

## Détection de contours par transformée en ondelettes et réseaux de neurones

---

### Edgedetection Using Wavelet Transform and Neural Networks

---



#### Martial FORTHOFFER

Université de Nancy I  
Faculté des Sciences  
CRAN - LEA  
BP 239  
54506 Vandœuvre-les-Nancy

M. Forthoffer est né à Sarreguemines (Moselle) le 7 octobre 1966. Il a obtenu le DEA Métrologie-Automatique-Electrotechnique en 1989, à l'Université de Nancy I. Sa thèse de Doctorat dans la spécialité Automatique, soutenue en janvier 1992, concerne la détection de contours par transformée en ondelettes et réseaux de neurones. Ses domaines de recherche actuels s'inscrivent dans la segmentation d'images par les contours et le traitement du signal bidimensionnel.



#### Jean-Pierre GIROD

Université de Nancy I  
même adresse

J.-P. Girod est né en 1959 à Paris. Il a interrompu ses études au niveau du Brevet de Technicien Supérieur en électronique (1980) pour travailler dans l'industrie. Après plusieurs années de formation continue dans le cadre du Conservatoire National des Arts et Métiers, il a obtenu le Diplôme d'Ingénieur CNAM, spécialité Automatique (1991). Il prépare actuellement une thèse de Doctorat sur les réseaux neuromimétiques, essentiellement en traitement d'images, mais reste ouvert à tout autre champ d'investigations.



#### Jacques BREMONT

Université de Nancy I  
même adresse

J. Bremont est né en 1938 à Châlon-sur-Marne. Professeur à l'Université de Nancy I depuis 1981, il dirige, avec Michel Lamotte, Directeur de Recherche

au CNRS, une équipe de 25 personnes au Centre de Recherche en Automatique de Nancy, URA CNRS 821. Avec sa thèse de 3<sup>e</sup> cycle en 1968 sur le perceptron et sa thèse d'Etat en 1975 sur la reconnaissance automatique de la parole par les ensembles flous, il a introduit, en Automatique à Nancy, la recherche en réseaux de neurones et en ensembles flous. Il renforce actuellement son action dans les domaines du traitement du signal et de l'information, de la reconnaissance de la parole, de la visionique, et dans l'appréciation quantitative de grandeurs qualitatives, parfois subjectives, et leur modélisation.

---

### RÉSUMÉ

La méthode présentée dans cet article, constitue un nouvel outil d'extraction des contours d'une image en niveaux de gris, par coopération de techniques : décomposition en ondelettes et réseaux neuromimétiques.

La première partie est consacrée aux rappels nécessaires quant au formalisme de la décomposition en ondelettes, ainsi que ses principales propriétés.

La phase délicate de l'algorithme réside dans la recombinaison optimale des différentes résolutions, afin d'obtenir des contours fins et sans bruit.

Cette tâche est avantagement confiée à un réseau de neurones, objet de la deuxième partie.

L'attrait majeur de cette nouvelle technique, est sa capacité à traiter correctement des images aux caractéristiques très différentes, sans avoir à modifier de paramètres.

#### MOTS CLÉS

Ondelettes, segmentation d'images, détection de contours, réseaux de neurones.

---

### ABSTRACT

The method exposed in this paper represents a new edge-detection tool of a grey-level image by the cooperation of two technics : wavelet decomposition and neural networks.

The first part recalls the necessary background on mono and bidimensional wavelet decomposition and their main properties.

The difficult phase of the algorithm lies in the optimal recombination of different resolutions, in the aim to obtain thin and noiseless edges. This

work is given to a neural network which constitutes the object of the second part.

The main interest of this new method is to give good results with images whose characteristics are completely different, without to modify any parameters.

#### KEY WORDS

Wavelets, image segmentation, edge detection, neural networks.

## 1. Introduction

La segmentation d'images est une étape pivot entre les phases d'amélioration-restauration et celle de décision. C'est à ce niveau qu'est effectuée une détection, le plus souvent non réversible, de l'information utile dans une image.

Il existe principalement deux approches pour segmenter une image : l'approche par les contours et l'approche par les régions qui lui est duale. Nous nous intéressons ici à l'approche par la détection de contours [10].

Il s'avère que, tenir compte de facteurs perturbateurs tels que le flou ou le bruit apportés lors des phases d'acquisition ou de prises de vues, améliore sensiblement les performances de la détection [5].

La transformée en ondelettes est une analyse multi-échelle permettant une meilleure interprétation du signal et donc des perturbations [4]. Nous comparons son apport à des méthodes plus classiques comme l'opérateur de Canny-Deriche [2].

La phase de détection de contours proprement dite réside dans l'extraction des discontinuités de l'image, depuis les différentes échelles. Une solution consiste à combiner les différentes résolutions du signal image, en utilisant un réseau de neurones [12]. Celui-ci est chargé de déterminer une loi de combinaison optimale, face à un critère d'erreur quadratique, calculé pendant la phase d'apprentissage, à l'aide d'une référence déterminée par un expert.

Cette approche originale permet d'appréhender automatiquement, par le biais de l'apprentissage neuronal, le caractère multirésolution de la décomposition en ondelettes.

## 2. Détection de contours par analyse multirésolution

### 2.1. TRANSFORMÉE EN ONDELETTES SUR SIGNAUX DISCRETS

La transformée en ondelettes est obtenue par la projection du signal continu sur une base orthogonale constituée d'une fonction d'échantillonnage, la fonction d'échelle  $\phi_j(t)$ , et d'une fonction analysante, l'ondelette  $\psi_j(t)$ ,  $j$  étant le niveau de résolution souhaité [6] [8] [9].

