaxPooling1D(pool_size=1)(cnn2) cnn2 = Flatten()(cnn2)  # merge input models merge = concatenate([cnn1, cnn2]) dense = Dense(55, activation='relu')(merge) output = Dense(1, activation='relu')(dense) model1 = Model(inputs=[visible1, visible2], outputs=output)                 </pre>	<p>The figure contains two vertically stacked line graphs. The top graph is titled 'Loss' and the bottom graph is titled 'Mean Squared Error'. Both graphs have an x-axis representing iterations from 0 to 1000 and a y-axis representing error values from 0 to 300. Each graph contains two lines: a blue line for 'train' and an orange line for 'test'. In both graphs, the training error starts at approximately 300 and drops sharply to near zero within the first 50 iterations. The test error starts at approximately 50 and also drops sharply to near zero within the first 50 iterations. Both errors remain very low and stable for the remainder of the 1000 iterations.</p>	<p>0.023692948592015185 /1000 itération</p>
---	---	---

Tableau III.1 : Exemple d'entrainement avec l'erreur d'apprentissage.



Après le test de plusieurs architectures on choisit l'architecture qui donne l'erreur minimum 0.014453906476305081..

- Une couche d'entrée (ensemble de vecteurs de déformation et le temps), cette couche s'exprime en deux bloc de construction.
  - Le premier bloc contient une: couche CNN filters=16, kernel\_size=1, activation='relu', et la déformation comme entrée, un neurones Dropout égale à 0.5, une couche de regroupement avec un pool\_size=1.
  - Le deuxième bloc contient une: couche CNN filters=16, kernel\_size=1, activation='relu', et le temps comme entrée, un neurones Dropout égale a 0.5, une couche de regroupement avec un pool\_size=1.
- ces deux bloc sont concaténer et connecter par une couche contient 50 neurones et une fonction d'activation "relu",
- Une couche de sortie (contrainte) contient 1 neurones correspond a le nombre de sortie du model et une fonction d'activation Relu.

### III.5.1. Paramètres d'Apprentissage

Pour notre modèle nous avons opté pour les paramètres suivants :

- Optimiseur d'erreur : Adam Gradient Descente
- Fonction d'erreur : Mean Square Error
- Taille de Mini-Batch : 100
- Nombre d'itérations : 1900
- Taille de Drop-out : 0.2 (20%) Le Drop-out est un paramètre additionnel qui consiste à ignorer des unités (neurones) aléatoirement en les mettant à 0 pour chaque mise à jour des poids pendant l'apprentissage ce qui permet d'éviter le sur-apprentissage (Overfitting).
- Taille d'ensemble de validation : 0.2 (20%)

### III.6. Les interfaces de l'application:

Nous avons développé une application pour effectuer une prédiction des propriétés mécanique des films PEBD avec précision acceptable et toujours avec la possibilité de tracer des graphes.

#### III.6.1. Création du Model Convnet:

Notre application permet à l'utilisateur de créer un nouveau Model ou bien ouvrir un Model déjà existant.

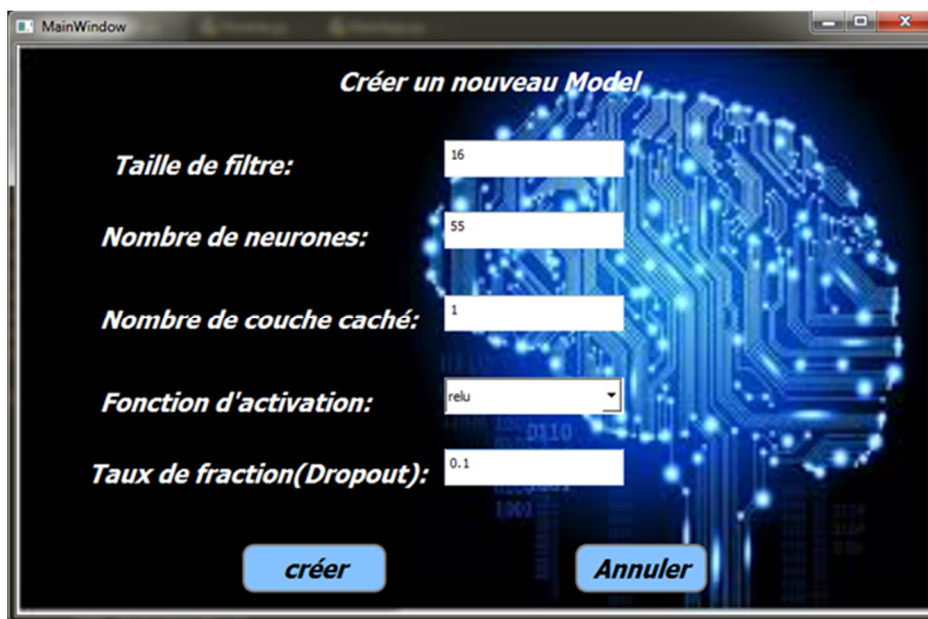


Figure III.6:Interface de Création du modèle CNN.

Pour créer un nouveau réseau, on doit tout d’abord charger et valider les données pour entrainé notre model.

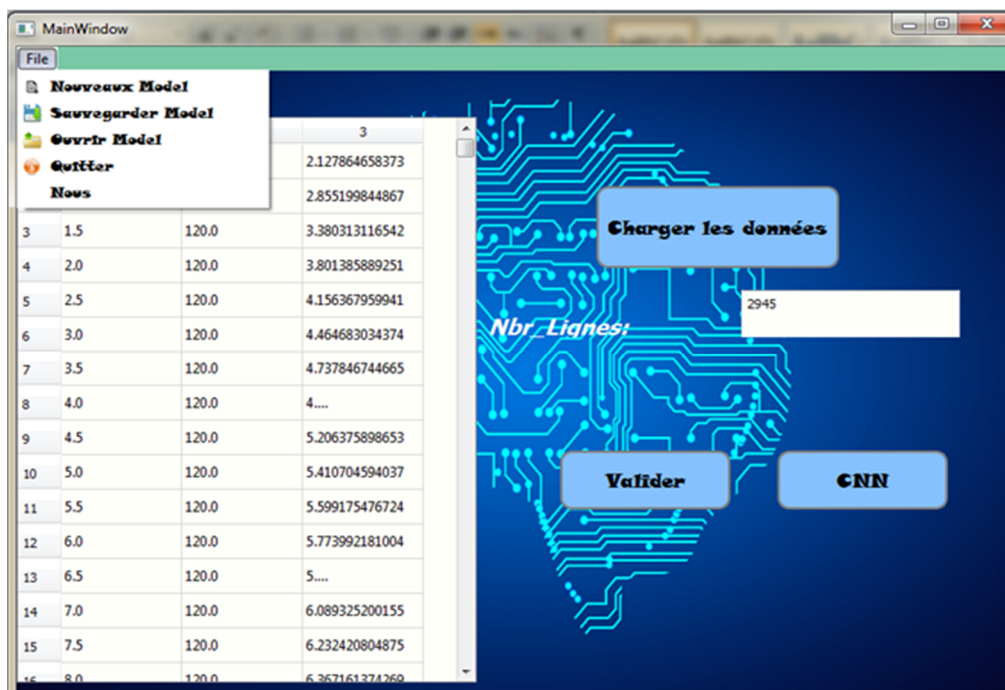
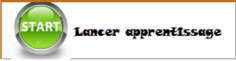


