

Deuxième partie

Analyse de scènes de contours par groupement perceptuel

Chapitre 4

Saillance structurelle et groupements élémentaires

Dans ce chapitre, nous abordons le premier niveau de groupement de notre approche. Il s'applique dès la détection de contours. Sa fonction est de faire ressortir les structures linéaires importantes présentes dans l'image de contours et de produire un ensemble de chaînes, ou groupements, correspondant à ces structures. Ces groupements servent de point de départ à l'extraction d'éléments de représentation réalisée aux niveaux suivants, en réduisant ainsi la complexité de la recherche visuelle aux seules structures d'intérêt de l'image.

4.1 Saillance structurelle

On peut définir deux sortes de saillances relatives à la perception. Un élément visuel peut présenter une saillance qui lui est propre, comme par exemple, un point blanc parmi un ensemble de points gris. Cette saillance *locale* est à distinguer de la saillance *globale* d'un groupe d'éléments visuels, qui traduit la structure d'ensemble de ce groupe. Cette saillance structurelle est voisine de l'idée de "bonne forme" de la Gestalt.

Le principal problème de ce niveau préliminaire est la définition d'une mesure de saillance sur les groupements possibles entre éléments de contours. Pour reprendre la définition rencontrée précédemment, il s'agit d'évaluer, pour chaque élément de contour, sa possible appartenance à une structure plus globale. On retrouve, en d'autres termes, le problème de séparation entre figure et fond, ou encore, entre forme et bruit.

Dans notre cas, mesurer la saillance d'éléments de contours revient donc à favoriser les éléments appartenant à des formes linéaires tout en pénalisant les éléments perturbateurs. En pratique, ce problème se traduit par la définition d'une fonction de coût, ou de qualité, pour un arrangement donné d'éléments de contours. On peut aussi rapprocher cette fonction de qualité de la probabilité de groupement accidentel

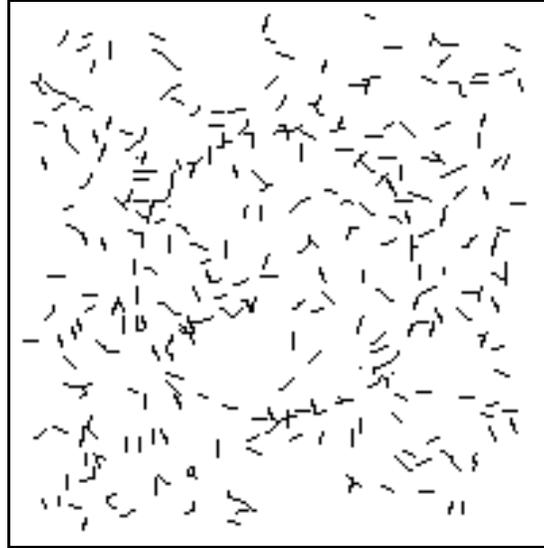


Figure 4.1 - Exemple de groupement saillant de segments dans une scène bruitée. Une mesure de saillance structurelle doit attribuer un score important aux segments placés sur le tracé du cercle.

suggérée par Lowe. Rechercher la valeur du meilleur groupement en chaque élément de contour devient alors un problème d'optimisation combinatoire de la fonction de qualité sur tous les groupements possibles. En outre, ce problème est assimilable à la recherche de sous graphes particuliers parmi l'ensemble de combinaisons possibles entre éléments de contours. Il s'agit donc d'un problème de classe NP-complet.

Le groupement perceptuel à l'aide d'une mesure de saillance soulève ainsi trois questions. Selon quels critères évaluer la qualité d'un groupement? Comment optimiser, en chaque élément de contour, la mesure de saillance? Et enfin, une fois définie la saillance de chaque élément, comment sélectionner les meilleurs groupements?

La méthode que nous appliquons pour extraire les structures importantes d'une image est inspirée des réseaux de saillance de [Shashua et Ullman, 1988]. Cette méthode tient à la fois de la programmation dynamique, de la relaxation et des réseaux de neurones. La mesure de saillance de Shashua est une fonction de qualité calculée le long d'un chemin reliant les éléments visuels à grouper. Ces chemins étant inconnus avant le calcul de cette fonction, celle-ci est construite à l'aide d'une approche itérative semblable à la programmation dynamique. Les éléments visuels à grouper forment un réseau de pixels localement connectés. La mesure de saillance est définie à partir de mesures locales entre chaque élément et ses voisins. En fin d'optimisation, les structures globales sont obtenues en parcourant les éléments du réseau selon les connexions de qualité maximale. L'annexe A présente en détail les principes d'utilisation de ce type de réseaux tels que définis par Shashua et Ullman, ainsi que les principales mesures de saillance définies depuis.

Nous définissons à présent un formalisme générique pour construire ce type de réseau et en utiliser les résultats à des fins de groupement perceptuel. Nous appliquerons ensuite ce nouveau formalisme au groupement de pixels et de chaînes de pixels afin de le comparer à la méthode d'origine.

4.2 Méthodologie de groupement par réseaux de saillance

Ce chapitre est composé de trois parties. Nous définissons dans un premier temps des principes génériques pour la construction de réseaux de saillance et pour l'extraction des meilleurs groupements après optimisation d'une mesure de saillance. Ces principes sont ensuite appliqués au groupement de pixels, puis de chaînes de pixels.

Comme nous le verrons par la suite, l'adaptation de cette méthode à différentes primitives conduit nécessairement à exploiter des propriétés caractéristiques de celles-ci. Cette approche générique permettra donc de séparer la méthodologie de groupement à partir de réseaux de saillance et son application au groupement de pixels puis de chaînes de pixels.

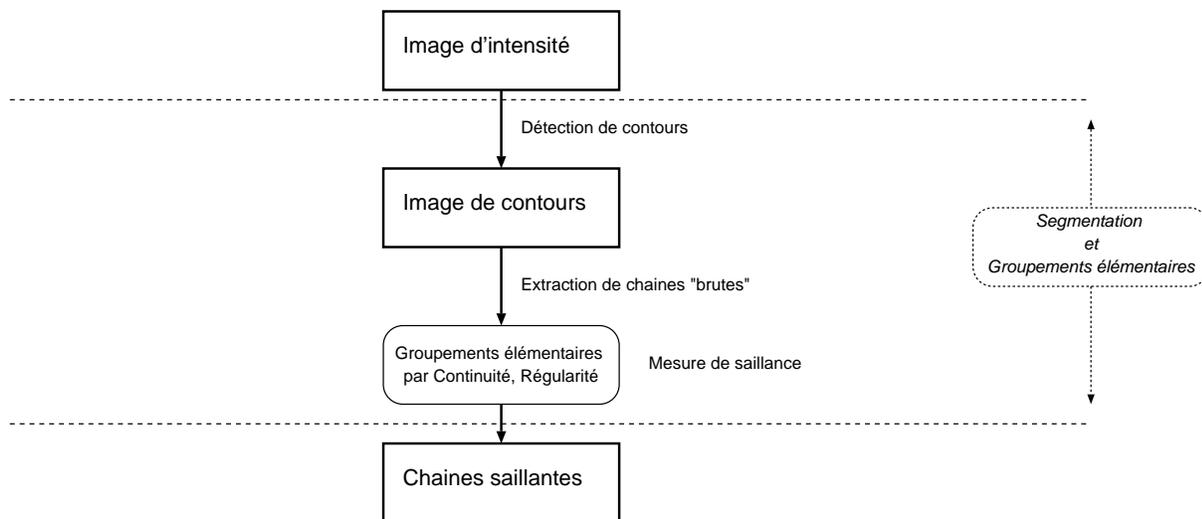


Figure 4.2 - *Principes du premier niveau de groupements. Le but est d'obtenir un nombre réduit de groupements de contours saillants, par rapport au nombre initial d'éléments de contours.*

4.2.1 Définitions

Soit \mathcal{P} un ensemble de primitives préalablement détectées dans une image. La nature de ces primitives n'est pas limitée aux seuls points de contours, comme dans la méthode originellement proposée par Shashua et Ullman. Il peut s'agir éventuellement de segments élémentaires ou bien encore d'objets plus complexes.

Une définition générique d'un réseau de saillance est un graphe d'éléments localement connectés, représenté par un quadruplet $(\mathcal{P}, \mathcal{V}, \mathcal{F}, \mathcal{S})$. Les noeuds de ce graphe sont les primitives de \mathcal{P} . Ses arcs sont des "éléments de connexion" entre ces primitives, définis à l'aide d'un voisinage \mathcal{V} . On appelle "groupement" un chemin, éventuellement cyclique, parmi les noeuds du graphe.

Deux mesures sont établies à partir de ce graphe. La fonction de qualité \mathcal{F} permet d'évaluer la compatibilité d'un groupement avec un ensemble de relations structurelles sur les primitives qui le composent. La mesure de saillance \mathcal{S} permet, quand à elle, d'évaluer à l'aide du graphe la qualité du meilleur groupement passant par chaque primitive.

On notera enfin N_p , le nombre de primitives de \mathcal{P} et N_v , le nombre moyen de voisins autour de chacune de ces primitives. Pour plus de détails sur l'origine de ces notations, on pourra se reporter à l'annexe A sur les réseaux de saillance tels que définis par Shashua.

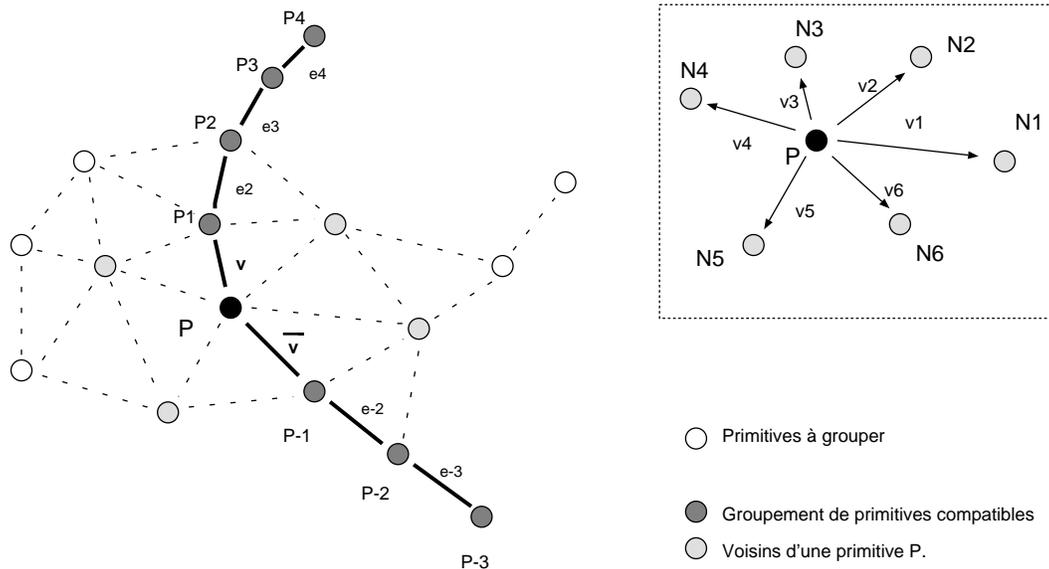


Figure 4.3 - Exemple de groupement de primitives compatibles dans un réseau localement connecté. Le groupement traverse P selon les "directions" des éléments $v = e_1$ et $\bar{v} = e_{-1}$. La mesure de saillance pour P est la qualité maximale des groupements possibles traversant P selon deux de ses voisins.

4.2.2 Voisinage

Le choix du voisinage \mathcal{V} conditionne la finesse des groupements tout en pesant lourdement sur la complexité de l'algorithme d'optimisation.

– Influence du nombre de voisins

Des voisins trop peu nombreux ou trop proches d'une primitive donnée rendront la forme des groupements trop dépendante de configurations locales. A l'inverse, un maillage trop dense peut conduire à un besoin de place mémoire prohibitif lorsque les primitives sont trop nombreuses.

Un ensemble d'orientations autour de pixels est un bon exemple de ce dilemme. Un voisinage trop réduit, en 8 connexité par exemple, ne couvre pas assez d'orientations pour détecter une grande variété de courbes, alors qu'un voisinage de 180 orientations imposerait de mémoriser, pour chaque pixel, 180 qualités possibles et rendrait la méthode impossible à appliquer à des images de taille raisonnable (512×512 pixels par exemple).

– Influence de la forme du voisinage

Une part importante d'opérations inutiles peut être évitée en choisissant un voisinage spécifique au type de primitive utilisé, en ne conservant que les voisins les plus susceptibles d'être groupés efficacement. Ceux-ci peuvent alors être déterminés à l'aide de procédures telles qu'un rayon ou un cône de recherche ou encore, une triangulation de Delaunay. Le nombre de voisins peut donc être éventuellement variable.

D'un point de vue de groupement perceptuel, le choix d'un ensemble de voisins revient à établir un groupement par proximité entre les primitives. Un voisinage statique correspond à un critère de proximité seul, alors qu'un voisinage dynamique correspond à des critères de proximité et de similarité conjugués.

Les deux applications de groupement données en fin de ce chapitre ont chacune un voisinage spécifique. Le groupement de pixels de contours porte sur un voisinage statique de 16 éléments de contours, alors que le groupement de chaînes utilise un voisinage dynamique, construit à l'aide de cônes de recherche dans la direction des extrémités de chaque chaîne.

Une dernière remarque peut être formulée sur la nature des primitives groupées. Les primitives présentes dans un voisinage peuvent être de nature éventuellement différente. C'était déjà le cas, par exemple, avec les éléments d'orientation "réels" et "virtuels" définis par Shashua. La seule contrainte sur le choix d'un voisinage est imposée par les relations structurelles de la fonction de qualité; les primitives doivent être au moins comparables.

4.2.2.1 Relations structurelles et fonction de qualité

La fonction de qualité \mathcal{F} est une mesure de compatibilité entre les primitives d'un groupement et les éléments de connexion qui les séparent.

Shashua et Ullman ont défini leur fonction de qualité comme une somme de contributions locales de chaque élément d'orientation, pondérée par des contraintes antagonistes. D'une part, une évaluation de la courbure globale d'un groupe de pixels assure à la fonction une décroissance monotone sur le nombre d'éléments du groupe. D'autre part, la proportion de discontinuité le long du groupe assure à la fonction une croissance monotone sur sa longueur. Les groupes assurant un bon compromis entre ces contraintes sont jugées de "bonne" qualité.

Cependant, le choix de combiner les contraintes de manière multiplicative présente deux inconvénients majeurs. Il rend tout d'abord la fonction de qualité trop sensible aux ordres de grandeur des variations de chacun des deux poids. Cet effet se traduit en pratique par une convergence trop rapide vers des groupements de taille réduite et de qualité localement élevée, par rapport à une convergence trop lente des groupements plus étendus et pourtant de meilleure qualité globale. La seconde restriction concerne l'extension éventuelle de la fonction de qualité à d'autres types de relations entre primitives, en rendant de plus en plus difficile à contrôler les influences respectives de chacune des contraintes.

Ce type d'interaction entre contraintes n'est pas sans rappeler les énergies internes et externes impliquées dans la définition des contours actifs ou 'snakes'¹. En effet, d'une manière semblable à la fonction de qualité de Shashua, l'énergie interne d'un contour actif est constituée d'un terme de tension (terme du premier ordre représentant la longueur du snake) et d'un terme d'élasticité (terme du second ordre représentant la courbure du snake). À l'inverse de la fonction précédente, l'énergie d'un snake est composée de contraintes additives du type :

$$E_{snake} = \sum_{contour} E_{interne} + \sum_{contour} E_{externe} + \sum_{contour} E_{contraintes}$$

Afin de permettre un meilleur contrôle de l'influence de chaque contrainte et un meilleur équilibre de ces influences, nous proposons d'exprimer la fonction de qualité à l'aide d'un formalisme inspiré de celui des contours actifs. Les relations structurelles qui composent cette fonction expriment ainsi deux types d'influences :

- Les influences externes aux groupements sont des contraintes imposées par l'image sur le parcours d'un groupe. Elles peuvent correspondre à la proportion de discontinuités d'une courbe, une somme d'intensités ou de gradients, ou bien encore, à une différence d'orientations entre éléments de contours consécutifs et le tracé de la courbe.

1. Au sujet des 'snakes', voir le sous-chapitre 2.3.2, page 57

- Les influences internes sont des fonctions de régularisation, définies par la forme du groupement. Pour des structures curvilignes, ces relations sont liées à une mesure de courbure ou de co-circularité le long du groupement.

A ces influences s'ajoutent un certain nombre de contraintes éventuelles, imposées par exemple par les contours de l'image ou encore des zones interdites pour le contour.

Nous proposons comme fonction de qualité une combinaison linéaire d'influences normalisées. Soit N_r le nombre de relations structurelles $R_k(\cdot)$ qui composent \mathcal{F} . L'expression de la qualité d'un groupement γ est de la forme :

$$\mathcal{F}(\gamma) = \sum_{k=1}^{N_r} \alpha_k R_k(\gamma) \quad \text{avec} \quad \forall k, 0 < \alpha_k < 1 \quad \text{et}, \quad 0 < R_k(\gamma) < 1 \quad (4.1)$$

Les paramètres α_i permettent un contrôle précis de l'influence de chaque relation sur la fonction de qualité finale. La normalisation de chaque relation assure une contribution finie de la part de chaque terme.

