

وزارة التعليم العالي و البحث العلمي

BADJI MOKHTAR-ANNABA UNIVERSITY
UNIVERSITE BADJI MOKHTAR-ANNABA



جامعة باجي مختار - عنابة

Faculté des Sciences de l'ingénieur

Département D'Electromécanique

Mémoire

Présenté en vue de l'obtention du diplôme

DE MAGISTER

Année 2010

**Etude et Modélisation de
Déclin de Potentiel de Surface par
les Réseaux de Neurones**

Option

Electromécanique

Par

Melle KASRI Souad

DIRECTEUR DE MEMOIRE : Mr. YOUSFI Ali Professeur (U. Annaba)

DEVANT LE JURY

PRESIDENT	: Mr HEROUS.L	M. Conférence	(U. Annaba)
EXAMINATEURS :	Mr BELHAMRA. A	M. Conférence	(U. Annaba)
	Mr LABAR.H	M. Conférence	(U. Annaba)
	Mr RAZEM.H	M. Conférence	(U. Annaba)

A ma famille
A la mémoire de mon père
Qui est parti très tôt

Remerciements

Il n'y a pas au monde un plus bel excès que celui de la reconnaissance... Au bout de mes années au sein du département de l'électromécanique, j'ai le grand plaisir d'exprimer ma grande gratitude envers les personnes en qui j'ai trouvé un soutien. Mes premières pensées se dirigent tout naturellement vers mon directeur du mémoire Mr YOUSFI Ali professeur de l'université de badji mokhtar Annaba pour le formidable encadrement qu'il m'a accordé tout au long de ce travail. Je ne peux que le remercier, non seulement pour ses compétences scientifiques, mais aussi pour ses qualités humaines et pour la confiance qu'il m'a toujours témoignée. Je remercie sincèrement Mr L.HEROUS, maître de conférence à l'université de badji mokhtar annaba de m'avoir fait l'honneur de présider mon jury de thèse. Je le remercie également pour m'avoir vivement conseillé ce mémoire au cours de ma recherche sous sa propre direction, ainsi pour nos fructueuses discussions et son implication dans mes travaux. Le regard critique, juste et avisé qu'il a porté sur mes travaux n'a pu que m'encourager à être encore plus perspicaces et engagée dans mes recherches. J'adresse également ma profonde reconnaissance à Mr BELHAMRA.A maître de conférences à l'université de Badji Mokhtar Annaba pour avoir accepté de juger mon travail et de participer à mon jury du mémoire en tant que rapporteurs. J'ai été aussi particulièrement honorée par la présence dans mon jury de Mr LABAR.H et Mr RAZEM.H maîtres de conférences à l'université de Badji Mokhtar Annaba.

Depuis mon arrivée à Annaba, j'ai eu la chance de côtoyer plusieurs personnes qui m'ont assuré les meilleures conditions pour ma réussite. Loin de chez moi, j'ai eu la chance d'être entourée d'un amour familial dans plusieurs occasions. Je tiens à remercier la famille BEN ZEMAMOUCHE pour l'aide et la confiance qu'elle m'a accordées. Egalement j'exprime ma profonde gratitude à Rima pour le soutien qu'elle m'a apporté à tous les niveaux, merci aussi à tous mes amis de longue date. J'exprime ma profonde reconnaissance pour les personnes qui m'ont aidée et accompagnée au cours de mon expérience.... Je ne pourrai terminer cette page sans dire un énorme MERCI à ma famille, qui loin des yeux, certes, a toujours été près de mon cœur. Merci Maman pour ta sagesse, ton amour immense et ton regard plein de fierté... Merci pour ta tendresse, tes prières et d'avoir accepté que je sois loin de toi... Merci Nana, Razika, Saida, Hiba, pour être ce que vous êtes, des sœurs qui, pour le monde entier je ne cesserai pas d'aimer... Tout ce que je suis est le fruit de vos sacrifices et j'espère être toujours à la hauteur. Que le Bon Dieu vous protège... nhebbkom bezzaf bezzaf.

Résumé

La modélisation du déclin de potentiel de surface par la technologie des réseaux de neurones artificiels (RNA) sert principalement à prédire le potentiel du polyéthylène téréphtalate (PET) afin d'améliorer la tenue de ce dernier qui a pu être perturbée par différentes contraintes (température, humidité, tension.....etc.) qu'un isolant peut rencontrer durant son fonctionnement, en effet la température et l'humidité ont un rôle très important dans l'évolution du processus d'écoulement de charges à la surface du (PET). Ces deux paramètres ne contribuent pas de la même manière dans le mécanisme de neutralisation des charges déposées en surface. La température intervient en accélérant ce processus tandis que l'humidité contribue beaucoup plus à son accentuation. La technique des RNA est apparue récemment, elle consiste à prendre l'information comme un ensemble d'exemples qui serviront de base d'apprentissage à un réseau de neurones artificiels. Les avantages des réseaux de neurones étant leur capacité d'apprentissage et de généralisation ainsi que leur architecture les rendant très intéressants pour leur implantation sur machine neuronale. Donc le but de ce travail vise à remonter à des informations climatiques et géométriques selon une approche statistique basée sur le concept des (RNA). Ces derniers constituent une famille d'outils de modélisation statistique supposés reproduire les capacités d'apprentissage et de reconnaissance du cerveau et sont parfois décrits comme un concept d'intelligence artificielle.

Une banque de données statistiques a été constituée et a permis d'entraîner un RNA apte à prédire le déclin de potentiel de surface de PET à partir d'une architecture à quatre entrées, une couche cachée à quatre neurones et une sortie. L'outil ainsi développé est finalement mis à l'épreuve sur une base de test.

MOTS CLES : DPS, décharge couronne négative, PET, RNA, modélisation, apprentissage.

Abstract

Modelling the decline in surface potential by the technology of artificial neural networks (ANN) is used primarily to predict the potential of téréphtalate polyethylene (PET) to improve the performance of the latter that could be affected by different constraints (temperature, humidity, voltage ... etc.) insulation that can be encountered during operation, because the temperature and humidity have an important role in the development process of load flow on the surface of (PET). These two parameters do not contribute equally in the mechanism of neutralization of surface charges filed. The temperature involved in accelerating the process while moisture contributes much more to his accent. The technique of RNA appeared recently, it is to take the information as a set of examples as a basis for learning artificial neural network. The advantages of neural networks is their learning ability and generalization as well as their architecture making them very attractive for their implementation on neuronal machine. So the purpose of this work is to trace climatic and geometric information using a statistical approach based on the concept of (NAS). They constitute a family of tools for statistical modeling supposed to reproduce the learning capabilities and recognition of the brain and are sometimes described as a concept of artificial intelligence.

A statistical database was established and helped train an ANN able to predict the decline of surface potential of PET using an architecture with four inputs, four hidden layer neurons and one output. The tool thus developed is finally tested on a test basis.

KEY WORDS: DPS, Negative corona discharge, PET, RNA, modeling, learning.

ملخص

نمذجة انتشار التوتر على السطح بواسطة تكنولوجيا الشبكة العصبية الاصطناعية تعمل أساسا على توقع التوتر على سطح مادة البوليثيلان تيريفتلات من اجل تطوير غلاف هذا الأخير الذي يمكن أن يتعرض لعدة مؤثرات مثل درجة الحرارة ، الرطوبة و الضغط الخ التي يمكن أن يصادفها أي عازل أثناء عمله ، فعلا عاملي درجة الحرارة و الرطوبة لها دور جد هام في ميكانيزمات انتقال الشحنات على سطح العازل، هذين العاملين لا يؤثران بنفس الكيفية في ميكانيزم تفاعل الشحنات على سطح المادة.

درجة الحرارة تتدخل في تسريع هذا الفعل بينما الرطوبة تؤثر أكثر على الزيادة فيها . ظهرت تكنولوجيا الشبكة العصبية الاصطناعية حديثا، تعمل على أخذ المعلومة على شكل مجموعة من التجارب التي تخدم في مرحلة تعليم الشبكة العصبية الاصطناعية.

إيجابيات هذه التقنية تكمن في قدرتها على التعلم والتعميم كذلك تصميمها الذي يجعلها قادرة على الدمج في أي آلة عصبية. إذا هدف هذا العمل يتجه إلى التطوير من خلال العوامل المحيطة و الجيومترية ب واسطة تقنية الإحصاء المتمثلة في الشبكة العصبية الاصطناعية . مجموعة من المعطيات العددية تكونت ، تعمل على تمرين هذه الشبكة ، قادرة على توقع انتشار التوتر على سطح العازل عن تركيبية مكونة من أربعة مداخل ، طبقة خفية مكونة من أربعة أعصاب، و مخرج وحيد. هذا الأخير تطور و جرب بواسطة مجموعة من الاختبارات.

الكلمات الرئيسية: انتشار التوتر على السطح ، تفريغ كوروني سالب ، تكنولوجيا الشبكة العصبية الاصطناعية ، التعلم، نمذجة.

Table des symboles utilisés

g, f	fonctions de transferts d'un neurone artificiel
a	La sortie d'un neurone artificiel
n	Le niveau d'activation du neurone.
R	Nombre d'entrées d'un neurone.
P	Vecteur des entrées.
b	Le biais du neurone (seuil).
$W:$	Matrice des poids.
S	Nombre de neurones d'une même couche.
W_{ij}	Poids de la connexion.
M	Nombre de couches.
$O(k)$	Sortie réelle du réseau.
$D(k)$	Sortie désirée du réseau.
$E(k)$	Ecart entre réelle et désirée.
A_i, A_j	Activations de deux neurones.
M'	Tau d'apprentissage.
ΔV	Différence de potentiel.
D_0	Ecart entre surface et sonde.
ω	Fréquence angulaire.
D_1	Amplitude des vibrations.
V_0	Potentiel initial.
A	Surface de la sonde.
ϵ	Permittivité absolue = $\epsilon_0 \epsilon_r$.
S_1	Nombre de neurones en couche cachée.

Abréviations Utilisées

(PP)	Polypropylène.
(MLP)	Multilayer perceptron.
(PMC)	Perceptron multicouche.
(LEMD)	Laboratoire d'électrostatique et de matériaux diélectriques
(DPS)	Déclin de potentiel.
(HT)	Haute tension.
(HR)	Humidité relative.
(BT)	Basse tension.
(UHMWPE)	Ultra high molecular weight polyethylene.
(UV)	Lumière ultraviolette.
(MSE)	Mean Squared Error.
(RNA)	Réseau de neurone artificiel.
(PEN)	Polyéthylène naphthalène.
(PEBD)	Polyéthylène basse densité.
(PET)	Polyéthylène téréphtalate.
(PE)	Polyéthylène.
(PS)	Polystyrène.
(PVC)	Poly (chlorure de vinyle).

Table des matières

Remerciement.....	i
Résumé.....	iii
Abstract.....	iv
ملخص.....	v
Table des symboles utilisés.....	vi
Table d'abréviations utilisées.....	vii
Table des matières.....	viii
Liste des figures.....	xiii
Liste des tableaux.....	xvi

Chapitre I

I. Introduction

I.1. Introduction.....	19
I.2. Position du problème.....	21
I.3. Objectifs et plan du mémoire..... ;	21

Chapitre II

II. Généralités sur les diélectriques

II.1. Introduction.....	24
II.2. Définition.....	26
II.3. Matériaux isolants.....	26
II.4. Grandeurs caractéristiques des milieux diélectriques.....	28
II.5. Quelques milieux diélectriques usuels.....	28
II.5.1. Solides.....	28
II.5.2. Gazeux.....	28

II.5.3. Liquides.....	29
II.6. Utilisations des diélectriques.....	29
II.7. Polymère.....	29
II.7.1. Un peu d'histoire.....	29
II.7.2. Définition.....	30
II.7.3. Généralités.....	31
II.7.4 Structure et conformation.....	32
II.8. Exemples d'utilisation d'isolants électriques organiques.....	34
II.9. Comportement des isolants polymères solides sous champ électrique.....	35
II.10. Le polyéthylène téréphtalate.....	35
II.11. Génération de charges à la surface des isolants.....	36
II.11.1. Introduction.....	36
II.11.2. Décharge couronne.....	36
II.12. Conclusion.....	39

Chapitre III

III. Réseaux de neurones artificiels

III.1. Introduction.....	41
III.2. Base biologique.....	42
III.3. Neurone artificiel.....	44
III.3.1. Modèle d'un neurone.....	44
III.3.2. Fonctions d'activations.....	46
III.4. Architecture de réseau.....	48
III.5. Structure d'interconnexion (topologie).....	51
III.5.1. Réseau multicouches.....	51
III.5.2. Réseau à connexions locales.....	52
III.5.3. Réseau à connexions récurrentes.....	52
III.5.4. Réseau a connexions complexes.....	53
III.6. Apprentissage.....	53

III.6.1. Généralités sur l'apprentissage.....	53
III.6.2. Principe général.....	54
III.6.2.1. Apprentissage d'un réseau de neurones.....	54
III.6.2.2. Exemple de la modélisation d'un processus non linéaire.....	55
III.6.2.3. Minimisation de la fonction de coût.....	56
III.6.2.4. L'apprentissage supervisé.....	56
III.6.2.5. L'apprentissage non supervisé	57
III.6.2.6. L'apprentissage par renforcement.....	57
III.6.3. L'apprentissage des réseaux de neurones formels.....	57
III.6.4. Règles d'apprentissage	58
III.6.4.1. La règle de Hebb.....	58
III.6.4.2. La règle de Widrow- Hoff	59
III.7. Le perceptron.....	59
III.7.1. Le perceptron multicouche.....	60
III.7.2. La rétropropagation du gradient.....	60
III.7.2.1. principe.....	60
III.7.2.2. Algorithme.....	61
III.8. Mise en œuvre des réseaux de neurones et domaine d'applications.....	62
III.8.1. La régression non linéaire, ou modélisation de données statiques.....	64
III.8.2. La modélisation de processus dynamiques non linéaires.....	64
III.8.3. La commande de processus.....	64
III.8.4. La classification.....	64
III.9. Conclusion.....	65

Chapitre IV

IV. Théorie de Déclin de Potentiel de Surface

IV.1. Introduction.....	67
IV.2. Phénomènes physiques dans le processus de déclin.....	68
IV.2.1. Conduction de surface.....	69
IV.2.2. Polarisation de l'échantillon.....	69

IV.2.3. Neutralisation par le gaz.....	70
IV.2.4. Phénomènes piézoélectriques.....	70
IV.2.5. Injection de charges.....	71
IV.3. Conclusion.....	72

Chapitre V

V. Techniques expérimentales

V.1. Introduction.....	74
V.2. Mesure du potentiel.....	75
V.2.1. Poste de charge.....	76
V.2.2. Poste de mesure.....	76
V.3. Matériau étudié.....	77
V.4. Mesures utilisées	78
V.4.1. Résultats de l'étude du PET d'épaisseur 0.5 mm.....	78
V.4.1.1. Influence de la température en polarité négative.....	78
V.4.1.2. Influence de l'humidité en polarité négative.....	79
V.4.2. Résultats d'étude du PET d'épaisseur 1 mm.....	80
V.4.2.1. Influence de la température en polarité négative.....	80
V.4.2.2. Influence de l'humidité relative en polarité négative.....	80
V.5. Les réseaux de neurones appliqués aux matériaux.....	81
V.5.1. Modélisation.....	82
V.6. Structuration des données.....	83
V.7. Evaluation de la performance.....	83
V.8. Le réseau de neurones utilisé.....	83
V.9. Simulation.....	85
V.10. Conclusion.....	89

Chapitre VI**VI. Résultats et discussions**

VI.1. Introduction.....	91
VI.2. Résultats d'étude.....	92
VI.2.1. Algorithme d'apprentissage.....	92
VI.2.2. Fonction de transfert.....	92
VI.3. Optimisation de l'architecture du RNA.....	93
VI.3.1. Essai N° : 01 ; Iitr=[1 :4 :q] ; Iival=[4 :4 :q].....	94
VI.3.2. Essai N° : 02 ; Iitr=[1 :2 :q] ; Iival=[2 :3:q].....	97
VI.3.3. Essai N° : 03 ; Iitr=[2 :1 :q] ; Iival=[1:5 :q].....	100
VI.3.4. Essai N° : 04 ; Iitr=[1 :3 :q] ; Iival=[2 :3 :q].....	103
VI.3.5. Essai N° : 05 ; Iitr=[3 :3 :q] ; Iival=[1 :3 :q].....	106
VI.3.6. Essai N° : 06 ; Iitr=[1 :5 :q] ; Iival=[2 :5 :q].....	109
VI.3.7. Essai N° : 07 ; Iitr=[1 :2 :q] ; Iival=[2 :2 :q].....	112
VI.3.8. Essai N° : 08 ; Iitr=[2 :3 :q] ; Iival=[1 :3 :q].....	115
VI.3.9. Essai N° : 09 ; Iitr=[2 :2 :q] ; Iival=[1 :2 :q].....	118
VI.4. Résumé des résultats.....	121
VI.5. Conclusion.....	124

Chapitre VII**Conclusions et Perspectives**

VII.1. Conclusion.....	126
VII.2. Perspectives.....	128
VII.3. Références bibliographiques.....	129

Listes des figures

Chapitre II

Fig II.1 : Les contraintes aux quelles est soumis un système d'isolation.....	27
Fig II.2 : Structure d'un homopolymère.....	33
Fig II.3 : Structure d'un copolymère.....	33
Fig II.4 : Polyéthylène téréphtalate.....	35
Fig II.5 : Schéma d'une décharge couronne en géométrie pointe /plan.....	37

Chapitre III

Fig III.1 : Neurone biologique.....	42
Fig III.2 : Modèle d'un neurone artificiel.....	44
Fig III.3 : Modèle mathématique d'un neurone artificiel.....	45
Fig III.4 : Représentation matricielle du modèle d'un neurone artificiel.....	46
Fig III.5 : Fonctions de transfert : (a) « seuil », (b) « linéaire » ; et (c) « sigmoïde ».....	48
Fig III.6 : Couche de S neurones.....	49
Fig III.7 : Représentation matricielle d'un réseau de trois couches.....	50
Fig III.8 : Réseau multicouche classique.....	51
Fig III.9 : Réseau multicouche à connexions locales.....	52
Fig III.10: Réseau à connexions récurrentes.....	52
Fig III.11: Réseau à connexions complètes.....	53
Fig III.12 : Système d'apprentissage pour la modélisation d'un processus.....	55
Fig III.13 : Un PMC à 1 couche cachée avec 5 entrées, 3 en couche cachée et 5 sorties.....	61
Fig III.14 : Le "surajustement".....	63

Chapitre IV

Fig IV.1 : Caractéristique du DPS du polyéthylène par décharge couronne [Ied67].....	68
Fig IV.2 : Conduction de surface.....	69
Fig IV.3 : Polarisation de l'échantillon.....	69
Fig IV.4 : Neutralisation par le gaz.....	70
Fig IV.5 : Phénomène piézoélectrique.....	70

Fig IV.6 : Injection de charges.....	71
--------------------------------------	----

Chapitre V

Fig V.1 : Poste de charge.....	76
Fig V.2 : Poste de mesure.....	76
Fig V.3 : Organigramme résume la mesure de PS après un dépôt de charge par décharge couronne...	77
Fig V.4 : Effet de la température sur le DPS en polarité négative avec $\epsilon=0.5\text{mm}$	79
Fig V.5. Effet de l'humidité relative sur le DPS avec $\epsilon=0.5\text{ mm}$	79
Fig V.6 : Effet de la température sur le DPS en polarité négative avec $\epsilon=1\text{ mm}$	80
Fig V. 7 : Effet de l'humidité relative sur le DPS avec $\epsilon=1\text{ mm}$	81
Fig V.8 : Perceptron multicouche PMC.....	84
Fig V.9 : Représentation de réseaux de neurones sur MATLAB.....	87
Fig V.10 : Comparaison entre les deux algorithmes.....	88

Chapitre VI

Fig VI.1 : Graphes caractéristiques des fonctions d'activation (<i>nomenclatures Matlab</i>).....	93
Fig VI.2 : Prédiction du DPS par les PMCs à 6 et 7 neurones : $iitr=[1 :4 :q]$; $lival=[4 :4 :q]$	95
Fig VI.3 : Corrélacion entre les DPS mesurés et prédits par les PMC à 6 et 7 neurones.....	96
Fig VI.4 : Prédiction du DPS par les PMCs à 4 et 10 neurones : $iitr=[1 :2 :q]$; $lival=[2 :3 :q]$	98
Fig VI.5 : Corrélacion entre les DPS mesurés et prédits par les PMCs à 4 et 10 neurones.....	99
Fig VI.6 : Prédiction du DPS par les PMCs à 3 et 4 neurones : $iitr=[2 :1 :q]$; $lival=[1 :5 :q]$	101
Fig VI.7 : Corrélacion entre les DPS mesurés et prédits par les PMC à 3 et 4 neurones.....	102
Fig VI.8 : Prédiction du DPS par les PMCs à 3 et 10 neurones : $iitr=[1 :3 :q]$; $lival=[2 :3 :q]$	104
Fig VI.9 : Corrélacion entre les DPS mesurés et prédits par les PMC à 3 et 10 neurones.....	105
Fig VI.10 : Prédiction du DPS par les PMCs à 9 et 12 neurones : $iitr=[3 :3 :q]$; $lival=[1 :3 :q]$..	107
Fig VI.11 : Corrélacion entre les DPS mesurés et prédits par les PMC à 9 et 12 neurones.....	108
Fig VI.12 : Prédiction du DPS par les PMCs à 6 et 14 neurones : $iitr=[1 :5 :q]$; $lival=[2 :5 :q]$..	110
Fig VI.13 : Corrélacion entre les DPS mesurés et prédits par les PMC à 6 et 14 neurones.....	111
Fig VI.14 : Prédiction du DPS par les PMCs à 6 et 7 neurones : $iitr=[1 :2 :q]$; $lival=[2 :2 :q]$	113
Fig VI.15 : Corrélacion entre les DPS mesurés et prédits par les PMC à 6 et 7 neurones.....	114
Fig VI.16 : Prédiction du DPS par les PMCs à 6 et 13 neurones $iitr=[2 :3 :q]$; $lival=[1 :3 :q]$	116
Fig VI.17 : Corrélacion entre les DPS mesurés et prédits par les PMC à 6 et 13 neurones.....	117

Fig VI.18 : Prédiction du DPS par les PMCs à 4 et 8 neurone $l_{itr}=[2 : 2 : q]$; $l_{ival}=[1 : 2 : q]$	119
Fig VI.19 : Corrélation entre les DPS mesurés et prédits par les PMC à 4 et 8 neurones.....	120
Fig VI.20 : Analyse comparative de la prédiction du DPS par les 9 modèles à la base du test....	123

Liste des tableaux

Tab II.1: Exemples d'utilisation des isolants organiques solides.....	34
Tab III.1 : Les différentes fonctions de transferts.....	47
Tab V.1 : Etude comparative entre les 2 algorithmes Levenberg-M et S. conjugate gradient.....	86
Tab VI.1 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[1 :4 :q]$; $I_{ival}=[4 :4 :q]$	94
Tab VI.2 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[1 :2 :q]$; $I_{ival}=[2 :3:q]$	97
Tab VI.3 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[2 :1 :q]$; $I_{ival}=[1:5 :q]$	100
Tab VI.4 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[1 :3 :q]$; $I_{ival}=[2 :3 :q]$	103
Tab VI.5 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[3 :3 :q]$; $I_{ival}=[1 :3 :q]$	106
Tab VI.6 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[1 :5 :q]$; $I_{ival}=[2 :5 :q]$	109
Tab VI.7 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[1 :2 :q]$; $I_{ival}=[2 :2 :q]$	112
Tab VI.8 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[2 :3 :q]$; $I_{ival}=[1 :3 :q]$	115
Tab VI.9 : Erreurs des trois bases de données pour $S_1=3$ à 20 $I_{itr}=[2 :2 :q]$; $I_{ival}=[1 :2 :q]$	118
Tab VI.10 : Représentation des meilleurs résultats.....	121
Tab VI.11 : Prédiction de 9 modèles sur la base du test.....	121

Chapitre I

Introduction

I. Introduction

Avec l'avènement des mini, micro et nano technologies dans l'ère du « tout électrique », le domaine de génie électrique demeure l'un des principaux domaines scientifiques qui réclame actuellement de plus en plus d'investigation. En effet la majorité des technologies, actuelles et futures, utilisées dans nos sociétés est dépendante de l'énergie électrique. On conçoit alors que la fiabilité des systèmes électriques, quels que soient les contraintes auxquelles ils sont soumis, fasse l'objet de nombreux travaux de recherche. Les matériaux, au sens large, ont joué un rôle prépondérant dans les progrès faits par les matériels électriques et les matériaux isolants sont parmi ceux dont le choix et l'emploi posent les problèmes les plus délicats à résoudre dans la conception, la réalisation et l'exploitation des systèmes électriques. La modélisation du processus de vieillissement des isolants organiques solides sous champ électrique intense ou l'évolution des charges électrostatiques sur la surface des matériaux isolants constitue le principal intérêt de notre présent travail. Malgré les différents avantages qu'offre l'utilisation de ces matériaux dans l'isolation électrique, l'expérience montre que pour de nombreuses raisons ces isolants ont des défaillances qu'ils soient utilisés sous champs continus ou alternatifs. C'est dans le but d'améliorer leur fiabilité qu'un nombre important de travaux ont été entrepris dans les laboratoires de recherches. Ces travaux ont pour but de comprendre les défaillances en prenant en compte les contraintes d'utilisation, mais aussi d'améliorer les paramètres de mise en œuvre. La fonction d'isolation est primordiale du fait qu'elle est l'une des conditions fondamentales du fonctionnement des matériels de production, de transport et de distribution d'énergie électrique. Depuis 1995, les travaux sur le sujet de vieillissement électrique ont connu des progrès considérables. En effet, le « temps de vie » des isolants polymères sous haute tension étant estimé à 30 ans, la majorité des systèmes de transport d'énergie électrique posés dans les années 1980 s'approchent de leur fin de service. Les enjeux sont importants et le travail présenté dans ce manuscrit vise une compréhension des phénomènes se rapportant à la dégradation sous champ électrique, des modèles neuronaux sont développés pour la prédiction du déclin de potentiel de surface, avant toute apparition de fracture du matériau qui, lorsqu'elle se produit, provoque rapidement une perte de fiabilité de l'isolant.

Le rôle essentiel des isolants étant de servir de barrière, on s'intéressera en premier lieu à leurs propriétés électriques.

Aucun isolant n'étant parfait, on est tout d'abord conduit à étudier les mécanismes de conduction dans les isolants solides qui débouchent sur les notions de résistance d'isolement et de résistivités.

Les phénomènes qui font qu'un isolant solide présentant des caractéristiques satisfaisantes à court terme peut voir celles-ci se dégrader à long terme sous l'effet du champ électrique avec, pour conséquence, un claquage diélectrique.

Un autre facteur de dégradation des isolants à long terme, surtout lorsqu'il s'agit de matériaux synthétiques, est la température. Or, tout matériel électrique ou électronique est le siège d'un échauffement dès qu'il est sous tension par suite des pertes par effet Joule dans les conducteurs, des pertes dans les circuits magnétiques et des pertes diélectriques dans les isolants eux-mêmes. De nombreuses autres contraintes d'environnement (par exemple l'humidité, les UV, les rayonnements de haute énergie,...) peuvent contribuer au vieillissement des matériaux isolants solides.

Les matériaux isolant sont soumis au cours de leur vie à de nombreuses contraintes pouvant influencer leur comportement à long terme. Leur rigidité diélectrique évolue dans le temps et dépend des différents mécanismes (possibles) de dégradation sous champ électrique. Les modes de défaillances des isolants comme ceux de type époxydes peuvent être d'origine thermique (Casale, 2001) (rupture thermique), d'origine électrique (Champion and Dodd, 1995) (décharges partielles, arborescences électriques) ou d'origine électromécanique. Ces différentes ruptures sont provoquées par la formation de canaux conducteurs.

La formulation de matériaux industriels est un domaine d'excellence des réseaux de neurones artificiels (RNA), il s'agit en effet de prédire des propriétés physiques (mécaniques, électroniques, thermodynamiques, etc.) ou chimiques (température d'ébullition, solubilité, etc.) en fonction de leur composition. Pour des propriétés et des matériaux importants, il existe des bases de données issues d'expériences industrielles ou universitaires, on peut donc utiliser les capacités de régression non linéaire parcimonieuse des réseaux de neurones pour effectuer ces prédictions.

Alors, Qu'est-ce qu'un Réseau de Neurones Artificiel ?

Les réseaux de neurones artificiels (RNA) constituent un outil statistique visant à reproduire les capacités d'apprentissage et de reconnaissance du cerveau. Ils appartiennent à la classe des méthodes statistiques non paramétriques (les paramètres des modèles ajustés n'ayant pas de sens physique). Parfois décrits comme un concept d'intelligence artificielle, les RNA sont de plus en plus utilisés du fait de leur simplicité et de leur capacité de résolution des problèmes complexes. Selon Dreyfus [Dreyfus et al. 2004], « l'avantage des RNA par rapport aux autres méthodes réside

dans leur capacité à réaliser des modèles de précision équivalente avec moins de données expérimentales ou dans leur capacité à constituer des modèles plus précis à partir du même nombre d'exemples. ». L'intérêt des RNA repose principalement sur leur parcimonie et leur capacité à dissocier des effets conjugués.

I.2. Position du problème

Notre problématique consiste à trouver un modèle paramétrique neuronal à partir de certains paramètres physico-chimiques d'entrée et nous devons évaluer sous forme d'une courbe l'évolution d'une charge déposée sur la surface d'un Polyéthylène téréphtalate (PET) comme paramètres de sortie du réseau à réaliser. Donc, il y a ici un problème de régression (apprentissage supervisé) ou bien on appelle aussi un problème d'estimation.

Expérimentalement, nous devons enregistrer une "base de données (couple : entrées-sorties)" sous forme matricielle, chaque entrée (composé de plusieurs paramètres (température, humidité, tension, épaisseur...) avec leur sortie). Le module d'apprentissage, supervisé, permet de collecter de manière continue les paramètres relatifs aux différents états, pour la mise en œuvre d'une base de données complète.

I.3. Objectifs et plan du mémoire

Notre travail consiste à essayer de comprendre l'évolution des charges déposées sur la surface du Polyéthylène téréphtalate (PET) par décharge couronne négative. En effet, les résultats nous permettront de définir le mécanisme de vieillissement pouvant entraîner la perte des caractéristiques du matériau. La compréhension de ces phénomènes permettra aux industriels d'améliorer par des procédés de polymérisation la tenue de ce matériau face à ces contraintes et d'améliorer la durée de vie.

Le deuxième objectif de ce travail est de montrer comment, à partir des notions fondamentales, il est possible d'aboutir à une véritable méthodologie de mise en œuvre, notamment dans le cadre de la modélisation des processus. Nous montrons en particulier que, contrairement à une croyance répandue, les réseaux de neurones ne sont pas nécessairement des « boîtes noires » : bien au contraire, il est parfaitement possible, et même vivement recommandé, d'introduire dans le réseau de neurones, dès sa conception, toutes les connaissances mathématiques disponibles concernant le processus à modéliser ou à commander.

L'exposé des travaux qui suivent se déroule de la manière suivante :

Le premier chapitre présente une introduction générale définit qu'est-ce qu'un réseau de neurones artificiel et présente la problématique du travail ainsi l'objectifs et le plan du mémoire.

Le chapitre II, présente des généralités sur les diélectriques : définition, utilisations et caractéristiques des milieux diélectriques, et plus particulièrement les polymères (Polyéthylène téréphtalate (PET)) qui est le matériau de notre étude. Il expose aussi le phénomène de chargement électrostatique obtenu par une décharge couronne négative.

Le troisième chapitre rappelle les définitions, et introduit la propriété essentielle des réseaux de neurones : la propriété d'approximation universelle parcimonieuse. Nous remplaçons ainsi les réseaux de neurones dans le contexte mathématique approprié, qui est celui de la régression non linéaire. Nous introduisons les notions nécessaires pour mettre en œuvre les algorithmes d'apprentissage ; nous insistons sur le caractère générique des algorithmes d'apprentissage, qui constitue l'un des atouts des réseaux de neurones dans le domaine de la modélisation. Nous abordons ensuite le domaine d'application essentiel des réseaux, celui de la modélisation de processus ; nous décrivons, et justifions mathématiquement, une méthodologie pour le choix de la structure d'un modèle neuronal. La fin du chapitre décrit des applications mettant en œuvre les réseaux de neurones artificiels.

Le chapitre IV est consacré à la construction de la banque de données expérimentales nécessaire au développement des modèles neuronaux. Il présente également une analyse qualitative des relations expérimentales observées entre déclin de potentiel de surface et contraintes climatiques, électriques et géométriques des échantillons de PET.