Figure III.7: interface de chargement des données.

Après avoir créé un réseau de neurone l'utilisateur peut effectuer un apprentissage avec un fichier Excel qui contient les entrées du Model associe à leur sortie. lorsque on appuyons sur la bouton  lancer apprentissage le model va commencé l'entrainement et affiche le graphe d'erreur. la bouton Annuler l'apprentissage va stoppé l'entrainement du Model.




Figure III.8: Fenêtre d'apprentissage.

### III.7. Les tests:

Dans tous les graphes ci-dessous la courbe en rouge correspond à la sortie réelle et la courbe en bleu représente la sortie obtenue par la prédiction.

Test pour temps=120h.

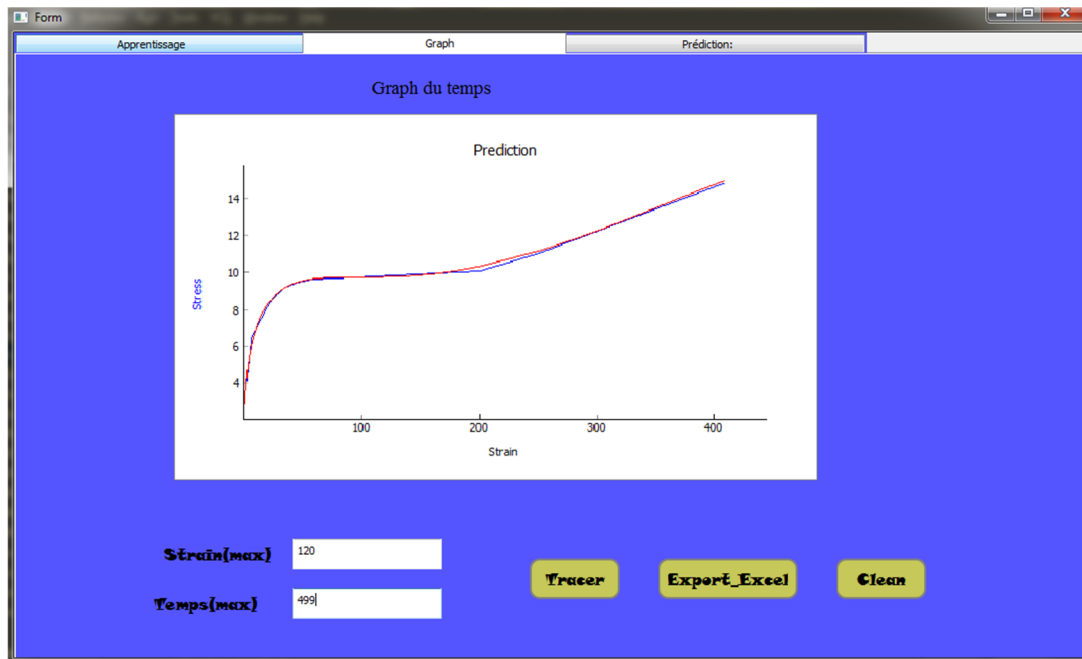


Figure III.9: Fenêtre test temps=120h.

Test pour temps=550h.

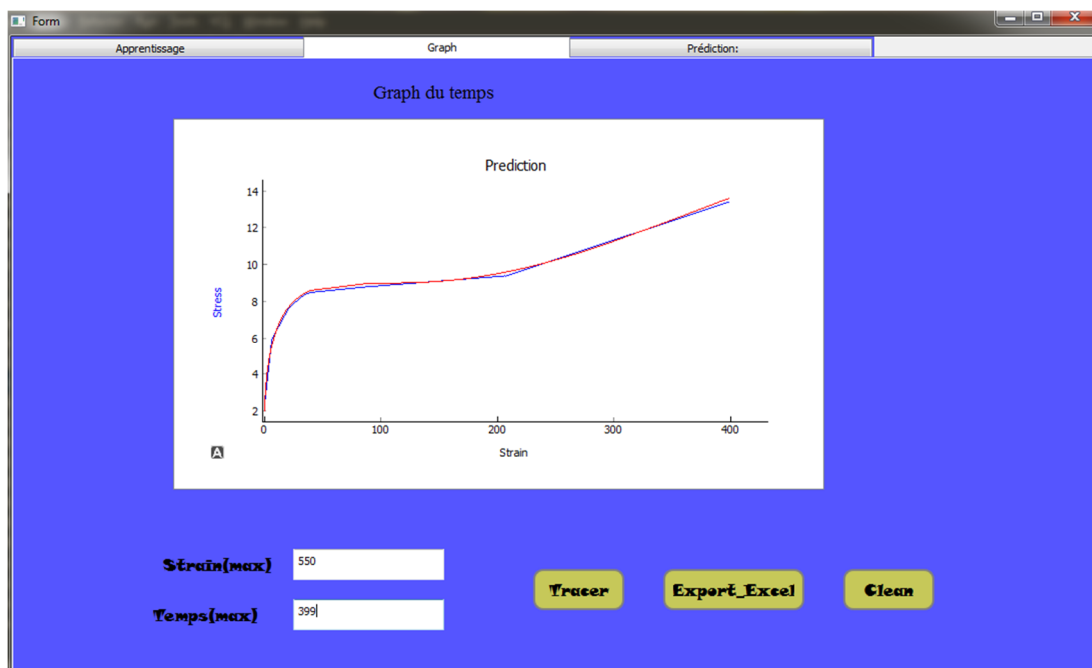


Figure III.10: Fenêtre test temps=550h.

pour temps=1010h.

