



**MINISTÈRE DE L'ENSEIGNEMENT SUPÉRIEUR ET DE LA
RECHERCHE SCIENTIFIQUE
UNIVERSITÉ ABDELHAMID IBN BADIS MOSTAGANEM**

**FACULTÉ DES SCIENCES ET DE LA TECHNOLOGIE
DÉPARTEMENT DE GENIE MÉCANIQUE
OPTION : MODÉLISATION, SIMULATION NUMÉRIQUE ET CALCULS
SCIENTIFIQUES APPLIQUÉS**

Mémoire de magister

**Application des réseaux de neurones et des SVM
dans la prédiction du potentiel et du taux de
corrosion d'un acier**

Présenté par :

- **SADI KHALED**

Le jury est composé de :

-ZENASNI Remdane	Pr.Univ.Mostaganem	président
-OUINAS Djamel	Pr.Univ.Mostaganem	Examineur
-MERAH Mustapha	M.C (A) Univ.Mostaganem	Examineur
-AIT SAADI Bachir	Pr. USTO	Encadreur

Année universitaire 2017/2018

Remerciements

En premier lieu je voudrais remercier mon enseignant et encadreur, Monsieur **B. AIT SAADI**, et Mm T . **AIT SAADI** pour m'avoir soutenu, encadré, appris et surtout pour m'avoir fait confiance le long de ces trois dernières années. Je tien à leurs exprimer toute ma gratitude pour leur application, leur implication, leurre disponibilité et leurs valeureux conseilles, sans lesquels ce travail n'aurait vu le jour.

J'adresse mes sincères remerciements à Monsieur **ZENASNI.** , professeur à l'Université de Mostaganem pour avoir accepter de présider la commission d'examen. Je saisi aussi cette occasion pour exprimer toute ma reconnaissance à Monsieur **D. OUINAS** pour son assistance au cours de l'année théorique pendant laquelle j'ai eu l'honneur de l'avoir comme enseignant.

Je tien à remercier profondément Monsieur **N. RETIEL** professeur à l'université de Mostaganem et Monsieur **M.MRAH**, maitre de conférence (A) à l'université de Mostaganem, pour m'avoir fait l'honneur d'accepter de juger le présent travail.

Merci à tous mes amis qui ont contribués de prés ou de loin à la réalisation de ce travail.

Dédicaces

Je dédie ce travail à :

Mon père,

Ma mère Djedjiga et ma mère Dehbia,

Mon épouse Hanane

Mes frères : Mohamed Said, Amine, Abdelkrime, Abdelah et Abdelhamid

Mes sœurs : Nacéra, Sakina, Souhila, Lamisse, Naima et Souad

Et à toute ma famille

Résumé

L'objectif de notre travail est d'apporter une méthode in situ, précise, pouvant donner l'état des armatures en acier de renforcement, présent dans un mortier (béton ou argile), en utilisant les données déjà disponibles, sans avoir recours à des méthodes supplémentaires plus au moins qualifiées de destructives, tel que le carottage ...etc. Il se trouve que la méthode la plus répondeur pour ausculter les structures est la mesure du potentiel de corrosion, données déjà à la possession de l'ingénieur. Pour se faire, nous avons proposé l'utilisation des réseaux de neurones artificiels, qui représentent une branche de l'intelligence artificielle, pour calculer et prédire le taux de corrosion. Le matériau est un barreau d'acier plongé dans une argile appelée le limon, malaxé dans l'eau du robinet. Cet échantillon a subi des essais en potentiel dynamique sur un Potentiostat Voltalb 40, pendant une période de deux mois. Ceci nous a permis d'extraire des valeurs du potentiel et du taux de corrosion en fonction du temps d'immersion. Nous avons constitué une base de données de 38*3 paramètres.

Le taux de corrosion du (N+1) potentiel de corrosion a été prédit avec une erreur relative allant de 0 à 5%. Nous avons donc montré que l'utilisation des réseaux de neurone avec une gestion des bases de données acquise, au fur et à mesure, par cette dernière, peut donc prédire le comportement en corrosion des structures avec une bonne précision et réduire ainsi de coût de leurs suivis. Cette vision peut être généralisée pour les pipes et toutes les structures dans lesquelles l'acier est difficilement accessible.

Abstract

The objective of our work is to provide a method in situ, precise which can give the state of reinforcing steel reinforcement, present in a mortar (concrete or clay), using the data already available, without having recourse to Additional methods known at least as destructive, such as coring ... etc. It turns out that the most answered method to auscultate the structures is the measurement of the corrosion potential, given already to the possession of the engineers. In order to do this, we proposed the use of artificial neural networks, which represent a branch of artificial intelligence, to calculate and predict the rate of corrosion. The material is a steel bar immersed in a clay called silt, kneaded in tap water. This sample has undergone dynamic potential testing on a potentiostat Voltalab 40 for a period of two months. This allowed us to extract values of the potential and the corrosion rate as a function of the immersion time. We have built up a data base of $38 * 3$ parameters.

The corrosion rate related of the $(N + 1)$ corrosion potential was predicted with a relative error ranging from 0 to 5%. We have thus shown that the use of neural networks with acquired data base management, and as a result, the latter can thus predict the corrosion behavior of the structures with good accuracy and thus reduce the cost of their monitoring. This vision can be generalized for pipes and all structures in which steel is difficult to access.

الملخص

الهدف من هذا العمل هو توفير طريقة دقيقة في الموقع، توصلنا إلى الحالة الحالية لحديد التسليح في الهاون (الأسمنت أو الطين)، وذلك باستخدام البيانات المتاحة ، دون اللجوء إلى وسائل أخرى والموصوفة بالدمرة كالحفر ... الخ. إن الأسلوب الأكثر انتشاراً لتفحص الهياكل هو قياس قيم كمنون التآكل، التي هي معطيات بحوزة المهندس. وفي هذا السياق، اقترحنا استخدام الشبكات العصبية الاصطناعية، والتي تمثل أحد فروع الذكاء الاصطناعي، لحساب وتوقع معدل التآكل. المادة المراد دراستها هو قضيب من حديد البناء مغمور في طين مسمى الطمي، معجون في ماء الحنفية. هذه العينة تخضع لاختبارات تغيير الكمنون على potentiostat VoltaLab40 ، لمدة شهرين. وقد سمح لنا هذا باستخراج قيم كمنون ومعدل التآكل بدلالة وقت الغمر. قمنا ببناء قاعدة بيانات من 38 * 3 قيم.

قد تم توقع معدل تآكل الموافق لقيمة $(N + 1)$ كمنون تآكل مع خطأ نسبي يتراوح بين 0-5%. وبذلك أظهرنا أن استخدام الشبكات العصبية مع إدارة قاعدة البيانات المكتسبة المستحدثة تدريجياً، تمكننا التنبؤ بسلوك تآكل الهياكل بدقة مقبولة، وبالتالي تقليل تكلفة الرصد الخاصة بهم. هذه الرؤية يمكن تعميمها للأنابيب والهياكل الحديدية التي من الصعب الوصول إليها

Sommaire

Introduction générale.....	1
----------------------------	---

Chapitre I : Introduction aux réseaux de neurones artificiels

I.1 Introduction.....	3
I.2. Neurone biologique	3
I.3. Neurone artificiel (formel)	4
I.4. Fonctions d'activation	5
I.4.1. Fonction tout/ rien (à seuil).....	6
I.4.2. Fonction linéaire	6
I.4.3. Fonction sigmoïde	6
I.5. Réseaux de neurones artificiel (RNA)	8
I.5.1 Définition	8
I.5.2 Architecture des réseaux de neurones	9
I.5.2.1 Les réseaux de neurones non bouclés	10
I.5.2.1.1 Les réseaux de neurones complètement connectés	10
I.5.2.1.2 Les réseaux de neurones à couches	11
I.5.2.2 Les réseaux de neurones bouclés	11
I.6. Apprentissage des réseaux de neurones	12
I.6.1. Apprentissage supervisé.....	12
I.6.2 Apprentissage non supervisé	13
I.6.3. Apprentissage par renforcement	13

I.7. Perceptron multicouche (MLP).....	14
I.7.1.Equation du réseau MLP	14
I.7.2.Algorithme d'apprentissage des réseaux de neurones multicouches	15
I.7.2.1.Algorithme d'entraînement	15
I.7.2.2.Amélioration de la vitesse de convergence de l'algorithme	17
I.7.2.3.Algorithme de Levenberg-Marquardt	18
I.7.2.4.Initialisation du vecteur des paramètres poids synaptiques..	19
I.7.2.5.Amélioration de la généralisation	20

CHAPITRE II - GENERALITE SUR LA CORROSION

II-1-Introduction	22
II-2-Historique	22
II-3-Impact économique de la corrosion	22
II-4- Types et morphologie des dégradations par corrosion	23
II-4-1-Types de dégradations par corrosion	23
II-4-1-1- Corrosion chimique (sèche)	23
II-4-1-2- Corrosion biochimique	23
II-4-1-3- Corrosion avec érosion, avec frottement et par cavitation ...	25
II-4-1-4- Corrosion électrochimique	26
II-4-2- Morphologie des dégradations par corrosion :.....	27
II-4-2-1- Etat d'immunité :	27
II-4-2-2- Etat de passivité	27

II-4-2-3- Etat d'activité	27
II-4-2-4- Diagramme de Pourbaix	27
II-5 - Principales formes de corrosion	28
II-5-1 - Corrosion uniforme.....	28
II-5-2. Corrosion localisée	29
II-6- Facteurs de la corrosion	32
II-7- Etude de la corrosion	33
II-8- Mesure de la corrosion	34
II-9- Cellule électrochimique	35
II-10-1 Densité de courant macro pile	36
II-10-2 Potentiel de corrosion	37
II-10-3- Potentiel d'une électrode (potentiel d'équilibre)	37
II-10-4 - Polarisation linéaire	37
II-11- Taux de corrosion	39
CHAPITRE III- PARTIE MÉTHODOLOGIE	
III.1. Problématique et objectif	40
III.2. Procédure de construction d'un réseau de neurones	41
III.2.1. Collecte d'une base de données	41
a- <u>Collecte de base de données pour Prédire le taux de corrosion</u>	42
b- <u>Collecte de base de donnée pour Prédire le potentiel de corrosion</u>	44

III.2.2. Séparation des bases de données	46
III.2.3. Choix de l'architecture du réseau	46
III.2.4 Prétraitement des données	48
III.2.5. Phase d'apprentissage	49
III.2.6. Phase de test	51

CHAPITRE III- PARTIE B : RESULTAS ET DISCUSSIONS

IV-1-Introduction	53
IV -2-Principe de l'essai de potentiel de corrosion	53
IV -3-Quelle est la fiabilité de l'essai de potentiel de corrosion ?.....	54
IV -4-Validation de notre approche :	54
IV -4-a- prédiction du taux de corrosion	56
IV -4-b- Le potentiel de corrosion	61
IV -5- Calcul du potentiel de corrosion a partir de notre base de données expérimentale	65
Conclusion	71

Annexes

INTRODUCTION GENERALE

INTRODUCTION GENERALE

Introduction

De nos jours, le nombre d'infrastructures concernées par la dégradation et le vieillissement a atteint un seuil alarmant. Les dotations consacrées au renforcement des ouvrages d'art du secteur public ont progressé d'environ 200 % depuis 1992 pour atteindre 93,3 millions d'euros en 2005.

Le Contrôle Non Destructif (CND) des structures en béton présente donc un enjeu économique important permettant la gestion du patrimoine bâti. La dégradation du béton, sous l'action des pathologies physico-chimiques (ex : corrosion des barres d'armatures) est parmi les facteurs majeurs qui limitent la durée de vie des ouvrages.

En effet, la corrosion des armatures est la principale cause de dégradation des ouvrages en béton armé. Plus ou moins à long terme, cette corrosion affecte la durabilité de ces ouvrages et peut conduire à une perte de leur capacité structurale. Il est donc extrêmement important d'ausculter périodiquement les ouvrages afin de déterminer s'ils sont atteints par cette corrosion. La principale technique utilisée dans cet objectif est le potentiel de corrosion.

En revanche, les relevés du Potentiel de Corrosion peuvent donc parfois soit surestimer, soit sous-estimer l'état de dégradation du béton. Ces relevés sont avant tout destinés à évaluer la probabilité de corrosion des armatures.

Les ingénieurs seraient donc intéressés à connaître l'état de dégradation des structures en béton armé, telles que les dalles des tabliers de ponts, et à quantifier cette dégradation. Ceci leur permet de décider du type de réparation et d'estimer le coût des travaux.

Les travaux de recherche présentés dans ce mémoire s'inscrivent dans cette optique. Ils visent à mettre en œuvre, une méthodologie de diagnostic plus précise et précoce des risques pathologiques basée sur le relevé du potentiel de corrosion. Le problème a été abordé selon une approche statistique. Dans cette thématique, les Réseaux de Neurones Artificiels (RNA) se positionnent comme une technique prometteuse du fait de leur parcimonie et de leur simplicité.

Notre travail a été partagé en quatre chapitres :

Dans le premier, nous avons présenté les réseaux de neurone artificiel, leurs historiques et le domaine de leurs utilisations, et élucide les facilités conférés et les avantages qu'ils confèrent.

Par la suite, dans le deuxième chapitre, nous avons abordé des généralités sur la corrosion.

INTRODUCTION GENERALE

Le troisième chapitre a été consacré à présenter la méthodologie avec laquelle nous avons abordé le problème. Nous avons fait une introduction du logiciel Matlab qui a servi de support comportant l'implantation des RNA.

Dans le quatrième chapitre, Nous avons présenté notre travail : Nous avons confronté nos résultats à ceux trouvés par deux références pour leurs mêmes bases de données, pour vérifier notre maîtrise de l'outil réseau de neurone.

Par la suite, et grâce à une base de donnée extraite d'un programme expérimental, réalisé au niveau du notre laboratoire, nous avons construit notre architecture RNA, faire l'apprentissage, le test et la prédiction du taux de corrosion.

Nous avons prouvé que le taux de corrosion peut être calculé par le RNA sur la base de la connaissance des potentiels de corrosion des armatures ainsi que le temps d'immersion dans le mortier.

CHAPITRE I
INTRODUCTION AUX
RESEAUX DE NEURONES
ARTIFICIELS

I.1.Introduction

Les réseaux de neurones connaissent depuis quelques années un succès croissant dans divers domaines des sciences de l'ingénieur, celui du génie mécanique n'échappe pas à cette règle.

En 1948, Mac Culloch et Pitts, ont donné naissance au premier modèle mathématique de neurone biologique, qu'ils ont appelé: neurone formel.

L'idée principale des réseaux de neurones est la suivante: On se donne une unité simple, un neurone, qui est capable de réaliser quelques calculs élémentaires. On relie ensuite un certain nombre de ces unités sous forme d'un réseau capable de résoudre un problème plus complexe. La structure, la taille du réseau et le mécanisme d'apprentissage utilisé dépendent du type et de la complexité de l'application en question [1].


Dans ce chapitre nous présenterons les réseaux de neurones d'un point de vue général ensuite nous traiterons en détails le perceptron multicouche qu'on va utiliser dans notre application, en régression non linéaire avec l'algorithme d'apprentissage de Levenberg-Marquardt qui est une variation de l'algorithme de la rétro propagation du gradient de l'erreur.

I.2.Neurone biologique

Le neurone considéré comme l'unité de base du système nerveux central est constitué d'un corps cellulaire appelé *soma*, qui se ramifie pour former ce que l'on nomme les dendrites.

Les dendrites acheminent l'information de l'extérieur, ou d'autres neurones, vers le soma. Après traitement de l'information par le corps cellulaire, l'information sera transmise aux autres neurones à travers un prolongement de sortie appelé axone.

Entre un axone et une dendrite, il existe un espace vide appelé synapse, à travers lequel la transmission se fait par l'intermédiaire de substances chimiques.



Figure(I.1).Représentation d'un neurone biologique [28].

Le cerveau se compose d'environ mille milliards 10^{12} , de cellules nerveuses appelées neurones. La sortie de chaque neurone est liée à des milliers d'autres neurones. Chaque neurone effectue un traitement local. Il collecte les signaux issus des dendrites et leur fait la somme. Si l'amplitude résultante dépasse un certain seuil interne, un signal est envoyé à travers l'axone vers d'autres neurones.

I.3.Neurone artificiel (formel)

Le neurone artificiel est un modèle de calcul dont la conception est inspirée du fonctionnement de vrais neurones. Ce neurone formel peut être considéré comme un opérateur recevant un nombre variable d'entrées du milieu extérieur ou d'autres neurones, chacune de ces entrées est pondérée par un poids dit poids synaptique, et fournissant une sortie seulement quand la somme dépasse un certain seuil interne.

L'évaluation de la sortie se fait typiquement par la somme pondérée des entrées, et le passage du résultat à travers une non linéarité. Mathématiquement, ceci peut être modélisé par les équations suivantes:

$$S = \sum_{i=1}^n w_i x_i + w_0 x_0 \quad (\text{I-1})$$

$$y = f(S) \quad (\text{I-2})$$

x_i : Composantes du vecteur d'entrée.

w_i : Composantes du vecteur poids synaptique.

S : Somme pondérée appelée potentiel.

Le terme ($w_0 x_0 = \theta_0$ avec $x_0 = 1$) représente la valeur du seuil interne qui doit être dépassée pour l'activation de la sortie du neurone. La non linéarité $f(s)$ est appelée fonction d'activation.

La somme pondérée peut se réécrire sous la forme simple suivante:

$$S = \sum_{i=0}^n w_i x_i \quad (I.3)$$

Conceptuellement, le fonctionnement du neurone biologique peut être représenté par le modèle de la figure(I.2)




Figure (I.2) : Modèle d'un neurone formel à n entrées [28].

I.4.Fonctions d'activation

Plusieurs types de fonctions d'activation sont utilisés, servant à limiter l'amplitude du signal de sortie du neurone et reproduire l'effet de seuil observé sur les neurones biologiques. Le tableau (I.1) énumère ces différentes fonctions.

Cependant, certaines fonctions sont les plus utilisées, telles que: la fonction à seuil, la fonction linéaire, et la fonction sigmoïde.

I.4.1. Fonction tout/ rien (à seuil)

La fonction seuil applique un seuil sur son entrée. Elle retourne 0 pour une entrée négative et 1 pour une entrée positive ou nulle. Elle est définie comme suit:

$$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases} \quad (\text{I.4})$$

I.4.2. Fonction linéaire

La fonction linéaire est très simple, elle affecte directement son entrée à sa sortie.

$$f(x) = x \quad (\text{I.5})$$

I.4.3. Fonction sigmoïde

Plus connue et plus populaire. Elle est souvent utilisée dans les réseaux de neurones. L'un de ses avantages est sa dérivabilité. Cette propriété est très importante, du fait qu'elle a permis de développer des algorithmes d'apprentissage à base du gradient pour les réseaux multicouches.

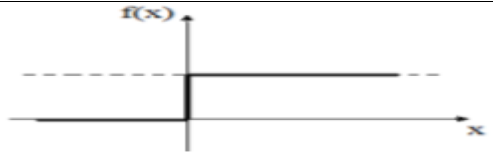
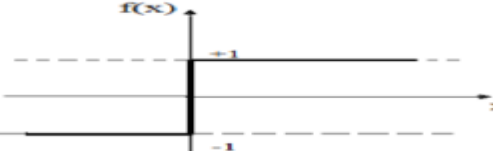
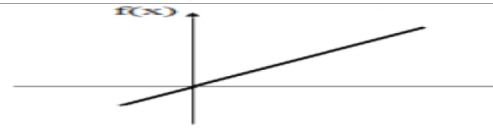
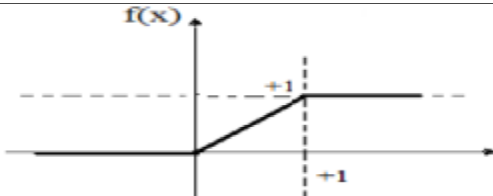
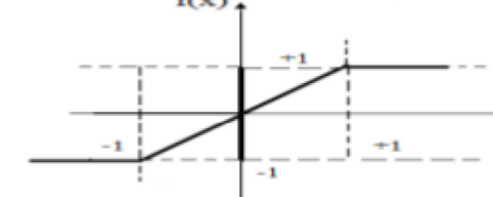
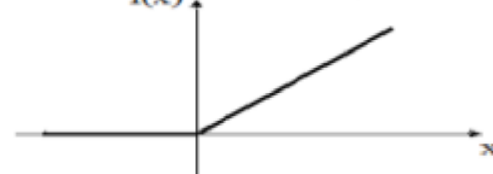
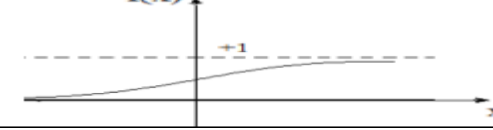
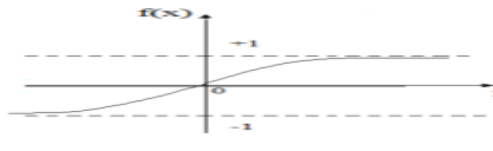
Deux formes de sigmoïdes sont utilisées:

- Sigmoides (logistique) : Ayant deux niveaux de saturation (0 et 1) est définie comme suit:

$$f(x) = \frac{1}{1 + e^{-x}} \quad (\text{I.6})$$

- Tangente hyperbolique: Peut être exprimée par la tangente-hyperbolique suivante:

$$f(x) = \tanh(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (\text{I.7})$$

Nom de la fonction	Relation entrée\sortie	L'allure
Seuil	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$	
Seuil symétrique	$f(x) = \begin{cases} -1 & \text{si } x < 0 \\ 1 & \text{si } x \geq 0 \end{cases}$	
Linéaire	$f(x) = x$	
Linéaire saturée	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } 0 \leq x \leq 1 \\ 1 & \text{si } x > 1 \end{cases}$	
Linéaire saturée symétrique	$f(x) = \begin{cases} -1 & \text{si } x < -1 \\ x & \text{si } -1 \leq x \leq 1 \\ 1 & \text{si } x > 1 \end{cases}$	
Linéaire positive	$f(x) = \begin{cases} 0 & \text{si } x < 0 \\ x & \text{si } x \geq 0 \end{cases}$	
Sigmoïde	$f(x) = \frac{1}{1 + e^{-x}}$	
Tangente hyperbolique	$f(x) = \tanh(x) = \frac{1 - e^{-x}}{1 + e^{-x}}$	

Tableau(I.1) : fonction de transfert f(x) [28].

I.5.Réseaux de neurones artificiel (RNA)

Les capacités d'un seul neurone sont limitées. L'implantation de fonctions complexes nécessite l'intégration de plusieurs neurones, fonctionnant en parallèles, sous forme d'un réseau.

I.5.1 Définition

Un réseau de neurones peut être considéré comme un modèle mathématique de traitement réparti, composé de plusieurs éléments de calcul non linéaire (neurones), opérant en parallèle et connectés entre eux par des poids.

Les réseaux de neurones artificiels sont des réseaux fortement connectés de processeurs élémentaires fonctionnant en parallèle. Chaque processeur élémentaire calcule une sortie unique sur la base des informations qu'il reçoit.