L'entraînement des PMC, souvent considéré comme délicat, est l'objet d'une étude plus approfondie au chapitre V. Plusieurs méthodes permettant d'accélérer leur phase d'apprentissage sont décrites, et une étude comparative des algorithmes est présentée. Bien que l'algorithme de Levenberg-Marquardt s'avère être très performant. Le perceptron multicouche à une seule couche cachée apparaît alors comme étant celui offrant la meilleure qualité de prédiction.

Pour obtenir un modèle optimal de perceptron multicouches délivre une bonne prédiction du déclin de potentiel de surface de PET, un ensemble d'essais est effectué au chapitre VI, plusieurs architectures sont examinées en changeant le nombre de neurones en couche cachée, ainsi les deux intervalles d'apprentissage et de validation. Ce chapitre décrit les différentes étapes de la construction des modèles neuronaux. L'importance de l'application, à la prédiction du déclin de potentiel de surface, d'un perceptron à une couche cachée avec un apprentissage supervisé, est également mise en évidence.

Enfin, les conclusions et les perspectives de ce travail sont présentées dans le chapitre VII.

**Généralités sur
les diélectriques**

II. Généralités sur les diélectriques

II.1. Introduction

Tout matériel électrique ou électronique est constitué d'un agencement judicieux de matériaux conducteurs qui servent à transporter l'énergie électrique (ou l'information) là où elle doit être utilisée et de matériaux isolants qui permettent d'empêcher celle-ci de se perdre en empruntant le plus « court » chemin d'un potentiel à un autre. Outre leur fonction première qui est de s'opposer au passage du courant entre conducteurs, les isolants solides ont également le rôle de maintenir mécaniquement les conducteurs dans des conditions prédéterminées.

Dans certains cas, la quantité de matériaux isolants solides utilisée est réduite à l'extrême : par exemple pour les lignes électriques aériennes en conducteurs nus.

Mais dès que l'on cherche à réduire l'encombrement d'un matériel (préoccupation permanente aujourd'hui), on est amené à rapprocher les conducteurs, et par conséquent à les maintenir rigidement en place pour éviter qu'ils ne viennent en contact sous l'effet de leur propre poids, de déformations, de forces extérieures au matériel ou des efforts électrodynamiques internes. Les matériaux isolants solides peuvent être employés seuls (comme, par exemple, dans le cas d'un câble à isolation synthétique extrudée), en association de plusieurs solides (bobinage réalisé en fil émaillé imprégné de résine thermodurcissable) ou en association d'un solide et d'un liquide (isolation en papier imprégné d'huile minérale pour les transformateurs à haute tension). Dans ces deux derniers cas, on parle de système d'isolation.

Lorsque l'on augmente la valeur du champ électrique appliqué à un isolant, on aboutit à un mécanisme destructif irréversible appelé claquage diélectrique.

La grande majorité des matériels électriques ou électroniques fonctionnant sous des tensions alternatives, l'étude des phénomènes de polarisation et de relaxation qui en découlent est abordée au chapitre où sont présentées les notions relatives à la permittivité qui joue un rôle très important lorsqu'il s'agit de stocker de l'énergie dans un condensateur ou, au contraire, de réduire des capacités parasites.

Les matériaux solides couramment utilisés comme isolants peuvent être classés en différentes familles :

- les isolants minéraux : verre, céramique,... ;
- les isolants naturels : cellulose ou latex ;
- les polymères thermoplastiques ;
- les polymères thermodurcissables ;
- les élastomères.

Les propriétés des matériaux isolants, et tout particulièrement leurs propriétés électriques, dépendent de divers paramètres. Parmi ceux-ci, deux sont à considérer en premier lieu :

- l'état hygrométrique de l'isolant.
- les impuretés contenues dans les matériaux.

Il faut citer d'abord le rôle primordial que joue l'état hygrométrique de l'isolant sur la plupart de ses caractéristiques électriques.

La quantité d'eau que peut retenir un matériau isolant donné est une fonction croissante de l'humidité relative du milieu ambiant avec lequel il est en équilibre (la loi de Henry se trouve généralement vérifiée en première approximation) et de la température à laquelle il est soumis. De très grandes différences existent en outre entre l'hygroscopicité des matériaux suivant leur nature chimique.

Les propriétés électriques des isolants sont affectées de façon sensible, voire considérable, non seulement par la quantité d'eau emmagasinée, mais également par sa répartition dans le volume du matériau ou de l'isolation.

Compte tenu des constantes de temps très élevées qui régissent les échanges d'eau dans les solides, il est rare qu'un objet ou une éprouvette soit en équilibre d'humidité avec le milieu ambiant, donc que la concentration en eau soit uniforme à l'intérieur de son volume, tout particulièrement dans le cas de fortes épaisseurs. De cela résulte, dans la plupart des cas, une influence de l'histoire hygrométrique antérieure du matériau sur son comportement diélectrique. Une valeur d'une propriété quelconque d'un isolant ne peut être considérée comme représentative de celui-ci que dans la mesure où les conditions hygrométriques auxquelles il a été soumis préalablement et pendant sa détermination sont précisées.

C'est pour cette raison que la plupart des caractéristiques électriques sont mesurées après que les matériaux ont été soumis à un conditionnement normalisé. La publication 212 de la CEI définit un certain nombre d'atmosphères préférentielles (température et humidité relative), ainsi que les durées recommandées pour le conditionnement des matériaux dans ces atmosphères. Des préconditionnements, visant à effacer l'histoire antérieure des éprouvettes, sont parfois conseillés.

II.2. Définition

Un matériau est diélectrique s'il ne contient pas de charges électriques susceptibles de se déplacer de façon macroscopique. Autrement dit, c'est un milieu qui ne peut pas conduire le courant électrique. À ce titre, on l'appelle parfois isolant électrique. On compte parmi ces milieux le vide, le verre et de nombreux plastiques. Par exemple, les câbles électriques sont souvent protégés d'un revêtement en plastique pour éviter que le courant électrique puisse en sortir.

Malgré l'impossibilité des milieux diélectriques de conduire le courant, ils présentent de nombreuses caractéristiques électriques. En effet les atomes qui constituent le matériau peuvent présenter des dipôles électrostatiques qui sont susceptibles d'interagir avec un champ électrique. Cette interaction se traduit par la création d'une polarisation reliée à ce champ électrique, au niveau microscopique, par une polarisabilité, et au niveau macroscopique, par la susceptibilité électrique.

II.3. matériaux isolants

Les matériaux isolants trouvent des applications dans un grand nombre de dispositifs de production, de transport, de distribution et d'utilisation de l'énergie électrique. Ils ont joué un rôle prépondérant dans les progrès faits par les matériels électriques. Ils constituent sans aucun doute les facteurs clés du développement des matériels électrotechniques de demain.

Les matériaux utilisés aujourd'hui sont extrêmement nombreux et variés. Le choix et l'emploi posent les problèmes les plus délicats, il doit répondre à un processus complexe. Le plus difficile à maîtriser est non seulement l'interaction de toutes les contraintes que peuvent influencer sur la tenue du système d'isolation mais aussi de l'impact sur l'environnement et la sécurité des biens et des personnes.

Les contraintes auxquelles est soumis un système d'isolation sont :

- **Contraintes électriques** : champ électrique, charge d'espace, décharge partielle, arborescence électrique, etc....
- **Contraintes thermiques** : échauffement des conducteurs par effet joule et par effet de Foucault, pertes magnétiques (transformateur), pertes diélectriques, etc....
- **Contraintes mécaniques** : effort sur les conducteurs, forces dues aux mouvements (machines tournantes), vibrations, forces de charge (isolateur de ligne), etc....
- **Contraintes climatiques** : rayonnement solaire, intempéries, pollutions (marine, industrielle), humidité, pluie, gel, air, ozone, etc....
- **Contraintes radiatives** : dans les applications nucléaires, spatiale, médicale, résistants aux rayonnement, etc..
- **Contraintes environnementales** : impact sur l'environnement en termes de rejet de toute nature (gazeux, solides, liquides), la toxicité des produits, traitement en fin de vie (recyclage), etc....

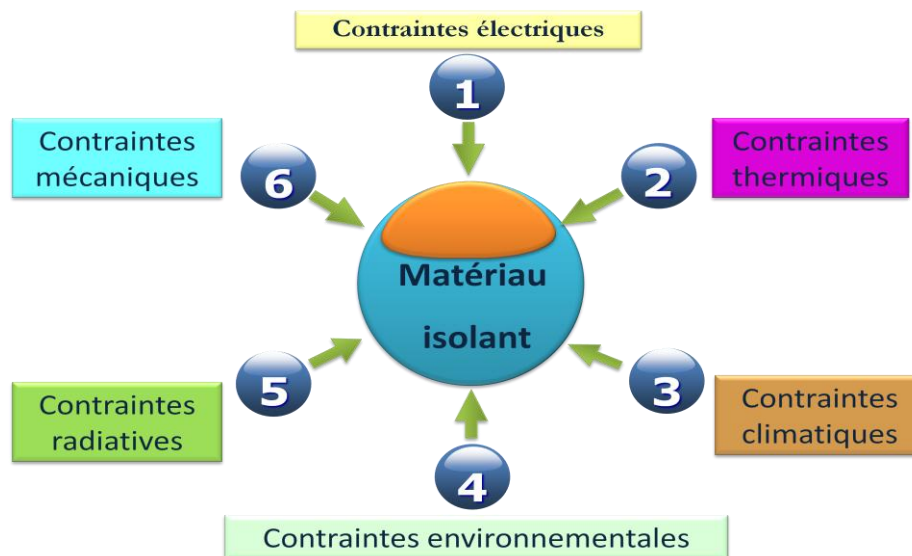


Fig II.1 : Les contraintes aux quelles est soumis un système d'isolation.

Les matériaux isolants se présentent selon leurs états sous diverses formes (solides, liquides, gazeux). On les regroupe en deux catégories principales selon leur nature : les matériaux organiques et les matériaux minéraux ou inorganiques.

Les matériaux naturels ou synthétiques utilisés jusqu'alors comme isolants électriques ont été très largement supplantés par des produits issus de la pétrochimie, en général des polymères. La possibilité de produire simplement les formes les plus variées au moindre coût a été pour beaucoup dans leur succès, ils sont également des matériaux qui présentent les pertes les plus faibles et les tensions de claquages les plus élevées.

II.4. Grandeurs caractéristiques des milieux diélectriques

Les matériaux diélectriques sont caractérisés en particulier par :

- leur rigidité diélectrique.
- leur permittivité diélectrique ϵ .
- leur angle de perte ou tangente delta.

II.5. Quelques milieux diélectriques usuels

II.5.1. Solides

- Le verre : utilisé pour faire des isolateurs de lignes haute tension ;
- La céramique : très utilisée pour les matériels des postes électriques ;
- La plupart des plastiques : en particulier polyéthylène sous sa forme réticulée (XLPE) et PVC, tous les deux sont utilisés pour les câbles ;
- Le Polypropylène : utilisé en particulier dans les condensateurs ;
- Le mica : qui n'est guère plus utilisé de nos jours dans l'industrie électrotechnique ;
- La bakélite : autrefois très utilisée pour l'appareillage électrique basse tension ;
- Le téflon : utilisé pour certaines pièces des disjoncteurs à haute tension ;
- Certains matériaux sous forme cristalline perovskite comme le PZT qui sont actuellement en cours de développement pour être utilisés comme condensateur à capacité variable ;

II.5.2. Gazeux

- L'air ;
- L'hexafluorure de soufre ;
- L'azote ;

II.5.3. Liquides

- Le pyralène : autrefois utilisé dans les transformateurs, mais qui tend à disparaître à cause de ses risques ;
- L'huile minérale : qui a remplacé le pyralène dans les transformateurs ;
- L'eau pure : si l'eau usuelle est conductrice, une eau parfaitement pure est un très bon isolant. La difficulté de garder une eau très pure rend toute utilisation industrielle difficile.

II.6. Utilisations des diélectriques

Les diélectriques étant de bons isolants électriques et thermiques, et sont donc utilisés pour gainer les câbles électriques afin d'éviter des contacts avec d'autres câbles ou des personnes aussi bien que dans les manches des casseroles.

Les diélectriques sont utiles dans les condensateurs. Dans le cas, très simple, du condensateur plan, on peut rapprocher les plaques sans risque de contact ou de claquage. On insère ainsi des couches de diélectriques dans les condensateurs industriels, ce qui permet d'augmenter la capacité en diminuant l'encombrement.

D'autre part, si on la soumet à un champ électrique suffisamment puissant, toute substance s'ionisera et deviendra conductrice. Les diélectriques étant plutôt difficiles à ioniser, l'air ambiant devient conducteur avant eux : on peut les employer pour des condensateurs à haute tension.

La plupart des diélectriques sont également transparents dans de larges gammes de fréquences, et sont parfois utilisés pour constituer une couche anti-reflet, par exemple sur certains modèles de verres de lunette.

II.7. Polymère

II.7.1. Un peu d'histoire...

Les matériaux polymères appelés aussi matériaux plastiques ou simplement plastiques sont constitués de la répétition d'un grand nombre d'unités constitutives appelées monomères. Ces derniers sont des molécules organiques comprenant un ou plusieurs atomes de carbone. 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. Le terme plastique souligne plus fortement le caractère de matériau de synthèse fini.

Bien que les matières plastiques soient considérées comme matériaux modernes, elles ont une histoire d'un siècle et demi. Les polymères sont nés de la recherche scientifique intensive du XX^e siècle. Dès le milieu des années 1920, les bases scientifiques nécessaires à leur développement ultérieur étaient fondées. Avec l'invention de la première résine synthétique, la bakélite (résine phénolique qui durcit sous l'effet de la pression et de la chaleur), Baekeland posa la première « pierre » dans le domaine de la production en grande série de pièces en matière thermodurcissable. A cette époque, ces matières étaient essentiellement connues pour leurs intérêts en électrotechnique. Un développement remarquable, surtout pour les thermoplastiques, a été observé à partir de 1926 avec les travaux du chimiste allemand Staudinger. Celui-ci mit en évidence, lors de ses investigations, que les matières plastiques sont effectivement formées de longues chaînes moléculaires, appelées macromolécules. Ce concept constitue encore aujourd'hui la base scientifique de l'étude systématique des matières plastiques. Une nouvelle impulsion importante pour le développement des matières plastiques survint à partir du milieu des années 1950 avec la conversion d'une matière première, le charbon, en dérivés pétrochimiques. Les principaux thermoplastiques dérivés sont le polypropylène (PP), le polyéthylène (PE), le polystyrène (PS) et le poly(chlorure de vinyle) (PVC). A partir de cette découverte, ces matières ont pu être produites d'une manière plus économique. En France, 6 % environ de la totalité des produits pétroliers sortant de raffinerie sont utilisés dans l'industrie des matières plastiques.

Les matières plastiques importantes à l'échelle industrielle correspondent à 30 ou 40 types de polymères différents, proposés selon 13 000 combinaisons et sous 25 000 marques commerciales environ [EHR 00]. D'une grande variété, ces matériaux ont rapidement envahi le domaine de l'isolation électrique. Les câbles et les gaines représentent environ 2 % de la consommation mondiale annuelle en plastique ; équivalent à 134 400 tonnes de matériaux [SYN 03]. Notons qu'une grande partie des matières plastiques a la capacité d'être recyclée diminuant ainsi leur impact sur l'environnement.

II.7.2. Définition

Le polymère est un mot qui vient du grec « pollus » plusieurs, et « meros » partie.

Un polymère est une macromolécule, organique ou inorganique, constituée de l'enchaînement répété d'un même motif, le monomère (du grec monos : un seul ou une seule, et meros ; partie), reliés les uns aux autres par des liaisons covalentes.

Un corps formé de polymères peut se présenter sous forme liquide ou solide à température ambiante.

Un polymère peut être naturel (exemple : polysaccharides, ADN), obtenu par modification chimique d'un polymère naturel (exemple : méthylcellulose), ou bien entièrement synthétisé par voie chimique (ex.: polystyrène, polyisoprène) par une réaction de polymérisation.

L'enchaînement des monomères peut se faire de façon linéaire (polymères linéaires), présenter des ramifications aléatoires (polymères branchés) ou systématiques et régulières (dendrimères).

Du fait des degrés de liberté de la conformation de chaque monomère, la conformation tridimensionnelle du polymère résulte de cet enchaînement mais également des interactions entre monomères.

II.7.3. Généralités

Les polymères peuvent être fabriqués à partir d'un seul type de monomère (on parle alors d'homopolymère, comme par exemple le polystyrène); ou bien à partir de plusieurs types de monomères (on parle alors de copolymères, comme par exemple l'acrylonitrile butadiène styrène).

On distingue deux grandes catégories de réactions chimiques permettant la préparation des polymères : la polymérisation en chaîne ou polyaddition (pour produire par exemple le polyéthylène, le polystyrène, le polypropylène...) et la polymérisation par étapes ou polycondensation (pour produire par exemple le PET ou polyéthylène téréphtalate).

Les polymères sont souvent classés d'après leurs propriétés thermomécaniques. Citons notamment :

- Les thermoplastiques, qui deviennent malléables quand ils sont chauffés ce qui permet leur mise en œuvre ;
- Les thermodurcissables, qui durcissent sous l'action de la chaleur ou par ajout d'un additif ;
- Les élastomères, qui sont déformables de manière réversible.

Les polymères sont devenus l'élément essentiel d'un nombre très important d'objets, dans lesquels ils ont souvent remplacé les substances naturelles. Le terme désigne des matières abondantes et variées : des protéines les plus ténues aux fibres de kevlar haute résistance. Certains

polymères sont utilisés en solution comme par exemple dans les shampooings ; d'autres forment des matériaux solides. Pour ces applications, les polymères sont généralement mélangés à d'autres substances - des charges telles que la silice, des additifs tels que les antioxydants - dans des opérations de formulation. La fabrication des objets eux-mêmes résulte la plupart du temps d'une opération de mise en œuvre dans un procédé industriel qui relève du domaine de la plasturgie.

La description des polymères en tant qu'objet physique permettant de comprendre leurs propriétés relève de la physique statistique.

II.7.4 Structure et conformation

II.7.4.1. Séquence primaire

Les polymères sont des macromolécules, résultant de l'enchaînement covalent (voir liaison covalente) de "motifs de répétition" identiques ou différents les uns des autres. La masse molaire de ces molécules dépasse souvent 10 000 g/mol. Les liaisons covalentes constituant le squelette macromoléculaire sont le plus souvent des liaisons carbone-carbone (cas du polyéthylène, du polypropylène...), mais peuvent également résulter de la liaison d'atomes de carbone avec d'autres atomes, notamment l'oxygène (cas des polyéthers et des polyesters) ou l'azote (cas des polyamides). Il existe aussi des polymères pour lesquels l'enchaînement résulte de liaisons ne comportant pas d'atomes de carbone (polysilanes, polysiloxanes, etc...)

Cet enchaînement de motifs répétés présente chez les polymères les plus simples une structure linéaire, un peu comme un collier de perles. On peut également rencontrer des branches latérales (elles mêmes plus ou moins branchées), résultant soit d'une réaction chimique parasite au cours de la synthèse du polymère (par exemple dans le cas du polyéthylène basse densité ou PEBD), soit d'une réaction de greffage pratiquée volontairement sur le polymère pour en modifier les propriétés physico-chimiques.

Dans le cas où la macromolécule est composée de la répétition d'un seul motif – ce qui résulte le plus souvent de la polymérisation d'un seul type de monomère, on parle d'homopolymères. Un homopolymère peut posséder 3 structures différentes : linéaire, ramifiée ou réticulée.

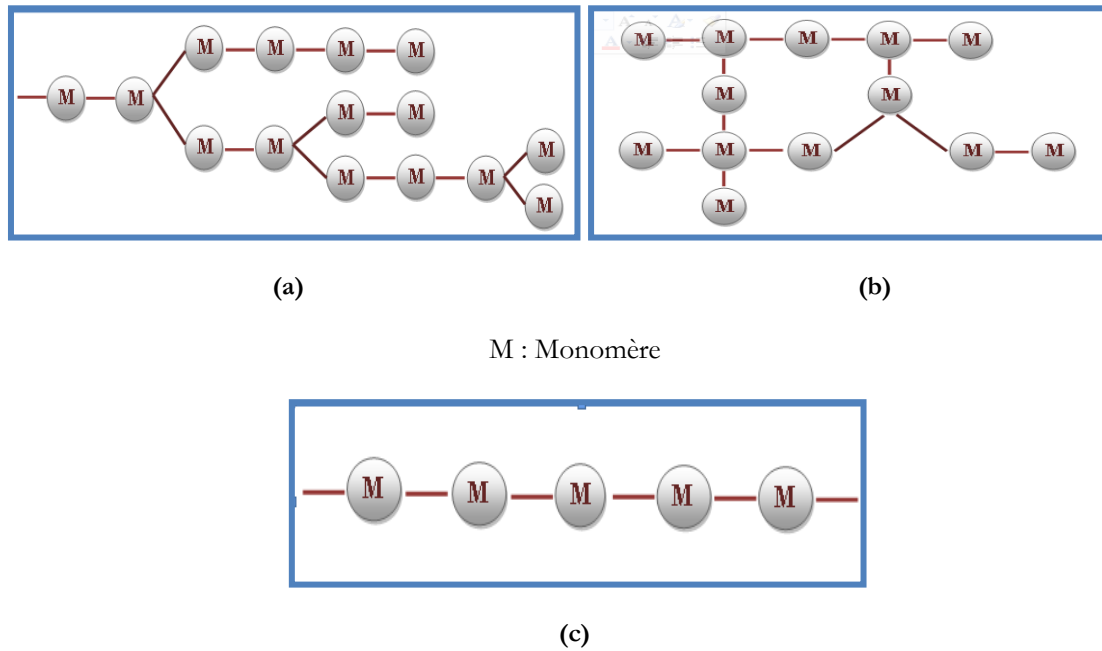


Fig II.2 : Structure d'un homopolymère a. ramifiée, b. réticulée, c. linéaire.

Quand plusieurs motifs différents sont répétés, on parle de copolymères. On distingue ensuite plusieurs types de copolymères suivant l'organisation entre les différents monomères. Dans le cas le plus fréquent, on a un copolymère statistique où les différents monomères se mélangent en fonction de la réactivité et de la concentration de ceux-ci. Les propriétés mécaniques sont alors moyennées. En revanche, dans un copolymère séquencé (l'anglicisme copolymère à blocs est parfois utilisé) ou copolymère alterné, il peut y avoir combinaison des propriétés mécaniques.



Fig II.3 : Structure d'un copolymère.

Il existe parfois des liaisons covalentes vers d'autres morceaux de chaînes polymères. On parle alors de molécules "branchées" ou ramifiées. On sait synthétiser par exemple des molécules en 'peigne' ou en 'étoile'. Lorsque de nombreuses chaînes ou chaînons ont été réunis par un certain nombre de liaisons covalentes, elles ne forment plus qu'une macromolécule gigantesque ; on parle alors de réseau macromoléculaire ou de gel.

II.8. Exemples d'utilisation d'isolants électriques organiques

Dans le domaine électrique, le champ d'application des isolants organiques solides (les polymères) est étendu : lignes de transport d'énergie, câbles de télécommunication, condensateurs, alternateurs, moteurs électriques, systèmes électroniques et composants de puissance terrestres et embarqués sur satellites... L'utilisation de ces matériaux dans l'isolation électrique présente plusieurs avantages tels que : d'excellentes propriétés électriques (résistivité, rigidité, permittivité), une bonne tenue mécanique et tribologique et une stabilité dimensionnelle. Ajoutons à cette liste, la mise en œuvre facile, le faible poids et pour certains la possibilité de recyclage. Le Tableau II.1 présente quelques exemples d'utilisation d'isolants organiques solides dans les systèmes de génie électrique.

Tableau II.1: Exemples d'utilisation des isolants organiques solides.

Exemples de polymères isolants	Applications
Polyéthylène (PE)	Câbles HT, HF
Polyéthylène réticulé (PR)	Câbles THT
Polychlorure de vinyle (PVC)	Câbles BT
Polypropylène (PP)	Condensateurs de puissance
Polyéthylène téréphtalate (PET)	Condensateurs de puissance
Polyéthylène naphthalène (PEN)	Câbles, condensateurs
Polysulfones, polyéther-éther-cétones (PEEK)	Accessoires électriques automobiles
Polyépoxy	Electrotechnique : entretoise, moteurs, isolateurs
Polyamides	Câbles BT des alimentations des avions

Les câbles haute tension, 400 kV, sont principalement utilisés pour assurer l'évacuation de la puissance de certaines centrales électriques, lorsqu'il n'est pas possible de faire par lignes aériennes. Leur puissance unitaire va de 600 à 1200 MW. Les artères de pénétration dans les grandes agglomérations utilisent des câbles 225 kV, 300 à 600 MW. Les câbles moyenne tension (20 kV) constituent une très grande partie du réseau de distribution d'énergie électrique. Les câbles basse tension quant à eux, constituent le plus sûr et le plus esthétique moyen de distribution de l'énergie électrique à l'utilisateur. Une grande partie des câbles moyenne et haute tension utilise encore une technologie « papier imprégné d'huile » [FAU 93]. Les premiers câbles haute tension alternative (225 kV) utilisant du polyéthylène extrudé ont été posés en 1972, puis en 1985 pour la tension 400-500 kV.

II.9. Comportement des isolants polymères solides sous champ électrique

Afin de décrire le comportement d'un polymère sous champ électrique, nous allons dans un premier temps décrire sa réponse à une sollicitation de type mécanique. En effet la réponse d'un matériau polymère sous sollicitation électrique a un caractère électromécanique [MAM 04a] [MAM 04b] [MAM 04c]. On peut décrire de deux façons le comportement de ces matériaux soumis à une telle sollicitation. La première approche consiste à ne considérer que le comportement macroscopique du matériau. Ce type de description concerne uniquement les phénomènes globaux et permet d'établir des lois de comportement macroscopique. Evidemment, il ne fournit a priori que peu d'informations sur les mécanismes qui se produisent à une autre échelle où se situent les atomes ou les molécules, éléments constitutants du matériau. Or le comportement macroscopique résulte.

II.10 Le polyéthylène téréphtalate

Le polyéthylène téréphtalate PET est un matériau de la famille thermoplastique.

C'est un matériau dur, rigide, solide avec une bonne stabilité dimensionnelle et un faible taux d'absorption d'eau. Il présente de bonnes propriétés de protection contre les gaz et une bonne résistance chimique, sa cristallinité varie entre amorphe relativement élevé. Il peut être très transparente incolore, mais les parties épaisses sont les plus souvent opaques et blanchâtres.

Ce polymère est largement connu sous forme de film orienté biaxialement et stabilisé thermiquement, appelé plus couramment sous les noms commerciaux Mylar, Melinex ou Hostaphan.

Ces films « type mylar » sont utilisés pour les condensateurs, les pellicules, les bandes d'enregistrement, etc...Le PET est également utilisé sous une large gamme de fibres de textile et pour des utilisations industrielles. D'autres applications incluent les composants électriques etc..




Fig II.4 : Polyéthylène téréphtalate.

II.11. Génération de charges à la surface des isolants

II.11.1. Introduction

Les deux manières les plus simples et les plus utilisées pour reproduire en laboratoire les phénomènes de chargement électrostatique des isolants se rapprochant le plus possible du phénomène physique rencontré dans les cas pratiques sont le chargement triboélectrique et le chargement par effet couronne.

La triboélectricité est l'une des plus vieilles formes connues de chargement. Cette méthode a le désavantage d'être non seulement non reproductible mais elle est fortement influencée par le couple frotteur/ frotté. Le chargement par des charges couronnes a l'avantage d'être simple, contrôlable (en niveau et en polarité) et surtout reproductible. De nos jours les décharges électriques dans le gaz suscitent un regain d'intérêt qui tient à leurs applications potentielles en laboratoire et dans l'industrie. Ces applications utilisent tout ou une partie des espèces présentes dans le plasma (électrons, ions, espèces neutres) sous forme d'atomes et de molécules.

II.11.2. Décharge couronne

Par le terme " décharge couronne ", on se réfère généralement à un ensemble de phénomènes se produisant, dans un milieu gazeux, au voisinage d'un conducteur de faible rayon de courbure, soumis à un champ électrique intense. Les premières études sur les décharges couronne ont été effectuées par Townsend au début du siècle [Town14], mais l'analyse des processus physiques mis en jeu dans ce phénomène a commencé dans les années trente. Depuis de nombreux travaux ont été publiés sur ce sujet [Loeb65; Triche38; Sig82].

Lorsque, au voisinage d'un fil mince et plus généralement au voisinage d'une surface à faible rayon de courbure, le champ électrique dans l'air atteint une certaine valeur, dite critique, les atomes s'ionisent et le phénomène se manifeste visuellement par l'apparition d'une gaine lumineuse entourant le fil comme une couronne de couleur bleu violette. C'est là l'origine historique de l'expression " effet couronne ".

On peut définir la décharge couronne comme une décharge électrique autoentretenu dans un gaz, dont la zone active, où se produisent l'ionisation et les phénomènes d'avalanche est limitée dans l'espace par la décroissance du champ électrique, par opposition aux décharges du type étincelle ou arc pour lesquelles la décharge est limitée géométriquement par une électrode.

De cette façon, un système de décharge couronne doit comporter une électrode active (pointe, fil) à champ élevé, laquelle sera entourée par une région d'ionisation où les processus d'ionisation auront lieu. D'autre part, l'électrode passive où le champ est faible (plan) est isolée de l'électrode active par la zone de dérive de faible conductivité (figure II.5).




Fig II.5 : Schéma d'une décharge couronne en géométrie pointe /plan.

Dans cette région de dérive, les porteurs de charge migrent et réagissent entre eux. Sous tension continue, une décharge couronne est appelée positive ou négative par rapport à la polarité appliquée sur l'électrode active.

L'intérêt de la configuration pointe/plan est double. Premièrement, elle permet de générer des champs électriques très intenses au niveau de la pointe (plusieurs MV/cm) pour des tensions modérées (quelques kV).

Deuxièmement, étant donné que la région de champ intense est localisée près de la pointe le lieu de génération des porteurs de charge est limité au voisinage de la pointe. Le risque de claquage est moindre. La région d'ionisation est d'autant plus localisée que le rayon de courbure de la pointe est faible.

L'intérêt porté à la décharge couronne a de multiples motivations, il peut être lié à :

- L'étude des phénomènes précurseurs au développement de l'arc.
- La possibilité de charge des particules dans un gaz (précipitation électrostatique).
- La multiplication électronique au seuil de la charge (compteur Geiger).

La décharge couronne est aussi appliquée en interaction solide dans deux domaines d'application.

- Le traitement de surface des isolants
- Le dépôt contrôlé et reproductible de charges électriques par des isolants.

La décharge couronne est une source d'ions et de rayonnement qui permet, par rupture et réarrangement des premières monocouches, de modifier les caractéristiques physiques de la surface des isolants et de polymères en particulier en vue d'améliorer des propriétés telles que l'adhérence d'électrodes et la mouillabilité des isolants comme le PE (polyéthylène), PET (polyéthylène téréphtalate) et le PP (polypropylène)

Le deuxième cas est le moyen le plus fiable pour reproduire le chargement électrostatique des isolants et de comprendre comment ces charges se comportent. La décharge couronne source d'ions va donc servir dans notre étude comme moyen de dépôt de charges sur la surface des polymères (PET). Avec ce procédé, il est possible de déposer des charges aussi bien positives que négatives par changement de la polarité de la haute tension appliquée à la pointe. Dans notre étude nous n'avons choisi que la polarité négative pour obtenir des charges négatives déposées sur la surface du PET.

II.12. Conclusion

La plupart des isolants industriels sont des polymères semi-cristallins présentant une phase amorphe et une phase cristalline. Ils possèdent une structure complexe, qui présente des comportements tout à fait singuliers. La microstructure d'un isolant polymère dicte les propriétés physiques, mécaniques et électriques que l'on attend de cet isolant.