A la différence des contours actifs, nous choisissons de maximiser notre fonction de qualité au lieu de réduire une énergie. Il est évidemment possible d'exprimer ces fonctions de manières différentes tant que le principe d'opposer des influences internes et externes au groupement est conservé.

4.2.2.2 Mesure de saillance

A partir de la fonction de qualité, la saillance d'une primitive P est définie comme la qualité du meilleur groupement partant de P dans la direction de chaque élément $v_i \in \mathcal{V}(P)$:

$$\mathcal{S}(P) = \mathbf{Max}_{\Gamma_P \in \delta^n(P)} \mathcal{S}^n(\Gamma_P) \quad (4.2)$$

où $\delta^n(P)$ est l'ensemble de tous les groupes possibles² de longueur n passant par la primitive P . Plus précisément, un groupe Γ_P traverse P selon deux "directions", définies par les éléments v et \bar{v} . La saillance du groupement est donc une fonction bilatérale de chaque relation structurelle :

$$\mathcal{S}^n(v, \bar{v}) = \mathcal{F}(\Gamma_P(v)) + \mathcal{F}(\Gamma_P(\bar{v})) \quad (4.3)$$

$$\mathcal{S}^n(v, \bar{v}) = \sum_{k=0}^{N_r} \alpha_k (R_k^n(v) + R_k^n(\bar{v}) + H_k(P, v, \bar{v})) \quad (4.4)$$

Les termes $R_k^n(v)$ et $R_k^n(\bar{v})$ sont les expressions récursives de la fonction de qualité de chaque branche de Γ_P . Elles ne dépendent que du choix des éléments de départ v et \bar{v} de chaque branche.

2. Par extension, $\delta^n(v_i)$ est l'ensemble des groupes de longueur n partant de P dans la direction de v_i . Si P_i est la primitive reliée à P par l'arc v_i , alors $\delta^1(v_i)$ s'écrit $\delta(v_i)$ et correspond au voisinage de P_i .

Le rôle des fonctions $H_k(\cdot)$ est de corriger les éventuels artefacts dus à la présence de termes communs dans la somme des contributions latérales. La définition de ces fonctions sera plus explicite en fin de chapitre avec les applications au groupement de pixels et de chaînes.

Une expression récursive de chaque relation structurelle est nécessaire pour optimiser la fonction de qualité à l'aide du graphe. Nous supposons que ces relations sont des fonctions extensibles répondant à la définition A.3 de la page 259, et que leur expression récursive s'écrit sous la forme :

$$R_k^{(n+1)}(v) = Q_k(v) + \rho_k \cdot \{P_k(v, e_j) \cdot R_k^{(n)}(e_j)\} \quad (4.5)$$

où $Q_k(v)$ est la contribution locale de l'élément v en P et ($0 < \rho_k < 1$) l'atténuation de la contribution de chaque élément avec la distance.

Le terme :

$$\{P_k(v, e_j) \cdot R_k^{(n)}(e_j)\}$$

est la contribution en v de la part de son voisin e_j . Ce voisin doit être choisi de manière à maximiser $S^n(v, \bar{v})$ afin de conserver la meilleure valeur de la fonction de qualité en permanence.

La fonction $P_k(v, e_j)$ permet d'accorder plus ou moins de crédibilité à une contribution en fonction de la configuration locale entre v et e_j . Les fonctions P_k et Q_k sont extraites de l'expression récursive de la fonction de qualité.

Il est important de noter que cette forme récursive n'est pas la seule possible. Le mécanisme d'optimisation reste le même pour toute fonction vérifiant la propriété d'extensibilité.

Cette définition permet de réduire l'espace de recherche des groupes de longueur n partant de l'élément v à $(N_v - 1) \cdot N_p$ possibilités³ parmi $(N_v - 1)^{N_p}$.

4.2.3 Optimisation par programmation dynamique

L'optimisation de la mesure de saillance revient à effectuer une opération de relaxation sur l'expression récursive de chacune des relations $R_k^n(\cdot)$. Elle procède en deux temps. Une première étape définit, dans le voisinage de chaque primitive, les paires d'éléments de connexion qui génèrent les meilleurs groupements. Ces paires sont ensuite utilisées pour mettre à jour les valeurs de l'expression récursive de saillance des primitives.

L'algorithme 4.1 donne une vue d'ensemble de l'optimisation du réseau pour une itération donnée n . Une version plus détaillée de cet algorithme est donnée page 112.

3. Si N_v est le nombre moyen de voisins dans $\mathcal{V}(P)$, $(N_v - 1)$ est le nombre d'éléments susceptibles de prolonger un groupe arrivant sur un noeud depuis l'élément v .

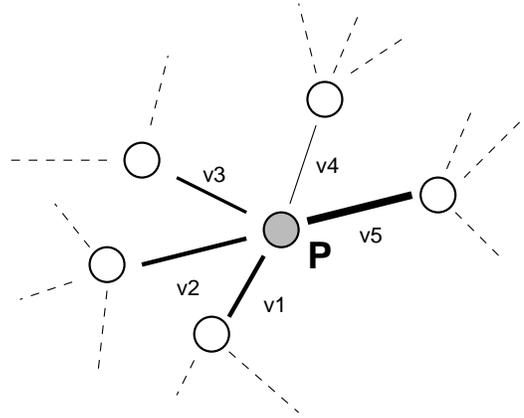


Figure 4.4 - Exemple d'une primitive P et de 5 éléments de connexion. La largeur des connexions correspond à la saillance de la courbe partant de P dans la direction de l'élément. Ici, v_5 est l'élément le plus saillant, et v_4 le moins saillant.

Algorithme 4.1 : Optimisation de réseau de saillance

```

début
  % Appariement des voisins
  %
  pour Chaque primitive  $P \in \mathcal{P}$  faire
    pour Chaque voisin  $v_i \in \mathcal{V}(P)$  faire
      Définir la paire de voisins  $(v_i, v_j)$  pour laquelle
      la saillance  $S^n(v_i, v_j)$  est maximale
       $v_j = \phi(v_i), \quad v_j \notin \delta^*(v_i)$ 
    %
    % Mise à jour des valeurs de saillance
    %
    pour Chaque primitive  $P \in \mathcal{P}$  faire
      pour Chaque voisin  $v_i \in \mathcal{V}(P)$  faire
        pour Chaque relation structurelle  $R_k, k \in [1, N_r]$  faire
          Mettre à jour  $R_k^{(n+1)}(v_i)$  en fonction de  $R_k^{(n)}(\phi(v_i))$ 
  fin

```

Chaque élément v_i dans le voisinage d'une primitive donnée, est associé à la variable d'état $R_k^n(v_i)$. Cette variable représente la saillance du meilleur groupe de longueur n partant de P dans la direction de v_i . Elle est initialisée par la contribution locale de v_i :

$$R_k^{(0)}(v_i) = Q_k(v_i), \quad \forall k \in [1, N_r]$$

D'après l'équation 4.5, chaque variable d'état est mise à jour en trouvant la paire d'éléments (v_i, e_j) , $e_j \in \delta(v_i)$ contribuant le plus à l'état de l'élément v_i .

Appariement d'éléments

D'une manière générale, la recherche des meilleures paires d'éléments se traduit par la définition d'une application entre voisins d'une même primitive.

$$\begin{aligned} \phi : \mathcal{V}(P) &\longmapsto \mathcal{V}(P) \\ v_i &\longrightarrow v_j, \quad v_j \notin \delta^*(v_i) \end{aligned} \quad (4.6)$$

où $\delta^*(v_i)$ est un ensemble d'éléments voisins de P pour lesquels l'appariement n'est pas souhaité. Ces limitations d'appariement dépendent surtout des propriétés des primitives utilisées. A défaut d'une définition plus précise, $\delta^*(v_i)$ est, au minimum, composé de l'élément v_i afin d'éviter tout retour en arrière le long d'un même groupement. La suite de ce chapitre donne deux exemples de limitations de voisinage.

Dans la méthode d'origine, cette application associe simplement à chaque élément le voisin qui apporte la meilleure contribution à sa variable d'état. Or, il est souvent nécessaire d'interdire certaines paires pour éviter des groupements indésirables. La figure 4.4 est un exemple de primitive avec son voisinage immédiat. Dans cet exemple, l'élément v_5 apporte la meilleure contribution, v_1, v_2 et v_3 apportent une contribution semblable et v_4 fournit la plus faible contribution. Le rôle du voisinage inhibiteur δ^* est de s'assurer, par exemple, que les angles entre primitives ne sont pas trop aigus. L'élément v_4 sera donc apparié avec v_1, v_2 ou v_3 .

Le choix de la meilleure paire d'éléments peut exercer une forte influence sur le résultat de l'optimisation. Ainsi dans [Shashua et Ullman, 1991], le choix de paires disjointes autour de chaque primitive permet de forcer la convergence vers une partition de l'image sous forme de groupes optimisés. Cependant, forcer l'application ϕ à être bijective coûte que coûte représente une contrainte trop restrictive car elle interdit toute intersection ou jonction impaire.

Nous proposons une approche intermédiaire en s'assurant simplement que les paires réversibles⁴ qui existent ont en permanence la meilleure qualité possible. L'appariement consiste alors à rechercher des paires de contributions maximales, puis à rectifier les paires réversibles si elles existent.

4. Une paire (v_i, v_j) est dite réversible si elle vérifie la propriété: $\phi(v_i) = v_j$ et $\phi(v_j) = v_i$.

Plus formellement, notons $\mathcal{C}^n(v_i, v_j)$, la saillance du meilleur groupement passant par P selon les directions v_i et v_j . La valeur de $\mathcal{C}^n(\cdot)$ est donc fonction des contributions de l'élément v_j à l'état de v_i selon les différentes relations de la fonction de qualité (cf. équation 4.4).

Les paires autour d'une primitive sont initialisées par la relation suivante :

$$\phi(v_i) = v_j \implies \mathcal{C}^n(v_i, v_j) = \mathbf{Max}_{v_j \notin \delta^*(P)} \{S^n(v_i, v_j)\} \quad (4.7)$$

v_j est l'élément qui, parmi les appariements possibles de v_i , fournit une contribution maximale à v_i .

Afin de privilégier les paires réversibles, il suffit de comparer la contribution de chaque paire avec la contribution des paires inverses éventuelles et de sélectionner, si elle existe, la paire réversible qui apporte la meilleure contribution.

Soit $\{\overline{v_1}, \dots, \overline{v_m}\}$, l'ensemble des éléments dont l'image par ϕ est l'élément v_j :

$$\forall e \in \{\overline{v_1}, \dots, \overline{v_m}\}, \quad \phi(e) = v_j$$

Si cet ensemble n'est pas vide, la contribution de la paire initiale $(v_j, \phi(v_j))$ est comparée à la contribution qu'apporterait chaque paire inverse (v_j, e) . Si l'une de ces contributions est meilleure, la paire $(v_j, \phi(v_j))$ est remplacée par la paire (v_j, e) .

Si :

$$\exists e \in \{\overline{v_1}, \dots, \overline{v_m}\} \quad / \quad \mathcal{C}^n(v_j, e) > \mathcal{C}^n(v_j, \phi(v_j))$$

Alors, on pose $\phi(v_j) = e$ et la paire $(v_j, \phi(v_j))$ est inversible.

Mise à jour de la saillance

Les contributions de chaque élément sont diffusées au travers du réseau à l'aide de l'expression récursive de chaque relation structurelle.

Soit, pour chaque paire $(v_i, \phi(v_i))$:

$$R_k^{(n+1)}(v_i) = Q_k(v_i) + \rho_k \cdot [P_k(v_i, \phi(v_i)) \cdot R_k^{(n)}(\phi(v_i))], \quad \forall k \in [1, N_r]$$

A chaque itération, les contributions prennent en compte l'influence de primitives de plus en plus distantes. Au cours de l'optimisation, les primitives situées le long de groupements visuellement importants sont alimentées en permanence par les contributions importantes des autres primitives de ces groupements. A l'inverse, les primitives plus isolées reçoivent peu de contributions, comme le montre l'exemple des figures 4.5 à 4.7. L'image de départ est une ellipse pour laquelle 5% de pixels ont été supprimés puis 10% de pixels de bruit blanc ont été ajoutés. Les régions noires sur l'image 4.5 (à droite) représentent les parties du réseau inutiles lors de la première itération (et par conséquent, non initialisées).

Le résultat de l'optimisation est une évaluation de la saillance de chaque primitive du réseau. En plus de cette *carte de saillance*, la mise à jour constante des meilleures paires d'éléments (v_i, v_j) autour de chaque primitive P permet de conserver les directions à emprunter pour suivre le meilleur groupe partant de P dans la direction de v_i . Cette information est fondamentale pour l'extraction des groupes les plus importants.

Algorithme 4.2 : Appariement et mise à jour des valeurs de saillance

```

début
  % Appariement des voisins
  %
  pour Chaque primitive  $P \in \mathcal{P}$  faire
    pour Chaque voisin  $v_i \in \mathcal{V}(P)$  faire
      Initialisation de la paire  $(v_i, \phi(v_i))$  pour laquelle
      la saillance  $S^n(v_i, v_j)$  est maximale
       $\phi(v_i) = v_j \implies C^n(v_i, v_j) = \mathbf{Max}_{v_j \notin \delta^*(P)} \{S^n(v_i, v_j)\}$ 
      %
      pour Chaque voisin  $v_i \in \mathcal{V}(P)$  faire
        Recherche des paires inversibles et mise à jour si elles existent
        pour Tout voisin  $e \notin \delta^*(v_i)$  tel que  $\phi(e) = v_i$  faire
          % Si la paire réversible génère une meilleure saillance que la paire initiale
          % alors remplacer la paire initiale par la paire réversible
          si  $(C^n(e, v_i) > C^n(v_i, \phi(v_i)))$  alors
             $\phi(v_i) = e, \quad e \notin \delta^*(v_i)$ 
          %
        % Mise à jour des valeurs de saillance
      %
    pour Chaque primitive  $P \in \mathcal{P}$  faire
      pour Chaque voisin  $v_i \in \mathcal{V}(P)$  faire
        pour Chaque relation structurelle  $R_k, k \in [1, N_r]$  faire
           $R_k^{(n+1)}(v_i) = Q_k(v_i) + \rho_k \cdot [P_k(v_i, \phi(v_i)) \cdot R_k^{(n)}(\phi(v_i))]$ 
fin

```

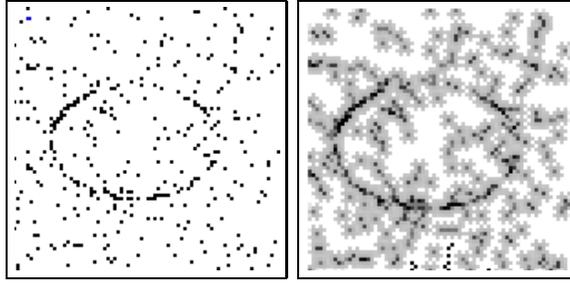


Figure 4.5 - Exemple d'évolution de la carte de saillance - L'image de départ, à gauche, est une image de 80×80 pixels. Le réseau de saillance est défini à l'aide d'un voisinage à 16 éléments tel que défini dans l'application au groupement de pixels. La figure de droite montre l'état initial du réseau ($n = 0$).

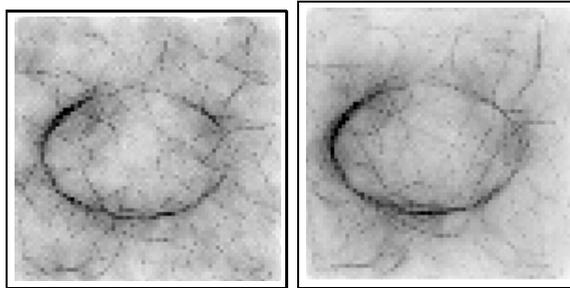


Figure 4.6 - Exemple d'évolution de la carte de saillance pour 5 et 10 itérations du réseau. L'intensité minimale correspond à un maximum de saillance.

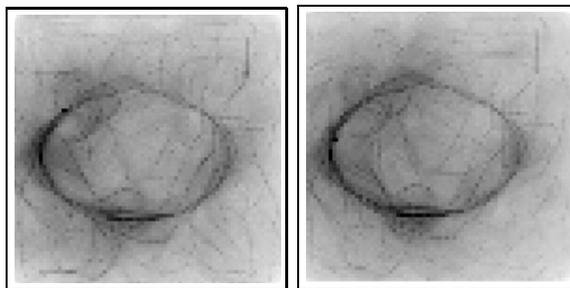


Figure 4.7 - Exemple d'évolution de la carte de saillance pour 15 et 20 itérations. Seuls les points situés dans le voisinage direct de structures linéaires conservent une saillance élevée. Les autres pixels, plus isolés, sont atténués.

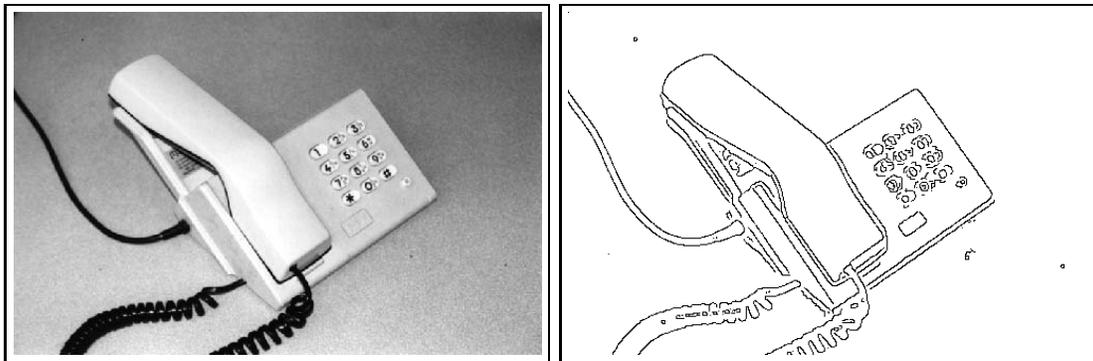


Figure 4.8 - Exemples de groupements individuels - Image d'intensité et détection de contours.