Les paramètres les plus importants de ce modèle sont les poids synaptiques. Ce sont eux qui construisent le modèle de résolution en fonction des informations données au réseau. Il faut donc trouver un mécanisme qui permet de les calculer à partir des grandeurs que l'on peut acquérir du problème. C'est le principe fondamental de l'apprentissage [2].

Les neurones artificiels sont souvent utilisés sous forme de réseaux qui diffèrent selon le type de connections entre les neurones, une cinquantaine de types peut être dénombrée. En guise d'exemples nous citons : le perceptron de Rosembat, les réseaux de Hopfield etc.....

Ces derniers sont les plus utilisés dans le domaine de la modélisation et de la commande des procédés. Ils sont constitués d'un nombre fini de neurones qui sont arrangés sous forme de couches. Les neurones de deux couches adjacentes sont interconnectés par des poids. L'information dans

Le réseau se propage d'une couche à l'autre, on dit qu'ils sont de type « feed-forward ».

Nous distinguons trois types de couches :

Couche d'entrée :

Les neurones de cette couche reçoivent les valeurs d'entrée du réseau et les transmettent aux neurones cachés. Chaque neurone reçoit une valeur, il ne fait pas donc de sommation.

Couches cachées :

Chaque neurone de cette couche reçoit l'information de plusieurs couches précédentes, effectue la sommation pondérée par les poids, puis la transforme selon sa fonction d'activation qui est en général une fonction sigmoïde. Par la suite, il envoie cette réponse aux neurones de la couche suivante.

Couche de sortie :

Elle joue le même rôle que les couches cachées, la seule différence entre ces deux types de couches est que la sortie des neurones de la couche de sortie n'est liée à aucun autre neurone.

Une fois que l'ajustement des poids synaptiques a été effectué, le réseau de neurones constitue un modèle statistique non linéaire [3]. L'avantage des réseaux de neurones sur les méthodes de régression classique est qu'ils nécessitent, en général, un nombre de paramètres ajustables plus faible pour obtenir un modèle non linéaire de précision donnée [4].

I.5.2 Architecture des réseaux de neurones

On distingue deux structures de réseau, en fonction du graphe de leurs connexions, c'est-à-dire du graphe dont les nœuds sont les neurones et les arêtes les «connexions» entre ceux-ci:

- Les réseaux de neurones statiques (ou acycliques, ou non bouclés).
- Les réseaux de neurones dynamiques (ou récurrents, ou bouclés).

Les réseaux bouclés sont le plus souvent utilisés pour des tâches telles que le traitement du signal, la commande ou la régulation. Les non bouclés eux sont utilisés pour la reconnaissance, la classification ou la prédiction [5].

I.5.2.1 Les réseaux de neurones non bouclés

Un réseau de neurones non bouclé réalise une (ou plusieurs) fonction algébrique de ses entrées par composition des fonctions réalisées par chacun de ses neurones. Dans un tel réseau (figure 1.3), le flux d'information circule des entrées vers les sorties sans retour en arrière. Si l'on représente le réseau comme un graphe dont les nœuds sont les neurones et les arêtes les « connexions » entre ceux-ci, le graphe d'un réseau non bouclé est acyclique.

Tout neurone dont la sortie est une sortie du réseau est appelé « neurone de sortie ». Les autres, qui effectuent des calculs intermédiaires, sont des « neurones cachés ».

Il existe deux types de réseaux de neurones : les réseaux complètement connectés et les réseaux à couche. Le réseau de neurones à une couche cachée et une sortie linéaire est un cas particulier de ce dernier type.

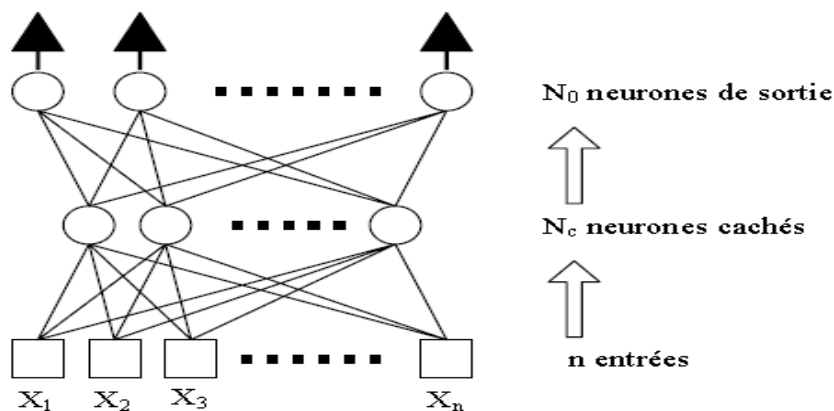


Figure (I.3) : structure d'un réseau non bouclé (non récurrent) [29].

I.5.2.1.1 Les réseaux de neurones complètement connectés :

Dans un réseau complètement connecté, les entrées puis les neurones (cachés et de sortie) sont numérotés, et, pour chaque neurone :

- Ses entrées sont toutes les entrées du réseau ainsi que les sorties des neurones de numéro inférieur.
- Sa sortie est connectée aux entrées de tous les neurones de numéro supérieur.

I.5.2.1.2 Les réseaux de neurones à couches

Dans une architecture de réseaux à couches, les neurones cachés sont organisés en couches, les neurones d'une même couche n'étant pas connectés entre eux. De plus les connexions entre deux couches de neurones non consécutives sont éliminées.

Une telle architecture est historiquement très utilisée, surtout en raison de sa pertinence en classification.

➤ **Remarque :**

Dans un réseau de neurones non bouclé, le temps ne joue aucun rôle fonctionnel : si les entrées sont constantes, les sorties le sont également. Le temps nécessaire pour le calcul de la fonction réalisée par chaque neurone est négligeable et on peut considérer ce calcul comme instantané.

Pour cette raison, les réseaux non bouclés sont souvent appelés « réseaux statiques », par opposition aux réseaux bouclés ou « dynamiques ». Ils sont utilisés en classification, reconnaissance des formes (caractères, parole, ...), en prédiction


I.5.2.2 Les réseaux de neurones bouclés

L'architecture la plus générale pour un réseau de neurones est le « réseau bouclé », dont le graphe des connexions est cyclique : lorsqu'on se déplace dans le réseau en suivant le sens des connexions, il est possible de trouver au moins un chemin qui revient à son point de départ (un tel chemin est désigné sous le terme de « cycle »). La sortie d'un neurone du réseau peut donc être fonction d'elle-même; cela n'est évidemment concevable que si la notion de temps est explicitement prise en considération.

Ainsi, à chaque connexion d'un réseau de neurones bouclé (ou à chaque arête de son graphe) est attaché, outre un poids comme pour les réseaux non bouclés, un retard, multiple entier (éventuellement nul) de l'unité de temps choisie. Une grandeur, à un instant donné, ne pouvant pas être fonction de sa propre valeur au même instant, tout cycle du graphe du réseau doit avoir un retard non nul.

Les connexions récurrentes ramènent l'information en arrière par rapport au sens de propagation défini dans un réseau multicouche. Ces connexions sont le plus souvent locales. Pour éliminer le problème de la détermination de l'état du réseau par bouclage, on introduit

sur chaque connexion « en retour » un retard qui permet de conserver le mode de fonctionnement séquentiel du réseau (figure 1.4).



Figure(I.4) : structure d'un réseau bouclé (récurrent) [28].

I.6.Apprentissage des réseaux de neurones

La propriété la plus importante pour un réseau de neurones, est sûrement sa capacité d'apprendre de son environnement, d'améliorer sa performance à travers un processus d'apprentissage.

L'apprentissage est une phase du développement d'un réseau de neurones durant laquelle les valeurs des poids synaptiques du réseau sont ajustées pour remplir au mieux la tâche à laquelle le réseau est destiné.

On peut distinguer trois types d'apprentissage

- L'apprentissage supervisé.
- L'apprentissage non supervisé.
- L'apprentissage par renforcement.

I.6.1.Apprentissage supervisé

Dans l'apprentissage supervisé, des couples de données (entrée, sortie attendue correspondante) sont fournis au réseau; les différentes réponses possibles du réseau étant donc connues à priori.

Les paramètres du réseau sont ajustés de façon à minimiser le signal d'erreur constitué par la différence entre la sortie obtenue et la valeur désirée correspondante.

Un apprentissage est dit supervisé lorsqu'on force le réseau à converger vers un état final précis, en même temps qu'on lui présente un motif. L'apprentissage supervisé est illustré d'une manière conceptuelle par la figure (I.5).

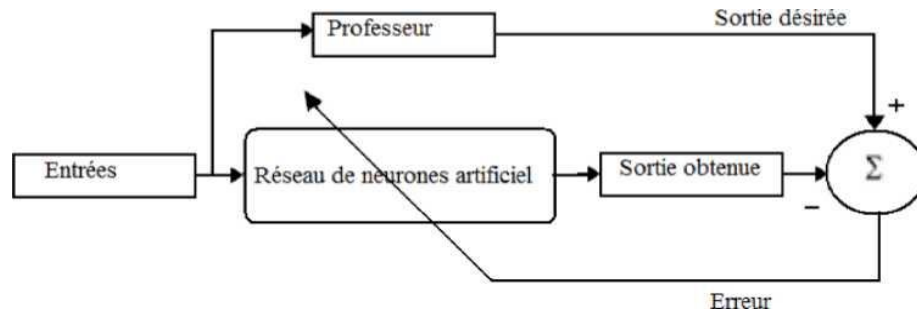


Figure (I.5) : Schéma bloc de l'apprentissage supervisé d'un réseau de neurone [28].

I.6.2 Apprentissage non supervisé

Dans un modèle non supervisé, on n'a pas de connaissance à priori sur l'information que l'on voudrait extraire. Le réseau est laissé libre de converger vers n'importe quel état final.

Dans ce cas, les exemples présentés à l'entrée provoquent une auto-adaptation du réseau (figure (1.6)) afin de produire des valeurs de sortie qui soient proches en réponse à des valeurs d'entrées similaires [7].




Figure (I.6): Schéma bloc de l'apprentissage non supervisé d'un réseau de neurone [28].

I.6.3. Apprentissage par renforcement

L'apprentissage par renforcement est utile quand une information de retour sur la qualité de la performance est fournie. Mais la conduite souhaitée du réseau n'est pas complètement spécifiée par le professeur.

I.7. Perceptron multicouche (MLP)

Le perceptron multicouche (figure (I.7)) est sans doute le plus simple et le plus connu des réseaux de neurones; le plus utilisé pour des problèmes d'approximation, de classification et de prédiction [8]. Il est constitué de plusieurs couches de neurones totalement connectées. La fonction d'activation utilisée est principalement la fonction sigmoïde. Ce type de réseau est dans la famille générale des réseaux à propagation vers l'avant (Feedforward en anglais).




Figure (I.7) : Structure d'un perceptron multicouche [28].

I.7.1. Equation du réseau MLP

Considérons le réseau de neurones MLP « Multi Layer Perceptron » à L couches, de p entrées et q sorties. La couche d'entrée contient les composantes du vecteur d'entrée (x_i) $0 \leq i \leq p$. Les calculs se font couche par couche de l'entrée vers la sortie. La sortie du j^{ème} neurone de la couche 1 ($0 < 1 < L$) est donnée par:

$$S_j^l = \sum_{i=0}^{N^l-1} w_{ji}^l \cdot u_i^{l-1} \quad (1.8)$$

$$u_j^l = f(S_j^l) \quad (1.9)$$

Ou :

s_j^l : est la somme pondérée à l'entrée du j^{ème} neurone dans la couche (l).

N^l : est le nombre de neurone de la couche (l).

u_j^l : est la sortie du j^{ème} neurone dans la couche (l).

w_{ji}^l : est le poids qui relie le i^{ème} neurone de la couche (l-1) au j^{ème} neurone dans la couche (l).

L : nombre de couches dans le réseau. La couche 0 correspond aux nœuds d'entrée,

$f(s)$: est la fonction d'activation, elle peut être linéaire ou non pour les neurones de la couche de sortie, mais toujours non linéaire pour les neurones appartenant à une couche cachée.

On note que le premier élément de chaque vecteur u^l ($l= 0, 1, \dots L-1$) est mis à un (i.e., $u_0^l = 1$) et que le produit $(w_{j0}^l * u_0^{l-1})$ représente la valeur du seuil interne du $j^{\text{ème}}$ neurone dans la couche l .

I.7.2.Algorithme d'apprentissage des réseaux de neurones multicouches

Les réseaux de neurones multicouches constitués de fonctions de transfert différentiables, utilisent un algorithme de rétro-propagation du gradient; dans lequel les poids du réseau sont ajustés de façon à minimiser une fonction de coût, en utilisant seulement les données d'entrée/sortie. En effet, l'erreur à la sortie du réseau est le résultat de fausses valeurs de plusieurs poids synaptiques. Ainsi la rétro-propagation consiste à rétro-propager l'erreur commise par un neurone à ses synapses et aux neurones qui y sont reliés.

On commence l'entraînement par un choix aléatoire des vecteurs initiaux du poids. On présente le vecteur d'entrée, une fois on a la sortie du réseau, l'erreur correspondante et le gradient de l'erreur par rapport à tous les poids sont calculés. Les poids sont alors ajustés. Ce processus est répété jusqu'à ce que les sorties du réseau soient suffisamment proches des sorties désirées.

I.7.2.1.Algorithme d'entraînement

Considérant un réseau de neurones constitué de L couches, ayant des fonctions d'activation de type sigmoïde.

Voici un résumé de la démarche à suivre pour entraîner un perceptron multicouche (voir annexe A pour les calculs détaillés) :

1. Initialiser le numéro du vecteur d'apprentissage: $k=1$
2. Initialiser tous les poids de connexions w_{ji}^l à des petites valeurs aléatoires.
L'indice i représente un neurone appartenant à une couche en amont et l'indice j un neurone appartenant à une couche en aval.
3. Présentation d'un vecteur d'entrée $X(k)$ aux nœuds d'entrée du réseau et le vecteur de sortie désirée $u_j^{d,l}(k)$ sur les neurones de la couche de sortie afin de calculer l'erreur commise par le réseau.

4. Calcul des sorties des neurones couches par couche de l'entrée vers la sortie.

La sortie d'un neurone j est donnée par :

Pour $l = 1 \rightarrow L$

Pour $j=1 \rightarrow N^l$

$$u_j^l(k) = f \left(\sum_{i=0}^{N^{l-1}} w_{ji}^l * u_i^{l-1}(k) \right) \quad (\text{I.10})$$

5. Calcul des erreurs sur les sorties des neurones, de la sortie vers l'entrée

Pour $j=1 \rightarrow N^l$

$$\delta_j^l(k) = u_j^l(k) - u_j^{L,D}(k) \quad (\text{I.11})$$

Pour $l=L-1 \rightarrow 1$

Pour $j=1 \rightarrow N^l$

$$\delta_j^l(k) = \sum_{m=1}^{N^{l+1}} \delta_m^{l+1}(k) \cdot w_{mj}^{l+1}(k) \cdot u_m^{l+1}(k) \cdot [1 - u_m^{l+1}(k)] \quad (\text{I.12})$$

6. Modification des poids de connexions:

Pour $l=L \rightarrow 1$

Pour $j=1 \rightarrow N^l$

Pour $i=0 \rightarrow N^{L-1}$

$$\Delta w_{ji}^l(k) = \delta_j^l(k) \cdot u_j^l(k) \cdot [1 - u_j^l(k)] \cdot u_i^{l-1}(k) \quad (\text{I.13})$$

$$w_{ji}^l(k+1) = w_{ji}^l(k) + \eta \Delta w_{ji}^l(k) \quad (\text{I.14})$$

η est le pas d'apprentissage ($0 \leq \eta \leq 1$)

7. calcul de l'erreur quadratique

$$E_N(k) = \frac{1}{2} \sum_{j=1}^{N^L} (u_j^L(k) - u_j^{d,L})^2 \quad (\text{I.15})$$

8. Si $k=K$ aller à l'étape 9; sinon $k=k+1$ et aller à l'étape 3 K étant le nombre d'exemples de la base d'apprentissage.

9. Calculer l'erreur totale moyenne :

$$EQM = \frac{1}{k} \sum_{k=1}^k E_N(k) \quad (\text{I.16})$$

Si $EQM \leq \varepsilon$ (avec $\varepsilon > 0$ donné) alors arrêter l'apprentissage sinon revenir en (1).

I.7.2.2. Amélioration de la vitesse de convergence de l'algorithme

Bien que l'algorithme de la rétro-propagation soit le plus utilisé pour l'apprentissage supervisé des MLP, son implantation se heurte à plusieurs difficultés techniques. A coté du choix d'une architecture appropriée pour le réseau et les valeurs initiales satisfaisantes pour les poids synaptiques, on peut citer le problème de choix du pas d'apprentissage q qui joue un rôle capital, si sa valeur est trop petite la convergence se fait très lentement, alors que si on prend une valeur trop grande, la convergence est accélérée mais les poids oscillent et ne se stabilisent pas.

Une des solutions est de rajouter un terme d'inertie appelé momentum (moment) a dans la règle d'apprentissage de l'algorithme, dont le rôle est de filtrer les oscillations dans la trajectoire de la descente du gradient et d'éviter les problèmes liés à une stabilisation dans un minimum local [9].

Le changement de poids prend en compte les informations des changements précédents. C'est cet effet de mémoire qui permet d'éviter les oscillations et accélère l'optimisation du réseau. Ainsi la règle d'adaptation des poids devient:

$$w(k+1) = w(k) - \eta \Delta w(k) - \alpha \Delta w(k-1) \quad (\text{I.17})$$

Avec α un paramètre compris entre 0 et 1.

Cependant, pour les problèmes complexes, les algorithmes de type rétro-propagation du gradient, convergent insuffisamment quel que soit le pas ou le momentum, nécessitant l'appel à des algorithmes plus puissants [10], dits algorithmes de second ordre, tel que l'algorithme de Levenberg Marquardt. Ils sont dits du second ordre parce qu'ils prennent en considération la dérivée seconde de la fonction de coût.

I.7.2.3. Algorithme de Levenberg-Marquardt

L'algorithme de Levenberg-Marquardt est très efficace pour l'entraînement des réseaux de petite et moyenne taille. Il est le plus rapide et assure la meilleure convergence vers un minimum de l'erreur quadratique pour les problèmes d'approximation de fonctions où le nombre de poids du réseau est inférieur à quelques centaines [11].

La méthode de Levenberg Marquardt utilise l'approximation de la matrice Hessienne (Dérivée seconde de la fonction de coût) suivante:

$$H = J^T J \quad (I.18)$$

Où $J = \partial E / \partial W$ est la matrice Jacobéenne.

A l'itération n, la modification des paramètres se fait selon l'équation suivante:

$$w(n+1) = w(n) - \left[J^T(w(n)) \cdot J(w(n)) + \lambda \cdot I \right]^{-1} J^T(w(n)) \cdot E(n) \quad (I.19)$$

I : Matrice identité.

λ : Pas.

E : Vecteur des erreurs du réseau.

La matrice jacobéenne contient les dérivées premières des erreurs du réseau par rapport à tous les poids et tous les biais. Elle peut être calculée en utilisant la technique de la rétro propagation de l'erreur [12]. Elle est définie (si on garde les même notations utilisées précédemment) par:

$$j(w(n)) = \begin{bmatrix} \frac{\partial E_1(1)}{\partial w_{1,0}^1} & \frac{\partial E_1(1)}{\partial w_{1,1}^1} & \dots & \frac{\partial E_1(1)}{\partial w_{N^1,p}^1} & \dots & \frac{\partial E_1(1)}{\partial w_{N^L,p}^L} \\ \frac{\partial E_2(1)}{\partial w_{1,0}^1} & \frac{\partial E_2(1)}{\partial w_{1,1}^1} & \dots & \frac{\partial E_2(1)}{\partial w_{N^L,p}^1} & \dots & \frac{\partial E_2(1)}{\partial w_{N^L,p}^L} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ \frac{\partial E_{N^L}(1)}{\partial w_{1,0}^1} & \frac{\partial E_{N^L}(1)}{\partial w_{1,1}^1} & \dots & \frac{\partial E_{N^L}(1)}{\partial w_{N^1,p}^1} & \dots & \frac{\partial E_{N^L}(1)}{\partial w_{N^L,p}^L} \\ \frac{\partial E_1(2)}{\partial w_{1,0}^1} & \frac{\partial E_1(2)}{\partial w_{1,1}^1} & \dots & \frac{\partial E_1(2)}{\partial w_{N^1,p}^1} & \vdots & \frac{\partial E_1(2)}{\partial w_{N^L,p}^L} \\ \dots & \dots & \vdots & \dots & \vdots & \vdots \\ \frac{\partial E_{N^L}(k)}{\partial w_{1,0}^1} & \frac{\partial E_{N^L}(k)}{\partial w_{1,1}^1} & \dots & \frac{\partial E_{N^L}(k)}{\partial w_{N^1,p}^1} & \dots & \frac{\partial E_{N^L}(k)}{\partial w_{N^L,p}^L} \end{bmatrix} \quad (I.20)$$

L'algorithme de Levenberg-Marquardt s'exécute en ces étapes :

- Étape 1 : initialisation de tous les poids de connexions à de petites valeurs aléatoires, et de λ (0,01 est convenable).
- Étape 2 : Présentation de tous les exemples d'entrées et sorties désirées correspondantes.
- Étape 3 : Calcul des sorties du réseau pour tous les exemples présentés selon l'équation (I.10), le vecteur des erreurs commises sur les sorties du réseau, pour chaque exemple $E(K)=u^L(K)-u^{d,L}(K)$, et la somme des erreurs quadratiques, E_1 et de la matrice jacobéenne (I.20) utilisant l'équation (A.14) (annexe A) et pour la couche de sortie en remplaçant (A.17) dans (A.14)(annexe A).
- Étape 4 : Calcul de ΔW selon l'équation (I.19) et recalculer la somme des erreurs quadratiques, E_2 pour le changement de poids effectuer $(W + \Delta W)$.
- Étape 5 : Si $E_2 < E_1$ alors λ est divisé par ν , conserver le changement de poids et aller à l'étape 7.
- Étape 6 : sinon on multiplie λ par ν et on retourne à l'étape 4.
- Étape 7 : Si $E_2 < \varepsilon$ (avec $\varepsilon > 0$ donné) alors arrêter l'apprentissage sinon retourner à l'étape 2.

Le paramètre λ est augmenté ou diminué à chaque étape, si l'erreur diminue, alors ce paramètre sera divisé par un facteur ν , et les nouveaux poids seront maintenus, il sera multiplié par ν dans le cas contraire et itère encore.

I.7.2.4. Initialisation du vecteur des paramètres poids synaptiques

Au début de l'apprentissage, les valeurs des poids synaptiques doivent être initialisées par de petites valeurs aléatoires différentes de zéro. D'autre part, l'utilisation de valeurs élevées peut provoquer un phénomène de saturation prématurée qui contribue à diminuer la vitesse de convergence de l'apprentissage [13]. Il faut aussi faire attention à ce que les poids initiaux soient différents d'un nœud à l'autre sinon les unités cachées feront toutes le même travail.

Cette étape d'initialisation est très importante car elle est susceptible de déterminer en partie le résultat obtenu en fin d'apprentissage, donc les performances du modèle ainsi conçu [14].