La structure de ces matériaux organiques est loin d'être homogène aux échelles micrométriques et nanométriques. D'une part, elle présente un désordre d'ordre chimique lié aux différents types de liaisons interatomiques, à l'arrangement moléculaire et à la présence de certains additifs. D'autre part, un désordre d'ordre physique dû à l'architecture moléculaire (structure semi-cristalline) joue un rôle important dans la complexité de la réponse de ces matériaux à une contrainte appliquée. En plus de leur structure hétérogène, les polymères sont des systèmes hors d'équilibre thermodynamique et cherchent de ce fait à atteindre l'équilibre le plus proche par une relaxation structurale directe commandée par la mobilité moléculaire au sein de ces matériaux. Etant donné que cette dernière présente un caractère multi-échelles, les relaxations structurales sont caractérisées par une distribution de leur temps de relaxation. Une étude théorique de la relaxation structurale permettant une bonne compréhension de ce phénomène et de ses caractéristiques : degré de coopérativité, non-linéarité et effet mémoire, a été faite. Le but est l'interprétation de ces théories afin de les intégrer dans notre modélisation de la réponse des isolants polymères soumis à l'application d'un champ électrique. La nécessité d'une étude à une échelle moléculaire locale de la réponse de ces matériaux a été évoquée. Les principaux effets induits par l'application d'un champ électrique sur les polymères et pouvant avoir un rôle important dans le processus de dégradation sont présentés, tels la déformation électromécanique de nature recouvrable et le courant électrique induit par le champ. A la vue de l'étude structurale faite dans ce chapitre, tenir compte en totalité de la structure complexe des polymères dans le phénomène de vieillissement sous champ électrique, paraît fort délicat. Le travail qui suit vise à apporter des éléments de réflexion nouveaux reposant sur des modèles déjà existant dans le but d'améliorer les bases physiques d'une modélisation du comportement des isolants organiques sous champ électrique.

Chapitre III

Réseaux de Neurones Artificiels

III. Réseaux de neurones artificiels

III.1. Introduction

Les réseaux de neurones artificiels (RNA) ou réseaux connexionnistes sont fondés sur des modèles qui tentent d'expliquer comment les cellules du cerveau et leurs interconnexions parviennent, d'un point de vue global, à exécuter des cellules complexes.

Ces systèmes qui stockent et retrouvent l'information de manière « similaire » au cerveau sont particulièrement adaptés au traitement en parallèle de problèmes complexes comme la reconnaissance automatique de la parole, la reconnaissance de visage, la simulation de fonctions de transfert. Ils offrent un nouveau moyen de traitement de l'information utilisé en reconnaissance de formes (vision, image, parole, etc). Les architectures connexionnistes s'inspirent de l'organisation neurale du cerveau humain. Dans les réseaux de neurones artificiels de nombreux processeurs appelés cellules ou unités, capables de réaliser des cellules élémentaires, sont structurés en couches de connexions qui les relient. On dit que ces unités qu'elles miment les neurones biologiques.

Grace a ce parallélisme massif, nous pouvons espérer pouvoir surmonter les problèmes posés par des temps d'attentes importants caractéristiques à la résolution des taches complexes par des méthodes numériques (tel que de taches en reconnaissance de visage, de voix,..).

Nous donnons dans ce chapitre les notions de base pour la compréhension des réseaux de neurones. Nous présentons tout d'abord l'élément de base d'un réseau connexionniste : le neurone ou processeur élémentaire.

Ces éléments sont assemblés suivant une certaine architecture, dont nous discuterons le rôle, pour former un réseau. Nous observerons aussi le processus d'apprentissage et leurs différentes règles, aussi la méthode de retropropagation des erreurs. Nous aborderons également les applications des réseaux de neurones, et enfin une conclusion.

III.2. Base biologique

III.2.1. Principe, fondement biologique

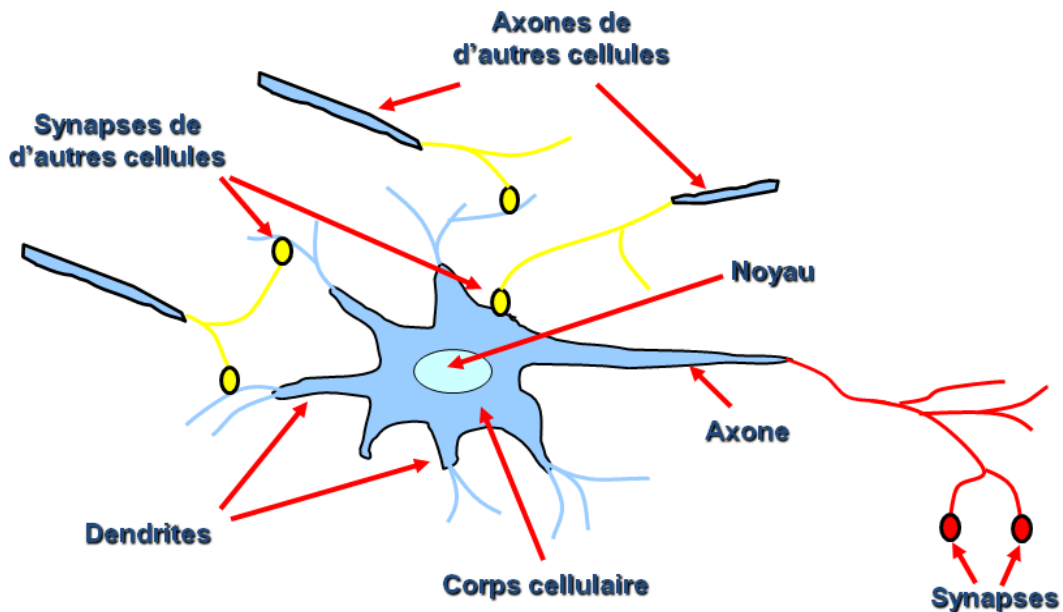


Fig III.1 : Neurone biologique.

Les cellules nerveuses, sont les éléments de base du système nerveux central. Ils sont constitués de trois parties : le corps cellulaires, les dendrites et l'axone.

a. Le corps cellulaire : contient le noyau du neurone et effectue les transformations biochimiques nécessaires à la synthèse des éléments assurant la vie du neurone et le traitement des informations.

b. Les dendrites : chaque neurone possède une chevelure de dendrites. Elles se ramifient et forment une arborescence autour du corps cellulaires. Elles sont les récepteurs principaux du neurone pour capter les signaux lui parvenant.

c. L'axone : sert de moyen de transport pour les signaux émis par le neurone, vers d'autres neurones. Il se distingue des dendrites par sa forme et les propriétés de sa membrane externe.

Généralement plus long que les dendrites, il se ramifie à ses extrémités (communication avec d'autres neurones) alors que les ramifications des dendrites se produisent près du corps cellulaire.

Pour constituer le système nerveux, les neurones sont interconnectés suivant une répartition spatiale complexe. Les connexions entre neurones sont réalisées au niveau des synapses, lieu de proximité d'axone émetteur et de dendrites réceptrices.

Schématiquement, un neurone traite les courants électriques lui provenant de ses dendrites, et transmet le courant électrique résultant aux neurones aux quels il est connecté par l'intermédiaire de son axone.

Le schéma classique présenté par les biologistes est celui d'un soma effectuant une sommation des influx nerveux transmis par ses dendrites (Figure III.1). Si la sommation dépasse un seuil, le neurone répond par un influx nerveux ou un potentiel d'action qui se propage le long de son axone. Si la sommation est inférieure au seuil, le neurone reste inactif. Les premières des cellules qui alimentent le réseau peuvent être constituées par les capteurs (cellules sensorielles) comme les cellules de la rétine de l'œil, par exemple.

Un phénomène fondamental dans le fonctionnement du système nerveux et celui de l'apprentissage. Il est caractérisé par :

Un système initial aux mécanismes de fonctionnement et au potentiel d'évolution fixés.

- L'évolution des connexions du réseau.
- L'interaction entre le monde extérieur et le réseau.

La modélisation des connexions du système initial se produit par apprentissage issu d'une confrontation avec le milieu extérieur. L'apprentissage peut être défini comme l'acquisition de propriétés associatives stables, et la mémorisation comme l'enregistrement et le rappel de ces propriétés ou modifications.

Les modèles mathématiques de réseaux de neurones artificiels reproduisent de manière simple la structure de réseaux de neurones réels. Les différents points de la modélisation sont :

- La représentation d'un neurone.
- La représentation des connexions, et les architectures retenus pour répondre à des traitements de reconnaissances de forme
- L'apprentissage du réseau.

Ces trois points sont détaillés dans les paragraphes suivants :

III.3. Neurone artificiel

III.3.1. Modèle d'un neurone

Le modèle mathématique d'un neurone artificiel est illustré à la (figure III.3). Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat n de cette somme est ensuite transformée par une fonction de transfert f qui produit la sortie a du neurone. En suivant les notations présentées à la section précédente, les R entrées des neurones correspondent au vecteur $P = [p_1 \ p_2 \dots \ p_R]^T$ alors que $W = [W_{11} \ W_{12} \dots \ W_{1R}]^T$ représente le vecteur des poids du neurone. La sortie n de l'intégrateur est donnée par l'équation suivante :

$$n = \sum_{j=1}^R W_{1,j} P_j - b$$

$$n = (W_{1,1}P_1 + W_{1,2}P_2 + \dots + W_{1,R}P_R) - b \quad (3.1)$$

Que l'on peut aussi écrire sous forme matricielle :

$$n = W^T P - b \quad (3.2)$$

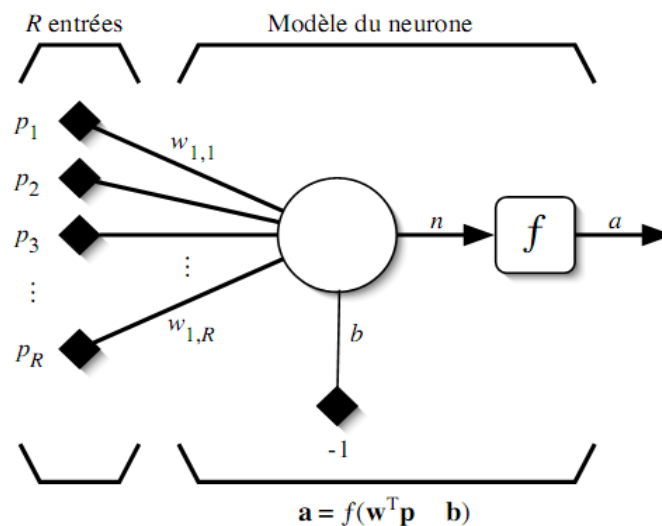


Fig III.2 : Modèle d'un neurone artificiel.




Fig III.3 : Modèle mathématique d'un neurone artificiel.

Cette sortie correspond à une somme pondérée des poids et des entrées moins ce qu'on nomme le biais b du neurone. Le résultat n de la somme pondérée s'appelle le niveau d'activation du neurone. Le biais b aussi s'appelle le seuil d'activation du neurone. Lorsque le niveau d'activation atteint ou dépasse le seuil b , alors l'argument de f devient positif (ou nul). Sinon, il est négatif.

Un poids d'un neurone artificiel représente donc l'efficacité d'une connexion synaptique. Un poids négatif vient inhiber une entrée, alors qu'un poids positif vient l'accentuer.....

Un autre facteur limitatif dans le modèle que nous nous sommes donné concerne son caractère discret. En effet, pour pouvoir simuler un réseau de neurones, nous allons rendre le temps discret dans nos équations. Autrement dit, nous allons supposer que tous les neurones sont synchrones, c.-à-d qu'à chaque temps t , ils vont simultanément calculer leur somme pondérée et produire une sortie $a(t)=f(n(t))$. Dans les réseaux biologiques, tous les neurones sont en fait asynchrones.

Revenons donc à notre modèle tel que formulé par l'équation (3.2) et ajoutons la fonction d'activation f pour obtenir la sortie du neurone :

$$a = f(n) = f(W^T P - b) \quad (3.3)$$

En remplaçant w^T par une matrice $W = w^T$ d'une seule ligne on obtient une forme générale qui nous adopterons tout au long de cet mémoire.

$$a = f(WP - b) \quad (3.4)$$

L'équation (3.4) nous amène à introduire un schéma de notre modèle plus compact que celui de (la figure III.2) illustre celui-ci. On y représente les R entrées comme un rectangle noir (le nombre d'entrées est indiqué sous le rectangle). De ce rectangle sort le vecteur P dont la dimension matricielle est $R \times 1$. Ce vecteur est multiplié par une matrice W qui contient les poids (synaptique)

des neurones. Dans le cas d'un neurone simple, cette matrice possède la dimension $1 \times R$. Le résultat de la multiplication correspond au niveau d'activation qui est ensuite comparé au seuil b (un scalaire) par soustraction. Finalement, la sortie du neurone est calculée par la fonction d'activation f . la sortie d'un neurone est toujours un scalaire.

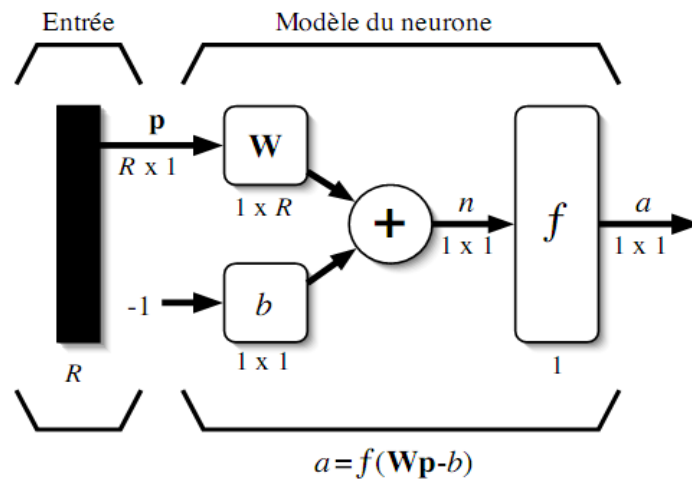


Fig III.4 : Représentation matricielle du modèle d'un neurone artificiel.

III.3.2. Fonctions d'activations

Jusqu'à présent nous n'avons pas spécifié la nature de la fonction d'activation de notre modèle. Il se trouve que plusieurs possibilités existent. Différentes fonctions de transfert pouvant être utilisées comme fonction d'activation du neurone sont énumérées au tableau III.1. Les trois les plus utilisées sont les fonctions « seuil » (en anglais « hard limite »), « linéaire » et « sigmoïde ».

Comme son nom l'indique, la fonction « seuil » applique un seuil sur son entrée. Plus précisément, une entrée négative ne passe pas le seuil, la fonction alors retourne la valeur 0 (on peut interpréter ce 0 comme signifiant faux), alors qu'une entrée positive ou nulle dépasse le seuil, et la fonction retourne à 1 (vrai). Utilisée dans le contexte d'un neurone, cette fonction est illustrée à (la figure III.5a). On remarque alors que le biais b dans l'expression de $a = \text{hardlin}(w^T p - b)$ (équation 3.4) détermine l'emplacement du seuil sur l'axe $w^T p$, ou la fonction passe de 0 à 1. Nous verrons plus loin que cette fonction permet de prendre des décisions binaires.

La fonction linéaire est très simple, elle effectue directement son entrée à sa sortie :










$$a = n \tag{3.5}$$

Appliquée dans le contexte d'un neurone, cette fonction est illustrée à (la figure III.5b). Dans ce cas la sortie du neurone correspond à son niveau d'activation dont le passage à zéro se produit lorsque $w^T p = b$.

La fonction de transfert sigmoïde est quant à elle illustrée à (figure III.5c). Son équation est donnée par :

$$a = \frac{1}{1 + \exp^{-n}} \quad (3.6)$$

Tab III.1 : Les différentes fonctions de transferts.

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

Elle ressemble soit à la fonction seuil, soit à la fonction linéaire, selon que l'on est loin ou près de b , respectivement. La fonction seuil est très non linéaire car il y a une discontinuité lorsque $w^T p = b$. De son côté la fonction linéaire est tout à fait linéaire. Elle ne comporte aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux précédentes. Notons finalement que la fonction « tangente hyperbolique » est une version symétrique de la sigmoïde [Marc.P 04].




Fig III.5 : Fonctions de transfert : (a) « seuil », (b) « linéaire » ; et (c) « sigmoïde ».

III.4. Architecture de réseau

Un réseau de neurone est un maillage de plusieurs neurones, généralement organisé en couches. Pour construire une couche de S neurones, il s'agit simplement de les assembler comme à (la figure III.6).

Les S neurones d'une même couche sont tous branchés au R entrées.

On dit alors que la couche est totalement connectée. Un poids $w_{i,j}$ est associé à chacune de connexions. Nous noterons toujours le premier indice par i et le deuxième par j (jamais l'inverse). Le 1^{er} indice (rangée) désigne toujours le numéro de neurone sur la couche, alors que le deuxième indice (colonne) spécifie le numéro de l'entrée.

Ainsi $w_{i,j}$ désigne le poids de la connexion qui relie le neurone i a son entrée j. l'ensemble des poids d'une couche forme donc une matrice W de dimension S*R :

$$W = \begin{bmatrix} w_{1,1} & \dots & w_{1,R} \\ \vdots & \ddots & \vdots \\ w_{S,1} & \dots & w_{S,R} \end{bmatrix} \quad (3.7)$$

Notez bien que $S \neq R$, dans le cas général (les nombres de neurones et d'entrées sont indépendants). Si l'on considère que les S neurone forment un vecteur de neurones, alors on peut créer les vecteurs $b = [b_1 \ b_2 \ \dots \ b_s]^T$, $n = [n_1 \ n_2 \ \dots \ n_s]^T$ et $a = [a_1 \ a_2 \ \dots \ a_s]^T$. Ce ci nous amène à la représentation graphique simplifiée, illustrée à (la figure III.6). On y retrouve, comme à (la figure III.4), les mêmes vecteurs et matrices. La seule différence se situe au niveau de la taille, ou plus précisément du nombre de la rangée (S), de b, n, a et w.

Finalement pour construire un réseau, il ne suffit plus que de combiner des couches comme à (la figure III.7). Cet exemple comporte R entrées et trois couches de neurones comptant respectivement $S^1 \neq S^2 \neq S^3$. Chaque couche possède sa propre matrice de poids w^k , ou k désigne

l'indice de couche. Dans le contexte des vecteurs et des matrices relatives à une couche, nous emploierons toujours un exposant pour désigner cet indice. Ainsi, les vecteurs b^k , n^k et a^k sont aussi associé à la couche k .

Il importe de remarquer dans cet exemple que les couches qui suivent la 1^{ère} ont comme entrée la sortie de la couche précédente. Ainsi, on peut enfilez autant de couche que l'on veut, du moins en théorie. Nous pouvons aussi fixer un nombre quelconque de neurone sur chaque couche. En pratique, nous verrons plus tard qu'il n'est cependant pas souhaitable d'utiliser trop de neurones. Finalement notez aussi que l'on peut changer de fonction de transfert d'une couche à l'autre.

Ainsi, toujours dans le cas général, $f^1 \neq f^2 \neq f^3$.




Fig III.6 : Couche de S neurones.

La dernière couche est nommée «couche de sortie ». Les couches qui nous verrons un peu plus tard pourquoi. Le réseau de (la figure III.7) possède donc deux couches cachées et une couche de sortie.

Les réseaux multicouches sont beaucoup plus puissants que les réseaux simples à une seule couche. En utilisant deux couches (une couche cachée et une couche de sortie), à condition d'employer une fonction d'activation sigmoïde sur la couche cachée, on peut entraîner un réseau

à produire une approximation de la plupart des fonctions, avec une précision arbitraire (cela peut cependant requérir un grand nombre de neurones sur la couche cachée). Sauf dans de rares cas, les réseaux de neurones artificiels exploitent deux ou trois couches.

Entraîner un réseau de neurones signifie modifier la valeur de ses poids et de ses biais pour qu'il réalise la fonction entrée/sortie désirée. Pour spécifier la structure du réseau, il faut aussi choisir le nombre de couches et le nombre de neurones sur chaque couche.

Tout d'abord, rappelons que le nombre d'entrées du réseau « R », de même que le nombre de neurones sur la couche de sortie est fixé par les spécifications du problème que l'on veut résoudre avec ce réseau.

Par exemple, si la donnée du problème comporte quatre variables en entrée et qu'elle exige de produire trois variables en sortie, alors nous aurons simplement $R=4$ et $S^M=3$, ou M correspond à l'indice de la couche de sortie (aussi qu'au nombre de couche). Ensuite, la nature du problème peut aussi nous guider dans le choix des fonctions de transfert. Par exemple, si l'on désire produire des sorties binaires 0 ou 1, alors on choisit a probablement une fonction seuil (voir tableau III.1) pour la couche de sortie. Il reste aussi à choisir le nombre du couche cachées ainsi le nombre de neurones sur ces couches, et leurs fonctionnes de transferts, il faudra aussi fixer les différentes paramètres de l'algorithme d'apprentissage. Mais nous y reviendrons en temps et lieu.

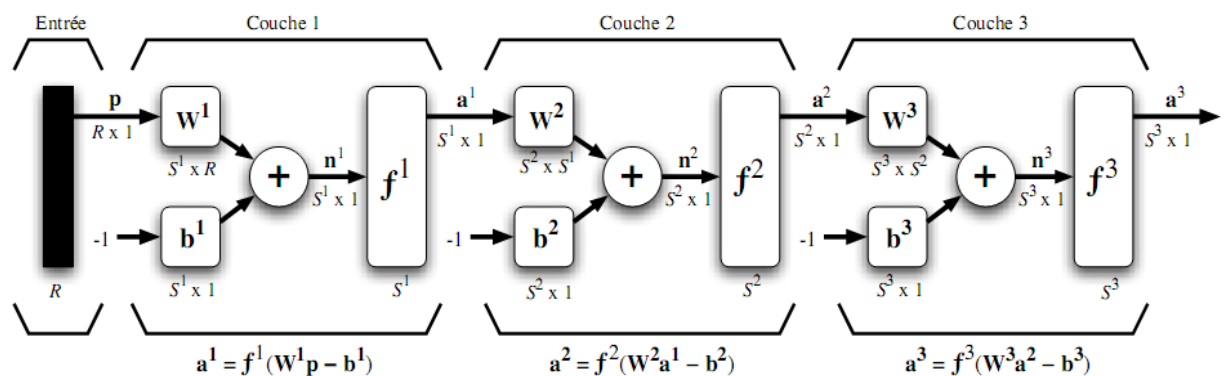


Fig III.7 : Représentation matricielle d'un réseau de trois couches.

III.5. Structure d'interconnexion (topologie)

Les connexions entre les neurones qui composent le réseau décrivent la « topologie » du modèle. Le plus souvent, cette topologie fait apparaître une certaine régularité de l'arrangement des neurones, cependant, celui-ci peut être quelconque.

III.5.1. Réseau multicouches

Les neurones sont arrangés par couche. On place ensuite bout à bout plusieurs couches et l'on connecte les neurones de deux couches adjacentes. Les entrées des neurones de la deuxième couche sont en fait les sorties des neurones de la couche amont.

Les neurones de la 1^{ère} couche sont reliés au monde extérieurs et reçoivent le vecteur d'entrée. Ils calculent alors leurs sorties qui sont transmises aux neurones de la seconde couche qui calculent eux aussi leurs sorties et ainsi de suite de couche en couche jusqu'à celle du sortie. Il peut y avoir une ou plusieurs sorties à un réseau de neurones.

Dans un réseau multicouche classique, il n'y a pas de connexion entre neurones d'une même couche et les connexions ne se font qu'avec les neurones de la couche aval. Tous les neurones de la couche amont sont connectés à tous les neurones de la couche aval.




Fig III.8 : Réseau multicouche classique.

III.5.2. Réseau à connexions locales

On repère la même structure en couche que précédemment, mais avec un nombre de connexions limité à un neurone n'est pas forcément connecté à tous les neurones de la couche précédente.




Fig III.9 : Réseau multicouche à connexions locales.

III.5.3. Réseau à connexions récurrentes

Un réseau de ce type signifie qu'une ou plusieurs sorties de neurones d'une couche aval sont connectées aux entrées des neurones de la couche amont ou de la même couche. Ces connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche.

Les réseaux à connexions récurrentes sont des réseaux plus puissants car ils sont séquentiels plutôt que combinatoires comme l'étaient ceux décrit précédemment. La rétraction de la sortie vers l'entrée permet à un réseau de ce type de présenter un comportement temporel.




Fig III.10: Réseau à connexions récurrentes.

III.5.4. Réseau a connexions complexes

Chaque neurone est connecté à tous les neurones du réseau y compris lui-même, c'est la structure d'interconnexion la plus générale.




Fig III.11: Réseau à connexions complètes.

III.6. Apprentissage

III.6.1. Généralités sur l'apprentissage

Le problème de l'approximation d'une fonction n'est qu'un aspect de l'apprentissage des réseaux de neurones, la propriété d'approximation universelle étant seulement une condition nécessaire à leur utilisation comme modèles et correcteurs non linéaires généraux.

Dans le cas où la tâche du réseau de neurones est une tâche de modélisation d'un processus physique, il est raisonnable de supposer que les sorties mesurées sur le processus obéissent à des lois déterministes, et de chercher une expression mathématique des fonctions f et g . La propriété d'approximation universelle est donc une propriété nécessaire du modèle utilisé à cette fin, mais elle n'est pas suffisante. En effet :

- D'une part, dans la pratique, les fonctions à déterminer sont définies par un ensemble fini de couples {entrées-sorties mesurées}, qui ne permet pas de déterminer ces fonctions de façon univoque ; le but de l'apprentissage est alors de trouver la solution la plus parcimonieuse, passant par tous les points d'apprentissage, qui, si l'ensemble d'apprentissage est bien choisi, tendra vers les fonctions f et g supposées régir le fonctionnement du processus.
- D'autre part, on est souvent en présence de processus affectés de perturbations aléatoires ; dans ce cas, le but de l'apprentissage ne peut être de passer par tous les points de l'ensemble d'apprentissage : bien que l'on ne dispose pas des valeurs prises sur l'ensemble d'apprentissage

par les fonctions f et g supposées régir le fonctionnement du processus, il doit ajuster les coefficients du réseau de façon que les fonctions qu'il réalise tendent vers f et g .

Dans le cas où la tâche du réseau est de réaliser une loi de commande imposant une dynamique désirée à un processus pour lequel on dispose d'un modèle, la démonstration de l'existence d'une telle loi de commande est en elle-même un problème. En effet, si la synthèse du correcteur est effectuée à l'aide d'un modèle neuronal, dont il est difficile de déterminer les caractéristiques de façon analytique, cette existence peut être difficile à établir. Ces problèmes spécifiques à la commande ne seront pas abordés ici.

Dans ce paragraphe, nous donnons les principes et décrivons la mise en œuvre des procédures d'apprentissage, indépendamment des considérations d'existence que nous venons d'évoquer.

III.6.2. Principe général

L'architecture du réseau de neurones n'est souvent que partiellement imposée par la tâche à réaliser : les entrées, l'état, et les sorties du réseau peuvent être fixées en fonction de celle-ci par le concepteur, ainsi que le type et la connectivité des neurones. Mais le nombre de neurones ne peut être fixé a priori, et il est en général déterminé selon une procédure itérative, suivant le succès de l'apprentissage (il existe des méthodes systématiques de sélection de modèles dynamiques [LEO87] [URB94]). L'architecture du réseau étant fixée, le but de l'apprentissage est l'estimation des coefficients pour remplir au mieux la tâche à laquelle le réseau est destiné.

III.6.2.1. Apprentissage d'un réseau de neurones

Comme mentionné plus haut, l'apprentissage d'un réseau est définie par :

- un ensemble d'apprentissage constitué de N exemples, chacun étant constitué d'un vecteur P appliqué aux entrées du réseau, et du vecteur a des valeurs désirées correspondantes pour les sorties. Dans le cas de l'automatique et du traitement du signal, ces exemples sont ordonnés temporellement ; on parle alors de séquences d'apprentissage. Il est très important que cet ensemble d'apprentissage soit suffisamment riche : il faut qu'il couvre aussi complètement que possible le domaine de fonctionnement désiré pour le réseau, et que le nombre d'exemples soit grand devant le nombre de coefficients du réseau. La propriété de parcimonie des réseaux de neurones permet de faciliter la réalisation de cette condition.

Notons que la nécessité de disposer d'exemples en nombre suffisant, et suffisamment représentatifs, est souvent présentée comme une limitation propre aux réseaux de neurones ; ceci est incorrect : c'est une limitation commune à toute méthode statistique ; grâce à la propriété de

parcimonie, cette contrainte est plus facile à satisfaire lorsque l'on utilise les réseaux de neurones que lorsque l'on utilise d'autres méthodes de régression.

- une fonction de coût à minimiser : en effet, la tâche ne consiste pas nécessairement à rendre les sorties du réseau égales aux sorties désirées ou proches de celles-ci. Par exemple, pour un problème de régulation, on peut souhaiter minimiser également le coût énergétique de la commande. Le critère fera donc intervenir non seulement l'écart de la sortie à la valeur de consigne, mais également l'énergie dépensée. Ou bien, si le processus possède plusieurs sorties, on peut attacher plus d'importance à certaines d'entre elles ; cela se traduit par une pondération des différents termes de la fonction de coût (c'est une généralisation de la commande linéaire quadratique).

L'apprentissage d'un réseau de neurones est ainsi défini comme un problème d'optimisation qui consiste à trouver les coefficients du réseau minimisant une fonction de coût. L'apprentissage est mis en œuvre par un système d'apprentissage qui comprend le réseau dont les coefficients sont à estimer, les séquences d'apprentissage et leur processus générateur (processus, modèle de référence.), et l'algorithme utilisé pour l'estimation.

III.6.2.2. Exemple de la modélisation d'un processus non linéaire

La (figure III.12) représente le système d'apprentissage pour la modélisation d'un processus : le but est d'estimer les coefficients du réseau prédicteur. Les séquences d'apprentissage sont constituées de la séquence des commandes $\{u(k)\}$ appliquées au processus et au prédicteur, et de la séquence des sorties désirées pour le prédicteur, qui sont les sorties $\{y_p(k)\}$ mesurées sur le processus. Les coefficients sont estimés de manière à minimiser une fonction de coût définie à partir de l'écart $y_p - y$, à l'aide d'un algorithme d'apprentissage approprié.

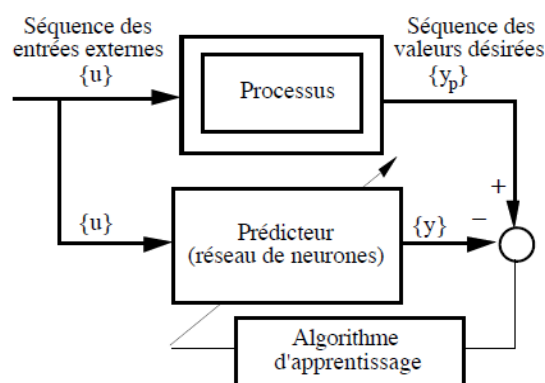


Fig III.12 : système d'apprentissage pour la modélisation d'un processus.

III.6.2.3. Minimisation de la fonction de coût

Puisque nous utilisons des réseaux de neurones, les sorties du système subissant un apprentissage sont en général des fonctions non linéaires des coefficients à estimer. La recherche du minimum de la fonction de coût ne peut s'effectuer à l'aide des moindres carrés ordinaires, et demande donc l'utilisation de méthodes de programmation non linéaire. Les algorithmes de calcul du gradient de la fonction de coût ainsi que des méthodes de minimisation du premier et du second ordre sont présentées dans ce que suit [RIV95].

Au-delà des aspects techniques de ces algorithmes, il faut retenir leur caractère générique : l'un des atouts majeurs des réseaux de neurones réside dans le fait que les algorithmes d'apprentissage sont applicables pour tout réseau mis sous forme canonique. Ainsi, le concepteur a toute liberté dans le choix de l'architecture la mieux adaptée au problème posé, il sait que, quelle que soit la structure du réseau, il pourra toujours utiliser la même panoplie d'algorithmes d'apprentissage ; cette souplesse permet notamment de concevoir des réseaux dont l'architecture est très fortement guidée par la physique du processus à modéliser et/ou à commander, exprimée par les équations des modèles de connaissance. La généralité des algorithmes rend ainsi possible la conception de modèles neuronaux de connaissance.

On appelle « apprentissage » des réseaux de neurones la procédure qui consiste à estimer les paramètres des neurones du réseau, afin que celui-ci remplisse aux niveaux la tâche qui lui est affecté.

Dans le cadre de cette définition, on peut distinguer deux types d'apprentissage : l'apprentissage « supervisé » et l'apprentissage « non supervisé ».

III.6.2.4. L'apprentissage supervisé

Nous avons vus précédemment qu'un réseau de neurones réalise une relation algébrique entre ses entrées et ses sorties.

On peut donc affecter à tel réseau la tâche qui consiste à réaliser une fonction algébrique non linéaire ; celle-ci peut être :

Connue analytiquement, mais pour laquelle on dispose de valeurs, en nombre fini, qui sont entachées de bruit si ses valeurs résultent de mesures effectuées sur un processus physique, chimique, économique, biologique...etc. le réseau réalise alors une tâche de modélisation statique ou une régression.

C'est essentiellement pour ce dernier type d'apprentissage qui est mis en œuvre les réseaux de neurones à apprentissage supervisé.

On connaît donc on tous points ou seulement en certains points, les valeurs que doit avoir la sortie du réseau en fonction des entrées correspondants : c'est en ce sens que l'apprentissage est « supervisé », métaphore qui signifie qu'un « professeur » peut fournir au réseau des « exemples » de ce que lui-ci doit faire.