Dans le cas discret, le signal d'origine  $s(t)$  devient  $S_{0,k}$  assimilé à l'approximation de  $s(t)$  au niveau de résolution  $j = 0$ . L'approximation, au niveau de résolution  $j$ , est donnée par la relation (1) dans laquelle  $h$  est un filtre passe-bas représentant la fonction d'échelle  $\phi$ .

$$(1) \quad S_{j,k} = \sum_n h_{2k-n} S_{j+1,n}$$

Les coefficients d'ondelettes, correspondant à la projection du signal sur les fonctions  $\psi_j$ , au niveau de résolution

$j$ , sont donnés par la relation (2), dans laquelle  $g$  est un filtre passe-haut représentant l'ondelette.

$$(2) \quad C_{j,k} = \sum_n g_{2k-n} S_{j+1,n}$$

L'opération de décomposition en niveaux de résolution successifs est illustrée par la figure 1, dans laquelle les traits pleins matérialisent la prise en compte des informations par les coefficients des filtres  $h$  et  $g$ . Les croix représentent les informations délaissées lors du passage de la résolution  $j$  à la résolution  $j - 1$ .

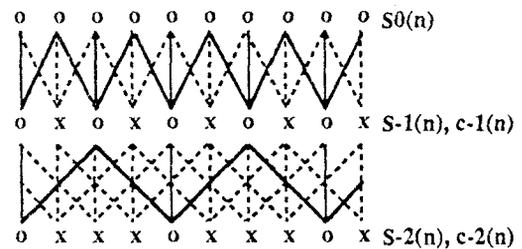


Figure 1. — Diagramme neuronal.

### 2.2. TRANSFORMÉE EN ONDELETTES SANS SOUS-ÉCHANTILLONNAGE

Dans la problématique de détection de contours, les informations exploitées sont essentiellement contenues dans les hautes-fréquences, c'est-à-dire les coefficients d'ondelettes  $C_{j,k}$ . Le sous-échantillonnage matérialisé par l'alternance des « x » et « o » dans la figure 1, provoque la non (invariance en translation de la transformée en ondelettes, ce qui entraîne une réponse différente, selon la position de la discontinuité (échantillon pair ou impair).

Pour pallier à ce problème, nous calculons la totalité des échantillons marqués « o » et « x », en intercalant simplement  $2^{-j} - 1$  zéros entre les coefficients des filtres  $h$  et  $g$  qui permettent le passage du niveau de résolution  $j$  au niveau de résolution  $j - 1$  [4] [7]. Cette opération revient à dilater l'échelle des fréquences ( $H(\omega) \rightarrow H(2^{-j}\omega)$  et  $G(\omega) \rightarrow G(2^{-j}\omega)$ ). Les figures 2 et 3 représentent la décomposition et la reconstruction du signal avec ces hypothèses.

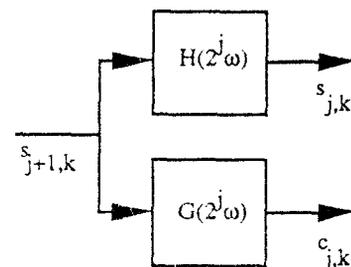


Figure 2. — Décomposition du signal.

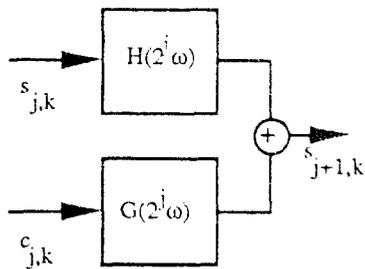


Figure 3. — Reconstruction du signal.

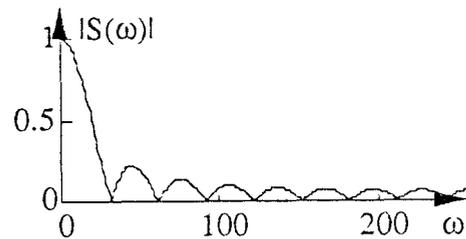


Figure 5. — Signal bruité.

### 2.3. DÉTECTION DE CONTOURS ET PERTURBATIONS

Dans notre étude, nous considérons que tout signal peut être caractérisé par un signal idéal auquel s'ajoute un flou et du bruit lors de l'acquisition. Le flou est modélisé par la convolution d'un signal net avec un filtre passe-bas de type gaussien, [11] :

$$(3) \quad S_f(x, \sigma) = S_n * \text{psf}(x, \sigma),$$

avec  $\text{psf}(x, \sigma) = \frac{e(-x^2/2\sigma^2)}{\sqrt{2\pi}\sigma}$ , où  $\sigma$  correspond à l'écart-type de la gaussienne.

Si le bruit est supposé additif, [10], le signal flou bruité peut être modélisé par la relation suivante :

$$(4) \quad S(x) = S_n * \text{psf}(x, \sigma) + \alpha b(x)$$

où  $b(x)$  est un bruit blanc de variance unitaire, dont  $\alpha$  pondère l'influence.

Nous nous intéressons essentiellement à un signal en échelon, défini par sa transformée de Fourier en forme d'une fonction sinus-cardinal.

$$(5) \quad S_n(x) = \begin{cases} 1 & \text{pour } x > 0 \\ 0 & \text{pour } x \leq 0. \end{cases}$$

L'influence du bruit sur un signal échelon est illustrée par les courbes spectrales des figures 4, 5, 6 et 7.

Il apparaît nettement que le bruit perturbe le signal sur toute l'échelle des fréquences. Cependant, son effet est très néfaste aux endroits où le signal est faible ( $\omega$  grand), et peu gênant où il est puissant ( $\omega$  petit). Le flou a pour

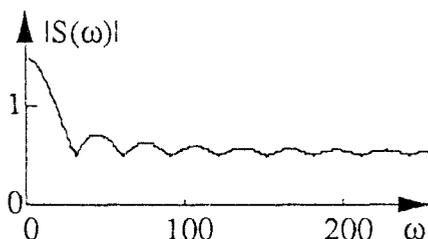


Figure 4. — Signal échelon.

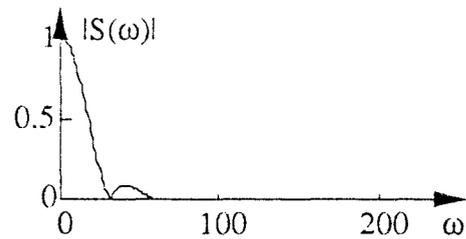


Figure 6. — Signal flou.