I.7.2.5. Amélioration de la généralisation

L'objectif recherché dans la modélisation par réseaux de neurone est l'obtention d'un modèle qui peut apprendre les données, et qui assure une bonne généralisation en évitant un problème de sur-apprentissage. Ce dernier, est causé par un sur-ajustement des paramètres (poids synaptiques).

Pour pallier à ce problème de sur-ajustement, on utilise la technique de l'arrêt précoce (early stopping en anglais). Cette méthode repose sur l'utilisation de trois jeux de données distincts: un jeu d'apprentissage, un jeu de validation, et un jeu de test.

Son principe consiste à mesurer les performances pendant l'apprentissage sur les deux bases, base d'apprentissage et de validation. Aux premières itérations, les fonctions de coût sur les bases de validation et d'apprentissage diminuent ensemble.

Lorsque le modèle commence à être sur-ajusté, la fonction de coût sur la base d'apprentissage continue à diminuer, alors que la fonction de coût sur la base de validation augmente. A une itération précédant le début du sur-apprentissage, l'apprentissage doit s'arrêter.

On vérifie la capacité de généralisation du réseau de neurones avec le dernier jeu de donnée, le jeu de test. La figure (1.8) illustre cette technique.

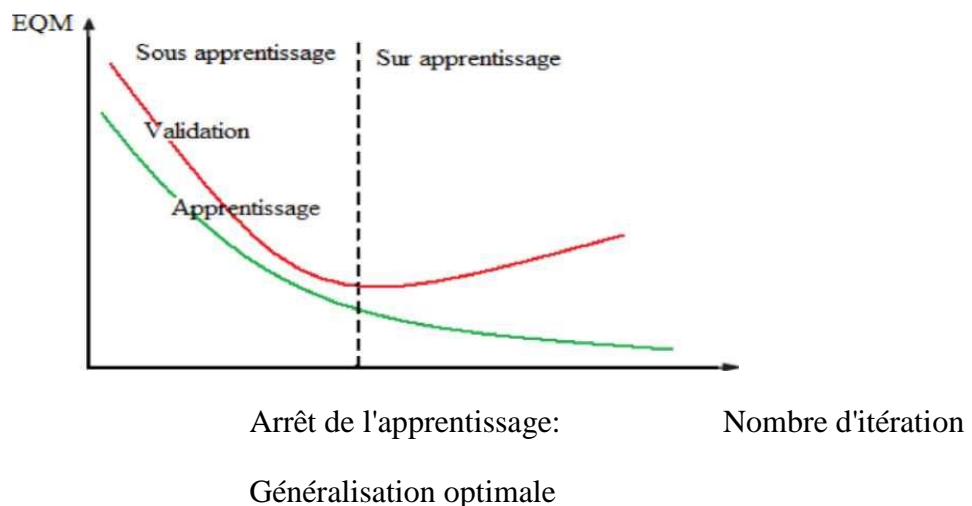


Figure (I.8) : Illustration de l'arrêt prématuré de l'apprentissage [28].

CHAPITRE II
GENERALITE SUR
LA CORROSION

CHAPITRE II - GENERALITE SUR LA CORROSION

II-1-Introduction

La corrosion, du latin ‘corrodere’, signifie ronger et attaquer. C'est une destruction non voulue des métaux sous l'action de milieux corrosifs (agents atmosphériques ou réactifs chimiques). Après attaque, les métaux ont tendance à retourner à leur état primitif d'oxyde, sulfure, carbonate etc., plus stable par rapport au milieu considéré, et ainsi à subir une détérioration de leurs propriétés [17].

Sa forme la plus connue est la rouille du fer exposé à l'air humide. Elle présente une grande importance, étant donné les conséquences qu'elle a dans des domaines très variés de l'activité humaine.

II-2-Historique

Les recherches sur la corrosion sont anciennes. Dès 1830, le physicien Auguste De La Rive en proposait une théorie électrochimique. Cependant, les recherches n'ont véritablement pris leur essor qu'au XX^e siècle. Leur but est double :

- déterminer le processus des phénomènes afin de leur trouver un remède,
- définir les matériaux susceptibles d'être utilisés dans des conditions données, pendant une durée qui est parfois de plusieurs décennies.

II-3-Impact économique de la corrosion

Du point de vue économique, la corrosion est d'une importance primordiale. On estime par exemple que chaque année le quart de la production d'acier est détruite par la corrosion, ce qui correspond environ à 150 millions de tonnes/an ou encore 5 tonnes/seconde. Ces pertes pouvaient être supérieures s'il n'y avait pas la protection contre la corrosion.

Le remplacement des équipements et matériel corrodés constitue pour l'industrie une charge financière très élevée à laquelle il faut ajouter le manque à gagner correspondant à l'arrêt des installations nécessaires pour effectuer les réparations.

Les coûts annuels imputables à la corrosion et à ses conséquences s'élèvent à plusieurs milliards de dollars par an dans la plupart des pays industrialisés. Aux Etats-Unis, les pertes occasionnées par celle-ci sont évaluées à plus de 7 milliards de dollars [17].

Les technologies avancées constituent également un bon exemple du rôle fondamental que joue la tenue des matériaux métalliques aux agents corrosifs. En effet, bien souvent, le

CHAPITRE II - GENERALITE SUR LA CORROSION

développement d'une technique est freiné par la difficulté de trouver un métal ou un alliage qui résiste aux conditions d'emploi, toujours plus difficiles.

II-4- Types et morphologie des dégradations par corrosion :


II-4-1-Types de dégradations par corrosion :

Le processus de corrosion consiste en une réaction hétérogène chimique ou électrochimique qui se produit à la surface de séparation matériau métallique-milieu ambiant. La corrosion est donc un mode de dégradation progressant à partir de la surface du matériau. Elle peut se développer suivant différents processus qui caractérisent chacun un type de corrosion :

II-4-1-1- Corrosion chimique (sèche) :

Il s'agit d'une réaction hétérogène entre une phase solide (le métal) et une phase gazeuse. Le processus d'oxydoréduction de la corrosion chimique se déroule dans le domaine atomique avec le milieu ambiant sans présence d'électrolyte.

L'attaque du métal par une réaction chimique avec le milieu ambiant sans intervention du courant électrique nécessite généralement des températures élevées, la réaction qui se produit est de la forme:



Il faut savoir que lorsqu'un métal est attaqué par un gaz à haute température (CO_2 , SO_2 , au-dessus de 400°C), il se forme des composés métalliques de surface de très faible épaisseur (10 à 10 000 Angströms), qui constituent une pellicule protectrice.

Si la couche ainsi formée est suffisamment épaisse, elle s'oppose à la continuation du processus de corrosion.

Dans le cas inverse, son pouvoir protecteur sera limité [17, 18].

II-4-1-2- Corrosion biochimique :

La corrosion biochimique, appelée encore corrosion bactérienne, rassemble tous les phénomènes de corrosion dans lesquels les bactéries agissent directement ou par l'intermédiaire de leur métabolisme en jouant un rôle primordial, soit en accélérant un processus déjà établi, soit en créant les conditions favorables à son établissement. Lorsque les colonies de microorganismes se fixent à la surface du matériau, elles créent ce que l'on


CHAPITRE II - GENERALITE SUR LA CORROSION

appelle alors un biofilm [19]. C'est l'attaque bactérienne des métaux en particulier dans les canalisations enterrées.


Le mécanisme de ce mode de corrosion peut être de plusieurs types :

a- Chimique par production de substances corrosives telles que CO_2 , H_2S , H_2SO_4 , NH_3 ou d'un acide organique. Le cas le plus répandu est celui rencontré dans les canalisations enterrées et caractérisé par la formation d'acide sulfurique qui attaque le métal.

b- Certaines bactéries peuvent réduire les sulfates par l'intermédiaire d'hydrogène.



L'hydrogène provient par exemple des régions cathodiques, il y a donc dépolarisation des cathodes et formation accélérée de Fe^{2+} aux anodes.



c- Dans certains cas, on peut observer sur les canalisations des dépôts adhérents résultant de l'attaque, non pas du métal lui-même, mais celle de certains constituants du milieu ambiant par des bactéries. Il en résulte la formation de piqûres sur le métal, à l'endroit où s'est produit le dépôt, suivant un processus de corrosion par différence de concentration en oxygène comme elle montre la figure (II.1), [17].




Figure (II.1) : Colonie de *Desulfovibrio vulgaris* sur acier inoxydable [19].

CHAPITRE II - GENERALITE SUR LA CORROSION

II-4-1-3- Corrosion avec érosion, avec frottement et par cavitation :

Dans ce cas les produits de corrosion forment un dépôt adhérent et continu à la surface du métal. Ils ralentissent en général la vitesse de la corrosion. Cette couche peut être éliminée en certains points par abrasion du métal due au mouvement du liquide lui-même ou bien à celui des particules solides qu'il contient, il y a accélération de la corrosion. Il en est de même lorsque deux pièces se déplacent l'une par rapport à l'autre (frottement).

La corrosion-érosion affecte de nombreux matériaux (aluminium, acier, etc.) et est particulièrement connue pour le cuivre en milieu marin. Ce phénomène correspond à une dégradation de la surface sous l'effet de l'impact de particules, de gouttelettes, d'un jet, ou sous l'action d'un écoulement turbulent au voisinage d'un défaut de surface figure(II.2), et conduit à un amincissement local qui revêt souvent l'aspect d'une piqûre allongée. La turbulence ainsi créée contribue à éroder le film protecteur jusqu'à le faire disparaître, créant ainsi une pile de corrosion.

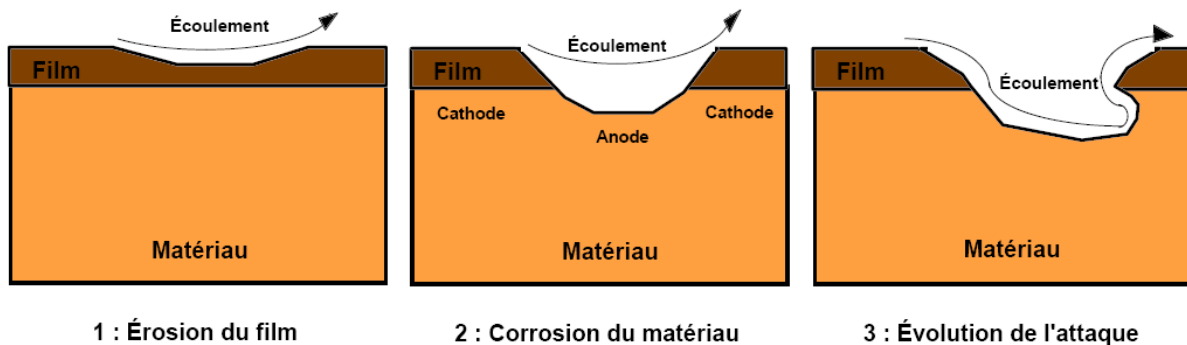


Figure (II.2) : Corrosion-érosion dans une zone turbulente [19].

La corrosion par cavitation est due à la présence de bulles de vapeurs qui se forment dans une canalisation figure(II.3), ou au voisinage d'une pièce tournante lorsque par suite de l'augmentation locale de la vitesse du liquide où la pression statique devient inférieure à la tension de vapeur du liquide, il en résulte un violent martèlement de la surface métallique et une destruction locale du film de corrosion protecteur, la corrosion peut donc se développer à nouveau.

CHAPITRE II - GENERALITE SUR LA CORROSION




Figure(II.3) : Corrosion-cavitation d'une aube de pompe [19].

Lorsque ces bulles atteignent une zone où la pression est plus forte, elles implosent en produisant une onde de choc. Cette dernière induit une fatigue locale du matériau conduisant à des ruptures répétées du film passif et à une attaque localisée. Ce phénomène affecte particulièrement les hélices de navires et les parties rotatives de pompes ou de turbines hydrauliques. Outre la dégradation prématurée du matériau, le phénomène de cavitation seul est à l'origine d'un signal sonore important qui peut s'avérer indésirable (localisation d'un sous marin par exemple). On y remédie le plus souvent en portant une attention particulière au profil des pales d'hélice afin de limiter au maximum les turbulences.

II-4-1-4- Corrosion électrochimique [20]

C'est le phénomène de corrosion le plus important. Elle se manifeste lorsque le réactif est un liquide ou lorsqu'il existe une hétérogénéité dans le métal ou dans le réactif, présentant une dissymétrie de composition. L'existence de ces hétérogénéités détermine la formation d'une pile. Un courant électrique circule alors entre anodes et cathodes, dont le réactif et les zones qui constituent les anodes sont attaquées (corrodées). Pour une corrosion électrochimique, on a :



En général il n'existe pas un métal idéalement pur, il contient toujours des hétérogénéités physiques ou chimiques dont le potentiel de corrosion est en général différent de celui de la matrice. C'est à dire les métaux ne sont pas monophasés lorsqu'ils sont plongés dans le réactif. Même pour un alliage, si ces éléments d'addition sont en solution solide, on ne peut pas les considérer comme parfaitement monophasés, car ils présentent toujours des inclusions, oxydes, sulfures, etc. ou bien des régions écrouis. Donc les légères différences de propriétés chimiques ou physiques entre les différentes parties du métal déterminent une électrode composite (cellule électrochimique) qui contient des microcathodes et des microanodes en court-circuit, c'est à dire formant des couples électriques (piles).

CHAPITRE II - GENERALITE SUR LA CORROSION

Lorsqu'une électrode composite est plongée dans un électrolyte, ce qui est toujours réalisé, elle est le siège d'un phénomène de corrosion électrochimique. Les anodes sont attaquées avec une vitesse qui dépend de l'intensité du courant débité par les piles locales.

II-4-2- Morphologie des dégradations par corrosion :

Un métal plongé dans une solution aqueuse peut se trouver dans l'un des états suivants :

II-4-2-1- Etat d'immunité :

Le métal ne se corrode pas, il est thermodynamiquement stable vis-à-vis de la plupart des solutions aqueuses, excepté certaines solutions complexâtes. Les métaux nobles que l'on trouve à l'état natif tels que l'or, le platine, le rhodium, etc., doivent leur résistance à la corrosion à cet état d'immunité que l'on peut toutefois obtenir pour l'ensemble des métaux dans des conditions opératoires particulières.

II-4-2-2- Etat de passivité :

Bien que l'origine de la passivité soit encore très discutée, il est généralement admis que l'absence de corrosion liée à cet état est due à la formation d'une mince couche d'oxyde jouant le rôle d'écran entre le métal et le milieu extérieur.

II-4-2-3- Etat d'activité :

Le métal est attaqué par le milieu environnant et se corrode. La corrosion en milieu aqueux se manifeste de différentes façons identifiables soit par un examen visuel, soit par un examen microscopique des zones endommagées.

Huit formes de corrosion peuvent être dénombrées, caractérisées par des faciès distincts ou des modifications de propriétés physiques du métal.

II-4-2-4- Diagramme de Pourbaix :

Le métal a un potentiel qui dépend fortement de son environnement. Certains potentiels d'électrode sont influencés par le pH du milieu environnant figure (II.4). Celui de la solution électrolytique à une forte influence sur le potentiel du métal. Si l'on fait varier le pH de la solution interstitielle, le potentiel du système métal / électrolyte va varier et modifier l'état de l'électrode. On trace ainsi le diagramme de Pourbaix [22].

CHAPITRE II - GENERALITE SUR LA CORROSION

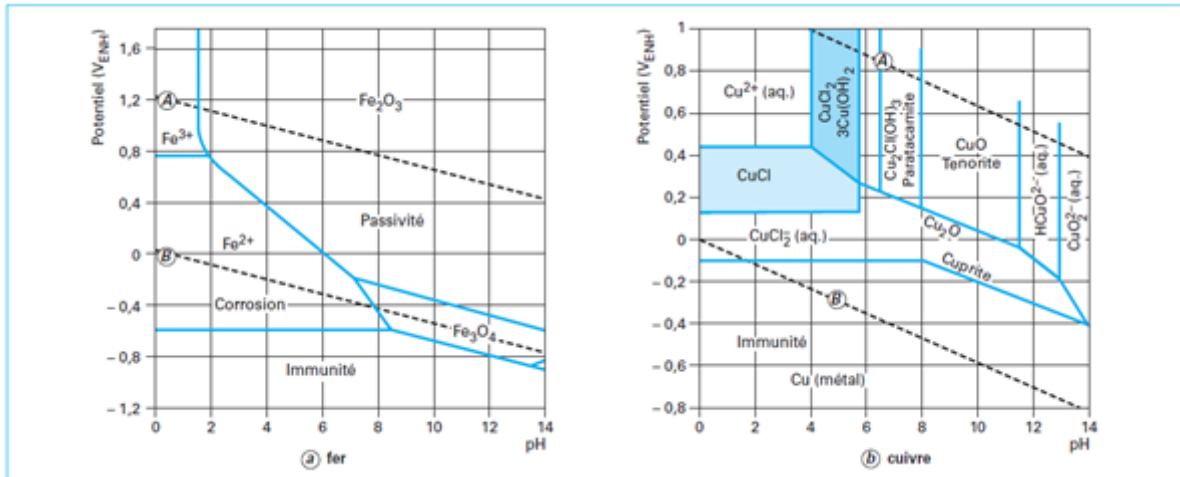


Figure (II.4) : Diagrammes de potentiel – pH (a) du fer et (b) du cuivre en milieu chloruré [23]

De nombreuses réactions d'électrode dont celles conduisant à la formation d'oxydes en milieu aqueux font intervenir les ions H⁺. Le potentiel E dépend donc du pH de la solution. Les diagrammes de Pourbaix (potentiel-pH) permettent de prévoir les réactions de corrosion métallique. Le diagramme potentiel-pH permet de déterminer, pour un potentiel et le pH du milieu donnés, l'espèce stable; la lecture de ce diagramme permet alors d'évaluer le risque éventuel de corrosion d'un métal pur (sous réserve d'avoir considéré toutes les espèces chimiques susceptibles de se former). Cependant, aucune information cinétique n'étant contenue dans le diagramme, la vitesse de corrosion ne peut pas être estimée. A ce titre, dans la passivité, le film passif se dissout et la corrosion peut avoir lieu, mais il est impossible de connaître sa vitesse. Même dans le domaine où la corrosion est possible, si sa vitesse est suffisamment lente, le risque de dégradation du matériau métallique peut être négligeable. L'approche cinétique est alors nécessaire pour évaluer le risque réel [23].

II-5 - Principales formes de corrosion :

II-5-1 - Corrosion uniforme

La réaction représentée sur la figure (II.5) est relativement uniforme sur toute la surface du fer. On ne distingue pas, à l'échelle macroscopique, les lieux cathodiques des lieux anodiques. La surface entière du métal est simultanément cathode et anode. On appelle ce type de réaction corrosion uniforme.

CHAPITRE II - GENERALITE SUR LA CORROSION




Figure (II.5) : Corrosion du fer en milieu acide

II-5-2. Corrosion localisée :

On appelle corrosion localisée une corrosion qui se déroule en un milieu spécifiquement anodique d'une surface ou d'une structure métallique. Elle diffère de la corrosion uniforme, car on distingue clairement les endroits anodiques et cathodiques, figure (II.6). En pratique, la corrosion localisée provient d'une hétérogénéité du matériau ou de l'environnement. Elle pose souvent plus de problèmes à l'ingénieur que la corrosion uniforme figure(II.7).


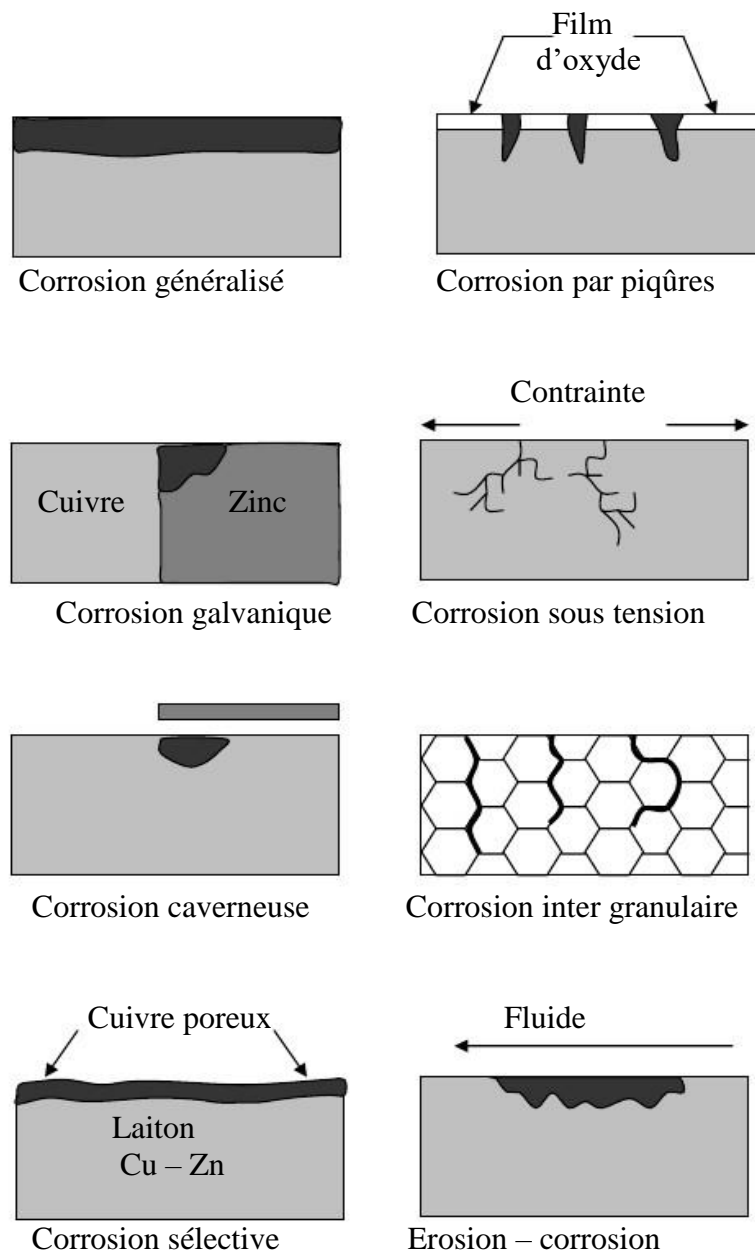


Figure II.6 : Corrosion uniforme et localisée



Figure(II.7): Différentes formes de corrosion

• **Corrosion par piqûre :**

Dans certaines conditions d'environnement, les métaux et alliages protégés par un film passif peuvent subir une attaque par piqûre, lorsqu'il se produit une rupture localisée du film. Ces piqûres se localisent en certains points de la surface métallique, elles se développent de façon insidieuse et s'auto-propagent au fond de la cavité créée. L'hydrolyse des ions métalliques dissous entraîne une augmentation du degré d'acidité, ce qui entretient le phénomène de corrosion.

CHAPITRE II - GENERALITE SUR LA CORROSION

- **Corrosion inter granulaire :**

C'est une attaque sélective aux joints de grains, par suite d'hétérogénéités locales : appauvrissement de l'un des constituants ou au contraire, enrichissement par suite de précipitation lors d'un traitement thermique par exemple, il y a alors création de piles locales avec dissolution des zones anodiques.

