REPUBLIQUE ALGERIENNE DEMOCRATIQUE ET POPULAIRE

MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE

UNIVERSITE YAHIA FARES DE MEDEA



Faculté de **T**echnologie

Mémoire de fin d'études de Master

Filière : **Electronique**

Spécialité : **Instrumentation**

Etude et Optimisation des Performances d'un Condensateur Plan à Base des Réseaux de Neurones

---

Présenté par :

KERMEZLI Farouk

HENNAB Miloud

Proposé et Dirigé par :

Dr MIMEN Bakhti

Promotion 2019

ملخص

لتحسين جودة وإنتاجية المكونات الإلكترونية، يستحسن على المهندسين تحسين دراساتهم من خلال التحكم في ظروف الإنتاج. المكثفات بالنظر إلى سلوكها وفي مجال استغلال التقنيات الجديدة وبناءً على هذه الافكار، قمنا بإجراء هذه الدراسة التي كان هدفها الرئيسي هو دراسة إمكانية توقع نتائج لخصائص وأداء المكثفات من خلال تحسينها باستخدام الشبكات العصبونية. تم تنفيذ هذا التوقع على أساس الشبكات العصبونية متعددة الطبقات التي يتم تنفيذ فترة التعلم فيها مع خوارزمية الخطأ التراجعي باستعمال برنامج MATLAB . تهدف هذه الشبكة بشكل أساسي إلى توقع سعة المكثف استنادًا إلى خصائصه التقنية، لا سيما قابلية العا زل الكهربائي المستخدم.

Résumé

Pour améliorer la productivité et la qualité des composants électroniques, les ingénieurs doivent optimiser leurs études par une grande maîtrise des conditions de production. Le condensateur, compte tenu de son comportement constitue un champ d'exploitation de nouvelles techniques. Partant de ce constat, nous avons entrepris cette étude dont l'objectif principal est d'étudier la possibilité de prédiction des caractéristiques et des performances des condensateurs par la suite œuvré à son optimisation à l'aide des réseaux de neurones. Cette prédiction a été réalisée sur la base de réseaux de neurones multicouches dont l'apprentissage est effectué avec l'algorithme de rétropropagation du gradient implanté sous langage MATLAB. Ce réseau est destiné essentiellement à la prédiction de la capacité d'un condensateur en partant de ses caractéristiques techniques en particulier la permittivité de son diélectrique utilisé.

Abstract

To improve the productivity and the quality of the electronic components, the engineers must optimize their studies by a hight control of the conditions of production. The capacitor, given its behavior is a field of exploitation of new techniques. Based on this observation, we have undertaken this study whose main objective is to study the possibility of prediction of the characteristics and performances of the capacitors later worked on its optimization using the neural networks. This prediction was performed and based on multilayer neural networks whose learning is performed with the algorithm of back propagation of the gradient in MATLAB. This network is intended essentially to predict the capacitance of a capacitor based on its technical characteristics, in particular the permittivity of its dielectric used.

Remerciements

Au terme de ce travail, nous tenons à remercier en premier lieu le Grand Bon Dieux Miséricordieux qui nous a donné le courage et la volonté pour accomplir ce travail.

Nous tenons à exprimer nos plus grands remerciements à notre promoteur Monsieur Mimen Bakhti qui nous a assisté par ses précieux conseils.

Nos sincères remerciements vont également à tous les enseignants de la promotion Instrumentation 2019

Nos vifs remerciements vont également à tous les membres de jury qui nous ont fait l'honneur de juger notre modeste travail.

Nous tenons également à remercier toutes les personnes qui nous aidés de près ou de loin pour venir à terme de ce travail.

Farouk & Miloud

Dédicaces

Je dédie ce modeste travail à :

A mes très chers parents

A la femme de ma vie

A Tasnim, Mohamed Baraa, Mohamed Abdessalem, mes très chers enfants

A mes chers frères et sœurs

A mon binôme Miloud

A mes chers amis

A tous mes camarades de la promotion Instrumentation 2019

A tous les enseignants qui nous ont encadrés durant l'année universitaire 2018/2019.

Farouk

Je dédie ce modeste travail à :

A ma chère femme

A mon très chers bijou, ma fille Wissam

A mes chers frères, sœurs et toute la famille

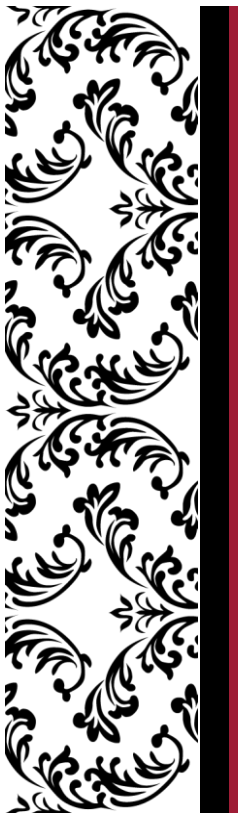
A mon binôme Farouk

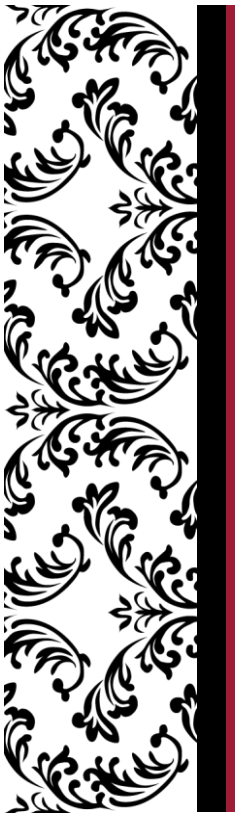
A mes chers amis

A tous mes camarades de la promotion Instrumentation 2019

A tous les enseignants qui nous ont encadrés durant l'année universitaire 2018/2019.

Miloud






SOMMAIRE

INTRODUCTION GENERALE……...……..….. 01

Chapitre I : GENERALITE SUR LES CONDENSATEURS

I.1 Introduction ……...……..02

I.2. Propriétés générales des condensateurs ……..……03

I.2.1. Stockage d'énergie (capacité) ……...……...04

I.2.2. Caractéristiques électriques ……..……...05

I.2.2.1. Schémas électriques ……...……...05

I.2.2.2 Influence de la température ……..……..09

I.2.2.3 Courant de fuite et résistance d'isolement …….…….……...09

I.2.2.4 Comportement de charge/décharge …….……...09

I.2.2.5.Rigiditédiélectrique…….....10

I.2.2.6.Dissipation de l'énergie ……10

I.2.2.7. Inductance …….……...10

I.2.3. Les type des condensateurs ……...……..12

a. Les condensateurs à Film ……....……..…...…12

b. Les condensateurs Céramique ……..…….……..12

c. Les condensateurs électrolytique …….……....……13

d. Les Supercondensateurs ….…….……..14

e. Les condensateurs Mica…….16

f. Les condensateurs en verre…….16

g. Les condensateurs à traversée..……...……..…….17

I.3 Conclusion ....……..…….....17

Chapitre II : LES RESEAUX DE NEURONES

II.1 Introduction ……. …….……18

II.2. Principe de fondement biologique …….……19

II.3. Le connexionnisme et les réseaux de neurones formels ……..…….....20

II.3.1. Définition ……..…….20

II.3.2. Neurone artificiel ……22

II.3.2.1. Modèle d'un neurone ……...…..…… 22

I.3.2.2. Fonctions d'activations ……...…… 24

II.3.3. Architecture de réseau ……..…..... 25

II.3.4. Structure d'interconnexion (topologie) ……..…… 27

II.3.4.1. Réseau multicouches ……..…… 27

II.3.4.2. Réseau à connexions locales ……..……. 28

II.3.4.3. Réseau à connexions récurrentes ……....…… 28

II.3.4.4. Réseau a connexions complexes ……..……..…..… 29

II.4. Apprentissage ……..…….…..... 29

II.4.1. Généralités sur l'apprentissage …….. 29

II.4.2. Principe général ……..…….…... 30

II.4.3. Apprentissage d'un réseau de neurones …… ..……..…. 31

II.4.3.1. L'apprentissage supervisé ……...…… 31

II.4.3.2. L'apprentissage non supervisé …….....……. 32

II.4.3.3. L'apprentissage par renforcement …….…….. 32

II.4.4. L'apprentissage des réseaux de neurones formels ……...……..…. 33

II.4.5. Règles d'apprentissage ……..…… 33

II.4.5.1. La règle de Hebb ……..……... 34

II.4.5.2. La règle de Widrow- Hoff ……..……..… 34

II.4.6. La rétro propagation du gradient ……..……..…. 34

II.4.6.1. Principe ……..……....…… 34

II.4.6.2. Algorithme ……..……..... 35

II.5. Mise en œuvre des réseaux de neurones et domaine d'applications ……...…….. 37

II.6. Conclusion ……..…….. 38

Chapitre III : SIMULATIONS ET RESULTAS

III.1. Introduction …….....…….…….. 39

III.2. Condensateur Plan ……..……... 40

III.3. Base de données d'apprentissage (Deffine pattern) ……..…..…. 40

III.4. Architecture du réseau …….…… 41

III.4.1. Les entrées ……...……..... 42

III.4.2 Les couches cachées ……...……... 42

III.4.3 Les sorties ……..…… 42

III.4.4 Les poids ……...……...…….. 42

III.4.5 la fonction de transfert ……...…….….. 42

III.5. Algorithme de rétro-propagation du Gradient……. 43

III.6 Application et Résultats……...……...…. 44

III.6.1 Application ……...……... 44

III.6.2 Résultats …….....……... 46

III.7. Conclusion…….……. 49

CONCLUSION GENERALE ……....…… 50

INTRODUCTION :

Les méthodes de mise en œuvres des circuits électroniques avec les performances soit disant les plus optimales sont basées essentiellement sur leurs caractéristiques techniques et sur l'expérience pendant les phases expérimentales ou d'exploitation pour prédire les performances futures des divers composants des circuits en question.

Les nouvelles technologies apportent à la conception des produits, des méthodes et des informations qui permettent de faire mieux qu'avant et surtout, de prévoir le comportement futur d'un matériel ou d'un composant.

Les performances des composants qu'elles soient définies par le constructeur, l'exploitant ou les deux, sont un facteur prépondérant dans la qualité des matériels et la détermination des coûts d'exploitation.

L'objectif de la prédiction des performances consiste à diagnostiquer les possibles états futurs dans lesquels un composant peut évoluer. Alors, une fois les états futurs identifiés, le pronostic nous permettra aussi d'estimer le temps de vie restant d'un système à partir de son état actuel jusqu'à un état défaillant.

L'aspect prédictif universel des réseaux de neurones et leur capacité à s'adapter au comportement désiré permettent d'élargir leurs utilisations pour l'identification, la prédiction et la commande des systèmes.

En interaction avec les paramètres environnementaux externes il est plus que souhaitable d'encourager le développement de divers techniques pour prédire et simuler des variables afin de gérer le comportement d'un composant électronique de manière efficace.
Les réseaux de neurones artificiels constituent l'une des approches d'intelligence artificielle dont le développement se fait à travers les méthodes par lesquelles l'homme essaye toujours d'imiter la nature et de reproduire des modes de raisonnement et de comportement qui lui sont propres.

Dans cette optique, notre Travail se devise en trois parties, entamé par une introduction aux généralités des condensateurs et leurs différentes technologies ainsi que leurs performances, on a défiler par la suites les réseaux de neurones en passant par leurs différentes structures et architectures, et aux terme de ce travail, une simulation des calculs et prédictions de la capacité d'un condensateur Plan en se basant sur les caractéristiques du condensateur en question.

CHAPITRE I

Généralité sur Les Condensateurs

I.1 Introduction :

Les condensateurs sont utilisés dans de nombreux domaines de l'électronique, leurs utilisations principales sont les suivantes [1, 2, 3] :

- Stockage d'énergie (sauvegarde de données, protection de systèmes…).
- Correction du facteur de puissance.
- Régulation de la tension de sortie des alimentations à découpage.
- Filtrage d'entrée ou de sortie des convertisseurs statiques.
- Réduction des impédances des lignes.
- Protection, démarrage des moteurs électriques.

Les contraintes électriques, thermiques et mécaniques liées à l'utilisation de ses composants sont très diverses. Il existe donc différents types de condensateurs qui permettent de couvrir l'ensemble des besoins des utilisateurs. Les paramètres technologiques sur les matériaux et les dimensions d'un composant ont une influence importante sur son fonctionnement et ses caractéristiques. Le choix d'un condensateur le mieux adapté au système peut s'avérer très important car il est responsable dans certaines applications de la plupart des défaillances [4]. On peut distinguer trois principaux types de condensateurs qui couvrent l'ensemble des besoins des utilisateurs :

- Les condensateurs à films plastique ou papier
- Les condensateurs céramiques, mica ou verre
- Les condensateurs électrolytiques à l'aluminium ou au tantale

Les deux principaux facteurs à prendre en compte pour le choix d'un type de condensateur sont : la capacité et la tension d'utilisation du composant. La Figure I-01 et 1-02 représentent les ordres de grandeur de capacité et tension en fonction du type de technologie des différents condensateurs présents sur le marché.

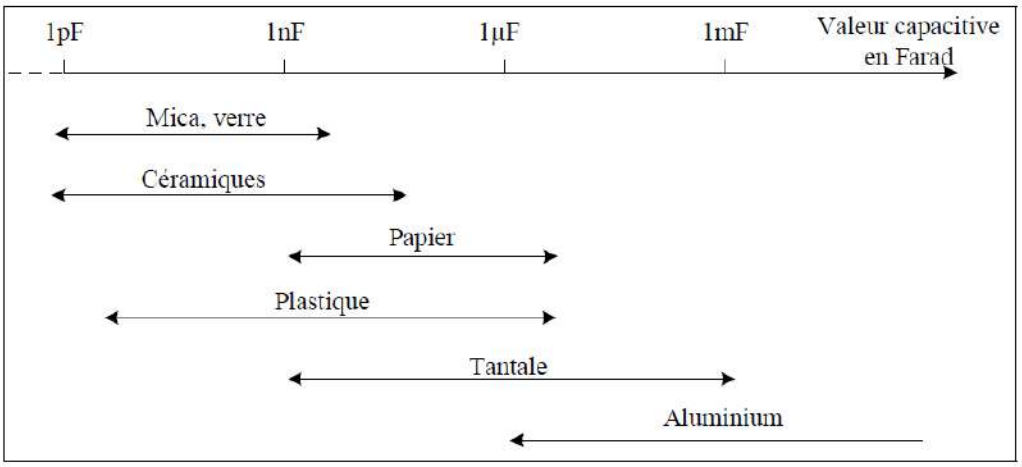


Figure I-1 : Famille de condensateur en fonction de leur capacité.

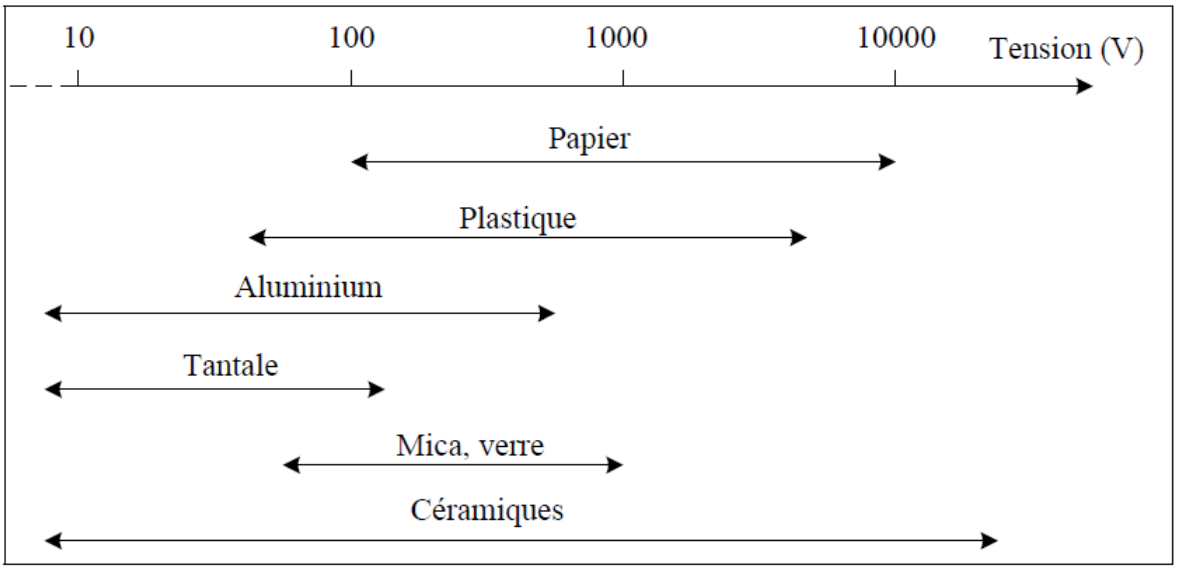


Figure I-2 : Gamme de tension nominale pour différentes familles de condensateurs.