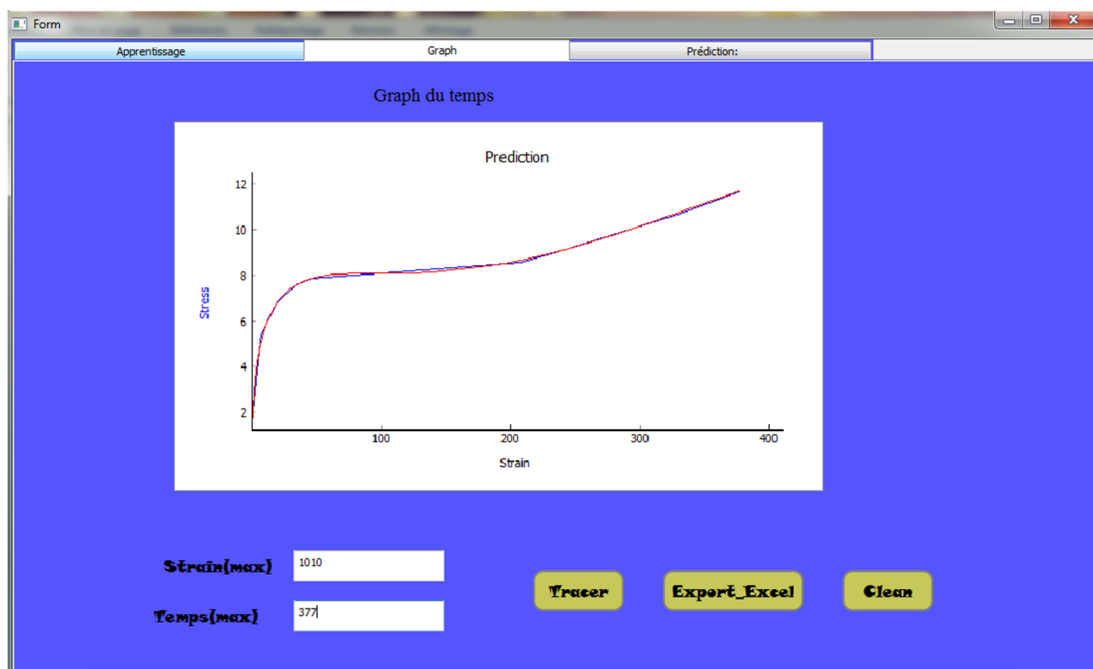


Figure III.11: Fenêtre test temps=1010h.

Pour temps=2040h.

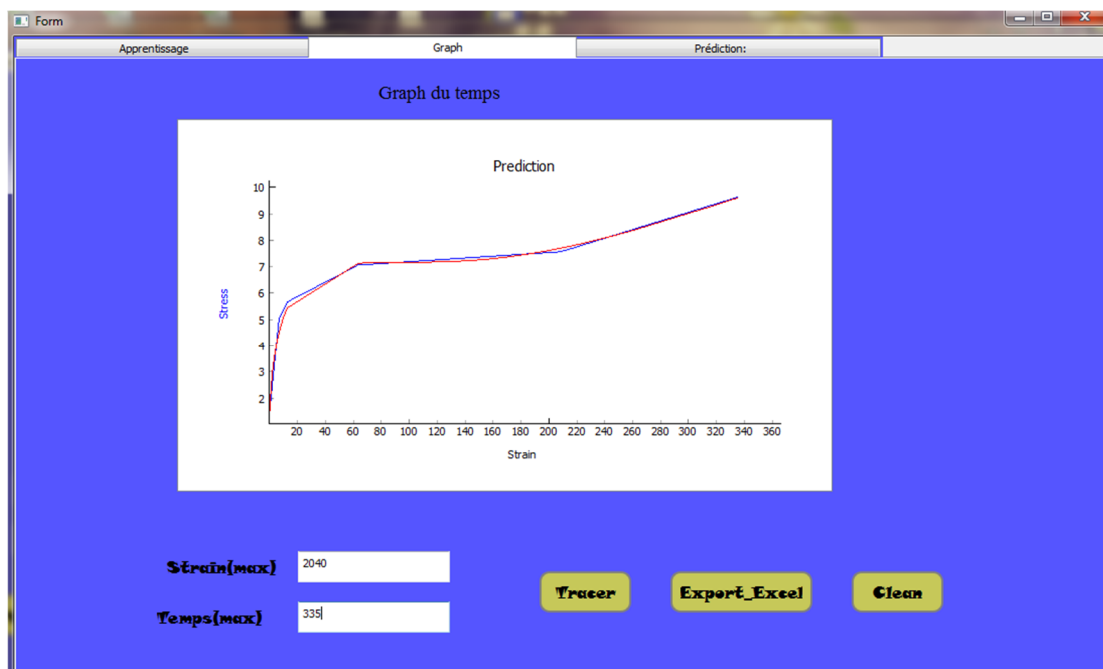


Figure III.12: Fenêtre test temps=2040h.

III.8.La prédiction:

La prédiction peut être effectuée soit sur une paire de donnée ou bien sur un ensemble de données. On fournit le temps et la déformation comme entrée pour le modèle et la contrainte comme sortie. Le graphique suivant démontre le stress en fonction du temps.

Prédiction pour temps=100h.