- **Corrosion par crevasse :**

Appelée aussi corrosion caverneuse, elle est due à une différence d'accessibilité de l'oxygène entre deux zones d'une structure métallique. Il y a alors une attaque des parties métalliques les moins accessibles à l'oxygène.

- **Corrosion galvanique :**

Il s'agit de l'attaque préférentielle de la phase la moins noble d'un alliage comportant deux phases ou de la corrosion pouvant exister entre au moins deux matériaux métalliques placés dans le même environnement. Il y a formation d'une pile. En cas de couplage, plus les métaux en présence sont éloignés sur l'échelle galvanique, plus la pile formée dispose d'énergie pour provoquer les transformations. Les phénomènes de corrosion sont amplifiés à la fois dans la cinétique de dégradation et dans la génération d'ions dans le milieu biologique. La partie la moins noble est l'anode et la plus noble est la cathode. Le rapport de surface anode/cathode joue un rôle très important. Il faut retenir que, plus l'anode est de petite taille, plus la vitesse de dissolution est élevée. Ce fait a une grande importance dans la pratique clinique en odontologie, en particulier lors du choix des alliages utilisés pour les réalisations prothétiques.

- **Corrosion et dissolution sélective :**

C'est l'oxydation d'un composant de l'alliage qui conduit à la formation d'une structure métallique poreuse.

- **Corrosion par frottement :**

C'est la détérioration qui se produit à l'interface entre deux surfaces en contact, suite à la conjugaison de la corrosion et d'un faible glissement réciproque des deux surfaces.

CHAPITRE II - GENERALITE SUR LA CORROSION

● Corrosion sous contrainte et fatigue-corrosion :

C'est une fissuration du métal qui résulte de l'action commune d'une contrainte mécanique (force de traction) et d'une réaction électrochimique. La corrosion sous l'effet de la fatigue est due à l'application répétée des contraintes.

II-6- Facteurs de la corrosion

Les phénomènes de corrosion dépendent de plusieurs facteurs qui peuvent être classés en quatre groupes principaux tels que [23]:

Facteurs définissant les modes d'attaques	Facteurs métallurgiques	Facteurs définissant les conditions d'emploi	Facteurs dépendant du temps
-Concentration du réactif -Teneur en oxygène -pH du milieu -Addition d'inhibiteurs -Température -Pression	-Composition de l'alliage -Procédé d'élaboration -Impuretés -Traitements thermiques - Traitement mécaniques - Addition de protecteurs	- Etat de surface - Forme des pièces - Sollicitations mécaniques - Emploi d'inhibiteurs - Procédés d'assemblage	- Vieillessement - Tension mécaniques - Température - Modification des revêtements protecteurs

II-7- Etude de la corrosion

Constitue une branche de la chimie puisqu'elle correspond à des réactions qui font intervenir un métal et un réactif. Mais, pour résoudre les problèmes qu'elle pose, on ne peut pas se contenter d'appliquer les lois classiques de la chimie. En effet, de nombreux facteurs spécifiques, se rapportant au métal ou au réactif, peuvent avoir une grande influence sur la genèse et le développement des phénomènes de corrosion, si bien qu'il est indispensable pour les étudier de faire également appel aux lois de la métallurgie et de l'électrochimie.

La corrosion ne se limite pas à l'acier, mais affecte tous les métaux ainsi que les polymères et céramiques et elle touche aussi tous les domaines de l'économie du circuit intégré, aux ponts en béton armé. L'évaluation des pertes dues à la corrosion doit prendre en considération :

- Les pertes directes : remplacement des matériaux et équipements corrodés.

CHAPITRE II - GENERALITE SUR LA CORROSION

- Les pertes indirectes : réparation, pertes de production.
- Les mesures de protection : utilisation de matériaux plus résistants à la corrosion et plus chers, de revêtement et de protection cathodique
- Les mesures de préventions : surdimensionnement des structures porteuses, inspection et entretien. Les pertes directes ne représentent donc qu'une partie des coûts de la corrosion. Elles sont souvent inférieures aux pertes indirectes.

Par exemple, si l'on doit arrêter une machine ou un équipement dont l'un des éléments constituant est corrodé, le prix de ce dernier est dérisoire par rapport aux pertes de gain dues au manque de production [17].

Anode = électrode où se produit la réaction d'oxydation (dissolution du métal), où le courant passe du métal vers la solution.

Cathode = électrode où se produit la réaction de réduction (déposition à la surface du métal), où le courant passe de la solution vers le métal.

II-8- Mesure de la corrosion

L'intensité de l'activité de corrosion peut être mesurée par des méthodes non destructives. Les méthodes les plus courantes sont la densité de courant macro pile, le potentiel de corrosion et la polarisation linéaire. Les particularités de chaque mesure sont présentées aux sous-sections suivantes [21].

Le principe général est de mesurer l'activité électrique que produit la réaction chimique de corrosion. Les réactions se traduisent par une transformation chimique qui implique un transfert de charge à l'interface entre un alliage métallique jouant le rôle d'un conducteur électronique appelé « électrode » et un milieu agressif représentant ainsi un conducteur ionique appelé « électrolyte ».

La loi de Faraday est la forme électrochimique de la loi de Lavoisier. Elle exprime donc la proportionnalité qui existe entre le nombre ne de charges élémentaires (charge de l'électron $e = 1,602 \times 10^{-19}$ C) transférées d'un milieu à l'autre et le nombre n d'entités microscopiques (ions, atomes, molécules) ayant subi une transformation chimique dans le même temps. En termes de vitesse, cette relation s'écrit donc :


CHAPITRE II - GENERALITE SUR LA CORROSION

$$\frac{dn_e}{dt} = z \frac{dn}{dt} \quad (1)$$

- n_e est le nombre de charges élémentaires
- z est le nombre de charges électroniques échangées dans chaque transfert élémentaire.

En milieu aqueux, la nature électrochimique de la corrosion d'un métal M de valence n est le siège des deux réactions simultanées. En effet, le courant anodique, dû à la dissolution du métal, produit des électrons qui sont compensés par le processus cathodique.

Une réaction anodique d'oxydation qui correspond à la dissolution du métal M, en produisant outre que des ions métalliques, des électrons, elle s'écrit :



Poursuivie par une réaction cathodique de réduction d'un oxydant dissout dans la solution est consommant les e^- libérés par la réaction (A), elle est établie d'une manière générale comme suit :



Alors,

$$J = j_a + j_c \quad (2)$$

Où j_a et j_c représentent respectivement les densités de courant anodique et cathodique.

L'étude à l'échelle du laboratoire nécessite une cellule électrochimique constituée d'une électrode de travail, une électrode de référence et la contre électrode qui est appelée aussi électrode auxiliaire.

II-9- Cellule électrochimique :

La figure (II.8) montre le principe de fonctionnement d'une cellule électrochimique.

CHAPITRE II - GENERALITE SUR LA CORROSION

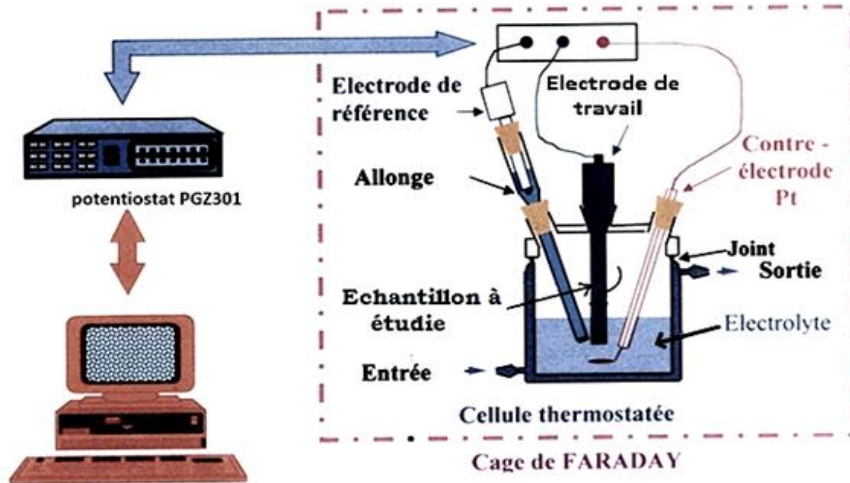


Figure (II.8): Schéma du montage d'une expérience en électrochimie [21].

Classiquement trois électrodes sont utilisées :

- **L'électrode de travail :**

Il s'agit de l'échantillon à étudier, entouré d'un cylindre en poly tétra fluor éthylène. L'ensemble échantillon-cylindre constitue l'embout de l'électrode à disque tournant afin de travailler sous un régime d'agitation dynamique reproductible assurant l'homogénéisation de la solution.

- **L'électrode de référence :**

Les tensions sont mesurées par rapport à une électrode de référence. Celle la plus souvent utilisée en laboratoire est saturée en chlorure de potassium (ECS). Elle est immergée dans une allonge qui communique avec l'électrolyte de la cellule par l'intermédiaire d'un fritté.

- **L'électrode auxiliaire :**

Un fil de platine est utilisé comme contre-électrode dans les études où des perturbations en tension ou en courant sont imposées au système. Le montage fait intervenir un potentiostat qui permet d'imposer un potentiel à l'électrode de travail, géré par des microprocesseurs. Des logiciels spécifiques assurent le pilotage des séquences expérimentales, l'acquisition et le traitement des données numériques.

II.10 paramètres mesurés par les cellules électrochimiques

CHAPITRE II - GENERALITE SUR LA CORROSION

II-10-1 Densité de courant macro pile

Comme son nom l'indique, la densité de courant macro pile est définie comme étant le courant électrique exprimé en fonction de la surface étudiée lors d'une réaction caractérisée par des régions anode/cathode séparables. Par exemple, une macro pile peut se former entre deux pièces métalliques qui baignent sans se toucher dans une solution conductrice. C'est donc la solution conductrice qui assure le contact électrique entre les deux électrodes. Le courant ne peut pas être mesuré directement à cause de sa trop faible intensité. Ainsi, le principe est de mesurer un potentiel électrique entre une anode et une cathode où la résistance entre les deux est connue. Par la suite, le courant est calculé à l'aide de la loi d'Ohm :

Courant = potentiel / résistance. Habituellement, le courant est exprimé en densité de courant ($i = I/S$), c'est-à-dire qu'il tient compte de la surface d'exposition de l'élément qui corrode (anode). La densité de corrosion est alors exprimée en $\mu\text{A}/\text{cm}^2$. [21]

II-10-2 Potentiel de corrosion

Le potentiel de corrosion peut être mesuré directement entre la barre à l'étude (anode) et une électrode de référence (cathode). Ainsi, il faut se procurer une électrode de référence ayant un potentiel d'équilibre stable. Les électrodes de référence les plus connues dans ce domaine sont : L'électrode au calomel saturé et celle de cuivre. Les électrodes de référence servent à déterminer avec précision le potentiel d'équilibre de l'anode en comparant le potentiel de l'anode avec celui de la cathode. Le potentiel de corrosion s'exprime généralement en mV et est négatif.

II-10-3- Potentiel d'une électrode (potentiel d'équilibre)

Le potentiel d'équilibre, appelé aussi potentiel réversible, est le potentiel que prend un métal par rapport à la solution et l'un de ses sels. Il représente la différence de potentiel électrique entre le métal et la solution à l'équilibre. Le potentiel d'électrode ne peut se mesurer dans l'absolu, car on ne mesure qu'une différence de potentiel entre deux électrodes formant une pile galvanique.

II-10-4 - Polarisation linéaire

CHAPITRE II - GENERALITE SUR LA CORROSION

La polarisation est la variation de la différence de potentiel initial (à l'équilibre) des électrodes d'une cellule galvanique (ou électrochimique). Une pile est un exemple de cellule galvanique.

La technique de polarisation consiste à imposer un potentiel ou un courant à une électrode et de mesurer le courant ou le potentiel correspondant. Selon que l'on fait un balayage du potentiel ou du courant, la technique prend le nom de polarisation potentiodynamique ou galvanodynamique respectivement. En pratique, trois électrodes sont nécessaires pour effectuer cette mesure : une électrode de travail, une électrode de référence et une contre-électrode, comme on l'a mentionné ci-dessus.

Le principe est le suivant : la contre-électrode conduit le courant vers l'électrode de travail pour la polariser. Le potentiel de l'électrode de travail est mesuré ou fixé (dans le cas du tracé des courbes potentiodynamiques) par rapport à l'électrode de référence dont le potentiel est toujours fixe.

La figure (II.9) montre une courbe obtenue lors d'un essai de potentiodynamique à l'échelle réelle, la figure (II.10) le tracé de cette courbe tracée dans le plan de Tafel (dans une échelle semi-logarithmique)

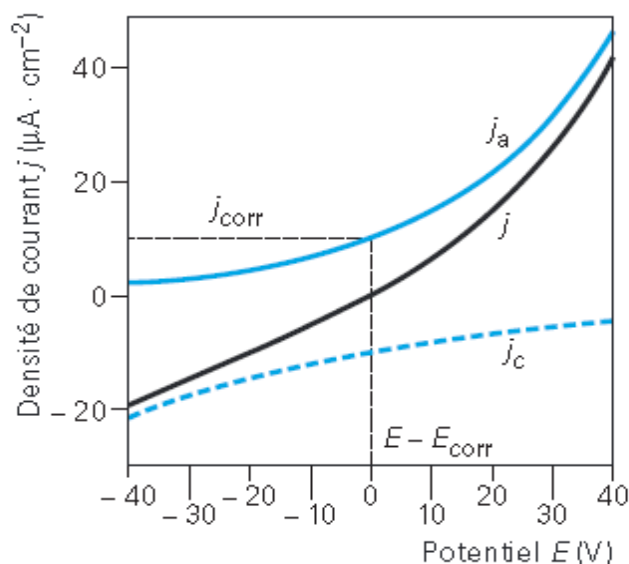


Figure (II.9) : Courbe de polarisation au voisinage de E_{corr} [$j = f(E)$] [21]

CHAPITRE II - GENERALITE SUR LA CORROSION

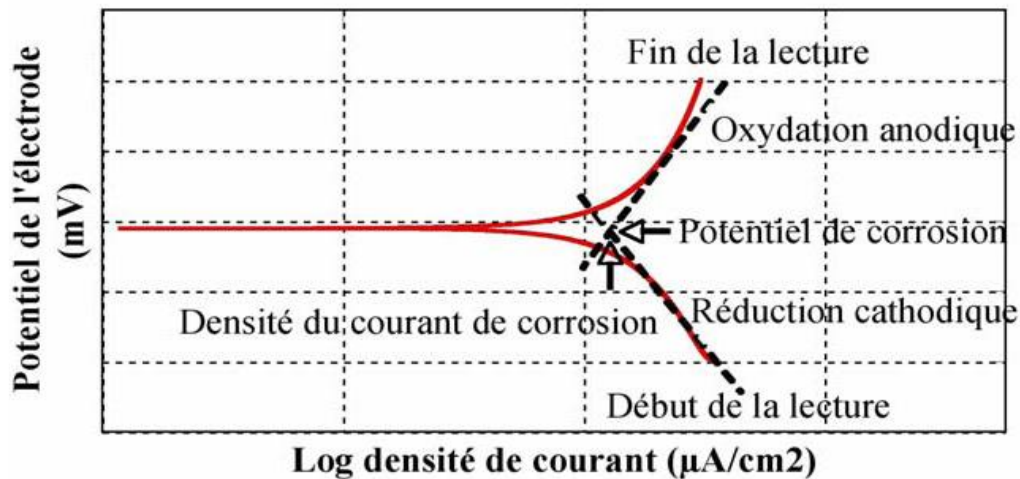


Figure (II.10) : Exemple de courbe typique de polarisation linéaire $\log(j)=f(E)$ [21].

ou :

- J_{corr} représente la densité de courant de corrosion. Dans le plan de Tafel, $[\log(j) - E]$,

- les composantes j_a et j_c décrivent chacune une droite, et leur- intersection donne directement la densité de courant J_{corr} et le potentiel de corrosion E_{corr}

II-11- Taux de corrosion

Le taux de corrosion ou la vitesse à laquelle la corrosion s'effectue peut avoir une influence sur la formation des produits de corrosion. Elle traduit d'une manière quantitative le comportement du métal et l'estimation de la durée de vie engendrée par ce phénomène. Il est donc important de connaître quelle est l'intensité de la corrosion observée sur le matériau. L'intensité de la réaction de corrosion dépend de la densité de courant ($\mu\text{A}/\text{cm}^2$) établie entre deux électrodes tel que la loi de Faraday le présente. Elle est donnée par :

$$m = \frac{A \cdot I \cdot t}{n \cdot 96500} \quad (7)$$

Où ;

m= masse corrodée

A= masse atomique

I= intensité électrique

n= valence

CHAPITRE II - GENERALITE SUR LA CORROSION

t= temps

CHAPITRE III

MÉTHODOLOGIE

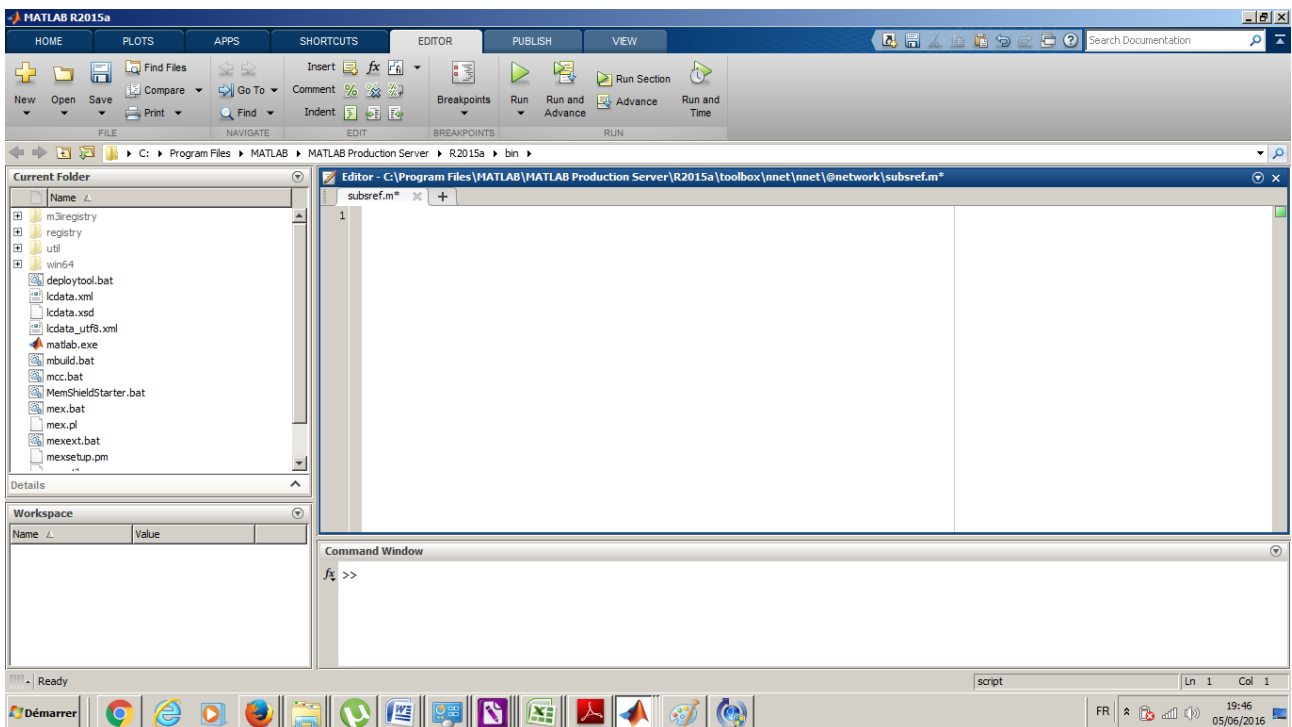
III.1. Problématique et objectif

L'une des plus grandes applications des réseaux de neurones se situe dans le domaine de laprédiction. Les caractéristiques desréseaux de neurones qui sont la parcimonie, la généralisation, l'approximation(Annexe B), la simplicité d'implantation, et le temps de calcul relativement faible, les rendent un outil très commode pour les tâches de prédiction, parrapport aux outils conventionnels de calculs.[28]

L'objectif de notre travail consiste à développer un modèle neural pour prédire des résultats expérimentaux tels que le taux et le potentiel de corrosion.

Pour cela, nous allons présenter, dans ce chapitre la procédure de construction du réseau de neurones prédictif du taux et du potentiel de corrosion, et son application.

Parmi les logiciels de calculs existants, et dans lesquels il a été implanté le réseau de neurone, notre intérêt a été porté sur MatlabR2015a, Figure(III.1). Grâce à sa forte instruction en relations mathématiques, et surtout la possibilité d'accès au script du programme des réseaux de neurones, il permet de bien contrôler le déroulement du programme et aussi d'extraire les poids et les biais trouvés pour l'architecture qu'on juge meilleure, ceci selon l'état de satisfaction des conditions d'une performance acceptable. D'autre part, l'utilisateur peut choisir n'importe quel langage de programmation qu'il voit plus pratiques selon ses connaissances en informatique.



Figure(III.1) : Interface Matlab R2015a

III.2. Procédure de construction d'un réseau de neurones

La procédure de conception d'un réseau de neurone peut être résumée en six étapes :

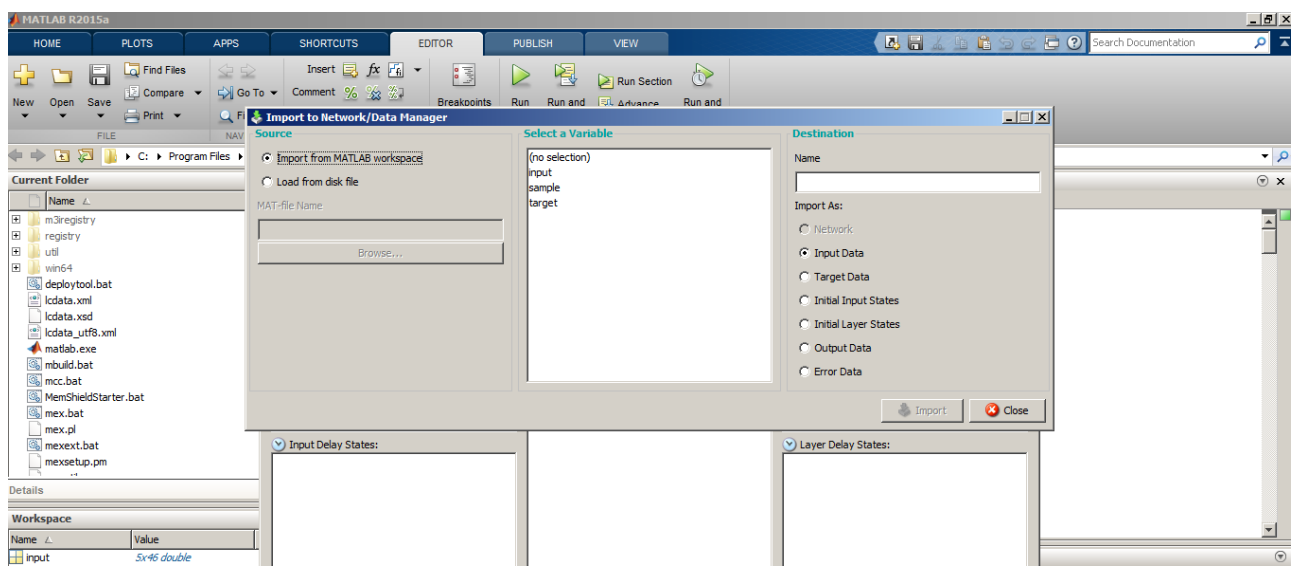
1. La collecte d'une base de données.
2. La séparation de la base de données en trois sous ensembles (base d'apprentissage, base de validation, et base de test).
3. Le choix de l'architecture du réseau de neurones (nombre de couches cachées, nombre de neurones dans ces couches, etc.).
4. Prétraitement des données.
5. Entraînement du réseau de neurones sur les bases d'apprentissage et de validation.
6. Mesure des performances du réseau de neurone sur la base de données.