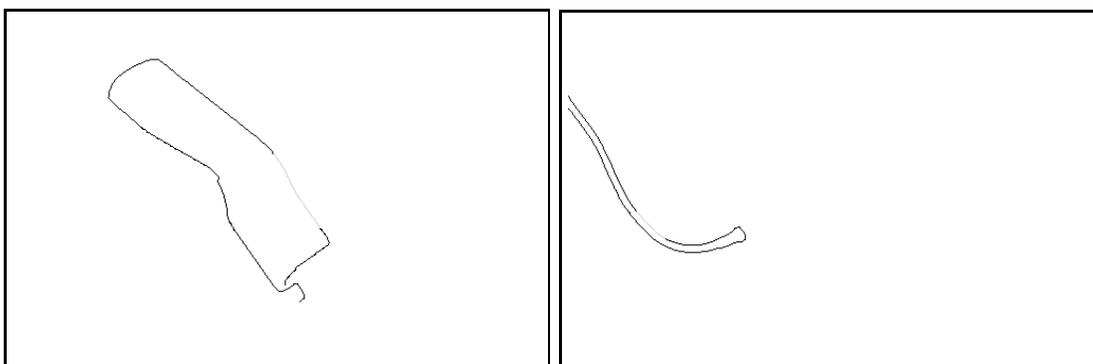


Figure 4.9 - Exemples de groupements individuels à partir de chaînes. Le groupement obtenu après suivi des éléments de connexion est en noir. La chaîne blanche représente le point de départ du groupement. Ces deux groupements délimitent les contours d'objets bien distincts. Ils illustrent bien l'intérêt d'organiser les contours selon des critères de régularité.

4.2.4 Groupement à partir d'une carte de saillance

L'une des principales conséquences de l'optimisation est de réduire le nombre de groupements possibles à un seul parcours pour chaque primitive P du réseau et chaque direction de départ v_i à partir de cette primitive, soit $N_v \cdot N_p$ parcours possibles dans le graphe.

La définition des meilleures paires d'éléments permet de réduire ce nombre à une moyenne de $p \cdot N_p$ parcours possibles, si p désigne le nombre moyen de paires définies autour de chaque primitive. Chaque paire définit les directions selon lesquelles les meilleurs groupes traversent une primitive. En privilégiant le couple apportant la

contribution la plus forte, on peut réduire le nombre de parcours possibles à un seul groupement par primitive, soit N_p groupements. Cette réduction de complexité rend possible une recherche exhaustive des groupements optimisés afin de sélectionner les meilleurs d'entre eux.

4.2.4.1 Extraction de groupes individuels

L'algorithme de reconstitution des meilleurs groupes revient simplement à suivre, de proche en proche, les paires d'éléments tant que celles-ci sont définies et que certaines conditions d'arrêt n'ont pas été rencontrées. Ce suivi peut être effectué à partir de chaque primitive, selon les directions de sa meilleure paire d'éléments.

Conditions d'arrêt du suivi

Les conditions d'arrêt d'un suivi peuvent être imposées par la structure du réseau, par la forme des groupes extraits ou bien encore, par la méthode même d'optimisation de ces groupements.

La contrainte la plus évidente imposée par le réseau correspond à l'absence de paire permettant de prolonger un groupement arrivant en une primitive P par un élément v_i . Il s'agit du cas où $\phi(v_i) = \emptyset$ (figure 4.11, à droite).

Ce type de suivi des primitives de proche en proche privilégie l'extraction de structures linéaires. Il est donc inutile de poursuivre plus loin un groupement en cas de boucle. En effet, si la boucle se referme sur le point de départ du groupement, il s'agit bien d'une structure circulaire. Si par contre il se referme plus loin dans le groupe, il s'agit d'une intersection ou d'une jonction, et le groupement ne possède pas assez d'information globale à ce niveau pour décider de poursuivre ou non le suivi.

La contrainte imposée par la méthode d'optimisation concerne la longueur des groupes reconstitués. Après n itérations, la saillance de chaque primitive est exprimée pour des groupes de longueur n partant dans une direction donnée. Poursuivre un parcours au delà de n noeuds du graphe reviendrait à ajouter des primitives peu significatives pour la primitive de départ.

En effet, pour un parcours $\{e_1, e_2, \dots, e_n\}$, l'élément e_2 a contribué n fois à l'état de e_1 au cours de l'optimisation. De même, l'élément e_3 a contribué $(n - 1)$ fois en e_1 , jusqu'à e_n qui n'apporte qu'une seule contribution en e_1 .

Afin de tenir compte de cette observation, l'ajout d'une nouvelle primitive dans un parcours est soumis à un test de "crédibilité". Ce test représente en quelque sorte la probabilité pour que la contribution apportée par e_t soit significative pour l'élément de départ e_1 . Le suivi est interrompu lorsque la crédibilité devient inférieure à un seuil (proche de 0).

Soit $p(\cdot)$ cette mesure, définie de la manière suivante :

$$p(t) = \exp^{-\lambda \frac{t^2}{\sigma^2}} \quad \text{avec} \quad \sigma = \frac{n}{2} \quad \text{et} \quad t \in [1, n]$$

λ est un coefficient de dégradation qui permet éventuellement de moduler la décroissance de $p(\cdot)$ (figure 4.10). Ce coefficient est utile, par exemple, pour limiter la taille des groupements dont la qualité est trop faible.

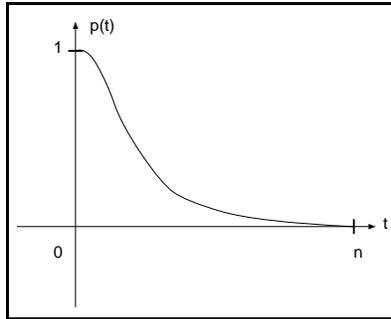


Figure 4.10 - Allure de la fonction de “crédibilité” pour les éléments d’un groupement de longueur n .

Analyse des groupes individuels

Comme le montrent les exemples des figures 4.8 à 4.11, le suivi des meilleures paires est insuffisant pour extraire des structures cohérentes depuis une image. Les principaux problèmes apparaissent autour des intersections entre structures linéaires. En effet, chaque branche d’une intersection se traduit par une forte contribution provenant de sa direction.

Un suivi au niveau des paires d’éléments permet, au mieux, de déterminer dans quelles directions se trouvent des structures d’intérêt. Le long d’une même structure, la présence de deux contributions de forte qualité permet de poursuivre le parcours sans difficulté. Dans le cas de jonctions entre structures, le suivi ne dispose pas d’assez d’informations globales pour décider de la meilleure direction à suivre - ce qui explique les changements de direction observables dans les deux exemples. Le cas le plus extrême se rencontre sur les “plateaux” de la carte de saillance, où les valeurs des contributions sont du même ordre dans chaque direction. C’est le cas de zones du réseau où la distribution de primitives est relativement homogène.

Les groupements individuels sont donc insuffisants pour extraire à coup sûr des structures cohérentes, mais ils n’en perdent pas pour autant leur caractère saillant. On peut raisonnablement les considérer comme des fragments dont la somme couvre les structures saillantes de la scène.

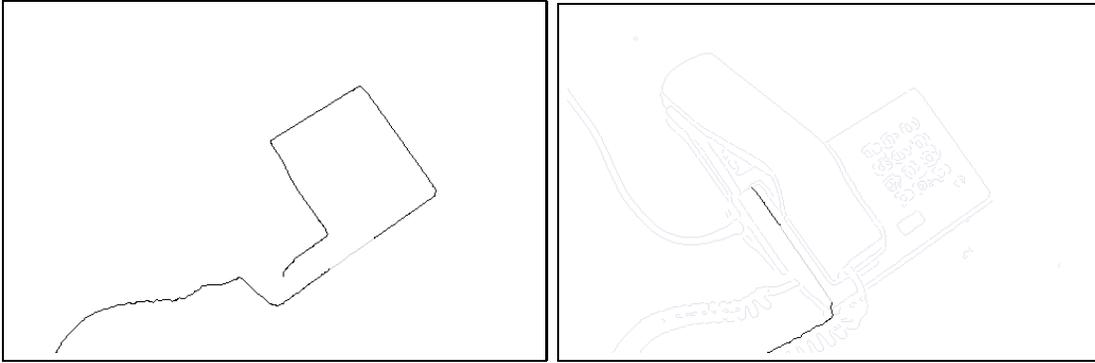


Figure 4.11 - Exemples de groupements individuels. Ces deux exemples illustrent des situations de groupements incomplets. Dans la figure de droite, le suivi des éléments du réseau de saillance est interrompu par le critère de distance. Passé une certaine distance de la chaîne de départ, ajouter de nouveaux éléments à un parcours n'est plus utile. La figure de droite illustre un groupement interrompu par manque de connexions valides entre chaînes.

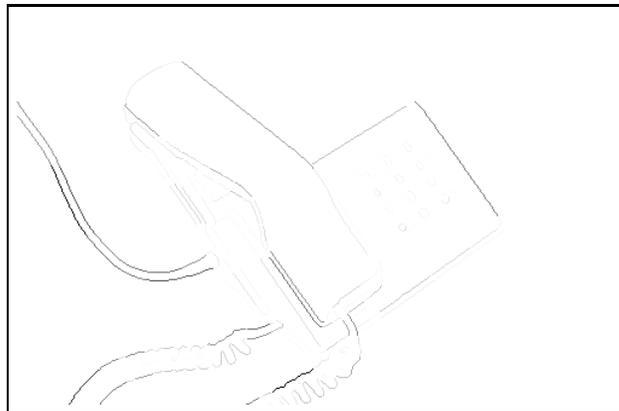


Figure 4.12 - Exemple de carte saillance locale pour des chaînes de pixels. Les chaînes les plus saillantes sont en noir. La valeur de saillance locale d'une chaîne dépend de la répartition du gradient de l'intensité lumineuse le long de cette chaîne. Dans le cas de chaînes, ce critère permet de privilégier les départs de suivi depuis les chaînes les plus longues.

4.2.4.2 Sélection des groupements

Afin d'obtenir la meilleure couverture possible des structures saillantes, tout en laissant de côté les mauvais groupements, il est nécessaire de définir des critères de sélection sur les groupements.

– *Saillance locale*

Le premier critère dans le choix du point de départ concerne les caractéristiques propres de chaque primitive. Un groupement a en effet plus de chance d'être saillant s'il part d'une primitive dont la saillance locale est importante. Le choix d'une mesure de saillance locale est intimement lié à la nature des primitives et sera, par conséquent, abordé dans la dernière partie de ce chapitre.

– *Saillance globale*

Les groupements peuvent être également caractérisés par leur saillance globale. Afin de tenir compte des éventuelles variations de longueur de parcours, la saillance d'un groupe est définie par la somme des saillances de chaque primitive rencontrée dans son parcours. Soit, pour un groupement Γ_P constitué des primitives $\{P_{-n}, \dots, P_{-1}, P, P_1, \dots, P_n\}$:

$$\mathcal{Q}(\Gamma_P(v, \bar{v})) = \sum_{k=0}^{n-1} S^n(e_{-k}, \phi(e_{-k})) + \sum_{k=0}^{n-1} S^n(e_k, \phi(e_k))$$

en reprenant les notations de la relation 4.4.

Ce critère permet de séparer les groupes visuellement importants des groupes isolés et peu saillants. Il n'est pourtant pas suffisant pour départager les meilleurs groupes entre eux. Toute primitive se trouvant à proximité d'une structure importante sera forcément le point de départ d'un groupement à forte saillance, qu'elle appartienne ou non à cette structure.

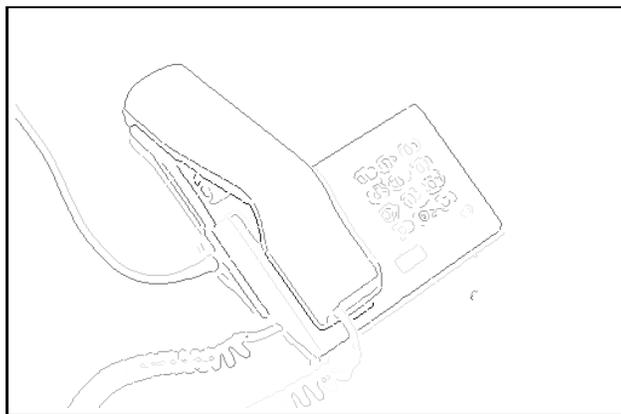


Figure 4.13 - *Exemple de carte de saillance globale pour des chaînes de pixels. Ce critère met en valeur les chaînes appartenant à des structures régulières, mais attribue également une forte saillance aux chaînes voisines de chaînes saillantes.*

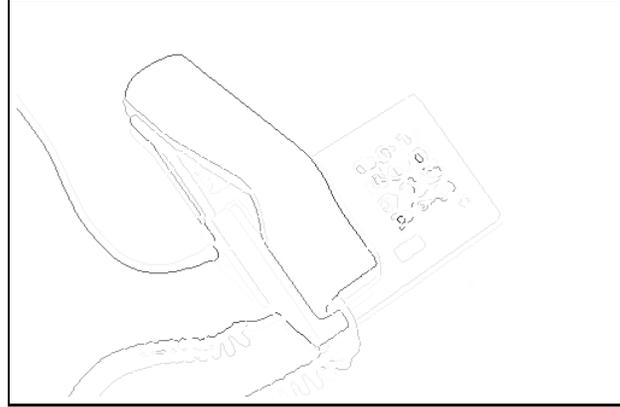


Figure 4.14 - *Exemple de carte d'accumulation pour des chaînes de pixels. Ce dernier critère élimine bien l'effet de voisinage de la mesure de saillance mais ignore également certaines chaînes longues pour lesquelles peu de groupements ont apporté leurs votes.*

– *Accumulation*

Afin de mieux séparer les véritables groupements saillants de ces groupements “parasites”, nous introduisons un troisième critère lié au nombre de groupes traversant chaque primitive. En effet, une primitive appartenant à une réelle structure saillante sera traversée par un nombre important de groupes, alors qu’une primitive proche de cette structure ne sera traversée que par des groupements “parasites”, en général moins nombreux.

Lors du parcours de tous les groupements possibles en préliminaire à la sélection, chaque groupe vote pour les primitives qu’il traverse. Il suffit ensuite de sélectionner les primitives ayant reçu le plus grand nombre de votes.

Les groupes correspondant à l’un de ces trois critères au moins sont sélectionnés. Les seuils de sélection de ces critères sont laissés à la discrétion de l’utilisateur afin d’adapter la méthode aux particularités de la scène observée comme par exemple, le rapport signal sur bruit entre les primitives provenant d’une fausse détection et celles appartenant réellement à des structures globales de la scène.

Dans la pratique, le critère prédominant est le seuil d’accumulation. Ce seuil permet de couvrir la majeure partie des structures saillantes de la scène. Les deux autres critères viennent en complément à cette première sélection. Le cas échéant, il est parfois nécessaire de terminer la sélection par des retouches manuelles. L’intérêt de ces critères est de simplifier la tâche de la sélection en la ramenant au choix de trois seuils au lieu d’une recherche manuelle exhaustive.

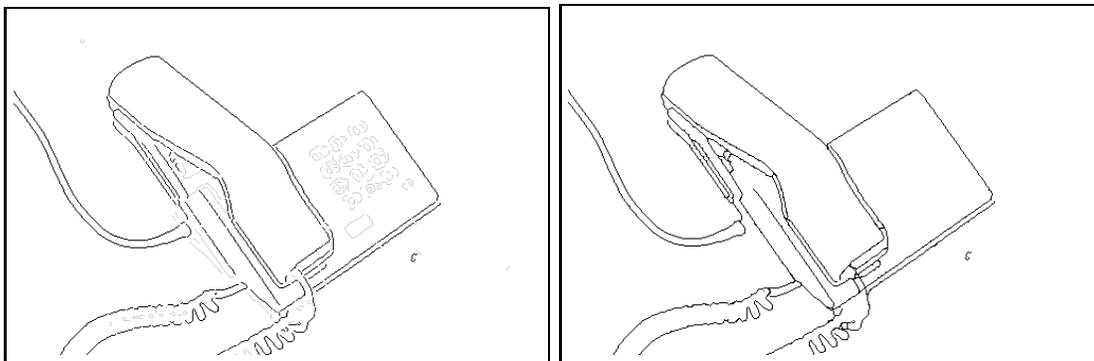


Figure 4.15 - *Sélection finale des chaînes servant de point de départ au suivi des éléments de connexion (à gauche) et superposition des groupements (à droite). A partir des 560 chaînes de contours, 90 groupements ont été sélectionnés.*

4.2.5 Conclusion et applications

En résumé, notre méthode de groupement perceptuel par réseaux de saillance se distingue de l'approche initiale de Shashua et Ullman par plusieurs aspects.

