

# **Simulations informatiques de réseaux neuronaux appliquées à la détection de volets plombés dans des images radiologiques digitales**

Ing. N. LEBERGER  
Ing. T. LAMOLINE  
Lic. M. JEUNECHAMPS  
GRAMME – Liège  
MEDEX – Loncin

*La radiologie médicale utilise de plus en plus des images numériques. La partie utile de l'image est limitée par des volets plombés, qui réduisent le rayonnement diffusé, augmentent le contraste mais introduisent un bord blanc désagréable lors de la visualisation. La détection des volets peut être réalisée par une analyse statistique du contenu de l'image ou en utilisant des techniques de reconnaissance de formes par réseaux neuronaux. Différents types de réseaux ont été programmés et comparés. Dans l'avenir, ils pourraient servir à la reconnaissance d'organes ou de pathologies.*

*Mots-clés : imagerie médicale, rayons X, réseau neuronal, apprentissage, reconnaissance de formes, algorithmes, perceptrons multicouches.*

*Medical radiology uses digital images more and more. The useful part of the image is limited by leaded shutters, which reduce the diffused radiation, increase contrast but introduce an unpleasant white edge during visualization. The detection of the shutters can be carried out by a statistical analysis of the contents of the image or by using techniques of pattern recognition by neural networks. Various types of networks were programmed and compared. In the future, they could be used for the recognition of organs or pathologies.*

*Keywords : medical imaging, X-ray, neural network, learning, pattern recognition, algorithms, multilayer perceptrons.*

## 1. Présentation du système DIGIVEX

### 1.1 Généralités

DIGIVEX est un système compact et autonome d'imagerie numérique, qui génère des rayons X pour obtenir des images de qualité immédiatement disponibles.

Bien connu et apprécié dans le domaine de la médecine humaine, ce concept d'imagerie numérique devient accessible en médecine vétérinaire. Après des années d'investissements en recherche et développement, et en étroite collaboration avec divers spécialistes en médecine vétérinaire, Medex Loncin S.A. a mis au point un détecteur RX numérique pour répondre aux exigences des praticiens, tout en respectant leurs contraintes budgétaires.

Ce système intègre une table, un générateur à RX, un détecteur numérique avec un software associé et un écran de visualisation (fig.1). Cette nouvelle technologie procure plus d'efficacité et de rapidité que les films ou les cassettes rémanentes.



*Figure 1 : Système DIGIVEX*

## 1.2 Description technique




Figure 2 : Principaux composants du DIGIVEX

Le générateur (fig. 2) alimente le filament du tube sous vide dans lequel les rayons X sont émis. Ils traversent ensuite un collimateur pour les limiter sur la table où l'animal est déposé.




Figure 3 : Schéma de principe du détecteur et de la caméra

Le détecteur (fig. 3) est formé d'iodure de césium et transforme les rayons X en lumière visible. La caméra CCD (Charge Coupled Device) convertit la lumière en signaux électriques. Plus précisément, il s'agit d'une matrice de capteurs photosensibles qui accumulent des charges électriques en proportion de la lumière qu'ils reçoivent. Dans chaque pixel (case de la matrice) se trouve un nombre qui est d'autant plus élevé qu'il aura reçu une forte intensité lumineuse. Ce nombre s'évalue en ADU (Analog to Digital Unit). Grâce à un convertisseur numérique à 14 bits, les niveaux de gris (échelle de luminosité allant du noir au blanc) sont compris entre 0 ADU et 16383 ADU.

### 1.3 Acquisition de l'image

Chaque pixel de l'image est codé sur 14 bits, alors que l'écran ne peut afficher que 8 bits, soit 256 niveaux de gris. Une table de correspondance, appelée "Look Up Table" (LUT) est donc utilisée pour répartir les 16384 niveaux de gris sur une échelle de 0 à 255.

Trois types de LUT sont connus (fig. 4) :

- linéaire,
- linéaire entre pixel minimum et maximum,
- non-linéaire entre pixel minimum et maximum.