III.2.1. Collecte d'une base de données

L'objectif de cette étape est de rassembler un nombre de données suffisant pour construire une base représentative de données, qui servira à l'apprentissage du réseau de neurones.

Cette base de données constitue l'entrée du réseau de neurones, Figure(III.2), et par conséquent va déterminer à la fois la taille du réseau (et donc le temps de simulation), et les performances du système (capacité de généralisation).

Nous allons donner comme exemple deux bases de données utilisées dans notre travail, pour valider notre application. Il s'agit de deux bases de données extraites des travaux de [Y.F.Wen et al] [24] et [Óscar Martín et al] [25], pour prédire respectivement le taux et le potentiel de corrosion. Le détail sera élucidé dans le quatrième chapitre.



Figure(III.2) Importation de la base de données entrée-sortie

CHAPITRE III MÉTHODOLOGIE

III.2.1. a -Collecte de base de données pour Prédire le taux de corrosion :

Il s'agit de prédire le taux de corrosion d'un acier 3C, plongé dans l'eau de mer. Ce type d'acier est utilisé dans la réalisation des ouvrages telle que la construction des structures en contact avec un environnement agressif, comme la production du pétrole, les raffineries, les pipelines...etc.

Il possède beaucoup de performance, on citera bien ces caractéristiques physiques, mécaniques, une soudabilité performante, etc.

- La base de données a été extraite de 46 expériences[24], Tableau(III.1). De chaque expérience nous avons relevé 5 facteurs, cités ci-dessous, ce qui fait $46*5$ soit 230 paramètres. Pour cible d'apprentissage, il a été utilisé le taux de corrosion correspondant à chaque expérience.

- $T_{(C^{\circ})}$ température de l'environnement;

- $DO_{(mg/l)}$ oxygène dissous dans l'eau de mer;

- $Sal_{(ppt)}$ la salinité de l'eau de mer;

-PH : du milieu (l'eau de mer);

- $ORP_{(mv)}$ potentiel d'oxydoréduction ou potentiel de corrosion:

- Rate ($\mu A/cm$) le taux de corrosion ;

CHAPITRE III MÉTHODOLOGIE

Numéro	T(°C)	DO (mg/l)	Sal (ppt)	Ph	ORP(mV)	Taux ($\mu\text{A cm}^{-2}$)
1	25,9	6,71	30,1	5,1	378	16,4
2	29,35	6,09	29	6,3	400	16,9
3	27,9	6,18	31,5	7	363	15,75
4	24	7,95	30,2	8,1	324	13,65
5	28	5,05	31,4	9,2	240	13,24
6	27,32	3,21	29,31	8,2	281	12,91
7	27,87	6,55	31,68	7,2	356	14,06
8	28,27	6,98	28,2	6,6	384	15,47
9	30,7	7,15	31,74	6,5	401	16,28
10	29,37	6,82	30,12	6,2	414	17,11
11	24,27	0,8	32,56	8,1	171	3,61
12	27,45	2,6	35,37	7,96	287	7,94
13	27,23	4,2	31,94	7,89	289	9,63
14	27,48	5,9	32,39	7,83	331	10,578
15	28,75	6,8	32,22	8	340	11,43
16	28,52	8,4	32,1	8,01	345	12,52
17	28,45	9,9	31,95	7,93	309	22,64
18	23,95	7,61	9,17	8,04	231	10,94
19	24,73	6,06	17,33	7,08	321	11,446
20	24,6	7,52	24,42	7,57	210	11,83
21	24,51	7,02	32	8,16	308	12,553
22	23,65	6,51	41,34	7,67	245	8,402
23	16,74	7,11	33,55	8,25	178	10,85
24	21,11	6,03	33,44	8,03	295	11,448
25	25,57	6,7	32,19	8,09	325	11,872
26	31,16	4,38	33,21	7,94	242	8,924
27	25,62	34,89	5,32	7,9	385	15,966
28	24,95	16,29	6,8	7,82	341	12,12
29	24,5	18,37	5,31	7,93	302	12,07
30	25,59	21	7,04	7,95	244	11,4
31	26,11	34,84	2,82	7,8	335,2	11,288
32	24,96	40	6,32	8,08	254	9,3
33	9,5	32,31	4,26	8,2	195	10,56
34	12,05	32,04	4,95	8,17	232	11,04
35	14,86	32,51	6,3	7,95	198	11,06
36	28,13	34,34	5,14	7,8	362,9	13,93
37	24,17	16,09	7,68	8,04	283,8	11,55
38	23,54	15,04	8,27	8,06	243,8	11,72
39	25,31	15,22	7,59	9,32	246,7	11,39
40	12,55	37,9	6,42	7,49	235,3	10,52
41	16,81	39,49	6,61	7,73	258,7	10,24
42	24,09	36,72	5,59	7,83	281,8	9,93
43	26,34	35,97	3,25	7,98	367,1	14,37
44	25,35	16,94	4,05	8	341,2	15,07
45	26,07	35,34	4,07	7,94	404	18,13
46	26,52	34,48	4,94	7,9	326,1	11,828

Tableau (III.1) : Base de données relative la prédiction de taux de corrosion [24]

CHAPITRE III MÉTHODOLOGIE

III.2.1. b-Collecte de base de données pour Prédire le potentiel de corrosion

Dans ce cas, Il s'agit de prédire le potentiel de corrosion d'un joint de soudure sur un acier austénitique AISI 304. En effet ce matériau possède un très bon comportement vis-à-vis la corrosion, ainsi que d'autres caractéristiques mécaniques et physiques [25]. En revanche, il a été rapporté dans la littérature que la cause principale pour sa dégradation par corrosion sont les joints de soudures qui sont affectés par plusieurs paramètres liés aux procédés du soudage dont :

- $WT_{(\text{cycles})}$ temps de soudure;
- $WC^2_{(\text{kA}^2)}$ le courant de soudure
- $EF_{(N)}$ la force d'électrode

Pour cela l'auteur [25] a utilisé une base de données extraite de 36 expériences, Tableau(III.2). De chaque expérience nous avons relevés 3 facteurs, cités ci-dessus, ce qui fait 36×3 soit 108 paramètres. Pour cible, il a été utilisé le potentiel de corrosion correspondant à chaque expérience.

CHAPITRE III MÉTHODOLOGIE

N°	Input of the ANN			Expérimental output Epitt (VSCE)
	WT (cycles)	WC ² (kA ²)	EF(N)	
1	7	37.9456	1500	0.45972
2	10	30.3601	1500	0.43381
3	5	31,8096	1500	0,44848
4	12	26,1121	1500	0,46085
5	8	24,8004	1500	0,44788
6	4	24,8004	1500	0,44093
7	9	21,0681	1500	0,43408
8	3	21,0681	1500	0,44233
9	10	15,4449	1500	0,44741
10	7	16,4836	1500	0,44269
11	10	12,5316	1500	0,45366
12	3	12,5316	1500	0,43094
13	9	8,2944	1500	0,48562
14	11	41,2164	1500	0,43477
15	12	6,2001	1500	0,48185
16	3	6,2001	1500	0,47015
17	5	3,8416	1500	0,46381
18	12	43,0336	1000	0,46062
19	7	41,2164	1000	0,44101
20	3	41,2164	1000	0,43612
21	8	34,81	1000	0,44579
22	3	31,8096	1000	0,43672
23	9	24,8004	1000	0,40456
24	5	26,1121	1000	0,404025
25	9	21,0681	1000	0,40207
26	5	16,4836	1000	0,42468
27	8	11,6281	1000	0,42403
28	2	12,5316	1000	0,41012
29	5	9,0601	1000	0,4828
30	8	3,8416	1000	0,46475
31	3	3,84516	1000	0,45244
32	6	6,2001	1000	0,47675
33	11	2,4649	1000	0,42257
34	7	2,4649	1000	0,42895
35	11	2,89	1500	0,43833
36	7	2,0736	1500	0,42685

Tableau(III.2) :Base de données relative à la prédiction du potentiel de corrosion [25].

III.2.2. Séparation des bases de données

Après avoir construit la base de données, il est nécessaire de procéder à la phase de séparation en trois ensembles. On construit un ensemble pour effectuer l'apprentissage, un autre pour la validation, qui permet de contrôler la phase d'apprentissage, et ensuite un troisième pour tester le réseau obtenu et déterminer ses performances.

Il n'y a pas de règle pour déterminer ce partage d'une manière quantitative. Toutefois, les bases de test et de validation représentent 10 à 25% (tenant compte du nombre de données dont on dispose) de la base de données totale et doivent être représentatives et distinctes.

Dans notre application, la base d'apprentissage représente 70% de la base de données, tandis que pour la base de test représente 15%, et pour la base de validation 15% de la base de données.

III.2.3. Choix de l'architecture du réseau

La définition de l'architecture du réseau est primordiale pour obtenir un système performant. Cela consiste à faire un compromis entre la complexité du réseau en réduisant le nombre d'unités cachées, ainsi que le nombre de neurones pour chaque couche, et sa performance.

Comme nous l'avons vu auparavant, il existe plusieurs types de RNA. Dans notre étude nous avons adopté le Perceptron Multicouches (PMC). En effet, ces dernières années plusieurs techniques à base de PMC ont prouvé leurs efficacités en termes d'erreurs de corrélations [25].

En outre, comme nous l'avons mentionné précédemment, la structure du réseau dépend étroitement de la base de données, constituée de couples entrées /sortie(s), choisis. Le nombre de nœuds d'entrées et de nœuds de sorties sont généralement imposés par la fonction à approximer. Le premier est déterminé par le nombre de variables utilisées en entrée.

Pour la couche de sortie, le nombre de neurones est déterminé par le nombre de sorties à approximer, c.à.d. de variables qu'on veut prédire. Dans notre cas, on va prédire soit le taux de corrosion, soit le potentiel de corrosion. On utilisera donc un seul neurone dans la couche de sortie pour chacun des deux cas.

Le choix n'est pas si facile pour le nombre de couches cachées ni pour le nombre de neurones de chaque couche. Ces choix sont des facteurs fondamentaux pour la réussite d'une application.

En effet, avec un nombre limité de neurones (trop petit), le réseau ne sera pas performant sur l'apprentissage, et avec un nombre de neurones trop grand, le réseau risque de posséder de mauvaises propriétés de généralisation (phénomène de sur-apprentissage).

CHAPITRE III MÉTHODOLOGIE

Dans la bibliographie, on a pu trouver certaines relation empiriques, qui lient le nombre de neurones de la couche cachée au nombre de nœuds d'entrées, ou au nombre de neurones de sorties, et le nombre d'exemples dans la base d'apprentissage, mais la meilleure méthode de choisir notre modèle neural est de construire plusieurs modèles, et de choisir le modèle le mieux convenable pour l'application [26,27].

Nous avons adopté une démarche qui consiste à considérer d'abord l'architecture la plus simple, Figure(III.3), puis la rendre de plus en plus complexe et retenir celle qui présente les meilleures performances.

Dans ce cas, on est partie d'une architecture à une couche cachée avec 1 neurone, puis on augmente le nombre de couche cachée et le nombre de neurones de chaque couche cachée.

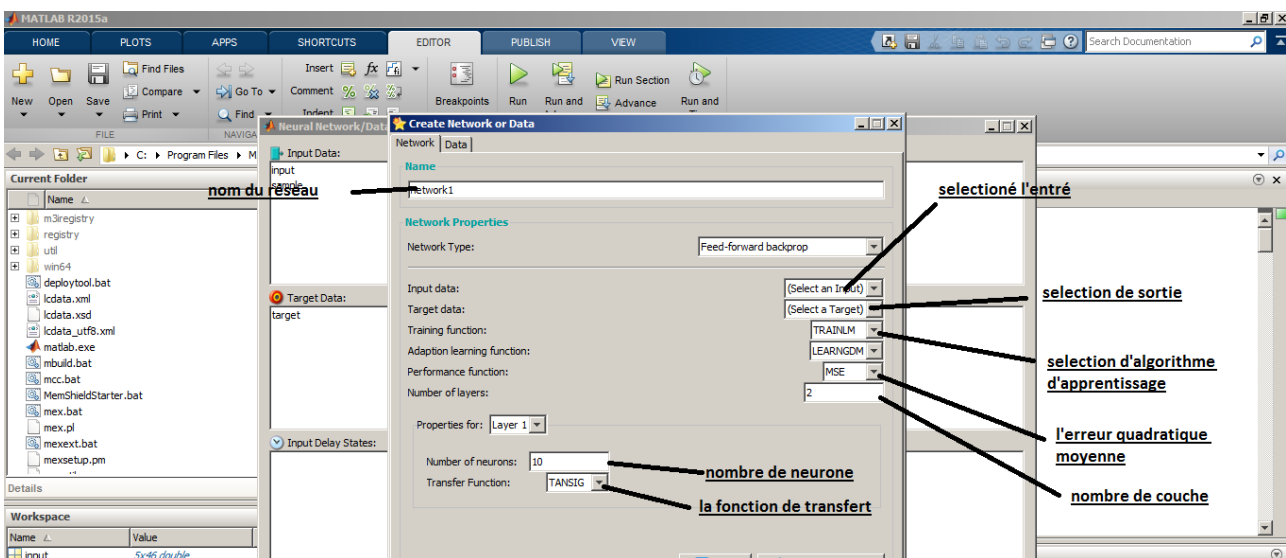


Figure (III.3) :Création d'un réseau de neurone

Après avoir essayé plusieurs architectures dans les deux cas on est arrivé aux architectures suivantes :

Architecture 1 : Pour la prédiction du taux de corrosion

Durant toute cette partie nous considérons un PMC contenant 3 couches cachées et une couche de sortie. La première couche contenant 5 neurones à fonction d'activation type tangente sigmoïde, la deuxième et troisième couche contenant 15 neurones à fonction d'activation type tangente sigmoïde et une couche de sortie à un seul neurone avec une fonction d'activation linéaire, Figure(III.4).

Architecture 2 : Pour la prédiction du potentiel de corrosion

Durant toute cette partie nous considérons un PMC contenant 4 couches cachées et une couche de sortie. La première couche contenant 3 neurones à fonction d'activation type tangente sigmoïde, la deuxième, troisième et la quatrième couche contenant 10 neurones à fonction d'activation type tangente sigmoïde et une couche de sortie à un seul neurone avec une fonction d'activation linéaire, Figure(III.4).

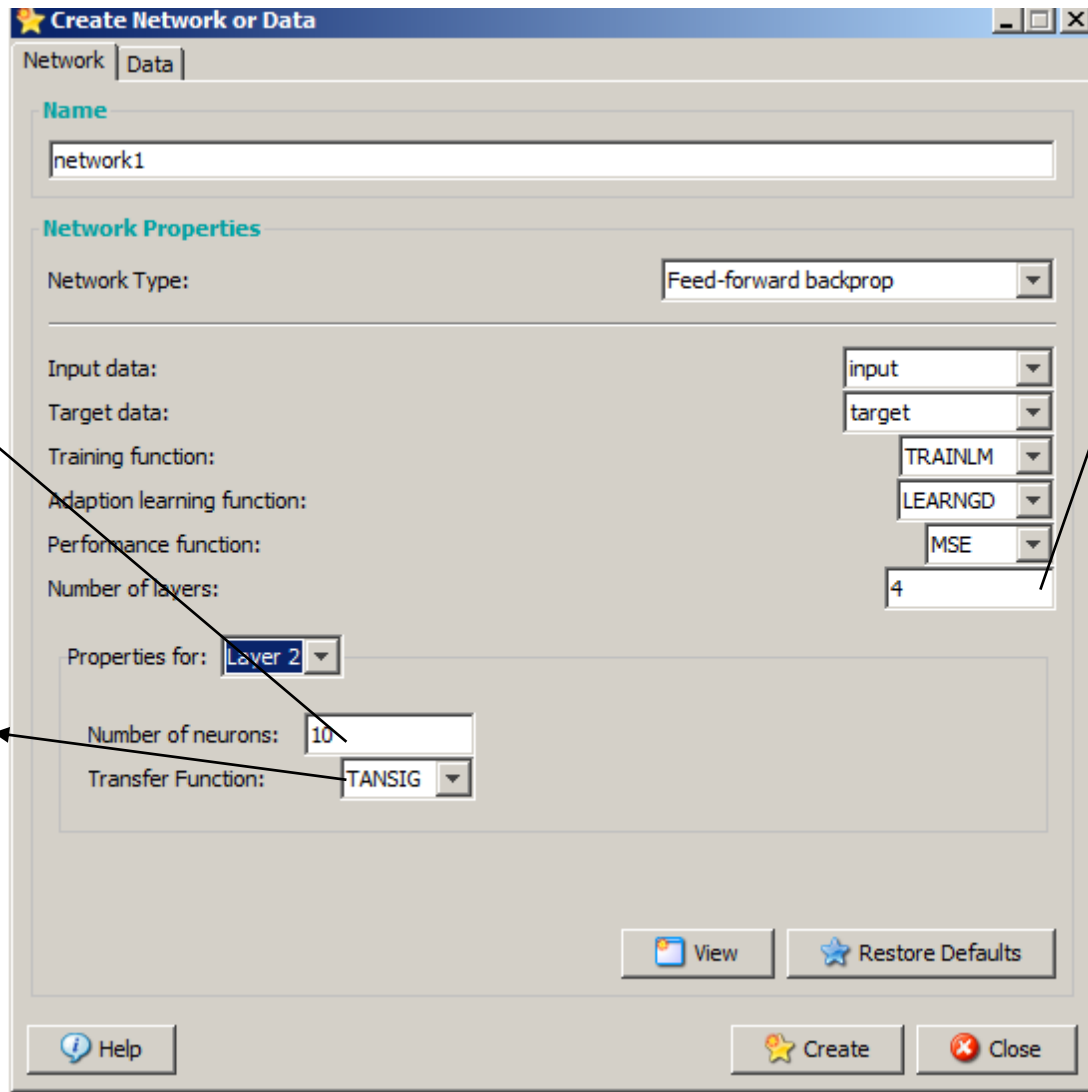


Figure (III.4) : choix de l'architecture

III.2.4 Prétraitement des données

De manière générale, les bases de données subissent un prétraitement, qui consiste à effectuer une normalisation appropriée tenant compte de l'amplitude des valeurs acceptées par le réseau[3], avant leur utilisation pour l'apprentissage du réseau de neurone, et ce afin d'assurer une homogénéisation des valeurs propagées dans le réseau.

CHAPITRE III MÉTHODOLOGIE

Les entrées et les sorties sont normalisées linéairement entre 0 et 1, par rapport à leur valeur minimale ou maximale, en appliquant l'équation de normalisation suivante :

$$valeur_normalisée = \frac{valeur_non_normalisée - valeur_min}{valeur_max - valeur_min}$$

Avec : valeur min et valeur max qui sont les valeurs minimale et maximale respectivement de la variable à normaliser.

Cette normalisation permet d'assurer qu'une entrée ne devienne pas prépondérante au détriment des autres, du fait des valeurs atteintes.

III.2.5. Phase d'apprentissage

Une fois qu'on a choisi l'architecture du réseau de neurone, elle doit subir une phase d'apprentissage qui consiste à calculer les pondérations optimales des différentes liaisons, en utilisant la base d'apprentissage.

Les poids sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement afin d'éviter que l'apprentissage ne s'arrête sur un minimum local de la fonction d'erreur.

L'ensemble des données d'apprentissage est donc présenté plusieurs fois au réseau avec différentes valeurs d'initialisations des poids synaptiques.

Et comme nous disposons des valeurs de sorties, nous avons choisi l'apprentissage supervisé, mettant en jeu l'algorithme de Levenberg-Marquardt, Figure(III.5) donnant de meilleurs résultats en termes de rapidité de convergence et de performance de généralisation [6].