Le formalisme générique nous a permis de séparer la stratégie de groupement par réseau de saillance des contraintes liées au choix d'une primitive spécifique. Ce formalisme permet d'envisager l'extension de cette approche à tout type de groupement par alignement d'éléments consécutifs.

Nous avons introduit une famille de fonction de qualité proche des fonctions d'énergie des contours actifs, qui permet ainsi un meilleur contrôle de l'influence de chaque relation structurelle sur l'aspect des courbes obtenues par groupement.

C'est également par le biais de la fonction de qualité que ce niveau de groupement pourrait être utilisé en coopération avec d'autres sources d'information visuelle que les contours. Ainsi, une mesure de saillance entre éléments de contours pourrait être renforcée par la connaissance d'une carte de régions ou de textures afin de privilégier la saillance de contours appartenant à une même région.

Notre algorithme d'optimisation, en recherchant à chaque itération les meilleurs appariements autour de chaque primitive, permet de guider la convergence vers des solutions plus stables tout en autorisant l'existence de jonctions multiples.

Enfin, les critères de reconstruction et de sélection des groupements nous permettent de mettre en valeur les courbes les plus importantes de la scène et non uniquement la meilleure courbe possible. De même que pour la définition de la fonction de qualité, les critères de suivi et de sélection sont ouverts à la coopération avec d'autres indices visuels. Pour reprendre l'exemple d'une carte de régions, les groupements respectant le mieux les frontières entre régions pourraient être ainsi privilégiés.

Paramètres

Indépendamment du type de primitive choisie, les paramètres utilisés par cette méthode de groupement sont les suivants :

- $0 < \alpha_i < 1$, poids de chaque terme dans la fonction de qualité.
- $0 < \rho_i < 1$, atténuation des contributions avec la distance.
- $n_{max} < N_p$, longueur maximale admissible pour un groupement.
- Seuils d'arrêt du suivi et de sélection des groupements.

Le rôle de chaque paramètre est abordé plus en détail dans la présentation de chaque application. Une fois ces paramètres fixés pour une catégorie de courbes, la méthode peut être appliquée à différentes situations sans avoir pour autant à redéfinir ces paramètres. Pour illustrer cette stabilité des paramètres, les résultats présentés pour le groupement de pixels et le groupement de chaînes, ont été obtenus dans chaque cas avec le même jeu de paramètres.

Complexité.

Nous nous plaçons dans un cas général, où le nombre de voisins autour de chaque primitive peut être éventuellement variable. La complexité algorithmique est directement liée au nombre de primitives N_p et au nombre moyen de voisins N_v autour de chaque primitive. Elle est de l'ordre de $\mathcal{O}(n \cdot N_p \cdot N_v^2)$ pour une optimisation de n itérations. La sélection des meilleurs groupements est, quand à elle, de l'ordre de $\mathcal{O}(N_p)$, les possibilités ayant été réduites à un seul parcours privilégié par primitive.

Nombre d'itérations

L'optimisation permet de diffuser l'influence de chaque primitive dans le réseau un peu plus loin à chaque itération. Le nombre d'itérations nécessaires à un groupement dépend essentiellement de la longueur des groupements recherchés. Cette longueur étant inconnue au préalable, la limite est fixée au nombre maximal d'éléments admissible pour un groupement. Ce nombre est limité, au pire, par le nombre de primitives du réseau. En effet, au delà de N_p éléments, un groupement est forcément une boucle et ne peut donc plus être prolongé.

Cette méthodologie de groupement perceptuel à partir de réseaux de saillance a été testée sur des groupements de pixels de contours [Montesinos et Alquier, 1996] , puis étendue au groupement de chaînes de pixels [Alquier et Montesinos, 1997] .

Le groupement de pixels utilise un voisinage statique de 16 voisins. Sa fonction de qualité implique des termes de courbure et de co-circularité pour les influences internes et des termes de continuité d'intensité et d'orientation pour les influences externes.

Par comparaison, le groupement de chaînes de pixels dispose d'un voisinage dynamique autour des extrémités des chaînes. Les influences externes de sa fonction de qualité est composée d'un terme de continuité et d'orientations respectives des extrémités. Ses influences internes impliquent une mesure de courbure et de co-circularité.

Chacune de ces applications fait l'objet d'une présentation plus détaillée dans la dernière partie de ce chapitre.

4.3 Application au groupement de pixels

Afin de mieux comparer notre approche des réseaux de saillance avec la méthode originalement proposée par Shashua et Ullman, la première application porte sur le groupement de pixels. Le but du groupement est ici d'extraire les structures curvilinéaires visuellement importantes dans l'image, tout en fermant les contours incomplets et en ignorant les fausses détections.

4.3.1 Primitive "pixel"

L'ensemble des primitives choisi pour cette application est constitué des pixels d'une image de détection de contours. La caractéristique principale de ces pixels est leur intensité, fixée à 1 pour la détection d'un point de contours et à 0 pour une primitive "virtuelle". Tous les pixels de l'image sont pris en compte dans ce réseau.

4.3.2 Voisinage statique

Les éléments de connexion représentant le voisinage d'une primitive constituent l'ensemble des orientations possibles pour des courbes la traversant. Ce voisinage définit un nombre constant d'orientations autour de chaque pixel.

Comme nous l'avons déjà évoqué dans la présentation de la méthode, cette discrétisation des orientations doit être suffisamment fine pour ne pas limiter la forme des courbes détectées. De plus, la notion d'échelle étant absente à ce niveau de détection, les changements d'orientations locales le long d'une courbe entraînent l'apparition "d'escaliers" qui pénalisent un peu plus sa mesure de qualité.

Les groupements détectés seront donc plus ou moins grossiers selon le nombre de voisins choisi. L'aspect des groupements peut être affiné en cours d'optimisation, comme suggéré dans [Shashua, 1988], ou bien en fin d'optimisation, en modélisant les groupements à l'aide de courbes polynômiales.

Un nombre d'orientations trop élevé peut, à l'inverse, imposer de sérieuses limitations sur la taille des images envisageables pour la méthode. En effet, l'optimisation nécessite de mémoriser, pour chaque pixel, N_v paires d'éléments, soit $2 \cdot N_v$ variables d'état pour la mise à jour de la mesure de saillance, sans compter les ressources nécessaires à la manipulation du réseau de saillance.

Cette restriction est moins importante que la précédente sachant que la méthode d'optimisation est parallélisable. Pour une itération donnée, les primitives ne dépendent que des valeurs des contributions de l'itération précédente. Chaque primitive pourrait donc être associée à un processeur particulier et la mise à jour de la mesure de saillance pourrait ainsi être réalisée simultanément sur toutes les primitives.

Cependant, en l'absence d'implémentation sur machine parallèle, la manipulation des voisinages peut être simplifiée en ne traitant que les pixels utiles pour une itération donnée. Il est en effet inutile de mettre à jour la saillance de primitives "virtuelles" lorsque les éléments de leur voisinage ont une contribution nulle. C'est le cas de tout pixel qui ne se trouve pas dans le voisinage immédiat d'un pixel de contour.

Il suffit alors d'inhiber ces pixels "virtuels" par défaut, et de ne les activer qu'au voisinage d'un pixel recevant au moins une contribution non nulle. A chaque itération, de plus en plus de pixels virtuels sont ainsi activés, ce qui assure la méthode de ne prendre en compte que les pixels utiles. Cette heuristique permet en pratique de gagner jusqu'à 40% de temps de calcul, en particulier sur des images de grande taille avec des zones de faibles densité de pixels⁵.

En tenant compte de ces considérations, le voisinage choisi pour le groupement de pixels est un voisinage à 16 éléments d'orientation tel que le montre la figure 4.16.

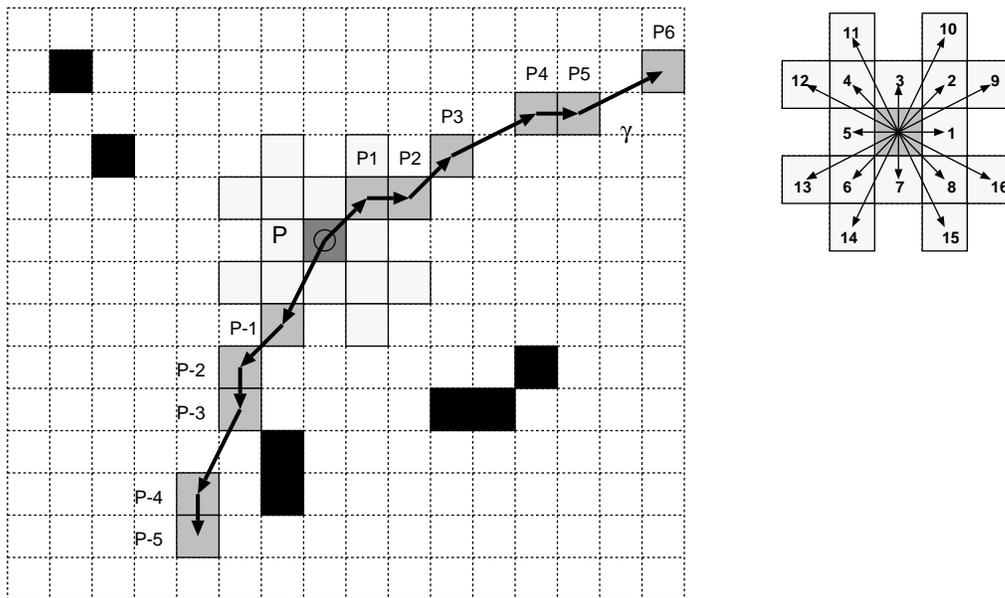


Figure 4.16 - *Voisinage de pixel à 16 éléments d'orientation. Ce voisinage permet à la fois des connexions rapprochées (voisins 1 à 8) et plus distantes (voisins 9 à 16).*

5. Voir à ce titre les résultats de groupement sur des images satellites.

4.3.3 Fonction de qualité

La fonction de qualité reprend les termes de continuité et de courbure définis par Shashua, auxquels sont associés des termes de co-circularité et d'orientations, introduits par [Montesinos et Blanc, 1994]. Pour reprendre un formalisme de contours actifs, les relations de continuité et d'orientations représentent des contraintes imposées par l'image sur le parcours des courbes à détecter. Les termes de courbure et de co-circularité représentent, à l'inverse, des relations structurelles internes à ces courbes.

Soit, pour une courbe γ composée des pixels $\{P, P_1, \dots, P_n\}$ et des éléments d'orientation $\{e_1, e_2, \dots, e_n\}$:

$$\mathcal{F}(P, e_1) = \begin{cases} \alpha_c \cdot \mathcal{C}(P, e_1) + \alpha_k \cdot \mathcal{K}(P, e_1) & (\textit{influences internes}) \\ + \alpha_g \cdot \mathcal{G}(P, e_1) + \alpha_o \cdot \mathcal{O}(P, e_1) & (\textit{influences externes}) \end{cases} \quad (4.8)$$

avec ($\forall i \in [c, k, g, o]$ $0 < \alpha_i < 1$), paramètres déterminant l'importance de chaque terme au sein de la fonction de qualité.

Ces paramètres permettent de moduler l'importance de chaque relation structurelle au sein de la fonction de qualité. Ils sont respectivement liés à la courbure (α_c), la co-circularité (α_k), la continuité d'intensité (α_g) et celle d'orientation (α_o). Ainsi, une forte valeur pour (α_g) favorisera les courbes passant par le plus grand nombre de pixels de contours alors qu'une forte valeur de (α_k) donnera un avantage aux cycles par rapport à des courbes ouvertes. Le réglage de ces paramètres pour la détection d'un certain type de courbe peut prendre un certain nombre d'essais. Par contre, une fois réglés, les paramètres montrent une bonne stabilité pour la détection d'un même type de courbe sur des images différentes.

A titre d'exemple de cette stabilité, les résultats présentés pour le groupement de pixels ont été réalisés avec les mêmes paramètres :

$$\alpha_c = 0.5, \alpha_k = 0.2, \alpha_g = 0.9, \alpha_o = 0.2$$

Comme tous les autres paramètres définis par la suite dans ce mémoire, ces valeurs ont été définies de manière empirique, à la suite d'essais sur différentes scènes. La robustesse de la méthode permet néanmoins de conserver le même jeu de paramètres une fois celui-ci fixé pour une classe de groupements donnée. Cette robustesse permet d'envisager, pour un certain nombre de ces paramètres, un apprentissage supervisé éventuel, en comparant les groupements obtenus avec les expressions paramétriques d'un jeu de courbes de référence. Cependant, au lieu de rechercher, dans le détail, un apprentissage particulier, nous avons privilégié une approche globale du problème de groupement, depuis la détection de contours jusqu'à l'interprétation.

Détaillons à présent chacun de ces termes :

– **Courbure globale et co-circularité: Relations structurelles internes**

L'une des principales différences de cette fonction de qualité avec l'expression d'origine est la dissociation des termes de courbure et de continuité. Le terme de courbure est donc uniquement composé de l'évaluation de courbure globale défini par la relation A.1, page 258.

Soit $C_{1,n}$ l'évaluation de la courbure globale entre les pixels P_1 et P_n :

$$C_{1,n} = \prod_{k=1}^{n-1} f(e_k, e_{k+1}) = \exp \left[- \sum_{k=1}^{n-1} \frac{2\theta_k}{\Delta s_{k,k+1}} \tan \frac{\theta_k}{2} \right]$$

Le terme de courbure globale pour γ est donc de la forme :

$$\mathcal{C}(P, e_1) = \mathcal{C}_0(P, e_1) + \mathcal{C}_0(P, e_1) \cdot \sum_{i=1}^{n-1} \rho_c^i \cdot f(e_i, e_{i+1}) \cdot C_{1,i} \quad (4.9)$$

où $\mathcal{C}_0(P, e_1)$ représente la courbure locale au point P .

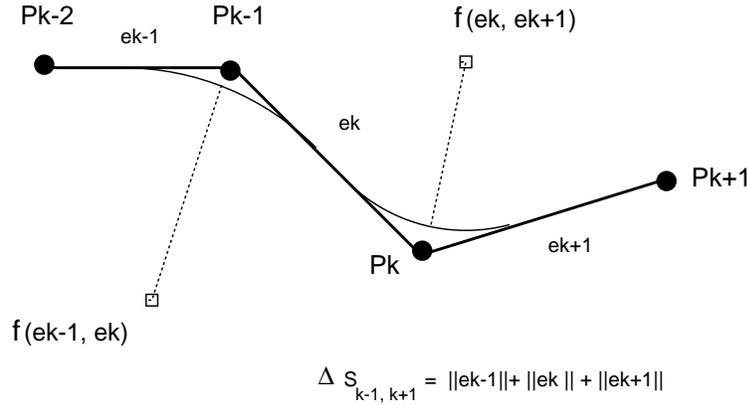


Figure 4.17 - Notations pour l'estimation de la co-circularité entre trois éléments de connexions e_{k-1} , e_k et e_{k+1} .

L'expression théorique de la co-circularité locale est une dérivée seconde de l'orientation en un point de la courbe, par rapport à l'abscisse curviligne de ce point, ($d^2\theta/ds^2$). La discrétisation des parcours du graphe conduit à estimer la co-circularité à partir de la différence du terme de courbure entre trois éléments d'orientation consécutifs, soit :

$$\kappa(e_{j-1}, e_j, e_{j+1}) = \frac{|\operatorname{sgn}(\theta_{j-1}) f(e_{j-1}, e_j) + \operatorname{sgn}(\theta_j) f(e_j, e_{j+1})|}{2 \Delta S_{j-1, j+1}}$$

Le terme de co-circularité globale est alors de la forme :

$$\mathcal{K}(P, e_1) = \mathcal{K}_0(P, e_1) + \sum_{i=2}^{n-1} \rho_k^i \cdot \kappa(e_{i-1}, e_i, e_{i+1}) \quad (4.10)$$

Les valeurs initiales de chaque terme, $\mathcal{C}_0(e_1)$ et $\mathcal{K}_0(e_1)$ représentent la contribution locale en termes de courbures et de co-circularité, de l'élément e_1 pour le pixel P . Comme elles dépendent de la paire d'éléments (e_1, \bar{e}_1) définie autour de P , leur expression sera fixée lors de la définition de la mesure de saillance.

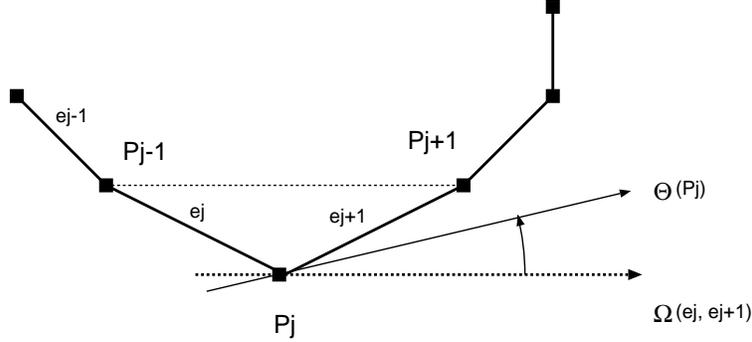


Figure 4.18 - Notations pour le terme d'orientation entre deux éléments e_j et e_{j+1} .