III.6.2.5. L'apprentissage non supervisé

La deuxième forme d'apprentissage que nous aborderons est dite « non supervisé » ou encore « auto-organisée ». Elle est caractérisée par l'absence complète de professeur, c.-à-d. qu'on ne dispose ni d'un signal d'erreur, comme dans le cas supervisé, ni d'un indice de satisfaction, comme dans le cas par renforcement. Nous ne disposons donc que d'un environnement qui fournit des stimuli, et d'un réseau qui doit apprendre sans intervention externe. En assimilant les stimuli de l'environnement à une description de son état interne, la tâche du réseau est alors de modéliser cet état le mieux possible. Pour y arriver, il importe d'abord de définir une mesure de la qualité pour ce modèle, et de s'en servir par la suite pour optimiser les paramètres libres du réseau, c'est-à-dire ses poids synaptiques. A la fin de l'apprentissage, le réseau a développé une habilité à former des représentations internes des stimuli de l'environnement permettant d'encoder les caractéristiques de ceux-ci et, par conséquent, de créer automatiquement des classes de stimuli similaires.

III.6.2.6. L'apprentissage par renforcement

Dans ce cas, bien que les sorties idéales ne soient pas connues directement, il y a un moyen quelconque de connaître si les sorties du RNA s'approchent ou s'éloignent du but visé. Ainsi, les poids sont ajustés de façons plus ou moins aléatoire et la modification est conservée si l'impact est positif ou rejetée sinon.

III.6.3. L'apprentissage des réseaux de neurones formels

Comme nous l'avons indiqué plus haut, l'apprentissage "supervisé", pour les réseaux de neurones formels, consiste à calculer les coefficients de telle manière que les sorties du réseau de neurones soient, pour les exemples utilisés lors de l'apprentissage, aussi proches que possibles des sorties "désirées", qui peuvent être la classe d'appartenance de la forme que l'on veut classer, la valeur de la fonction que l'on veut approcher ou de la sortie du processus que l'on veut modéliser, ou encore la sortie souhaitée du processus à commander. La plupart des algorithmes d'apprentissage

des réseaux de neurones formels sont des algorithmes d'optimisation, ils cherchent à minimiser, par des méthodes d'optimisation non linéaire, une fonction de coût qui constitue une mesure de l'écart entre les réponses réelles du réseau et ses réponses désirées. Cette optimisation se fait de manière itérative, en modifiant les poids en fonction du gradient de la fonction de coût, le gradient est estimé par une méthode spécifique aux réseaux de neurones, dite méthode de rétropropagation, puis il est utilisé par l'algorithme d'optimisation proprement dit. Les poids sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement jusqu'à l'obtention d'un compromis satisfaisant entre la précision de l'approximation sur l'ensemble d'apprentissage et la précision de l'approximation sur un ensemble de validation disjoint du précédent. Contrairement à des affirmations maintes fois répétées, l'apprentissage des réseaux de neurones n'est pas spécialement lent, il existe des algorithmes d'optimisation non linéaire extrêmement rapides [PRES 92] qui permettent de faire des développements industriels sur de simples PC. L'apprentissage des réseaux de neurones bouclés (pour réaliser des modèles dynamiques) est très semblable à celui des réseaux non bouclés [NERR 93].

III.6.4. Règles d'apprentissage

Un réseau de neurone artificiel, comme le cerveau animal, apprend à réagir correctement à un stimulus provenant de l'extérieur. Le principe de l'apprentissage consiste à soumettre le réseau à un stimulus dont on connaît la réponse souhaitée, autant de fois qu'il lui est nécessaire à la modification des poids des connexions, jusqu'à obtention de la bonne réponse.

Il existe plusieurs règles de modification des poids, les principales sont :

- la règle de Hebb
- la règle de Widrow- Hoff
- l'algorithme du gradient de l'erreur.

III.6.4.1. La règle de Hebb

Valable pour le perceptron, repose sur le principe suivant : si deux neurones connectés entre eux sont activés au même moment, la connexion qui les relie doit être renforcée. Dans le cas contraire elle n'est pas modifiée.

Lorsque les poids sont modifiés, ils sont augmentés de la quantité $M \cdot A_i A_j$ pour un pas d'apprentissage. A_i et A_j représentent l'activation des deux neurones, et leur produit vaut 0 ou 1, M est une constante numérique, appelée Tau d'apprentissage.

III.6.4.2. La règle de Widrow- Hoff

Proposée en 1960, repose sur un principe de minimisation d'erreur quadratiques, l'erreur d'une couche étant la différence entre la repense fournie et la repense attendue. La muséification des poids est réalisée de façon itérative, suivant une méthode de retropropagation du gradient de l'erreur.

On considère deux paramètres d'apprentissage. η identique au paramètre de la règle de Hebb, correspondant à une vitesse d'apprentissage qui conditionne la précision obtenue dans le traitement de problèmes de classification. Un paramètre de seuil, fournissant une limite en dessous de laquelle l'erreur n'est plus rétropropagée, permet d'augmenter la vitesse de convergence du réseau.

Le gradient des erreurs est calculé en dérivant l'erreur quadratique $E(i)$ par rapport au poids, ce qui nécessite une fonction d'activation dérivable. Dans ce cas les fonctions de Heaviside, seuil, et linéaire ne sont plus utilisables. On utilise alors la fonction sigmoïde.

III.7. Le perceptron

Le perceptron, mis au point par Roseblatt dans les années cinquante, associe des configurations (formes, stimuli) présentées en entrées à des réponses. Il est composé de deux couches, et les cellules d'entrées sont reliées aux cellules de sorties grâce à des liaisons (synapses) d'intensité variables (poids). Les cellules d'entrées fournissent des réponses binaires suivant leur activation et la réponse désirée est obtenue en modifiant l'intensité des synapses suivant un processus d'apprentissage.

Le perceptron est limité dans la résolution des problèmes et certaine situation comme les problèmes de classifications non linéaires, ne peuvent être résolus. Une solution consiste à fournir au réseau la possibilité de se reformuler le problème avec une préservation interne propre, à partir d'une structure avec couches cachées.

III.7.1. Le perceptron multicouche (PMC)

Le multilayer perceptron (MLP) appartient aux réseaux multicouches, il ne possède pas donc de boucle de retour, en prenant les sorties d'une couche et en les injectant comme des entrées de la couche suivante. Leur principe de fonctionnement est similaire à celui d'un perceptron simple. Pour donner une réponse à un stimulus présent, le réseau propage dans un premier temps le signal de la couche d'entrée à la couche cachée, via une première série de connexions.

Les cellules de la couche cachée calculent leur activation en fonction du signal reçu et fournissent une réponse (rôle de la fonction d'activation).

Cette réponse est propagée vers la couche cachée suivante avec le même principe, ainsi de suite jusqu'à la couche de sortie.

A la section suivante nous allons développer un algorithme très répandu car facile à implanter dit de « rétropropagation des gradients » qui utilise une erreur quadratique moyenne. Elle permet d'entraîner un réseau multicouche.

III.7.2. La rétropropagation du gradient

III.7.2.1. principe

La rétropropagation du gradient consiste à propager « à l'envers » (de la couche de sortie vers la couche d'entrée) l'erreur obtenue sur les exemples de la base d'apprentissage. On utilise pour cela l'erreur quadratique, le carré de différence entre ce qu'on obtient et ce qu'on désire.

Si on calcule la dérivée partielle de l'erreur quadratique par rapport aux poids des connexions (d'où le « gradient »), il est possible de déterminer la contribution des poids à l'erreur générale, et de corriger ces poids de manière à se rapprocher des résultats souhaités.

La correction se fait par itération en corrigeant plus au moins fortement les poids par l'intermédiaire d'un coefficient η .

A l'issue d'un certain nombre d'itération, lorsque qu'on est satisfait du classement des exemples de notre base d'apprentissage, on fixe les poids qui constituent ainsi des frontières entre classe.

III.7.2.2. Algorithme

Considérons un réseau à une couche cachée. Le réseau possède :

- Une couche d'entrée à R cellules d'entrées $x_i = p_i$ (il ne s'agit pas de neurones, ces cellules représentent simplement les entrées p_i au réseau).
- Une couche cachée à S neurones d'activation y_i .
- Une couche de sortie M neurone d'activation Z_k .
- $R \times S$ connexions entre la couche d'entrée et la couche cachée chacune pondérée par $w_{i,j}$.




Fig III.13 : Exemple d'un réseau MLP à une couche cachée avec 5 entrées, 3 neurones en couche cachée et 5 sorties.

Etape 01 : Initialisation des poids des connexions: ces poids sont choisis au hasard à de petites valeurs.

Etape 02: Propagation des entrées : les p_i sont présentées à la couche d'entrée : $x_i = p_i$.

On propage vers la couche cachée :

$$y_i = f\left(\sum_{i=1}^R x_i w_{i,j}\right) + b_1 \quad (2.9)$$

Puis de la couche cachée vers la couche de sortie :

$$Z_i = f\left(\sum_{j=1}^S y_j w_{k,j}\right) + b_2 \quad (2.10)$$

Les valeurs b_1 et b_2 sont les biais, des scalaires et non des sorties de la couche précédente. La fonction d'activation f est choisie en fonction du phénomène à résoudre.

Etape 03 : Pour chaque exemple de la base d'apprentissage appliqué en entrée du réseau, on calcule son erreur sur les couches de sorties c-à-d la différence entre la sortie désirée d_0 et la sortie réelle a_k .

$$E_k = a_k(1 - a_k)(d_k - a_k) \quad (2.11)$$

On propage cette erreur sur la couche cachée, l'erreur de chaque neurone de la couche cachée est donnée par :

$$F_j = y_j(1 - y_j) \sum_{k=1}^M W_{kj} E_k \quad (2.12)$$

Etape 04 : correction des poids des connexions, il reste à modifier les poids des connexions :

- Entre la couche d'entrée et la couche cachée :

$$\begin{cases} \Delta W_{kj} = \eta y_j E_k \\ \Delta b_1 = \eta E_k \end{cases} \quad (2.13)$$

- Entre la couche cachée et la couche de sortie :

$$\begin{cases} \Delta W_{ij} = \eta x_i F_j \\ \Delta b_2 = \eta F_j \end{cases} \quad (2.14)$$

η étant un paramètre qu'il reste à déterminer.

Boucler à l'étape 2 jusqu'à un critère d'arrêt à définir.

III.8. Mise en œuvre des réseaux de neurones et domaine d'applications

Pour réaliser l'approximation de la fonction de régression cherchée, à partir d'échantillons généralement bruités, à l'aide d'un réseau de neurones, trois étapes successives sont nécessaires:

- Il faut tout d'abord choisir l'architecture du réseau, c'est-à-dire les entrées externes, le nombre de neurones cachés, et l'agencement des neurones entre eux, de telle manière que le réseau soit en mesure de reproduire ce qui est déterministe dans les données ; le nombre de poids ajustables est un des facteurs fondamentaux de la réussite d'une application, si le réseau possède un trop grand nombre de poids, c'est-à-dire si le réseau est trop "souple", il risque de s'ajuster au bruit qui est présent dans les données de l'ensemble d'apprentissage, et, même en l'absence de bruit, il risque

de présenter des oscillations non significatives entre les points d'apprentissage, donc de posséder de mauvaises propriétés d'interpolation (ou, dans le jargon des réseaux de neurones, de "généralisation") ; si ce nombre est trop petit, le réseau est trop "rigide" et ne peut reproduire la partie déterministe de la fonction. Le problème de la détermination de l'architecture optimale est resté pendant longtemps un problème ouvert, mais il existe actuellement diverses méthodes, mettant notamment en jeu des tests statistiques, qui permettent de déterminer cette architecture pour une vaste classe de réseaux [URBA 94] ; (la Figure III.14) illustre l'influence du nombre de paramètres sur la qualité de l'approximation.

- Il faut calculer les poids du réseau - ou, en d'autres termes, estimer les paramètres de la régression non linéaire - à partir des exemples, en minimisant l'erreur d'approximation sur les points de l'ensemble d'apprentissage, de telle manière que le réseau réalise la tâche désirée. Ce calcul des coefficients synaptiques constitue l'apprentissage supervisé pour le réseau de neurones.
- Il faut enfin estimer la qualité du réseau obtenu en lui présentant des exemples qui ne font pas partie de l'ensemble d'apprentissage.




Fig III.14 : Le "surajustement" : le réseau le plus parcimonieux (4 neurones cachés, soit 13 coefficients) produit un bien meilleur ajustement qu'un réseau trop riche en coefficients (8 neurones cachés, soit 25 coefficients).

Les grands domaines d'application des réseaux de neurones découlent naturellement de leur propriété fondamentale :

III.8.1. La régression non linéaire, ou modélisation de données statiques

Il existe une immense variété de phénomènes statiques qui peuvent être caractérisés par une relation déterministe entre des causes et des effets ; les réseaux de neurones sont de bons candidats pour modéliser de telles relations à partir d'observations expérimentales, sous réserve que celles-ci soient suffisamment nombreuses et représentatives.

III.8.2. La modélisation de processus dynamiques non linéaires

Modéliser un processus, c'est trouver un ensemble d'équations mathématiques qui décrivent le comportement dynamique du processus, c'est-à-dire l'évolution de ses sorties en fonction de celle de ses entrées ; c'est donc typiquement un problème qui peut être avantageusement résolu par un réseau de neurones, si le phénomène que l'on désire modéliser est non-linéaire. La prédiction de séries chronologiques (prédictions financières, prédiction de consommation, etc.) entre dans ce cadre.

III.8.3. La commande de processus

Commander un processus, c'est imposer à celui-ci un comportement défini à l'avance en fonction des signaux de commande ; l'ensemble commande plus processus peut donc être considéré comme un système qui réalise une fonction (non linéaire) qu'un réseau de neurones peut approcher.

III.8.4. La classification

Supposons que l'on désire classer des formes en deux catégories, A ou B, en fonction de certaines caractéristiques de ces formes ; on peut définir une fonction φ qui vaut +1 pour toutes les formes de la classe A et -1 pour toutes les formes de la classe B. Les réseaux de neurones sont de bons candidats pour réaliser une approximation de cette fonction φ , et l'on peut démontrer que cette approximation constitue une estimation de la probabilité d'appartenance de la forme inconnue à la classe A. Les réseaux de neurones fournissent donc une information très riche, qui est loin d'être une simple réponse binaire. Cette propriété remarquable (que les réseaux de neurones partagent avec d'autres classifieurs) n'est malheureusement pas mise à profit dans la plupart des applications.

III.9. Conclusion

Nous avons exposé les éléments essentiels qui permettent de comprendre pourquoi, et dans quels cas, il est avantageux de mettre en œuvre des réseaux de neurones. En présentant quelques applications typiques, nous avons tenté de montrer, de manière concrète, ce que l'ingénieur peut attendre de cette technique. S'ils sont bien compris et convenablement utilisés, les réseaux de neurones peuvent rendre des services considérables dans des domaines très variés. Résumons donc les points fondamentaux qu'il convient de toujours garder à l'esprit lorsque l'on cherche à mettre en œuvre des réseaux de neurones :

- Les réseaux de neurones sont des outils statistiques, qui permettent d'ajuster des fonctions non linéaires très générales à des ensembles de points ; comme toute méthode statistique, l'utilisation de réseaux de neurones nécessite que l'on dispose de données suffisamment nombreuses et représentatives ;
- Les réseaux de neurones sont des approximateurs parcimonieux ;
- Les réseaux de neurones permettent de modéliser des phénomènes statiques (réseaux non bouclés) et dynamiques (réseaux bouclés) ;
- Il est toujours souhaitable, et souvent possible, d'utiliser, pour la conception du réseau, les connaissances mathématiques dont on dispose sur le phénomène à modéliser : les réseaux de neurones ne sont pas nécessairement des "boîtes noires".

Théorie de Déclin de Potentiel de Surface (DPS)

IV. Théorie de Déclin de Potentiel de Surface (DPS)

IV.1. Introduction

Le problème de l'électricité statique se présente fréquemment dans plusieurs situations, en particuliers sur les matériaux isolants en connexion avec la haute tension, il peut être présent aussi dans différentes formes de l'électroreprographie en copiant sur la surface du diélectrique et probablement se présente aussi dans les circuits microélectroniques. Les isolants, en particuliers les polymères, lorsqu'il apparaît un dépôt de charges sur leur surface, différents phénomènes peuvent évoluer et contribuent au vieillissement des matériaux isolants qui se traduit notamment par une détérioration des multiples propriétés isolantes par différents processus (chimiques, électriques, etc.). Cependant malgré les progrès récents obtenus avec les instruments de mesure, l'identification du mécanisme prédominant reste toujours obscure. Le processus de conduction, de polarisation ou d'injection de charge, le processus de piégeage/dépiégeage sont des phénomènes complexes et difficiles à expliquer et l'interprétation des résultats est malgré tout assez délicate. En dépit de l'importance de tels problèmes, il apparaît qu'il y a eu peu de tentatives pour comprendre la nature de la migration de la charge sur la surface de l'isolant.

Il est donc utile, voire indispensable de pouvoir mesurer, analyser et comprendre l'origine du déclin de potentiel de surface (DPS). Cette nécessité est renforcée par le fait que l'évolution actuelle en construction électrique tend vers des puissances et des températures de fonctionnement plus élevées.

Ce phénomène est pris en compte depuis une cinquantaine d'année et des travaux de recherches ont été entrepris dans ce sens. Bon nombre d'études du point de vue appliqué que fondamentale ont été menées principalement en lien avec trois domaines, l'étude des condensateurs et des électrets, le développement des dispositifs de reprographie et l'étude de propriétés isolantes du polyéthylène pour son utilisation dans les câbles de transport d'énergie électrique. Dans ce dernier domaine, nous pouvons citer les travaux d'Ieda [Ied67, 68]. Ses travaux ont surtout montré que le potentiel de surface de films de polyéthylène chargés à des tensions élevées déclinait plus vite que celui de films chargés à une tension inférieure. Cette différence de vitesse conduit souvent au croisement des courbes de déclin ou ce qu'on appelle le phénomène de « cross-over » (figure IV.1).




Fig IV.1 : Caractéristique du déclin de potentiel de surface du polyéthylène par décharge couronne [Ied67].

Un échantillon plus chargé qu'un autre peut atteindre un potentiel de surface inférieur au bout d'une même période de mesure. Ce phénomène ne se produit qu'en décharge négative. Il est initialement attribué à la dépendance des paramètres du champ telle que la mobilité des transporteurs et le temps de piégeage. Cependant, il a été prouvé [VonB85] que la dépendance seulement du champ est insuffisante pour expliquer ce phénomène et il a été constaté que l'explication probable est basée sur l'injection partielle de charges lorsqu'une grande quantité de charges est disposée sur la surface du polymère. Ces observations ont fourni le point de départ de la plupart des modèles théoriques formulés ensuite et ont amené un renouvellement de l'intérêt pour les expériences de déclin de potentiel.

IV.2. Phénomènes physiques dans le processus de déclin

Les modélisations du déclin de potentiel ont surtout mise en évidence la complexité des causes physiques qui donnent naissance à ce déclin.

Nous allons expliquer rapidement les différentes causes physiques possibles du déclin de potentiel de surface.

Les phénomènes physiques qui interviennent dans le déclin de potentiel de surface d'un isolant chargé dépendent de plusieurs facteurs, qui peuvent être intrinsèques ou extrinsèques. On observe ainsi :

IV.2.1. Conduction de surface

La conduction de surface constitue une des causes du déclin. Elle est observée surtout dans les cas d'échantillons épais vieillis par décharges couronnes [Cris96]. Les charges se déplacent sur les couches primaires de la surface (figure IV.2).




Fig IV.2 : Conduction de surface.

Lorsque la surface d'un isolant est soumise à la décharge couronne pendant un certain temps, il apparaît une modification rapide et importante des propriétés de la surface [Cris96]. Grâce à la présence de l'oxygène, l'ensemble de la surface présente une structure différente sous forme de couche dégradée fortement oxydée [Moli92]. Les propriétés physico-chimiques de cette couche sont très différentes de celle du matériau initial. Il en résulte une importante conductivité de surface. Selon le même auteur, l'évolution de cette surface est assez complexe et dépend de plusieurs paramètres tels que la structure de l'isolant, du mode de vieillissement, etc...

IV.2.2. Polarisation de l'échantillon

Plusieurs études [Moli95 et 96] ont montré que les phénomènes de polarisation sont responsables pour une partie du déclin de potentiel et parfois même pour expliquer à eux seuls le déclin (figure IV.3).




Fig IV.3 : Polarisation de l'échantillon.

La charge déposée sur la surface de l'isolant modifie le champ existant dans le matériau. Sous l'action du champ électrique créé par ces charges surfaciques, des dipôles s'orientent sous ce champ ; les dipôles les plus proches de la surface s'orientent de telle manière qu'ils viennent

compenser la charge surfacique. Ces charges ne peuvent se déplacer que sur une distance de l'ordre de grandeur d'une molécule. Chaque molécule présente alors un dipôle.

Ce phénomène est caractérisé par l'apparition d'une mince couche de charges positives. A l'intérieur, il y a une compensation des charges de polarisation. La circulation de la charge peut être alors expliquée en partie par l'apparition de charges de polarisation. Ce phénomène est généralement caractérisé par la constante diélectrique qui demeure sensible à la température.

IV.2.3. Neutralisation par le gaz

La neutralisation des charges déposées sur la surface de l'isolant par les charges libres provenant directement du gaz qui entoure l'isolant est un autre processus qui peut contribuer au déclin de potentiel de surface (figure IV.4).




Fig IV.4 : Neutralisation par le gaz.

Lors du dépôt de charges, le champ électrique environnant la surface de l'isolant est complètement modifié. Les atomes et les molécules subissent alors l'effet du champ et s'orientent de manière à créer une charge opposée à celle de la surface. Coelho [Coel84] a considéré la neutralisation par le gaz lors de ces études sur le téflon.

IV.2.4. Phénomènes piézoélectriques

L'effet piézoélectrique a été cité souvent comme processus physique qui peut participer au déclin de potentiel [Llo02] (figure IV.5).




Fig IV.5 : Phénomène piézoélectrique.

Les polymères ont une structure moléculaire désordonnée, ils contiennent des zones cristallines et des zones amorphes. La piézo-électricité est un phénomène propre à certains types de cristaux.

Cet effet apparaît à la surface de ces corps quand on les soumet à des pressions ou à des charges électriques.

Sous l'effet d'un champ électrique, la structure piézoélectrique sera le siège de champs de déformations et de contraintes induites. De plus, la charge déposée sur la surface crée une force sur le matériau qui subit une contraction de son volume, cela se traduit alors par l'apparition d'une polarisation électrique à la surface [Llo02].

IV.2.5. Injection de charges

Le phénomène d'injection de charge à partir de la surface du matériau isolant dans le volume est une injection des porteurs de charges déposés sur la surface de l'isolant à travers le volume. Ainsi, une partie du volume de l'isolant change de propriétés électriques et devient chargée (figure IV.6). Par ailleurs, la conduction en volume correspond à un déplacement de charges dans le volume, alors que le matériau reste plutôt neutre.




Fig IV.6 : Injection de charges.

Le phénomène d'injection de charges est le processus qui domine les mécanismes observés dans la littérature sur les mesures de déclin de potentiel [Moli99]. C'est un phénomène assez complexe qui dépend de plusieurs paramètres. L'état de surface ou, son contact avec un autre matériau joue un rôle important sur le processus de l'injection. La décharge couronne, le temps d'exposition à la décharge, ainsi que la température et l'humidité volumique sont des facteurs qui peuvent jouer un rôle de premier plan. Selon Crisci [Cris96] la conduction en volume est surtout présente dans le cas des échantillons minces (épaisseur de l'ordre du micron) mais elle reste également observée dans des échantillons épais.

Tous ces phénomènes peuvent agir en même temps et devront être considérés pour interpréter le déclin. Toutefois, on peut noter la présence prédominante de trois interprétations dans la littérature : la conduction de surface, la conduction de volume et le phénomène de polarisation des matériaux diélectriques. Depuis les premières mesures par Ieda et al [Ied67] sur l'évolution du DPS, bon nombre de travaux ont été réalisés, dans ce sens.

IV.3. Conclusion

L'étude bibliographique de ce chapitre nous montre à la fois le contexte qui a motivé l'intérêt pour les mesures de potentiel de surface et leur mise en œuvre.

Différents mécanismes de polarisation ou de conduction peuvent être impliqués dans l'évolution de l'écoulement des charges déposées sur la surface du matériau isolant. Le problème principal consiste à comprendre à partir d'une courbe le mécanisme prépondérant qui gouverne l'évolution des charges déposées sur la surface de l'isolant. De plus et selon la bibliographie l'un des points importants est le développement d'un modèle de dissipation des charges en fonction des différents paramètres physiques. D'autres études sur les polymères ont montré la pertinence des modélisations thermodynamiques pour certains essais expérimentaux.

Nous remarquons en conclusion qu'en dépit des multiples investigations expérimentales et théoriques sur le transport de charge dans les matériaux isolants, les processus et les paramètres physiques qui interviennent dans le déclin ne sont pas totalement élucidés.

Données

Techniques

Expérimentales

V. Données Techniques expérimentales

V.1. Introduction

Les études sur la charge d'espace se sont multipliées depuis deux décennies dans le domaine de l'isolation polymérique haute tension. Elles ont permis par exemple une plus grande maîtrise des phénomènes initiateurs du vieillissement des câbles, des condensateurs, des transformateurs, ainsi que le développement de nouveaux matériaux. Les phénomènes d'injection et de transport de la charge ont donc été largement étudiés pour divers matériaux utilisés dans ces installations, à commencer par le polyéthylène et le polypropylène. Ce sont les propriétés de surface, notamment le recouvrement de l'hydrophobie, qui ont fait l'objet de la préoccupation industrielle la plus forte, et ont été les plus étudiées [More 01], [Yosh 99] et les études sur les propriétés électriques volumiques se sont souvent limitées à la spectroscopie diélectrique [Nguy 04], [Tunc 00]. L'étude de l'injection et du transport de la charge dans ces matériaux est donc un domaine de recherche relativement inexploré, et pourtant les résultats que nous allons utiliser [Herous 2006] dans nos travaux de recherches font apparaître pour certaines formulations un comportement extrêmement original.

L'appareillage utilisé a été réalisé dans le laboratoire d'électrostatique et de matériaux diélectriques (LEMD) afin de permettre de quantifier par une mesure les niveaux de chargement électrostatique des isolants et des polymères en particuliers. Cette technique qu'on appelle « déclin de potentiel de surface » (DPS) est une méthode d'investigation des propriétés électriques des matériaux isolants. Son intérêt réside essentiellement dans sa simplicité et sa puissance dans la caractérisation de l'aptitude d'un matériau à évacuer une charge électrique déposée à sa surface. L'apparition des sondes électrostatiques fiables (1970) notamment celle à « condensateur vibrant » (type Trek ou Monroe) qui assurent un minimum de perturbation de la surface en s'asservissant au potentiel de celle-ci, a rendu ce type de mesure assez accessible et la technique en elle-même non destructive.

V.2. Mesure du potentiel

La mesure du potentiel de surface implique l'usage de sonde de mesure qui fonctionne selon le principe de condensateur vibrant [Zism32]. La vibration d'un petit volet à l'intérieure de la sonde fait varier la capacité entre ce volet et la surface. Dans le cas où il existe une différence de potentiel ΔV aux bornes de cette capacité un courant proportionnel à la valeur du potentiel électrique circulera dans le circuit selon :

$$I(t) = \Delta V \times \frac{dC}{dt} \quad (5-1)$$

$$= \Delta V \times \frac{d}{dt} \left(\frac{\epsilon \epsilon_0 A}{D_0 + D_1 \sin(\omega t)} \right) \quad (5-2)$$

$$= -\Delta V \epsilon \epsilon_0 A \frac{D_0 \omega \cos(\omega t)}{[D_0 + D_1 \sin(\omega t)]^2} \quad (5.3)$$

Où :

D_0 : Est une constante représentant la séparation entre la surface du matériau et la sonde [m].

D_1 : Est l'amplitude des vibrations [m].

ω : La fréquence angulaire des vibrations $\omega = 2\pi f$ [rad/s] ou f la fréquence en [Hz].

A : Est la surface de la sonde (électrode) [m²].

$\epsilon_r \approx 1$ Pour l'air.

Le principe de mesure est d'annuler en permanence ce courant en faisant varier le potentiel de la sonde et du volet, la sonde est donc au même potentiel que la surface, ce qui permet de perturber le moins possible l'échantillon. Il suffit alors de mesurer le potentiel appliqué à la sonde pour connaître celui de la surface.

La technique expérimentale de mesure de DPS comprend deux phases essentielles :

La première phase consiste à faire un dépôt de charge négative sur la surface du matériau isolant à partir d'une décharge couronne.

La deuxième phase est une quantification par une mesure de l'évolution du potentiel de surface.

V.2.1. Poste de charge

Le poste de charge, (figure V.1) est constitué d'un générateur (Spellman) de tension continue stabilisée entre 0 et ± 20 KV à polarité réversible commandé sur la pointe. L'électrode plane étant connectée à la terre. A l'aide d'un micro-ordinateur on fixe les paramètres de la décharge (temps et valeur de la tension appliquée sur la pointe). La décharge couronne est obtenue à partir d'une tension seuil appliquée sur la pointe (de l'ordre de -7 kV).

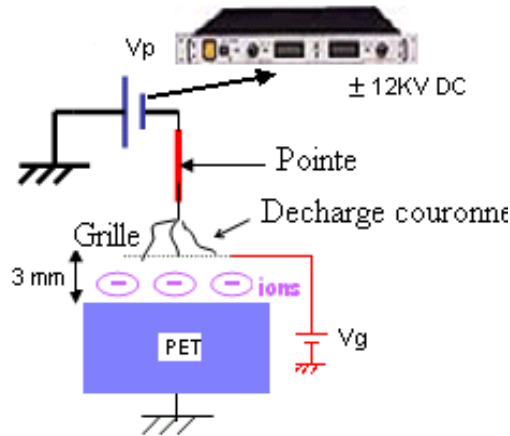


Fig V.1 : Poste de charge.

Une grille répartitrice reliée à une alimentation stabilisée HT est intercalée entre la pointe et la surface de l'échantillon. Son intérêt est double, d'une part le dépôt de charges s'effectue d'une manière homogène sur la surface de l'échantillon et d'autre part, elle nous permet de contrôler expérimentalement le potentiel initial V_0 de la charge déposée sur la surface du matériau.

V.2.2. Poste de mesure

Le poste de mesure est constitué d'une sonde électrostatique reliée à un voltmètre électrostatique digital de type Trek (figure V.2).




Fig V.2 : Poste de mesure.

Les mesures ont été réalisées avec plusieurs températures pour un tau d'humidité relative allant de 20% à 80%. Les échantillons utilisés sont en polyéthylène téréphtalate (PET) et se présente sous forme de plaques de différentes épaisseurs (1 mm et 0.5mm).

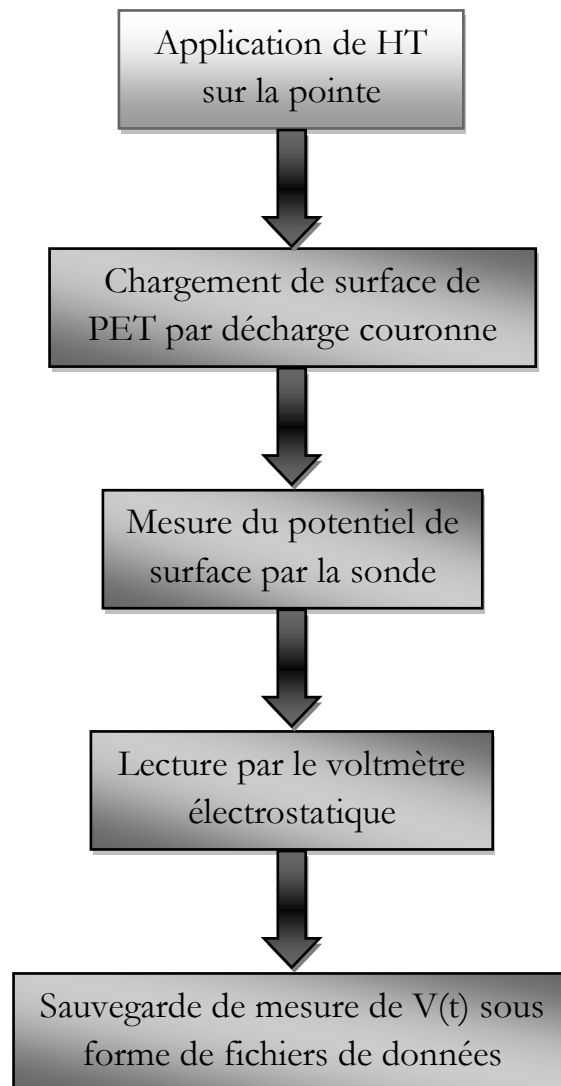


Fig V.3 : Organigramme résume la mesure de potentiel de surface après un dépôt de charge par décharge couronne des échantillons de PET.