Ce dernier cherche à minimiser, par des méthodes d'optimisations non linéaires une fonction de cout. La fonction cout est l'erreur quadratique moyenne. MSE en anglais (Mean Square Error), Figure(III.6), reflétant l'écart entre la sortie du réseau et la sortie désirée, elle est définie par :

$$MSE = \frac{1}{N} \sum_{k=1}^N e(k)^2 = \frac{1}{N} \sum_{k=1}^N (t(k) - a(k))^2$$

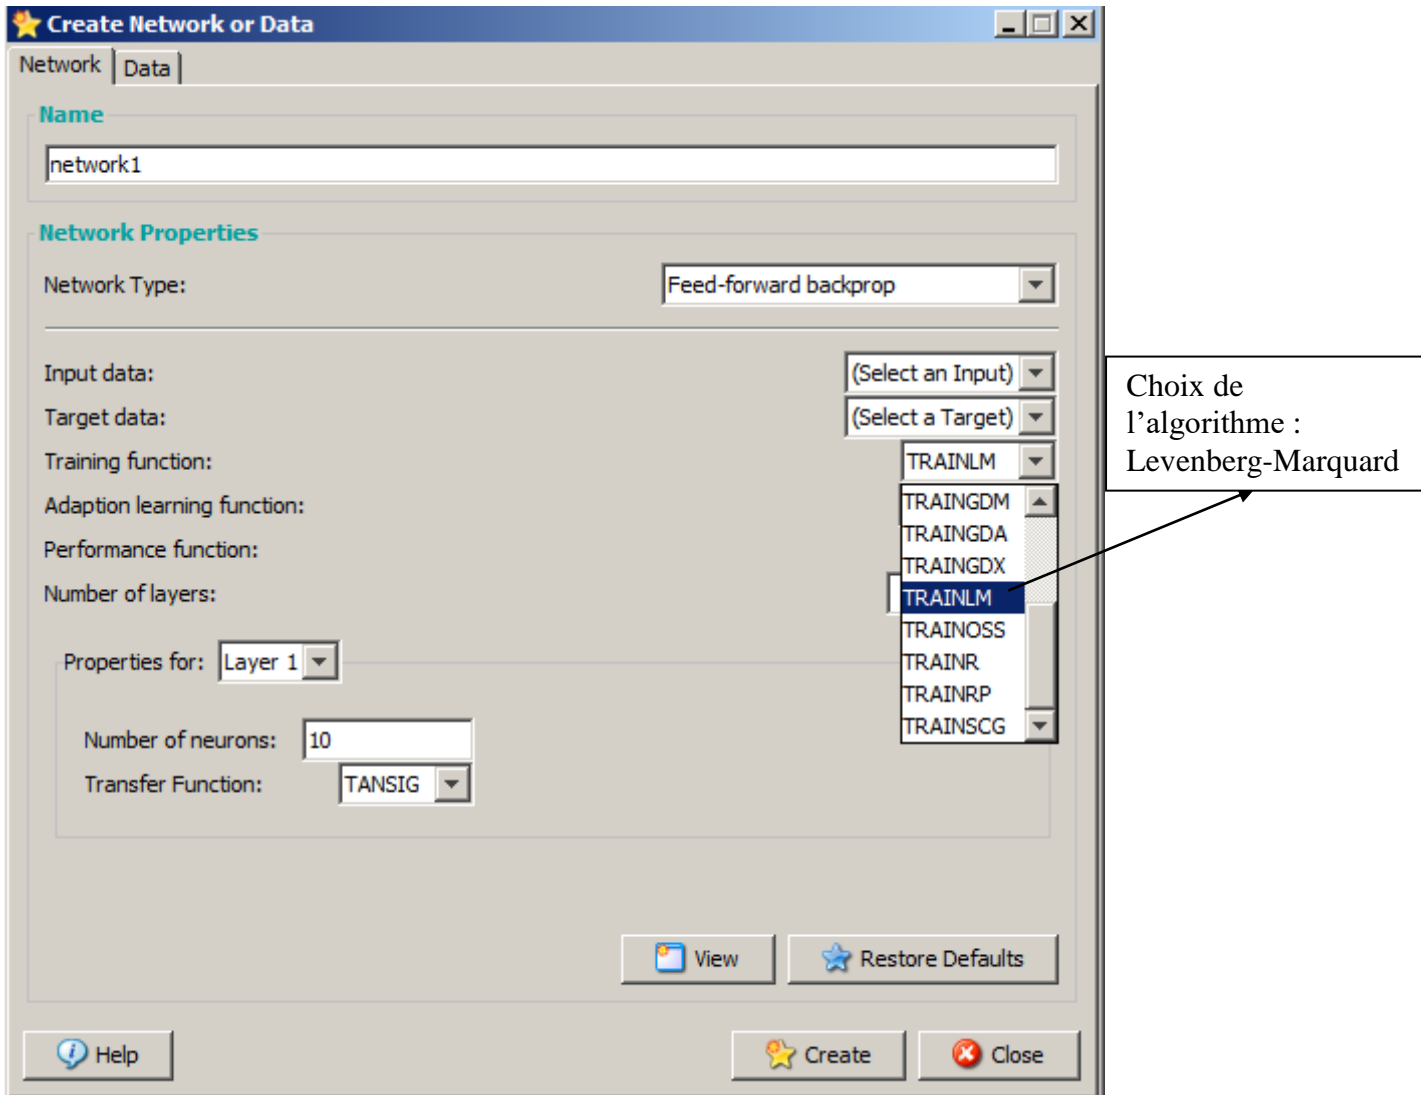
Avec

N : le nombre d'exemples dans la base d'apprentissage;

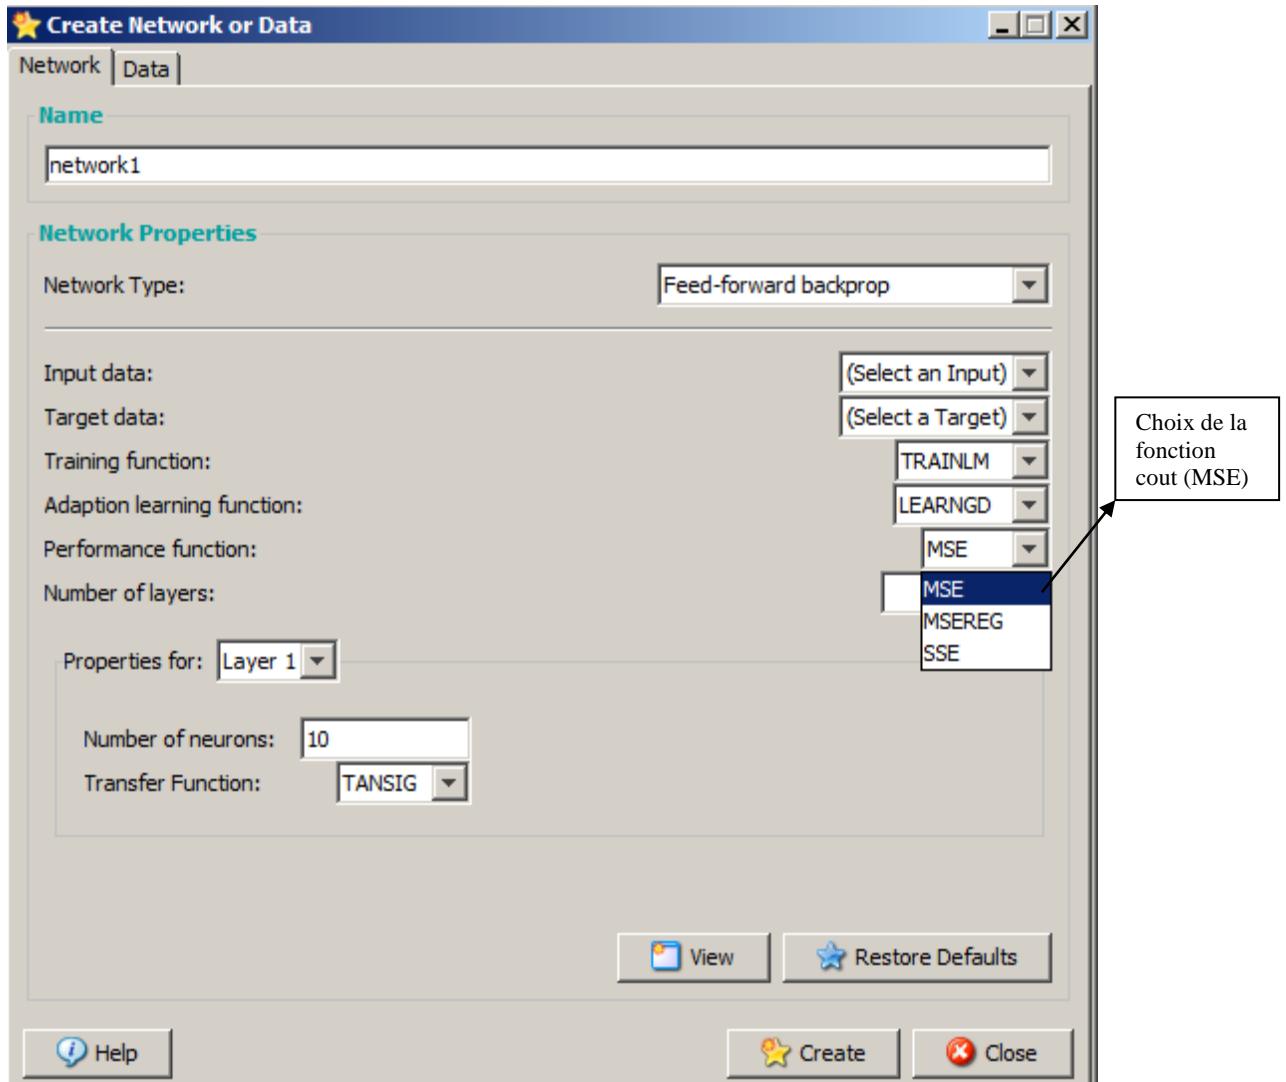
e(k) : l'erreur quadratique commise à la sortie du réseau;

t(k) : le vecteur cible (sortie désirée);

a(k) : le vecteur de sortie élaboré par le réseau;



Figure(III.5) : Le choix de l'algorithmme d'apprentissage



Figure(III.6) : Le choix de la fonction cout

III.2.6. Phase de test

Une fois l'apprentissage du réseau est terminé, il faut toujours procéder à des tests pour estimer sa qualité de généralisation, et ce en lui présentant une base de données différente de celles utilisée pour l'apprentissage ou la validation croisée. Si les performances ne sont pas satisfaisantes, il faudra soit modifier l'architecture du réseau, soit modifier la base d'apprentissage.

CHAPITRE IV

RESULTAS ET DISCUSSIONS

IV-1-Introduction

La corrosion des armatures est la principale cause de dégradation des ouvrages en béton armé. Cette corrosion affecte la durabilité de ces ouvrages et peut conduire à une perte de leur capacité structurale. Il est donc extrêmement important d'ausculter périodiquement les ouvrages afin de déterminer s'ils sont atteints par cette corrosion. La principale technique utilisée dans cet objectif : le potentiel de corrosion [29].

IV-2-Principe de l'essai de potentiel de corrosion

Ce sont les travaux de R. Stratfull sur des dalles en béton armé qui ont permis l'élaboration, au début des années 70, de la norme ASTM C876 'Standard Test Method for Half-Cell Potentials of Uncoated Reinforcing Steel in Concrete'. Selon cette norme, la mesure de la différence de potentiel électrique entre une armature dans le béton et une électrode de référence en cuivre-sulfate de cuivre en contact avec le béton de recouvrement de cette armature permet d'avoir une information sur la probabilité de corrosion de l'armature, tel que indiqué dans le tableau(IV.1) :

Potentiel mesuré	Probabilité de corrosion
Supérieur à -200 mV	Inférieure à 10%
Entre -200 mV et -350 mV	Égale à 50%
Inférieur à -350 mV	Supérieure à 90 %

Tableau (IV.1) : Probabilité de Corrosion en fonction du potentiel de corrosion mesuré [29].

Dans la pratique (ex. cas d'une dalle de stationnement), les mesures du Potentiel de Corrosion sont effectuées selon des lignes parallèles espacées de 1 m. Les résultats sont généralement présentés sous la forme d'une cartographie en couleur indiquant la probabilité de corrosion des armatures au sein de la structure auscultée, tel que montré à la figure(IV.1) [29].




Figure (IV.1): Cartographie obtenue par la mesure du potentiel de corrosion [29].

L'essai de potentiel de corrosion permet tout simplement de localiser les endroits où le béton est corrosif et les endroits où le béton est non corrosif, et d'associer successivement ces endroits à des endroits où la probabilité de corrosion des armatures est forte ou faible [29].

IV.3-Quelle est la fiabilité de l'essai de potentiel de corrosion ?

Les mesures de potentiel de corrosion donnent des résultats qui sont généralement corroborés par les résultats de carottages. Ces mesures doivent être effectuées en tenant compte notamment de certains facteurs qui peuvent [29] :

- Soit conduire à une sous-estimation de la probabilité de corrosion (ex. une température du béton sous le zéro, un recouvrement important des armatures, la carbonatation du béton),
- Soit conduire à une surestimation de la probabilité de corrosion (ex. béton saturé),
- Soit conduire à des résultats mitigés (ex. une mauvaise continuité électrique entre les armatures, présence d'armatures galvanisées ou avec revêtement d'époxy).

Les ingénieurs sont donc intéressés de connaître l'état de dégradation des structures en béton armé, telles que les dalles des tabliers de ponts, et à quantifier cette dégradation. Ceci leur permettra de décider du type de réparation et d'estimer le coût et le moment des réparations et des travaux.

Pour apporter une réponse, nous avons utilisé le réseau de neurone artificiel avec comme base de données le potentiel de corrosion mesuré, et le temps de mesure pour prédire la vitesse de corrosion.

Pour se faire, nous avons partagé cette partie en deux tranches. La première a été consacrée à la validation de notre connaissance et maîtrise de l'utilisation des RNA, et dans la deuxième, nous avons construit notre architecture RNA, fait l'apprentissage, le test, et prédit la vitesse de corrosion.

IV.4-Validation de notre approche :

Pour valider notre approche, nous avons repris les travaux de [Y.F.Wen et al][24] et [Oscar Martin et al] [25], qui avaient respectivement pour but la prédiction du taux de corrosion et du potentiel de corrosion. Pour le premier cas où il a été utilisé la méthode des SVR, nous avons construit une architecture RNA et prédit le taux de corrosion tandis que

pour le second cas , nous avons repris les calculs avec les RNA en changeant l'architecture du réseau pour prédire le potentiel de corrosion, tout en gardant les mêmes bases de données. Les résultats obtenus ont été confrontés à ceux des deux auteurs.

IV.4.a- Prédiction du taux de corrosion

Rappelons qu'il s'agit de prédire le taux de corrosion d'un acier 3C, plongé dans l'eau de mer. Ce type d'acier est utilisé dans la réalisation des ouvrages tels que la construction des structures en contact avec un environnement agressif.

La base de données a été extraite de 46 expériences. De chaque expérience il a été relevé 5 facteur, cités ci-dessous, ce qui fait 46×5 soit 230 paramètres. Le taux de corrosion représente la cible de test et d'apprentissage :

- $T_{(C^{\circ})}$ température de l'environnement;
- $DO_{(mg/l)}$ oxygène dissous dans l'eau de mer;
- $Sal_{(ppt)}$ la salinité de l'eau de mer,
- PH : du milieu (l'eau de mer),
- ORP $_{(mv)}$ potentiel d'oxydoréduction ou potentiel de corrosion,
- Rate ($\mu A\ cm$) le taux de corrosion.

- **Méthode de l'auteur [24] :**

L'auteur a utilisé la méthode SVR pour faire la prédiction du taux de corrosion.

- **Notre méthode :**

Comme il a été dit dans le chapitre III, nous avons considéré un PMC contenant 3 couches cachées et une couche de sortie. La première couche contenant 5 neurones à fonction d'activation type tangente sigmoïde, la deuxième et troisième couche contenant 15 neurones à fonction d'activation type tangente sigmoïde et une couche de sortie à un seul neurone avec une fonction d'activation linière. La figure(IV.2) donne un aperçu sur la méthode que nous avons utilisée.

Montre l'architecture du réseau

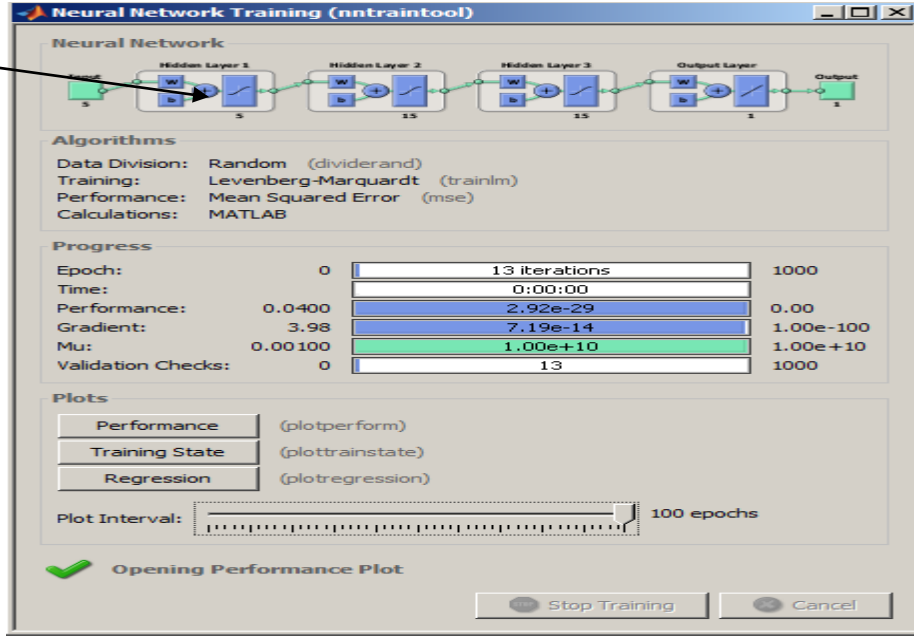


Figure (IV.2) : Fenêtre d'exécution du réseau de neurones.

- **Résultats et discussions**

La figure(IV.3) montre l'évolution de la fonction coût exprimée par EQM(erreur quadratique moyenne) en anglais MSE. En effet, on constate que la meilleure performance, par rapport à la cible que nous avons fixé, a été atteinte après la 1ère itérations.

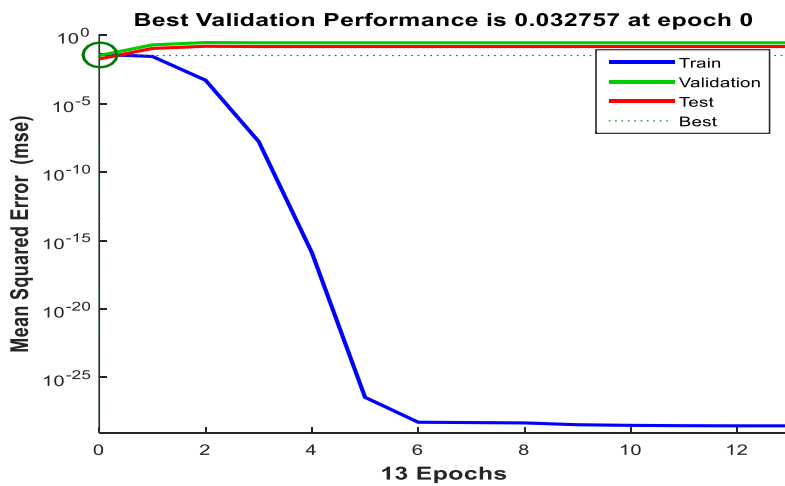


Figure (IV.3) : L'évolution de l'erreur quadratique moyenne (EQM).

La figure(IV.4) représente la régression linéaire entre la sortie désirée et la sortie du réseau.

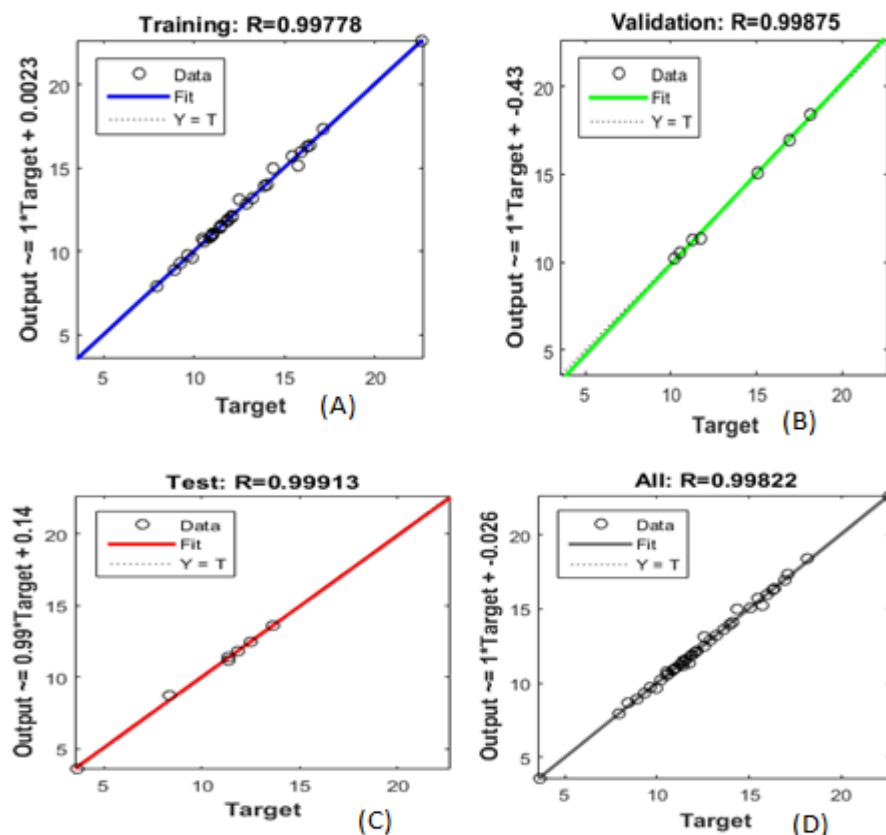


Figure (IV.4) : corrélation

- (a) entre la sortie désirée et la sortie du réseau pour la base d'apprentissage,
- (b) entre la sortie désirée et la sortie du réseau pour la base validation,
- (c) entre la sortie désirée et la sortie du réseau pour la base de test,
- (d) entre la sortie désirée et la sortie du réseau pour la base de données globales.

Constatation :

On remarque qu'il y a une très bonne corrélation entre les valeurs de sortie désirées et celles de notre réseau sur les quatre graphes :

Déduction :

Nous déduisons à partir des graphes restitués par le logiciel, que le modèle a été exécuté avec une meilleure corrélation, pour les trois phases, apprentissage, test et validation.

- **Confrontation de nos résultats avec ceux de l'auteur**

Le tableau(IV.2) présente la base de données d'apprentissages et les résultats que nous avons obtenus pour les trois phases (test, validation et apprentissage).

Les deux dernières colonnes font ressortir l'erreur et l'erreur relative par rapport à la valeur expérimentale.

CHAPITRE IV: RESULTATS ET DISCUSSIONS

Numéro	T(°C)	DO (mg/l)	Sal (ppt)	Ph	ORP(mV)	Taux (µA/ cm ²)	Notre résultat RNA	Erreur	Erreur relative%
1	25,9	6,71	30,1	5,1	378	16,4	16,4	0	0
2	29,4	6,09	29	6,3	400	16,9	16,9	7,11E-15	0
3	27,9	6,18	31,5	7	363	15,75	15,193567	0,556433	3,6622934
4	24	7,95	30,2	8,1	324	13,65	13,65	1,07E-14	0
5	28	5,05	31,4	9,2	240	13,24	13,24	0	0
6	27,3	3,21	29,31	8,2	281	12,91			
7	27,9	6,55	31,68	7,2	356	14,06	14,06	1,78E-15	0
8	28,3	6,98	28,2	6,6	384	15,47	15,746548	-0,276548	1,756245
9	30,7	7,15	31,74	6,5	401	16,28			
10	29,4	6,82	30,12	6,2	414	17,11	17,325922	-0,215922	1,246237
11	24,3	0,8	32,56	8,1	171	3,61	3,61	0	0
12	27,5	2,6	35,37	7,96	287	7,94	7,94	1,51E-14	0
13	27,2	4,2	31,94	7,89	289	9,63			
14	27,5	5,9	32,39	7,83	331	10,578	10,578	-1,07E-14	0
15	28,8	6,8	32,22	8	340	11,43	11,43	-3,55E-15	0
16	28,5	8,4	32,1	8,01	345	12,52	12,496879	0,0231212	0,1850142
17	28,5	9,9	31,95	7,93	309	22,64	22,64	-1,78E-14	0
18	24	7,61	9,17	8,04	231	10,94			
19	24,7	6,06	17,33	7,08	321	11,446	11,446	-5,33E-15	0
20	24,6	7,52	24,42	7,57	210	11,83			
21	24,5	7,02	32	8,16	308	12,553	13,118514	-0,565514	4,310808
22	23,7	6,51	41,34	7,67	245	8,402	8,7075557	-0,305556	3,509087
23	16,7	7,11	33,55	8,25	178	10,85	10,85	-3,55E-15	0
24	21,1	6,03	33,44	8,03	295	11,448	11,49317	-0,04517	0,393016
25	25,6	6,7	32,19	8,09	325	11,872	11,872	1,42E-14	0
26	31,2	4,38	33,21	7,94	242	8,924	8,924	8,88E-15	0
27	25,6	34,89	5,32	7,9	385	15,966	15,966	1,07E-14	0
28	25	16,29	6,8	7,82	341	12,12	12,12	-1,78E-15	0
29	24,5	18,37	5,31	7,93	302	12,07	12,07	7,11E-15	0
30	25,6	21	7,04	7,95	244	11,4	11,21225	0,1877497	1,6745078
31	26,1	34,84	2,82	7,8	335,2	11,288	11,288	-1,07E-14	0
32	25	40	6,32	8,08	254	9,3	9,3	3,55E-15	0
33	9,5	32,31	4,26	8,2	195	10,56	10,56	-3,55E-15	0
34	12,1	32,04	4,95	8,17	232	11,04	11,04	0	0
35	14,9	32,51	6,3	7,95	198	11,06	11,06	5,33E-15	0
36	28,1	34,34	5,14	7,8	362,9	13,93	13,93	-5,33E-15	0
37	24,2	16,09	7,68	8,04	283,8	11,55	11,55	-3,55E-15	0
38	23,5	15,04	8,27	8,06	243,8	11,72	11,323055	0,3969452	3,5056352
39	25,3	15,22	7,59	9,32	246,7	11,39	11,39	1,78E-15	0
40	12,6	37,9	6,42	7,49	235,3	10,52	10,756151	-0,236151	2,195497
41	16,8	39,49	6,61	7,73	258,7	10,24	10,24	-5,33E-15	0
42	24,1	36,72	5,59	7,83	281,8	9,93	9,6649759	0,2650241	2,7421082
43	26,3	35,97	3,25	7,98	367,1	14,37	14,988904	-0,618904	4,129081
44	25,4	16,94	4,05	8	341,2	15,07	15,07	3,55E-15	0
45	26,1	35,34	4,07	7,94	404	18,13	18,39783	-0,26783	1,45577
46	26,5	34,48	4,94	7,9	326,1	11,828	11,828	1,78E-15	0

Tableau (IV.2) : Base de données (taux de corrosion expérimental), taux de corrosion du RNA et l'erreur.