La capacité utilisable d'un condensateur peut différer de sa valeur nominale en raison de plusieurs facteurs. Notamment :

- Température
- Humidité
- Tension AC/DC
- Fréquence du signal
- Âge du condensateur
- Caractéristiques mécaniques
- Effet piézoélectrique

Lors du choix d'un condensateur pour une application, il faut tenir compte de ses caractéristiques nominales pour ces facteurs.

I.2. Propriétés générales des condensateurs :

Un condensateur est un dispositif pouvant stocker de l'énergie électrostatique. Il est composé de deux plaques conductrices (électrodes) séparées par un matériel isolant (diélectrique). Quand une différence de potentiel est appliquée entre les deux plaques conductrices, une charge électrique proportionnelle à la tension appliquée et à la capacité s'accumule dans le condensateur.

I.2.1. Stockage d'énergie (capacité) :

L'énergie stockée E pour un condensateur de capacité C_{AK} entre anode et cathode sous une tension U est :

$$E = \frac{1}{2} Q.U = \frac{1}{2} C_{AK}.U^2 \qquad (1\text{-}1)$$

La figure ci-dessous représente un condensateur plan idéal :

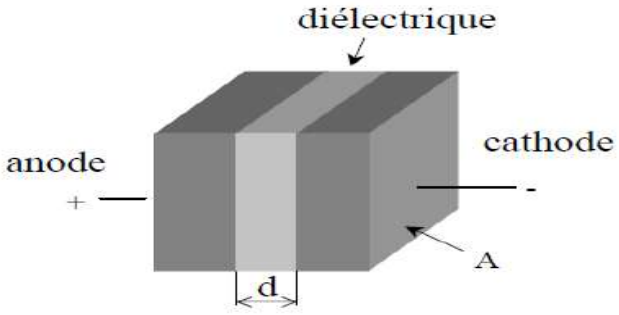


Figure I-3 : Condensateur plan idéal.

La valeur de la capacité C_{AK} est directement proportionnelle à la surface de l'anode et inversement proportionnel à l'épaisseur du diélectrique :

$$C_{AK} = \varepsilon_0.\varepsilon_r.\frac{A}{d} \qquad (1\text{-}2)$$

Avec : ε_0 = permittivité absolue du vide ($\varepsilon_0 = 8{,}854.10^{-12} F/m$)

ε_r = permittivité relative du diélectrique (sans dimension)

A = surface de contact anode-diélectrique en m²

d = épaisseur du diélectrique en m.

La valeur de la capacité d'un condensateur dépend donc fortement de la valeur de la constante diélectrique du matériau isolant utilisé et de l'épaisseur de ce celui-ci. Une autre des caractéristiques essentielles du diélectrique est sa tenue en tension fonction de son épaisseur.

Le tableau I-1 donne les valeurs de la constante diélectrique (ε_r) ainsi que de la rigidité diélectrique (e_v) de différents matériaux utilisés pour la fabrication des condensateurs. Pour certains matériaux la rigidité diélectrique n'est pas toujours linéaire en fonction de l'épaisseur [5].

Les contraintes technologiques dues aux matériaux et à la fabrication des condensateurs imposent des limitations sur l'épaisseur du diélectrique et sur sa tenue en tension.

Type de condensateur	Matériaux diélectriques	Constante diélectrique ε_r	Rigidité diélectrique e_v (kV/cm)
Air	Air	1,00059	21
Film	Plastique	2,1 à 6	600 à 4500
	Papier	2 à 6	300 à 600
Electrolytique	Aluminium Oxyde d'alumine (AL_2O_3)	8 à 10	6600 à 7700
	Tantale Oxyde de tantale (Ta_2O_3)	10 à 26	6600 à 10000
Verre, Mica, Céramique	Verre	4,8 à 9,9	100 à 400
	Mica	5,4 à 8,7	600 à 1800
	Céramique	12 à 20000	200 à 400

Tableau I-1 : Constante et rigidité diélectrique des principaux matériaux utilisés pour la fabrication des condensateurs.

- Les condensateurs à air sont peu utilisés actuellement.
- Les condensateurs à film ont un bon comportement aux courants et tensions élevés.
- Les condensateurs électrolytiques possèdent une épaisseur de diélectrique faible donc une capacité volumique élevée. Par contre, leurs caractéristiques sont fortement dépendantes de la température et du temps de vieillissement.

Les condensateurs céramiques peuvent avoir une très forte valeur de permittivité relative mais ne peuvent posséder des couches fines de diélectrique. De plus leur tenue en température est mauvaise. Notons qu'il existe trois classes différentes en fonction de la constante diélectrique.

Les condensateurs au mica utilisés pour les faibles valeurs de capacité ont une très bonne tenue en température. Ils sont parfois remplacés par les condensateurs au verre compte tenu de leurs coûts.

I.2.2. Caractéristiques électriques :

I.2.2.1. Schémas électriques :

Le schéma équivalent d'un condensateur peut être mis sous différentes formes.
Un des modèles les plus utilisé est représenté sur la Figure I-04 :

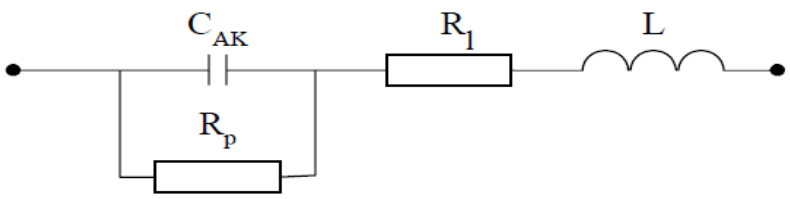


Figure I-4 : Schéma équivalent d'un condensateur.

Avec :

C_{AK} = capacité idéale entre anode et cathode

R_p = résistance parallèle représentant les pertes dans le diélectrique

R_l = résistance série des connexions des armatures et de l'électrolyte

L = inductance équivalente série des connexions et des enroulements.

La capacité C_{AK} est fonction de la constante diélectrique ainsi que de la surface des électrodes et de l'épaisseur du matériau diélectrique employé. Elle dépend principalement de la température et de la tension.

La résistance R_p varie en fonction de la tension appliquée à ses bornes et de la température.

La résistance R_l ainsi que l'inductance L varient en fonction de la température.

Nous pouvons simplifier ce schéma selon la représentation normalisée de la Figure I-05 qui ne prend pas en compte la résistance R_p représentant principalement le courant de fuite :

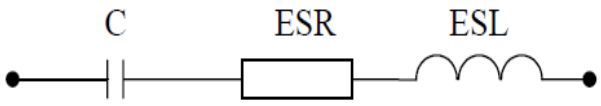


Figure I-5 : Schéma équivalent série simplifié du condensateur.

Avec :

C = capacité.

ESR = résistance équivalente série représentant toutes les pertes dans le composant.

ESL = inductance équivalente série.

Ces trois valeurs sont dépendantes de la fréquence ainsi que de la température du condensateur.

Ce modèle est utilisé pour un fonctionnement en filtrage, c'est aussi le modèle définissant les valeurs nominales du condensateur [5].

L'identification des impédances (Z_a Impédance schéma série et Z_b Impédance schéma parallèle) des deux schémas équivalents précédents nous permet d'établir les relations suivantes entre les paramètres :

$$\boldsymbol{Z_a = \frac{R_l + R_p + R_l.R_p^2.C_{AK}^2.\omega^2}{1 + C_{AK}^2.R_l^2.\omega^2} + j.\frac{L\omega - C_{AK}.R_p^2.\omega. + L.C_{AK}^2.R_p^2.\omega^2}{1 + C_{AK}^2.R_p^2.\omega^2}} \qquad (1\text{-}3)$$

$$\boldsymbol{Z_b = ESR + j.\left(ESL.\omega - \frac{1}{C.\omega}\right)} \qquad (1\text{-}4)$$

$$\boldsymbol{C = C_{AK} + \frac{1}{C_{AK}.\omega^2.R_p^2}} \qquad (1\text{-}5)$$

$$\boldsymbol{ESR = R_l + \frac{R_p}{1 + C^2.\omega^2.R_p^2}} \qquad (1\text{-}6)$$

$$\boldsymbol{ESL = L} \qquad (1\text{-}7)$$

ω étant la pulsation électrique.

En négligeant *ESL*.ω, on exprime aussi un autre paramètre qui est la tangente de l'angle de perte définie par :

$$\boldsymbol{\tan\delta = ESR.C.\omega} \qquad (1\text{-}8)$$

Le diagramme de Fresnel représenté sur la Figure I-06 indiquant l'angle de perte **δ** :

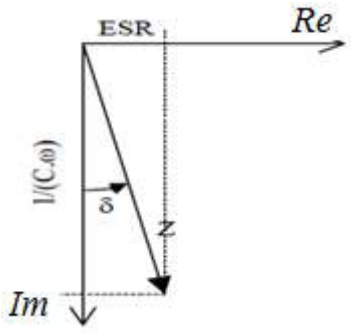


Figure I-6 : Diagramme de Fresnel.

Pour effectuer la caractérisation en fréquence d'un condensateur, on peut négliger la résistance R_p si sa valeur et la fréquence de mesure sont suffisamment grandes.

La Figure I-07 montre l'influence de R_p en fonction de la fréquence sur les valeurs de C et ESR pour un condensateur électrolytique ayant une capacité nominale de 4,7mF et une résistance équivalente série nominale de 20mΩ.

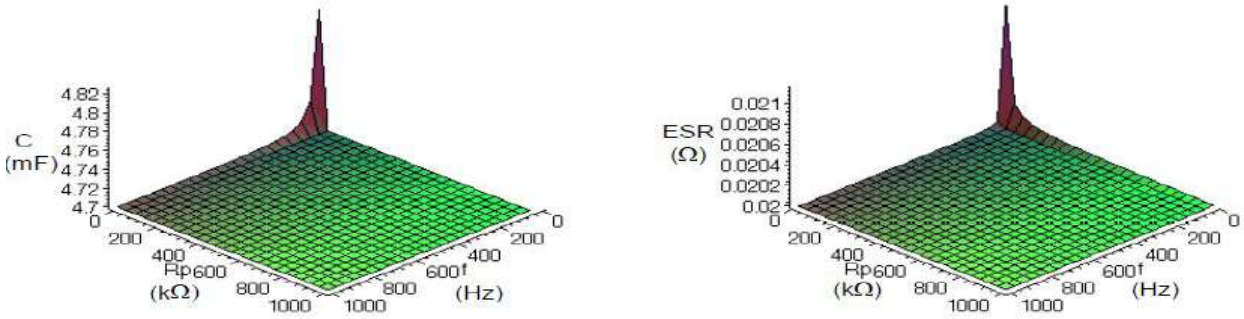


Figure I-7 : Influence de R_p en fonction de la fréquence f sur C et ESR. [5].

Les deux graphiques ci-dessus montrent que suivant les valeurs du couple R_p, f, l'approximation selon la Figure I-6 est valable pour les mesures en fréquence.

La résistance R_p représentant la résistance d'isolement du condensateur est fonction de la tension continue à ses bornes, de la température et du temps de polarisation. Cette résistance induit un courant appelé courant de fuite qui dépend des mêmes paramètres. Les ordres de grandeurs de ce courant sont variables selon le type de diélectrique et la technologie du condensateur.

Pour une utilisation des condensateurs en stockage d'énergie, le schéma équivalent de la Figure I-04 peut être simplifié par le schéma de la Figure I-08. L'inductance L peut être négligée ainsi que la résistance R_l petite devant R_p. C'est le schéma utilisé en continu.

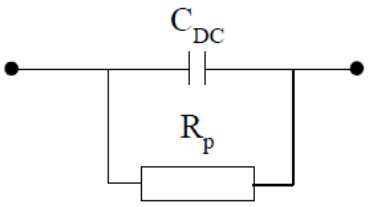


Figure I-8 : Schéma équivalent simplifié en continu

Avec : C_{DC} = capacité continue ($C_{DC} \approx C_{AK}$).

Rp = résistance parallèle représentant les pertes dans le diélectrique.

I.2.2.2 Influence de la température :

Les principales caractéristiques des condensateurs sont en général dépendantes de la température, de la fréquence et de la tension. La dépendance à la température est très variable selon le type de diélectrique et la technologie de fabrication du composant. Par exemple pour les condensateurs électrolytiques les températures d'utilisation sont limitées par l'électrolyte et non par le diélectrique. Les valeurs de températures minimum et maximum d'utilisation sont fixées selon deux critères : la tenue des matériaux aux températures spécifiées et les limites de variation des valeurs électriques du composant.

I.2.2.3 Courant de fuite et résistance d'isolement :

Les matériaux diélectriques des condensateurs ne sont pas des isolants idéaux ; ils peuvent laisser passer un faible courant continu de fuite pour diverses raisons spécifiques à chaque type de diélectrique. La tension aux bornes d'un condensateur chargé chutera lentement à mesure que le courant de fuite évacuera sa charge.

En général, la résistance d'isolement tend à diminuer à mesure que les valeurs de capacité augmentent. Le courant de fuite augmente avec la hausse de la température.

La relation entre le courant de fuite (LC) et la résistance d'isolement (IR) du diélectrique du condensateur est donnée par la formule simple :

$$\mathbf{I(LC) = V/R(IR)} \qquad (1\text{-}9)$$

I.2.2.4 Comportement de charge/décharge :

Lorsqu'une tension continue est appliquée à un condensateur en série avec une résistance, le condensateur se charge à une vitesse déterminée par la tension appliquée, l'état de charge par rapport à sa valeur finale, la résistance série ainsi que sa propre capacité. Le produit résistance-capacité, RC, est connu comme la constante de temps du circuit. Pour être précis, la constante de temps RC est le temps nécessaire pour charger le condensateur à 63,2 % [5] de la différence entre les valeurs initiale et finale. La même valeur RC régit également le temps nécessaire pour décharger le condensateur à travers la résistance série.

I.2.2.5. Rigidité diélectrique :

Si la tension à travers un condensateur est trop élevée, le champ électrique finira par provoquer la rupture du diélectrique et par conduire le courant. Avec certains diélectriques, l'effet est permanent, donc le condensateur est détruit.

Certains diélectriques, cependant, peuvent se réparer seuls. Par exemple, les condensateurs à film et à papier avec des électrodes très minces peuvent se réparer seuls lorsque l'important courant de claquage réchauffe les couches d'électrodes, ce qui provoque l'évaporation et l'oxydation des métaux loin de la zone affectée, isolant ainsi le chemin du court-circuit du reste du condensateur. Ce processus peut se produire même dans des applications à très haute puissance pouvant atteindre plusieurs kilowatts.

I.2.2.6. Dissipation de l'énergie :

Lorsqu'une tension alternative est appliquée dans un condensateur, le courant circule à travers son matériau diélectrique et ses parties conductrices. En pratique, une partie de ce courant est dissipée dans la faible résistance du condensateur. Cette dissipation se manifeste par une augmentation de la température du condensateur. La résistance globale du condensateur, appelée résistance série équivalente (ESR), est la somme de deux éléments :

- Résistance du matériau diélectrique
- Résistance des pièces conductrices

I.2.2.7. Inductance

Les électrodes et les fils de raccordement ou les terminaisons d'un condensateur sont des conducteurs métalliques, auxquels est associée une certaine inductance. Cette inductance a tendance à résister aux variations du courant alternatif à travers le condensateur. Elle est connue sous le nom d'inductance série équivalente ou ESL.