– **Continuité d'intensité et d'orientation:** *Influences externes*

Afin de pénaliser les courbes discontinues, nous définissons un terme de continuité d'intensité comme la somme des intensités des pixels d'un groupe pondérées par un facteur d'atténuation. L'intensité en chaque pixel est définie par :

$$\sigma_j = \begin{cases} 1, & \text{si } P_j \text{ est un pixel de contour} \\ 0, & \text{sinon} \end{cases}$$

Le terme recherché est donc :

$$\mathcal{G}(P, e_1) = \mathcal{G}_0(P, e_1) + \sum_{i=1}^n \rho_g^i \cdot \sigma_i \quad (4.11)$$

Provenant directement de la détection de contours, ce terme d'intensités est trop dépendant de mesures locales. Une mesure plus globale, comme l'estimation de la tangente en chaque point de contour⁶, permet d'assurer à l'optimi-

6. [Parent et Zucker, 1989] montrent comment la direction de la tangente le long d'un contour peut être estimée de manière relativement simple à l'aide d'un jeu de filtres directionnels constitués de différences de gaussiennes.

sation de courbes une plus grande robustesse face au bruit. Le terme d'orientation qui en découle mesure la différence entre cette tangente $\Theta(P_j)$ et une estimation locale entre éléments de connexion $\Omega(e_j, e_{j+1})$:

$$\Phi_j = \exp^{(-Tan|\Theta(P_j) - \Omega(e_j, e_{j+1})|)}$$

Les angles $\Omega(e_j, e_{j+1})$ sont pré-calculés de la manière suivante :

$$\Omega(e_j, e_{j+1}) \simeq \text{orient}(\overrightarrow{P_{j-1}, P_{j+1}})$$

Ce critère est maximal lorsque les deux orientations coïncident.

Le terme de continuité d'orientations est finalement :

$$\mathcal{O}(P, e_1) = \mathcal{O}_0(P, e_1) + \sum_{i=1}^{n-1} \rho_o^i \cdot \Phi_i \quad (4.12)$$

4.3.4 Mesure de saillance

En reprenant la relation 4.4, page 107, la mesure de saillance à optimiser dépend de la définition d'une paire d'éléments (v, \bar{v}) autour d'un pixel P . Elle s'exprime sous la forme d'une somme de qualités des branches partant de P dans chaque direction de la paire d'éléments.

Si on note Γ_P la courbe correspondant à ces deux branches, sa saillance est définie par :

$$S^n(\Gamma_P) = \begin{cases} \alpha_c \cdot (\mathcal{C}^n(P, v) + \mathcal{C}^n(P, \bar{v}) + H_c(P)) \\ + \alpha_k \cdot (\mathcal{K}^n(P, v) + \mathcal{K}^n(P, \bar{v}) + H_k(P)) \\ + \alpha_g \cdot (\mathcal{G}^n(P, v) + \mathcal{G}^n(P, \bar{v}) + H_g(P)) \\ + \alpha_o \cdot (\mathcal{O}^n(P, v) + \mathcal{O}^n(P, \bar{v}) + H_o(P)) \end{cases} \quad (4.13)$$

En tenant compte de la paire (v, \bar{v}) , les valeurs initiales de chaque terme de la fonction de qualité sont respectivement :

$$\left\{ \begin{array}{ll} \mathcal{C}_0(P, v) = f(\bar{v}, v) & \mathcal{C}_0(P, \bar{v}) = f(v, \bar{v}) \\ \mathcal{K}_0(P, v) = \kappa(\bar{v}, v, e_2) & \mathcal{K}_0(P, \bar{v}) = \kappa(\bar{e}_{-2}, \bar{v}, v) \\ \mathcal{G}_0(P, v) = \sigma_P & \mathcal{G}_0(P, \bar{v}) = \sigma_P \\ \mathcal{O}_0(P, v) = \Phi_P & \mathcal{O}_0(P, \bar{v}) = \Phi_P \end{array} \right. \quad (4.14)$$

Les termes de courbure et de co-circularité sont établis sur les éléments du voisinage direct du pixel P . On note σ_P l'intensité du pixel P et Φ_P la tangente locale de la courbe en P :

$$\Phi_P = \exp^{(-Tan|\Theta(P_j) - \Omega(\bar{v}, v)|)} = \exp^{(-Tan|\Theta(P_j) - \Omega(v, \bar{v})|)}$$

Ce qui conduit aux fonctions de correction suivantes :

$$\forall P \in \mathcal{P} \quad \left\{ \begin{array}{l} H_c(P) = -f(\bar{v}, v) \\ H_k(P) = 0 \\ H_g(P) = -\sigma_P \\ H_o(P) = -\Phi_P \end{array} \right. \quad (4.15)$$

Leur rôle est d'éliminer les termes communs à chaque contribution latérale en P .

4.3.5 Optimisation

Les particularités de l'algorithme d'optimisation dues aux choix des pixels comme primitives portent essentiellement sur la définition des paires interdites.

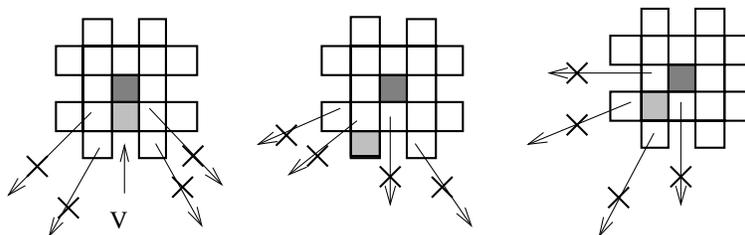


Figure 4.19 - Paires interdites pour les trois types d'éléments v du voisinage d'un pixel. Les éléments e_j interdits correspondent dans chaque cas à une valeur $f(v, e_j) < 0.05$.

Lors de la recherche d'un candidat pour l'appariement avec un élément v , les paires formant des angles trop aigus sont rejetées pour éviter la formation de boucles ou de rebroussements lors du suivi. Les éléments immédiatement voisins de v forment une sorte d'angle mort interdisant toute connexion. En pratique, le choix des candidats est établi par simple seuillage sur la valeur de $f(v, e_j)$.

$$f(v, e_j) < 0.05 \quad \implies \quad \text{paire } (v, e_j) \text{ interdite}$$

L'expression récursive des termes de la mesure de saillance se dérivent naturellement de leur définition. Soit, pour l'une des deux branches d'un groupement traversant un pixel P selon la paire (\bar{v}, v) :

– Initialisation: $n = 0$

$$\left\{ \begin{array}{l} \mathcal{C}^0(P, v) = f(\bar{v}, v) \\ \mathcal{K}^0(P, v) = \kappa(\bar{v}, v, \phi(v)) \\ \mathcal{G}^0(P, v) = \sigma_P \\ \mathcal{O}^0(P, v) = \Phi_P \end{array} \right. \quad (4.16)$$

– Mise à jour: $n \neq 0$

$$\left\{ \begin{array}{l} \mathcal{C}^{n+1}(P, v) = 1 + \rho_c \cdot f(v, \phi(v)) \cdot \mathcal{C}^n(P_v, \phi(v)) \\ \mathcal{K}^{n+1}(P, v) = \kappa(\bar{v}, v, \phi(v)) + \rho_k \cdot \mathcal{K}^n(P_v, \phi(v)) \\ \mathcal{G}^{n+1}(P, v) = \sigma_P + \rho_g \cdot \mathcal{G}^n(P_v, \phi(v)) \\ \mathcal{O}^{n+1}(P, v) = \Phi_P + \rho_o \cdot \mathcal{O}^n(P_v, \phi(v)) \end{array} \right. \quad (4.17)$$

avec P_v , pixel relié à P par l'élément v . Ces variables d'état sont définies de manière symétrique pour la branche du groupement arrivant en P par l'élément \bar{v} .

Les poids $\rho_i \in [0, 1]$ constituent le second jeu de paramètres liés à l'optimisation. Ils représentent l'atténuation avec la distance des contributions d'éléments éloignés. Bien qu'ils puissent être éventuellement différents, ils ont été fixés en pratique à une valeur unique, $\rho = 0.95$ pour tous les termes.

4.3.6 Extraction et sélection des meilleurs groupes

La prise en compte de tous les pixels de l'image assure au réseau une mesure de saillance dense sur l'image. Si elle permet de fermer les discontinuités le long de structures importantes, cette densité pose quelques problèmes pour le suivi et la sélection des meilleurs groupements.

– Suivi

Au voisinage d'une structure saillante, les pixels du réseau reçoivent des contributions importantes dans la direction de cette structure.

Supposons qu'une courbe visuellement importante se termine brutalement en un point P de l'image. Les pixels environnant reçoivent une forte contribution

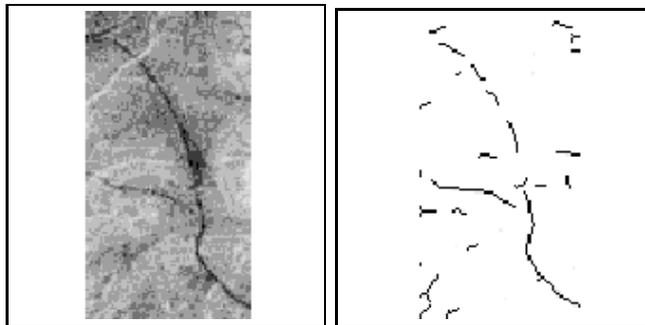


Figure 4.20 - *Détection des lignes de crête d'un fragment d'image satellite infrarouge.*

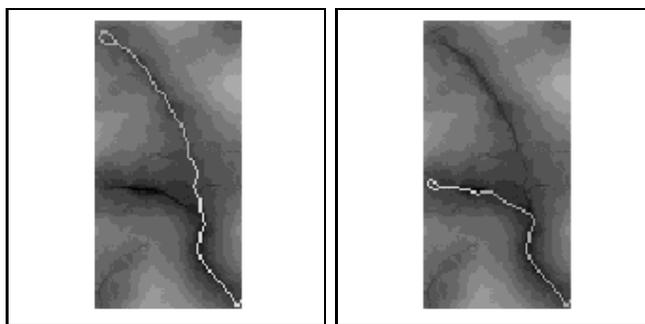


Figure 4.21 - *Exemples de "bucles" indésirables en fin de suivi, après groupement des pixels de lignes de crête.*

dans la direction de P et ce, jusqu'à une distance égale au nombre d'itérations. Un suivi de la courbe arrivant en P se trouverait devant des éléments de connexion de qualité équivalente pour peu qu'il n'y ait aucune autre structure importante dans le voisinage. Il en résulte un suivi d'éléments "virtuels" qui, s'éloignant de P finira fatalement par être attiré par la seule structure importante ; celle de P .

En conséquence de cette observation, le suivi de groupements individuels montre une certaine tendance à former localement des cycles en arrivant sur des zones clairsemées de l'image de contours. Ce problème est facilement résolu en éliminant du suivi les derniers éléments virtuels en cas de cycles.

- Sélection

Chaque pixel pouvant servir de point de départ au suivi d'un groupement, les structures globales de l'image génèrent des classes de groupements de qualité équivalentes. Ces classes sont constituées des groupements dont les points de départ se trouvent dans un proche voisinage d'une structure globale. Afin

de mieux départager les groupements autour d'une même structure, la qualité globale d'un groupement est pondérée par le rapport entre pixels réels et pixels "virtuels" le long du tracé. Les pixels "virtuels" jouant le rôle de discontinuités, on peut considérer ce poids comme un rapport signal sur bruit pour un groupement.

$$\mathcal{Q}(\Gamma_P(v, \bar{v})) = \frac{N_{\text{réels}}}{1 + N_{\text{virtuels}}} \cdot \left[\sum_{k=1}^n S^n(e_{-k}, \phi(e_{-k})) + \sum_{k=1}^n S^n(e_k, \phi(e_k)) \right]$$

Enfin, pour compléter les critères de sélection de courbes, la saillance locale d'un pixel est définie comme la norme du gradient de l'intensité d'origine en ce point. Ce qui permet de privilégier les groupements dont les points de départ se trouvent sur un gradient élevé, donc sur un contour probable.

Dans la pratique, les seuils de sélection sont définis par rapport à un pourcentage de la valeur maximale de chaque critère.

4.3.7 Résultats et développements éventuels

Cette méthode a été appliquée à différentes situations, d'abord sur des images synthétiques pour en tester les performances dans des situations extrêmes, puis sur des scènes réelles pour en démontrer l'utilité. Dans tous les cas, les résultats ont été obtenus dans des conditions identiques, avec le même jeu de paramètres⁷.

4.3.7.1 Images synthétiques

Les images synthétiques suivantes ont été choisies afin de tester les performances du groupement de pixels dans différentes conditions de bruit : bruit blanc, bruit gaussien et bruit structuré.

Dans chaque cas, un rapport Signal sur Bruit (RSB) peut être défini par :

$$RSB_{dB} = -10 \log \left(\frac{\sum_i \sum_j I(i, j)^2}{\sum_i \sum_j N(i, j)^2} \right)$$

où $I(i, j)$ est la fonction intensité de l'image non bruitée, et $N(i, j)$ celle de l'image altérée.

Les groupements obtenus dans chaque situation ont été sélectionnés manuellement afin de montrer l'existence de groupements correspondant à la forme recherchée.

7. Implémentation en C sur une station de travail SPARC-5.

– *Paramètres de la fonction de qualité*

Le premier jeu de tests illustre le rôle de chaque terme de la fonction de qualité. Dans un premier temps, l'optimisation du réseau de saillance ne tient compte que d'un seul terme de qualité à la fois : termes d'intensité et d'orientation pour la figure 4.23 et termes de courbure et de co-circularité pour la figure 4.24). Dans chaque cas, un groupement représentatif de la fonction de qualité appliquée a été sélectionné manuellement et tracé par dessus la carte de saillance. Ces résultats montrent le rôle dominant des termes d'intensité et de courbure. Leur influence sur les connexions du réseau est suffisante pour guider correctement la reconstitution de groupements réellement saillants. Les termes d'orientation et de co-circularité jouent, quand à eux, un rôle d'appoint. Ces deux termes sont utiles pour corriger certaines situations ambiguës mais leur influence doit rester limitée pour qu'ils ne perturbent pas trop le suivi des groupements. Une fonction de qualité composée uniquement des termes de courbure et d'intensité est ainsi suffisante à reconstituer une majeure partie de l'ellipse (figure 4.25), mais n'est pas assez flexible pour permettre des courbes fermées. Les termes de co-circularité (figure 4.26) et d'orientation (figure 4.27) apportent les contraintes manquantes pour reconstituer une plus large gamme de courbes.

– *Stabilité par rapport au bruit*

Les figures 4.28 à 4.30 représentent une ellipse pour laquelle 40% de pixels ont été supprimés aléatoirement. Malgré l'ajout de 5% à 20% de pixels de bruit blanc, une forme circulaire peut être détectée par le réseau. Les situations suivantes représentent respectivement un cercle et une ellipse (figure 4.31) perturbés par un bruit gaussien. Dans ce cas, la détection de contours est perturbée par le faible contraste entre les deux régions. Bien entendu, une meilleure détection de contours aurait pu être obtenue en changeant de paramètre d'échelle (σ pour un filtre gaussien), mais ce n'est pas le but recherché ici. L'intérêt de ces résultats est de montrer qu'un parcours cyclique peut être reconstitué malgré la présence de structures bruitées le long du contours. Les derniers tests, figures 4.34 et 4.35, illustrent l'influence d'un bruit structuré sur le groupement. Malgré des perturbations locales de la forme de la courbe extraite, l'important est de noter l'existence d'un groupement proche de la courbe initiale. La figure 4.35 montre en particulier un groupement selon une courbe de forme quelconque, indépendamment de tout modèle géométrique (cercle ou bien ellipse).

On peut noter enfin les temps de calculs élevés pour des images de taille relativement modeste, ce qui était à prévoir étant donnée la densité du réseau de pixels. Ces temps n'étant dépendant que de la taille de l'image (*i.e.*, du nombre de primitives du réseau) et non de la complexité de la scène, il est toutefois possible de prévoir précisément la durée du traitement.