Figure 4 : Différents types de LUT

Remarque : Le pixel minimum est celui qui a reçu le moins de lumière parmi l'ensemble des pixels de la matrice de la caméra CCD.

#### 1.4 But de la détection des volets plombés

L'utilisation de volets plombés, situés dans le collimateur, diminue la surface exposée aux rayons X et réduit le rayonnement diffusé autour de la table de radiologie. Au point de vue de l'image, le contraste est augmenté et la partie utile est mise en évidence. Cependant, la fermeture des volets introduit des bords blancs qui sont désagréables lors de la visualisation. La possibilité est donnée à l'utilisateur de fermer des caches "électroniques" afin de noircir ces zones blanches. La détection de la position des volets est réalisée via un algorithme basé sur la comparaison des moyennes et écarts-types des valeurs des pixels sur les lignes et les colonnes voisines.



*Figure 5 : Noircissement des zones blanches*

## 2. Théorie sur les réseaux de neurones

### 2.1 Le neurone biologique

Les cellules nerveuses, appelées neurones, sont les unités de traitement de l'information du système nerveux central. En général, les neurones sont constitués de 3 parties : le corps cellulaire, les dendrites et l'axone.

Les dendrites forment la "chevelure" du neurone. Elles sont les récepteurs principaux du neurone pour capter les signaux qui lui parviennent.

L'axone, qui est à proprement parler la fibre nerveuse, sert de moyen de transport pour les signaux émis par le neurone. Les connexions entre deux neurones se font en des endroits appelés synapses. Le rôle des synapses est fondamental pour permettre aux cellules nerveuses de communiquer entre elles. En effet, lorsqu'un influx nerveux arrive au niveau d'une synapse, il provoque la libération d'un médiateur chimique qui, selon sa nature, va activer ou inhiber l'activité de la cellule cible. Les synapses pondèrent ainsi l'information qui se propage de neurone à neurone

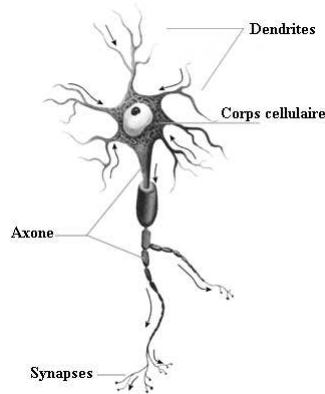


Figure 6 : Neurone biologique

## 2.2 Le neurone artificiel

Un neurone artificiel est une représentation mathématique et informatique d'un neurone biologique. Le neurone artificiel possède plusieurs entrées et une sortie. Les actions excitatrices et inhibitrices des synapses sont modélisées par des coefficients numériques (les poids synaptiques) associés aux entrées : le neurone calcule la somme pondérée des entrées reçues, puis applique à cette valeur une fonction de transfert. La valeur finale obtenue est la sortie du neurone.




Figure 7 : Schéma d'un neurone artificiel

La première phase consiste à calculer la somme pondérée des entrées, appelée également activation, selon l'expression :

$$a = \sum_{i=1}^n w_i \cdot e_i \text{ où les } w_i \text{ sont les poids des différentes entrées } e_i$$

Ensuite, une fonction d'activation  $\Phi$  calcule la valeur de l'état du neurone :  $y = \Phi(a)$ . C'est cette valeur qui sera transmise aux neurones avals.

## 2.3 Les réseaux de neurones artificiels

### *Introduction*

Un RNA (Réseau de Neurones Artificiels) est un ensemble de neurones artificiels (d'unités de calcul simples) associés en couches.

Dans un réseau, chaque couche effectue un traitement indépendant des autres et transmet le résultat de son analyse à la couche suivante. L'information donnée au réseau va donc se propager couche par couche, de la couche d'entrée à la couche de sortie, directement ou en passant par une ou plusieurs couches intermédiaires, dites couches cachées.


Habituellement (excepté pour les couches d'entrée et de sortie), chaque neurone dans une couche est connecté à tous les neurones de la couche précédente et de la couche suivante.