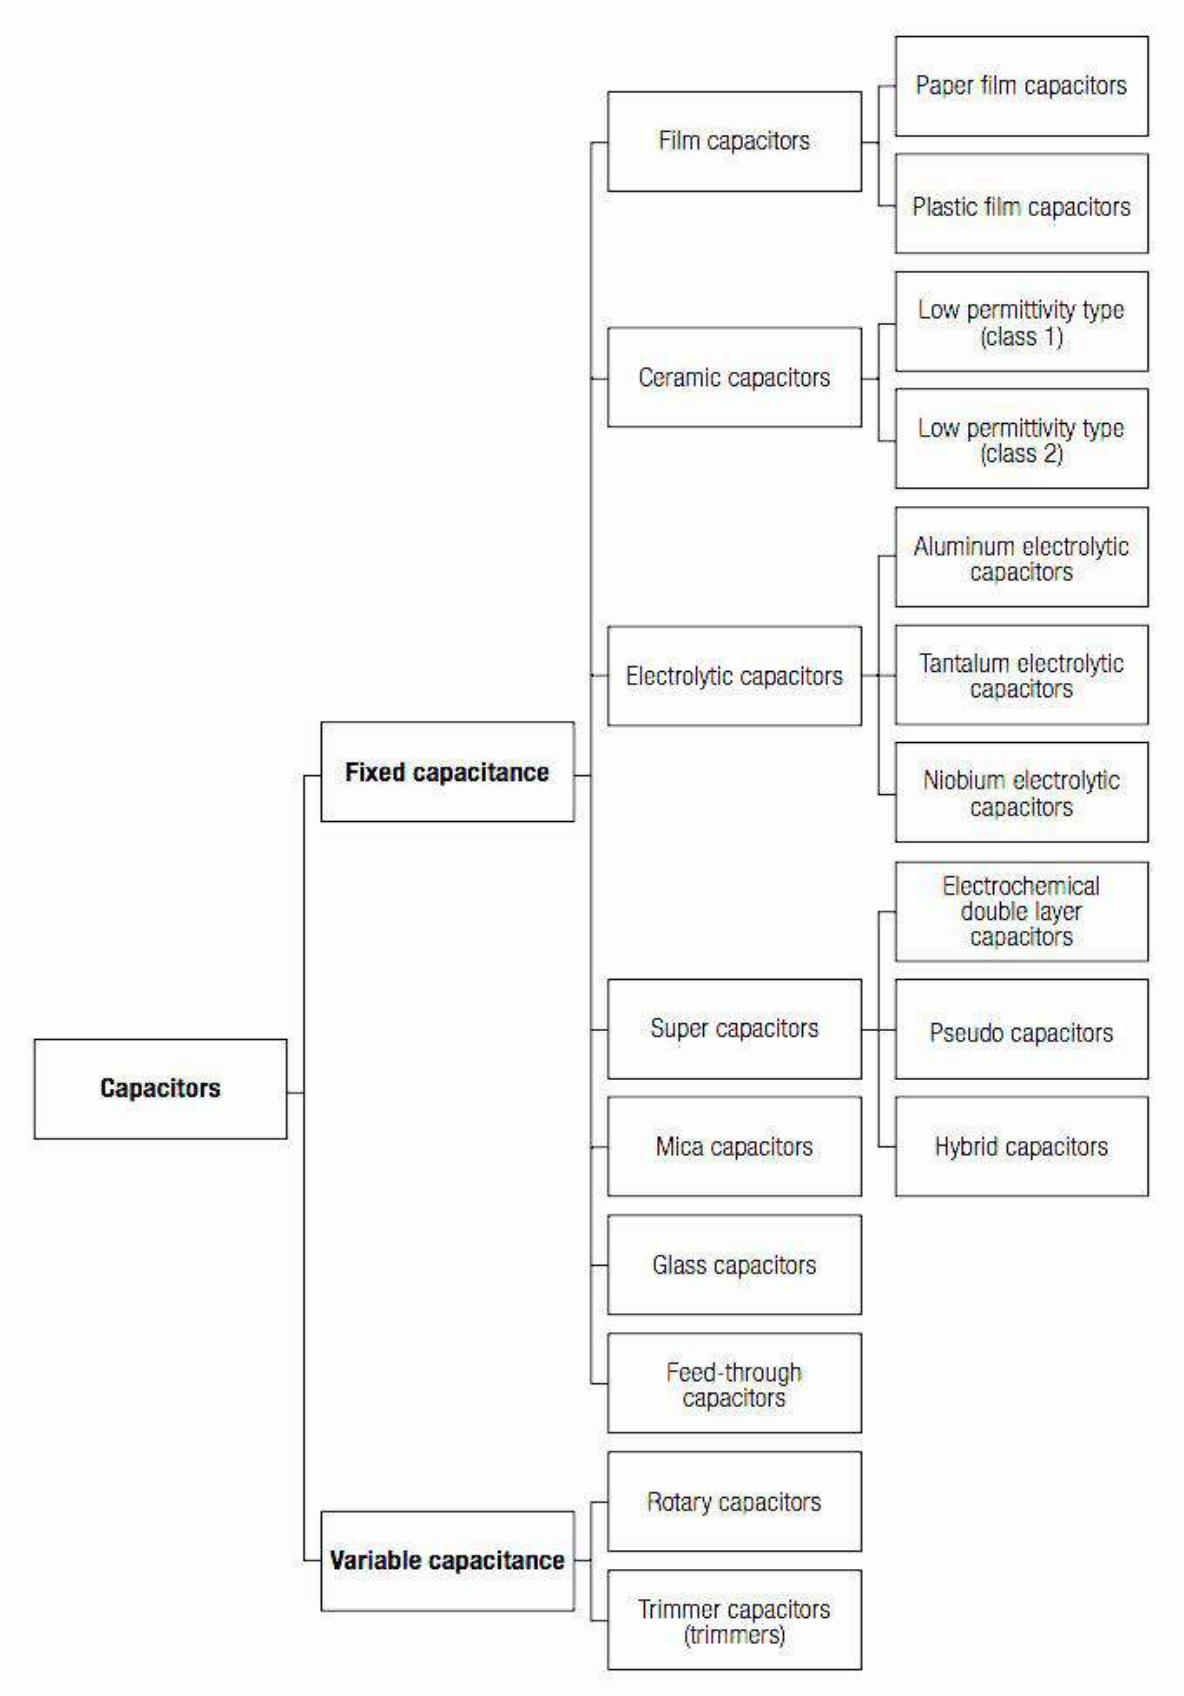


Figure I-9 : Hiérarchie des types de condensateurs [2]

I.2.3. Les type des condensateurs :

a. Les condensateurs à Film :

Les condensateurs à film utilisent un film plastique mince comme diélectrique ; celui-ci peut être métallisé ou non traité, selon les propriétés requises du condensateur. Ces types offrent stabilité, faible inductance et faible coût. Différentes versions de films sont disponibles : polyester, métallisé, polypropylène, PTFE et polystyrène. Les capacités vont de moins de 1 nF à 30 µF [6].

Ces types de condensateurs sont non polarisés, ce qui les rend appropriés pour les applications de signaux et de puissance en courant alternatif. Les condensateurs à film peuvent avoir des valeurs de condensateurs de très haute précision, qu'ils conservent plus longtemps que les autres types de condensateurs. Ils sont très fiables et ont une longue durée de vie, avec un processus de vieillissement généralement plus lent que d'autres types tels que l'électrolytique. Ils ont de faibles valeurs ESR et ESL, donc de très faibles facteurs de dissipation. Ils peuvent être conçus pour résister à des tensions de l'ordre du kilovolt et fournir des impulsions de courant de surcharge très élevées. [6].

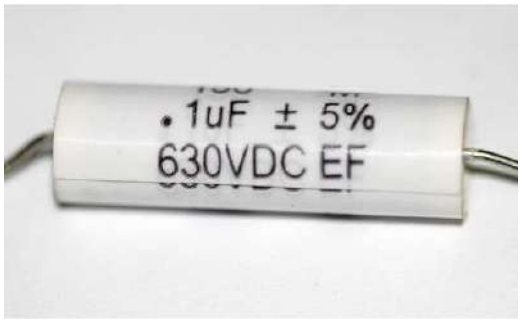


Figure I-10 : Condensateurs à film polyester

b. Les condensateurs Céramique :

Les condensateurs céramiques utilisent un matériau céramique comme diélectrique. Le condensateur à puces multicouches (MLCC) et le condensateur à disque céramique sont les types les plus couramment utilisés dans l'électronique moderne. Les MLCC sont fabriqués selon la technologie de montage en surface (SMT) et sont largement utilisés en raison de leur petite taille. Les valeurs de capacité se situent généralement entre 1 nF et 1 µF, bien que des valeurs allant jusqu'à 100 µF soient disponibles. Ils ne sont pas polarisés et peuvent donc être utilisés

dans des circuits AC. Ils ont une grande réponse en fréquence due à de faibles effets parasitaires résistifs et inductifs. [6].

Il existe aujourd'hui deux classes de condensateurs céramiques : la classe 1 et la classe 2, les condensateurs céramique de classe 1 sont utilisés lorsqu'une grande stabilité et de faibles pertes sont requises. Ils sont très précis et la valeur de la capacité est stable en ce qui concerne la tension, la température et la fréquence appliquées.

Les condensateurs de classe 2 ont une capacité élevée par volume et sont utilisés pour des applications moins sensibles. Leur stabilité thermique est typiquement de ± 15 % dans la plage de température de fonctionnement et les tolérances des valeurs nominales sont d'environ 20 %.

Les MLCC offrent des compacités élevées pour le montage des circuits imprimés, bien qu'il existe également des composants céramiques plus gros qui peuvent résister à des tensions de 2 kV à 100 kV, avec une puissance nominale supérieure à 200 VA. [6].



Figure I-11 : Condensateur céramique

c. Les condensateurs Électrolytique :

Les condensateurs électrolytiques utilisent un électrolyte pour fournir une plus grande valeur de capacité que les autres types de condensateurs. Presque tous les condensateurs électrolytiques sont polarisés, ils doivent donc être utilisés dans des circuits DC et correctement polarisés. Les condensateurs électrolytiques peuvent être soit des électrolytes humides, soit des polymères solides. Ils sont généralement fabriqués en tantale ou en aluminium. Les condensateurs en aluminium ont généralement des capacités comprises entre 1 µF et 47 mF, avec une tension de fonctionnement allant jusqu'à quelques centaines de volts DC. Cependant,

les supercondensateurs, parfois appelés condensateurs à double couche, sont également disponibles avec des capacités de centaines ou de milliers de farads [6].

Les inconvénients comprennent des courants de fuite importants, de grandes valeurs de tolérance généralement de 20 % [6], une résistance de série équivalente et une durée de vie limitée. Les valeurs de capacité dérivent également au fil du temps. Les condensateurs peuvent surchauffer ou même exploser s'ils sont soumis à des tensions de polarité inverse.

Les condensateurs électrolytiques sont utilisés dans des applications qui ne nécessitent pas de tolérances restreintes et de polarisation AC, mais qui nécessitent des valeurs de capacité élevées. Il peut s'agir, par exemple, d'étages de filtrage dans les alimentations pour éliminer l'ondulation AC, ou d'un filtre passe-bas pour les signaux DC ayant une faible composante AC pour le lissage d'entrée et de sortie [6].

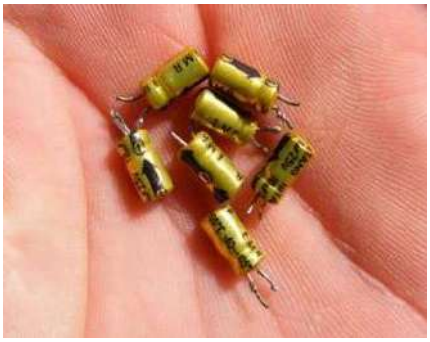


Figure I-12 : Condensateur électrolytique

d. Les Supercondensateurs :

Les supercondensateurs sont un type de condensateurs électrolytiques, comme décrit ci-dessus. Ils peuvent stocker de très grandes quantités d'énergie électrique en utilisant deux mécanismes : la capacité double couche et la pseudo-capacité. Le premier est électrostatique, tandis que le second est électrochimique, de sorte que les supercondensateurs combinent les caractéristiques des condensateurs normaux avec celles des batteries ordinaires.

En fait, ils sont utilisés comme alternatives aux batteries dans de nombreuses applications, y compris les systèmes de récupération d'énergie cinétique automobile (KERS), les flashs photographiques et les mémoires RAM statiques. Les possibilités d'avenir comprennent les téléphones portables, les ordinateurs portables et les voitures électriques ; leur plus grand avantage est leur taux de recharge très rapide, qui permet de recharger une voiture électrique en quelques minutes.

Cette technologie permet d'atteindre des valeurs de capacité jusqu'à 12000 F [7]. Ils ont des temps de charge et de décharge très rapides, comparables à ceux des condensateurs ordinaires, en raison de leur faible résistance interne. En revanche, les batteries peuvent prendre jusqu'à plusieurs heures avant d'être complètement chargées. Les supercondensateurs ont également des puissances spécifiques 5 à 10 fois supérieures à celles des batteries, par exemple 10 kW/kg contre 1 à 3 kW/kg pour les batteries Li-ion. Les supercondensateurs ne chauffent pas autant que les batteries lorsqu'ils sont maltraités et ont une durée de vie pratiquement illimitée, contrairement aux batteries qui disposent généralement d'environ 500 cycles [7].

Les inconvénients des supercondensateurs comprennent une faible énergie spécifique (Wh/kg), une tension de décharge linéaire (un supercondensateur conçu pour une sortie de 2,7 V tomberait à 1,35 V à une décharge de 50 %, par exemple) et des coûts élevés. Cela a empêché jusqu'à présent le remplacement des batteries par des supercondensateurs dans la plupart des applications. [6].

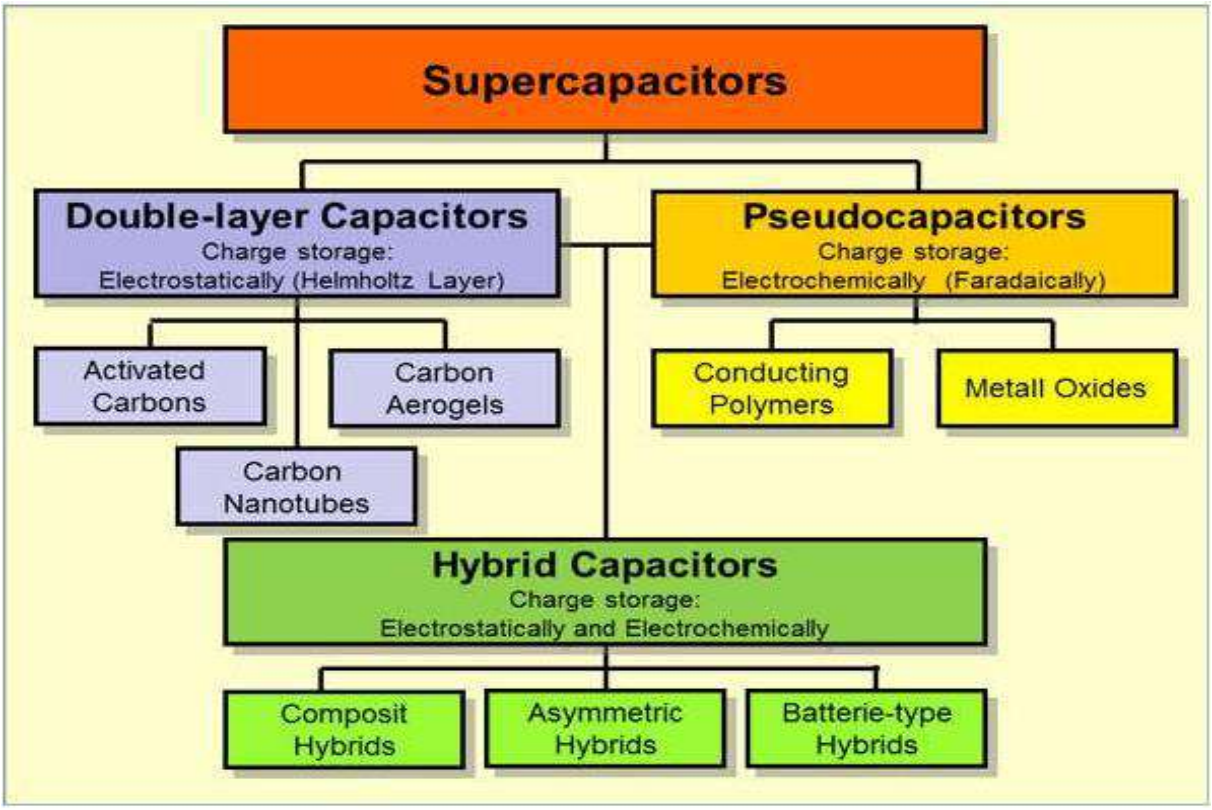


Figure I-13 : Technologies de super condensateur

e. Les condensateurs Mica :

Les condensateurs mica aujourd'hui sont des condensateurs mica argenté, fabriqués en interposant des feuilles de mica recouvertes de métal sur les deux faces. Les valeurs de capacité sont faibles, généralement de quelques pF à quelques nF, bien que les plus grands types mica puissent atteindre 1 µF. Les tensions nominales sont généralement de 100 à 1000 volts, bien que certains condensateurs puissent atteindre 10 kV pour les applications d'émetteurs RF. Ils sont également utilisés dans d'autres applications hautes tension, en raison de leur tension de claquage élevée.