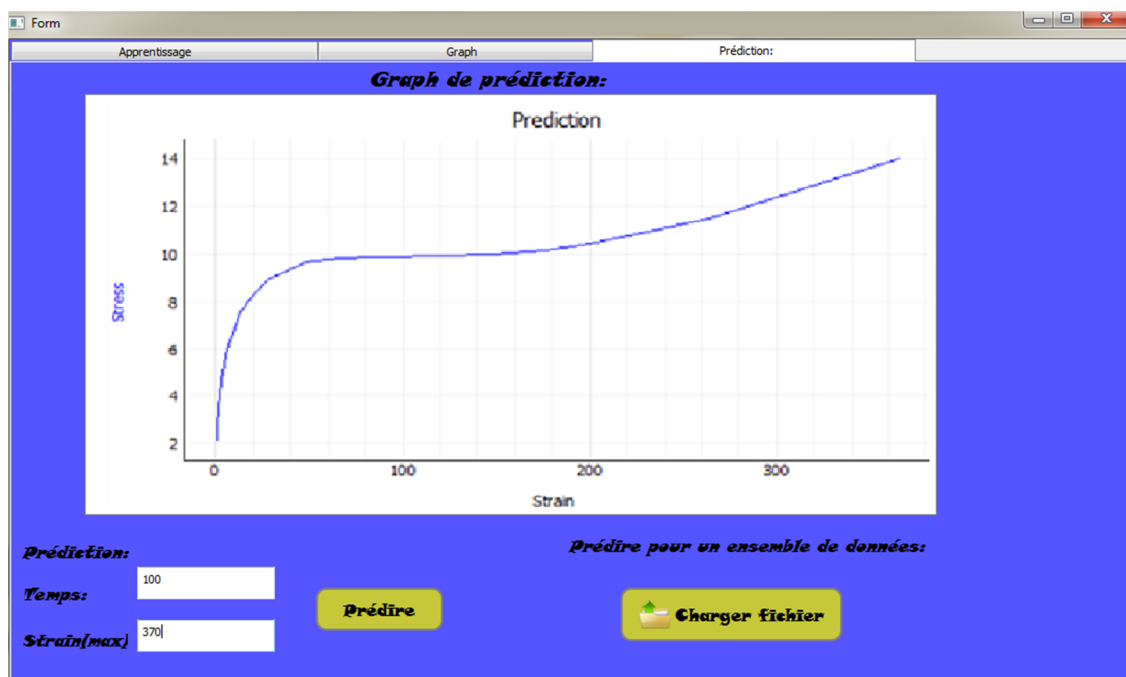


Figure III.13: Fenêtre de prédiction temps=100h.

Prédiction pour temps=80h.

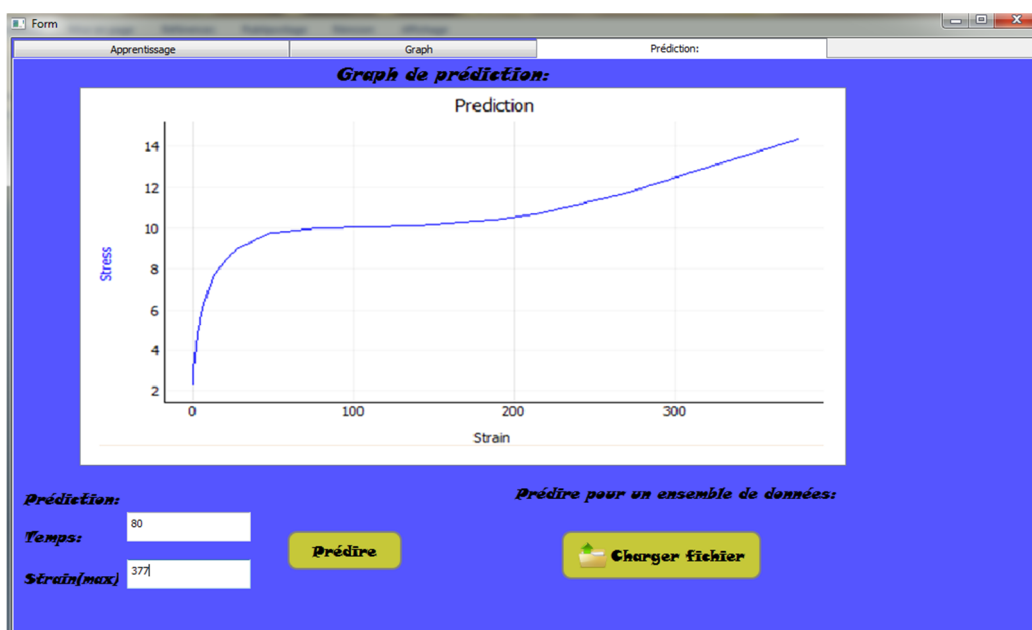


Figure III.14: Fenêtre de prédiction temps=80h.

**III.9. Conclusion:**

Dans ce chapitre nous avons, en premier lieu, présenté les différents outils et langages que nous avons utilisés pour implémenter notre application. Ainsi une approche de apprentissage profond (Convnet) a été utilisée pour modéliser et analyser les propriétés mécaniques d'un PEbd. Le modèle a été développé pour prédire la courbe contrainte-déformation d'un PEbd lors le changement du temps (dégradation). Nous avons présenté quelques interfaces de notre application en expliquant comment manipuler l'application ainsi que les résultats des tests et de la prédiction.

## **Conclusion générale**



## Conclusion générale

---

### Conclusion générale

Dans de nombreux secteurs d'activités, le vieillissement doit être maîtrisé sinon il constitue un obstacle important à l'utilisation des matériaux polymères. Il n'y a pas un vieillissement des polymères mais des vieillissements, ceux-ci peuvent avoir une origine physique, chimique et les différents mécanismes sont souvent liés ou induits les uns par les autres. La conception d'un produit en matériau polymère doit prendre en compte les effets du vieillissement de la matière sur les fonctions premières.

Ce travail porte en premier temps sur la modélisation physique et mécanique du phénomène de vieillissement d'un isolant organique (PEBD) mais le succès et l'utilisation massive et intense de ces polymères s'accompagne malheureusement de risques encourus suite à leur dégradation.

En l'absence de l'outil expérimental et la présence de ses risques, il devient impératif d'utiliser l'outil informatique pour palier à cette carence. Les réseaux de neurones profonds ont pu remplacer le côté expérimental en simulant tous les phénomènes observés au laboratoire tels que le vieillissement des polymères avec une erreur très faible.

Dans le premier chapitre, nous avons présenté la dégradation des matériaux polymères tels que les polyéthylènes. Cet axe a connu un développement prodigieux suite à des recherches accélérées au cours de ces dernières années.

Dans le deuxième chapitre, nous avons défini les notions fondamentales des réseaux de neurones convolutifs en présentant les différents types de couches utilisées dans le cas de régression afin de modéliser et analyser les propriétés mécaniques des films PEBD multicouches pour prédire leur déformation.

Dans l'étape de réalisation, nous avons sélectionné les technologies les plus adaptées à notre choix technique, pour finir par une illustration des différentes, nous avons principalement appliqué l'algorithme des réseaux des neurones convolutifs pour examiner les informations profondes d'un réseau multicouche dans ce processus de vieillissement.