Les capacités de traitement du réseau vont être mémorisées dans les poids synaptiques, obtenus par des processus d'adaptation ou d'apprentissage. En ce sens, les RNA ressemblent donc au cerveau car non seulement, la connaissance est acquise au travers d'un apprentissage mais de plus, cette connaissance est stockée dans les poids synaptiques.

### *Structure*

La structure (ou architecture) d'un réseau est définie par le nombre de neurones, leur disposition et leurs interconnexions.

L'exemple de la structure illustrée à la figure 8 correspond aux perceptrons multicouches.



*Figure 8 : Perceptrons multicouches*

## *Apprentissage*

L'apprentissage est la modification des poids du réseau à l'aide d'un algorithme dans le but d'accorder la réponse du réseau aux exemples et à l'expérience. Il est souvent impossible de décider a priori des valeurs des poids des connexions d'un réseau pour une application donnée. A l'issue de l'apprentissage, les poids sont fixés : la phase d'utilisation peut commencer.

Au niveau des algorithmes d'apprentissage, il a été défini 2 grandes classes selon que l'apprentissage est dit supervisé ou non supervisé.


Dans le cas de l'apprentissage supervisé, les exemples sont des couples (Entrée, Sortie associée). Le réseau s'adapte par comparaison entre le résultat qu'il a calculé et la réponse attendue en sortie.

Pour l'apprentissage non supervisé, on ne dispose que de valeurs d'entrée. Le réseau doit "découvrir par lui-même" les corrélations existant entre les exemples d'apprentissage. Les cellules et les connexions doivent dégager un certain degré d'auto-organisation. L'apprentissage consiste donc à trouver un ensemble de classes (ou catégories) et pour chaque exemple à quelle classe il appartient.

### **3. Filtrage de l'image**

#### **3.1 Filtre de Sobel**

Ce type de filtre exécute essentiellement une différenciation numérique pour accentuer les variations dans l'image. Le filtre de Sobel utilise le fait que les contours d'une image sont de rapides changements des valeurs de niveau de gris dans un petit espace.



*Figure 9 : Traitements d'images successifs*

La seconde image est obtenue grâce au filtre de Sobel. La troisième a subi une inversion noir/blanc en recalculant chaque pixel de la manière suivante : "valeur d'un pixel" = 255 - "valeur de ce même pixel".



Pour la dernière image, un seuil (nombre entier, par exemple 15) a été utilisé. Les pixels de valeur inférieure à 15 sont forcés à zéro (noir) et ceux de valeur supérieure ou égale à 15 sont fixés à 255 (blanc).

### 3.2 Filtre d'érosion

Ce traitement permet d'affiner les contours d'une image préalablement filtrée par Sobel. L'érosion peut s'appliquer soit dans le sens des colonnes de pixels formant l'image, soit dans le sens des lignes.




Figure 10 : Erosion des colonnes de l'image

## 4. Méthodes de détection des volets plombés

### 4.1 Moyennes et écarts-types

La détection des volets longitudinaux (horizontaux) et transversaux (verticaux) se base respectivement sur les moyennes et les écarts-types des lignes et des colonnes de la matrice définissant l'image. Le but est d'identifier les 2 lignes et les 2 colonnes qui délimitent l'organe radiographié.




Figure 11 : Différences entre les lignes de pixels dans le volet longitudinal supérieur (zone 1) et dans l'image (zone2)

D'après la figure 11, on constate que les bords blancs introduits par la fermeture des volets constituent des zones où la valeur des pixels reste comprise entre 250 et 255 (valeurs proches du blanc).

Ainsi, dans la zone (1) :

- La moyenne d'une ligne reste également comprise dans cet intervalle.
- L'écart-type d'une ligne est faible étant donné qu'il représente le caractère homogène des pixels le long de cette même ligne.

Par contre, dans la zone (2), les moyennes des lignes sont plus faibles et les écarts-types sont plus élevés en raison des nombreux niveaux de gris présents.

Finalement, ces différences sont exploitées pour repérer le passage de la zone (1) à la zone (2) et la limite du volet sera donc détectée.