Ils sont à faible perte, permettant une utilisation à haute fréquence, sont fiables, et leur valeur reste stable dans le temps. Les condensateurs sont également stables sur de larges plages de tension, de température et de fréquence. Ils ont généralement une valeur capacitive relativement faible. Ils sont précis, avec de faibles tolérances de +/- 1 %. Cependant, les condensateurs sont encombrants et coûteux. [6]



Figure I-14 : Condensateurs mica argenté

f. Les condensateurs en Verre :

Les condensateurs en verre sont utilisés dans les circuits RF où la performance ultime est requise. Ils offrent un faible coefficient de température sans hystérésis, un taux de vieillissement nul, aucun bruit piézoélectrique et des pertes extrêmement faibles. Ils ont également une grande capacité de courant RF, avec des températures de fonctionnement élevées, atteignant souvent 200 °C. [6].

g. Les condensateurs à Traversée :

AVX propose une gamme de condensateurs à traversée, disponibles en taille standard 0805 et 1206. Ces condensateurs sont des choix idéaux pour la suppression des interférences électromagnétiques, le filtrage des E/S à large bande ou le conditionnement des lignes électriques V DC. La construction unique d'un condensateur à traversée fournit une faible inductance parallèle et offre une excellente capacité de découplage pour tous les environnements à haute di/dt et permet une réduction significative du bruit dans les circuits numériques jusqu'à 5 GHz. AVX propose des condensateurs à traverser de qualité automobile conformes à la norme AEC-Q200. Ces condensateurs sont disponibles en diélectriques NP0 et X7R avec des options de terminaisons incluant Ni et Sn plaqués. [6].

I.3. Conclusion :

Le condensateur est un composant électronique élémentaire, constitué de deux armatures conductrices appelées « électrodes » en influence totale et séparées par un isolant polarisable ou « diélectrique ». Sa propriété principale est de pouvoir stocker des charges électriques opposées sur ses armatures. La valeur absolue de ces charges est proportionnelle à la valeur absolue de la tension qui lui est appliquée.

Le condensateur est utilisé principalement pour :

- stabiliser une alimentation électrique (il se décharge lors des chutes de tension et se charge lors des pics de tension) ;
- traiter des signaux périodiques (filtrage…) ;
- séparer le courant alternatif du courant continu, ce dernier étant bloqué par le condensateur ;
- stocker de l'énergie, auquel cas on parle de supercondensateur.

La caractéristique particulière de ce composant et la permittivité du diélectrique ou de son isolant dont dépond particulièrement sa capacité.

CHAPITRE II

Les Réseaux de Neurones

II.1 Introduction

La physiologie du cerveau montre que celui-ci est constitué de cellule (neurones) interconnectés. Quelques étapes de cette découverte :

- Van Leuwenhock (1718) première description fidèle de ce qu'on appellera plus tard les axones.
- Dutrochet (1824) : Observation du corps cellulaire du neurone
- Valentin : Découverte des dendrites
- Deiters (1865) Image actuelle de cellule nerveuse
- Sherington (1897) : les synapses
- Les neuro transmetteurs (première moitié du 20 eme siècle)

Les neurones reçoivent les signaux (impulsions électriques) par des extensions très ramifiés de leurs corps cellulaires (les dendrites) en envoient l'information par de long prolongements (les axones) [8]. Les impulsions électriques sont régénérées pendant le parcours le long de l'axone. La durée de chaque impulsion est de l'ordre de 1 ms et son amplitude d'environ 100 mVolts.

Les contacts entre deux neurones, de l'axone à une dendrite se font par l'intermédiaire des synapses. Lorsqu'un potentiel d'action atteint la terminaison d'un axone, des neuromédiateurs sont libérés et se lient à des récepteurs post synaptiques présent sur les dendrites. L'effet peut être excitateur ou inhibiteur.

Chaque neurone intègre en permanence jusqu'à un millier de signaux synaptiques. Ces signaux n'opèrent pas de manière linéaire (effet de seuil).

II.1.1. Quelques information en VRAC :

- Le cerveau contient environ 100 milliards de neurones
- On ne dénombre que quelques dizaines de catégories distinctes de neurones.
- Aucune catégorie de neurones n'est propre à l'homme
- La vitesse de propagation des influx nerveux est de l'ordre de 100 m/s. c'est à dire bien inferieur a la vitesse de transmission de l'information dans un circuit électronique.
- On compte de quelles centaines à plusieurs dizaines de milliers de contacts synaptiques par neurone. Le nombre totale de connexion est estimé à environ 10^{15}.
- La connectique du cerveau ne peut pas être codée dans un « document biologique » tel l'ADN pour de simples raisons combinatoires. La structure du cerveau provient donc

en partie des contacts avec l'environnement. L'apprentissage est donc indispensable à son développement.

- Le nombre de neurone décroit après la naissance, cependant cette affirmation semble être remise en question par la science moderne.
- On observe par contre une grande plasticité de l'axone, des dendrites et des contacts synaptiques. Celle-ci est surtout très importante après la naissance cette plasticité est conservée tout au long de l'existence.
- Les synapses entre des neurones qui ne sont pas simultanément actifs sont affaiblies puis éliminés

Il semble que l'apprentissage se fasse par un double mécanisme : des connexions sont établies de manière redondante et aléatoire puis seules les connexions entre des neurones simultanément actifs sont concernées (phase de sélection) tandis que les autres sont éliminés. On parle de la stabilisation sélective. [9] [10]

II.2. Principe de fondement biologique :

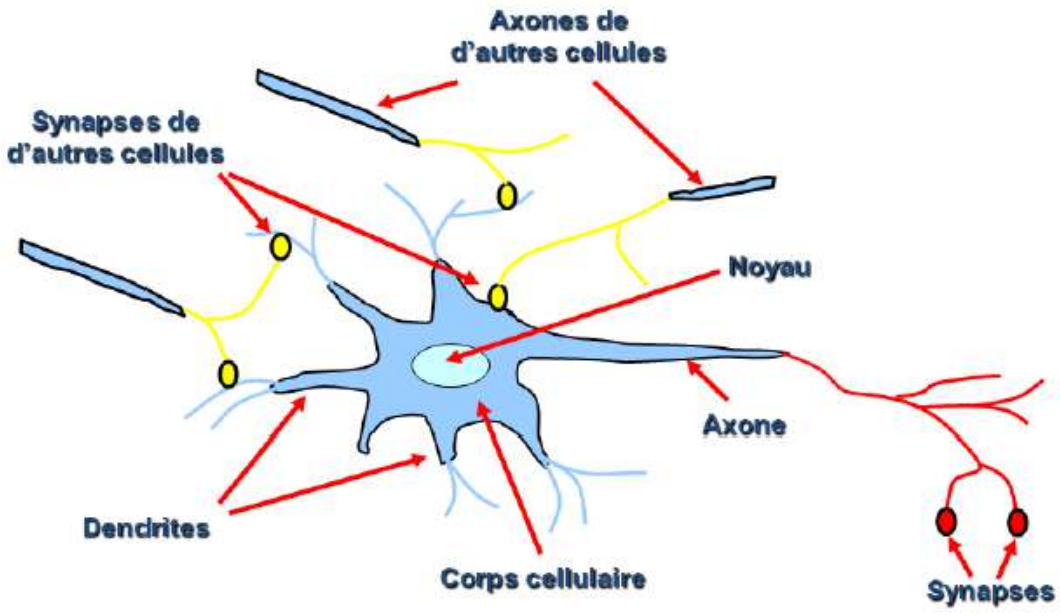


Figure II-01 : Neurone biologique.

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

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

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

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

Les réseaux de neurones biologiques réalisent facilement un certain nombre d'applications telles que la reconnaissance de formes, le traitement du signal, l'apprentissage par l'exemple, la mémorisation, la généralisation. Ces applications sont pourtant, malgré tous les efforts déployés en algorithmique et en intelligence artificielle, à la limite des possibilités actuelles. C'est à partir de l'hypothèse que le comportement intelligent émerge de la structure et du comportement des éléments de base du cerveau que les réseaux de neurones artificiels se sont développés. Les réseaux de neurones artificiels sont des modèles, à ce titre ils peuvent être décrits par leurs composants, leurs variables descriptives et les interactions des composants.
Les modèles mathématiques de réseaux de neurones artificiels reproduisent de manière simple la structure de réseaux de neurones réels. Les différents points de la modélisation sont :

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

II.3. Le connexionnisme et les réseaux de neurones formels :

II.3.1. Définition :

Le réseau de neurone formel ou artificiel est une fonction mathématique [11] comprenant comme toute fonction, des variables et un résultat ; elle comprend de plus des paramètres ajustables appelés Poids. Le calcul des résultats est effectué par n'importe quel ordinateur, celui-ci peut être muni d'un logiciel spécifique de traitement de données par réseau

de neurones, ou bien l'utilisateur peut écrire lui-même un court programme dans le langage de son choix. Un réseau de neurone n'est que très exceptionnellement un objet matériel (circuit électronique spécifique) cela peut être le cas pour les applications ayant de très fortes contraintes de vitesse de traitement ou de miniaturisation

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. Toute structure hiérarchique de réseaux est évidemment un réseau.

La question fondamentale du connexionnisme est :

Comment rendre compte des processus cognitifs à partir d'un ensemble d'unités, dotée chacune d'une faible puissance de calculs et interconnectées en réseau ?

La définition des réseaux de neurones formels et l'expérimentation menées sur ces réseaux ont permis d'étudier et de tester cette hypothèse, citons quelques étapes dans la formalisation des réseaux de neurones. [11]

- Première définition d'un neurone formel par Mc Culloch et Pitts en 1943.
- Les concepts sont physiquement représentés dans le cerveau par l'entrée en activité (simultanée) d'une assemblée de neurones (Donald Hebb 1949), l'hypothèse concurrente est la spécialisation de certains neurones dans des taches cognitive complexe.
- Deux neurones entrant en activité simultanément vont être associés (c'est-à-dire leurs contacts synaptiques vont être renforcés) c'est la loi de Hebb et d'associationnisme.
- Le perceptron de Franck Rosenblatt (1958) : le premier model pour lequel un processus d'apprentissage a pu être défini. De cette période, datent également les travaux de Widrow et Hofftrés complète des perceptrons. Ce livre a été réédité en 1980, avec des ajouts et des corrections manuscrite dans les marges, sans doute pour qu'on ne puisse pas les accuser de camoufler la première version du texte car on lui reproche parfois violement d'avoir sonné le glas des recherches sur les réseaux de neurones dans les années 70.
- L'algorithme de rétro propagation du gradient dans les réseaux multicouches découvert au début des années 80 par Rumelhart, McClelland, Parker, Hinton et Le Cun. Les inventeurs sont nombreux car l'idée de descente du gradient est naturelle, la plupart de ces travaux étaient associés à des études empiriques montrant la puissance du model.

- Le model de Hopfield 1982 qui utilise des réseaux totalement connectés basés sur la règle de Hebb qui ont permis des définir la notion d'attracteurs et de mémoire associative.
- Les cartes de Kohonen 1984 avec un algorithme non supervisé basé sur l'auto-organisation.
- La machine de Boltzman 1984 Le réseau de Boltzmann a été introduit par Ackley, Seijnowski et Hinton. Ce réseau est une extension originale de Hopfield et peut être considéré comme étant une variante probabiliste de celui-ci. C'est un réseau récurrent mais qui a la particularité d'inclure une couche cachée. Malgré la présence de cette couche le réseau est tout de même capable d'apprendre un comportement désiré.

II.3.2. Neurone artificiel :

II.3.2.1. Modèle d'un neurone :

Le modèle mathématique d'un neurone artificiel est illustré à la (figure II.2). Un neurone est essentiellement constitué d'un intégrateur qui effectue la somme pondérée de ses entrées. Le résultat n de cette somme est ensuite transformée par une fonction de transfert f qui produit la sortie a du neurone. En suivant les notations présentées à la section précédente, les R entrées des neurones correspondent au vecteur P= [P_1 P_2…… P_R] alors que W= [$W_{1.1}$ $W_{1.2}$… $W_{1.R}$] représente le vecteur des poids du neurone. La sortie n de l'intégrateur est donnée par l'équation suivante :

$$n = \sum_{j=1}^{R} W_{1,j} P_j + b \qquad (2\text{-}1)$$

$$n = (W_{1.1}P1 + W_{1.2}P2 + \ldots\ldots\ldots\ldots\ldots\ldots + W_{1.R}PR) + b \qquad (2\text{-}2)$$

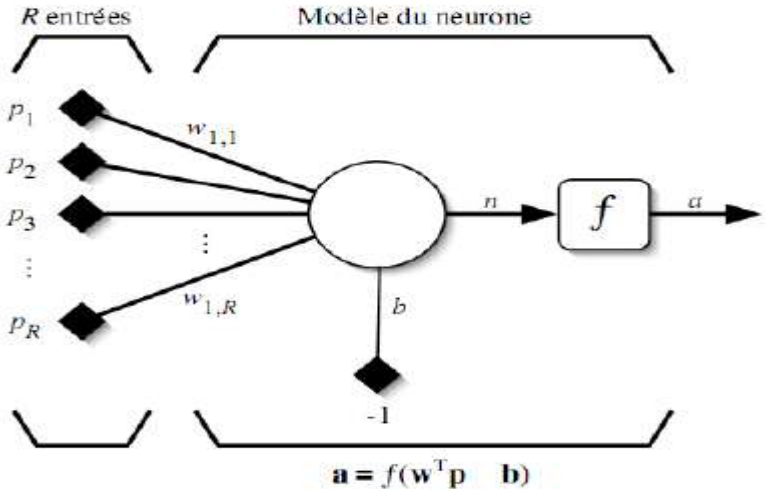


Figure II.2 : Modèle d'un neurone artificiel.

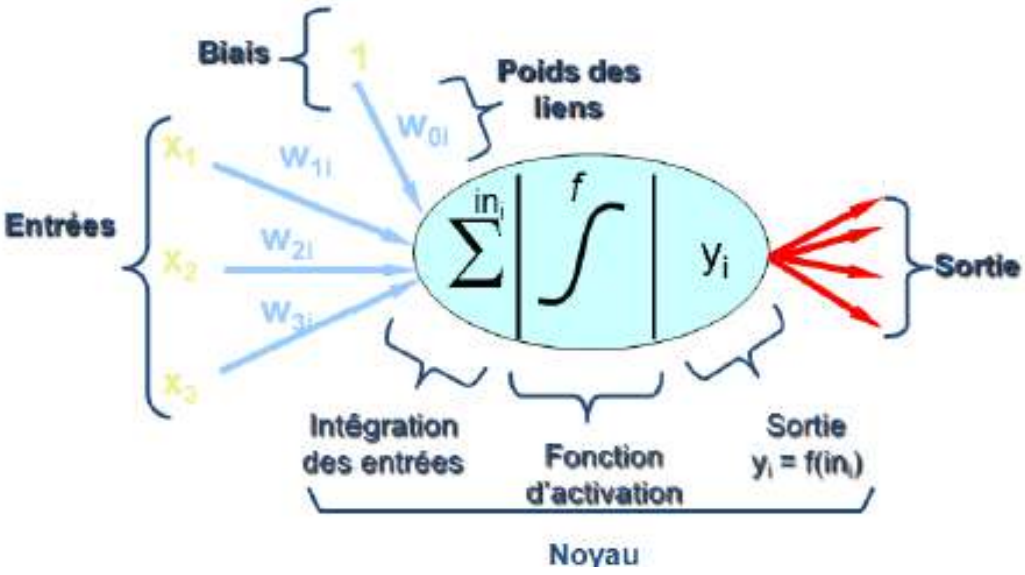


Figure II.3.Modèle mathématique d'un neurone artificiel.