Constatations :

Après exploitation des résultats afficher dans le tableau si dessus nous avons constaté :

- 1- 28 valeurs sur 41 affichent un taux d'erreur de 0%,.
- 2- 6 valeurs sur 41 affichent un taux d'erreur < à 2%,
- 3- 7 valeurs sur 41 affichent un taux d'erreur < à 5%.

Déduction

Nous déduisons à partir des résultats que notre modèle a été exécuté avec satisfaction et a réussi à prédire le taux de corrosion avec une précision plus acceptable.

Confrontations des résultats pour le calcul du taux de corrosion

Le tableau (IV.3) présente une comparaison des résultats obtenue par notre model neural, BPNN et SVR.

N°Exp	Valeur du taux de corrosion				Erreur relative		
	Expérimentale [24]	BPNN [24]	SVR [24]	Calculé par nous	BPNN [24]	SVR [24]	Notre
7	14,06	13,12	14,195	14,06	6,69	0,96	0
10	17,11	17,14	16,175	17,325922	0,175	1,88	1,261962
14	10,578	11,1	10,928	10,578	4,93	3,31	0
19	11,446	12,08	11,653	11,446	5,54	1,23	0
21	12,553	11,59	13,963	13,118514	7,67	11,23	4,505013

Tableau (IV.3): comparaison des résultats prédits [24] par deux méthodes et nos résultats.

Constatations :

On constate que l'erreur relative affichée par le modèle que nous avons construit est inférieure à celles des deux méthodes BPNN et SVR.

Déduction :

On déduit encore une fois que les résultats que nous avons obtenus par notre modèle RNA donne une meilleure satisfaction.

IV.4.b- Le potentiel de corrosion

Rappelons qu'il s'agit de prédire le potentiel de corrosion d'un joint de soudure sur acier austénitique AISI 304, il a été rapporté dans la littérature que la cause principale pour sa dégradation par corrosion sont les joint de soudure qui sont affecté par plusieurs paramètre lié au procédé du soudage dont :

- $WT_{(cycles)}$ temps de soudure,

- $WC^2_{(kA^2)}$ le courant soudure,

- $EF_{(N)}$ la force d'électrode.

Pour ce la l'auteur a utilisé une base de données extraite de 36 expériences. De chaque expérience il a été relevé les 3 facteurs, cités ci-dessus, ce qui fait 36×3 soit 108 paramètres. Pour cible, il a été utilisé le potentiel de corrosion correspondant à chaque expérience.

- **Méthode de l'auteur [25] :**

L'auteur a utilisé un model neural pour faire la prédiction du potentiel de corrosion.

Il a utilisé une architecture PMC contenant 3 couches cachées et une couche de sortie. la première couche contenant 3 neurones à fonction d'activation tangente sigmoïde, la deuxième et la troisième couche contenant 15 neurones à fonction d'activation type tangente sigmoïde et une couche de sortie à un seule neurone avec une fonction d'activation linière.

- **Notre méthode :**

Comme il déjà été dit dans la première partie de ce chapitre, nous avons considéré un PMC contenant 4 couches cachées et une couche de sortie. La première couche contenant 3 neurones à fonction d'activation type tangente sigmoïde, la deuxième, troisième et la quatrième couche contenant 15 neurones à fonction d'activation type tangente sigmoïde et une couche de sortie à un seule neurone avec une fonction d'activation linière. La figure(IV.5) donne un aperçu sur notre méthode.

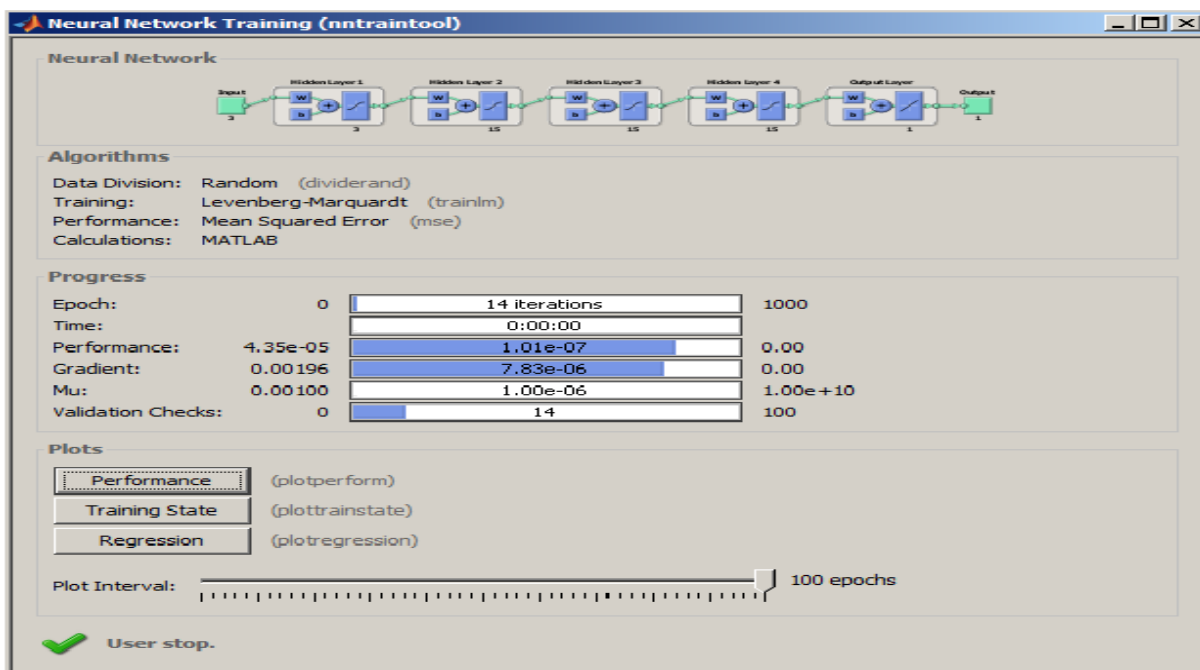


Figure (IV.5) : Exécution de réseau de neurone.

- **Résultats et discussions**

La figure(IV.6) montre l'évolution de la fonction cout exprimée par EQM (erreur quadratique moyenne) en anglais MSE. En effet, on constate que la meilleure performance, par rapport à la cible que nous avons fixée, a été atteinte après 1ère itérations.




Figure (IV.6) évolution de l'erreur quadratique moyenne (EQM)

La figure (IV.7) représente la régression linéaire entre la sortie désirée et la sortie du réseau.

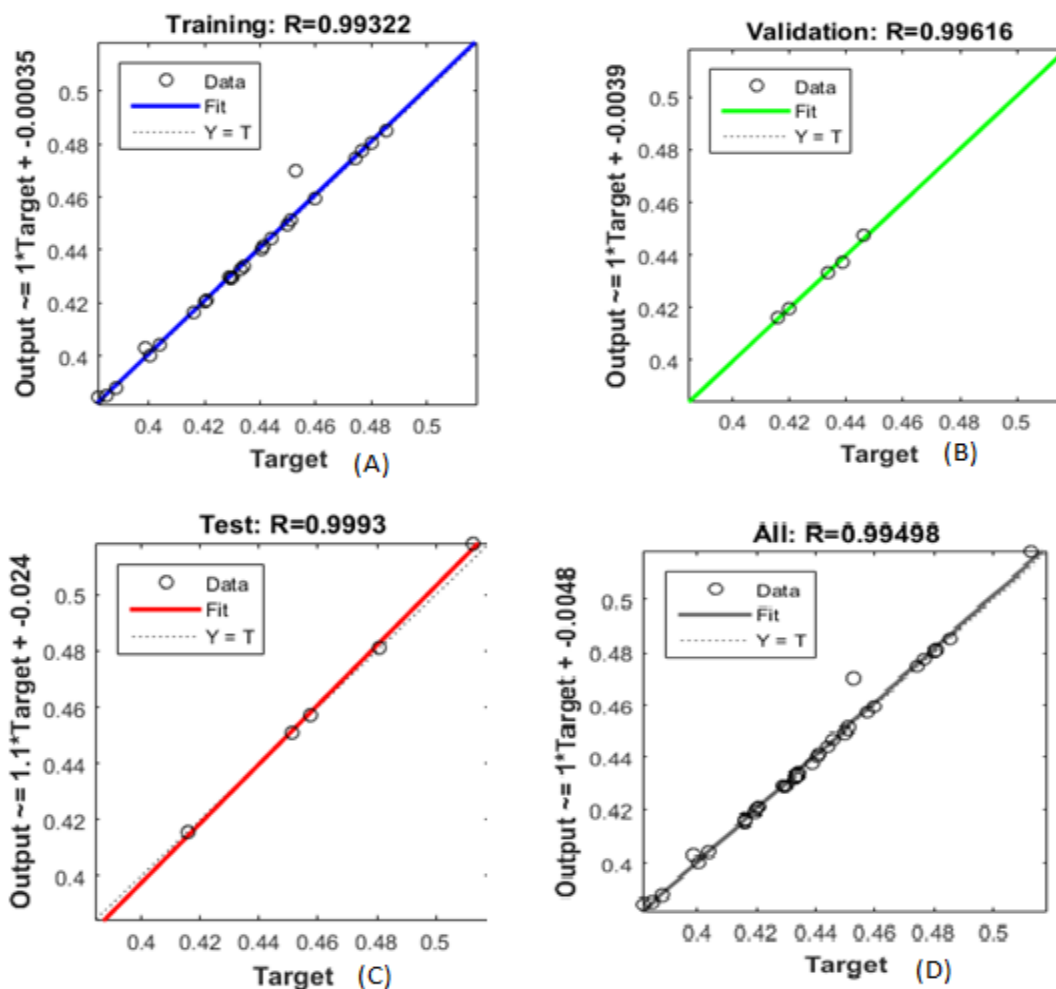


Figure (IV.7) : corrélation

- (a) entre la sortie désirée et la sortie du réseau pour la base d'apprentissage,
- (b) entre la sortie désirée et la sortie du réseau pour la base validation,
- (c) entre la sortie désirée et la sortie du réseau pour la base de test,
- (d) entre la sortie désirée et la sortie du réseau pour la base de données global.

Constataion :

On remarque qu'il y a une bonne corrélation entre les valeurs de sorties que représentent les quatre graphes.

Déduction :

Nous déduisons à partir des graphes restitués par le logiciel, que le modèle a été exécuté avec une bonne corrélation, pour les trois phases, apprentissage, test et validation.

Confrontation de nos résultats avec ceux de l'auteur [25]

Le tableau (IV.4) présente la base de données, les résultats que nous avons obtenus pour les trois phases (test, validation et apprentissage).

CHAPITRE IV: RESULTATS ET DISCUSSIONS

Input of the ANN			Ancien RNA(Epitt)(VSCE)	Expérimental (Epitt)(VSCE)	Δa (VSCE)	$\Delta b\%$	Nos resultats RNA	ERREUR	erreur relative
WT (cycles)	WC2 (kA2)	EF(N)							
7	37.9456	1500	0.45972	0.42684	0.03288	7,7			
10	30.3601	1500	0.43381	0.44997	0.01616	3.59	0.441854905	0.008115095	1,803475
5	31,8096	1500	0,44848	0,42009	0,02839	6,76	0,419727677	0,000362323	0,08624883
12	26,1121	1500	0,46085	0,44586	0,01499	3,36	0,450084861	-0,004224861	0,94757578
8	24,8004	1500	0,44788	0,40059	0,04729	11,81	0,406314358	-0,005724358	1,42898182
4	24,8004	1500	0,44093	0,47656	0,03563	7,48	0,475686069	0,000873931	0,18338312
9	21,0681	1500	0,43408	0,42911	0,00497	3,36	0,421144671	0,007965329	1,85624408
3	21,0681	1500	0,44233	0,44096	0,00137	0,31	0,448564699	-0,007604699	1,72457808
10	15,4449	1500	0,44741	0,44979	0,00238	0,53			
7	16,4836	1500	0,44269	0,47989	0,0372	7,75	0,481713279	-0,001823279	0,37993692
10	12,5316	1500	0,45366	0,45271	0,00095	0,21	0,456887924	-0,004177924	0,92286978
3	12,5316	1500	0,43094	0,45122	0,02028	4,49	0,451399148	-0,000179148	0,03970314
9	8,2944	1500	0,48562	0,48547	0,00015	0,03	0,485216923	0,000253077	0,05213025
11	41,2164	1500	0,43477	0,44419	0,00942	2,12	0,448934959	-0,004744959	1,06822743
12	6,2001	1500	0,48185	0,48063	0,00122	0,25	0,482094023	-0,001464023	0,30460496
3	6,2001	1500	0,47015	0,47447	0,00432	0,91	0,476774057	-0,002304057	0,48560643
5	3,8416	1500	0,46381	0,42925	0,03456	8,05	0,429753056	-0,000503056	0,11719417
12	43,0336	1000	0,46062	0,4197	0,04092	9,75			
7	41,2164	1000	0,44101	0,45718	0,01617	3,54	0,457322125	-0,000142125	0,03108736
3	41,2164	1000	0,43612	0,44041	0,00429	0,97	0,440834719	-0,000424719	0,09643724
8	34,81	1000	0,44579	0,45112	0,00533	1,18	0,451047302	7,27E-05	0,01611505
3	31,8096	1000	0,43672	0,43388	0,00284	0,65	0,42734308	0,00653692	1,50661933
9	24,8004	1000	0,40456	0,38479	0,01977	5,14	0,386137976	-0,001347976	0,3503147
5	26,1121	1000	0,44025	0,42085	0,0194	4,61	0,420771084	7,89E-05	0,01875149
9	21,0681	1000	0,40207	0,38849	0,1368	3,5	0,389387729	-0,000897729	0,23108161
5	16,4836	1000	0,42468	0,44086	0,01618	3,67	0,492957759	-0,052097759	11,8173024
8	11,6281	1000	0,42403	0,42994	0,00591	1,37	0,42990125	3,87E-05	0,00901289
2	12,5316	1000	0,41012	0,41633	0,00621	1,49	0,4160244	0,0003056	0,07340328
5	9,0601	1000	0,4828	0,5124	0,0296	5,78	0,512427161	-2,72E-05	0,0053007
8	3,8416	1000	0,46475	0,43339	0,3136	7,24	0,433559708	-0,000169708	0,03915819
3	3,84516	1000	0,45244	0,43284	0,0196	4,53	0,432994921	-0,000154921	0,03579178
6	6,2001	1000	0,47675	0,43886	0,03789	8,63	0,439154323	-0,000294323	0,06706528
11	2,4649	1000	0,42257	0,399	0,02357	5,91	0,39916864	-0,00016864	0,04226559
7	2,4649	1000	0,42895	0,38187	0,04708	12,33	0,381129591	0,000740409	0,19389036
11	2,89	1500	0,43833	0,41596	0,02237	5,38	0,41563165	0,00032835	0,07893799
7	2,0736	1500	0,42685	0,41606	0,1079	2,59	0,415784494	0,000275506	0,06621786

Tableau (IV.4) : Base de données, potentiel de corrosion expérimental, potentiel de corrosion du RNA, l'erreur et l'erreur relative

Constatations :

Après exploitation des résultats affichés dans le tableau (IV.4) nous avons constaté :

32 valeurs sur 33 sont <2%,

1 valeur sur 33 égales a 11%.

Déduction

Nous déduisons de l'ensemble de ces résultats que le potentiel de corrosion prédit à partir de notre modèle présente une meilleure précision.

Confrontations des résultats pour le calcul du taux de corrosion

Le tableau (IV.5) présente une comparaison des résultats obtenus de notre modèle neural et celle de l'auteur [25].

N°	Expérimental [25]	Ancien RNA [25]	Erreur [25]	Erreur relative [25]	Nos résultats RNA	Erreur	Erreur relative
1	0,42684	0,45972	0,03288	-7,70312061	0,4241	0,00265	0,64192672
7	0,42911	0,43408	0,00497	-1,15821118	0,4211	0,0079	1,86665424
18	0,4197	0,46062	0,00429	-9,7498213	0,4194	0,0002789	0,07147963

Tableau (IV.5): comparaison des résultats prédits.

Constatations :

On constate que l'erreur relative affichée par le modèle que nous avons construit est inférieure à celle de l'auteur.

Déduction :

Nous déduisons de l'ensemble de ces résultats que le potentiel de corrosion prédit à partir de notre modèle présente une meilleure précision.

IV.5- Calcul du taux de corrosion à partir de notre base de données expérimentale

La base de données a été obtenue à l'échelle du notre laboratoire. Il s'agit d'un barreau d'acier de construction plongé dans un mortier d'argile.

38 expériences ont été réalisées. Trois paramètres issus de chacune de ces dernières ont été utilisés, dont le potentiel de corrosion, le temps d'immersion et la vitesse de corrosion. Soit au total 108 paramètres :

- Les données de 35 expériences (35* 3) potentiels de corrosions et 35 temps d'immersions et 35 taux de corrosions ont été injectés comme paramètres d'entrés, ce qui en fait 105 valeurs. La prédiction a porté sur trois expériences dont le taux de corrosions.

Les potentiels de corrosion ont été obtenus par les essais de potentio dynamique . Le matériel utilisé est le VOLTALAB 301 piloté par le logiciel VOLTAMASTER. Les paramètres ont été ajustés par le logiciel de traitement des données ORIGINE.

- . La figure (IV.8) donne un aperçu sur l'architecture utilisée.

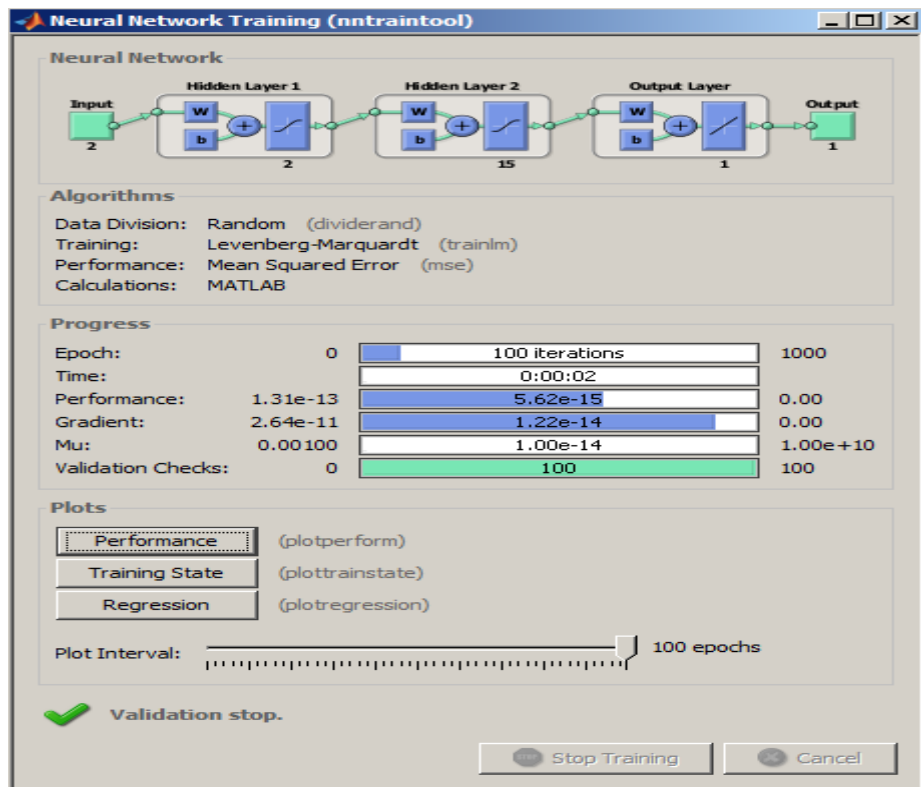


Figure (IV.8) : Exécution de réseau de neurone.

- **Résultats et discussions des graphes**

La figure (IV.9) montre l'évolution de la fonction cout exprimée par EQM (erreur quadratique moyenne) en anglais MSE. En effet, on constate que la meilleure performance, par rapport à la cible que nous avons fixé, a été atteinte après 100 itérations.




Figure (IV.9) l'évolution de l'erreur quadratique moyenne (EQM).

La figure (IV.10) représente la régression linéaire entre la sortie désirée et la sortie du réseau.