V.3. Matériau étudié

Le PET est un thermoplastique appartenant à la famille des polyesters. Sa production a commencé dans les années 50 avec Dupont de Nemours. Depuis, il prend une place de plus en plus importante dans notre vie sous toutes ses formes, films, fibres, contenants. Sa consommation est en constante augmentation.

Le motif du polyéthylène téréphtalate est composé d'un groupe phényl C_6H_4 et du groupe ester qui composent essentiellement le groupe téréphtalate et d'un groupe éthylène.

Le PET peut être considéré comme un matériau modèle pour une étude fondamentale.

V.4. Mesures utilisées

En déposant une charge négative sur la surface de l'isolant puis, en plaçant la sonde du voltmètre digital, on crée une différence de charge entre la sonde et la surface de l'isolant, ce qui donne naissance à une d.d.p. Plus la charge s'écoule plus la d.d.p diminue et plus on transfère de charges à la surface de l'isolant, plus la d.d.p augmente. Cette tension dépend de la distance entre les deux corps et du milieu isolant (air).

En suite, en effectuant des mesures du déclin de potentiel de surface en fonction des épaisseurs différentes du matériau diélectrique, de la température et de l'humidité relative qui sont contrôlées sur une durée de 24 heures et plus.

Les résultats utilisés concernent :

- La mesure du potentiel de surface en fonction de l'épaisseur
- La mesure du potentiel de surface en fonction de la température à humidité relative constante.
- La mesure du potentiel de surface en fonction de l'humidité à température constante.
- La mesure du potentiel de surface en fonction de la tension initiale à température et humidité constante

V.4.1. Résultats de l'étude du PET d'épaisseur 0.5 mm

V.4.1.1. Influence de la température en polarité négative

Nous présentons les résultats de l'effet de la température sur l'évolution temporelle du potentiel en surface d'un échantillon ayant subi un dépôt de charge et ceci en fixant le taux d'humidité relative à 50% et la tension initiale à -1800 V.





Fig V.4 : Effet de la température sur le DPS en polarité négative avec :

$V_0 = -1800 \text{ V}$; $RH = 50\%$ et $T^\circ = \circ : 20^\circ\text{C}$; $\square : 30^\circ\text{C}$; $\blacklozenge : 40^\circ\text{C}$; $\times : 55^\circ\text{C}$; $\blacktriangle : 60^\circ\text{C}$

Les résultats présentés sur la (figure V.4) montrent que le déclin de potentiel en surface dépend fortement de la température. En effet, on remarque que la cinétique du déclin de potentiel en surface s'accroît avec la température et devient de plus en plus importante pour des valeurs plus élevées de la température.

V.4.1.2. Influence de l'humidité en polarité négative

Les mesures de déclin de potentiel en surface sont effectuées dans une gamme d'humidité de 20 à 80% à une valeur de température fixe égale à 55°C. La tension de dépôt de charge correspond à -1800 V. Les résultats de mesure sont donnés sur la (figure V.5).



FigV.5 : Effet de l'humidité relative sur le DPS avec : $V_0 = -1800 \text{ V}$

$T^\circ = 55^\circ\text{C}$ et $RH = \blacklozenge : 20\%$; $\blacksquare : 50\%$; $\blacktriangle : 80\%$

On constate que l'humidité relative agit fortement sur la cinétique du déclin de potentiel en surface pendant toute la durée de mesure. Elle devient de plus en plus importante pour des valeurs plus élevées de l'humidité.

V.4.2. Résultats d'étude du PET d'épaisseur 1 mm

V.4.2.1. Influence de la température en polarité négative

Les mesures de déclin de potentiel de surface sont effectuées dans une gamme de température de 20°C à 60°C à un taux d'humidité relative fixé à 50%. La tension de dépôt de charges correspond à -1800 V. Les mesures sont données sur la (figure V.6).




Fig V.6 : Effet de la température sur le DPS en polarité négative :

RH = 50%, $V_0 = -1800$ V. □ : 60°C ; ■ : 55°C ; □ : 50°C ;

◇ : 40°C ; ■ : 38°C ; △ : 35°C ; × : 30°C ; + : 20°C

V.4.2.2. Influence de l'humidité relative en polarité négative

Sur la (figure V.7), nous présentons les mesures de déclin de potentiel de surface pour différentes valeurs de l'humidité relative. La température a été maintenue constante égale à 55°C et le potentiel initial de dépôt à -1800V.

Nous avons observé une importante dépendance du DPS. De plus, la dépendance devient encore plus significative pour des valeurs plus élevées de l'humidité.




Fig V. 7 : Effet de l'humidité relative sur le DPS :

▲ : 80% ; + : 50% ; ● : 20% ; avec : $V_0 = -1800$ V ; $T^\circ = 55^\circ\text{C}$

V.5. Les réseaux de neurones appliqués aux matériaux

Les réseaux de neurones artificiels simulent très étroitement le système nerveux biologique.

Ce sont des modèles de calcul parallèle pour la représentation et le traitement de l'information. Du fait de leur grande similitude avec le cerveau, les réseaux de neurones ont des capacités semblables à celle de l'être humain et notamment ; l'apprentissage, la classification et la simulation ou prédiction [Krös 96].

Les réseaux de neurones sont des modèles de calcul très robustes et tolérants aux informations bruitées ou même incomplètes, ces caractéristiques ont fait des réseaux de neurones un bon candidat pour une large variété d'applications en génie civil. Parmi les premiers articles publiés dans ce domaine c'est celui de Adeli et Yeh [Adel 89] paru en 1989 décrivant l'utilisation et l'apprentissage du perceptron dans la conception en ingénierie, et depuis plusieurs équipes se sont orientés vers l'application des réseaux de neurones aux problèmes de mécanique des structures, modélisation des matériaux, contrôle des vibrations, prédiction de fissures, détection des dommages, régulation des transports et la liste est longue [Ghab 93, 94], [Rafi 01] et [Rafi 01]. Dans le domaine des matériaux bons nombres d'applications ont vu le jour, surtout dans les domaines de la modélisation, de la composition des matériaux, de la durabilité des matériaux composites de la fissuration etc.

Le domaine de l'isolation présente des caractéristiques bien spécifiques qu'il est indispensable d'en tenir compte dans la construction d'une démarche globale de prévention des risques. La qualité doit être garantie par une surveillance et un contrôle permanents à travers des mesures qualifiables et quantifiables dans le but de ne pas ralentir la production et d'en assurer un niveau de qualité élevé et uniforme.

Durant ces dernières années, d'importants efforts ont été déployés dans le développement de méthodes de contrôle et de surveillance automatique dans ce domaine. Les techniques de l'intelligence artificielle qui servent comme outil de base pour l'aide à la décision, présentent une réponse plus élaborée qui peut être obtenue soit à partir de données brutes venant directement des variables de surveillance, soit à partir de données traitées venant des sorties de traitements de bas niveau [ZEM 03]. Parmi ces techniques, on trouve les réseaux de neurones artificiels (RNAs) qui se démarquent des autres outils par leurs capacité et rapidité d'apprentissage. Présentant des performances dans plusieurs domaines.

V.5.1. Modélisation

Comme dans d'autres domaines, les mathématiques ont joué un rôle très important dans le domaine de la modélisation. Les modèles mathématiques sont souvent essentiels dans la compréhension du comportement du milieu étudié, et donnent beaucoup d'informations utiles pour la phase de conception. Cette approche a fait ses preuves et ses limitations sont de plus en plus perceptibles. Les réseaux de neurones offrent une approche très différente de la méthode analytique du fait de leur capacité d'apprentissage et de la disponibilité de données.

En effet, le point de départ dans la modélisation des matériaux est toujours un ensemble de résultats expérimentaux. Dans la technique de modélisation analytique traditionnelle, le comportement du matériau est observé dans le but d'identifier ses caractéristiques, une fois chose faite, un modèle mathématique est développé pour simuler ce comportement. Ce processus consiste à coder la connaissance du comportement dans un ensemble de règles mathématiques.

La technique de modélisation par les réseaux de neurones introduite par J. Ghaboussi [Wu 90, 91, 92] [Ghab 90, 91] et son équipe Wu et Garrett en 1991, utilise la capacité d'apprentissage de ces derniers pour simuler le comportement du matériau. A partir des tests de laboratoire, le réseau de neurones subit la première phase d'apprentissage, qui fait que l'information est codée et stockée dans le poids des interconnexions. La deuxième phase est celle de la simulation (validation), dans cette phase les données de quelques tests non-utilisés dans la phase d'apprentissage sont pris et comparés aux résultats obtenus par le réseau de neurones. Les auteurs ont trouvé que cette technique donnait de très bons résultats. Tout ça sans avoir recours à développer des règles ou utiliser des approximations analytiques.

Souvent les tests sont conçus pour que l'état de contrainte en un point soit constant. Sidarta et Ghaboussi [Ghab 94] et [Sida 98] ont publié des travaux sur la modélisation des matériaux en géotechniques en introduisant de nouveaux tests faisant inclure un état de contrainte non uniforme. En utilisant les réseaux de neurones ils ont montré qu'on pouvait, à partir d'un seul test, extraire plus d'informations qu'à partir de plusieurs tests traditionnels.

V.6. Structuration des données

La mise en œuvre d'un réseau de neurones artificiels nécessite de déterminer les entrées pertinentes, c'est-à-dire les grandeurs qui ont une influence significative sur le phénomène que l'on cherche à modéliser. Il s'agit également de collecter les données nécessaires à l'apprentissage et à l'évaluation des performances du réseau de neurones. Afin de s'assurer de la capacité de généralisation du RNA et donc de sa performance, la banque de données expérimentales est divisée en trois parties : base d'apprentissage (dédiée à l'optimisation des poids), base de validation et base de généralisation. La segmentation des données en 3 banques distinctes doit être réalisée en suivant quelques règles élémentaires. La banque de données se divise en trois groupes aléatoirement. Par ailleurs, il faut s'assurer que la banque d'apprentissage contient les exemples présentant des valeurs extrêmes des variables d'entrée. Le RNA se ramène en effet à une régression réalisée sur des données expérimentales, et, à ce titre, ses capacités d'extrapolation sont limitées.

V.7. Evaluation de la performance

La performance des RNA peut être évaluée de différentes façons. Les erreurs calculées lors de l'optimisation sur les bases d'apprentissage et de généralisation donnent une première indication. Cependant, il est nécessaire d'éprouver également le RNA sur des données non impliquées dans le processus d'apprentissage. A ce titre, la base de généralisation n'est pas éligible car elle participe à l'apprentissage dans le sens où elle conditionne l'arrêt du processus d'optimisation. C'est ici qu'intervient la base de test. Sur les données de la base de test, le RNA est réellement éprouvé en aveugle.

Il est usuel d'évaluer la performance sur des graphiques représentant la corrélation entre les valeurs prédites et les valeurs cibles. Naturellement, plus le nuage de point est resserré autour de la droite de corrélation parfaite ($y=x$), meilleure est la performance. Ces représentations permettent également de quantifier facilement l'erreur absolue commise sur les prédictions.

V.8. Le réseau de neurones utilisé

Le travail présenté dans cette partie, utilise ces RNAs intégrés dans un système de surveillance dédié au contrôle de déclin de potentiel de surface d'un échantillon de PET. Un module d'apprentissage supervisé par un expert humain collecte de façon continue et permanente les paramètres relatifs aux différents états de l'échantillon de PET pour la mise en œuvre d'une base de connaissance.

Notre objectif recherché se limite toutefois à la validation par simulation des RNAs dans ce domaine. Une évaluation des performances en matière de temps d'apprentissage, de taux de

reconnaissance est effectuée. Les paramètres descripteurs choisis dans l'analyse sont comme suit : la température (T°), l'humidité relative (HR), l'épaisseur (ϵ), et la haute tension (HT). En utilisant le perceptron multicouche avec au moins une seule couche cachée, (figure V.8).




Fig V.8 : Perceptron multicouche PMC.

Les neurones de la couche cachée ont la capacité de traiter l'information reçue. Chaque neurone effectue deux opérations bien distinctes, à savoir une somme pondérée de ses entrées, suivie d'une transformation par une fonction d'activation non linéaire, continue, et complètement dérivable. Plusieurs fonctions de ce type existent, notre choix est porté cependant sur la fonction sigmoïde.

Ce type de fonctions a la propriété d'être différentiable ; les fonctions dérivées qui en résultent peuvent être exprimées facilement à l'aide de ces mêmes fonctions, ce qui assure un gain en temps de calcul non négligeable. L'apprentissage supervisé par le réseau consiste à déterminer les poids qui minimisent sur l'ensemble des données de la base d'entraînement, les écarts entre les valeurs de la sortie désirée y_r , et les valeurs de la sortie décidée y_d .

La technique traditionnellement employée pour effectuer l'apprentissage supervisé est l'algorithme de rétro propagation de l'erreur [DAV 93]. Initialement, on utilisait la méthode d'optimisation non linéaire du gradient [TOR 97]. Une méthode connue pour avoir un comportement oscillatoire proche de la solution. Actuellement les méthodes dites du 2ème ordre sont plutôt préférées ; elles fournissent toutefois de bien meilleurs résultats. Parmi les plus connues, citons la méthode de Levenberg-Marquardt utilisée dans notre application.

V.9. Simulation

Il n'existe pas de procédure rigoureuse permettant de définir l'architecture d'un RNA pour un problème donné. Plusieurs architectures peuvent conduire à des résultats comparables en termes de performance. Il convient alors de sélectionner l'architecture la plus simple au regard d'un objectif fixé. Pour cela, on a testé plusieurs architectures de RNA présentant différents degrés de complexité et en choisissant la plus efficace.

Le choix des algorithmes d'apprentissage est toujours délicat et demande beaucoup de réflexion. Il se base principalement sur la connaissance physique du phénomène à modéliser. Nous proposons ici des modèles neuronaux de type Perceptron Multi-Couches : Les uns utilisent l'algorithme de Levenberg-Marquardt. Les autres utilisent l'algorithme de Scaled conjugate gradient. Cette démarche a été mise en œuvre afin de choisir le meilleur et le plus adapté pour la prédiction du déclin de potentiel de surface d'un échantillon de PET.

Les modèles de RNA implantés disposent de quatre neurones en entrée correspondant aux capteurs utilisés. Différentes architectures sont testées pour déterminer le nombre adéquat de couches et de neurones cachés. Pour cela les algorithmes d'apprentissage (Scaled conjugate gradient et Levenberg-Marquardt) sont tous les deux utilisés. On présente dans le (tableau V.1) les résultats correspondants. Les paramètres tels que le nombre d'itérations (NI), le temps d'apprentissage (T_{appr}) et l'erreur d'entraînement (Er) sont indiqués pour différents types de réseaux testés.

Tabl V.1 : Etude comparative entre les deux algorithmes
Levenberg-Marquardt et Scaled conjugate gradient

Algorithme	Architecture du réseau		NI	T-app Sec	Er
	Nbre de couches cachées	Nbre de neurones en CC			
Levenberg- Marquardt	1	3	50	5	0.0030
		4	500	11	0.0080
		6	2000	25	0.0066
		8	1000	16	0.0085
		16	3000	61	0.0054
		20	50	175	0.0141
	2	3 – 6	3000	15	0.0034
		6 – 8	1000	39	0.0090
		16 – 20	3000	691	0.0064
	3	2 – 3 – 4	500	14	0.0091
6 – 8 – 10		1000	82	0.0055	
Scaled conjugate gradient	1	3	50	1	0.0826
		4	500	10	0.1004
		6	2000	22	0.0165
		8	1000	11	0.2616
		16	3000	35	0.1014
		20	50	87	0.1314
	2	3 – 6	3000	13	0.4200
		6 – 8	1000	29	0.0082
		16 – 20	3000	132	0.0989
	3	2 – 3 – 4	500	17	0.3196
6 – 8 – 10		1000	35	0.2153	

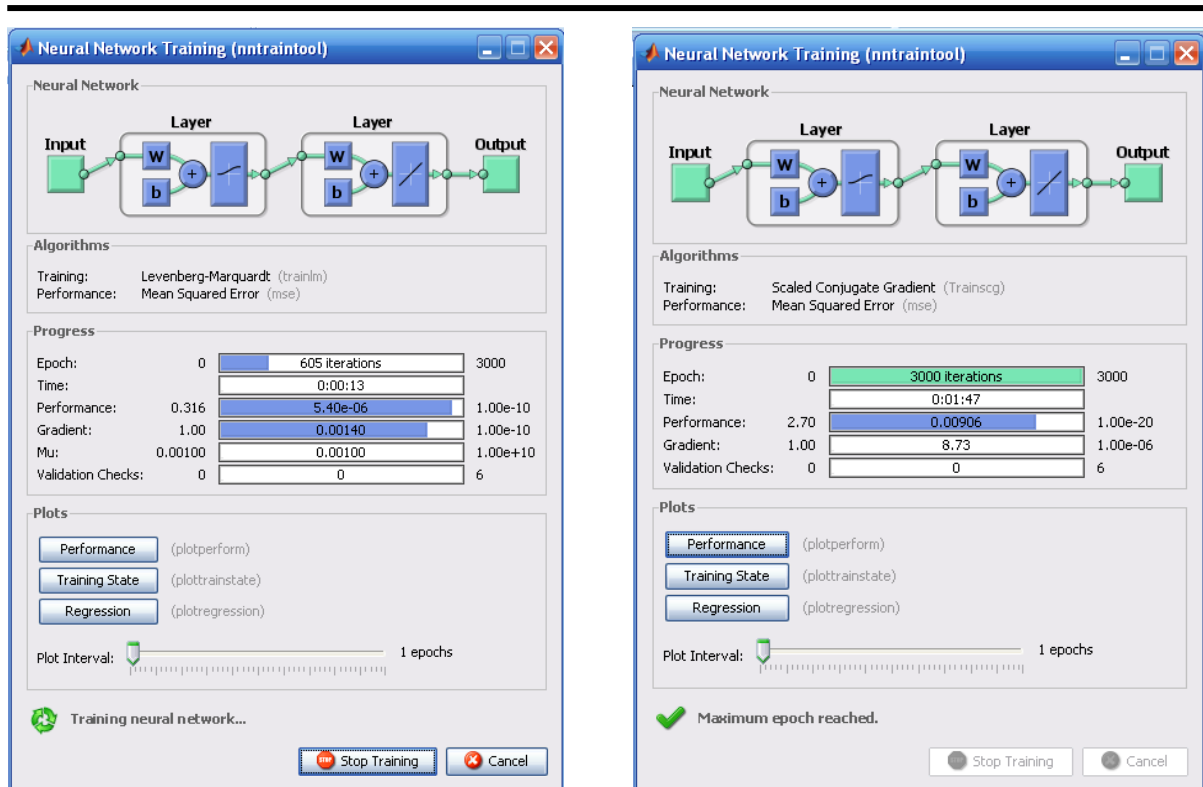


Fig V.9. Représentation de réseaux de neurones sur MATLAB.

Les résultats montrent qu'avec l'application de l'algorithme « Scaled conjugate gradient », l'erreur d'entraînement reste relativement faible (0.0082 pour le réseau à deux couches cachées). Pour les autres architectures, ce type d'algorithme présente des erreurs plus importantes (allant jusqu'à 0.4200), remarquant qu'il réagit plus rapidement que l'autre algorithme (le temps d'apprentissage est de l'ordre d'une sec pour une architecture d'une seule couche cachée à trois neurones).

Cependant l'utilisation de l'algorithme de « Levenberg-Marquardt » est plutôt préférable, car il fournit de bien meilleurs résultats (une erreur d'entraînement de 0.0030 pour une architecture à trois neurones dans la couche cachée). Le réseau à trois neurones dans la couche cachée utilisant ce même algorithme s'avère le mieux adapté. Il se caractérise par un temps d'apprentissage de 5sec et une erreur d'entraînement de 0.0030.

Cette procédure consiste à tester différentes architectures et à retenir l'architecture la plus efficace au regard d'un objectif de performance fixé.

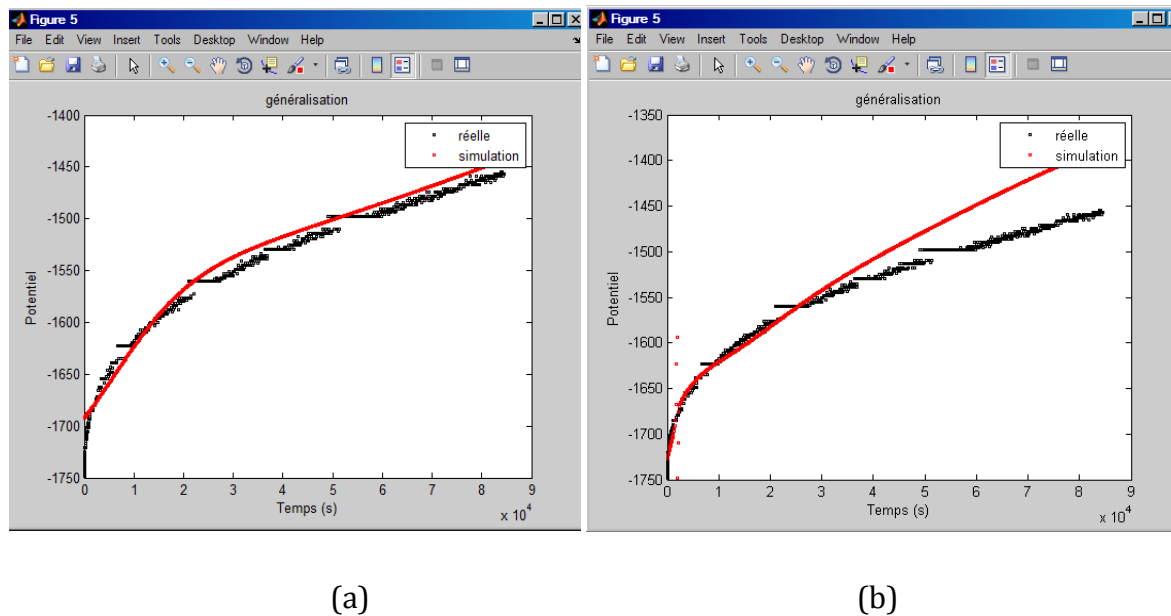


Fig V.10 : Comparaison entre l'erreur obtenue par l'algorithme de (a) « Levenberg-Marquardt » et celle de (b) « Scaled conjugate gradient », pour la base de généralisation.

Le teste précédent (tableau V.1) nous conduit à éliminer l'utilisation de l'application de l'algorithme de « Scaled conjugate gradient » et continuer nos essais seulement avec l'algorithme de « Levenberg-Marquardt » car il est le plus adapté et présente les meilleurs résultats.

Observant le graphe correspondant à l'architecture d'une seule couche cachée à trois neurones ; la sortie simulée est très proche à celle réelle se qui confirme l'utilité de l'application de cette architecture avec l'algorithme de « Levenberg-Marquardt ». Pour cela nous utilisons dans tout ce qui suit la même architecture (une seule couche cachée) avec le même algorithme, en changeant chaque fois le nombre de neurones en couche cachée, ainsi l'intervalle d'apprentissage et celle de validation.

Après avoir testé plusieurs configurations, on a sélectionné une combinaison de fonctions de transfert : *logsig* en couche cachée et *purelin* en couche de sortie.

V.10. Conclusion

D'après l'ensemble d'essais expérimentales on a enregistré une base de données (couple : entrées, sortie) sous forme matricielle, où les entrées sont : la température, l'humidité relative, la tension et l'épaisseur avec une sortie correspond au déclin de potentiel de surface (DPS) de polyéthylène téréphtalate (PET).

Les résultats obtenus montrent que l'échantillon de polyéthylène téréphtalate soumis à des températures allant jusqu'à 38°C montre un léger déclin de potentiel de surface. Au de là de cette température le PET marque des DPS importants. Donc dans le reste de notre travail on prend en considération que les températures supérieures à 40°C.

L'architecture à une seule couche cachée donne des bons résultats. Alors on ne constate pas d'apport significatif de la 2^{ème} et la 3^{ème} couche cachée concernant l'erreur de généralisation. Par contre, les comparaisons portant sur l'algorithme de « Levenberg-Marquardt » et de « Scaled conjugate gradient », montrent clairement que le PMC entraînant par l'algorithme de « Scaled conjugate gradient » à une couche cachée est moins performant sur la base de généralisation.

On remarque aussi qu'on peut avoir un bon résultat avec un nombre d'itération égale à 50 pour une architecture à une couche cachée à 3 neurones, mais on constate également qu'avec le même nombre pour autres architectures l'erreur soit importante. Et dès que ce nombre augmente, l'erreur se diminue, pour cela on fixe le nombre d'itération à 3000.

Après avoir défini le nombre de couche cachée optimal, plusieurs PMCs ayant une couche cachée à (3 à 20) neurones par couche ont été testés afin de prédire le déclin de potentiel de surface de l'échantillon de polyéthylène téréphtalate. Ce que nous verrons au chapitre suivant.

Résultats et discussions

VI. Résultats et discussions

VI.1. Introduction

Ce chapitre présente les détails et les résultats d'une campagne d'essais visant à constituer une banque de données expérimentales associant les contraintes climatiques, électrique et géométrique au déclin de potentiel de surface d'un échantillon de PET. Ce travail constitue la base du développement de modèles statistiques (réseaux de neurones artificiels) dédiés au déclin de potentiel de l'échantillon. Les contraintes climatiques visées sont la température et l'humidité. La contrainte électrique est la tension, et la caractéristique géométrique visée est l'épaisseur.

Notre problématique consiste à trouver un modèle paramétrique neuronal à partir de certains paramètres d'entrée et nous devons évaluer sous forme d'une courbe d'une charge déposée sur la surface d'un isolant comme paramètres de sortie du réseau à réaliser. Donc, il y a ici un problème de régression (apprentissage supervisé) ou bien on appelle aussi un problème d'estimation.

Expérimentalement, nous devons enregistrer une "base de données (couple : entrées-sorties)" sous forme matricielle, chaque entrée (composé de quatre paramètres (température, humidité, tension, épaisseur) avec leur sortie). Le module d'apprentissage, supervisé, permet de collecter de manière continue les paramètres relatifs aux différents états, pour la mise en œuvre d'une base de données complète.

Dans ce chapitre, nous présentons les résultats expérimentaux et les discussions obtenues lors de la modélisation d'un échantillon en polyéthylène téréphtalate (PET) chargé en surface par effet couronne négatif. Le réseau de neurone utilisé est le perceptron multicouche (Multilayer perceptron) avec quatre entrées, la température T ($^{\circ}\text{C}$), l'humidité relative HR (%), l'épaisseur ϵ (mm), et la haute tension HT (V). Une couche cachée (le nombre de neurones varie de 3 à 20 neurones), et une couche de sortie à un seul neurone correspond au potentiel de surface de l'échantillon de PET de deux épaisseurs différentes : 1 mm et 0.5 mm.

Nous verrons comment ces résultats peuvent être reliés aux phénomènes expliquant l'évolution des charges sur la surface du matériau et dans quelle mesure les méthodes d'analyse peuvent contribuer à l'identification du mécanisme prépondérant.

VI.2. Résultats d'étude

Les mesures de déclin de potentiel de surface sont effectuées à une température supérieure à 40°C à un taux d'humidité relative varie entre 20% à 80%. La tension de dépôt de charges allant jusqu'à -1800 V, l'épaisseur de l'échantillon varie entre 0.5mm et 1mm. Plusieurs architectures de réseaux sont testées, utilisant l'algorithme de Livenberg-Marquardt, et la sigmoïde comme fonction d'activation en couche cachée, et la fonction purelin en couche de sortie. En variant l'intervalle d'apprentissage et de validation à fur et à mesure.

Les résultats de mesure sont donnés sur les tableaux suivants, ainsi les graphes correspondants.

Le développement du modèle neuronal a été effectué à l'aide de Matlab et de la boîte à outils 'Neural Network'. La boîte à outils 'Neural Network' de Matlab présente de nombreux avantages : définition simple des architectures, choix des critères d'arrêt, choix des fonctions de transfert, choix des algorithmes d'optimisation...

VI.2.1. Algorithme d'apprentissage

Après avoir testé les performances des différents algorithmes d'apprentissage en termes de temps de calcul et de qualité des solutions, nous avons retenu l'algorithme de Levenberg- Marquardt. L'avantage observé de ce dernier réside dans la réduction de l'erreur de calcul, le temps étant pratiquement du même ordre de grandeur que celui produit par l'autre algorithme testé (Scaled conjugate gradient).

VI.2.2. Fonction de transfert

La fonction de transfert (ou fonction d'activation) applique une transformation linéaire ou non linéaire aux valeurs sommées. Les RNAs peuvent utiliser n'importe quelle fonction différentiable comme fonction de transfert. Les fonctions ($a=f(n)$) décrites ci-après sont les deux fonctions utilisées pour l'apprentissage de notre réseau.

_ La fonction log-sigmoïde (*logsig*) : la plus fréquente

$$a = \frac{1}{1 + e^{-n}}$$

Il s'agit d'une fonction non linéaire qui génère des sorties entre 0 et 1 (figure IV.5A).

_ La fonction linéaire (*purelin*)

$$a = n$$

La fonction purelin est une fonction linéaire parfois utilisée dans les RNA à rétropropagation quand on veut que les sorties ne se limitent pas à un domaine précis, car cette fonction génère des sorties pouvant prendre n'importe quelle valeur (figure IV.5B).




Fig VI.1 : Graphes caractéristiques des fonctions *logsig* et *purelin* (nomenclatures Matlab).

Nous présentons la procédure d'optimisation des modèles : définition de l'architecture du réseau, modification du nombre de neurones par couche cachées, informations d'entrées, sorties.

La base de données utilisée pour la mise en œuvre de ces RNAs est constituée de plusieurs exemples composés en trois groupes, groupe d'apprentissage du réseau, de validation, et de généralisation. Le choix des trois groupes d'exemples a été fait de manière aléatoire.

VI.3. Optimisation de l'architecture du RNA

Cette partie présente la démarche d'optimisation de l'architecture du RNA. Les variables d'optimisation est ici le nombre de neurones en couche cachée, ainsi le nombre d'exemples de la base d'apprentissage et celle de validation.

Les performances des RNAs testés sont évaluées sur la base de deux critères qui sont :

- Le coefficient de corrélation (R).

$$R = \frac{\sum (T - \bar{T})(S - \bar{S})}{\sqrt{\sum (T - \bar{T})^2} \times \sqrt{\sum (S - \bar{S})^2}}$$

- L'erreur quadratique moyenne (EQM) ;

$$EQM = \frac{1}{N} \sum (T - S)^2$$

Où :

T = la sortie désirée

S = la sortie du réseau

\bar{T} = la moyenne des sorties désirées

\bar{S} = la moyenne des sorties RNA

Ces 2 coefficients reflètent les qualités de précision et de généralisation du réseau.