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

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

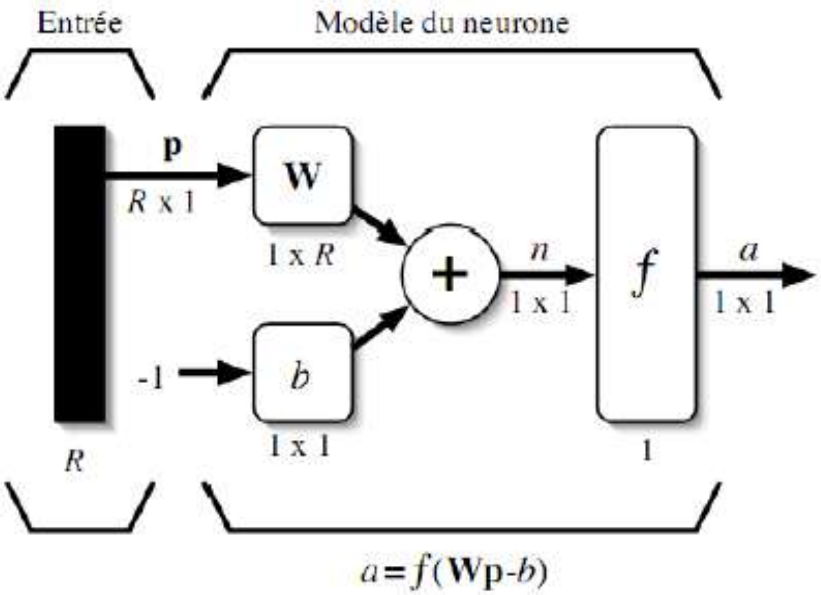


Figure II.4 : Représentation matricielle du modèle d'un neurone artificiel.

II.3.2.2. Fonctions d'activations :

Différentes fonctions de transfert pouvant être utilisées comme fonction d'activation du neurone sont énumérées au tableau II.1

Les trois les plus utilisées sont les fonctions « seuil » (en anglais « hard limite »), « linéaire » et « sigmoïde ». [12]

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

Tableau II.1 : Les différentes fonctions de transferts.

a- la fonction seuil

Comme son nom l'indique, la fonction « seuil » applique un seuil sur son entrée illustrée à (la figure II.4a). Plus précisément, une entrée négative ne passe pas le seuil, la fonction alors retourne la valeur 0 (on peut interpréter ce 0 comme signifiant faut), alors qu'une entrée positive ou nulle dépasse le seuil, et la fonction retourne à 1 (vrai)

b- La fonction linéaire

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

Appliquée dans le contexte d'un neurone, cette fonction est illustrée à (la figure II.4b). Dans ce cas la sortie du neurone correspond à son niveau d'activation

c- La fonction de transfert sigmoïde

La fonction de transfert sigmoïde est quant à elle est illustrée à la (figure II.4c). Son équation est donnée par :

$$a = \frac{1}{1+e^{-n}} \qquad (2\text{-}3)$$

Elle ressemble soit à la fonction seuil, soit à la fonction linéaire, selon que l'on est loin ou prés de *b*, respectivement.

De son côté la fonction linéaire est tout à fait linéaire. Elle ne comporte aucun changement de pente. La sigmoïde est un compromis intéressant entre les deux précédentes. Notons finalement que la fonction « tangente hyperbolique » est une version symétrique de la sigmoïde [13].

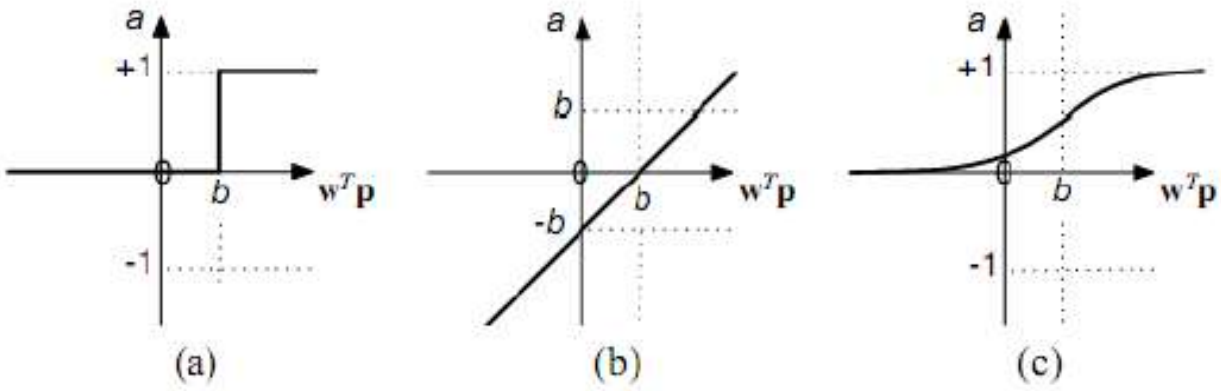


Figure II.5 : Fonctions de transfert : (a) « seuil », (b) « linéaire » ; et (c) « sigmoïde ».

II.3.3. Architecture de réseau :

Un réseau de neurone est un maillage de plusieurs neurones, généralement organisé en couches. Pour construire une couche de *S* neurones, il s'agit simplement de les assembler comme à (la figure II.5).

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

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

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

$$W = \begin{bmatrix} w_{1.1} & \cdots & w_{1.R} \\ \vdots & \ddots & \vdots \\ w_{S.1} & \cdots & w_{S.R} \end{bmatrix}$$

Notez bien que *S≠R*, dans le cas général (les nombres de neurones et d'entrées sont indépendants). Si l'on considère que les S neurone forment un vecteur de neurones, alors on peut créer les vecteurs *b= [b1 b2….bs], n=[n1 n2….ns] et a=[a1 a2….as]*. Ceci nous amène à la représentation graphique simplifiée, illustrée à (la figure II.6). On y retrouve, comme à (la figure II.4), les mêmes vecteurs et matrices. La seule différence se situe au niveau de la taille, ou plus précisément du nombre de la rangée *(S)*, de *b*, *n*, *a* et *w*.

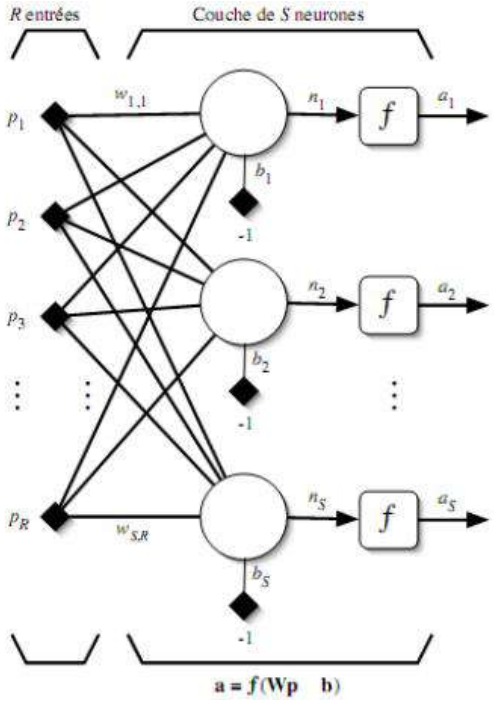


Figure II.6 : Couche de S neurones.

Finalement pour construire un réseau, il ne suffit plus que de combiner des couches comme à la figure II.7. Cet exemple comporte *R* entrées et trois couches de neurones complant respectivement $S^1 \neq S^2 \neq S^3$. Chaque couche possède sa propre matrice de poids w^k, ou *k* désigne l'indice de couche. Dans le contexte des vecteurs et des matrices relatives à une couche, nous emploierons toujours un exposant pour désigner cet indice. Ainsi, les vecteurs b^k, n^k et a^k sont aussi associé à la couche k.

Il importe de remarquer dans cet exemple que les couches qui suivent la 1ere ont comme entrée la sortie de la couche précédente. Ainsi, on peut enfiler autant de couche que l'on veut, du moins en théorie. Nous pouvons aussi fixer un nombre quelconque de neurone sur chaque

couche. En pratique, nous verrons plus tard qu'il n'est cependant pas souhaitable d'utiliser trop de neurones. Finalement notez aussi que l'on peut changer de fonction de transfert d'une couche à l'autre.

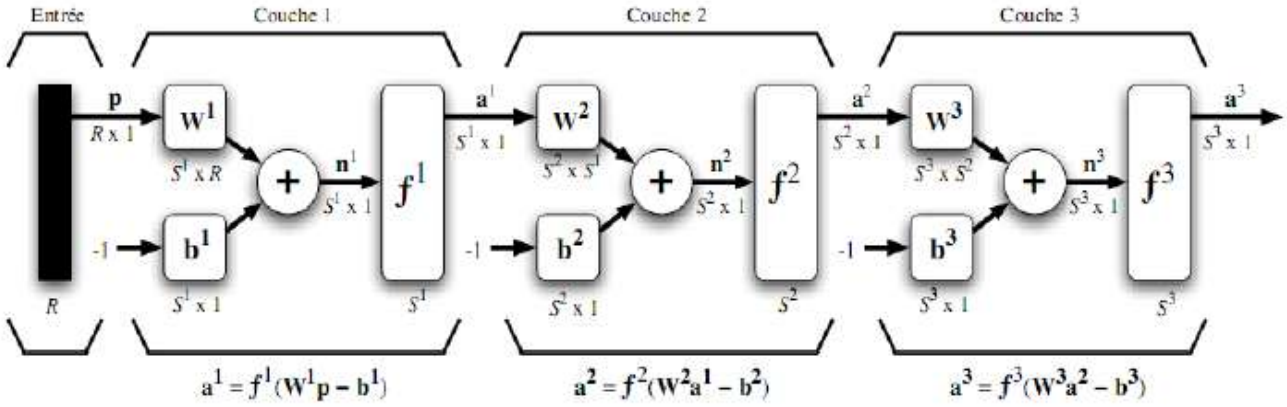


Figure II.7: Représentation matricielle d'un réseau de trois couches

II.3.4. Structure d'interconnexion (topologie) :

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

II.3.4.1. Réseau multicouches :

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

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

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

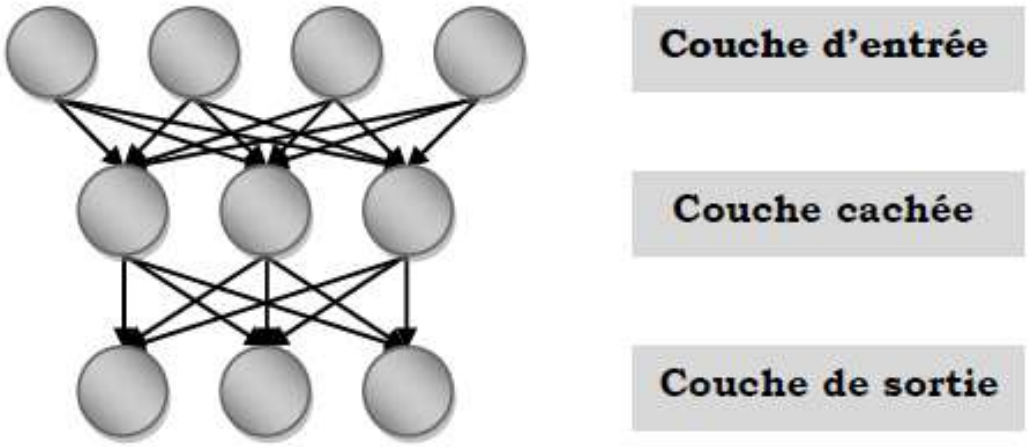


Figure II.8 : Réseau multicouche classique.

II.3.4.2. Réseau à connexions locales :

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

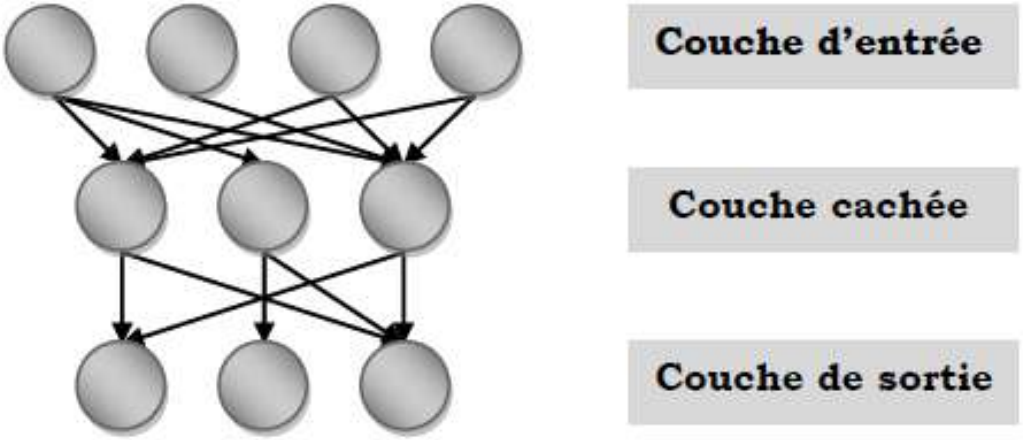


Figure II.9 : Réseau multicouche à connexions locales.

II.3.4.3. Réseau à connexions récurrentes :

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

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

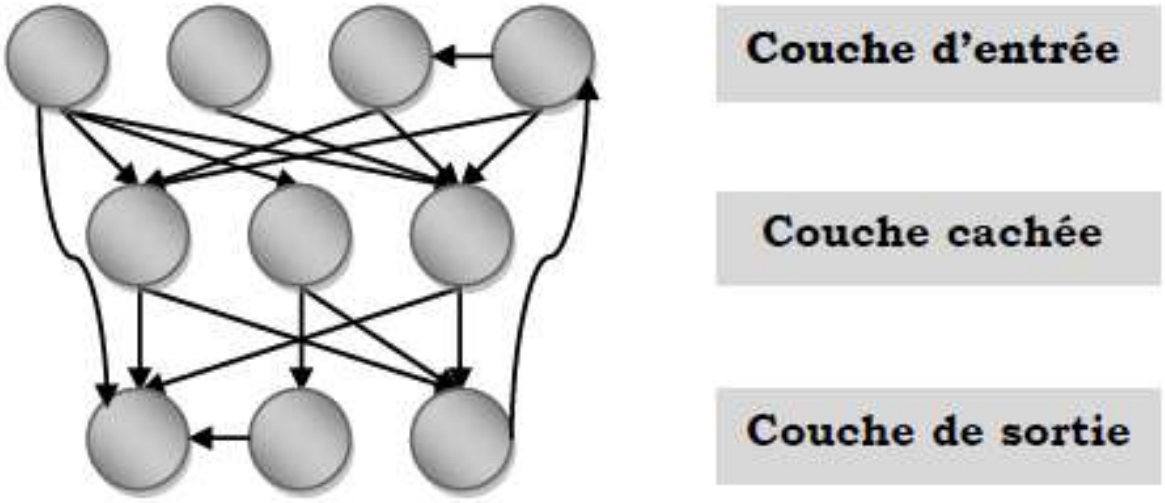


Figure II.10 : Réseau à connexions récurrentes.

II.3.4.4. Réseau a connexions complexes :

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

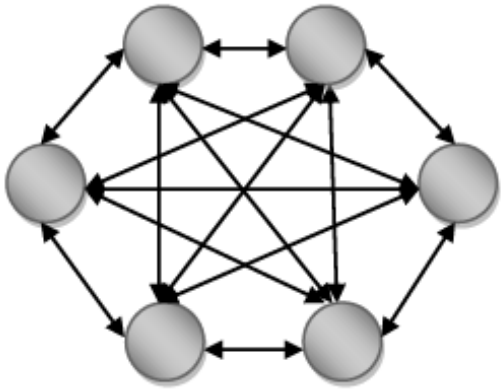


Figure II.11 : Réseau à connexions complètes.