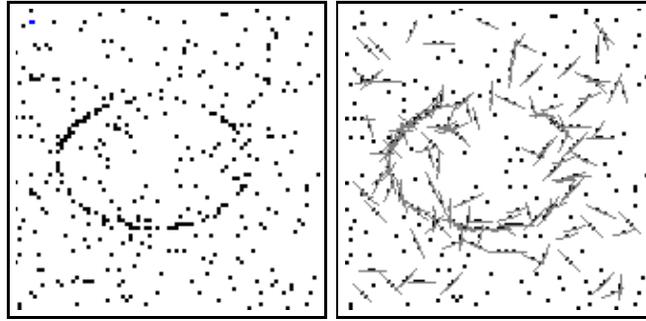


Figure 4.22 - *Ellipse 80×80 pixels avec 5% de bruit. Image d'intensité et évaluation des orientations locales.*

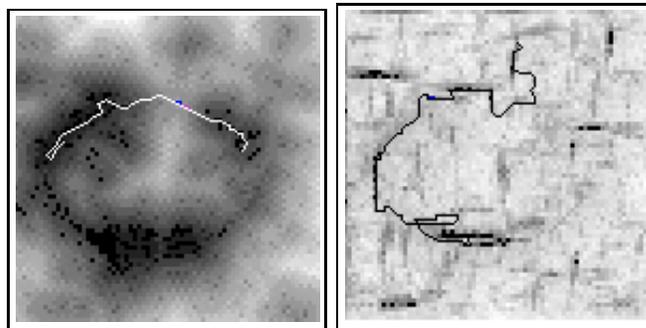


Figure 4.23 - *Optimisation du réseau de saillance et sélection manuelle du meilleur groupement. A gauche: Terme d'intensité seul $\alpha_g = 0.9$. A droite: Terme d'orientation seul $\alpha_o = 0.9$. La saillance maximale est en noir.*

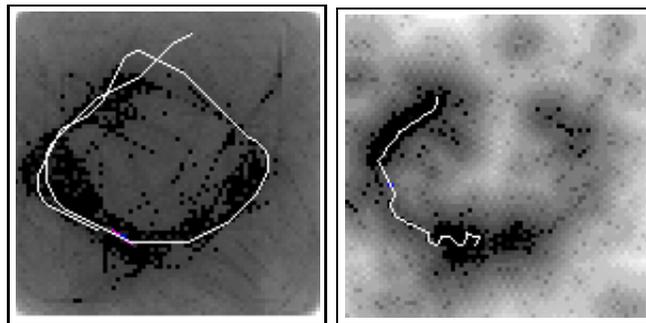


Figure 4.24 - *Optimisation du réseau de saillance et sélection manuelle du meilleur groupement (gauche). A gauche: Terme de courbure seul $\alpha_c = 0.9$. A droite: Terme de cocircularité seul $\alpha_k = 0.9$.*

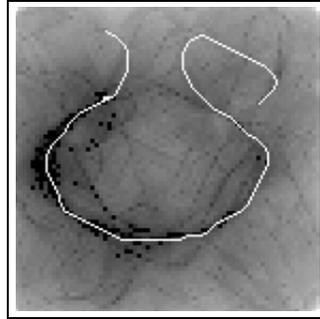


Figure 4.25 - *Optimisation du réseau avec les termes de courbure et d'intensité: $\alpha_c = 0.6$, $\alpha_k = 0$, $\alpha_g = 0.9$, $\alpha_o = 0$.*

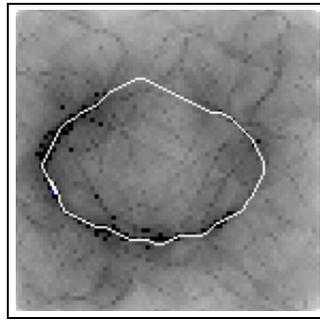


Figure 4.26 - *Optimisation du réseau avec les termes de courbure, d'intensité et de co-circularité: $\alpha_c = 0.6$, $\alpha_k = 0.2$, $\alpha_g = 0.9$, $\alpha_o = 0$.*

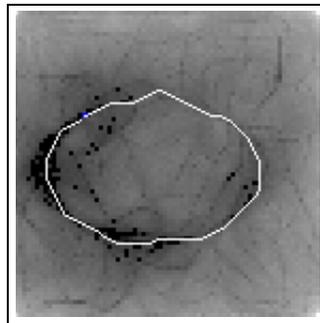


Figure 4.27 - *Optimisation du réseau avec tous les termes: $\alpha_c = 0.6$, $\alpha_k = 0.2$, $\alpha_g = 0.9$, $\alpha_o = 0.2$.*

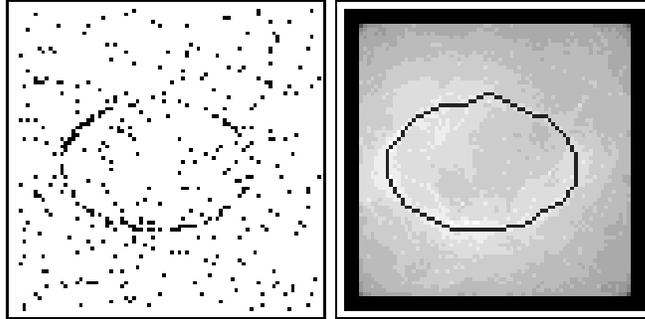


Figure 4.28 - *Ellipse 80×80 pixels avec 5% de bruit - 30 itérations (30 sec / itération)*

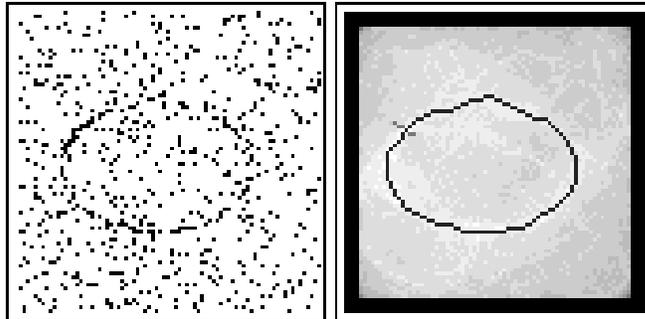


Figure 4.29 - *Ellipse 80×80 pixels avec 10% de bruit - 25 itérations (30 sec / itération)*

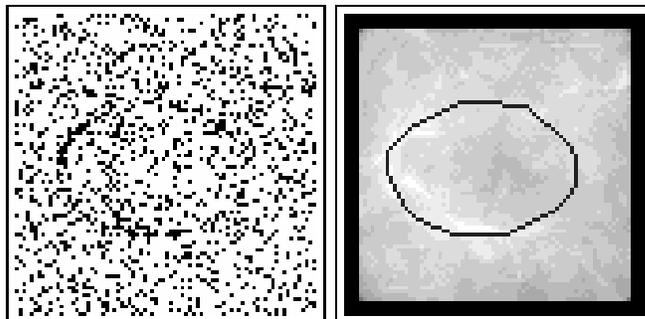


Figure 4.30 - *Ellipse 80×80 pixels avec 20% de bruit - 20 itérations (30 sec / itération). Le nombre d'itérations inférieur au cas précédent s'explique par la présence de pixels de bruit plus nombreux, qui renforcent accidentellement le parcours de la forme saillante.*

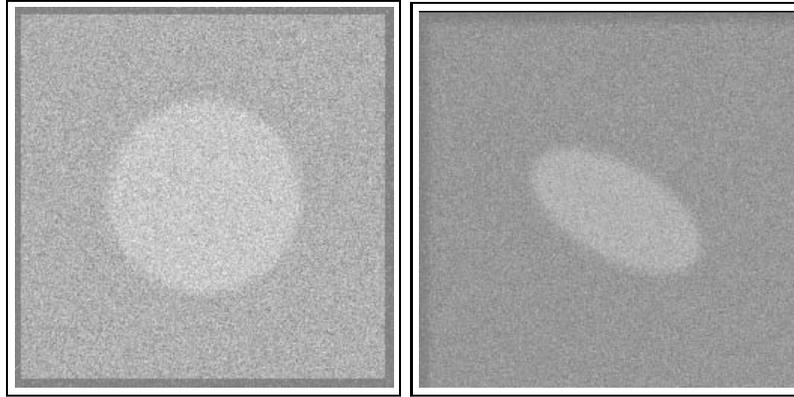


Figure 4.31 - *Cercle et ellipse 256 × 256 pixels, avec bruit gaussien*

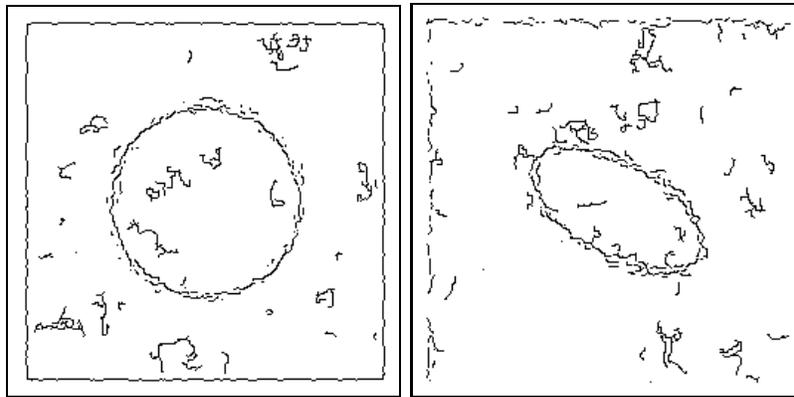


Figure 4.32 - *Détection de contours - Cercle ($RSB = 5.8db$) et Ellipse ($RSB = 7.6db$)*

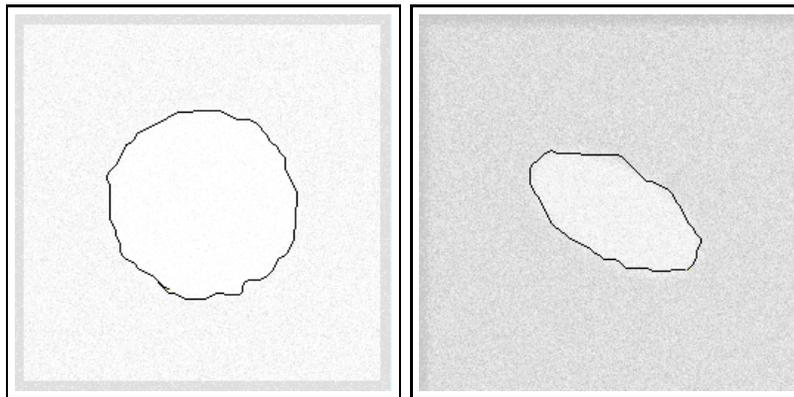


Figure 4.33 - *Groupement - 10 itérations (1 min / itération)*

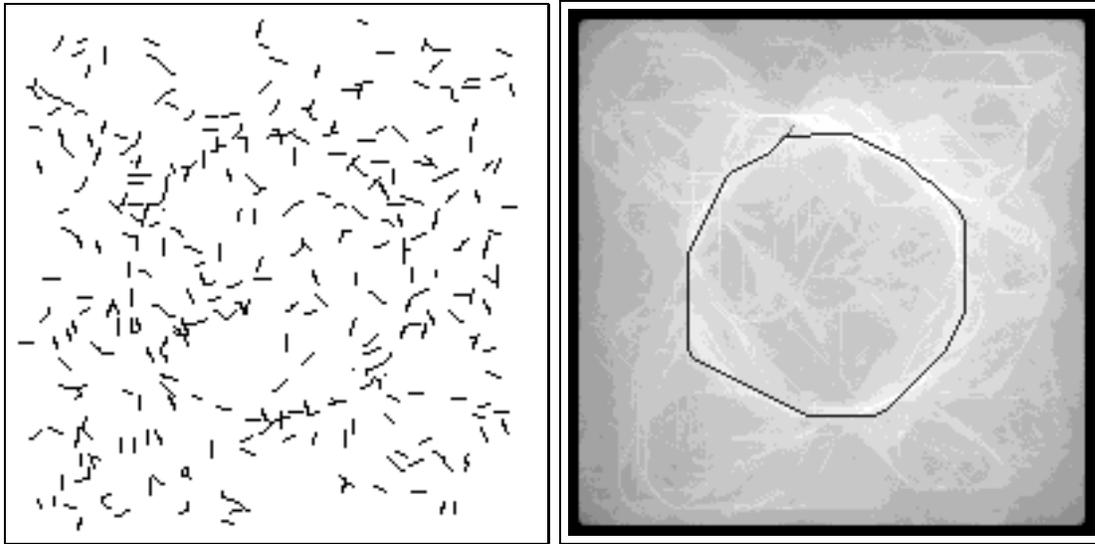


Figure 4.34 - *Cercle avec bruit directionnel. Les segments orientés aléatoirement perturbent la forme finale du groupement. Malgré ce défaut, celui-ci peut néanmoins servir de centre d'attention pour la recherche d'une forme plus précise.*

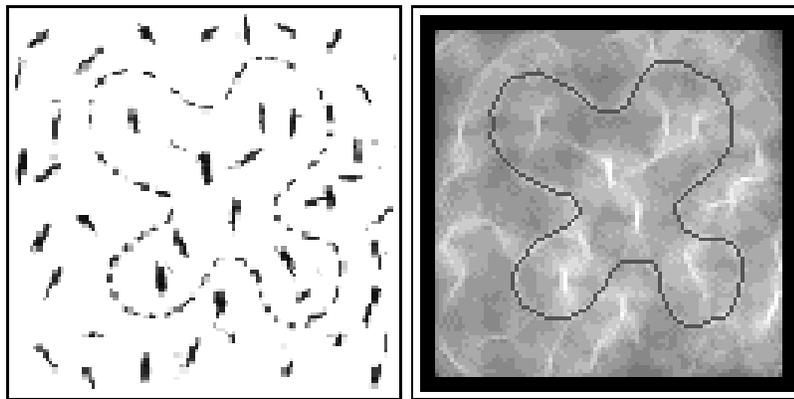


Figure 4.35 - *Courbe et bruit structuré. Ici encore, le groupement est choisi manuellement pour montrer l'existence de parcours corrects dans l'ensemble de groupements possibles sur l'image.*

4.3.7.2 Scènes réelles

Nous illustrons l'utilisation de notre méthode sur des images réelles au travers d'une application particulière d'extraction de réseaux fins. Un réseau fin est un ensemble de structures curvilinéaires tel qu'un réseau routier sur des images satellites ou bien des réseaux sanguins sur des images médicales. Les exemples utilisés ici sont respectivement une image SPOT infrarouge, figure 4.36, et une image d'angiographie du réseau vasculaire du cerveau, figure 4.38.

Dans chaque cas nous présentons l'image d'origine (image monochrome de l'intensité lumineuse), l'image issue de la détection de réseau fin et finalement, les meilleurs groupements extraits après optimisation.

La méthode utilisée pour la détection de réseaux fins est une détection de contours de type "crêtes" telle que décrite en page 59. Le facteur d'échelle relatif à la largeur des crêtes désirées est le même pour chaque exemple ($\sigma = 1$).

Les paramètres d'optimisation et de calcul de la fonction de qualité sont les mêmes pour les trois images. Ces conditions d'utilisation illustrent bien la stabilité de la méthode face au choix des paramètres de la fonction de qualité. Une fois définis pour une certaine classe de courbes, ici, des réseaux fins, les même paramètres donnent de bons résultats pour de nouvelles images présentant ce type de courbes. Ils ne demandent qu'un ajustement éventuel pour affiner les résultats.

Dans ces trois exemples, les groupements ont été extraits à l'aide des seuils de sélection automatique. Ces seuils sont cependant moins stables que les paramètres de la fonction de qualité. Ils doivent être ajustés pour chaque image, afin d'obtenir les groupements les plus représentatifs de la scène.

Enfin, il est important de noter que l'extraction des meilleurs groupements n'obéit qu'à des critères de continuité géométrique, en dehors de toute connaissance particulière sur le type de scène observée. Dans le cas d'une application réelle, cette connaissance devrait intervenir à partir de la sélection des groupements.

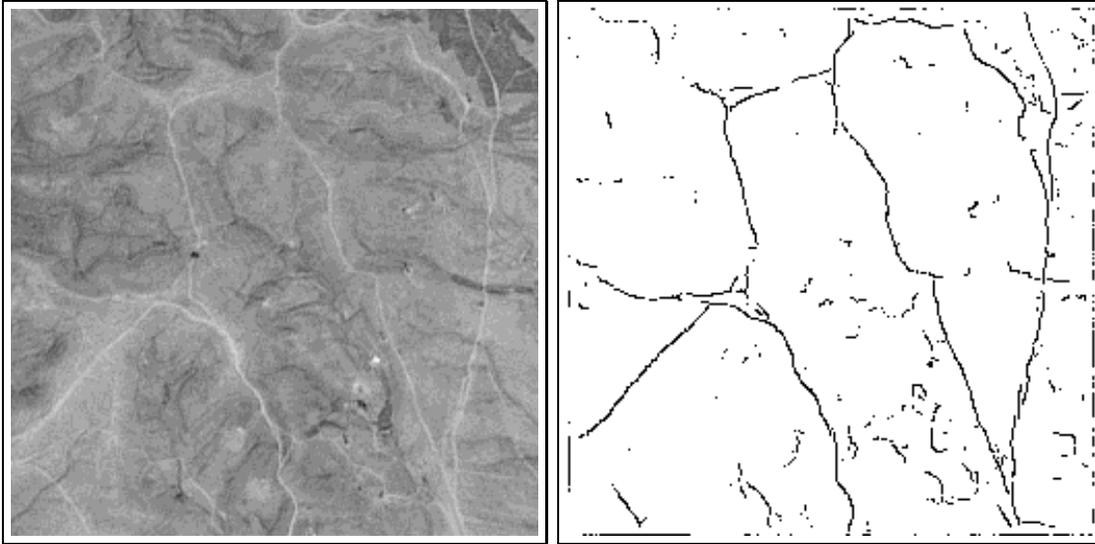


Figure 4.36 - *Image SPOT 256 × 256 pixels - Détection de réseau fin*

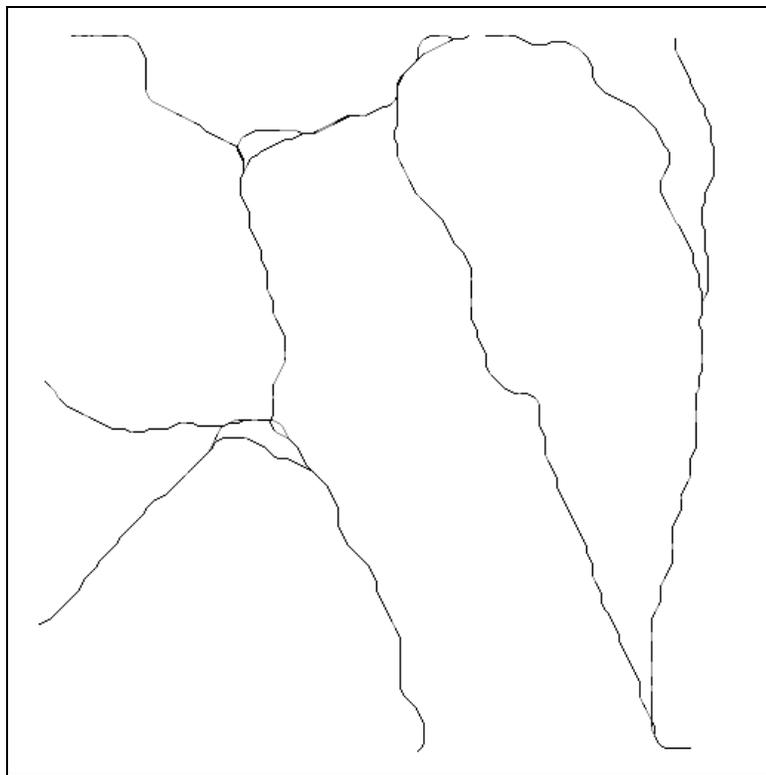


Figure 4.37 - *Détection de routes - Extraction de 16 groupements saillants - 18 itérations (40 sec / itération)*