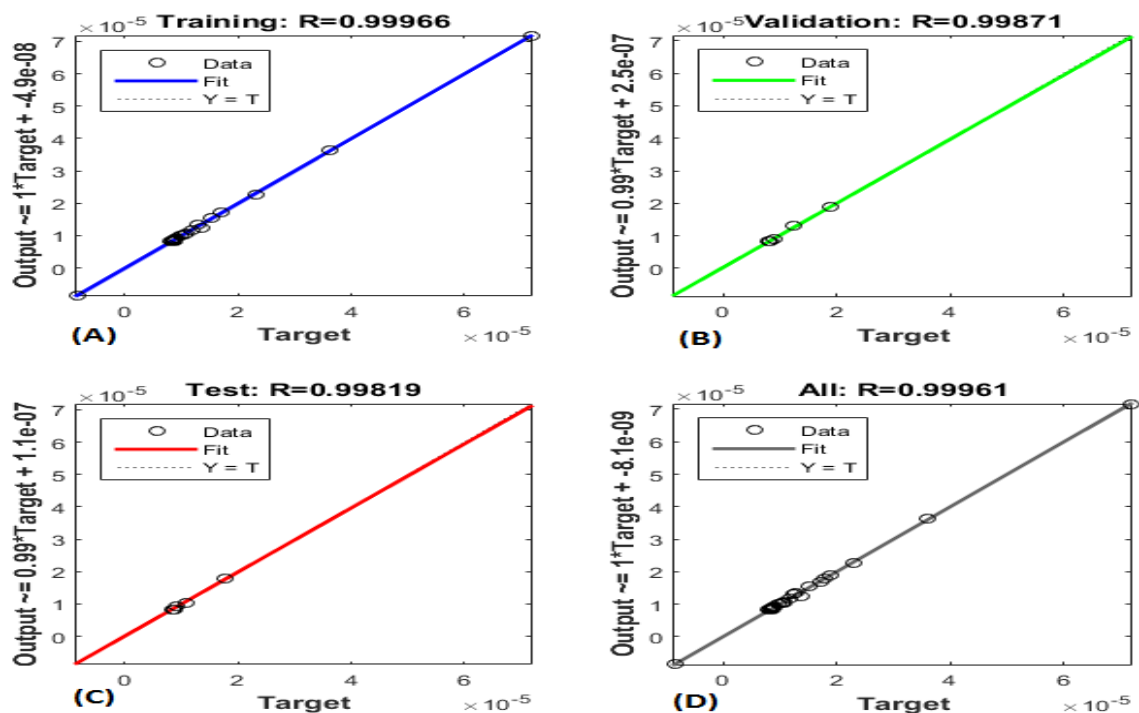


Figure (IV.10) : Corrélation

- (a) entre la sortie désirée et la sortie du réseau pour la base d'apprentissage,
- (b) entre la sortie désirée et la sortie du réseau pour la base validation,
- (c) entre la sortie désirée et la sortie du réseau pour la base de test,
- (d) entre la sortie désirée et la sortie du réseau pour la base de données global.

Constataion :

On remarque qu'il y a une bonne corrélation entre les valeurs de sorties représentés sur les quatre graphes :

Déduction :

Nous déduisons à partir des graphes restitués par le logiciel, que le modèle a été exécuté avec une bonne corrélation, pour les trois phases, apprentissage, test et validation.

Discussion des résultats

Il est à noter que trois valeurs ont été soigneusement laissées pour la prédiction.

CHAPITRE IV: RESULTATS ET DISCUSSIONS

Temps d'immersion	E(corrosion)	Taux de corrosion		Erreur	Erreur relative
		expérimentale	RNA		
0	-6,71E-01	2,31E-05	2,26E-05	4,93E-07	2,19
2	-6,76E-01				
4	-6,85E-01	1,17E-05	1,18E-05	-5,62E-08	0,74
6	-6,88E-01	1,07E-05	1,04E-05	2,80E-07	2,47
8	-6,96E-01	8,48E-06	8,56E-06	-7,91E-08	0,94
10	-6,98E-01	8,30E-06	8,43E-06	-1,34E-07	1,66
12	-7,11E-01	8,00E-06	8,38E-06	-3,76E-07	4,68
14	-7,11E-01	8,44E-06	8,38E-06	6,24E-08	0,71
16	-7,12E-01	8,33E-06	8,38E-06	-4,77E-08	0,54
18	-7,13E-01	8,58E-06	8,38E-06	2,00E-07	2,29
20	-7,15E-01	8,62E-06	8,40E-06	2,23E-07	2,61
22	-7,16E-01	8,32E-06	8,42E-06	-9,64E-08	1,1
24	-6,14E-01	7,17E-05	7,17E-05	2,92E-08	0
27	-6,61E-01	3,61E-05	3,64E-05	-3,20E-07	0,76
30	-6,80E-01	1,51E-05	1,54E-05	-2,57E-07	1,83
33	-6,83E-01	1,28E-05	1,34E-05	-6,28E-07	5,19
36	-6,90E-01	9,85E-06	1,01E-05	-2,01E-07	2,03
39	-6,93E-01	9,10E-06	9,20E-06	-9,62E-08	1,09
42	-6,98E-01	8,53E-06	8,50E-06	3,15E-08	0,41
45	-7,11E-01	8,31E-06	8,39E-06	-8,24E-08	1,02
48	-7,11E-01	8,18E-06	8,39E-06	-2,14E-07	2,62
56	-7,14E-01	8,58E-06	8,41E-06	1,72E-07	2,05
60	-7,14E-01	8,58E-06	8,41E-06	1,70E-07	2,04
64	-7,17E-01	8,43E-06	8,46E-06	-3,38E-08	0,44
68	-7,18E-01	8,64E-06	8,50E-06	1,38E-07	1,63
92	-7,28E-01	9,00E-06	9,02E-06	-1,99E-08	0,17
116	-7,33E-01	-8,57E-06	-8,55E-06	-1,97E-08	0,2
140	-7,38E-01	8,71E-06	8,68E-06	3,32E-08	0,38
164	-7,42E-01	8,76E-06	8,65E-06	1,09E-07	1,23
188	-7,46E-01	8,83E-06	8,31E-06	5,19E-07	5,86
212	-7,48E-01				
236	-7,50E-01	8,98E-06	9,31E-06	-3,27E-07	3,6
404	-7,51E-01	1,37E-05	1,23E-05	1,42E-06	10,26
572	-7,50E-01	1,26E-05	1,30E-05	-4,03E-07	3,5
740	-7,40E-01	1,07E-05	1,07E-05	3,46E-09	0,19
908	-7,57E-01	1,04E-05	1,04E-05	9,19E-09	0,27
1580	-7,64E-01	1,71E-05	1,70E-05	9,48E-08	0,63
2252	-7,82E-01				

Tableau (IV.6) : Base de données (taux de corrosion expérimental), taux de corrosion du RNA, erreur et erreur relative.

On constate que :

- 21 parmi les 35 valeurs sont < 2%
- 9 parmi les 35 valeurs sont 2% et 5%
- 4 parmi les 35 valeurs sont 5% et 6%
- 1 valeur >10%.

Le tableau (IV.7) fait ressortir les valeurs prédites ainsi que les erreurs affichées par notre RNA.

Temps d'immersion	E(corrosion)	Taux de corrosion		erreur	Erreur relative
		expérimentale	RNA		
2	-6,76E-01	1,78E-05	1,77E-05	1,00E-07	0,56
212	-7,48E-01	8,66E-06	8,85E-06	-1,91E-07	2,21
2252	-7,82E-01	1,89E-05	1,88E-05	1,00E-07	0,74

Tableau (IV.7): comparaison des résultats prédits.

Constatations :

On constate que l'erreur relative affichée par le modèle que nous avons construit est satisfaisante. La plus grande erreur est 2,21 alors que la plus petite est 0.2.

Déduction :

A partir des données expérimentales, nous avons validé notre modèle, puis nous avons calculé avec succès le taux de corrosion à un instant choisi sans avoir recours au carottage ou à tous autres méthodes destructives, et nous avons obtenu avec précision satisfaisante l'état d'avancement de la corrosion de l'armature, comme il a été souligné au début de cette partie, à partir de la connaissance des données de N potentiels de corrosion avec les temps de mesure correspondants.

CONCLUSION

Conclusion

L'objectif de notre travail est d'apporter une méthode in situ, précise pouvant donner l'état des armatures en acier présent dans un mortier (béton ou argile). En effet la méthode la plus répondu pou cela est la mesure du potentiel de corrosion. Seulement pour avoir plus de précision, on doit recourir a des méthodes supplémentaires plus ou moins qualifié de destructive, tel que le carottage ...etc.

Pour contourner ce problème nous avons proposé l'utilisation des réseaux de neurones artificiels. Nous avons procédé en deux étapes :

Dans un premier temps, nous avons vérifié notre maitrise de l'utilisation de la méthode des réseaux de neurones, en se basant sur deux références. Nous avons comparé les résultats trouvés à ceux des deux auteurs pour les mêmes bases de données.

Dans un deuxième temps, nous avons fait recoure à une base de données obtenue lors d'un programme expérimental

Et nous nous avons montré que :

1- La prédiction du taux de corrosion à partir du potentiel de corrosion et le temps d'immersion a été réalisée avec une précision satisfaisante. Nous avons comparé les erreurs qui sont ressortit de notre calculs à ceux de la littérature.

2-Nous avons montré que la connaissance de N potentiels de corrosion et leurs temps de mesure (immersion) peut donner des informations supplémentaires, sur l'état des armatures, en occurrence le taux de corrosion correspondant au $(N+1)^{ème}$ potentiel mesuré. En d'autre terme, il suffit d'avoir une base de données suffisante (composé d'ancienne mesure de potentiel de corrosion, le temps d'immersion, et d'ancienne valeur du taux de corrosion), relative à une structure donné,et faire la mesure du potentiel de corrosion à un temps donné pour prédire le taux de corrosion de l'armature à ce même moment.

Références bibliographiques

- [1] F. Junod, M. Bornoz, « A la découverte des réseaux de neurones », Yverdon, le 7 juin 2002.
- [2] S. M. Ait cheikh, « Etude, Investigation et conception d'algorithmes de commande appliqués aux systèmes photovoltaïques », thèse de Doctorat d'Etat en électronique, Ecole Nationale Polytechnique, soutenue en Décembre 2007.
- [3] F. Elie, « Conception et réalisation d'un système utilisant des réseaux de neurones pour l'identification et la caractérisation, à bord de satellites, de signaux transitoires de type sifflement », thèse de Doctorat en électronique, Université d'Orléans soutenue le 23 Septembre 1997.
- [4] G. Dreyfus, « les réseaux de neurones », mécanique Industrielle et Matériaux, n°51, Septembre 1998.
- [5] F. Vincent, « Panorama des outils de prédiction en vue de leur application aux énergies renouvelables », rapport de stage de la 1^{ere} année Master, Physique & Ingénierie Conversion des Energies, 3 Mai– 1^{er} Juin 2007.
- [6] G. Dreyfus, M. Martinez, M. Samueldies, M.B. Gordon, F. Badron, S. Thiria, L. Hérault, « réseaux de neurones méthodologie et application », Ed Eyrolles, 2002.
- [7] O. Benzaim, « Techniques multi-port pour la conception et la réalisation de systèmes micro-ondes dédiés à l'évaluation non destructive de matériaux », thèse de Doctorat en micro et nano technologies, acoustique et télécommunications, Université Lille 1 sciences & technologies, soutenue le 7 Juillet 2009.
- [8] M. Parrizeau, « Réseaux de neurones », presse de l'université de Laval, Automne 2004.
- [9] M.T. Hagan, H.B. Demuth, M. Beale, « Neural network design», PWS Publishing, Boston, 1996.
- [10] G. Foggia, « Pilotage optimal de système multi-sources pour le bâtiment », thèse de Doctorat en Génie Electrique, Institut polytechnique de Grenoble, soutenue le 17 Juillet 2009.
- [11] M.T. Hagan, H.B. Demuth, M. Beale, « Neural Network Toolbox™ 6, User's Guide», Copyright, The MathWorks, Inc, 1992–2009.
- [12] A. Mellit, «sizing of a stand-alone photovoltaic system based on neural networks and genetic algorithms: application for remote areas», journal of electrical & electronics engineering, 2007.
- [13] Y Lee, S.H Oh, M W Kim, « The Effect of Initial Weights on Premature Saturation in Back-Propagation Learning », International Joint Conference on Neural Networks, 1, 765-770, 1991
- [14] Y. OUSSAR, « Réseaux d'ondelettes et réseaux de neurones pour la modélisation statique et dynamique de processus », thèse de Doctorat en robotique, Université Paris VI, soutenue le 06 Juillet 1998.
- [15] L.T.Grujic, « Réseaux de neurones et systèmes flous. Notes de cours», Belfort.1995

- [16] K. Hornik, M. Stinchcombe, H. White, P. Auer, « Degree of approximation results for feed forward networks approximating unknown mappings and their derivatives», *Neural Computation*, 6, 1262-1275, 1994.
- [17] S. Bensaada - Effet Des Inhibiteurs De Corrosion Sur Le Comportement De L'acier Pour Armature a Béton En Milieu Oxydant NaCl. Laboratoire de recherche en Hydraulique Souterraine et de Surface LARHYSS Université Mohamed Khider, 07004 Algérie.
- [18] Marc Grumbach; la corrosion des aciers; technique de l'ingénieur ; 2004
- [19] D. Landolt, vol 12 de traité des matériaux. CEFRACOR 4^{eme} Partie Les Différentes Formes De Corrosion Aqueuse, Presses Polytechnique et Universitaire Romandes, 1993.
- [20] Dieter Landolt, chimie de surfaces des métaux Presses Polytechnique et Universitaires Romandes.
- [21] VINCENT LAPOINTE, INITIATION ET PROPAGATION DE LA CORROSION DANS UN ÉLÉMENT DE BÉTON ARMÉ ,2009
- [22] Vervisch-Fortuné isabelle , sensibilité de la technique acoustique a la corrosion des armatures dans le béton, université de Toulouse, 2009.
- [23] C.GABERIELLI, H.TAKENOUTI, Méthodes électrochimiques appliquées a la corrosion, technique de l'ingénieur 2010.
- [24] Y.F. Wen et al Corrosion rate prediction of 3C steel under different seawater environment by using support vector regression *Corrosion Science* 51 (2009) 349–355.
- [25] Óscar Martín et al Artificial neural networks for pitting potential prediction of resistance spot welding joints of AISI 304 austenitic stainless steel *Corrosion Science* 52 (2010) 2397–2402.
- [26] V.Andronova, (Utilisation de données météo et des réseaux de neurones pour la prédiction de vitesses de vent), université technique de Sofia, 2006.
- [27] Y. Jiang, (prediction of monthly mean daily diffuse solar radiation using artificial neural networks and comparison with other empirical models), *Energy Policy* 36, 3833-3837,2008.
- [28] TRAHI Fatiha, Prédiction de l'irradiation solaire globale pour la région de Tizi-Ouzou par les réseaux de neurones artificiels. Application pour le dimensionnement d'une installation photovoltaïque pour l'alimentation du laboratoire de recherche LAMPA. Université Mouloud Mammeri de Tizi-Ouzou,2011.
- [29] R. Stratfull - Half-cell potentials and the corrosion of steel in concrete. *Highway Res Rec* 1973:433

Annexes

Annexes

ANNEXE A

A.1. Algorithme d'apprentissage de la rétro-propagation du gradient de l'erreur:

L'algorithme de rétro-propagation repose sur la minimisation de l'erreur quadratique entre les sorties calculées et celles désirées. Le critère de performance à minimiser peut être alors exprimé par :

$$E_N = \frac{1}{2} \sum_{j=1}^{N^L} [u_j^L(k) - u_j^{d.L}(k)]^2 \quad (\text{A.1})$$

$E_N(k)$: Valeur du critère d'erreur.

$u_j^L(k)$: Valeur de la sortie du réseau.

$u_j^{d.L}(k)$ Valeur désirée correspondante à $u_j^L(k)$.

L'adaptation des poids se fait par la méthode du gradient basée sur la formule itérative suivante :

$$w_{ji}^L(k+1) = w_{ji}^L(k) - \eta \Delta w_{ji}^L(k) \quad (\text{A.2})$$

$$\Delta w_{ji}^L(k) = \frac{\partial E_N(k)}{\partial w_{ji}^L(k)} \quad (\text{A.3})$$

Où η est le taux d'apprentissage.

Pour un poids arbitraire dans la couche l, le gradient $\frac{\partial E_N(k)}{\partial w_{ji}^l(k)}$ Peut être calculé par la règle de chaînage :

$$\frac{\partial E_N(k)}{\partial w_{ji}^l(k)} = \frac{\partial E_N(k)}{\partial u_j^l(k)} \frac{\partial u_j^l(k)}{\partial w_{ji}^l(k)} \quad (\text{A.4})$$

Le deuxième terme de l'expression (A.4) peut être exprimé par :

$$\frac{\partial u_j^l(k)}{\partial w_{ji}^l(k)} = \frac{\partial f(S_j^l(k))}{\partial S_j^l(k)} \frac{S_j^l(k)}{\partial w_{ji}^l(k)} \quad (\text{A.5})$$

Le premier terme dans (A.5) correspond à la dérivée de la fonction d'activation. Si on utilise la fonction sigmoïde donnée par l'expression (I.6), sa fonction dérivée est exprimée par :

$$f'(S_j^l) = f(S_j^l)(1 - f(S_j^l)) = u_j^l(1 - u_j^l) \quad (\text{A.6})$$

Le deuxième terme dans (A.5) peut être facilement calculé, si on utilise l'expression (I.8)

$$\frac{\partial S_j^l(k)}{\partial w_{ji}^l(k)} = u_i^{l-1} \quad (\text{A.7})$$

Annexes

L'expression (A.5) sera :

$$\frac{\partial u_j^l(k)}{\partial w_{ji}^l(k)} = u_j^l(1 - u_j^l)u_i^{l-1} \quad (\text{A.8})$$

Calcul du premier terme de (A.4) :

- Pour la couche de sortie on a :

$$\frac{\partial E_N(k)}{\partial u_j^L(k)} = u_j^L(k) - u_j^{d,L}(k) = \delta_j^L(k) \quad (\text{A.9})$$

Où $\delta_j^L(k)$ est l'erreur sur la sortie du j^{ème} neurone dans la couche de sortie L.

- Pour les couches cachées :

$$\frac{\partial E_N(k)}{\partial u_j^l(k)} = \sum_{m=1}^{N^{l+1}} \frac{\partial E_N(k)}{\partial u_m^{l+1}} \frac{\partial u_m^{l+1}}{\partial u_j^l(k)} \quad (\text{A.10})$$

Le terme $\frac{\partial E_N(k)}{\partial u_j^l(k)}$ peut s'écrire comme suit :

$$\frac{\partial u_m^{l+1}}{\partial u_j^l(k)} = \frac{\partial f(S_m^{l+1}(k))}{\partial S_{jm}^{l+1}(k)} \frac{\partial S_{jm}^{l+1}(k)}{\partial u_j^l(k)} = u_m^{l+1}(k)[1 - u_m^{l+1}(k)]w_{mj}^{l+1}(k) \quad (\text{A.11})$$

En substituant (A.11) dans (A.10), on écrit :

$$\frac{\partial E_N(k)}{\partial u_j^l(k)} = \sum_{m=1}^{N^{l+1}} \delta_m^{l+1}(k) \cdot w_{mj}^{l+1}(k) \cdot u_m^{l+1}(k) [1 - u_m^{l+1}(k)] \quad (\text{A.12})$$

Cette expression nous permet de calculer les erreurs, de la sortie vers l'entrée, couche par couche. D'où l'appellation algorithmique de la **rétro-propagation** du gradient. En remplaçant (A.8) et (A.12) dans (A.4), et en posant

$$\frac{\partial E_N(k)}{\partial u_j^l(k)} = \delta_j^l(k) \quad (\text{A.13})$$

On obtient la valeur du gradient $\frac{\partial E_N(k)}{\partial u_j^l(k)}$ correspondant à chaque poids synaptique w_{ji}^l .

$$\frac{\partial E_N(k)}{\partial w_{ji}^l(k)} = \delta_j^l(k) u_j^l(k) [1 - u_j^l(k)] u_i^{l-1}(k) \quad (\text{A.14})$$

En remplaçant (A.14) dans (A.3)

$$\Delta w_{ji}^l(k) = \delta_j^l(k) u_j^l(k) [1 - u_j^l(k)] u_i^{l-1}(k) \quad (\text{A.15})$$

Annexes

Les poids seront adaptés suivant l'expression :

$$w_{ji}^l(k+1) = w_{ji}^l(k) - \eta \Delta w_{ji}^l(k) \quad (\text{A.16})$$

A.2. Calcul de la matrice Jacobéenne :

Pour les réseaux de neurones MLP, les éléments de la matrice Jacobéenne peuvent être calculés par une simple modification de l'algorithme de la rétro-propagation du gradient de l'erreur. Pour créer la matrice jacobéenne, on a besoin de calculer les dérivées premières des erreurs au lieu des erreurs quadratiques comme c'est le cas pour la rétro-propagation. Il faut noter que, pour chaque entrée appliquée au réseau il y'aura N^L erreurs à la sortie; un pour chaque neurone de sortie du réseau, et à chaque erreur correspondra une ligne dans la matrice jacobéenne.

Le processus de la rétro-propagation permet de calculer les erreurs, de la sortie vers l'entrée, couche par couche selon une relation de récurrence, on peut utiliser le même concept pour calculer les éléments de la matrice jacobéenne.

La seule différence est dans le calcul du gradient $\frac{\partial E_N(k)}{\partial w_{ji}^l(k)}$ pour la couche de sortie.

Dans ce cas l'équation (A.9) sera égale à:

$$\frac{\partial E(k)}{\partial u_j^l(k)} = \delta_j^l(k) = 1 \quad (\text{A.17})$$

On utilise simplement l'équation (A.14) pour le calcul des éléments de la matrice jacobéenne.

Annexes

ANNEXE B

Propriétés fondamentales des réseaux de neurones formels :

Les principales propriétés des réseaux de neurones artificiels sont :

- **Le parallélisme** : Ce concept qui est lié à la conception même des réseaux de neurones permet d'accroître la rapidité de calcul. [15]
- **La capacité d'adaptation** : A partir d'une série d'exemples, un réseau de neurones devra apprendre à retrouver ou à deviner les comportements permettant de résoudre un problème donné. [15]
- **La capacité de généralisation** : Celle-ci se traduit par la capacité d'apprentissage du réseau. Ceci permet aux réseaux de neurones de tenir compte de nouvelles contraintes de données en provenance du monde extérieur. [15]
- **Approximation universelle** : Les réseaux de neurones formels possèdent une propriété remarquable qui est à l'origine de leur intérêt pratique dans des domaines très divers. Cette propriété peut s'énoncer comme suit [6]:

<< Toute fonction bornée suffisamment régulière peut être approchée uniformément, avec une précision arbitraire, dans un domaine fini de l'espace de ses variables, par un réseau de neurones comportant une couche de neurones cachés en nombre fini, possédant tous la même fonction d'activation, et un neurone de sortie linéaire.>>.

Cette propriété justifie l'utilisation de l'architecture présentée dans le chapitre III

- **La parcimonie** : La spécificité des réseaux de neurones réside dans le caractère parcimonieux de l'approximation, Par rapport à d'autres outils de modélisation non-linéaire, les réseaux de neurones atteints l'efficacité la plus grande, avec le minimum de coefficients ajustables.

Dans cette optique, [16] ont montré que :

Si le résultat de l'approximation (c'est-à-dire la sortie du réseau de neurones) est une fonction non linéaire des paramètres ajustables, elle est plus parcimonieuse que si elle est une fonction linéaire de ces paramètres. De plus, pour des réseaux de neurones à fonction d'activation sigmoïdale, l'erreur commise dans l'approximation varie comme l'inverse du

Annexes

nombre de neurones cachés, et elle est indépendante du nombre de variables de la fonction à approcher. Par conséquent, pour une précision donnée, donc pour un nombre de neurones cachés donné, le nombre de paramètres du réseau est proportionnel au nombre de variables de la fonction à approcher.

Ce résultat s'applique aux réseaux de neurones à fonction d'activation sigmoïdale puisque la sortie de ces neurones n'est pas linéaire par rapport aux poids synaptiques.