En conclusion, la méthode des moyennes et des écarts-types atteint un pourcentage de réussite de l'ordre de 95 %. Les raisons d'une détection ratée sont diverses :

- la présence importante de peau donne une image de teinte gris clair à proximité des volets;
- une image est noircie de manière excessive à cause d'un réglage inadéquat des paramètres du générateur à rayons X;
- des "taches" peuvent apparaître sur l'image et il en résulte des pixels "parasites" rendant les calculs inexploitable pour la détection des volets plombés.

## 4.2 Réseau connecté

Ce premier type de réseau de neurones s'inspire de la méthode précédente en utilisant uniquement le calcul des moyennes des lignes et des colonnes. Ce réseau est constitué de 2 couches, représentées chacune par un vecteur dans lequel chaque élément est symbolisé par un neurone.




Figure 12 : Schéma du réseau connecté

Le principe de détection dans le cas des lignes est le suivant :

Dans la première couche, on affecte à chaque neurone la moyenne d'une ligne de l'image. Ensuite, une fonction à seuil (type de fonction d'activation) est utilisée pour calculer la sortie de chacun de ces neurones. La valeur du seuil correspond à la moyenne de l'ensemble des pixels de l'image. Elle est généralement comprise entre 200 et 220. Si la moyenne d'une ligne est supérieure au seuil, la sortie du neurone est fixée à 1, sinon la sortie est fixée à 0.

Dans la seconde couche, on calcule la différence entre 2 sorties successives des neurones de la première couche et chaque résultat est directement transmis en sortie du neurone (fig.12). Ainsi, le vecteur de sortie est composé de "0" et de deux "1", représentatifs des volets longitudinaux supérieur et inférieur (exemple de la figure 11).

La méthode du réseau connecté est une modeste approche des réseaux de neurones artificiels.

### 4.3 Autres types de réseaux programmés et utilisés (mais non développés dans cet article)

#### *Mémoires associatives*

Dans "mémoire associative", le terme "mémoire" fait référence à la fonction de stockage de l'information et le terme "associative" au mode d'adressage. L'information mémorisée ne peut être obtenue à une adresse précise, le seul moyen d'accès est de fournir une information qui peut être incomplète. La matrice des poids est ici créée par avance en fonction des réponses attendues.

#### *Réseau de Hamming*

Les formes à mémoriser sont représentées par un vecteur comprenant N composantes codées en binaire. La couche de sortie comporte autant de neurones que de formes à mémoriser. Soit M ce nombre. La première couche permet d'évaluer la distance, au sens de Hamming, entre la forme inconnue  $\vec{X}$  et celles qui sont mémorisées (par exemple  $\vec{U}_j$ , l'une d'entre elles, de composantes  $u_{ji}$ ) :

$$d_H(\vec{U}_j, \vec{X}) = \sum_{i=1}^N (u_{ji} \bar{x}_i + \bar{u}_{ji} x_i) \quad \text{où } \bar{x}_i = 0 \text{ si } x_i = 1 \text{ et } \bar{x}_i = 1 \text{ si } x_i = 0.$$

La sortie du neurone de la première couche associée à la forme stockée la plus proche de celle présentée à l'entrée est maximale.  
La deuxième couche permet de détecter ce maximum. A la fin de la procédure le numéro de la sortie présentant un maximum est celui de la forme reconnue.




Figure 13 : Réseau de Hamming

### Réseau de Kohonen

La méthode proposée par Kohonen a pour objet de faire apparaître une organisation dans un ensemble de données, pouvant être de nature quelconque. On considère le cas d'un réseau constitué de  $N$  entrées connectées à  $M$  neurones de sortie. Les neurones de la couche de sortie sont connectés entre eux de manière à réaliser une inhibition latérale.




Figure 14 : Réseau de Kohonen

### Réseau ART1

ART (Adaptive Resonance Theory) est un modèle de réseau de neurones à architecture évolutive. Les neurones de la couche de sortie sont interconnectés et des connexions descendantes ont été ajoutées. En fait, cette couche est identique à celle de sortie du réseau de Hamming. Le nombre  $M$  de classes est fixé à l'avance. Chaque forme est représentée par un vecteur de  $N$  composantes pouvant être continues ou discrètes. On admet que ces composantes sont binaires dans le cas des réseaux ART1.