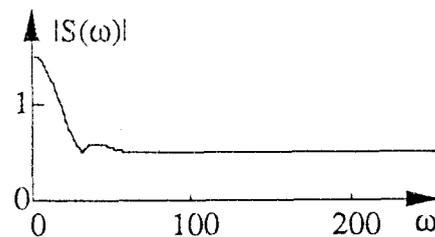


Figure 7. — Signal flou et bruité.

effet de pondérer le signal en laissant intactes les basses fréquences et en atténuant les hautes fréquences.

L'apport de l'analyse multirésolution par ondelettes, nous permet d'étudier le signal sous différentes bandes de fréquences, dans lesquelles les effets des perturbations diffèrent.

### 2.4. CHOIX DE LA BASE DE HAAR

Le problème de la détection de contours impose un choix de base assez restrictif. Celle-ci doit être représentée par un filtre  $g(n)$ , de type gradient ou laplacien, c'est-à-dire du 1<sup>er</sup> ou du 2<sup>e</sup> ordre. Malheureusement, la plupart des bases d'ondelettes sont d'ordre supérieur, ce qui les rend inadaptées à notre problème. Une seconde contrainte est la taille de ces filtres. Pour une détection rapide, il est impératif de minimiser les temps de calcul et les effets de bords, par l'utilisation de filtres courts. Parmi les bases répondant à ces contraintes, nous trouvons celle de Shen et celle de Haar, toutes deux du premier ordre. L'application proposée utilise la base de Haar, qui offre un bon compromis entre la qualité des résultats obtenus et les moyens de calculs à mettre en œuvre [5].

Les filtres H et G associés à la base de Haar sont de la forme :

$$(6) \quad |H(\omega)| = \left| \cos \frac{\omega}{2} \right| \quad \text{et} \quad |G(\omega)| = \left| \sin \frac{\omega}{2} \right|$$

avec  $\omega \in [-\pi, \pi]$ .

La décomposition en ondelettes est alors effectuée par des filtres  $F_j(\omega)$ , où  $j$  représente le niveau de résolution. Pour  $j = -1$  à  $-3$ , ils ont la forme suivante :

$$(7) \quad \begin{aligned} F_{-1}(\omega) &= G(\omega), \\ F_{-2}(\omega) &= H(\omega) G(2\omega), \\ F_{-3}(\omega) &= H(\omega) H(2\omega) G(4\omega). \end{aligned}$$

Pour une décomposition complète, il faudrait ajouter un filtre représentant l'approximation du signal à la résolution  $j$  :

$$(7') \quad \begin{aligned} A_{-1}(\omega) &= H(\omega), \\ A_{-2}(\omega) &= H(\omega) H(2\omega), \\ A_{-3}(\omega) &= H(\omega) H(2\omega) H(4\omega). \end{aligned}$$

## 2.5. CAS BIDIMENSIONNEL

Dans le cadre de la détection de contours dans les images, l'algorithme est appliqué en lignes et en colonnes. Les filtres de décomposition deviennent alors :

$$(8) \quad \begin{aligned} F_{Hj}(\omega_1, \omega_2) &= F_j(\omega_1) A_j(\omega_2) \\ F_{Vj}(\omega_1, \omega_2) &= A_j(\omega_1) F_j(\omega_2) \\ F_{Dj}(\omega_1, \omega_2) &= F_j(\omega_1) F_j(\omega_2), \end{aligned}$$

où  $F_{Hj}$ ,  $F_{Vj}$  et  $F_{Dj}$  ont pour effet de détecter respectivement les contours horizontaux, verticaux et diagonaux.

Pratiquement le signal obtenu avec  $F_{Dj}$ , n'apportant que très peu d'informations supplémentaires, n'est plus considéré par la suite.

## 3. Détection de contours par combinaisons multi-échelles

### 3.1. INTERPRÉTATION DES EFFETS DU BRUIT ET DU FLOU SUR UN SIGNAL

La figure 8 représente un signal en échelon rendu flou par la convolution avec une gaussienne de variance  $\sigma^2 = 4$ , et bruité par un bruit blanc de moyenne nulle et de variance  $\sigma^2 = 0,04$ .

Les figures 9, 10 et 11 représentent sa décomposition en coefficients d'ondelettes pour les niveaux de résolutions  $-1$ ,  $-2$  et  $-3$ .

Nous remarquons que les contours détectés sont plus marqués et moins bruités à mesure que le niveau de résolution diminue. En revanche, leur localisation devient moins précise.

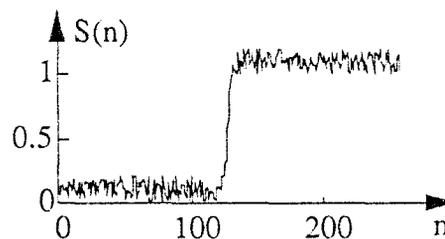


Figure 8. — Echelon flou et bruité.

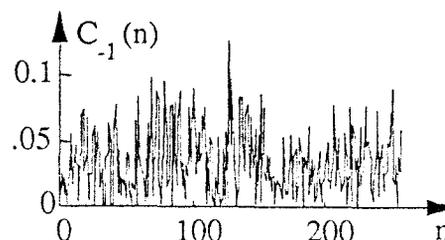


Figure 9. — Décomposition en ondelettes  $j = -1$ .

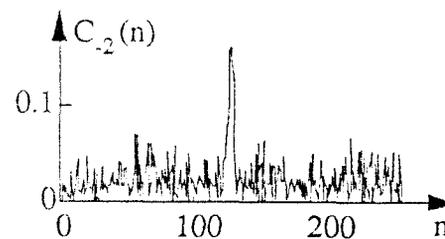


Figure 10. — Décomposition en ondelettes  $j = -2$ .