Notre objectif principale est l'utilisation de nouvelles stratégies à base de réseaux de neurones profonds de commande afin d'améliorer le control et la prédiction du déclin de potentiel de surface d'un PEBD. Ces derniers sont des techniques puissantes de traitement non linéaire de données et qui ont fait leurs preuves dans de nombreux domaines d'application à caractère industriel, ceux-ci (les CNN) disposent de règles bien précises pour fixer le nombre de neurones et de couches cachées.

Notre projet a été une opportunité pour approfondir nos connaissances dans le domaine de Deep Learning et d'apprendre ses différents modèles et leurs applications. Il est

## **Conclusion générale**

---

important pour nous de dire que l'un des avantages majeurs de ce travail est de familiariser avec la compréhension des articles et apprendre la méthodologie idéale pour la rédaction d'un bon document et la maîtrise de plusieurs bibliothèques où nous avons su les exploiter pour la création des modèles d'apprentissage profond (Deep Learning).

## *Références bibliographiques*

### Bibliographie

- [01]: K. Hachour, « contribution à l'élaboration d'un critère de plasticité pour le Pehd », thèse de doctorat en génie mécanique, université mouloud mammeritizi ouzou,2010.
- [02]: Nadine Lahoude " Modélisation du vieillissement des isolants organiques sous contrainte électrique. Application à la fiabilité des matériaux." Thèse de Doctorat, 25 Mars 2009. Université de TOULOUSE.
- [04]: P. Weiss, la chimie des polymères, université médicale virtuelle francophone, société francophone de biomatériaux dentaires, 2009-2010.
- [05]: THÈSE Doctorat. Mr. BENSaid Mohamed Ouassini. "Étude Des Polymères Par Dynamiques Moléculaire". 2015.
- [06]: A. Soldera, N. Metatla, Compos. A: Appl. Sci. Manuf. 36 (2005) 521.
- [07]: F.J. Boerio, J.L. Koenig, J. Macromol. Sci. C7 (1972) 209.
- [08]: J.J.L. Cascales, T.F. Otero, J. Chem. Phys. 120 (2004) 1951.
- [09]: Tasaki, Macromolecules 29 (1996) 8922.
- [10]: J. Ennari, J. Hamara, F. Sundholm, Polymer 38 (1997) 3733.
- [11]: L.J.A. Siqueira, M.C.C. Ribeiro, J. Chem. Phys. 122 (2005) 194911.
- [12]: R. Khare, M.E. Paulaitis, Macromolecules 28 (1995) 4495.
- [13]: MBAREK BOUHARKAT. Prédiction des propriétés mécaniques de PEbd vieillis en utilisant les réseaux neurones. 2016.thèse magister.
- [14]:SADOUN SOFIANE."Contribution à l'étude expérimentale d'un polythélénea haute densité(PEHD) effet de la temperature et de la vitesse de deformation.2007" thèse magister.
- [15]: J.DorlotT, J. Massounave et al, "des matériaux", édition de l'ecole polytechnique des matériaux, Juillet, (1995).
- [16]: B. Vieille, J. Aucher, L. Taleb « Carbon fiber fabrics reinforced PPS laminates: influence of environmental conditions on the behavior of notched laminates and bolted joints » soumis à Mechanics of Mat., 2009.
- [17]: Etude du comportement du polyéthylène haute densité sous irradiation ultraviolette ou sollicitation m´mécanique par spectroscopie de fluorescence - Ludovic Douminge J. Martin et al, " traité des matériaux ", Tome 14, (2001).
- [18]: Masakazu Matusugu, Katsuhiko Mori, Yusuke Mitari et Yuji Kaneda, « *Subject independent facial expression recognition with robust face detection using a convolutional neural network* », Neural Networks, vol. 16, n° 5, 2003, p. 555–559 .

## Références bibliographiques

---

- [19]: Pan J., Shaw W.J.D., Effects of processing parameters on material properties of mechanically processed polyamide, *Journal of Applied Polymer Science*, 56 (5), 557-566 (1995)
- [20]: Pan J., Shaw W.J.D., Properties of a mechanically processed polymeric material, *Journal of Applied Polymer Science*, 52 (4), 507-514 (1994)
- [21]: Weibo Liua, Zidong Wanga., Xiaohui Liua, Nianyin Zeng, Yurong Liuc., Fuad E. Alsaadi " A survey of deep neural network architectures and their applications", *Neurocomputing* 234 (2017) 11–26
- [22]: «les techniques du polyéthylène » thème élaboré par le Chef de Subdivision en Enseignement Gaz Mr.DibNaouar.
- [23]: THÈSE Doctorat. Mr. BENSALIM Mohamed Ouassini. "Étude Des Polymères Par Dynamiques Moléculaire". 2015.
- [24]: V, Chaffraix. Etude de l'extrusion du polyéthylène téréphtalate et de ses mélanges noncomptabilisés avec le polyéthylène haute densité, mécanique [physics.med-ph], Ecole nationale supérieure des mines, Paris, 2002.
- [25]: M. Lassiaz, Corrélation entre les Mécanismes de Vieillessement Artificiel de Film Polymériques et l'Evolution des Propriétés Mécaniques, Thèse de Doctorat, Université Bordeaux 1 France (1993).
- [26]: N. Kerboua, Vieillessement naturel et Artificiel de Polyéthylène, Thèse de Magistère, Université FerhatAbbas de Sétif Algérie (1994).
- [27]: Introduction à la Mécanique des Polymères, Edition Christian G'ssell et Jean MaecHaudin.
- [28]: J. L. Bolland, *Quart Review, Chemistry Soc* 3 (1972) .
- [29]: J. P. Trotignon, J. Verdu, A. Dobraczynski et M. Piperaud, AFNOR, Editions Nathan(1996).
- [30]: M. Lassiaz, Vieillessement des Plastiques, Application en Serriculture, DEA Mécanique, UniversitéBordeaux 1 France (1990).
- [31]: S. Fuzessery, *Techniques de L'Ingénieur* (1988).
- [32]: A.Bélaid. mémoire de magister "caractérisation sur site du polyéthylène tri-couches AFS3 utilise comme couverture de serre » Univ ORAN 2005.
- [33]: VERDU J. - Vieillessement chimique des plastiques : aspects généraux, *Techniques de l'ingénieur, traitéPlastiques et Composites*, AM 3 151, 14 pp.
- [34]: ARGON, A. S., COHEN, R. E. Toughenability of polymers. *Polymer*, 2003, Vol. 44, 6013-6032.