Figure 15 : Réseau ART1

#### 4.4 Perceptrons multicouches

##### *Introduction*

Parmi les nombreuses structures de réseaux multicouches, on ne considère ici qu'un réseau dans lequel chaque neurone d'une couche est connecté à tous les neurones de la couche suivante et celle-ci seulement.

L'apprentissage consiste à établir le poids des connexions entre les différents éléments, à partir des données connues, car l'apprentissage est supervisé. Un algorithme particulièrement efficace est celui de la rétropropagation de l'erreur, dont de nombreuses variantes ont été élaborées.

Le principe est le suivant :

Après avoir établi les valeurs initiales, la sortie souhaitée et l'entrée correspondante sont appliquées simultanément. L'état du réseau évolue, le traitement progresse de bas en haut. Un écart peut se manifester entre le résultat obtenu en sortie du réseau et la valeur souhaitée et connue à l'avance de la sortie. Dans ce cas, cette différence est utilisée pour modifier la pondération en progressant cette fois de haut en bas. Quand tous les poids sont actualisés, couche après couche, l'entrée étant maintenue, un autre exemple est présenté au réseau. Celui-ci évolue de nouveau et l'information progresse de bas en haut. Si un écart est à nouveau constaté en sortie, la procédure de rétropropagation recommence. Cette alternance du sens de l'évolution de l'information dans le réseau est reconduite jusqu'à ce que l'erreur obtenue en sortie se maintienne à un niveau inférieur à un seuil convenu à l'avance.

L'apprentissage est alors terminé, on dit que le réseau a convergé. Cette propriété de convergence n'est pas garantie a priori pour un réseau quelconque. Dans les cas habituels, cet état n'est atteint qu'au bout d'un très grand nombre d'itérations.

Le schéma présenté à la page suivante permet de visualiser les connexions entre les couches successives et la convention utilisée pour les notations.

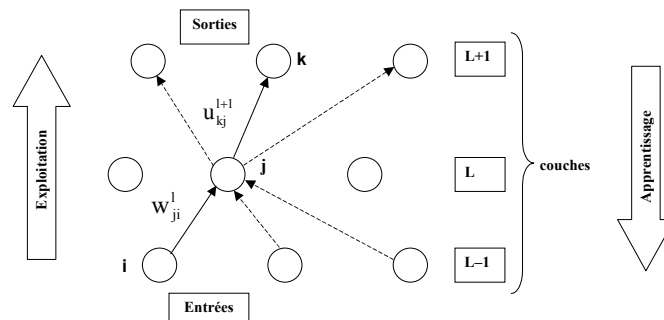


Figure 16 : Perceptrons multicouches

### Principe de l'apprentissage

En entrée, les couples de données sont constitués des pixels d'une image et en sortie, des coordonnées du coin supérieur gauche et du coin inférieur droit délimitant les volets.




Figure 17 : Couple de données (pixels de l'image et coordonnées des coins des volets)

Pour profiter des capacités de reconnaissance du réseau, les images utilisées comme exemples d'apprentissage représentent diverses configurations de fermeture des volets plombés.



Figure 18 : Types d'images utilisées pour l'apprentissage

La dimension des images est de 32x32 pixels. Cette taille, d'apparence faible, a pour conséquence de fournir 1024 entrées au réseau. La couche de sortie est constituée de 4 neurones, représentant les 4 coordonnées décrites à la figure 17. Concernant les couches cachées, deux solutions ont été testées : soit une couche intermédiaire de 512 neurones, soit 2 couches de 256 et de 64 neurones. Les résultats obtenus après l'apprentissage sont comparables pour les 2 types de réseaux, l'avantage de celui possédant 4 couches est de réduire le nombre de connexions d'environ 50%.