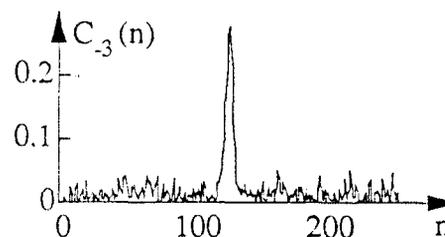


Figure 11. — Décomposition en ondelettes  $j = -3$ .

Ces constatations démontrent la nécessité d'exploiter les informations contenues dans les différentes résolutions, afin de s'affranchir au mieux des perturbations.

Le problème qui se pose est de trouver une loi de composition permettant de reconstituer les contours recherchés. Dans cet objectif nous avons expérimenté une simple combinaison des différentes résolutions  $C_j$ , pondérées par des coefficients  $\alpha_j(x)$ . Pour cette étude nous nous sommes limités aux trois premières résolutions qui contiennent la majeure partie de l'information utile.

$$(9) \quad \text{Cont}(x) = \alpha_{-1}(x) C_{-1}(x) + \alpha_{-2}(x) C_{-2}(x) + \alpha_{-3}(x) C_{-3}(x),$$

où  $C_j(x)$  correspond aux signaux des figures 9, 10 et 11.

Cette approche, avec des pondérations constantes ( $\alpha_{-1}(x) = 1/3$ ,  $\alpha_{-2}(x) = 1/2$  et  $\alpha_{-3}(x) = 1$ ), est illustrée par la figure 12, où  $\text{Cont}(x)$  reflète un compromis entre la précision de la localisation et la sensibilité aux perturbations.

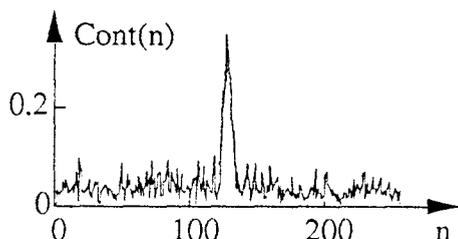


Figure 12. — Détection des discontinuités.

### 3.2. ALGORITHME DE DÉTECTION DE CONTOURS 2D

Nous reprenons les remarques précédentes, pour la détection de contours dans une image. L'algorithme, schématisé dans la figure 13, se compose d'une étape de décomposition en ondelettes, effectuée en lignes et en colonnes avec les filtres  $F_j$  et  $A_j$  définis au paragraphe 2.4. Les différentes résolutions de l'image sont combinées par les facteurs  $\alpha_j(x)$ . Ceux-ci sont, soit fixés, soit déterminés par une opération de mesure du bruit et du flou. On note que pour obtenir des contours fins, et bien localisés, une opération d'extraction des maxima locaux s'avère impérative.

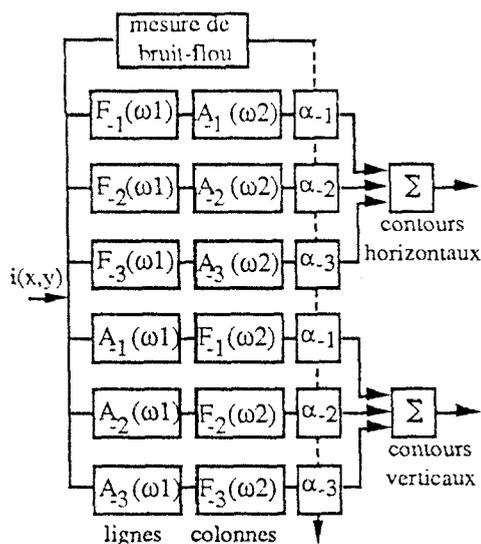


Figure 13. — Algorithme de détection de contours.

Pour déterminer ces facteurs, différentes méthodes existent. Les figures 20, 23 et 26 présentent les résultats obtenus sur les images des figures 19, 22 et 25, ayant des

caractéristiques très différentes et pour lesquelles les  $\alpha_j(x)$  prennent les valeurs empiriques précédemment définies. Les images sont représentées après une phase de seuillage, dont le seuil est réglé manuellement.

La solution idéale consiste à effectuer une mesure précise du bruit et du flou dans l'image ce qui apporterait une non-linéarité au niveau des coefficients  $\alpha_j(x)$ , tenant ainsi compte des caractéristiques locales de l'image [5]. Cependant, celle-ci a pour inconvénient d'être imparfaite et de nécessiter des temps de calculs importants. C'est pourquoi nous lui avons préféré une méthode de recombinaisons par un réseau de neurones.

### 3.3. DÉTECTION DE CONTOURS 2D PAR COOPÉRATION « ONDETTES-NEURONES »

#### 3.3.1. Principe

La recherche d'une loi de composition de toutes ces informations, optimale pour un grand nombre d'images aux caractéristiques très différentes, est donc le point crucial de cette technique. Les difficultés rencontrées dans la recherche de cette loi, nous ont conduits à confier cette tâche à un réseau de neurones, [3], [12].

Le modèle utilisé est représenté par la figure 14. Il s'agit d'un réseau à couches, dont l'apprentissage est régi par la règle de rétropropagation du gradient [1].

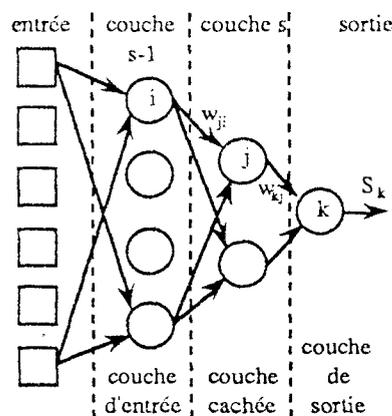


Figure 14. — Réseau à couches.

L'interface entre la décomposition en ondelettes et le réseau de neurones est réalisée en appliquant à chaque neurone de la couche d'entrée, les niveaux des pixels présents dans chacune des trois résolutions retenues, dans les deux directions et suivant un voisinage  $3 \times 3$ . Chaque neurone de la couche d'entrée reçoit donc 3 résolutions  $\times$  2 directions  $\times$  9 pixels.