## Références bibliographiques

---

- [35]: NITTA, K. TAKAYANAGI, M. Tensile Yield of Isotactic Polypropylene in Terms of a Lamellar-Cluster Model. *Journal of Polymer Science: Part B: Polymer Physics*, 2000, Vol. 38, 1037–1044.
- [36]: ABOULFARAJ, M., G’SELL, C., ULRICH, B., DAHOUN, B. In situ observation of the plastic deformation of polypropylene spherulites under uniaxial tension and simple shear in the scanning electron, microscope. *Polymer*, 1995, Vol. 36, N°. 4, 731-742.
- [37]: TIJSSSEN, M. G. A., VAN DER GIESSEN, E., SLUYSA, L. J. Simulation of mode I crack growth in polymers by crazing. *International Journal of Solids and Structures*, 2000, Vol. 37, 7307-7327 75.
- [38]: CASTAGNET, S., GACOUGNOLLE, J. L., DANG, P. Correlation between macroscopical viscoelastic behaviour and micromechanisms in strained a polyvinylidene fluoride (PVDF). *Materials Science and Engineering*, 2000, A276, 152-159.
- [39]: PETERLIN, A. Molecular model of drawing polyethylene and polypropylene. *Journal of Materials Science*, 1971, Vol. 6, 490-508.
- [40]: LIN, L., ARGON, A. S. Structure and plastic deformation of polyethylene. *Journal of Materials Science*, 1994, Vol. 29, 294-323 178.
- [41]: FOND, C., G’SELL, C. Localisation des déformations et mécanismes d'endommagements dans les polymères multiphasés. *Mécanique et Industries*, 2002, Vol. 3, N°. 5. 431-438.
- [42]: DIJKSTRA, P. T. S., VAN DIJK, D. J., HUÉTINK, J. A Microscopy Study of the Transition From Yielding to Crazing in Polypropylene. *Polymer Engineering and science*, 2002, Vol. 42, N°. 1, 152-160.
- [43]: LEZAK, E., BARTCZAK, Z. Plastic Deformation Behavior of  $\alpha$  Phase Isotactic Polypropylene in Plane-Strain Compression at Elevated Temperatures. *Journal of Polymer Science: Part B: Polymer Physics*, 2008, Vol. 46, 92-108.
- [44]: PETERMANN, J., SCHULTZ J. M. Lamellar separation during the deformation of high density polyethylene. *Journal of Materials Science*, 1978, Vol. 13, 50-54.
- [45]: B. Benmammar, “Apprentissage automatique”, rapport de recherche, p. 71
- [46]: A. Schmitt and B. Le Blanc, “Les réseaux de neurones artificiels,” vol. 13, 2016
- [47]: X. P. Burgos-Artizzu, P. Perona, and P. Doll’ar, “Robust face landmark estimation under occlusion,” in ICCV, 2013,
- [48]: **MBAREK BOUHARKAT**, « Prédiction des propriétés mécaniques de PEBD vieilliss en utilisant les réseaux de neurones », mémoire en vue de l’obtention du diplôme de magister, 2016.
- [49]: M. Parizeau. « Réseaux de neurones », GIF-21140 et GIF-64326, Université Laval, Automne 2004.

## Références bibliographiques

---

- [50]: Dreyfus, G., J-M. Martinez, M. Samuelides, M.B. Gordon, F. Badran, and S2010.
- [51]: Rumelhart and McClelland, 1986a D.E. Rumelhart, J.L. McClelland, the PDP Research Group Parallel distributed processing : Explorations in the microstructure of cognition, Vols. 1 and 2, MIT Press, Cambridge, MA (1986) Rumelhart et al., 1986.
- [52]: E. Rumelhart, G.E. Hinton, R.J. Williams Learning internal representation by error propagation. In Parallel distributed processing Explorations in the microstructure of cognition, MIT Press, Cambridge, MA (1986), pp. 318-362.
- [53]: Pierre Buysens, Fusion de différents modes de capture pour la reconnaissance du visage appliquée aux e\_ transactions DOCTORAT de l'UNIVERSITÉ de CAEN Le 4 Janvier 2011
- [54]:Jeff\_Heaton.Artificielintelligence for humans.volume:Deep learning and neural network– October 28, 2015.
- [55]: G. Dreyfur. « Réseaux de neurones : Méthodologie et application », édition Eyrolles, 2004.
- [56]: RUMELHART, David E., HINTON, Geoffrey E., et WILLIAMS, Ronald J. Learning internal representations by error propagation. California Univ San Diego La Jolla Inst for Cognitive Science, 1985.
- [57]: G. E. HINTON, S. OSINDERO et Y.-W. TEH. A fast learning algorithmfor deep belief nets.Neural computation, 18 : 1527–1554, 2006.
- [58]: Y. BENGIO, P. LAMBLIN, D. POPOVICI, H. LAROCHELLE et coll. Greedy layer-wise training of deep networks. Advances in neural information processing systems, 19 : 153, 2007.
- [59]: M. C. CRAIR, D. C. GILLESPIE et M. P. STRYKER. The role of visual experience in the development of columns in cat visual cortex. Science, 279 : 566–570, 1998.
- [60]: G. G. BLASDEL. Orientation selectivity, preference, and continuity in monkey striate cortex. The Journal of Neuroscience, 12 : 3139–3161, 1992.
- [61]: M. Adrien F. Vincent." Vers une utilisation synaptique de composants mémoires innovants pour l'électronique neuro inspirée".Thèse de doctorat de l'Université Paris-Saclay préparée à l'Université Paris-Sud 2017.
- [62]: L. Deng, D. Yu, et al., "Deep learning : methods and applications," Foundations and Trends R inSignal Processing, vol. 7, no. 3–4, pp. 197–387, 2014.
- [63]: Book Deep learning . J .Patterson,A.\_Gibson- 2017.
- [64]: Stéphane Lathuilière, Pablo Mesejo, Xavier Alameda-Pineda, Member IEEE, and Radu Horaud" A Comprehensive Analysis of Deep Regression" arXiv:1803.08450v2 [cs.CV] 13 Feb 2019.