VI.3.1. Essai N° : 01

litr=[1 :4 ;q] ; lival=[4 :4 ;q]

Tab VI.1 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	MSE-Apprentissage	MSE-Validation	MSE-Généralisation
3	0.0010	0.2641	0.0061
4	0.0026	0.2646	0.0068
5	0.0101	0.2647	0.0066
6	0.0121	0.2647	0.0035
7	5.1746 e ⁻⁰⁰⁴	0.2647	0.0059
8	0.0197	0.2632	0.0067
9	0.0012	0.2647	0.0401
10	5.6501 e ⁻⁰⁰⁴	0.2647	0.1415
11	0.0026	0.2647	0.0106
12	6.4349 e ⁻⁰⁰⁴	0.2647	0.0115
13	0.0018	0.2647	0.0178
14	5.8392 e ⁻⁰⁰⁴	0.2647	0.0071
15	5.2213 e ⁻⁰⁰⁴	0.2647	0.0101
16	9.5771 e ⁻⁰⁰⁴	0.2647	0.2035
17	0.0018	0.2644	0.0644
18	5.4214 e ⁻⁰⁰⁴	0.2647	0.0139
19	5.0415 e ⁻⁰⁰⁴	0.2647	0.0109
20	6.8941 e ⁻⁰⁰⁴	0.2647	0.0365

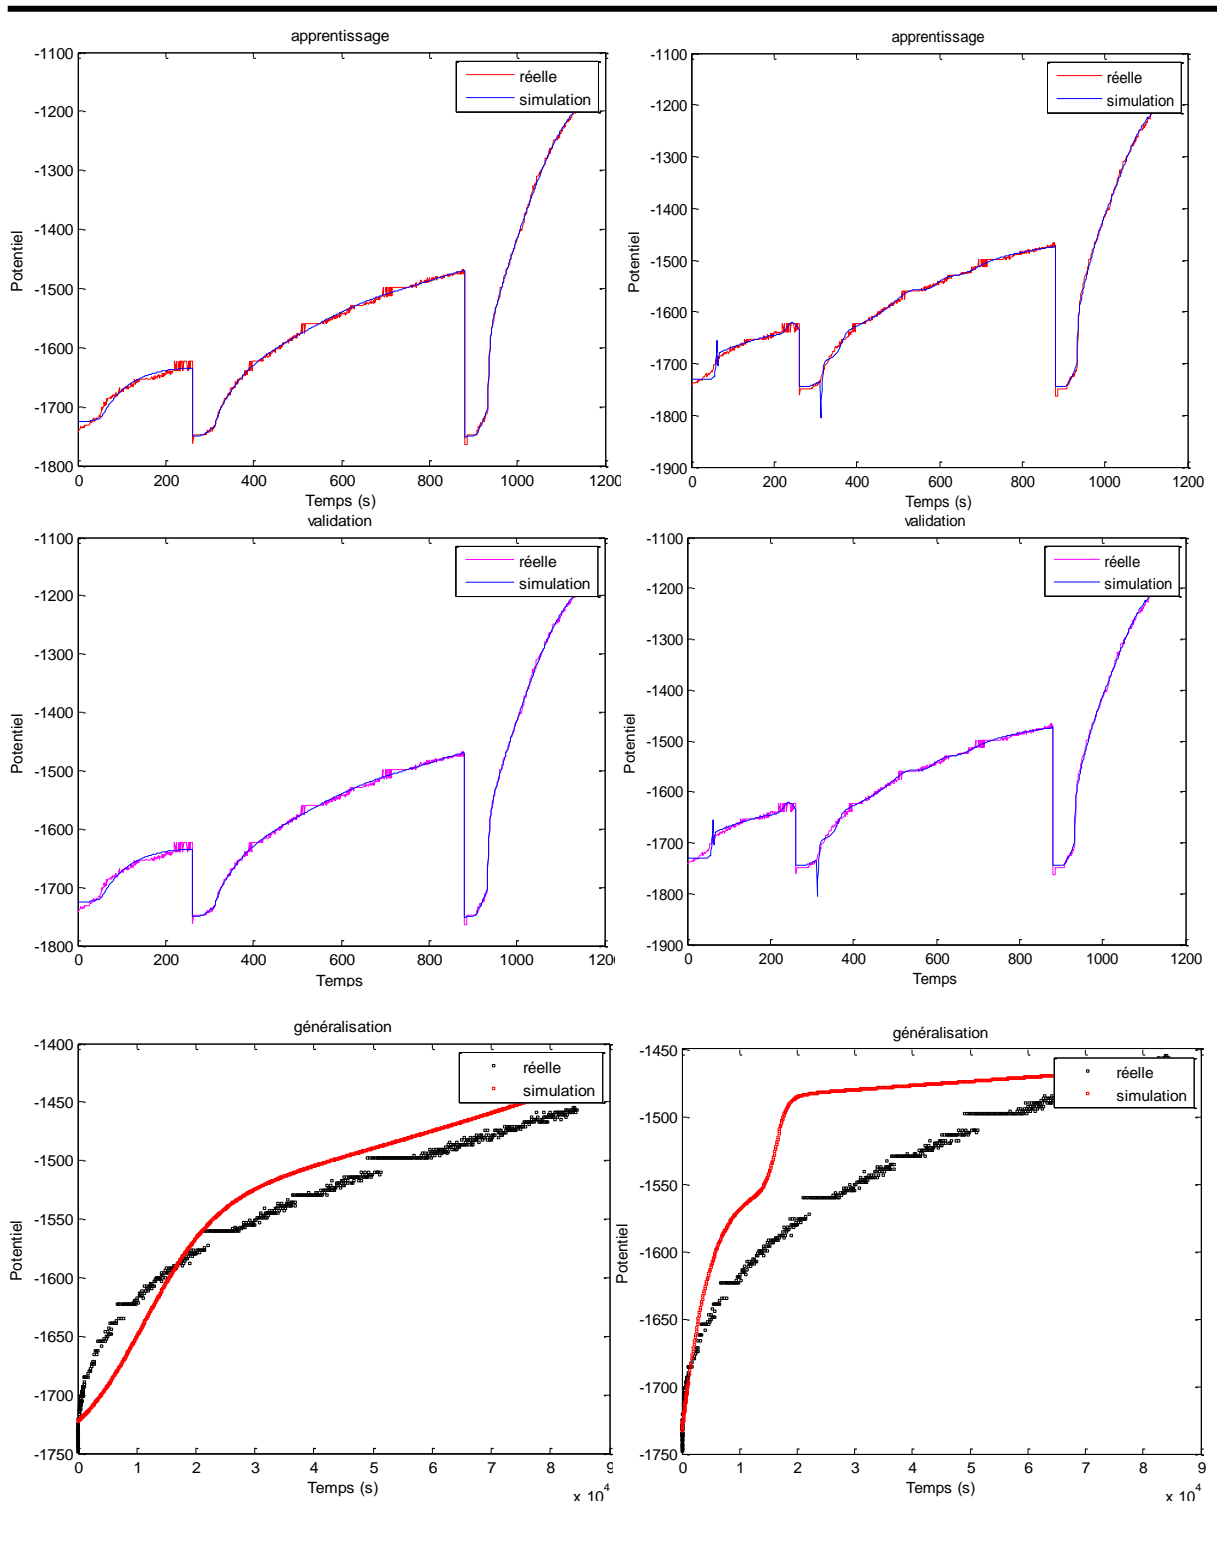


Fig VI.2 : Prédiction du déclin de potentiel de surface par les PMCs à 6 et 7 neurones respectivement

Pour les intervalles $I_{itr}=[1 :4 ;q]$; $I_{ival}=[4 :4 ;q]$.




Fig VI.3 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMC à 6 et 7 neurones.

● Résultats

Sur le tableau VI.1, on peut constater que les MSE mesurées sur la base de généralisation commencent à se stabiliser au tour de 0.006 pour des réseaux à 3, 4, 5, 6, 7 et 8 neurones en couche cachée. Au-delà de ce nombre de neurones, les erreurs atteignent des valeurs importantes. Les erreurs enregistrées pour un réseau à 6 neurones en couche cachée sont de 0.0121 sur la base d'apprentissage, 0.2657 sur la base de validation et 0.0035 sur la base de généralisation

On constate également des très bonnes prédictions de DPS pour les bases d'apprentissage et de validation avec les deux architectures (à 6 et 7 neurones). Ce qui traduit clairement par les coefficients de corrélation obtenus.

L'évolution du coefficient de corrélation (R) en fonction du nombre de neurones en couche cachée est présentée sur (la figure VI.3) (architecture à 1 couche cachée). Cette figure montre que pour un nombre de neurones égal à 6 et 7, une bonne corrélation est enregistrée pour la base d'apprentissage ($R_6=0.99964$ et $R_7=0.99821$).

Les 2 critères montrent que la performance des RNAs s'améliore lorsque le nombre de neurones augmente jusqu'à 8 neurones. Avec ce nombre de neurones en couche cachée, on note une stabilisation des performances, dès que ce nombre augmente l'erreur soit importante. On conserve alors l'architecture la plus simple générant le niveau de performance optimal, soit 6 neurones en couche cachée.

VI.3.2. Essai N° : 02

litr=[1 :2 ;q] ; lival=[2 :3 ;q]

Tab VI.2 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	MSE-Apprentissage	MSE-Validation	MSE-Généralisation
3	0.0015	0.2647	0.0135
4	0.0013	0.2647	0.0031
5	$8.4419 e^{-004}$	0.2647	0.0071
6	0.0088	0.2643	0.0076
7	$6.7385 e^{-004}$	0.2647	0.0073
8	$6.3152 e^{-004}$	0.2647	0.0232
9	$6.1549 e^{-004}$	0.2647	0.1072
10	0.0037	0.2617	0.0064
11	0.0185	0.2645	0.0314
12	0.0015	0.2647	0.0249
13	$5.5550 e^{-004}$	0.2647	0.1035
14	$5.8141 e^{-004}$	0.2647	0.0140
15	0.0061	0.2648	0.2130
16	$5.6967 e^{-004}$	0.2647	0.0168
17	$7.8002 e^{-004}$	0.2647	0.0221
18	0.0675	0.02645	0.0123
19	0.0381	0.2668	0.3685
20	0.0020	0.2647	0.0085

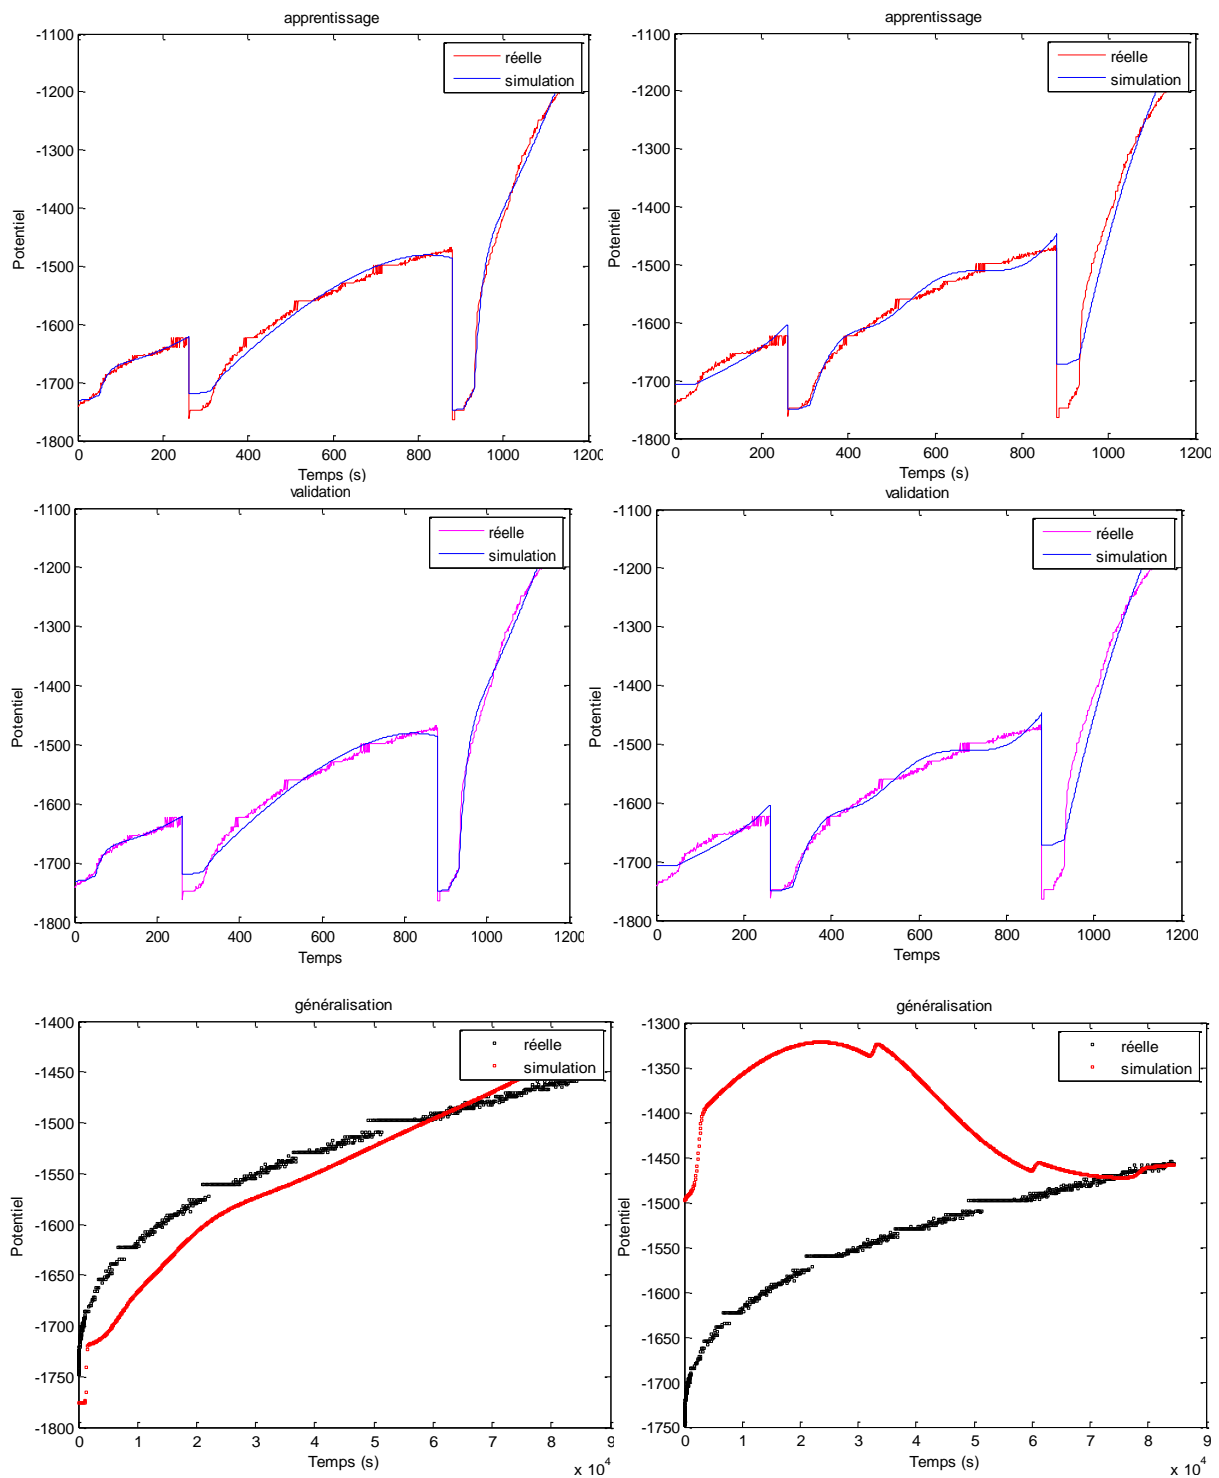


Fig VI.4 : Prédiction du déclin de potentiel de surface par les PMCs à 4 et 10 neurones

Pour les intervalles $l_{itr}=[1 :2 ;q]$; $l_{ival}=[2 :3 ;q]$.




Fig VI.5 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMCs à 4 et 10 neurones.

● Résultats

Le tableau précédant présente les erreurs des trois banques de données : d'apprentissage, de validation et de généralisation pour plusieurs architectures (nombre de neurones en couche cachée vari de 3 à 20), nous choisissons les résultats les plus répondus dont l'erreur de généralisation est la plus petite avec un tau de corrélation adéquat.

La (figure VI.4) illustre l'erreur entre les potentiels de surface de l'échantillon de PET mesurés et prédits pour les trois bases de données, par les deux architectures des réseaux à 4 et 10 neurones en couche cachée respectivement, on note une bonne prédiction sur tout l'ensemble d'exemples constituant les bases d'apprentissage et de validation. Sur la base de généralisation, on note aussi que les potentiels sont prédits avec des erreurs égales à 0.0031 et 0.0064

La (figure IV.5) représente les coefficients de corrélation correspondants. La corrélation est très bonne avec des coefficients de corrélation (R) égaux à 0.99738 et 0.997, pour les réseaux à 4 et 10, respectivement. Ces résultats témoignent donc des qualités de généralisation du réseau à 4 neurones en couche cachée.

VI.3.3. Essai N° : 03

litr=[2 :1 ;q] ; lival=[1:5 ;q]

Tab VI.3 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	MSE-Apprentissage	MSE-Validation	MSE-Généralisation
3	0.0015	0.2647	0.0031
4	0.0037	0.2647	0.0051
5	6.6546e-004	0.2647	0.0121
6	7.3732e-004	0.2647	0.0165
7	0.0027	0.2647	0.0119
8	0.1042	0.3257	0.1581
9	6.2596 e ⁻⁰⁰⁴	0.2647	0.1918
10	8.7856 e ⁻⁰⁰⁴	0.2647	0.0745
11	6.7362 e ⁻⁰⁰⁴	0.2647	0.0160
12	0.0046	0.2647	0.0248
13	0.0013	0.2647	0.0106
14	0.0068	0.2647	0.1746
15	0.0247	0.2707	0.0733
16	0.0013	0.2647	0.0678
17	6.5656 e ⁻⁰⁰⁴	0.2644	0.0169
18	0.0083	0.2644	0.0095
19	5.2780 e ⁻⁰⁰⁴	0.2647	0.0140
20	5.5850 e ⁻⁰⁰⁴	0.2647	0.0182

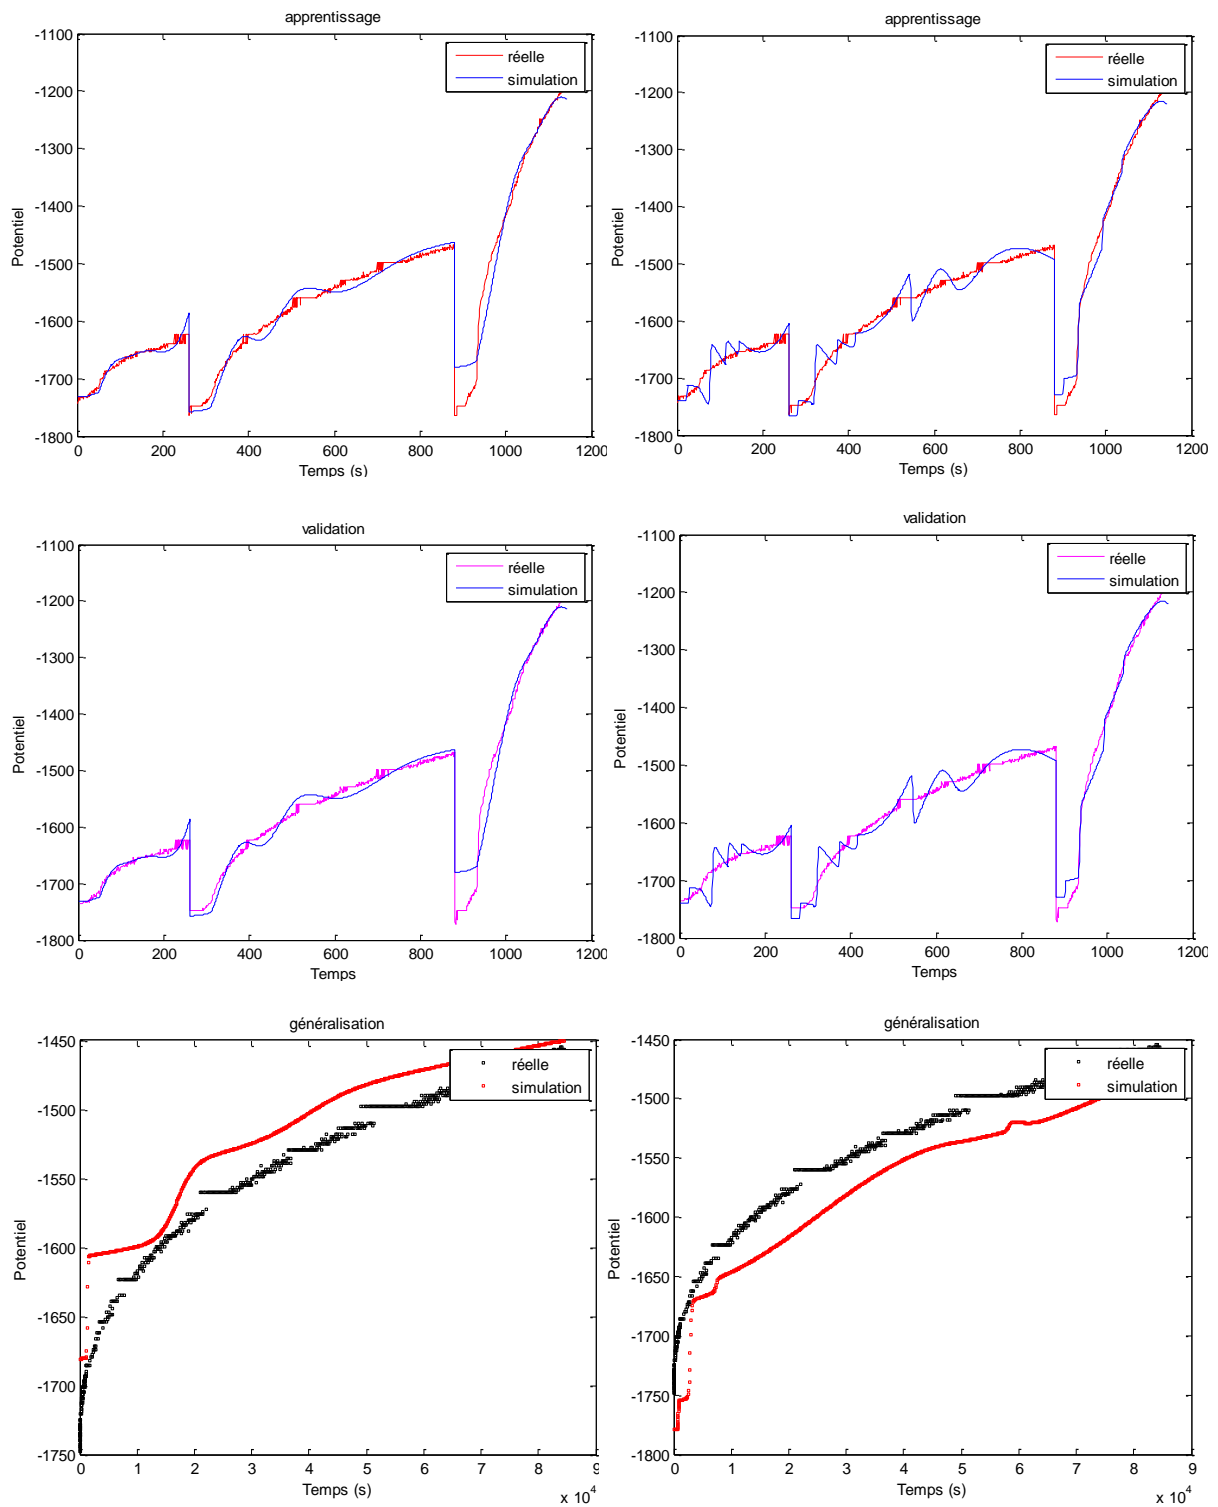


Fig VI.6 : Prédiction du déclin de potentiel de surface par les PMCs à 3 et 4 neurones

Pour les intervalles $I_{tr}=[2 : 1 ; q]$; $I_{val}=[1 : 5 ; q]$.




Fig VI.7 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMC à 3 et 4 neurones.

● Résultats

Le tableau montre clairement qu'avec les deux intervalles utilisés, les erreurs sur la phase de généralisation enregistrées sont importantes, sauf avec deux types de perceptrons multi couches l'un à trois et l'autre à quatre neurones en couche cachée.

Sur (la figure VI.7), nous montrons la corrélation existant entre les potentiels des surfaces mesurées et calculées pour la banque d'apprentissage par les deux modèles de réseaux. Cette figure montre que ces deux modèles de réseaux prédisent le potentiel de surface avec une bonne précision (coefficients de corrélation égal à 0.9989 et 0.99305). En effet, nous marquons que les exemples sur la banque d'apprentissage sont prédits avec une erreur de potentiel de surface de l'échantillon de PET égale à 0.0015 et 0.0037, pour les réseaux à 3 et 4 neurones respectivement. Concernant la base de généralisation, l'erreur mesurée est égale à 0.0031 et 0.0051 pour respectivement 3 et 4 neurones. Sur la base de validation, l'erreur mesurée est pratiquement constante le long des essais (0.2647). En fin, seulement deux modèles de réseaux sont optimaux dans cette partie, comparant ces deux résultats nous choisissons le réseau à 3 neurones comme optimal.

VI.3.4. Essai N° : 04

litr=[1 :3 ;q] ; lival=[2 :3 ;q]

Tab VI.4 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	MSE-Apprentissage	MSE-Validation	MSE-Généralisation
3	0.0014	0.2647	0.0032
4	0.0119	0.2614	0.0124
5	$7.5560 e^{-004}$	0.2647	0.0330
6	$6.3049 e^{-004}$	0.2647	0.0290
7	$6.1719 e^{-004}$	0.2647	0.2120
8	$7.6094 e^{-004}$	0.2647	0.0072
9	$7.4138 e^{-004}$	0.2647	0.0117
10	$6.3293 e^{-004}$	0.2647	0.0062
11	$6.1058 e^{-004}$	0.2647	0.0414
12	$5.2076 e^{-004}$	0.2647	0.0863
13	$7.3798 e^{-004}$	0.2647	0.0422
14	$5.4093 e^{-004}$	0.2647	0.0495
15	$5.8768 e^{-004}$	0.2647	0.0702
16	0.0020	0.2647	0.0167
17	$5.9867 e^{-004}$	0.2647	0.1457
18	0.0044	0.2647	0.0088
19	$5.0739 e^{-004}$	0.2647	0.0078
20	$5.2001 e^{-004}$	0.2647	0.0759

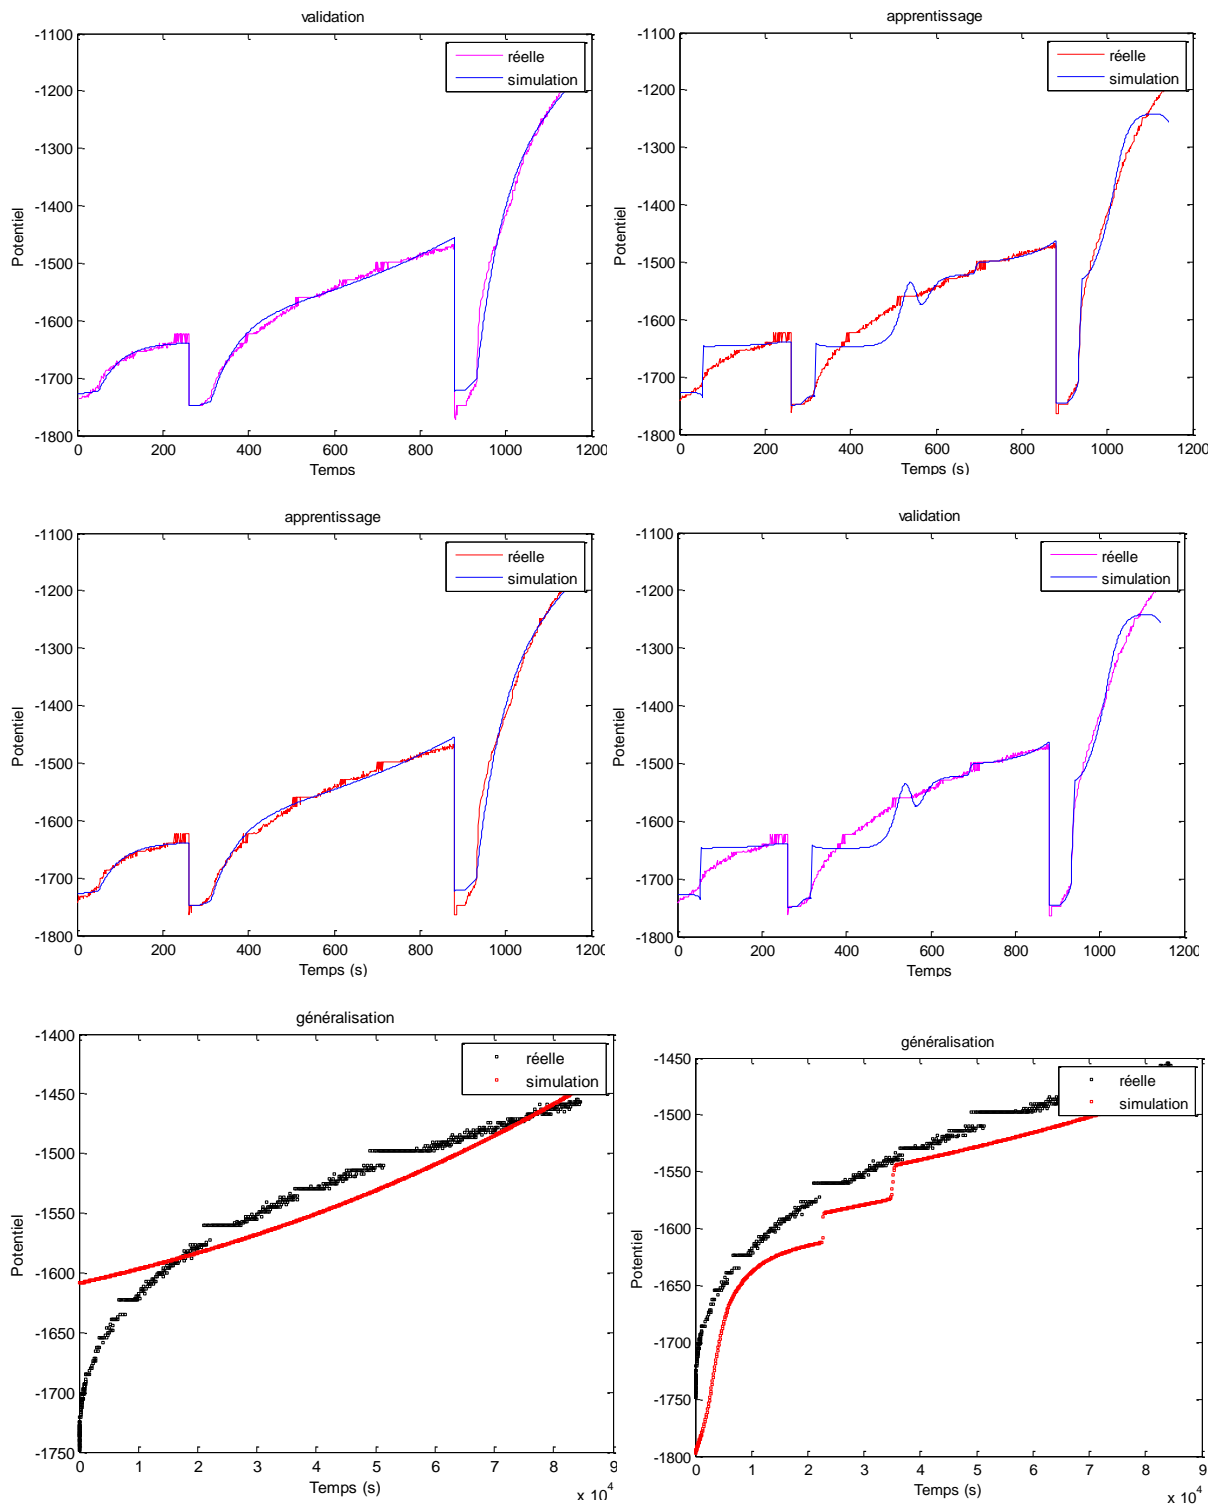


Fig VI.8 : Prédiction du déclin de potentiel de surface par les PMCs à 3 et 10 neurones

Pour les intervalles $I_{tr}=[1 :3 ;q]$; $I_{val}=[2 :3 ;q]$.




Fig VI.9 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMC à 3 et 10 neurones.

● Résultat

La (figure VI.9) présente la corrélation entre les potentiels de surface mesurés et prédits par deux modèles de PMC choisis du tableau présentant les meilleurs résultats. La corrélation est bonne puisque les coefficients de corrélation (R) égal à 0.99888 et 0.99799. Sur la base de généralisation, nous notons que les exemples sont prédits avec des erreurs égales à 0.0032 et 0.0062 pour les réseaux à 3 et 10 neurones en couche cachée, respectivement. Sur les essais qui composent la banque de données de validation, on note les mêmes valeurs d'erreurs : 0.2647.

Les 2 critères (coefficient de corrélation « R » et l'erreur quadratique moyenne « MSE ») montrent que le RNA à 3 neurones en couche cachée présente les résultats meilleurs. On conserve alors l'architecture la plus simple générant le niveau de performance optimal, soit 3 neurones en couche cachée.