II.4. Apprentissage :

II.4.1. Généralités sur l'apprentissage :

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

Dans le cas où la tâche du réseau de neurones est une tâche de modélisation d'un processus physique, il est raisonnable de supposer que les sorties mesurées sur le processus obéissent à des lois déterministes, et de chercher une expression mathématique des fonctions f et g.

La propriété d'approximation universelle est donc une propriété nécessaire du modèle utilisé à cette fin, mais elle n'est pas suffisante.

En effet :

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

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

Dans ce paragraphe, nous donnons les principes et décrivons la mise en œuvre des procédures d'apprentissage, indépendamment des considérations d'existence que nous venons d'évoquer. [12]

II.4.2. Principe général :

L'architecture du réseau de neurones n'est souvent que partiellement imposée par la tâche à réaliser. Les entrées, l'état, et les sorties du réseau peuvent être fixées en fonction de celle-ci par le concepteur, ainsi que le type et la connectivité des neurones. Mais le nombre de neurones ne peut être fixé a priori, et il est en général déterminé selon une procédure itérative, suivant le succès de l'apprentissage (il existe des méthodes systématiques de sélection de modèles dynamiques [13] [14]. L'architecture du réseau étant fixée, le but de l'apprentissage est l'estimation des coefficients pour remplir au mieux la tâche à laquelle le réseau est destiné.

II.4.3. Apprentissage d'un réseau de neurones :

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

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

Notons que la nécessité de disposer d'exemples en nombre suffisant, et suffisamment représentatifs, est souvent présentée comme une limitation propre aux réseaux de neurones ; ceci est incorrect : c'est une limitation commune à toute méthode statistique ; grâce à la propriété de parcimonie, cette contrainte est plus facile à satisfaire lorsque l'on utilise les réseaux de neurones que lorsque l'on utilise d'autres méthodes de régression.

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

L'apprentissage d'un réseau de neurones est ainsi défini comme un problème d'optimisation qui consiste à trouver les coefficients du réseau minimisant une fonction de coût. L'apprentissage est mis en œuvre par un système d'apprentissage qui comprend le réseau dont les coefficients sont à estimer, les séquences d'apprentissage et leur processus générateur (processus, modèle de référence.), et l'algorithme utilisé pour l'estimation. [12]

II.4.3.1. L'apprentissage supervisé :

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

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

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

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

On connait donc on tous points ou seulement en certains points, les valeurs que doit avoir la sortie du réseau en fonction des entrées correspondants : c'est en ce sens que l'apprentissage est « supervisé », métaphore qui signifie qu'un « professeur » peut fournir au réseau des « exemples » de ce que lui- ci doit faire. [12]

II.4.3.2. L'apprentissage non supervisé :

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

II.4.3.3. L'apprentissage par renforcement :

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

II.4.4. L'apprentissage des réseaux de neurones formels :

Comme nous l'avons indiqué plus haut, l'apprentissage "supervisé", pour les réseaux de neurones formels, consiste à calculer les coefficients de telle manière que les sorties du réseau de neurones soient, pour les exemples utilisés lors de l'apprentissage, aussi proches que possibles des sorties "désirées", qui peuvent être la classe d'appartenance de la forme que l'on veut classer, la valeur de la fonction que l'on veut approcher ou de la sortie du processus que l'on veut modéliser, ou encore la sortie souhaitée du processus à commander. La plupart des algorithmes d'apprentissage des réseaux de neurones formels sont des algorithmes d'optimisation, ils cherchent à minimiser, par des méthodes d'optimisation non linéaire, une fonction de coût qui constitue une mesure de l'écart entre les réponses réelles du réseau et ses réponses désirées. Cette optimisation se fait de manière itérative, en modifiant les poids en fonction du gradient de la fonction de coût, le gradient est estimé par une méthode spécifique aux réseaux de neurones, dite méthode de rétro propagation, puis il est utilisé par l'algorithme d'optimisation proprement dit. Les poids sont initialisés aléatoirement avant l'apprentissage, puis modifiés itérativement jusqu'à l'obtention d'un compromis satisfaisant entre la précision de l'approximation sur l'ensemble d'apprentissage et la précision de l'approximation sur un ensemble de validation disjoint du précédent. Contrairement à des affirmations maintes fois répétées, l'apprentissage des réseaux de neurones n'est pas spécialement lent, il existe des algorithmes d'optimisation non linéaire extrêmement rapides [12] qui permettent de faire des développements industriels sur de simples PC. L'apprentissage des réseaux de neurones bouclés (pour réaliser des modèles dynamiques) est très semblable à celui des réseaux non bouclés [15].

II.4.5. Règles d'apprentissage :

Un réseau de neurone artificiel, comme le cerveau animal, apprendre à réagir correctement à un stimules provenant de l'extérieur. Le principe de l'apprentissage consiste à soumettre le réseau à un stimules dont on connait la réponse souhaitée, autant de fois qu'il lui est nécessaire à la modification des poids des connexions, jusqu'à obtention de la bonne réponse. Il existe plusieurs règles de modification des poids, les principales sont [15] :

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

II.4.5.1. La règle de Hebb :

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

Lorsque les poids sont modifiés, ils sont augmentés de la quantité *M'AiAj* pour un pas d'apprentissage. *Ai* et *Aj* représentent l'activation des deux neurones, et leur produit vaut 0 ou 1, M est une constante numérique, appelée Taux d'apprentissage [15].

II.4.5.2. La règle de Widrow- Hoff :

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

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

Le gradient des erreurs est calculé en dérivant l'erreur quadratique *E(i)* par rapport au poids, ce qui nécessite une fonction d'activation dérivable. Dans ce cas les fonctions de Heaviside, seuil, et linéaire ne sont plus utilisables. On utilise alors la fonction sigmoïde [15].

II.4.6. La rétro propagation du gradient :

II.4.6.1. Principe :

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

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

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

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

II.4.6.2. Algorithme :

Considérons un réseau à une couche cachée.

Le réseau possède :

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

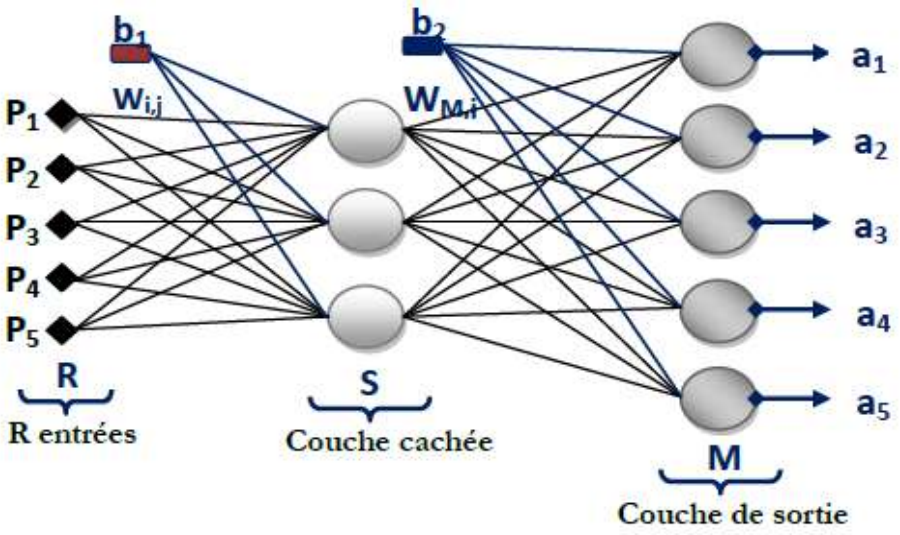


Figure II.12 : Exemple d'un réseau MLP à une couche cachée avec 5 entrées, 3 neurones en couche cachée et 5 sorties.

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

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

On propage vers la couche cachée :

$$y_i = f\left(\sum_{i=1}^{R} x_i\, w_{i,j}\right) + b_1 \qquad (2\text{-}4)$$

Puis de la couche cachée vers la couche de sortie :

$$Z_i = f\left(\sum_{j=1}^{S} y_i\, w_{k,j}\right) + b_2 \qquad (2\text{-}5)$$

Les valeurs b1et b2 sont les biais, des scalaires et non des sorties de la couche précédente. La fonction d'activation *f* est choisie en fonction du phénomène à résoudre.

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

$$E_k = a_k(1 - a_k)(d_k - a_k) \qquad (2\text{-}6)$$

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

$$F_j = y_j(1 - y_j)\sum_{k=1}^{M} W_{kj}E_k \qquad (2\text{-}7)$$

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

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

$$\begin{cases} \Delta W_{kj} = \eta y_j E_k \\ \Delta b_1 = \eta E_k \end{cases} \qquad (2\text{-}8)$$

- Entre la couche cachée et la couche de sortie :

$$\begin{cases} \Delta W_{ij} = \eta x_i F_j \\ \Delta b_2 = \eta F_j \end{cases} \qquad (2\text{-}9)$$

η étant un paramètre qu'il reste à déterminer.

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

II.5. Mise en œuvre des réseaux de neurones et domaine d'applications :

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

• Il faut tout d'abord choisir l'architecture du réseau, c'est-à-dire les entrées externes, le nombre de neurones cachés, et l'agencement des neurones entre eux, de telle manière que le réseau soit en mesure de reproduire ce qui est déterministe dans les données ; le nombre de poids ajustables est un des facteurs fondamentaux de la réussite d'une application, si le réseau possède un trop grand nombre de poids, c'est-à-dire si le réseau est trop "souple", il risque de s'ajuster au bruit qui est présent dans les données de l'ensemble d'apprentissage, et, même en l'absence de bruit, il risque de présenter des oscillations non significatives entre les points d'apprentissage, donc de posséder de mauvaises propriétés d'interpolation (ou, dans le jargon des réseaux de neurones, de "généralisation") ; si ce nombre est trop petit, le réseau est trop "rigide" et ne peut reproduire la partie déterministe de la fonction. Le problème de la détermination de l'architecture optimale est resté pendant longtemps un problème ouvert, mais il existe actuellement diverses méthodes, mettant notamment en jeu des tests statistiques, qui permettent de déterminer cette architecture pour une vaste classe de réseaux [14] ; la figure (II.13) illustre l'influence du nombre de paramètres sur la qualité de l'approximation.

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

• Il faut enfin estimer la qualité du réseau obtenu en lui présentant des exemples qui ne font pas partie de l'ensemble d'apprentissage.

Les grands domaines d'application des réseaux de neurones découlent naturellement de leur propriété fondamentale [12] :

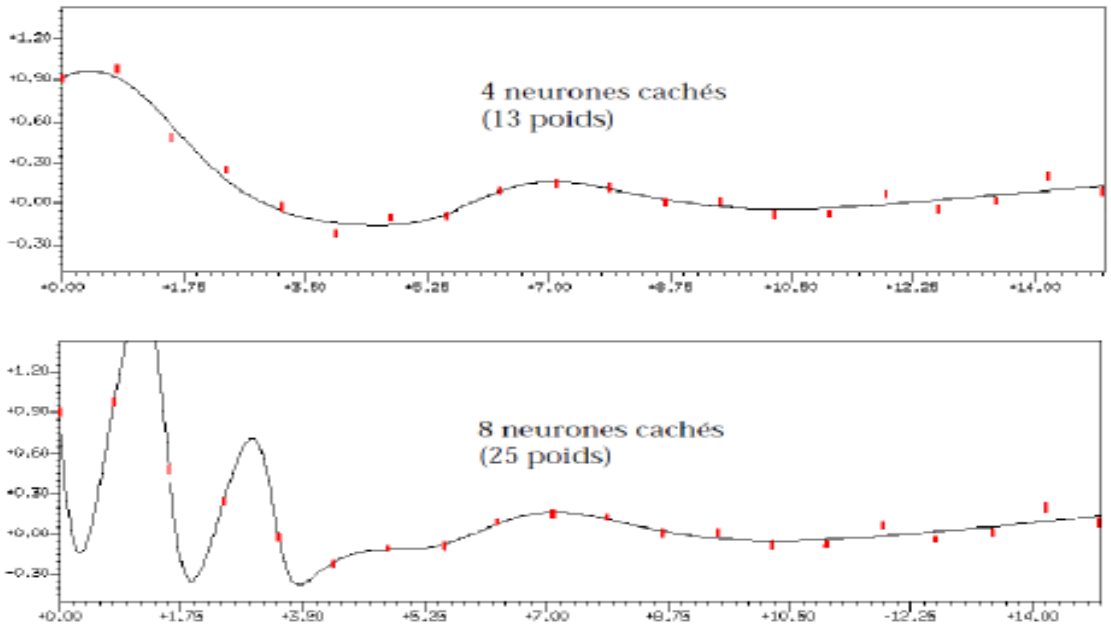


Figure II.13 : Le "sur ajustement"

II.6. Conclusion :

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

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

CHAPITRE III

Applications et Résultats

III.1. Introduction :

Les réseaux de neurones sont déjà largement exploités dans les domaines de classification et de reconnaissance de formes. Leurs sorties approximent en effet les probabilités a posteriori des différentes classes de sortie ; ce qui signifie que ce type de classificateur tend vers l'optimalité.

Nous utilisons ici ces réseaux de neurones dans un but tout à fait différent. Nous désirons les appliquer à la prédiction d'une valeur de la capacité d'un condensateur en partant sur les données caractéristiques du condensateur à calculer en l'occurrence les dimensions et en particuliers la nature du diélectrique utilisé dans la technologie de construction du condensateur Nous ne disposons d'aucune information quant au dimensionnement de ce réseau et devrons donc explorer l'ensemble des possibilités de manière à affiner notre choix de configuration de réseau.

Les paramètres fixes et variables, ainsi que l'architecture du réseau devront être également déterminés de manière à obtenir une prédiction efficace.

Ces deux étapes seront réalisées par un ensemble d'essais successifs car il n'y a pas de méthode bien fixe pour pouvoir déterminer l'architecture ou les paramètres du réseau d'une façon exacte.

Nous avons opté pour nos premières expérimentations à l'application sur un condensateur Plan pour la simplicité de ce derniers vis-à-vis des paramètres du condensateur, et par la suite généraliser le model de test sur les différents types de condensateur existants.

Le Training et le Test sont appliqués au condensateur Plan, le code final est élaboré d'une façon à pouvoir changer la formule mathématique qui calcule la capacité désirée selon l'usage et selon les paramètres du condensateur en prenant en considération les paramètres géométriques du condensateur en question (introduction du paramètre Rayon pour les condensateurs cylindriques).

III.2. Condensateur Plan :

Le condensateur Plan dépond essentiellement des 04 paramètres suivants :

La surface S des armatures du condensateur exprimée en mètre carré.

La distance d séparant les deux armatures exprimée en mètre.

La permittivité ou rigidité du diélectrique exprimé en pF/m

La permittivité de l'air (égale à celle du vide) ε_0 exprimé en pF/m qui est fixe est qui est calculée comme suit :

$$\varepsilon_0 = \frac{1}{36 \,.\, \pi \,.\, 10^9} = 8.85\ pF/m \qquad (3\text{-}1)$$

Par conséquent les entrées du réseau choisi sont déjà fixées relativement à ces quatre paramètres ce qui induit que quelques soit l'architecture du réseau choisi la couche d'entrée est dore et déjà fixée à 04 neurones d'entrée.

Notre Objectif est bien sur la prédiction de la valeur numérique de la capacité du condensateur y afférente aux paramètres déjà choisies, cette dernière est calculée par l'équation mathématique caractéristique du condensateur en question comme suit :

$$C = \varepsilon_0 . \varepsilon_r \,.\, \frac{S}{d} \qquad (3\text{-}2)$$

III.3. Base de données d'apprentissage (Deffine pattern) :

Pour l'apprentissage et afin d'entrainer le réseau de neurone a bien fonctionner sur le but choisi, il va nous falloir une base de donnée d'apprentissage bien sûr, pour cela on a opté pour le choix de différents condensateurs choisis selon la nature de l'isolant ou du diélectrique utilisé.

Résumé sur le tableau III-1 les différents types de condensateurs utilisés dans la phase Training dépendant particulièrement de leurs permittivités et des rigidités diélectriques, ces valeurs sont approximatives et peuvent varier nettement en fonction de la fréquence, de la température, de l'hygrométrie voir de la pression atmosphérique.