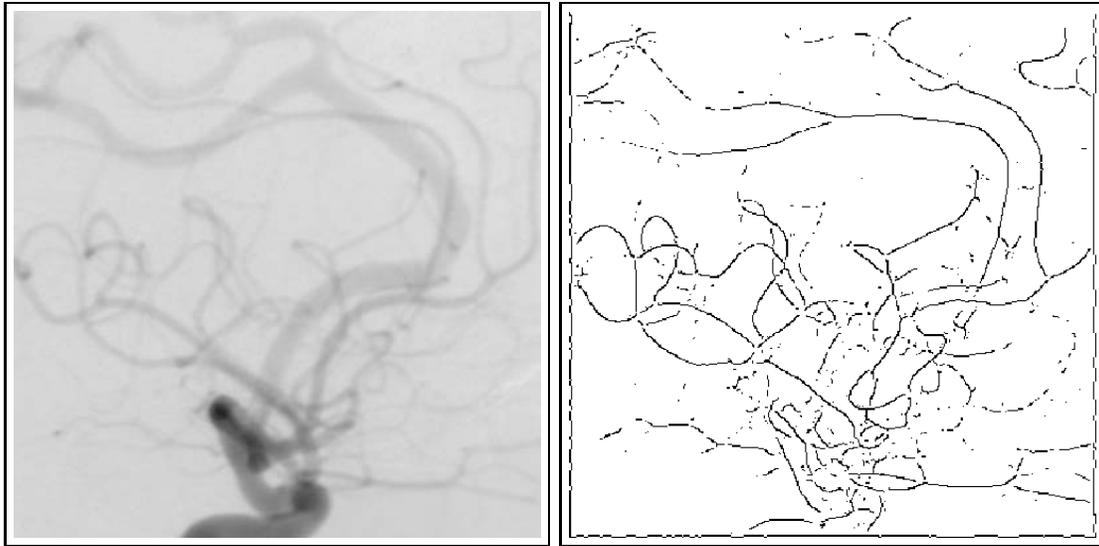


Figure 4.38 - *Angiographie du cerveau 400 × 400 pixels - Détection de réseau fin*

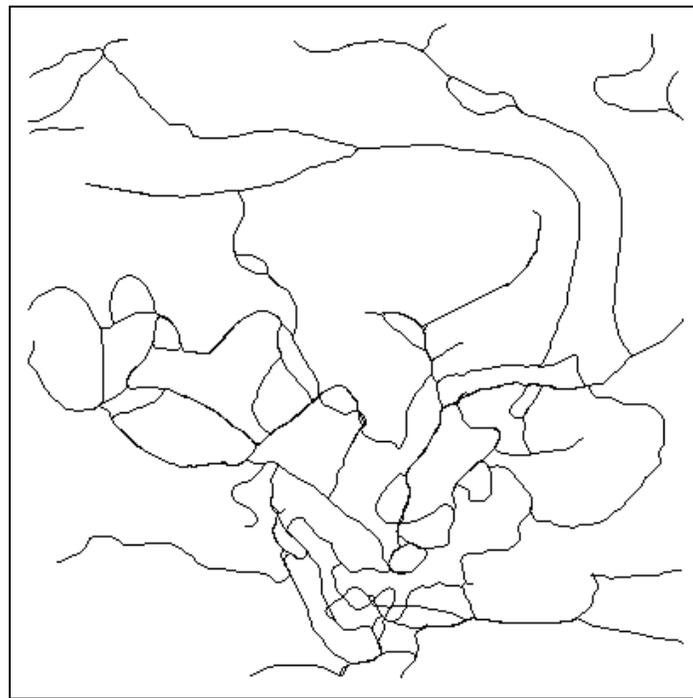


Figure 4.39 - *Extraction d'un réseau de 50 groupements - 30 itérations (2 min / itération)*

4.3.7.3 Conclusion

Malgré la qualité des résultats obtenus, un certain nombre de points mériteraient d'être développés.

Le choix d'un voisinage à 16 orientations s'est révélé être un bon compromis entre qualité des courbes obtenues et complexité de l'algorithme. L'estimation d'une orientation en certains points de contours permettrait d'améliorer ce voisinage en adaptant sa forme à l'environnement de chaque pixel. A ce titre, une version finie des champs d'extension de Guy et Medioni donnerait plus de choix d'orientations autour d'une direction privilégiée tout en interdisant des changements d'orientations trop abrupts.

D'autres extensions possibles à la méthode concernent le suivi et la sélection des meilleurs groupements. En particulier, la présence de paires ambiguës pourrait être mise à profit pour autoriser des retours en arrière lors du parcours des paires optimisées et permettre ainsi une exploration plus poussée des meilleurs chemins du graphe.

En dépit des critères de sélection définis pour les points de départ des courbes, un certain nombre de redondances subsistent. La discrimination entre différentes classes de groupements pourrait être améliorée dans une étape supplémentaire. En guise d'exemple, les groupements sélectionnés à l'issue de l'optimisation peuvent servir d'initialisation à autant de contours actifs qu'il suffit ensuite de comparer. Cette méthode a été appliquée à l'extraction de routes en imagerie aérienne dans [Alquier, 1994] [Montesinos et Alquier, 1996] .

La principale limitation de cette méthode de groupement de pixels est bien entendu son coût élevé en temps et ressources de calcul. Chaque itération peut ainsi aller jusqu'à plusieurs minutes pour une image de 512×512 pixels. S'il serait intéressant d'implémenter la méthode sous une forme parallèle, d'autres solutions existent pour améliorer ses performances ; en particulier, comme le montre l'application suivante, par un choix de primitive plus approprié.

4.4 Application au groupement de chaînes

Nous l'avons vu au chapitre 2, l'utilisation d'éléments de contours sous forme de chaînes ou de segments rectilignes constitue une étape préliminaire à de nombreuses méthodes de structuration des images de contours. Ces segments étant considérablement moins nombreux que les pixels de l'image, ils forment de bons candidats pour réduire la complexité de notre méthode de groupement.

4.4.1 Primitive "chaîne"

Par souci de clarté avec les chapitres suivants, nous appellerons "chaînes" les primitives décrites dans cette partie. Une chaîne est un ensemble de pixels, éventuel-

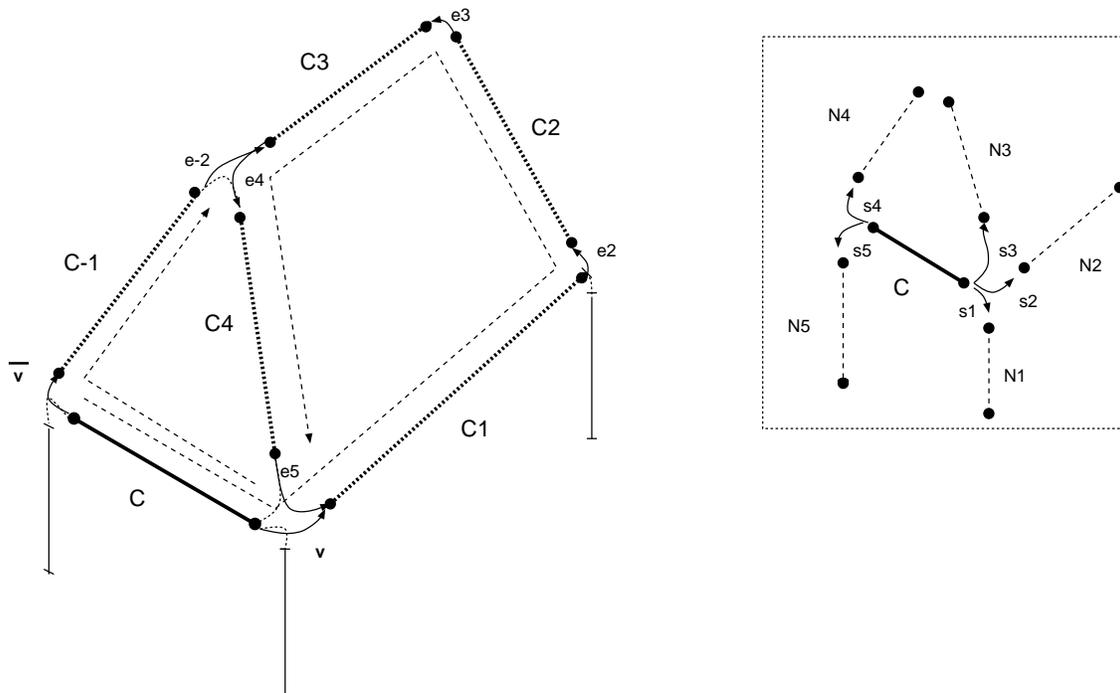


Figure 4.40 - Exemple de voisinage de chaînes avec deux groupements, représentés par les séquences $(C, v, C_1, e_2, C_2, \dots, C_4, e_5)$ et $(C, \bar{v}, C_{-1}, e_{-2})$.

lement rectiligne, obtenu à partir de l'image de contours à l'aide d'un pré-traitement classique de chaînage en 8 connexité.

En termes de groupements perceptuels, cette étape préliminaire revient à grouper les pixels de contours selon un critère de proximité afin de former des chaînes de pixels contigus. Un critère de similarité (orientation commune et courbure faible) permet ensuite d'obtenir un ensemble de segments élémentaires. Ce dernier critère est délibérément choisi avec une tolérance très faible de manière à pouvoir reconstituer fidèlement les courbes saillantes de l'image.

À la différence des pixels, la primitive "chaîne" présente évidemment une structure de dimension plus élevée. Le réseau de saillance doit en conséquence tenir compte des extrémités de chaque chaîne, de leur longueur et éventuellement, leur orientation.

4.4.2 Voisinage dynamique

Nous définissons le voisinage d'une chaîne C par la réunion de chaînes détectées à proximité de chaque extrémité. Un exemple de construction de voisinage de chaînes est donné ci-après mais la définition reste ouverte à d'autres possibilités. Contrairement aux pixels, il est impossible de prévoir le nombre de chaînes pré-

sentes dans le voisinage d'une extrémité. La solution qui consisterait à admettre des primitives "virtuelles" se heurte à la difficulté de définition de telles primitives. De quelle longueur et selon quelle orientation doit-on les établir? A quelle distance des extrémités? C'est pourquoi nous définissons le voisinage de C comme un ensemble de chaînes "réelles" auxquelles chaque extrémité est susceptible d'être reliée.

– Construction d'un voisinage de chaînes

Une première conséquence de cette définition est un voisinage dynamique, défini à l'aide d'une procédure de recherche de voisins compatibles. A partir des extrémités de chaque chaîne, un cône de recherche est établi dans la direction de chaque extrémité. Sa longueur et l'évolution du diamètre en fonction de la distance permettent de modifier la forme de l'espace de recherche et d'adapter éventuellement le voisinage selon l'application désirée. Toute chaîne dont une extrémité se trouve dans la zone de recherche est testée pour être éventuellement incluse dans le voisinage.

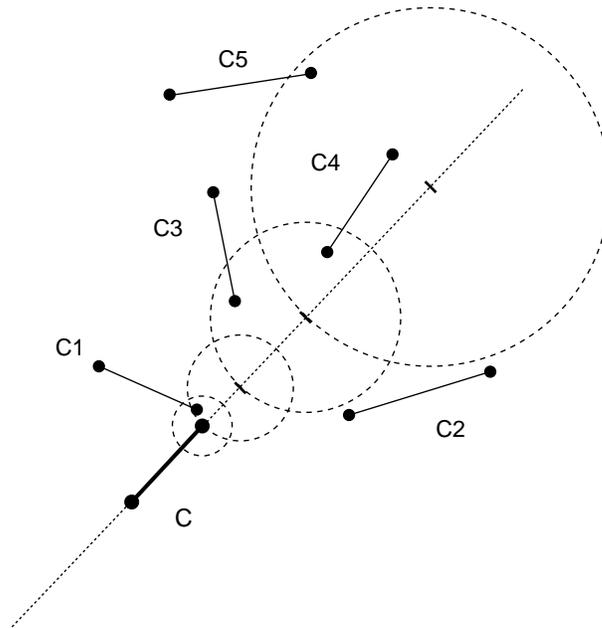


Figure 4.41 - *Cône de recherche pour la construction du voisinage de la chaîne C . La chaîne C_2 se trouve en dehors des zones de recherche successives, elle n'est pas incluse dans le voisinage de C . Les autres chaînes sont des candidats possibles et doivent passer le test de compatibilité afin d'être admises dans $\mathcal{V}(C)$.*

En pratique, le voisinage d'une chaîne est construit à l'aide de cercles centrés sur la direction de la chaîne, à partir de chaque extrémité. La distance d du centre de chaque cercle de recherche avec l'extrémité et leur rayon r sont

exprimés en fonction d'un paramètre t . Le choix de chacune de ces fonctions permet de changer la forme du voisinage de recherche. Par exemple :

$$\text{Cercles concentriques : } \begin{cases} d(t) = 0, & \forall t \\ r(t) = a \cdot t, & t \in [0, t_{max}] \end{cases} \quad (4.18)$$

$$\text{Cône de recherche simple : } \begin{cases} d(t) = b \cdot t, & t \in [0, t_{max}] \\ r(t) = a \cdot t, & t \in [0, t_{max}] \end{cases} \quad (4.19)$$

Dans le cas de notre application, les paramètres du cône de recherche sont définis de manière récursive :

$$\begin{cases} d(t+1) = b \cdot d(t), & t \in [1, 2, \dots, t_{max}] & d(0) = 1 \\ r(t+1) = d(t), & t \in [1, 2, \dots, t_{max}] \end{cases} \quad (4.20)$$

La recherche de nouveaux voisins est interrompue en cas de taille maximale de l'espace de recherche ($t = t_{max}$) ou bien lorsqu'un nombre limite de voisins est atteint. Ces conditions d'arrêt permettent d'éviter les voisinages trop gros par rapport à la taille de la chaîne de départ ainsi que des voisinages trop denses. Notons que les paramètres qui définissent la forme et la taille du voisinage pourraient être ajustés automatiquement en fonction des images observées, et en particulier, par rapport à la densité de chaînes autour de chaque extrémité. En effet, une mesure de densité de chaînes permettrait d'élargir le voisinage de recherche dans les zones de faible densité ou, à l'inverse, limiter les voisinages des chaînes de zones plus denses.

Afin d'être éventuellement incluse dans le voisinage d'une extrémité, une chaîne doit passer un test de compatibilité. Ce test permet d'éviter des configurations locales entre chaînes en contradiction avec le type de groupement recherché.

Soient deux chaînes C_0 , C_1 et $S_{0,1}$ le segment rectiligne reliant une extrémité de chaque chaîne, X_0 et X_1 . On note enfin $\lambda_{0,1}$ l'angle formé par $S_{0,1}$ et la direction de C_0 , et $\lambda_{1,0}$ l'angle formé par $S_{0,1}$ et la direction de C_1 .

$$\lambda_{0,1} = \widehat{\overrightarrow{X_0 X_1}, \overrightarrow{T_0}} \quad \lambda_{1,0} = \widehat{\overrightarrow{X_1 X_0}, \overrightarrow{T_1}}$$

Dans ce cas, l'extrémité X_1 de la chaîne C_1 peut être connectée à l'extrémité X_0 de la chaîne C_0 si les deux angles vérifient la relation :

$$C_1 \in \mathcal{V}(C_0) \implies \lambda_{0,1} < \lambda_{seuil} \text{ et } \lambda_{1,0} < \lambda_{seuil} \quad (4.21)$$

L'angle limite λ_{seuil} est arbitrairement fixé à 70 degrés afin d'éviter les connexions trop abruptes. Notons que ce critère strict de compatibilité est donné

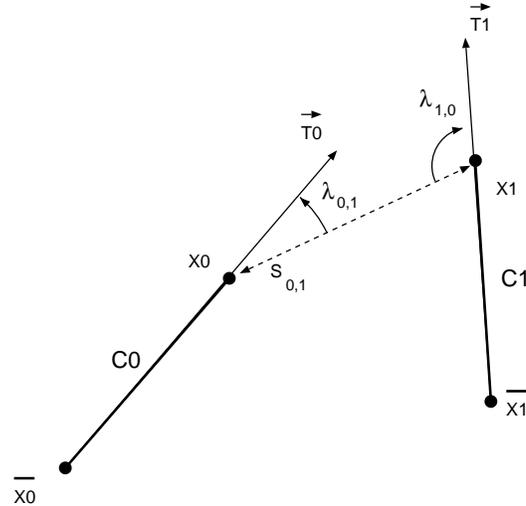


Figure 4.42 - Test de compatibilité entre une chaîne C_0 et un voisin possible C_1 . Ici, le test est négatif car $\lambda_{1,0} > \lambda_{seuil}$.