## Références bibliographiques

---

- [65]: Charu C. Aggarwal, "Book Neural Networks and Deep Learning", IBM T. J. Watson Research Center, International Business Machines, Yorktown Heights, NY, USA September 2018.
- [66]: Marc Briane et Gilles Pagès, *Théorie de l'intégration*, Vuibert, 2012 (ISBN 978-2-311-00738-1).
- [67] : X. Zhu and D. Ramanan, "Face detection, pose estimation, and landmark localization in the wild," in CVPR, 2012
- [68]: X. P. Burgos-Artizzu, P. Perona, and P. Dollár, "Robust face landmark estimation under occlusion," in ICCV, 2013,
- [69]: C.-R. Chou, B. Frederick, G. Mageras, S. Chang, and S. Pizer, "2d/3d image registration using regression learning," CVIU, vol. 117, no. 9, pp. 1095–1106, 2013.
- [70]: D. M. Bates, "Nonlinear Regression Analysis and Its Applications", Edition John Wiley & Sons, 1988.
- [81]: djakhdane khaled mémoire de magister( étude des vieillissements artificielles d'un film de polyethylene basse densite (PEbd)«température, eau et rayons uv »)univ tiaret 2011.
- [82]: RAAB, M., SCUDLA, J., KOLARIK, J. *The effect of specific nucleation on tensile mechanical behaviour of isotactic polypropylene*. European Polymer Journal, 2004, Vol. 40, 1317–1323
- [83] NA, B., LV, R. Effect of Cavitation on the Plastic Deformation and Failure of Isotactic Polypropylene. Journal of Applied Polymer Science, 2007, Vol. 105, 3274–3279.-1101.

### Webographie:

- [71]: [<https://www.mathworks.com/videos/advanced-programming-with-matlab-87540.html>]
- [72]: Python Language Copyright c 2001-2018 Python Software Foundation. All rights reserved. Licence : <https://docs.python.org/3/license.html>, Python documentation : <http://docs.python.org/3/>. <https://wiki.python.org/moin/BeginnersGuide/Overview>]
- [73]: <https://www.anaconda.com/why-anaconda/>
- [74]: <https://www.jetbrains.com/pycharm/?fromMenu>
- [75]: Scikit-learn Library : <http://scikit-learn.org/stable/>. Github : <https://github.com/scikit-learn/scikit-learn>
- [76]: Keras Framework : <https://keras.io/>. Github : <https://github.com/keras-team/keras>



## Références bibliographiques

---

[77]: Keras Licence : <https://github.com/keras-team/keras/blob/master/>

LICENSE

[78]: Bibliothèque PyQt5 v5.10.1 : <http://pyqt.sourceforge.net/Docs/PyQt5/>,

Github : <https://github.com/pyqt>

[79]: Entreprise Qt : <https://www.qt.io>, Github : <https://github.com/qt>

[80]: PyQt Licence : <https://www.riverbankcomputing.com/commercial/>

license-faq

## *Annexes*

**Annexe1** : Algorithm of Greedy layer-by-layer algorithm for DBN.

**Input:** Input visible vector  $v_{in}$ , training period  $T$ , learning rate  $\epsilon$ , number of layers  $J$ .  
**Output:** Weight matrix  $\omega^i$  of layer  $i$ ,  $i = 1, 2, \dots, J - 2$ .  
Initialize  $\omega$  with random values from 0 to 1,  $h^0 = v_{in}$ ; where  $h^0$  denotes the value of units in the input layer.  $h^i$  represents the units' value of the  $i$ th layer. layer=1;  
for  $\forall t=1: T$  do,  
for layer <  $L$ , do gibbs sampling  $h^{layer}$  using  $P(h^{layer}|h^{layer-1})$   
Computing the CD in Algorithm 1,  $\omega(layer)$  is achieved using  
 $\omega(t + 1) = \omega(t) + \epsilon \times \Delta\omega$   
End for  
End for

**Annexe2:** Algorithm of k-step contrastive divergence for RBMs.

**Input:** RBM( $V_1, \dots, V_m, H_1, \dots, H_n$ ), training period  $T$ , learning rate  $\epsilon$   
**Output:** The RBM weight matrix  $\omega$ , gradient approximation  $\Delta\omega_{ij}$ ,  $\Delta a_i$  and  $\Delta b_j$  for  $i = 1, \dots, m$ ,  $j = 1, \dots, n$   
Initialize  $\omega$  with random values distributed uniformly in  $[0, 1]$ ,  
 $\Delta\omega_{ij} = \Delta a_i = \Delta b_j = 0$  for  $i = 1, \dots, m$ ,  $j = 1, \dots, n$   
For  $\forall t = 1: T$  do,  
Sample  $v_i^{(t)} P(v_i|h^{(t)})$  when  $i = 1, \dots, m$   
Sample  $h_j^{(t+1)} P(h_j|v^{(t)})$  when  $j = 1, \dots, n$   
For  $i = 1, \dots, m$ ,  $j = 1, \dots, n$  do  

$$\Delta\omega_{ij} = \Delta\omega_{ij} + \epsilon \times P(H_j = 1|v^{(0)}) \times v_i^{(0)}$$

$$- \epsilon \times P(H_j = 1|v^{(T)}) \times v_i^{(T)}$$

$$\Delta a_i = \Delta a_i + \epsilon \times (v_i^{(0)} - v_i^{(T)})$$

$$\Delta b_j = \Delta b_j + \epsilon \times [P(H_j = 1|v^{(0)})$$

$$- P(H_j = 1|v^{(T)})]$$

$$\omega = \omega + \epsilon \times \Delta\omega_{ij}$$
End For  
End For

**Annexe 3:** Algorithm Back propagation algorithm for updating weights pseudocode.

```
function backpropagation-algorithm
( network, training-records, learning-rate ) returns network
network <- initialize weights (randomly)
start loop
  for each example in training-records do

    // compute the output for this input example
    network-output <- neural-network-output( network, example )

    // compute the error and the [delta] for neurons in the output layer
    example_err <- target-output - network-output

    // update the weights leading to the output layer
     $W_{j,i} \leftarrow W_{j,i} + \alpha \times a_j \times \text{Err}_i \times g'(input\_sum_i)$ 

    for each subsequent-layer in network do

      // compute the error at each node
       $\Delta_j \leftarrow g'(input\_sum_j) \sum_i W_{j,i} \Delta_i$ 

      // update the weights leading into the layer
       $W_{k,j} \leftarrow W_{k,j} + \alpha \times a_k \times \Delta_j$ 

    end for

  end for
end loop when network has converged
return network
```