Le réseau de neurones a pour fonction de déterminer si le pixel de coordonnées  $(x, y)$  dans l'image d'origine, appartient au tracé d'un contour.

A cet effet, il ne comporte qu'un seul neurone dans sa couche de sortie, puisque son niveau d'activation doit

refléter un degré d'appartenance à une frontière. Pour effectuer ce traitement sur toute l'image, la structure neuronale est appliquée successivement sur tous les pixels des images de la décomposition en ondelettes.

### Apprentissage :

La rétropropagation du gradient est un algorithme d'apprentissage supervisé, il est donc indispensable de lui fournir une image de référence, modèle du résultat à atteindre. Nous avons à cet effet constitué des leçons, à partir de la banque d'images du GRECO GDR 134-GT8, sur lesquelles nous avons extrait les contours à l'aide de méthodes classiques, adaptées à chacune d'elles.

Le but visé étant l'obtention d'un réseau capable de traiter indifféremment et sans modification de réglage, des images de caractéristiques très différentes, la propriété recherchée est la capacité de généralisation.

Pour que le réseau bénéficie de cette propriété, deux conditions principales sont à respecter :

- il faut que les images utilisées lors de l'apprentissage aient des caractéristiques variées ; le lot utilisé est représenté par les figures 19 et 22 ;

- il faut limiter la connectivité du réseau, sans quoi il serait capable d'apprendre « par cœur » les leçons, et incapable de traiter correctement une image inconnue.

Par ailleurs, les temps de calculs devenant rapidement prohibitifs lorsque la connectivité augmente, nous avons scindé le réseau représenté figure 15 en deux parties visibles sur la figure 16 :

- la première, reliée à la transformation en ondelettes, est chargée de la recombinaison multirésolution des informations et génère une image unique, dont les niveaux de gris représentent les degrés d'appartenance aux contours des pixels correspondants dans l'image d'origine ;

- la deuxième, reliée à l'image des degrés d'appartenance dans un voisinage  $3 \times 3$ , a pour rôle la validation des contours en fonction de leur géométrie.

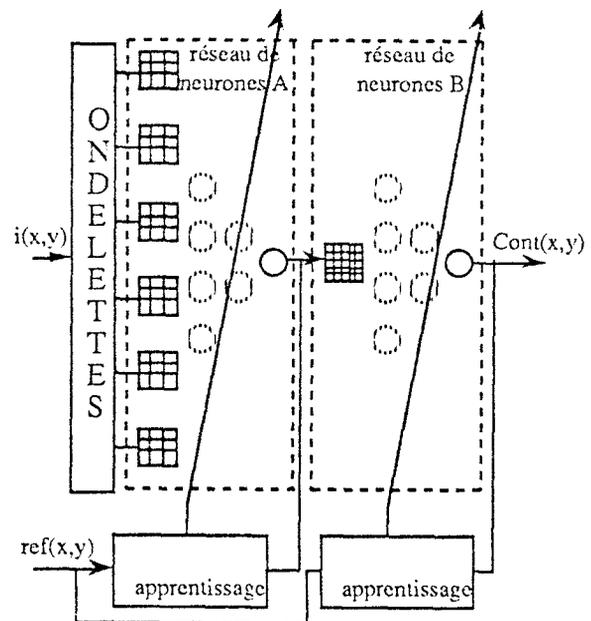


Figure 16. — Topologie des réseaux utilisés.

### Utilisation :

Lors de l'utilisation, les deux parties de réseau concaténées, reçoivent en entrée l'image des différentes résolutions de la décomposition en ondelettes. Le réseau se comporte comme un classificateur dont la valeur de sortie définit le tracé des contours.

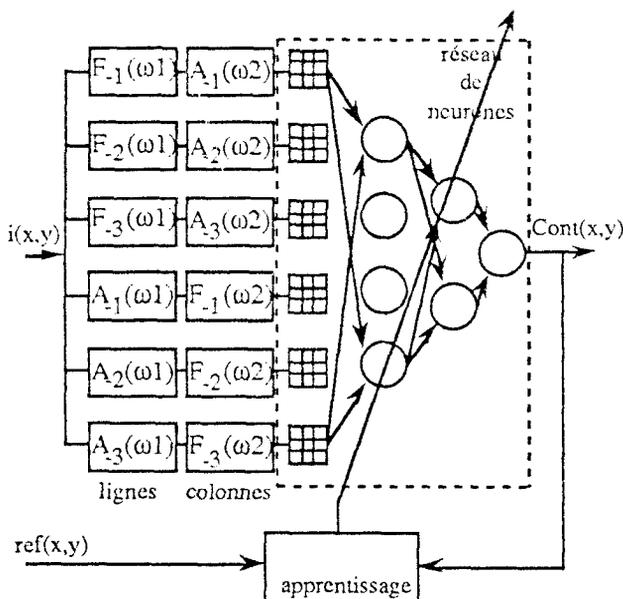


Figure 15. — Coopération ondelettes-neurones.

### 3.3.2. Expérimentations

Dans le but d'obtenir une bonne généralisation du réseau employé, les images brutes et de références sont en fait des agrégats de différentes images, choisies pour leurs disparités de caractéristiques.

La difficulté majeure rencontrée, lors de la mise en œuvre des réseaux de neurones, est le choix du nombre de couches et du nombre de neurones que comporte chacune d'elles.

La configuration retenue, comporte trois couches dans chacune des deux parties de réseau, soit six couches au total. La première partie comporte six neurones dans la couche d'entrée, quatre dans la couche cachée et un dans celle de sortie. La couche d'entrée est reliée aux décompositions en ondelettes par l'intermédiaire de  $6 \text{ neurones} \times 3 \text{ résolutions} \times 2 \text{ directions} \times 9 \text{ pixels}$  soit 324 poids variables. La couche cachée reçoit les informations de la couche d'entrée via  $6 \times 4$ , soit 24 poids variables. Le neurone de sortie est relié aux quatre précédents par 4 poids variables.