En récapitulatif, la structure du réseau à 3 couches est la suivante :

1024 neurones en entrée

la première matrice de poids :  $w[512][1024]$  (512 lignes et 1024 colonnes)

512 neurones dans la couche cachée

la seconde matrice des poids :  $u[4][512]$  (4 lignes et 512 colonnes)

4 neurones de sorties

### *Algorithme d'apprentissage*

1. Initialisation aléatoire (étape  $t$ ) des matrices de poids (valeur comprise entre  $-1$  et  $+1$ ) :  $w_{ji}(t)$  et  $u_{kj}(t)$ .
2. Calculs des activations de la couche cachée :

$$\alpha_j^{(L)} = \sum_{i=1}^{N_{(L-1)}} w_{ji}^L y_i^{(L-1)}.$$

3. Calculs des sorties de cette même couche cachée :

$$y_j^{(L)} = \Phi_j(\alpha_j^{(L)}) = \frac{1}{1 + \exp(-\alpha_j^{(L)})}.$$

4. Calculs des activations et des sorties de la couche de sortie :

$$\alpha_k^{(L+1)} = \sum_{j=1}^{N_{(L)}} u_{kj}^{(L+1)} y_j^{(L)} \quad \text{et} \quad y_k^{(L+1)} = \Phi_k(\alpha_k^{(L+1)}) = \frac{1}{1 + \exp(-\alpha_k^{(L+1)})}.$$

5. Calcul de l'énergie quadratique :

$$E_p = \frac{1}{2} \sum_{k=1}^{N_{(L+1)}} (d_k^{(L+1)} - y_k^{(L+1)})^2 \text{ avec } \mathbf{d}_k = \{x_1, y_1, x_2, y_2\}. \text{ (fig.17)}$$

6. Mise à jour des poids de la couche de sortie :

$$u_{kj}(t+1) = u_{kj}(t) + \eta (d_k - y_k^{(L+1)}) y_k^{(L+1)} (1 - y_k^{(L+1)}) y_j^{(L)}$$

avec  $\eta$  = coefficient d'apprentissage.

7. Mise à jour des poids de la couche cachée :

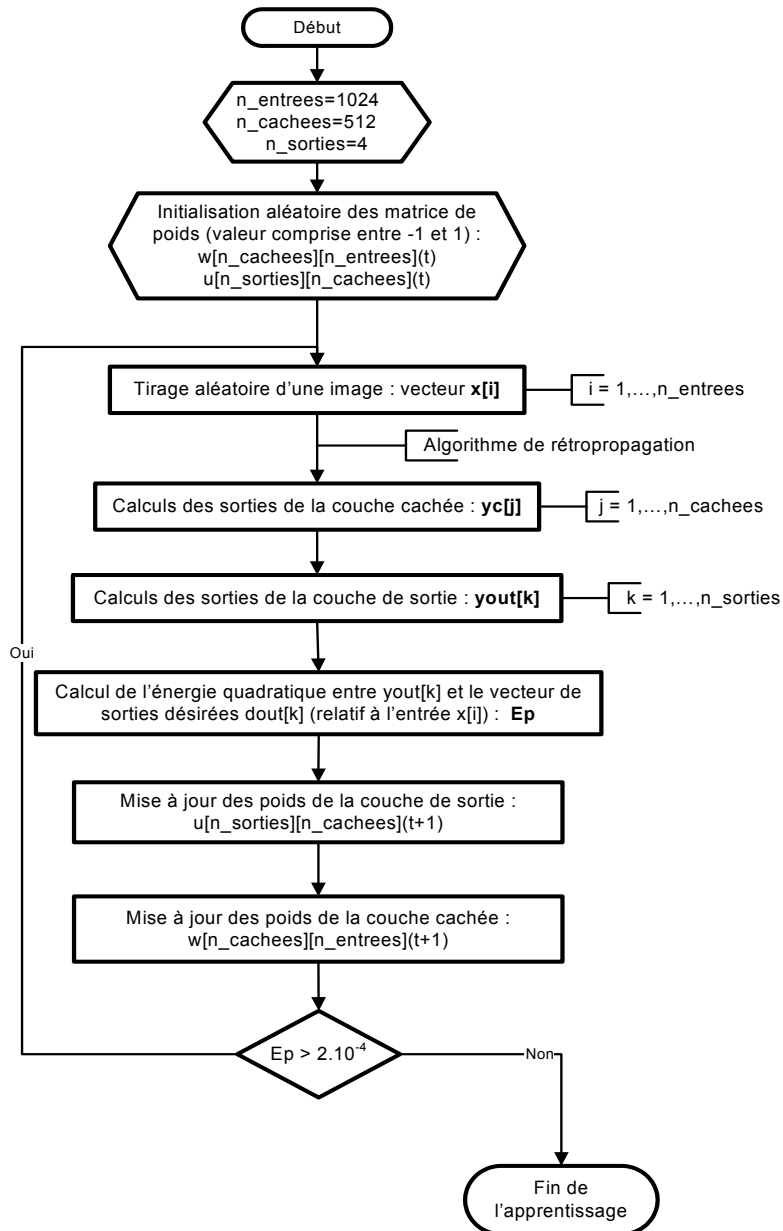
$$w_{ji}(t+1) = w_{ji}(t) + \eta y_j^{(L)} (1 - y_j^{(L)}) \left( \sum_{k=1}^{N_{(L+1)}} \delta_k u_{kj} \right) y_i^{(L-1)}$$