**Annexe 4 : CNN Algorithm.**

➤ Forward pass :

output deviation of the  $k$  th neuron in output layer  $O$ :

$$d(O_k^o) = y_k - t_k$$

input deviation of the  $k$  th neuron in output layer:

$$d(I_k^o) = (y_k - t_k) \varphi'(v_k) = \varphi'(v_k) d(O_k^o)$$

weight and bias variation of  $k$  th neuron in output  $O$ :

$$\Delta W_{k,x}^o = d(I_k^o) y_{k,x}$$

$$\Delta Bias_k^o = d(I_k^o)$$

output bias of  $k$  th neuron in hide layer  $H$ :

$$d(O_k^h) = \sum_{i=0}^{i<17} d(I_i^o) W_{i,k}$$

input bias of  $k$  th neuron in hide layer  $H$ :

$$d(I_k^h) = \varphi'(v_k) d(O_k^h)$$

weight and bias variation in row  $x$ , column  $y$  in the  $m$  th feature pattern ,a former layer in front of  $k$  neurons in hide layer  $H$

$$\Delta W_{m,x,y}^{h,k} = d(I_k^h) y_{x,y}^m$$

$$\Delta Bias_k^h = d(I_k^h)$$

output bias of row  $x$ , column  $y$  in  $m$  th feature pattern ,sub sample layer  $S$

$$d(O_{x,y}^{s,m}) = \sum_k d(I_{m,x,y}^h) W_{m,x,y}^{h,k}$$

input bias of row  $x$ , column  $y$  in  $m$  th feature pattern ,sub sample layer  $S$

$$d(I_{x,y}^{s,m}) = \varphi'(v_k) d(O_{x,y}^{s,m})$$

weight and bias variation of row  $x$ , column  $y$  in  $m$  th feature pattern ,sub sample layer  $S$

$$\Delta W^{s,m} = \sum_{x=0}^{\hat{m}} \sum_{y=0}^{\hat{m}} d(I_{[x/2][y/2]}^{s,m}) O_{x,y}^{c,m}$$

among them,  $C$  represents convolution layer.

$$\Delta Bias^{S,m} = \sum_{x=0}^{f_h} \sum_{y=0}^{f_w} d(O_{x,y}^{S,m}) \quad (3.16)$$

output bias of row  $x$ , column  $y$  in  $k$  th feature patten ,convolution layer  $C$

$$d(O_{x,y}^{C,k}) = d(I_{\lfloor x/2 \rfloor, \lfloor y/2 \rfloor}^{S,k}) W^k \quad (3.17)$$

input bias of row  $x$ , column  $y$  in  $k$  th feature patten ,convolution layer  $C$

$$d(I_{x,y}^{C,k}) = \varphi'(v_k) d(O_{x,y}^{C,k}) \quad (3.18)$$

weight variation of row  $r$ , column  $c$  in  $m$  th convolution core, corresponding to  $k$  th feature pattern in  $l$  th layer ,convolution  $C$ .

$$\Delta W_{r,c}^{k,m} = \sum_{x=0}^{f_h} \sum_{y=0}^{f_w} d(I_{x,y}^{C,k}) O_{x+r,y+c}^{l-1,m} \quad (3.19)$$

total bias variation of the convolution core

$$\Delta Bias^{C,k} = \sum_{x=0}^{f_h} \sum_{y=0}^{f_w} d(I_{x,y}^{C,k}) \quad (3.20)$$

➤ Back propagation

output deviation of the  $k$  th neuron in output layer  $O$  :

$$d(O_k^o) = y_k - t_k$$

input deviation of the  $k$  th neuron in output layer:

$$d(I_k^o) = (y_k - t_k) \varphi'(v_k) = \varphi'(v_k) d(O_k^o)$$

weight and bias variation of  $k$  th neuron in output  $O$  :

$$\Delta W_{k,x}^o = d(I_k^o) y_{k,x}$$

$$\Delta Bias_k^o = d(I_k^o)$$

output bias of  $k$  th neuron in hide layer  $H$  :

$$d(O_k^H) = \sum_{i=0}^{i<17} d(I_i^O) W_{i,k}$$

input bias of  $k$  th neuron in hide layer  $H$  :

$$d(I_k^H) = \varphi'(v_k) d(O_k^H)$$

weight and bias variation in row  $x$  , column  $y$  in the  $m$  th feature pattern ,a former layer in front of  $k$  neurons in hide layer  $H$

$$\Delta W_{m,x,y}^{H,k} = d(I_k^H) y_{x,y}^m$$

$$\Delta Bias_k^H = d(I_k^H)$$

output bias of row  $x$  , column  $y$  in  $m$  th feature pattern ,sub sample layer  $S$

$$d(O_{x,y}^{S,m}) = \sum_k^{170} d(I_{m,x,y}^H) W_{m,x,y}^{H,k}$$

input bias of row  $x$  , column  $y$  in  $m$  th feature pattern ,sub sample layer  $S$

$$d(I_{x,y}^{S,m}) = \varphi'(v_k) d(O_{x,y}^{S,m})$$

$$\Delta Bias^{S,m} = \sum_{x=0}^{f_h} \sum_{y=0}^{f_w} d(O_{x,y}^{S,m})$$

output bias of row  $x$  ,column  $y$  in  $k$  th feature patter ,convolution layer  $C$

$$d(O_{x,y}^{C,k}) = d(I_{\lfloor x/2 \rfloor, \lfloor y/2 \rfloor}^{S,k}) W^k$$

iutput bias of row  $x$  ,column  $y$  in  $k$  th feature patter ,convolution layer  $C$

$$d(I_{x,y}^{C,k}) = \varphi'(v_k) d(O_{x,y}^{C,k})$$

weight variation of row  $r$  ,column  $c$  in  $m$  th convolution core,corresponding to  $k$  th feature pattern in  $l$  th layer ,convolution  $C$  .

$$\Delta W_{r,c}^{k,m} = \sum_{x=0}^{f_h} \sum_{y=0}^{f_w} d(I_{x,y}^{C,k}) O_{x+r,y+c}^{l-1,m}$$

total bias variation of the convolution core

$$\Delta Bias^{C,k} = \sum_{x=0}^{f_h} \sum_{y=0}^{f_w} d(I_{x,y}^{C,k})$$