Isolant	ε_r : Permittivité (pF/m)	Capacité du condensateur (pF)
Air sec	1	$26{,}562 * 10^{-12}$
Bakélite	5	$132{,}81 * 10^{-12}$
Caoutchouc	4	$106{,}24 * 10^{-12}$
Caoutchouc Silicone	4,2	$11{,}56 * 10^{-12}$
Carton	4	$106{,}24 * 10^{-12}$
Mica	6	$159{,}36 * 10^{-12}$
Papier	2	$53{,}12 * 10^{-12}$
Papier Bakélisé	5	$132{,}81 * 10^{-12}$
Paraffine	2,2	$58{,}43 * 10^{-12}$
PVC	5	$132{,}81 * 10^{-12}$
Plexiglas	3,3	$87{,}64 * 10^{-12}$
Polyster	3,3	$87{,}64 * 10^{-12}$
Polyéthylène	2,25	$59{,}76 * 10^{-12}$
Polyprpylène	2,2	$58{,}43 * 10^{-12}$
Polystyrène	2,4	$63{,}74 * 10^{-12}$
Polycarbonate	2,9	$77{,}02 * 10^{-12}$
Porcelaine	5	$132{,}81 * 10^{-12}$
Presspahn	3	$79{,}68 * 10^{-12}$
Stéatite	5,8	$154{,}04 * 10^{-12}$
Styroflex	2,5	$66{,}4 * 10^{-12}$
Teflon	2,1	$55{,}77 * 10^{-12}$
Verre	5	$132{,}81 * 10^{-12}$
Stratifé-verre-epoxy	5	$132{,}81 * 10^{-12}$

Tableau III-1. Les différents types de condensateur utilisés dans la phase test

III.4. Architecture du réseau :

Nous avons opté d'une façon généralisée au début de l'apprentissage et procéderont aux changements adéquats par la suite selon la convergence de l'algorithme.

III.4.1. Les entrées :

Les entrées du réseau sont déjà fixées par les paramètres caractéristiques du condensateur qui sont 04 unités d'entrées (04 neurones d'entrée) en l'occurrence :

ε_0 : La permittivité de l'air (égale à celle du vide) ε_0 exprimé en pF/m

ε_r : La permittivité ou rigidité du diélectrique exprimé en pF/m

S : La surface S des armatures du condensateur exprimée en mètre carré.

d : La distance d séparant les deux armatures exprimée en mètre.

III.4.2 Les couches cachées :

Les couches cachées sont fixées de façon intuitive et peuvent être changées au fur et à mesure de la phase d'apprentissage selon la convergence de l'algorithme.

III.4.3 Les sorties :

La sortie du réseau est également fixée par une seule sortie relative à la valeur de la capacité du condensateur en question.

III.4.4 Les poids :

Les poids sont initialisés à des valeurs uniformément aléatoires dans un intervalle bien défini]-0.1, 0.2 [

III.4.5 la fonction de transfert :

La fonction de transfert utilisée est la fonction Sigmoïde :

$$f(x) = \frac{1}{1+Exp(x)} \qquad (3\text{-}3)$$

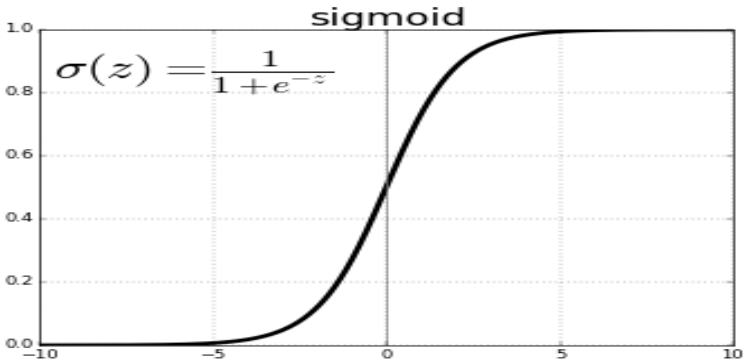


Figure III.1 La Fonction Sigmoïde

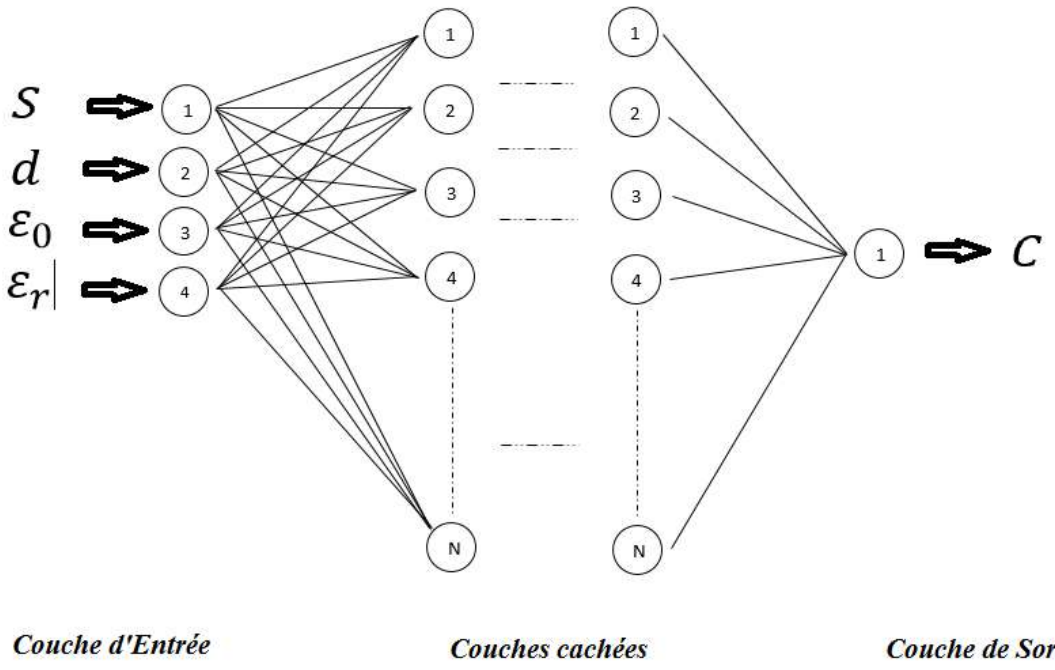


Figure III.2 Réseau Multicouche Une entrée avec 04 neurones - Plusieurs couches cachées avec N neurones –1 Sortie avec un seul neurone

III.5. Algorithme de rétro-propagation du Gradient

Cet algorithme nécessite une fonction continue et dérivable comme fonction de transfert du neurone, pour cette partie on a opté pour la fonction sigmoïde.

A chaque itération, on retire un exemple d'apprentissage et on calcule une nouvelle estimation du poids synaptique.

Cette itération consiste en deux phases :

- **Propagation vers l'avant :** à chaque itération, un élément de l'ensemble d'apprentissage est introduit à travers la couche d'entrée. L'évaluation des sorties du réseau se fait couche par couche, de l'entrée vers la sortie.
- **Rétro-propagation** : cette étape est similaire à la précédente. Cependant, les calculs s'effectuent dans le sens inverse (de la sortie vers l'entrée). A la sortie du réseau, on met en évidence l'erreur en fonction de la sortie réelle de système et sa valeur désirée. Puis, on évalue le gradient par rapport aux différents poids en commençant par la couche de sortie et en remontant vers la couche d'entrée.

e_i : Entrée du neurone i

s_i : Sortie du neurone i

d_i : Sortie désirée du neurone i

Pour l'implémentation de l'algorithme de rétropropagation du gradient nous avons envisagé les étapes suivantes :

1- Initialisation des poids à des valeurs aléatoires de faibles grandeurs.
2- Sélection d'une matrice d'apprentissage [S, d, ε_0 , ε_r] de la base d'apprentissage
3- Calcul de la sortie s_i de chaque Neurone
4- Propagation des sorties couche par couche
5- Evaluation de l'erreur entre la sortie calculée par le réseau et la sortie désirée *(s-d).*
6- Rétropropagation de l'erreur vers l'arrière de tous les neurones depuis la sortie jusqu'à l'entrée
   - *Si i est un neurone de sortie alors* $\delta_i = f'(s_i)(s_i - d_i)$
   - *Si i est un neurone caché alors* $\delta_i = f'(s_i)\sum_k(W_{ki} . s_k)$

     k : neurone entre la couche actuelle et celle de sortie
7- Ajustement des poids par la procédure du gradient

$$W_{ij}\,(t+1) = W_{ij}(t) + \mu.\delta_i.s_i \qquad (3\text{-}4)$$

μ : *Pas d'apprentissage*

8- Tant que l'erreur est trop importante, retour à l'étape 2 (exemple suivant).
9- Sauvegarder les poids et Fin.

III.6 Application et Résultats

Dans le but d'avoir de bons résultats et après avoir procéder à plusieurs essais, on est arrivé à fixer les paramètres suivants :

III.6.1 Application

a- Configuration du réseau utilisé :

Pour notre application on utiliser l'architecture suivante :

- Une couche d'entrée de 04 neurones
- Une couche cachée de 10 neurones
- Une couche de sortie de 01 neurone

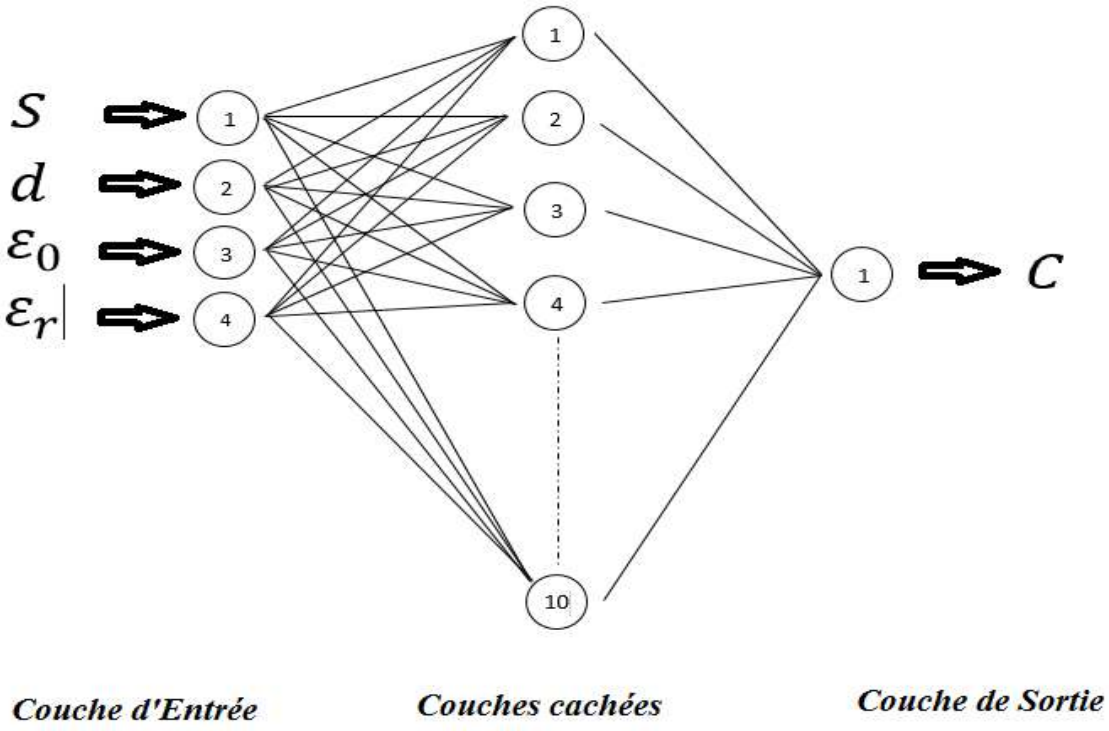


Figure III-3 Architecture du réseau utilisé

Le choix a été fixé sur une seule couche cachée après plusieurs essais pour simplifier le plus possible l'architecture du réseau, par contre le Code initiale est élaboré d'une façon générique à introduire d'autres couches cachées en cas de nécessité.

b- Matrice d'entrée :

C'est l'ensemble des valeurs fixes prise pour les dimensions du condensateur dépendants des surfaces des armatures ainsi que la distance entre les armatures, la permittivité de l'air ou du vide ainsi que la permittivité de l'isolant ou du diélectrique qui est en forme de matrice [4,1]

c- La sortie :

La sortie désirée est la capacité C du condensateur calculée par la formule mathématique caractéristique suivante :

$$C = \varepsilon_0 . \varepsilon_r . \frac{S}{d} \qquad (3\text{-}5)$$

d- Parametres de calculs du réseau choisis :

- Taux d'apprentissage μ = 0.9
- Les poids sont initialisés à des valeurs uniformément aléatoires proches de zéro
- Les neurones sont considères biaisés

e- Fonction d'activation :

La fonction d'activation est la sigmoïde tel que suit :

$$f(x) = {}^{1}/_{1 + Exp\ (-x)} \qquad (3\text{-}6)$$

f- L'erreur quadratique moyenne :

La condition du bouclage du code principale de l'erreur quadratique moyenne a était fixée à l'échelle de 10^{-4}

III.6.2 Résultats

A noter que durant tous notre travail, l'outil utiliser pour l'implémentation de notre algorithme est le Langage MALAB.

a- **Etape d'apprentissage (training)** :

Comme illustré précédemment pour cette partie on a pris une base de données d'apprentissage (entrées et sortie) détaillées sur le tableau III-1.

La donnée est injecté au code principale de calcul via une fonction « Deffine Pattern Train » qui est une fonction généralisée par calcul mathématique systématique de la sortie (capacité désirée) et qui est structurée en fonction des entrées qui représentent les caractéristiques du condensateur, elle sera appelé à chaque itérations du code principale durant l'apprentissage.

La variation de l'erreur quadratique moyenne entre les sorties désirées et calculées par le réseau en fonction du nombre d'itérations est représentée sur les figures Figure III-2 et Figure III-3 :

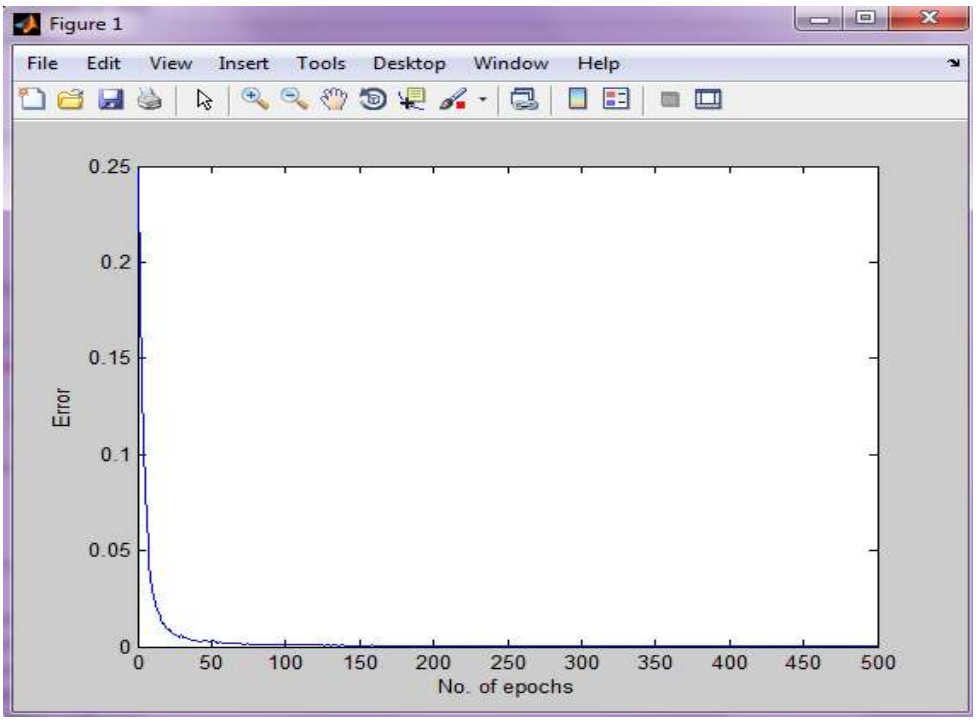


Figure III-2 : l'erreur quadratique moyenne en fonction du nombre d'itérations 5000 itérations