VI.3.5. Essai N° : 05

litr=[3 :3 ;q] ; lival=[1 :3 ;q]

Tab VI.5 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	MSE-Apprentissage	MSE-Validation	MSE-Généralisation
3	0.0112	0.2645	0.0103
4	0.0012	0.2647	0.0082
5	0.0030	0.2647	0.8258
6	0.0019	0.2647	0.0044
7	0.0071	0.2650	0.0139
8	$6.5115 e^{-004}$	0.2647	0.2646
9	0.0036	0.2647	0.0067
10	$6.5239 e^{-004}$	0.2647	0.0218
11	0.0014	0.2647	0.0174
12	$7.6406 e^{-004}$	0.2647	00052
13	$5.2632 e^{-004}$	0.2647	0.0990
14	0.0030	0.2647	0.1001
15	$7.0482 e^{-004}$	0.2647	0.0522
16	$5.3260 e^{-004}$	0.2647	0.0141
17	0.0083	0.2646	0.0273
18	0.0017	0.2647	0.0528
19	$5.8584 e^{-004}$	0.2647	0.0566
20	$9.4773 e^{-004}$	0.2647	0.0225

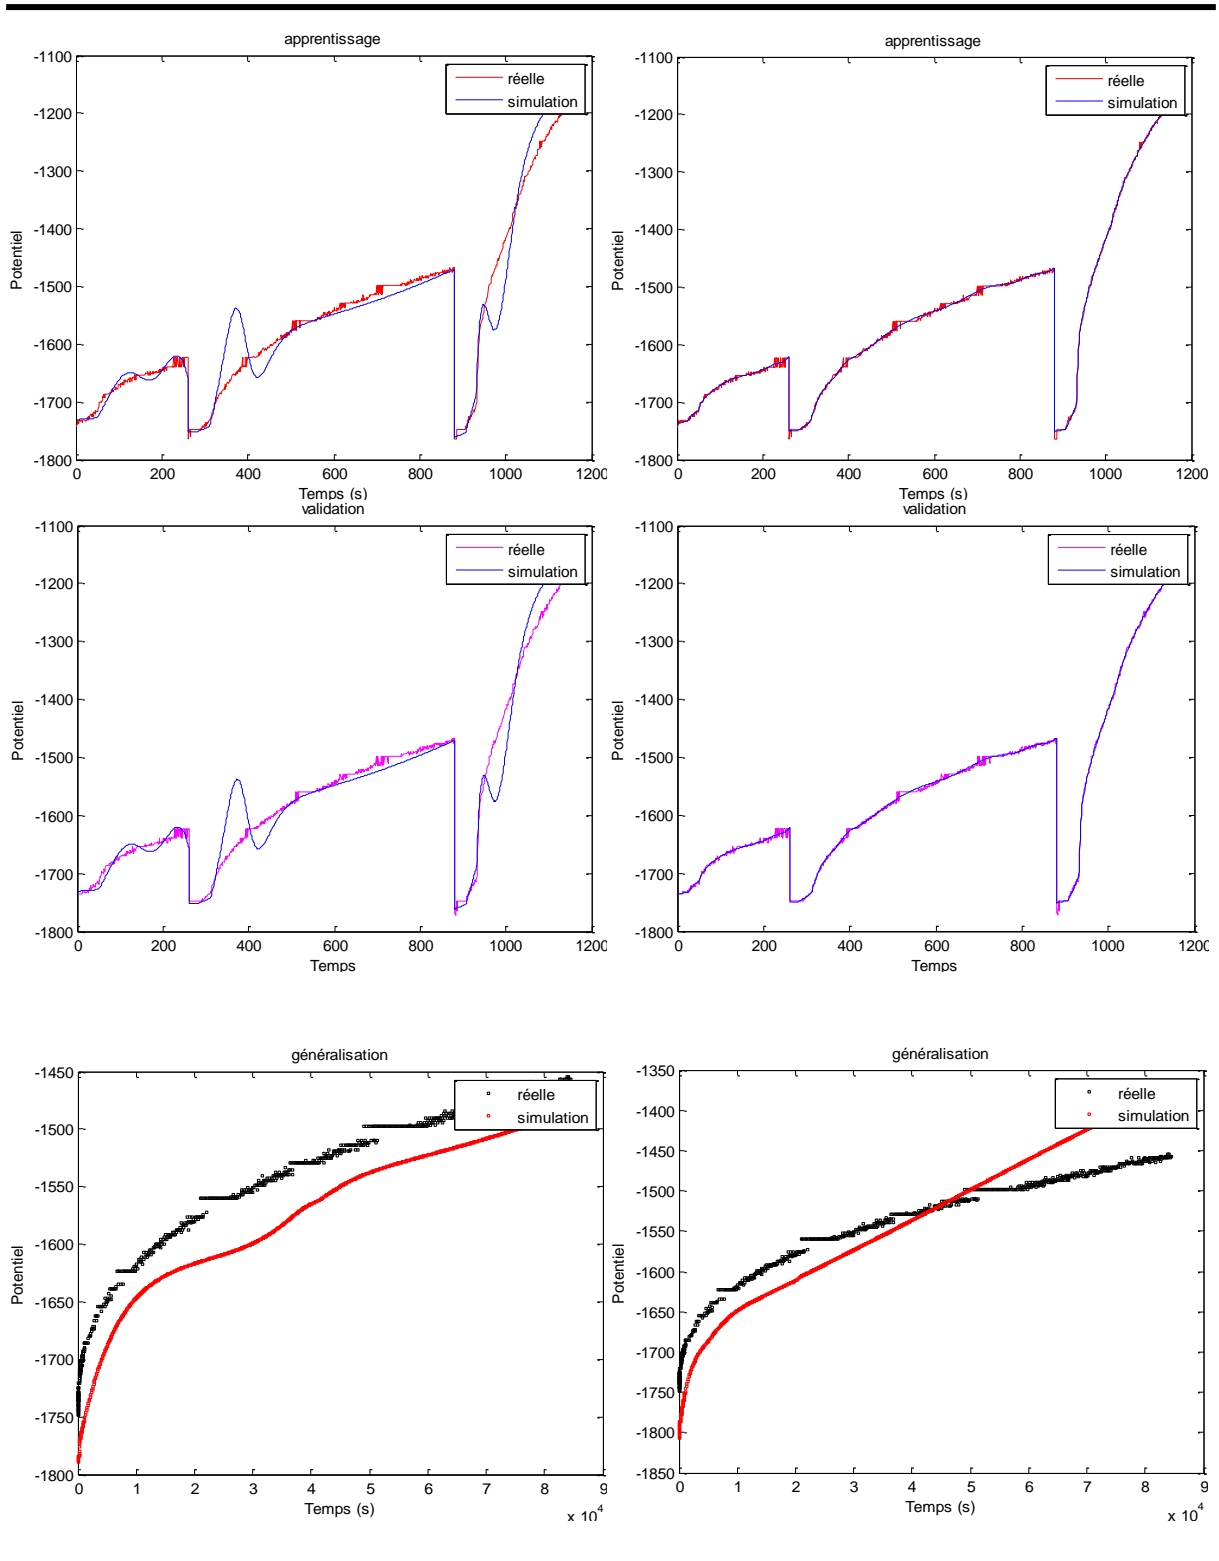


Fig VI.10 : Prédiction du déclin de potentiel de surface par les PMCs à 9 et 12 neurones

Pour les intervalles $I_{itr}=[3 : 3 : q]$; $I_{ival}=[1 : 3 : q]$.

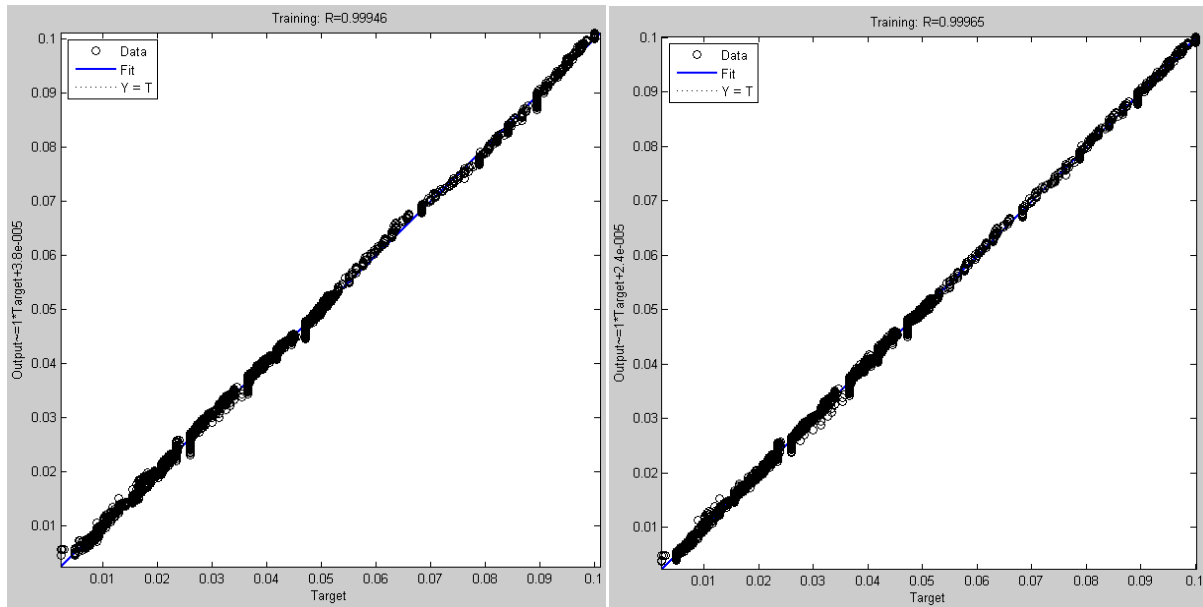


Fig VI.11 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMC à 9 et 12 neurones.

● Résultats

La (figure VI.11) illustre la corrélation entre les potentiels de surfaces de PET mesurés et prédits par les modèles des réseaux de neurones présentant les résultats les mieux adaptés sur le tableau VI.5.

Les coefficients de corrélation marqués par les deux réseaux (à 9 et 12 neurones) sont respectivement : 0.99946 et 0.99965.

Sur les exemples de la base d'apprentissage, nous notons que :

- Un PMC à 9 neurones en couche cachée prédit avec une erreur égale à 0.00362 ;
- Un PMC à 12 neurones en couche cachée prédit avec une erreur égale à $7.6406e^{-004}$;

Sur les exemples qui composent la banque de données de généralisation, l'erreur mesurée est :

- 0.0067 pour un modèle à 9 neurones ;
- 0.0052 pour un modèle à 12 neurones ;

Enfin, l'erreur présentée concernant la base de validation reste toujours égale à 0.2647. Ces résultats témoignent donc des qualités de généralisation du RNA adopté à 12 neurones en couche cachée.

VI.3.6. Essai N° : 06

litr=[1 :5 ;q] ; lival=[2 :5 ;q]

Tab VI.6 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	MSE-Apprentissage	MSE-Validation	MSE-Généralisation
3	0.0040	0.2646	0.0166
4	0.0020	0.2646	0.0296
5	0.0025	0.2646	0.0141
6	0.0031	0.2646	0.0061
7	0.0041	0.2646	0.0112
8	$6.4056 e^{-004}$	0.2646	0.0175
9	$5.6807 e^{-004}$	0.2646	0.0104
10	$5.8280 e^{-004}$	0.2646	0.0143
11	$6.2785 e^{-004}$	0.2646	0.0078
12	$6.9375 e^{-004}$	0.2646	0.0099
13	0.0020	0.2646	0.0101
14	0.0042	0.2646	0.0072
15	$5.5947 e^{-004}$	0.2646	0.0322
16	$6.3940 e^{-004}$	0.2647	0.1643
17	$6.0295 e^{-004}$	0.2646	0.0216
18	$5.5947 e^{-004}$	0.2646	0.0322
19	0.0023	0.2647	0.0197
20	0.0017	0.2646	0.0173

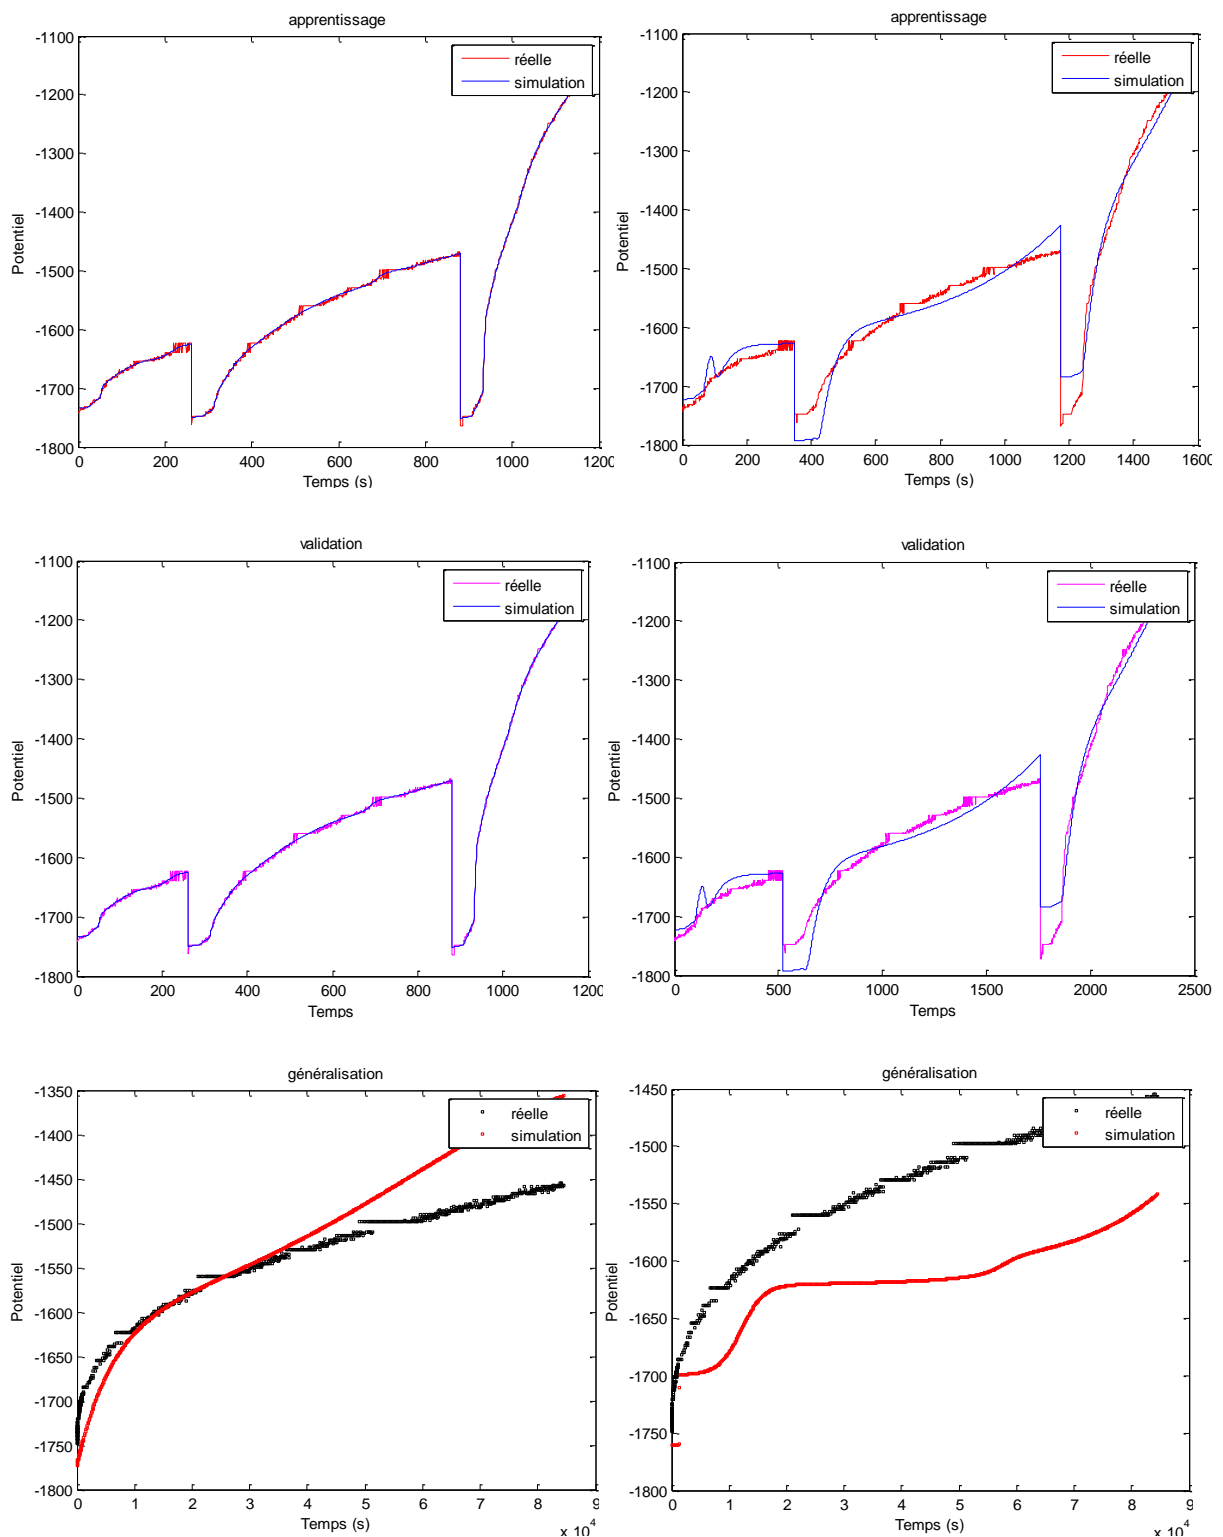


Fig VI.12 : Prédiction du déclin de potentiel de surface par les PMCs à 6 et 14 neurones

Pour les intervalles $l_{itr}=[1 :5 ;q]$; $l_{ival}=[2 :5 ;q]$.




Fig VI.13 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMC à 6 et 14 neurones.

● Résultats

Constatant le tableau VI.6, pour les données d'apprentissage, nous enregistrons des erreurs mesurées égales à 0.0031 et 0.0042, respectivement, à 6 et 14 neurones en couche cachée. Concernant l'ensemble d'exemples composant la banque de généralisation. On enregistre des erreurs de l'ordre de 0.0061 et 0.0072.

La (figure VI.12) montre les performances de deux types de PMCs sur les bases d'apprentissage, de validation et de généralisation. On marque que le réseau à six neurones représente un tau de prédiction très élevé pour les deux premières bases. Pour le second réseau on note une erreur un peu plus importante.

Les coefficients de corrélation (R) sont respectivement égaux à 0.99952 et 0.99501 pour des réseaux à 6 et 14 neurones en couche cachée. Ces graphiques et ces résultats de l'erreur mesurée entre valeurs cibles et valeurs prédites ainsi le coefficient de corrélation nous conduisent à choisir le PMC à 6 neurones en couche cachée.

VI.3.7. Essai N° : 07

litr=[1 :2 ;q] ; lival=[2 :2 ;q]

Tab VI.7 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	MSE-Apprentissage	MSE-Validation	MSE-Généralisation
3	0.0035	0.2647	0.0149
4	0.0098	0.2642	0.0104
5	0.0025	0.2647	0.0126
6	0.0013	0.2641	0.0047
7	7.6376 e⁻⁰⁰⁴	0.2647	0.0079
8	0.0052	0.2646	0.0685
9	6.7320 e ⁻⁰⁰⁴	0.2647	0.0148
10	0.0016	0.2647	0.0223
11	6.8594 e ⁻⁰⁰⁴	0.2647	0.0219
12	0.0093	0.2646	0.0097
13	0.0020	0.2647	0.0124
14	0.0144	0.2647	0.0505
15	6.5103 e ⁻⁰⁰⁴	0.2647	0.0909
16	5.5810 e ⁻⁰⁰⁴	0.2647	0.2021
17	6.6427 e ⁻⁰⁰⁴	0.2647	0.0722
18	5.7713 e ⁻⁰⁰⁴	0.2647	0.0121
19	0.0031	0.2646	0.0381
20	0.0162	0.2668	0.0135

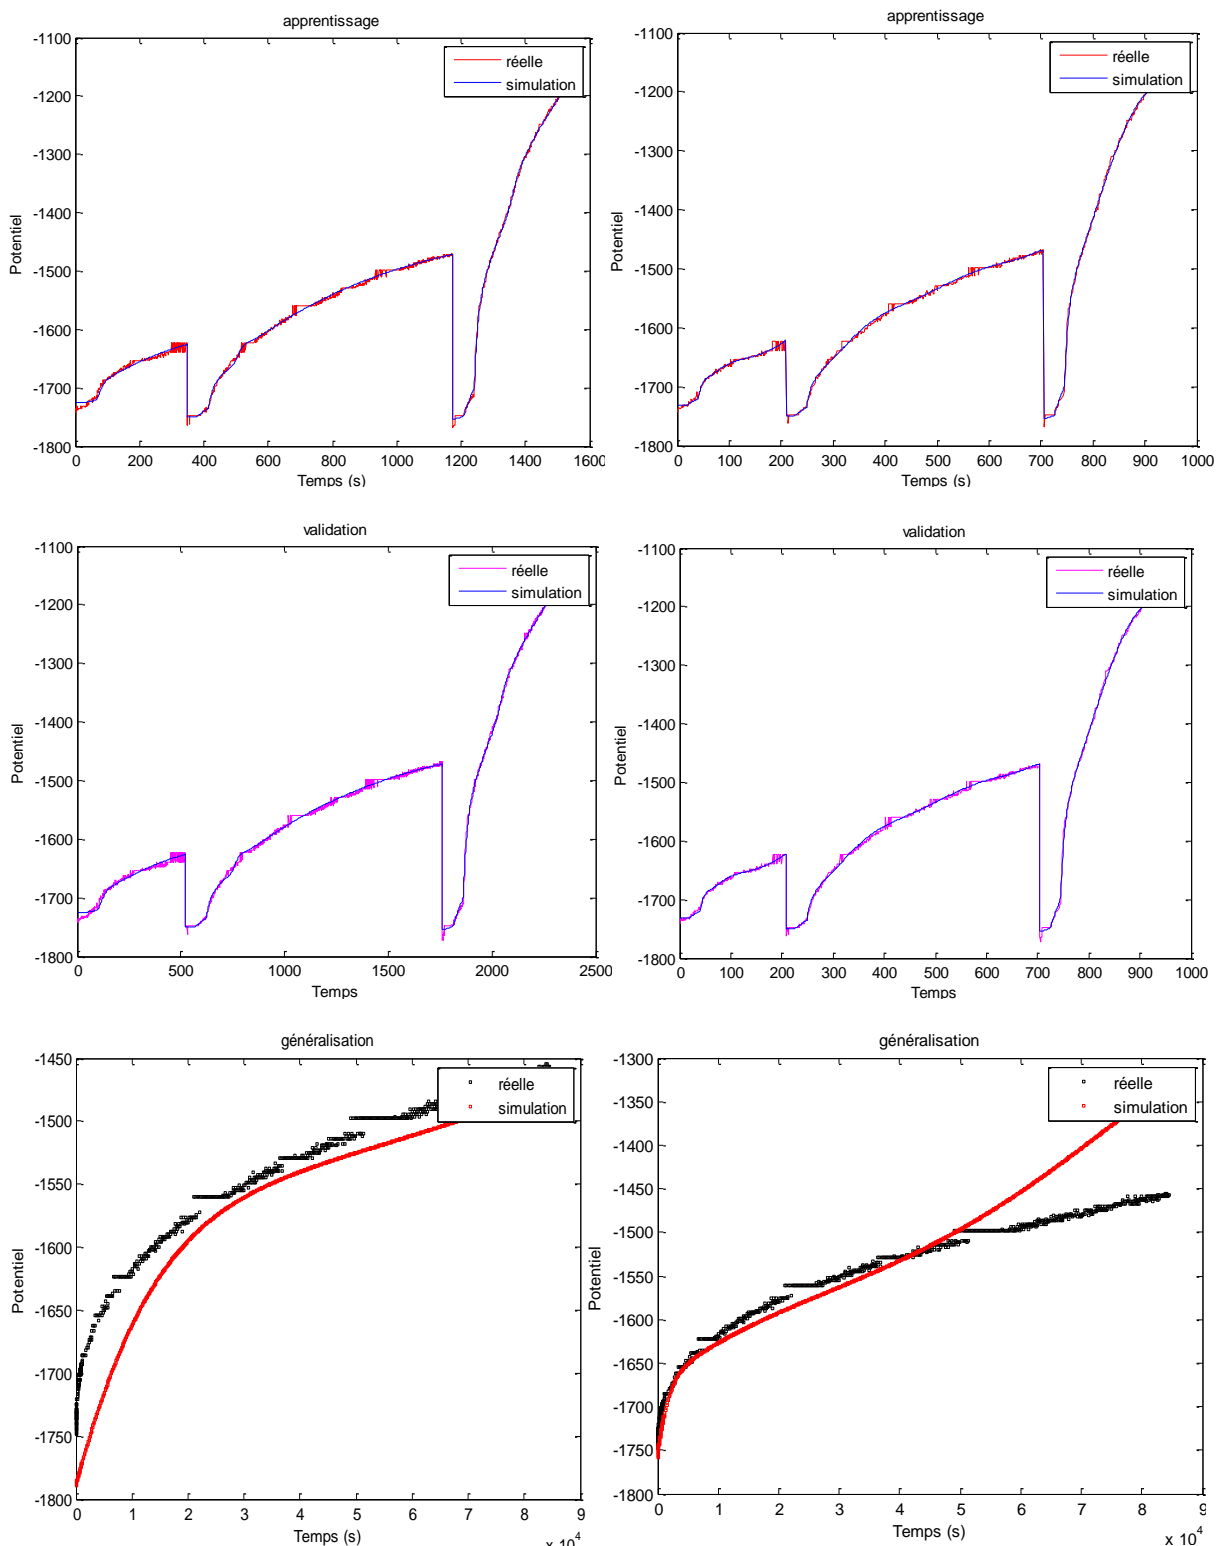


Fig VI.14 : Prédiction du déclin de potentiel de surface par les PMCs à 6 et 7 neurones

Pour les intervalles $l_{itr}=[1 :2 ;q]$; $l_{ival}=[2 :2 ;q]$




Fig VI.15 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMC à 6 et 7 neurones.

● Résultat

La (figure VI.15) présente la corrélation entre les potentiels de surface mesurés et prédits par deux modèles de PMC (à 6 et 7) choisis du tableau présentant les meilleurs résultats. La corrélation est bonne pour le PMC à 6 neurones (0.9997). Sur la base de généralisation, nous notons que les exemples sont prédits avec une erreur égale à 0.0047, sur les essais composant la même base nous marquons une erreur de 0.0079 pour le réseau à 7 neurones en couche cachée. Sur la banque de données de validation, on note une légère différence (0.2641 et 0.2647).

Les 2 critères (coefficient de corrélation « R » et l'erreur quadratique moyenne « MSE ») montrent que le RNA à 6 neurones en couche cachée présente les résultats meilleurs. On conserve alors l'architecture la plus simple générant le niveau de performance optimal, soit 6 neurones en couche cachée.

VI.3.8. Essai N° : 08

litr=[2 :3 :q] ; lival=[1 :3 :q]

Tab VI.8 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	RMSE-Apprentissage	RMSE-Validation	RMSE-Généralisation
3	0.0124	0.2645	0.0108
4	0.0013	0.2647	0.0144
5	0.0112	0.2645	0.0103
6	0.0011	0.2647	0.0053
7	0.0026	0.2647	0.0092
8	$6.6715 e^{-004}$	0.2647	0.0092
9	0.0065	0.2648	0.0226
10	$5.9769 e^{-004}$	0.2647	0.0670
11	0.0059	0.2649	0.0080
12	0.0026	0.2647	0.0066
13	$6.0063 e^{-004}$	0.2647	0.0064
14	0.0106	0.2648	0.0143
15	0.0430	0.2701	0.0625
16	$5.7706 e^{-004}$	0.2647	0.0920
17	$6.4385 e^{-004}$	0.2647	0.0545
18	$6.3984 e^{-004}$	0.2647	0.0256
19	$6.0566 e^{-004}$	0.2647	0.0173
20	0.0030	0.2647	0.0228

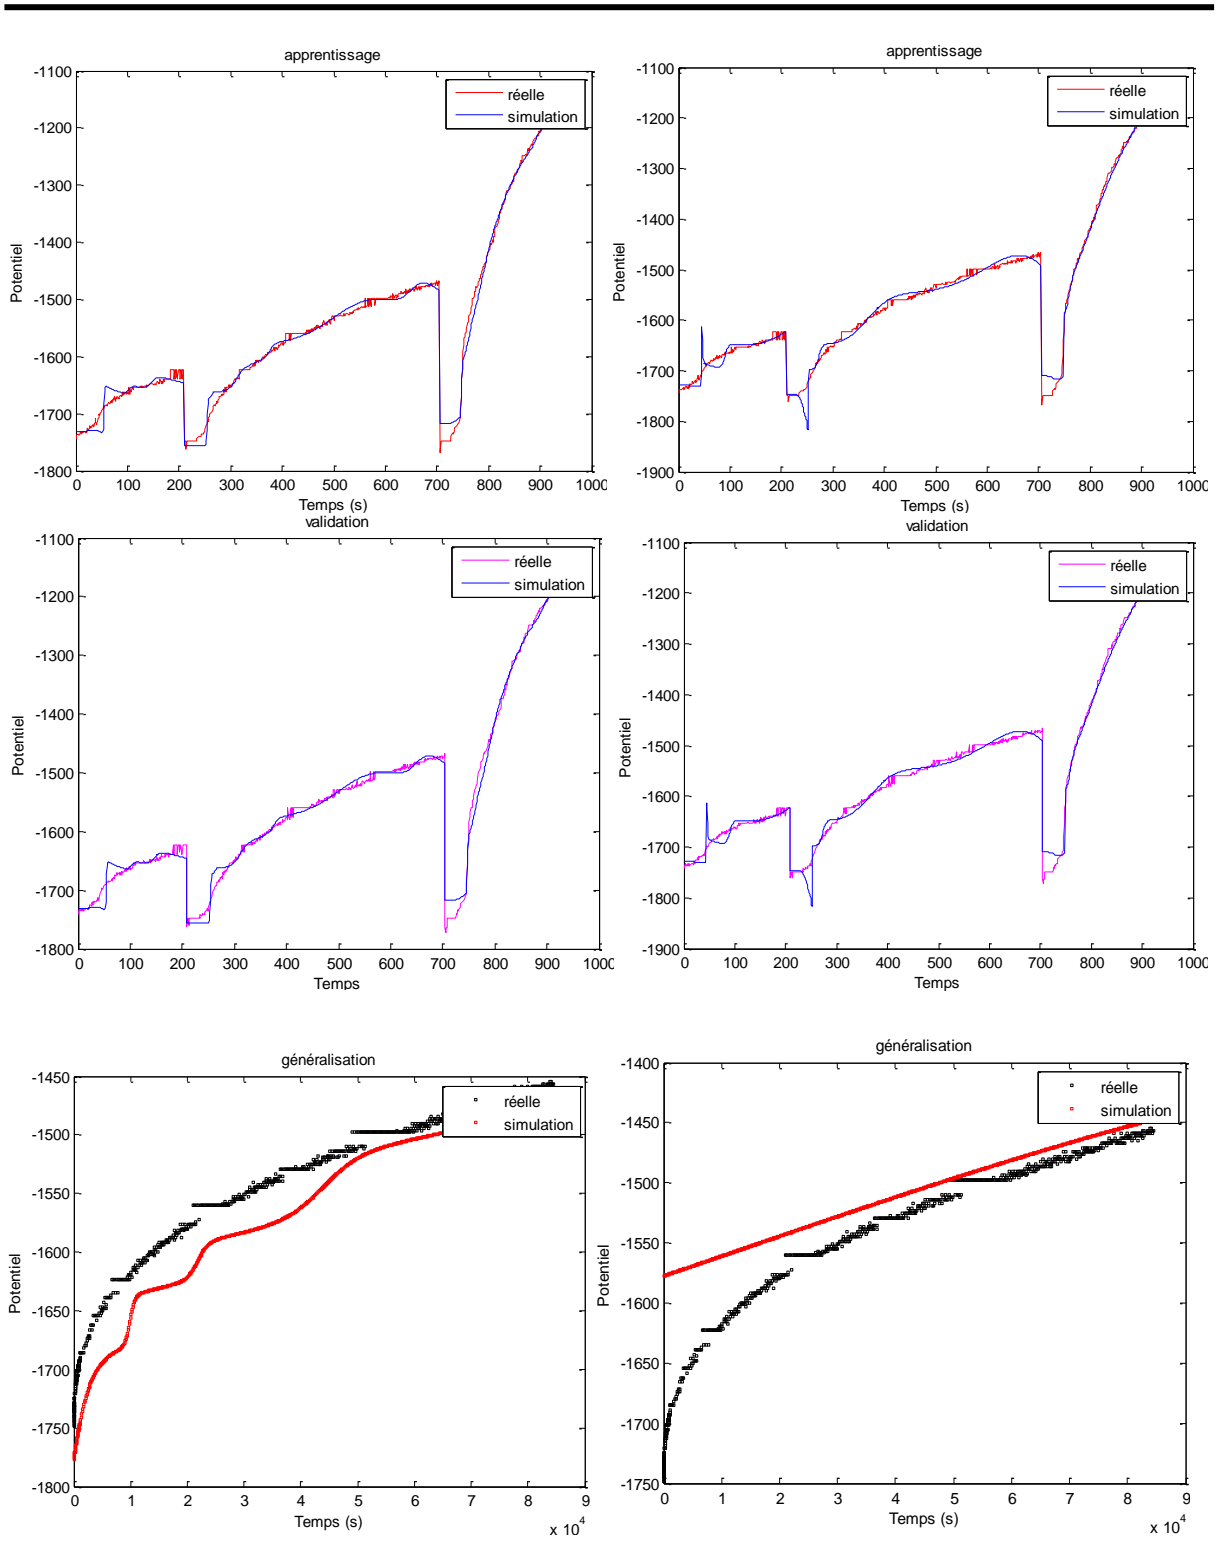


Fig VI.16 : Prédiction du déclin de potentiel de surface par les PMCs à 6 et 13 neurones

Pour les intervalles $I_{itr}=[2 :3 :q]$; $I_{ival}=[1 :3 :q]$.