avec

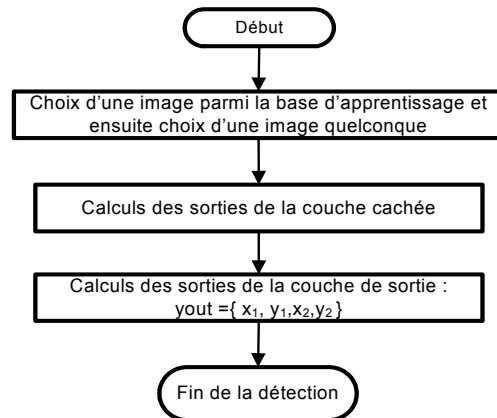
$$\delta_k = (d_k - y_k^{(L+1)}) y_k^{(L+1)} (1 - y_k^{(L+1)}).$$

Retour à l'étape 2 si  $E_p$  est supérieur à un seuil fixé à l'avance, représentatif de l'erreur tolérée entre les sorties souhaitées ( $d_k$ ) et les sorties calculées par l'algorithme ( $y_k$ ).



*Organigramme de l'apprentissage*

### *Organigramme de détection des volets*



### *Conclusions*

La méthode de détection des volets par les perceptrons multicouches procure des résultats encourageants sur les quelques images qui constituent une base d'apprentissage même si le temps d'apprentissage peut atteindre 7 à 8 minutes.

Afin d'améliorer ce temps de calculs, il faudrait considérer un autre code de programmation plus rapide que le C/C++. La programmation en code assembleur pourrait être envisagée.

Cette option sera d'autant plus intéressante que la base d'apprentissage devra contenir quelques centaines d'images pour que le réseau soit utilisé de façon optimale.

En effet, l'échantillon d'images utilisé lors de l'apprentissage devra être suffisant pour que le réseau développe ses capacités de généralisation et de plasticité. Autrement dit, le réseau sera capable d'identifier la position des volets dans une image totalement inconnue de sa base d'apprentissage. De nombreux essais seront nécessaires pour déterminer le nombre minimum d'images à inclure dans cette base.

Il reste à souligner le principal avantage des perceptrons multicouches qui est l'extrême rapidité de l'utilisation de ce réseau. Une fois l'apprentissage terminé, l'ensemble des connexions représentées par les matrices des poids sont "figées". La détection des volets plombés se résume alors en un simple calcul matriciel de quelques millisecondes.

## 5. Comparaisons des diverses méthodes utilisées

Le temps que prend une méthode de détection des volets est un critère important en programmation, surtout pour l'utilisateur futur, désireux d'obtenir un résultat rapide de la part du logiciel de traitement d'images.