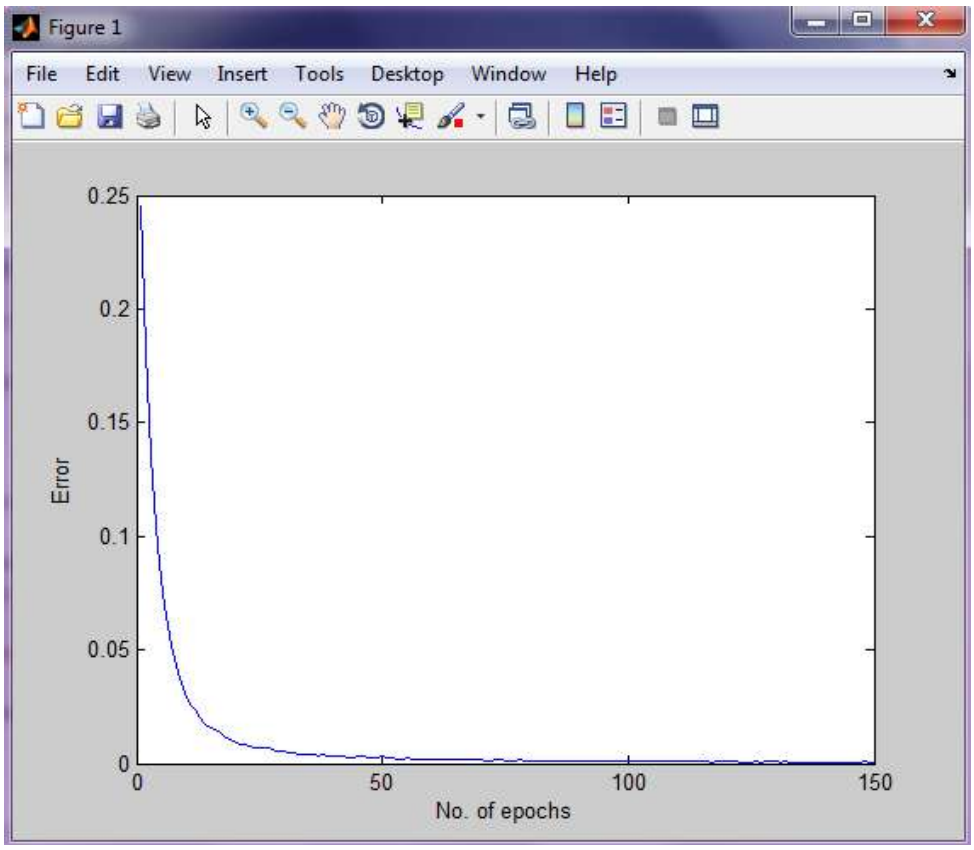


Figure III-3 : l'erreur quadratique moyenne en fonction du nombre d'itérations 150 itérations

b- Etape de généralisation (Test) :

Pour l'étape de test le principe consiste à injecter d'autres valeurs que celles de l'apprentissage et voir le comportement du réseau par rapports à ces nouvelles données appliquées aux entrées et comparé par la suite les sorties désirées à celle calculées par le réseau.

Pour cela et vu le peu de disponibilité de données récoltées pour pouvoir effectuer les tests sur de nouvelles donnes on a procéder comme suit :

- **Méthode 01 :**

Vu que la base de données d'apprentissages comportait 15 exemple d'apprentissages, on a pris que 12 exemples d'apprentissages lors de chaque training et d'en garder les 03 restantes pour la phase de test, mais en prenant à chaque fois 03 exemple différents de l'ensemble des 15 exemples existants et refaire le training afin d'essayer de comparer les résultats par la suite.

Les résultats sur le test nous donnent ce qui suit :

```
Input on which it is tested

x =

    0.0300    0.0100    0.0000    2.2000

Desired Output

outDesired =

   5.8430e-11

Obtained Output

yOut =

   5.8420e-11


ESP =

  -1.0000e-14
```

Pour une donnée précise de : S = 0.03 m ; d = 0.01 m ε_0 = 8.85 pF , ε_r = 2.2 pF

Sortie désirée : C = 58.430 pF

Sortie calculée par le réseau : C = 58.420 pF

ESP : Erreur Quadratique Moyenne ESP = -1*10^{-14}

L'erreur est à l'échelle de 10^{-14} normalisé pour l'utilisation du Picofarad à l'échelle de 10^{-12}.

- **Méthode 02 :**

Sur cette application, à la phase test on a procéder à une très légère variation aléatoire de la permittivité du diélectrique représenté par $\Delta\varepsilon_r$ comprise aléatoirement dans l'intervalle [-1,1] et appliquer le test sur ces nouvelles données uniquement en partie Test ce qui a induit par conséquent une légère variation sur la Capacité calculée est qui est relative à la capacité du condensateur avec la même valeur de variation par rapport à la capacité du condensateur en question si cette Variation de son diélectrique est nulle.

Les résultats obtenues ont été pratiquement quasi identiques à celle utilisé durant le training ainsi que durant le test de la 1^{ere} méthode ce qui nous ramène à la fiabilité du réseau pour la tache demandée.

- Variation $\Delta\ \varepsilon_r$ = 0.5 sur quelques exemples d'apprentissages et du Test :

```
Input on which it is tested

x =

    0.0300    0.0100    0.0000    1.5000

Desired Output

outDesired =

   3.9825e-11

Obtained Output

yOut =

   3.9815e-11


ESP =

  -1.0000e-14
```

Pour une donnée précise de : S = 0.03 m ; d = 0.01 m ε_0 = 8.85 pF , ε_r = 1.5 pF

Sortie désirée : C = 39.825 pF

Sortie calculée par le réseau : C = 39.815 pF

Erreur quadratique moyenne ESP = $-1*10^{-14}$

- Variation Δ ε_r = 0.8 sur quelques exemples d'apprentissages et du Test :

```
Input on which it is tested

x =

    0.0300    0.0100    0.0000    5.2000

Desired Output

outDesired =

   1.3806e-10

Obtained Output

yOut =

   1.3805e-10


ESP =

  -1.0000e-14
```

Pour une donnée précise de : S = 0.03 m ; d = 0.01 m ε_0 = 8.85 pF , ε_r = 5.2 pF

Sortie désirée : C = 138.06 pF

Sortie calculée par le réseau : C = 138.05 pF

Erreur quadratique moyenne ESP = -1*10^{-14}

- Variation Δ ε_r = - 0.2 sur quelques exemples d'apprentissages et du Test :

```
Input on which it is tested

x =

    0.0300    0.0100    0.0000    2.8000

Desired Output

outDesired =

   7.4340e-11

Obtained Output

yOut =

   7.4330e-11


ESP =

  -1.0000e-14
```

Pour une donnée précise de : S = 0.03 m ; d = 0.01 m ε_0 = 8.85 pF , ε_r = 2.8 pF

Sortie désirée : C = 74.34 pF

Sortie calculée par le réseau : C = 74.33 pF

Erreur quadratique moyenne ESP = -1*10^{-14}

III.7. Conclusion :

Ce qui peut être tiré comme conclusion est que l'utilisation de l'algorithme de rétropropagation du gradient nous a donné de bons résultats dans le domaine de la prédiction des calculs mais la convergence de l'algorithme n'était pas autant facile à cause des paramètres suivants :

- Problème de normalisation des unités de mesure en Pico ou en Nano fard qui sont a l'échelle de 10^{-12} et 10^{-9} respectivement, on aurait dû avoir recours à la normalisation à l'échelle 10^{-6} vois même10^{-3}.
- Problème de saturation de la fonction d'erreur (Oscillation de l'erreur autour d'une valeur pendant plusieurs itérations) dont la solution consistait à prendre un taux d'apprentissage un peu plus élevé pour contourner le souci de l'oscillation.
- Le temps d'apprentissage assez long respectivement aux normalisations prises en considérations, plus la normalisation prend plusieurs chiffres derrière la virgule sur les valeurs des capacités et des permittivités relatives plus le temps d'apprentissage devient plus long.

Durant le Test le choix de prendre des variations légères sur le paramètre de la permittivité de l'isolant ou du diélectrique est le but finale du sujet car en fait cette variation même si elle est prise aléatoirement elle représente en réalité l'influence des caractéristiques ou phénomène externes appliquées au condensateur de son milieu de travail tel que la température, l'humidité, la pression ou même s'il s'agit d'usage de condensateur variables.

Les résultats obtenus étaient assez fiables et assez satisfaisantes dans le but de pouvoir prédire une capacité finale d'un condensateur déployé dans un milieu soumis à des contraintes externes en prenant part de ses paramètres géométrique ainsi qu'aux caractéristiques de construction.

CONCLUSION :

Dans ce travail nous avons montré qu'il est possible de réaliser des systèmes intelligents à base de modèls connexionnistes Pour la prédiction des données.

Les réseaux de neurones artificiels possèdent une propriété fondamentale qui justifie l'intérêt croissant qui leur est accordé et qui sont capables d'intervenir dans des domaines très divers, et qui les distinguent des techniques classiques de traitement des données.

Compte tenu de la complexité de la relation entre les entrées et les sorties, les résultats obtenus sont très encourageants et satisfaisants et nous conduisent à comprendre qu'une bonne prédiction nécessite l'utilisation d'une architecture optimal ainsi qu'un nombre suffisant de données.

Le réseau neuronal peut apprendre de nouveaux modèles qui ne sont pas disponibles auparavant sur les ensembles de données à exploiter, et comme il peut mettre à jour les connaissances au fil du temps, il aboutit à un plus grand degré de tolérance de précision, que d'autres techniques
d'analyse.

Par conséquent, la technique se révèle être plus facile et économique par rapport à des travaux expérimentaux coûteux et peut être utilisée avec succès en tant que substitut pour cela. Ainsi, le système peut être interrogé sur les valeurs futures prises à un horizon donné.

Mais si les systèmes neuronaux présentent des avantages ils ne sont pas à l'abri de certains problèmes qu'on site parmi lesquels :

- Problème de convergence de l'algorithme de rétro propagation du gradient du essentiellement aux choix des paramètres du réseau, vu qu'il n'y a pas de méthodes analytiques de choix.
- Problème des Minimum Locaux lors de la convergence de l'algorithme

Algorithme de Rétropropagation du Gradient « Back propagation »

X_p : Matrice d'entrée

Y_p : Valeur de sortie désirée

S_p : Valeur de sortie calculée

N : Nombre de neurone dans la couche d'entrée

L : Nombre de neurone dans la couche cachée

M : Nombre de neurones dans la couche de sortie

P : Nombre d'exemple d'apprentissage

Début

Initialiser les poids à des valeurs aléatoires

Donner μ et E_0

1 : E=0, p=0

2 : p=p+1

Donner x_p et y_p

$t_j = f(\sum_{i=1}^{N+1} w_{ji} \, . \, x_i)$

$S_k = f(\sum_{j=1}^{L+1} w_{kj} \, . \, t_j)$

$\varepsilon_k^0 = (S_k - y_p) . f(\sum_{j=1}^{L+1} w_{ji}^0 \, . \, t_j)$

$\varepsilon_k^0 = f'(\sum_{i=1}^{N+1} w_{ji}^h \, . \, x_i) . \sum_{k=1}^{M} \varepsilon_k^0 \, w_{ki}^0$

$w_{kj}^0 = w_{kj}^0 + \mu . \varepsilon_k^0 t_j$

$w_{ji}^0 = w_{ji}^h + \mu . \varepsilon_j^h x_i$

$E = E + \frac{1}{2} \sum_{k=1}^{M} (y_k - S_k)^2$

Si p<P aller à 2 ;

Si E>E_0 aller à 1 ;

Fin

Base de données d'apprentissage (Training)

```
%define patterns
function [input,output] = DefinePatternTrainFinale()
%pattern 1
input(1,:)=[3e-2 1e-2 8.85e-12 1];
output(1,1)=26.562e-12;
%pattern 2
input(2,:)=[3e-2 1e-2 8.85e-12 5];
output(2,1)=132.81e-12;
%pattern 3
input(3,:)=[3e-2 1e-2 8.85e-12 4];
output(3,1)=106.24e-12;
%pattern 4
input(4,:)=[3e-2 1e-2 8.85e-12 4.2];
output(4,1)=11.56e-12;
%pattern 5
input(5,:)=[3e-2 1e-2 8.85e-12 6];
output(5,1)=159.36e-12;
%pattern 6
input(6,:)=[3e-2 1e-2 8.85e-12 2];
output(6,1)=53.12e-12;
%pattern 7
input(7,:)=[3e-2 1e-2 8.85e-12 2.2];
output(7,1)=58.43e-12;
%pattern 8
input(8,:)=[3e-2 1e-2 8.85e-12 2.4];
output(8,1)=63.74e-12;
%pattern 9
input(9,:)=[3e-2 1e-2 8.85e-12 3.3];
output(9,1)=87.64e-12;
%pattern 10
input(10,:)=[3e-2 1e-2 8.85e-12 2.25];
output(10,1)=59.76e-12;
%pattern 11
input(11,:)=[3e-2 1e-2 8.85e-12 2.9];
output(11,1)=77.02e-12;
```

Base de données Test (Testing)

```
function [input,output] = DefinePatternTest()
%pattern 1
input(1,:)=[3e-2 1e-2 8.85e-12 3];
output(2,1)=79.68e-12;
%pattern 2
input(2,:)=[3e-2 1e-2 8.85e-12 5.8];
output(2,1)=6154.04e-12;
%pattern 3
input(3,:)=[3e-2 1e-2 8.85e-12 2.5];
output(3,1)=66.4e-12;
%pattern 4
input(4,:)=[3e-2 1e-2 8.85e-12 2.1];
output(4,1)=55.77e-12;
```

Bibliographie 

[1] W. J. Sarjeant, J. Ziirnheld, F. W. MacDougall, “Capacitors”, IEEE transaction on Plasma Science, Vol. 26, N5, Octobre 1998, pp 1368-1392

[2] G. Mouriès, “Condensateurs utilisés en électronique de puissance”, Techniques de l’ingénieur, traité de génie électrique, D 3 280. Éditions T.I. (Techniques de l'Ingénieur) saint denis France Mars 1989

[3] C. Hantouche, “Condensateurs de puissance”, Techniques de l’ingénieur, traité de génie électrique, D 4 710. Éditions T.I. (Techniques de l'Ingénieur). Saint Denis France Juin 1996.

[4] P. Venet, Surveillance d’alimentation à découpage. Application à la maintenance. 134 p. Thèse pour obtenir le grade de Docteur. Université Claude Bernard (Villeurbanne, Rhône) 1993

[5] Normes de la C.E.I, “Condensateurs fixes utilisés dans les équipements électroniques – Partie 1 : Spécification générique”, CEI 60384-1, Troisième édition 1999-03.

[6]. R COUSSEAU “Contribution à la modélisation et à l’étude du vieillissement des condensateurs électrolytiques aluminium dédiés à des applications à hautes températures” -166 p. Thèse pour obtenir le grade de Docteur Spécialité : Génie Électrique- UTC Université de technologie de Compiègne 2015

[7]. FARNEL An Avnet Compagny https://uk.farnell.com/capacitor-types-and-performance [consulté le 15 Avril 2019] Registered number: 860093 | Registered office: 150 Armley Road, Leeds, LS12 2QQ, England.

[8]. C.TOUZET les reseaux de neurones artificiels , Introduction au connexionnisme, 126 p. LERI (Laboratoire d'Etudes et Recherche à Nîmes), Juillet 1992.

[9] H.KORN « les inattendus en neurophysiologie », In Pour la Science, VOL-235, Mai 1997.

[10] A.GELLATLY & O.ZARATE « Mind and Brain for Beginner » éditeur Cambridge.Icon Books, ISBN 1840460059 9781840460056 176 p. 1998.

[11] G. DREYFUS « Ecole Superieure de Physique et de Chimie Industrielle de la Ville de Paris ESPCI- Laboratoire d'Electronique » MESURES , N° 699, Novembre 1997.

[12] KASRI Souad « Thèse de Magister Etude et Modélisation de Déclin de Potentiel de Surface par les Réseaux de Neurones ; Faculté des Sciences de l'ingénieur Département D'Electromécanique, Université Badji mokhtar Annaba, Juillet 2010.

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

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

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