Fig VI.17 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMC à 6 et 13 neurones.

● Résultat

Le tableau VI.8 présente les erreurs pour les trois banques de données (apprentissage, validation et généralisation). Il montre clairement que le modèle de PMC à 6 neurones prédit le potentiel de surface de l'échantillon de PET mieux que le PMC à 13 neurones.

La (figure VI.17) illustre la corrélation par les deux modèles de réseaux (PMC à 6 et 13 neurones en couche cachée). Notons une bonne précision pour le PMC à 6 neurones (coefficient de corrélation égale à 0.99966). En effet, la base d'apprentissage prédit avec une erreur égale à 0.0011. L'erreur concernant les données de la base de généralisation enregistrée est 0.0053. Pour le modèle à 13 neurones le coefficient de corrélation est de 0.99883, les erreurs des deux bases d'apprentissage et de généralisation respectivement sont $6.0036e^{-004}$ et 0.0064. L'erreur de validation reste constante (0.2647).

Nous notons ici que le perceptron multicouche à 6 neurones en couche cachée est le réseau optimal.

VI.3.9. Essai N° : 9

litr=[2 :2 :q] ; lival=[1 :2 :q]

Tab VI.9 : Erreurs des trois bases de données pour $S_1=3$ à 20.

S_1	RMSE-Apprentissage	RMSE-Validation	RMSE-Généralisation
3	0.0034	0.2647	0.0414
4	0.0031	0.2647	0.0023
5	0.0040	0.2647	0.0112
6	0.0036	0.2647	0.0067
7	0.0030	0.2647	0.0154
8	6.1806 e⁻⁰⁰⁴	0.2647	0.0029
9	6.2564 e ⁻⁰⁰⁴	0.2647	0.0136
10	0.0081	0.2645	0.0143
11	6.3152 e ⁻⁰⁰⁴	0.2647	0.0169
12	0.0010	0.2647	0.0078
13	6.9371 e ⁻⁰⁰⁴	0.2647	0.1375
14	5.3946 e ⁻⁰⁰⁴	0.2647	0.1989
15	0.0231	0.2658	0.2495
16	0.0039	0.2645	0.0592
17	5.7095 e ⁻⁰⁰⁴	0.2647	0.0095
18	8.3837 e ⁻⁰⁰⁴	0.2647	0.0083
19	0.0029	0.2646	0.0114
20	0.0445	0.2685	0.0468

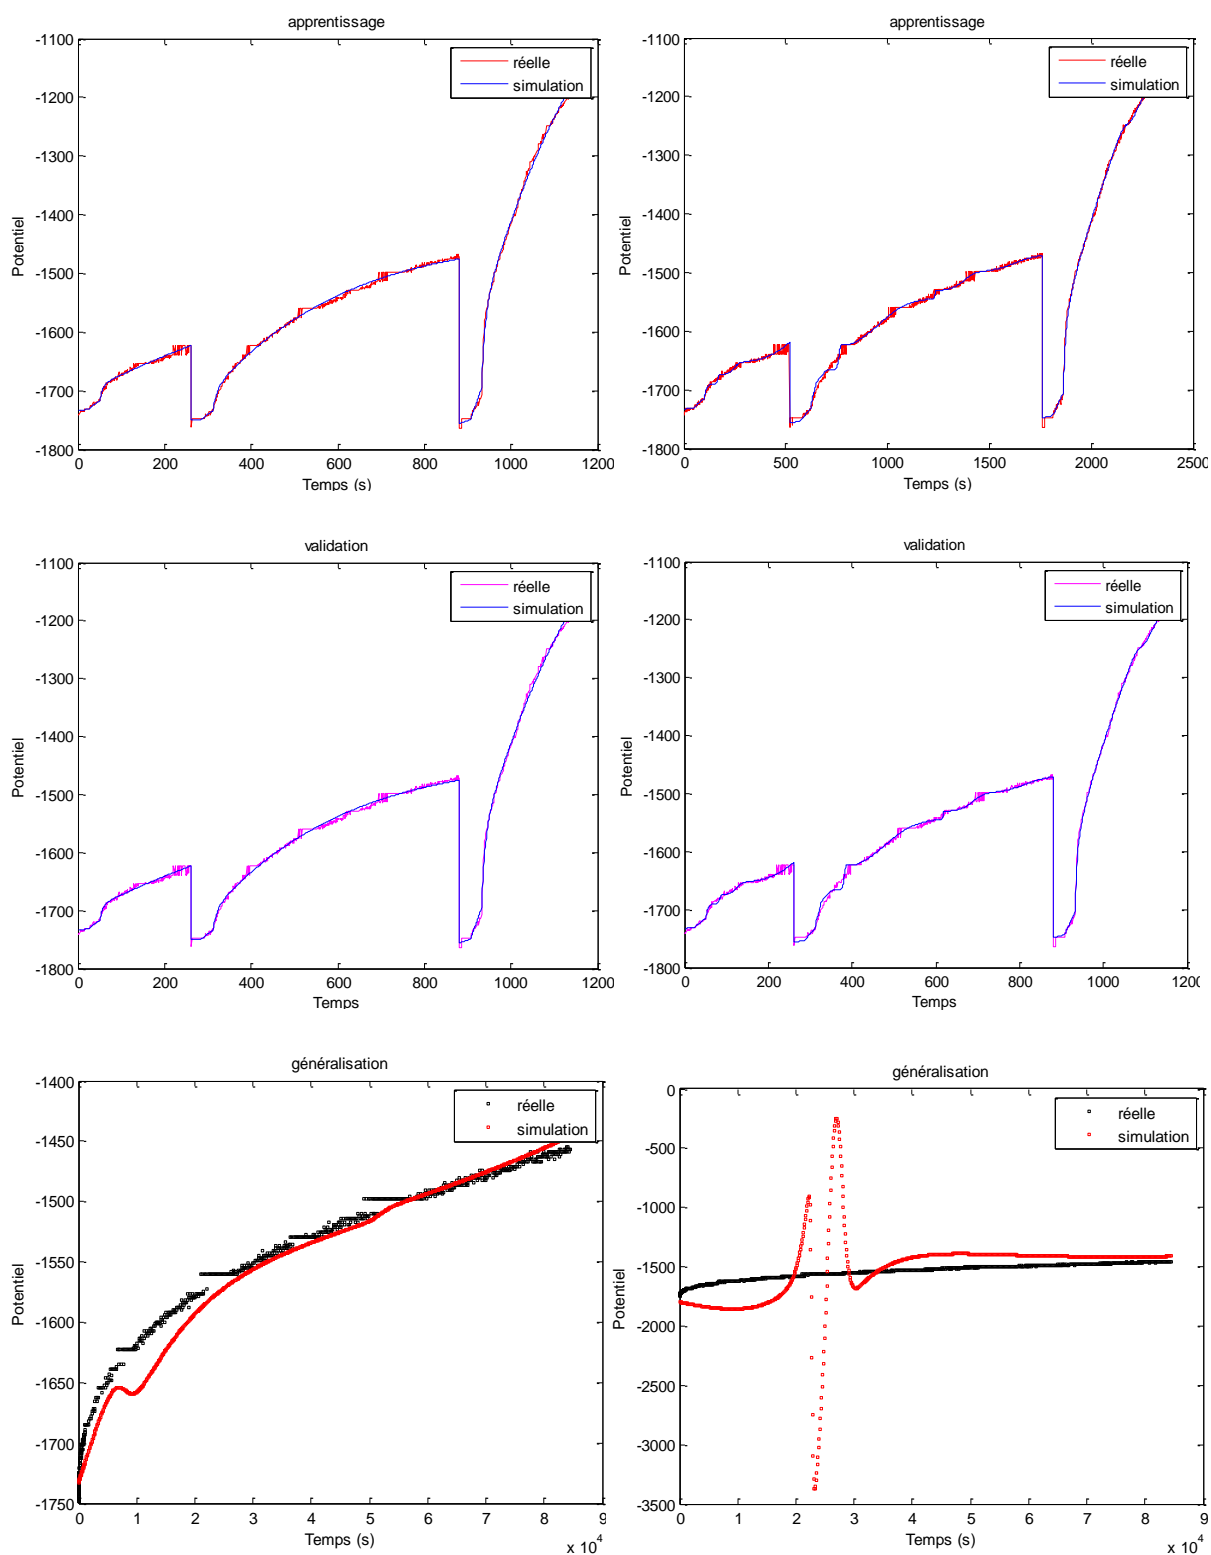


Fig VI.18 : Prédiction du déclin de potentiel de surface par les PMC's à 4 et 8 neurones

Pour les intervalles $I_{tr}=[2 : 2 : q]$; $I_{val}=[1 : 2 : q]$.




Fig VI.19 : Corrélation entre les déclinés de potentiel de surface mesurés et prédits par les PMC à 4 et 8 neurones.

● Résultat

La (figure VI.19) illustre la corrélation entre les potentiels de surfaces de PET mesurées et prédits par les modèles des réseaux de neurones présentant les résultats les mieux adaptés sur le tableau.

Les coefficients de corrélation marqués par les réseaux (à 4 et 8 neurones) sont respectivement : 0.99965 et 0.99944.

Sur les exemples de la base d'apprentissage, nous notons que :

- _ Un PMC à 4 neurones en couche cachée prédit avec une erreur égale à 0.0031 ;
- _ Un PMC à 8 neurones en couche cachée prédit avec une erreur égale à $6.1806e^{-004}$;

Sur les exemples qui composent la banque de données de généralisation, l'erreur mesurée est :

- _ 0.0023 pour un modèle à 4 neurones ;
- _ 0.0029 pour un modèle à 8 neurones ;

Enfin, l'erreur présentée concernant la base de validation reste toujours égale à 0.2647. Ces résultats témoignent donc des qualités de généralisation du RNA adopté à 4 neurones en couche cachée.

VI.4. Résumé des résultats

Tab VI.10 : Représentation des meilleurs résultats.

Essais	Nb de N	Mse d' app	Mse de val	Mse de gén	R
Essai N° : 1	6	0.0121	0.2647	0.0035	0.99964
Essai N° : 2	4	0.0013	0.2647	0.0031	0.99738
Essai N° : 3	3	0.0015	0.2647	0.0031	0.9989
Essai N° : 4	3	0.0014	0.2647	0.0032	0.99888
Essai N° : 5	12	$7.6406e^{-004}$	0.2647	0.0052	0.99965
Essai N° : 6	6	0.0031	0.2646	0.0061	0.99959
Essai N° : 7	6	0.0013	0.2641	0.0047	0.9997
Essai N° : 8	6	0.0011	0.2647	0.0053	0.99966
Essai N° : 9	4	0.0031	0.2647	0.0023	0.99965

Nb de N : Nombre de neurones en couche cachée ;

Mse d'app : Erreur quadratique moyenne sur la base d'apprentissage ;

Mse de val : Erreur quadratique moyenne sur la base de validation ;


Mse de gén : Erreur quadratique moyenne sur la base de généralisation ;

R : Le coefficient de corrélation ;


Les résultats d'essais nous conduit à choisir 9 modèles neuronaux. Les modèles développés ont été éprouvés sur une base de test dont les contraintes différentes à celles constituant la banque de données. Nous résumons les résultats dans le tableau suivant :

Tab VI.11 : Prédiction de 9 modèles sur la base du test.


Nb d'essai	1	2	3	4	5	6	7	8	9
Mse de test	0.0031	0.0022	0.0025	0.0030	0.0034	0.0038	0.0031	0.0033	0.0020




Essai N° : 1




Essai N° : 2




Essai N° : 3



Essai N° : 4



Essai N° : 5



Essai N° : 6




Fig VI.20 : Analyse comparative de la prédiction du DPS par les neuf réseaux optimaux dans la phase de test.

Enfin, nous avons obtenu un modèle neuronal optimal caractérisé par :

- **Architecture** : perceptron multicouches à :
 - 4 entrées : température, humidité relative, tension et épaisseur.
 - Une couche cachée à 4 neurones.
 - Une couche de sortie à un neurone correspond au déclin de potentiel de surface.
- **Algorithme** :
 - Levenberg-Marquardt basé sur la technique de retropropagation de l'erreur.
 -

VI.5. Conclusion

Ce chapitre a présenté le développement de différents modèles neuronaux utilisés pour la prédiction du déclin de potentiel de surface d'un échantillon de PET soumis à des contraintes climatiques (température « supérieure à 40°C » et humidité), électrique (tension) et géométrique (épaisseur). Ces 4 grandeurs utilisées comme entrées des réseaux de neurones pour toute la gamme d'essais effectuée. Après avoir que l'architecture d'un PMC à une seule couche cachée est la meilleure adapté au chapitre précédant, nous avons réalisé un ensemble d'essais environ 9*18 essais, pour avoir un modèle neuronal optimal. En jouant sur l'intervalle d'exemples de la banque d'apprentissage et la banque de validation (Iitr et Iival), ainsi le nombre de neurones en couche cachée (de 3 à 20). Les modèles ont été mis au point sur la base des résultats de la campagne d'essais de laboratoire présentée dans le chapitre V. Les résultats de prédiction montrent clairement, notamment sur les bases de données de généralisation, que les modèles développés présentent des aptitudes certaines vis-à-vis des objectifs visés.

Les neuf modèles neuronaux obtenus sont testés sur une banque du test constituée d'un ensemble d'exemples différent à celle de banque de données. Finalement, on a développé un modèle neuronal optimale qui nous a donné des excellents résultats dont l'erreur égale à 0.0020.

Enfin, ce chapitre est ponctué par la présentation d'un modèle neuronal pour la prédiction du déclin de potentiel de surface de l'échantillon de polyéthylène téréphtalate.

Chapitre VII

Conclusions et Perspectives

VII. Conclusions et Perspectives

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 du phénomène de vieillissement d'un isolant organique (PET) sous l'application d'un champ électrique. Connus pour leur grande capacité d'isolation électrique, les polymères ont envahi ce domaine. Ils sont devenus les isolants électriques par excellence. Le succès et l'utilisation massive et intense de ce type d'isolants s'accompagnent malheureusement de risques encourus suite à leur dégradation ; ces matériaux vieillissent. Le premier but de ce travail est la compréhension du processus de vieillissement des isolants polymères qui, de part leur utilisation, sont soumis à des champs électriques mais aussi à des contraintes thermiques et mécaniques. Dans ce but, nous nous sommes d'abord intéressés aux propriétés structurales des polymères isolants électriques qui sont pour la majorité semi-cristallins. En effet, ces matériaux présentent une structure spécifique qui dicte leurs propriétés physiques, mécaniques et électriques. La prise en compte de cette microstructure est donc nécessaire pour décrire leur comportement sous champ électrique.

En raison de propriétés mathématiques qui sont maintenant bien comprises, et grâce au développement de méthodologies rigoureuses pour la conception de modèles, les réseaux de neurones sont devenus des outils de modélisation puissants dont les domaines d'application sont multiples. Ils permettent de réaliser, de manière simple et efficace, des modèles précis, statiques ou dynamiques, parcimonieux en nombre de paramètres. Contrairement à une idée répandue, ils ne sont pas nécessairement des «boîtes noires!» sans signification physique! la méthodologie de modélisation semi-physique permet de tirer la meilleure partie possible des données expérimentales disponibles et des connaissances avérées, sous formes d'équations algébriques ou différentielles, qui peuvent résulter d'une étude physique du processus que l'on cherche à modéliser.

Dans ce présent travail, notre deuxième objectif est l'utilisation de nouvelles stratégies –à base de réseaux de neurones artificiels– de commande afin d'améliorer le control et la prédiction du déclin de potentiel de surface d'un PET. 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 RNAs) ne disposent cependant pas de règles bien précises pour fixer le nombre de neurones et de couches cachées. Un problème de choix est posé et reste donc le principal inconvénient.

On a eu en premier lieu fait une comparaison entre les deux algorithmes de Levenberg-Marquardt et Scaled conjugate gradient, aussi bien entre différentes architectures en changeant le nombre de couche cachée, afin de fixer l'architecture optimale du réseau.

Il apparaît que le réseau RNA choisi (un réseau à une seule couche cachée entraînant par l'algorithme de Levenberg-Marquardt) a présenté de bons résultats, avec des erreurs allant jusqu'à 0.0030 en généralisation.

Ce travail est une première étape dans le développement d'un modèle neuronal complet capable de prédire le déclin de potentiel de surface d'un PET, nous avons défini seulement le nombre de couche cachée, non plus le nombre de neurones par couche. Pour ceci une large étude a été effectuée pour définir la bonne architecture du réseau est présentée au chapitre VI. Après un ensemble d'essais (18*9) nous avons obtenu neuf modèles neuronaux présentant les meilleurs résultats. Ensuite, nous avons réalisé une analyse comparative de ces différents modèles par un test comprenant des exemples n'appartiens pas de la banque de données utilisée pour les trois phases d'apprentissage, de validation et de généralisation.

Les résultats de ce test nous conduisent à choisir un modèle neuronal optimal caractérisé par :

- **Architecture** : perceptron multicouches à :
 - 4 entrées : température, humidité relative, tension et épaisseur.
 - Une couche cachée à 4 neurones.
 - Une couche de sortie à un neurone correspond au déclin de potentiel de surface.

- **Algorithme** :
 - Levenberg-Marquardt.

Faut-il souligner que le principal souci reste l'obtention d'une architecture optimale. Donc Comme perspectives, des améliorations peuvent toujours être opérées à ce niveau en ajoutant de nouveaux capteurs en entrée capables de fournir plus d'informations. D'autres techniques

d'apprentissage statistiques telles que les machines à vecteurs de support (SVMs) peuvent aussi être appliquées.

Nous comptons développer le logiciel qui teindre compte des DPS en charges positives. De plus, nous ajouterons dans notre logiciel les températures inférieures à 40°C.

Nous souhaitons compléter l'étude du DPS par le développement d'un autre logiciel sur les algorithmes génétiques. Comme nous espérons faire une étude comparative sur la simulation des modèles avec les réseaux de neurones et les algorithmes génétiques.

Enfin, nous souhaitons que ce modeste travail servira comme référence bibliographique aux chercheurs qui s'intéressent au domaine de la commande neuronale.

Références bibliographiques

A

[Adam81] Adamc. V, Cloderwood. J. H « Electrical conduction and polarisation phenomena in polymeric dielectrics at low fields » J. Phys. D, Vol 14, 1487,1981.

[Adel 89] H. Adeli and C. Yeh, « Perceptron learning in engineering design», Microcomputers in Civil Engng Vol. 4, pp. 247, 1989.

[Awa72] Awakuni Y., Calderwood K.D., seki H. « Water vapor absorption and surface conductivity of solids » J. Phys. D: Appl phys, Vol 20, pp. 1038-1045, 1972.

B

[Baum75] Baum E. A, Lewis. T.J. « Controlled charging of insulator surfaces, static electrification conference » Serie N°27 (institut of physic and physicol society, London) pp.130.140, 1975.

[Baum78] Baum E. A, Lewis T.J, Toomer .R. « The lateral motion of charge on thin film of film of polyethylene terephtalate » J. Phys. D: Appl.Phys, Vol. 11, N° 6, pp. 963-977, 1978.

[Bolin97] Bolinche. R. « Caractérisation des phénomènes de transport surfacique et volumique de charges électrique dans les polymères » thèse de doctorat université Paul Sabatier Toulouse, 1997.

C

[Ches 90] Chester D. L. Why two hidden layers are better than one. *In Proceedings of International Joint Conference on Neural Networks*, Vol. 1, pp. 265-268, Washington, DC, 1990.

[Coel84] R. Coelho, L. Levy, D. Serrail « On the naturel decay of corona charged Teflon sheet I » IEEE. IAS 84 : 36C, pp. 1033-1037, 1984.

[Cris96] A. Crisci. « Etude du déclin de potentiel d'une surface chargée par une décharge électrique de type couronne » Rapport pour maîtrise de physique LEMD, 1996.

[Cris98] A. Crisci, B. Gosse, J .P. Gosse, V .Ollier-Durault. « surface potentiel decay due to surface conduction » Eur. Phys. App. 4. 20, pp107-116, 1998.

D

[Dava 93] E. Davalo, P. Naïm, *Des réseaux de neurones*, 2ème édition, Edition EYROLLES, Paris, 1993.

E

[Ehre 00] Ehrenstein G.W., Montagne F. *Matériaux Polymères–Structure, propriétés et applications*. Paris, HERMES Science Publications, 2000, 365 p.

F

[Fauv 93] FAUVARQUE J.F. *Polymères pour isolants électriques. Propriétés électriques des polymères et applications*. Groupe Français d'Etudes et d'Applications des Polymère, GFP, 1993, ch. VII, pp 273-318.

G

[Ghab 90] J. Ghaboussi, J. H. Garrett and X. Wu, « Material modeling with neural networks», Proceedings of the International Conference on Numerical Methods in Engineering, Theory and Applications, Swansea, UK. pp. 701, 1990.

[Ghab 91] J. Ghaboussi, J. H. Garrett and X. Wu, « Knowledge based modeling of material behavior with neural networks», J. Engng. Mech. Div. ASCE. Vol. 117, pp. 132. 1991.

[Ghab 93] J. Ghaboussi, « An overview of the potential applications of neural networks in civil engineering», Proceedings Structures Congress ASCE Irvine, pp. 1324, April 1993.

[Ghab 93]J. Ghaboussi, « Applications of soft computing with neural networks in some civil engineering problems», Quadrilateral Seminar, Taejon, S. Korea, Sept 1993.

[Ghab 94]J. Ghaboussi, « Current trends in neural networks research in engineering applications», NATO Adv. Rsch. Nafplio Greece, August 1994.

[Ghab 94] J. Ghaboussi, P. V. Lade and D. E. Sidarta, « Neural networks based modeling in geomechanics», Proceedings of the 8th International Conference on Computer Methods and Advances in Geomechanics, Morgantown, WV, 1994.

[Ghab 98] J. Ghaboussi and D. E. Sidarta, « New nested adaptive neural networks (NANN) for constitutive modelling», Computers and Geotechnics, Vol. 22, pp. 29, 1998.

[Gross42] Gross. B. « On discharge voltage and return curves for absorptive capacitors » Physical. Review, Vol. 62, pp 383-387, 1942.

H

[Hero 06] HEROUS.L. « Etude des mécanismes d'écoulement de charge dans les matériaux isolants au moyen de mesures électrostatiques de déclin » Thèse de docteur 2006.

I

[Ied67] Ieda .M., Sawa. G, Schinohara .U. « A decay process of surface electric charges across polyethylene film »Japan. J .Appl .Phys, Vol. 6. pp.793-794, 1967.

[Ied67] Ieda .M., Sawa. G, Schinohara .U. « A decay process of surface electric charges across polyethylene film »Japan. J .Appl .Phys, Vol. 6. pp.793-794, 1967.

[Ied68] Ieda .M., Sawa. G, Schinohara .U. « Decay of electric charges on polymeric films » Electric .Eng. Japan ,Vol. 88, N°6, pp.67-73 ,1968.

J

[Jest87] Jestin .P , Coelho. R, Goldman. M. « Surface potential decay on epoxy resine » Inst. Phys Conf. Ser N°85. Sect 2, pp. 193-196, 1987.

K

[Krös 96] B. Kröse et P. van der Smagt, « An introduction to neural network», ebook of The University of Amsterdam, November 1996.

L

[Leon 87] Leontaritis I. J. & Billings S.A. (1987) .Model selection and validation for nonlinear systems. Int. J. Control Vol.1, pp. 311-341.

[Llov 02] P. Llovera. « Etude des mécanismes d'injection de charge dans les matériaux isolants au moyen de mesures électrostatiques de déclin et retour de potentiel. » Thèse de docteur en sciences de l'université Paris XI orsay, 2002.

[Llo2004] P. Llovera., Molinié P. « New methodology for surface potential decay measurements-application to study charge injection dynamics on polypropylene films » *IEEE. Trans. Dielect. Elec. Ins.*, Vol.11, pp. 1049-1056, 2004.

[Loe65] Loeb .L.B. « Electrical coronas » Berkeley and Los Angeles: University of California Press, 1965.

M

[Makh 89] Makhoul J., El-Jaroudi A., et Schwartz R. Formation of disconnected decision regions with a single hidden layer. *In Proceedings of the International Joint Conference on Neural Networks*, Vol. 1, pp. 455-460, 1989.

[Mamy 04a] MAMY P.R. Etude de la réponse mécanique des isolants organiques solides au cours de l'application d'un champ électrique : cas de PET semi-cristallin. -152p. Th : Génie Electrique : Toulouse : 2004.

[Mamy 04b] MAMY P.R., BOUDOU L., MARTINEZ-VEGA J. Correlation between electrical conduction and mechanical deformation induced by an electrical field to PET. *Proc 2004 IEEE Int. Conf. Sol. Dielectr*, Toulouse France, July 2004, pp 615-618.

[Mamy 04c] MAMY P.R., MARTINEZ-VEGA J., DUPRE J.C, BRETAGNE N. Quantification of mechanical deformations induced by an electric field in a semicrystalline organic insulator. *J. Appl. Polym. Sci.*, 2004, 93, pp 2313-2321.

[Marc 04] Marc Parizeau. Réseaux de neurones gif-21140 et gif-64326. Automne 2004 Cherney E.A, Gorur R.S., « RTV Silicone Rubber Coatings for Outdoor Insulators », *IEEE Transactions On Dielectrics and Electrical Insulation*, vol.6, 1999, pp. 605-611.

[Moli92] P. Molinie. « Etude de la neutralisation de la charge électrique déposée par effet couronne à la surface d'un isolant. Application au suivi des premiers stades de vieillissement d'un isolateur époxyde » Thèse de doctorat. Université. ParisVI, 1992.

[Moli95] P. Molinie, M. Goldman and J. Gatellet. « Surface potential decay on corona charged epoxy samples due to polarization processes » *J. Phys. D : App. Phys*, Vol. 28, pp 1606-1610, 1995.

[Moli 96] P. Molinie. « Potential decay interpretation and insulating film: necessity of combining charge injection and slow volume polarisation processes » *Seven. Int. Conf. Of . Dielect. Meas*, 1996.

[Moli 99] P. Molinie. « Charge injection in corona charged polymeric films :Potential decay and current measurement » J. of Electrostatics , pp, 265-273, 1999.

[More 01] Moreno V.M., Gorur R.S., « Effect of long term corona on non-ceramic outdoor insulator housing materials », *IEEE Transactions On Dielectrics and Electrical Insulation*, 2001.

N

[Nerr 93] Nerrand. O, Roussel-ragot. P., Personnaz. L., Dreyfus. G., “Neural networks and nonlinear adaptive filtering: unifying concepts and new algorithms”, *Neural Computation* Vol.5, pp. 165-199, 1993.

[Nguy 04] Nguyen D.H., Sylvestre A., Gonon P., Rowe S., « Dielectric properties analysis of silicone rubber », *6th International Conference on Solid Dielectrics*, Toulouse, 2004.

O

[Ollé 95] V. Ollier. Durault. « Vieillissement de surface d’isolations en résines epoxy anhydride: rôle respectif des UV et du champ électrique » Thèse de doctorat d’université Joseph Fourier Grenoble, 1995.

[Owe 75] D K Owens. « mechanism of corona-induced self-adhesion of polyethylene film » J. Appl. Polym .Sci. 19, 265, 1975.

P

[Press 92] Press. W.H, Teukolsky. S.A, Vetterling. W.T, Flannery. B.P, *Numerical Recipes in C : the Art of Computing*, Cambridge University Press, 1992.

[Patc 79] R. Patch. « Electrical conduction in polyethylene under the influence of water vapour » *Ann. Rep. Conf .Elec. Ins. And. Diel. Phenomena*, 114, 1979.

R

[Rafi 01]M. Y. Rafiq, G. Bugmann and D. J. Easterbrook, « Neural network design for engineering applications», *Computers and Structures*, Vol. 79, pp. 1541, July 2001

[Reyn 02] R. A. Reyna Rojas, Conception et intégration VLSI d’un système de vision générique, Application à la détection et la localisation d’objets à l’aide de support vector machines, Thèse de doctorat, Laboratoire LAAS – CNRS, N°02226, Toulouse, France, 2002.

[Riva 94] Rivals I., Canas D., Personnaz L. & Dreyfus G. (1994) .Modeling and control of mobile robots and intelligent vehicles by neural networks., IEEE Conference on Intelligent Vehicles, 24-26 octobre 1994, Paris, pp. 137-142.

[Riva 95] Rivals I. (1995) .Modélisation et commande de processus par réseaux de neurones ; application au pilotage d'un véhicule autonome., Thèse de Doctorat de l'Université Paris 6.

S

[Sawa 71] G. Sawa, J. H. Calderwood. « Dependence of the surface conduction current in oxidized PE on electric fields at various humidities » C. Solid. St. Phys, Vol. 4, pp.2313-2348, 1971.

[Sida 98] D. E. Sidarta and J. Ghaboussi, « Constitutive modeling of geomaterials from non uniform material tests», Computers and Geotechnics, Vol. 22, pp. 53, 1998

[Sigm 82] Sigmond R.S and Goldman .M. «Corona discharges physics and applications » Electrical breakdown and discharges: phenomenon Press, pp1-64, 1982.

[Synd 03] Syndicats des producteurs de matières plastiques, Matières Plastiques–Chiffres 2003. Le Diamant A - 92909 Paris La Défense CEDEX.

T

[Torr 97] Juan-manuel Torres-moreno, Apprentissage et généralisation par des réseaux de neurones : Etude de nouveaux algorithmes constructifs, Thèse de Doctorat, Institut national polytechnique de Grenoble, France, 1997.

[Town14] Townsend .J.S. « The potential required to maintain currents between coaxial cylinders » Philo.Mag, Vol. 28, pp. 83-90, 1914.

[Tri38] Trichel G.W. « The mechanism of negative point to plane corona near onser » Phys. Rev, Vol. 54. pp.1078-1084, 1938.

[Tunc 97] Tuncer, E., Gubanski, S.M., « Electrical properties of filled silicone rubber », *Journal of Physics: Condensed Matter*, Vol.12, 2000, pp. 1873-1897.

U

[Urba 94] Urbani. D, Roussel-ragot. P, Personnaz. L, Dreyfus. G, “The selection of neural models of nonlinear dynamical systems by statistical tests”, *Neural Networks for Signal Processing I*, pp. 229-237, IEEE Press, 1994..

V

[Von B85] H.Von.Berlepsch. « Interpretation of surface potential kinetics in HDPE by a trapping model » *J. Phys. D : App. Phy*, N°18. pp.1155-1170, 1985.

W

[Wasz 01] Z. Waszczyszyn and L. ZiemiaImageski, « Neural networks in mechanics of structures and materials – new results and prospects of applications», *Computers and Structures Vol. 79*, pp. 2261, September 2001.

[Wu 90] X. Wu, J. H. Garrett and J. Ghaboussi, « Representation of material behavior. Neural network based models», *Proceedings International Joint Conference on Neural Networks*, San Diego, California, June 1990.

[Wu 91] X. Wu, « Neural network based material modeling», PhD Thesis, Dept. Civil Engng, Univ. of Illinois at Urbana-Champaign, 1991.

[Wu 92] X. Wu and J. Ghaboussi, « Neural network based material modeling of composite materials with emphasis on reinforced concrete», *Proceeding of the 8th ASCE Conference on Computing in Civil Engng*, Dallas, Texas, June 1992

Y

[Yosh 99] Yoshimura N., Kumagai Nishimura S., « Electrical and Environmental Aging of Silicone Rubber used in outdoor insulation », *IEEE Transactions on Dielectrics and Electrical Insulation*, vol. 6, 1999, pp.632-647.

Z

[Zemo 03] M. R. Zemouri, Contribution à la surveillance des systèmes de production à l'aide des réseaux de neurones dynamique, Application à la e-maintenance, Thèse de doctorat, Université de Franche-Comté, 2003.

[Zism 32] Zisman W.A.«A new method of measuring contact potential differences in metals »
Rev. Of. Scien. Instr, Vol. 3 (7), pp.367-370, 1932.