Méthodes	Temps d'apprentissage (ms)	Temps de détection (ms)
Moyennes et écarts-types	/	100
Réseau connecté	/	5
Mémoires associatives	0,4	20
Réseau de Hamming	/	10
Réseau de Kohonen	100	200
Réseau ART1	1	5
Perceptrons multicouches	6500 à 8000 (1)	12

*Tableau 1: Comparaison des temps d'apprentissage et de détection*

Toutes les méthodes de détections, à part celle de Kohonen, sont beaucoup plus rapides que celle basée sur les moyennes et les écarts-types. L'utilisation des réseaux de neurones artificiels démontre donc un réel avantage en terme de vitesse de calcul de la position des volets plombés.

Concernant les perceptrons multicouches, le temps d'apprentissage (tab. 1) est nettement plus long vu d'une part, le nombre important de neurones et d'autre part, la convergence très lente de ce réseau, caractéristique de son algorithme de rétropropagation.

Il est également intéressant de montrer l'influence du nombre d'images de la base d'apprentissage sur le temps d'apprentissage.

Nombre d'images	Temps d'apprentissage (s)	Temps de détection (ms)
1	8	12
2	37	12
3	64	12
4	382	12

*Tableau 2 : Evolution du temps d'apprentissage des perceptrons multicouches en fonction du nombre d'images*

---

(1) Apprentissage d'une seule image.

## 6. Perspectives

Dans un premier temps, l'utilisation des réseaux neuronaux se limite à détecter des volets plombés pour ensuite les noircir. Cependant, les capacités offertes par ces réseaux peuvent être exploitées pour reconnaître et différencier des formes plus complexes.

Pour des clichés radiologiques, il s'agirait de faire reconnaître au réseau la forme d'un genou, d'une tête ou encore d'une main. Une régulation des niveaux de gris pourrait être opérée uniquement dans la partie utile de l'image et en fonction du type d'organe radiographié.

L'avantage serait alors d'appliquer des traitements d'images spécifiques permettant de mettre en évidence les tissus à observer. Par exemple, le réglage des niveaux de gris dans le cas de tissus osseux sera nettement différent que dans celui de tissus pulmonaires.

## 7. Références bibliographiques

### 7.1 Ouvrages

BODERI, Jean-Bernard, *Elaboration d'un réseau de neurones pour la prédiction du flux de chaleur critique dans les réacteurs à eau pressurisée*, Institut Gramme, Angleur, 1998.

DAVALO E., NAIM P., *Des réseaux de neurones*, France, Eyrolles, 1992.

DELACOUR J., LEVY J-C., *Systèmes à mémoire, Une approche multidisciplinaire*, France, Masson, 1989.

DEMANT C., STREICHER-ABEL B., WASZKEWITZ P., *Industrial Image Processing, Visual Quality Control in Manufacturing*, USA, Springer, 1999.

DREYFUS G., MARTINEZ J-M., SAMUELIDES M., GORDON M., BADRAN F., THIRIA S., HERAULT L., *Réseaux de neurones, Méthodologie et applications*, France, Eyrolles, 1994.

FAURE, Alain, *Cybernétique des réseaux neuronaux, Commande et perception*, France, Hermès, 1998.

TOUZET, Claude, *Les réseaux de neurones artificiels*, France, 1992.

VALLURU B.Rao, HAYAGRIVA V.Rao, *C++ Neural Networks and Fuzzy Logic*, USA, MIS Press, 1993.

## 7.2 Sites internet

[http://fr.wikipedia.org/wiki/Neurone\\_formel](http://fr.wikipedia.org/wiki/Neurone_formel)

<http://neuralnets.web.cern.ch/NeuralNets/nnwInHepHard.html>

<http://www.astrosurf.com/jmllapasset/publ/ccd.htm>

<http://www.grappa.univ-lille3.fr/polys/apprentissage/>

<http://www.lesia.obspm.fr/~erard/docs/CCD/CCD1.html>

<http://www.medex.be/fr/index.php>

<http://www.scico.u-bordeaux2.fr/~corsini/Cours/mainRNA>

<http://www.vieartificielle.com/article/index.php?id=54>

<http://www-igm.univ-mlv.fr/~dr/XPOSE2002/Neurones>