Cette première partie possède donc 11 neurones interconnectés par 352 poids variables.

La deuxième partie comporte 25 neurones dans la couche d'entrée, deux dans la couche cachée et un neurone de sortie. Le nombre de neurones de la couche d'entrée correspond aux 25 premières formes de contours obtenues par association de segments élémentaires suivant 4 orientations (0°, 45°, 90° et 135°). La couche d'entrée est reliée à la première partie de réseau dans un voisinage cinq, par l'intermédiaire de 25 neurones × 25 entrées soit 625 poids variables. La couche cachée reçoit les informations de la couche d'entrée via 25 × 2 soit 50 poids variables. Le neurone de sortie est relié aux deux précédents par deux poids variables.

Cette deuxième partie possède donc 28 neurones interconnectés par 677 poids variables.

L'ensemble des deux parties concaténées se comporte comme un unique réseau composé de 28 + (11 × 25) = 303 neurones, interconnectés par 677 + (352 × 25) = 9 477 poids variables.

Chaque poids variable représente un paramètre réglable par l'apprentissage. Mais en réalité, les poids de la première partie sont répétés 25 fois, ce qui limite le nombre total de paramètres à 677 + 352 = 1 029.

La simulation de cette configuration est réalisée sur une machine de type VME sous OS9, munie d'un microprocesseur 68 030 cadencé à 25 MHz.

Les différentes images de référence sont concaténées en une seule, dont les dimensions sont de 256 × 512 pixels.

L'apprentissage de la première partie est arrêté après 40 itérations, ce qui représente environ 192 heures de temps CPU, le réseau n'évoluant plus significativement.

Dans les mêmes conditions, la deuxième partie du réseau est obtenue après 25 itérations, soit après 16 heures d'apprentissage environ.

Les figures 21 et 24 illustrent les contours extraits sur les images des figures 19 et 22 choisies parmi le lot d'apprentissage.

Les capacités de généralisation de notre méthode sont visibles sur la figure 27, où le traitement est effectué sans modification de réglage, sur l'image de la figure 25 étrangère au lot d'apprentissage.

Subjectivement, nous pouvons apprécier la finesse et la relative continuité des contours extraits, ainsi que le faible bruit.

Pour être en mesure de quantifier la qualité de notre méthode, il fallait une image de contours de référence incontestable. A cet effet, nous avons construit une image de synthèse comportant divers niveaux de gris, dont les contours exacts sont très faciles à obtenir. Nous lui avons ajouté un bruit blanc de moyenne 25 et d'écart-type 14,5. Cette image et ses contours exacts sont représentés sur les figures 28 et 29.

L'image des contours exacts comporte 3 220 pixels et nous nous proposons, pour qualifier notre méthode, de compter le nombre de pixels de contours détectés PDet et le nombre de pixels parasites PPar.

Ces mesures permettent de définir un pourcentage de contours extraits %PV et un rapport signal sur bruit SNR :

$$(9) \quad \%PV = \frac{P_{Det}}{3\,220}$$

$$(10) \quad SNR = \frac{P_{Det}}{P_{Par}}$$

Bien entendu, cette mesure n'est valable que par comparaison ; c'est pourquoi nous effectuons le même calcul pour une méthode classique, l'algorithme de CANNY-DERICHE [2].

Les courbes des figures 17 et 18 reportent respectivement %PV et SNR correspondant aux images des figures 31 et 32, lesquelles sont obtenues par seuillage à 20 pour CANNY-DERICHE, et 128 pour notre méthode.

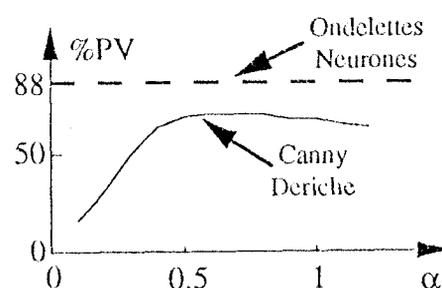


Figure 17. — Pourcentage de pixels extraits.

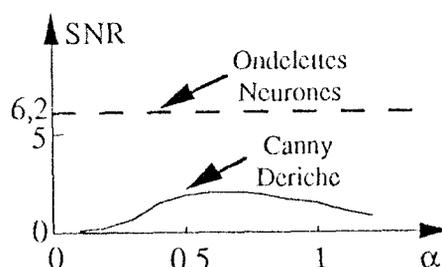


Figure 18. — Rapport signal/bruit.



Figure 19. — Image AQUITAIN.

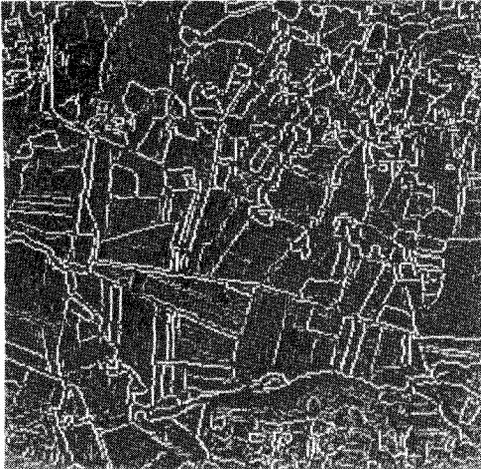


Figure 20. — Contours Ondelettes.

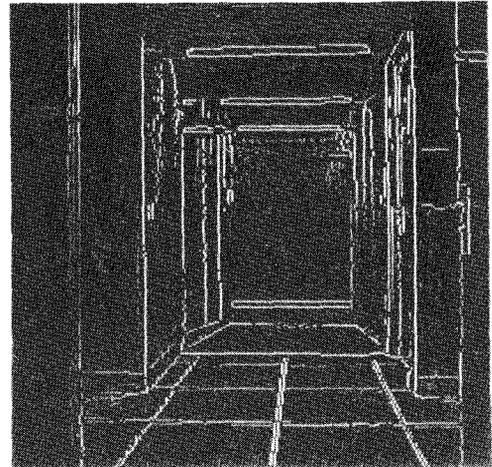


Figure 23. — Contours Ondelettes.

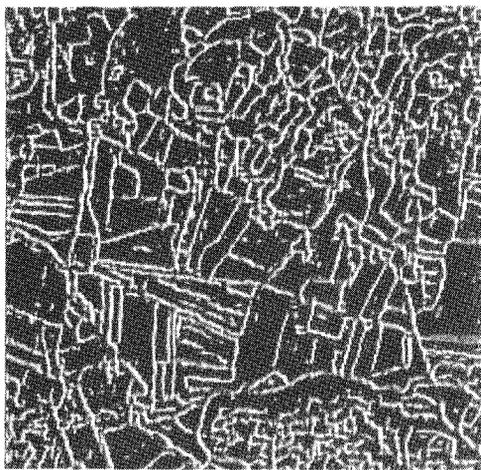


Figure 21. — Contours Ondelettes + Neurones.

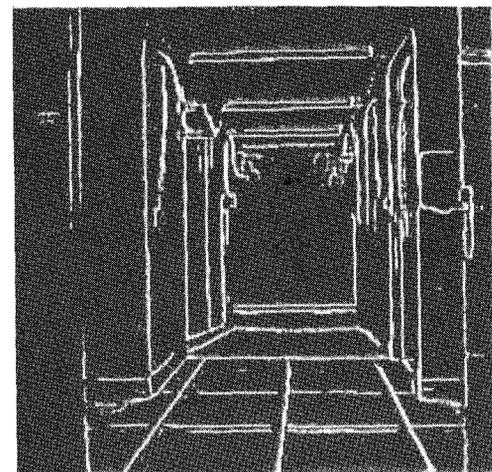


Figure 24. — Contours Ondelettes + Neurones.

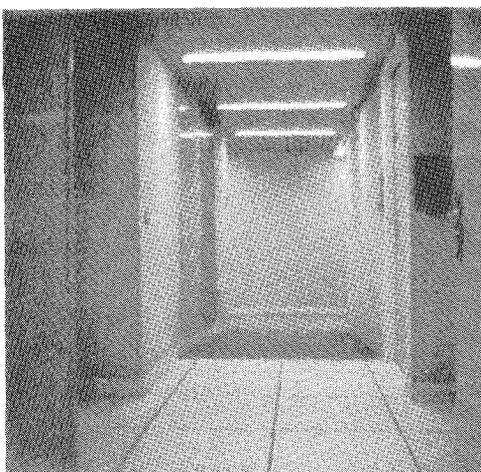


Figure 22. — Image COULOIR.



Figure 25. — Image FEMME.



Figure 26. — Contours Ondelettes.

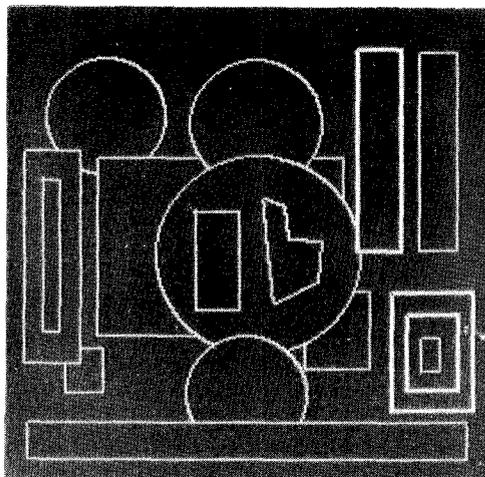


Figure 29. — Contours de références.



Figure 27. — Contours Ondelettes + Neurones.

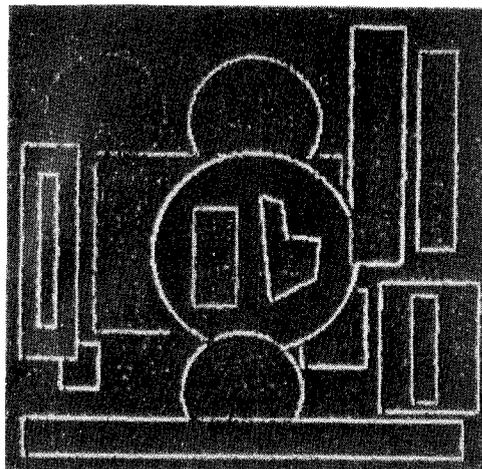


Figure 30. — Contours Ondelettes + 1<sup>re</sup> Partie.

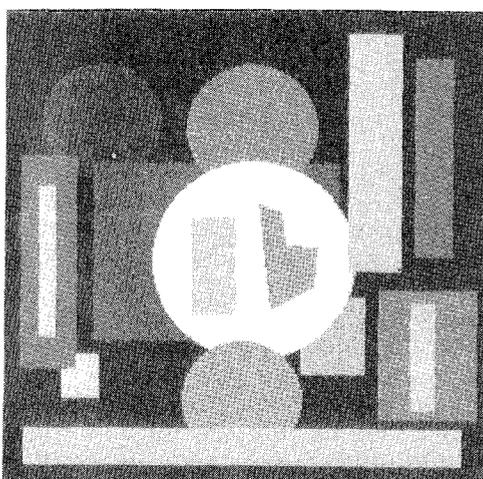


Figure 28. — Image SYNTHESE + BRUIT.

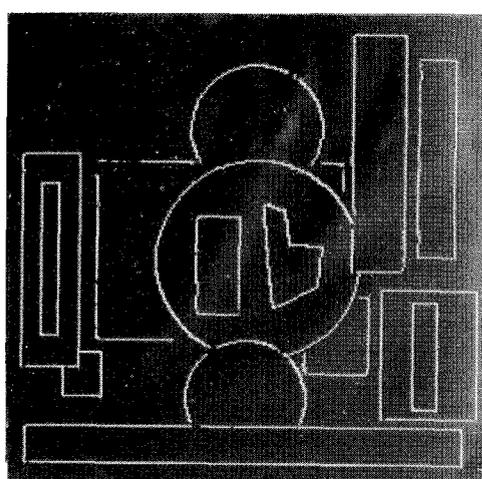


Figure 31. — Contours Ondelettes + Neurones.

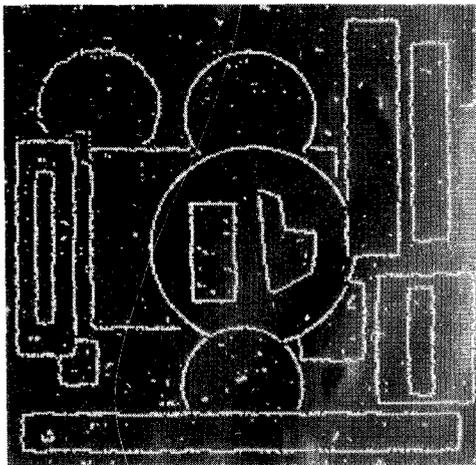


Figure 32. — Contours CANNY-DERICHE.

Le seuil choisi pour CANNY-DERICHE correspond au meilleur compromis entre %PV et SNR, tandis que notre algorithme est utilisé avec un seuil invariable de 128, valeur médiane de l'échelle de quantification (256 niveaux de gris).

Nous constatons que l'algorithme de CANNY-DERICHE donne au plus 71 % de pixels de contours, avec un rapport signal sur bruit de 2,09 pour un alpha de 0,6, tandis que nous atteignons 88 % et 6,15 pour l'algorithme ondelettes-neurones, sans aucun paramètre à régler. En fait, la comparaison des images des figures 31 et 32 illustrant les deux méthodes, montre que CANNY-DERICHE extrait bien tous les contours, mais que ceux-ci sont très bruités, entraînant la chute de %PV et l'augmentation de SNR, alors que la coopération ondelettes et réseau de neurones fournit des contours nets et rectilignes, exempts de bruit. L'image de la figure 30, extraite à la sortie de la première partie du réseau, tend à démontrer que la deuxième partie recherche des relations géométriques ou corrélatives pour éliminer le bruit et affiner les contours.

Le défaut de détection du cercle supérieur gauche est probablement dû à un manque de représentativité du lot d'images d'apprentissage.

## 4. Conclusions et perspectives

La coopération des deux techniques permet d'allier avantageusement d'une part, la représentation complète du signal sous différentes résolutions, fournie par la transformation en ondelettes, et d'autre part le caractère autoréglable des réseaux neuromimétiques, dans la recherche d'une loi de recombinaison optimale.

Le principal attrait de cette méthode, contrairement à celles utilisant les gradients ou les laplaciens, est de fournir des contours presque binaires, bien localisés, pour des

transitions lentes, rapides ou bruitées, sans avoir de paramètres à ajuster pour chaque situation.

La méthode proposée n'a pas la prétention de devenir un outil universel, mais elle ouvre la voie à d'autres expérimentations dans la recherche de moyens polyvalents de segmentation, en intégrant une phase embryonnaire d'interprétation.

Hormis la phase préliminaire d'apprentissage très coûteuse en temps de calculs, l'exploitation de cette méthode peut s'envisager en temps réel avec une architecture pipe-line, dans la mesure où la transformée en ondelettes, comme les réseaux de neurones, peuvent se décomposer en produits de convolution.

Par ailleurs, il reste beaucoup d'expérimentations à faire dans le domaine des ondelettes, comme l'utilisation de décompositions en quinconce, leur caractère isotrope et non séparable, permet de réduire le nombre de résolutions à étudier, donc a priori les temps de calculs. Cependant, elle nécessite l'emploi d'opérateurs d'ordre supérieur à 2 dont le comportement peut-être plus difficile à exploiter.

Manuscrit reçu le 9 septembre 1991.

## BIBLIOGRAPHIE

- [1] E. DAVALO & P. NAIM, *Des réseaux de neurones*, Paris, Eyrolles, 1990.
- [2] R. DERICHE, *Fast algorithm for low-level vision*. IEEE Transaction on PAMI, Vol. 12, N° 1, 1991, p. 78-87.
- [3] D. J. EVANS *et al.*, *Searching sets of properties with neural networks*. Parallel Computing, N° 16, 1990, p. 279-285.
- [4] J. C. FAUVEAU, *Analyse multi-résolution par ondelettes non orthogonales et bancs de filtres numériques*. Thèse de Doctorat, spécialité informatique, Université de Paris Sud, 1990.
- [5] M. FORTHOFER, *Détection de contours par transformée en ondelettes et réseaux de neurones*. Thèse de Doctorat, spécialité automatique, Université de Nancy I, 1991.
- [6] A. GROSSMANN & J. MORLET, *Decomposition of Hardy functions into square integrable wavelets of constant shape*. SIAM J. Math., Vol. 15, 1984, p. 723-736.
- [7] S. G. MALLAT, *Multiresolution representations and wavelets*. Thèse, GRASP Lab., Dept. of computer and information science, Univ of pennsylvania, 1988.
- [8] P. MATHIEU *et al.*, *Compression d'images par transformée en ondelette et quantification vectorielle*. Traitement du Signal, Vol. 7, N° 2, 1990.
- [9] Y. MEYER, *Principe d'incertitude, bases hilbertiennes et algèbre d'opérateurs*, Séminaire Bourbaki n° 662, 1985-86.
- [10] O. MONGA, *Segmentation d'images : où en sommes-nous ?* Rapport de recherche INRIA-Rocquencourt, N° 1216, support de cours pour le congrès PIXIM 89, 1990.
- [11] A. ROSENFELD & A. KAK, *Digital picture processing*. Academic Press, 1982, Vol. 1 et 2.
- [12] P. J. WERBOS, *Backpropagation through time : what it does and how to do it*. Proceedings of the IEEE, N° 10, October 1990, Vol. 78.