à titre d'exemple. Il pourrait être utile, en effet, d'envisager des relations plus "floues" entre chaînes pour résoudre des situations ambiguës (par exemple, dans la figure 4.41, les chaînes C_2 et C_3 jouent un rôle équivalent par rapport à C).

– Définition des éléments de connexion

Une autre conséquence de cette définition de voisinage concerne la nature des éléments de connexion entre chaînes, naturellement définis comme un chemin dans l'image reliant deux extrémités de chaque chaîne. Les connexions entre chaînes voisines d'une même extrémité sont interdites afin de forcer toute courbe arrivant par l'extrémité d'une chaîne à ressortir par l'autre extrémité. Cette contrainte correspond à la définition des paires interdites entre voisins d'une même chaîne.

Le modèle choisi pour relier deux chaînes entre elles est une simple courbe polynômiale d'interpolation ou *Cardinal-Spline*. Ce type de courbe est défini par un polynôme d'ordre 3. Soit $M(t)$ une telle courbe et $M'(t)$ sa dérivée, $t \in [0, 1]$:

$$M(t) = \sum_{i=0}^3 a_i \cdot t^i \quad \implies \quad M'(t) = 3 \cdot a_3 \cdot t^2 + 2 \cdot a_2 \cdot t + a_1$$

Relier les extrémités de deux chaînes revient à trouver les coefficients de la courbe de manière à ce qu'elle passe par chaque extrémité X_0 et X_1 , avec une tangente correspondant à l'orientation de chacune des chaînes, T_0 et T_1 .

En écrivant le système pour $t = 0$ et $t = 1$, on obtient :

$$\begin{cases} M(0) = X_0 & M(1) = X_1 \\ M'(0) = T_0 & M'(1) = T_1 \end{cases} \quad (4.22)$$

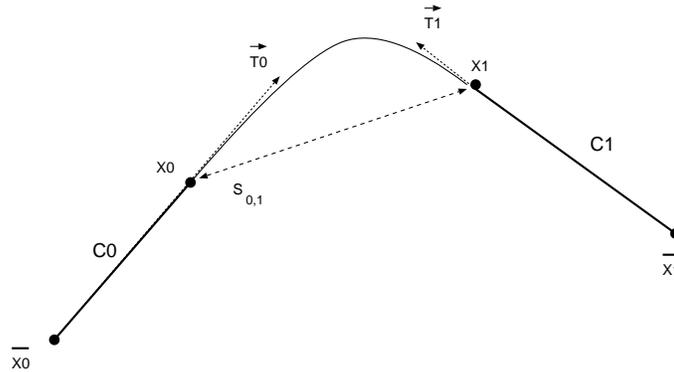


Figure 4.43 - *Élément de connexion entre deux chaînes - une courbe polynômiale définie par les extrémités X_0, X_1 et les tangentes T_0, T_1*

Soit, après substitution :

$$\begin{cases} a_3 = -2 \cdot [M(1) - M(0)] + M'(0) + M'(1) \\ a_2 = 3 \cdot [M(1) - M(0)] - 2 \cdot M'(0) - M'(1) \\ a_1 = M'(0) \\ a_0 = M(0) \end{cases} \quad (4.23)$$

Afin d'éviter des connexions entre chaînes trop petites, les chaînes réduites à un ou deux pixels sont éliminées immédiatement après l'étape d'approximation polygonale.

– Cas des jonctions en T

Relier les chaînes par leurs extrémités interdit la détection de jonctions multiples entre chaînes, à moins d'avoir découpé les chaînes autour de jonctions détectées au préalable. Un détecteur spécialisé de coins ou de jonctions tel que présenté dans la section 2.3.3 permettrait d'avoir un accès direct à ces points de coupure éventuels.

En l'absence de tels détecteurs, une recherche exhaustive des points de coupures possibles permet de préparer les chaînes à la construction du réseau de saillance. Cette recherche consiste à détecter la présence de chaînes traversant un voisinage réduit de chaque extrémité et de les découper dans le prolongement de l'extrémité comme le montre la figure 4.44.

Il appartient à l'algorithme de découpage autour des jonctions de limiter la taille des chaînes à découper afin de ne pas accroître inutilement le nombre de primitives du réseau de saillance. Un nombre trop important de chaînes réduirait la vitesse d'optimisation du réseau. En outre, les petites chaînes étant peu fiables pour des mesures d'orientations ou de courbure, il n'est pas utile de fragmenter les éléments de contours en chaînes trop petites.

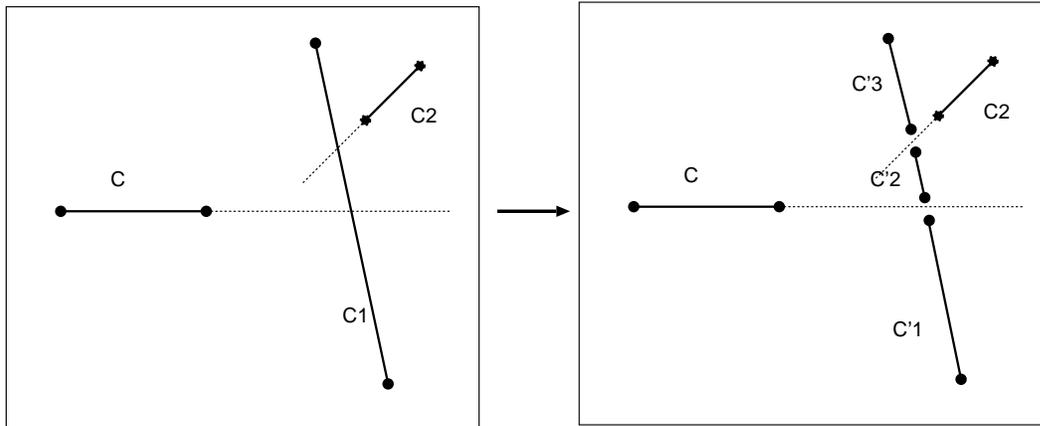


Figure 4.44 - *Le découpage de chaînes dans la direction des extrémités des chaînes voisines est indispensable pour permettre d'éventuelles jonctions en "T". La chaîne C_1 est ainsi remplacée par trois sous chaînes à cause de la proximité des chaînes C et C_2 .*

Finalement, la construction du réseau de saillance pour les chaînes est constituée des étapes résumées par l'algorithme suivant :

Algorithme 4.3 : Préparation d'un réseau de saillance de chaînes

début

- Chaînage de l'image de contours pour obtenir un ensemble de chaînes primaires.
- Élimination des chaînes trop petites.
- Estimation des orientations en bout de chaque chaîne.
- Découpage autour de jonctions en T éventuelles.
- Construction du voisinage aux extrémités de chaque chaîne

fin

4.4.3 Fonction de qualité

De la même manière que pour le groupement de pixels, la fonction de qualité utilisée pour le groupement de chaînes est une combinaison linéaire de quatre termes. Soit, pour une courbe γ composée des chaînes $\{C, C_1, \dots, C_n\}$ et des éléments de connexion $\{s_1, s_2, \dots, s_n\}$:

$$\mathcal{F}(C, s_1) = \begin{cases} \alpha_t \cdot \mathcal{T}(C, s_1) + \alpha_k \cdot \mathcal{K}(C, s_1) & (\textit{influences internes}) \\ + \alpha_d \cdot \mathcal{D}(C, s_1) + \alpha_o \cdot \mathcal{O}(C, s_1) & (\textit{influences externes}) \end{cases} \quad (4.24)$$

Cette fonction doit être forte pour des groupements de chaînes selon des courbes lisses, continues et peu sinueuses. Les termes de cette somme sont définis à l'aide des relations suivantes :

– Relations structurelles internes

L'estimation de la courbure, et à plus forte raison de la co-circularité, se heurte à un difficile problème d'échelle lorsqu'il s'agit de chaînes de pixels [Worring et Smeulders, 1993] . Les approximations utilisées pour le groupement de pixels n'ont de sens que pour des évaluations locales, sur des portions élémentaires de courbes. Dans le cas de chaînes, nous privilégions la recherche de caractéristiques indirectement dérivées de la courbure.

Afin de favoriser les courbes peu sinueuses par rapport à des groupements plus bruités, nous introduisons un premier terme de courbure. Ce terme est maximal lorsqu'un élément de connexion relie deux chaînes colinéaires et décroît en fonction des angles entre cet élément et chacune des chaînes :

$$\mathcal{T}(C, s_1) = \sum_{i=1}^n \rho_i^{i-1} \cdot \frac{2\pi - |\lambda_{i-1,i}| - |\lambda_{i,i-1}|}{2\pi} \quad (4.25)$$

Le terme suivant est assimilable à un terme de co-circularité. Comme c'était le cas pour les pixels, ce terme apporte une information plus globale sur la forme d'un groupement. Il permet de favoriser les portions de courbes tournant d'une manière régulière dans un même sens.

Ce terme est nul lorsque la connexion entre chaînes forme une inflexion, c'est à dire, lorsque les angles $\lambda_{0,1}$ et $\lambda_{1,0}$ sont de même signe.

Dans le cas contraire, les cercles passant par trois sommets consécutifs de la connexion, respectivement $(\overline{X_0}, X_0, X_1)$ et $(X_0, X_1, \overline{X_1})$, permettent de définir :

$$K(C, C_1) = \begin{cases} \frac{\min(r_0, r_1)}{\max(r_0, r_1)} & \textit{si } \textit{sgn}(\lambda_{0,1}) \cdot \textit{sgn}(\lambda_{1,0}) > 0 \\ 0 & \textit{sinon} \end{cases} \quad (4.26)$$

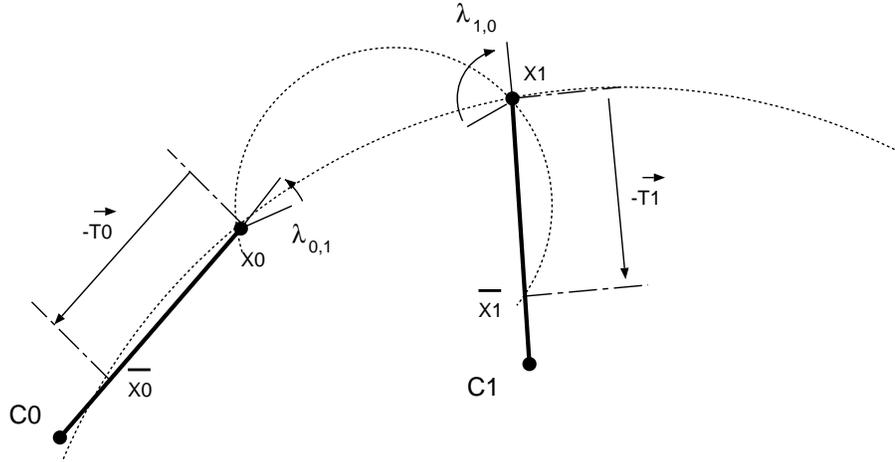


Figure 4.45 - Estimation de la co-circularité de deux chaînes. Dans le cas où les deux angles $\lambda_{0,1}$ et $\lambda_{1,0}$ sont de signe opposé, la connexion entre les deux chaînes ne forme pas d'inflexion. La co-circularité est estimée par le rapport entre les rayons des cercles "porteurs".

où r_0 et r_1 sont les rayons respectifs des deux cercles. Ce terme est maximal lorsque les deux cercles ont un rayon identique. Les points $\overline{X_0}$ et $\overline{X_1}$ sont définis à l'aide des vecteurs d'orientation en extrémité des chaînes, comme le montre la figure 4.45. Les deux chaînes sont d'autant plus co-circulaires que les deux cercles ont un rayon similaire.

Soit, pour le terme total :

$$\mathcal{K}(C, s_1) = \sum_{i=1}^n \rho_k^{i-1} \cdot K(C_i, C_{i-1}) \quad (4.27)$$

– Influences externes

Les contraintes imposées par l'image sont plus proches de celles utilisées pour les pixels. Leur rôle est de pénaliser les courbes discontinues et présentant des écarts angulaires trop importants.

Le premier terme externe récompense les connexions dont la longueur reste faible par rapport à la longueur des chaînes connectées, ce qui permet de récompenser les courbes contenant peu de discontinuités.

Soient L_0 et L_1 les longueurs respectives de chaque chaîne et $L_{s_{0,1}}$ la longueur de l'élément de connexion entre ces chaînes. Le terme recherché peut être défini par :

$$\mathcal{D}(C, s_1) = \sum_{i=1}^n \rho_d^{i-1} \cdot \frac{(L_{i-1} + L_i)}{(L_{i-1} + L_i + L_{s_{i-1,i}})} \quad (4.28)$$

La contribution de ce terme est proche de 1 lorsque la longueur de la connexion est faible devant les longueurs des chaînes. Sa valeur décroît ensuite en fonction de la longueur de connexion.

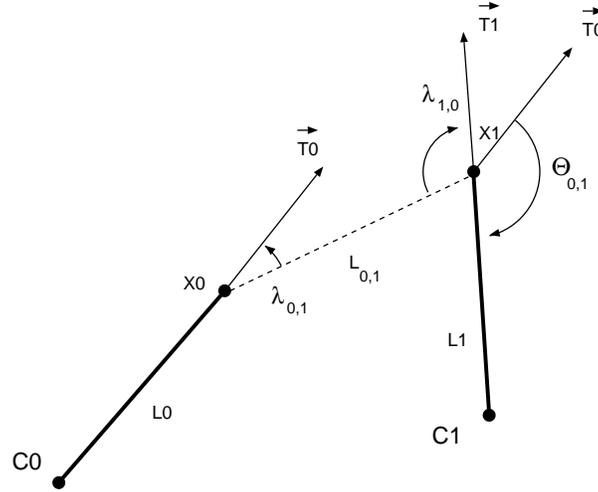


Figure 4.46 - Mesures de longueurs et d'orientation entre deux chaînes et leur connexion.

Pénaliser les écarts angulaires forts revient simplement à calculer cet écart. Soient \vec{T}_0 et \vec{T}_1 les orientations aux extrémités de chaque chaîne. L'écart angulaire entre ces tangentes est noté :

$$\Theta_{0,1} = (\vec{T}_0, -\vec{T}_1) [\pi]$$

Ce qui conduit au terme d'orientations :

$$\mathcal{O}(C, s_1) = \sum_{i=1}^n \rho_o^{i-1} \cdot \left(1.0 - \left(\frac{\Theta_{i-1,i}}{\pi}\right)\right) \quad (4.29)$$

Ce terme accorde de l'importance aux connexions lorsque les chaînes partagent une direction similaire. Sa valeur décroît lorsque l'écart angulaire entre les deux directions se rapproche de π .

Les termes ainsi définis permettent de contrôler le type de courbes désiré de la même manière que pour le groupement de pixels.

4.4.4 Mesure de saillance

En conservant toujours les mêmes notations, la mesure de saillance à optimiser est exprimée en fonction des courbes partant d'une chaîne C , selon les directions d'une paire d'éléments de connexion (v, \bar{v}) . Soit, pour une courbe Γ_C :

$$S^n(\Gamma_C) = \begin{cases} \alpha_t \cdot (\mathcal{T}^n(C, v) + \mathcal{T}^n(C, \bar{v}) + H_t(C)) \\ + \alpha_k \cdot (\mathcal{K}^n(C, v) + \mathcal{K}^n(C, \bar{v}) + H_k(C)) \\ + \alpha_d \cdot (\mathcal{D}^n(C, v) + \mathcal{D}^n(C, \bar{v}) + H_d(C)) \\ + \alpha_o \cdot (\mathcal{O}^n(C, v) + \mathcal{O}^n(C, \bar{v}) + H_o(C)) \end{cases} \quad (4.30)$$

En tenant compte de la paire (v, \bar{v}) , les valeurs initiales de chaque terme de la fonction de qualité sont, pour la branche de la courbe relative à v :

$$\begin{cases} \mathcal{T}_0(C, v) = \frac{2\pi - |\lambda_{0,1}| - |\lambda_{1,0}|}{2\pi} & \mathcal{K}_0(C, v) = K(C, v) \\ \mathcal{D}_0(C, v) = \frac{(L_0 + L_1)}{(L_0 + L_1 + L_{s0,1})} & \mathcal{O}_0(C, v) = (1.0 - (\frac{\Theta_{0,1}}{2})) \end{cases} \quad (4.31)$$

Les valeurs initiales des termes de l'autre branche sont symétriques. Contrairement à la fonction de qualité des pixels, aucun de ces termes ne dépend à la fois de v et de \bar{v} , ce qui conduit aux fonctions de correction suivantes :

$$H_i(C) = 0, \quad \forall i \in [t, k, d, o]$$

4.4.5 Optimisation et sélection des meilleures courbes

Comme nous l'avons signalé lors de la définition du voisinage d'une chaîne, la principale contrainte imposée sur le choix des paires d'éléments interdit toute connexion entre éléments partageant une même extrémité de la chaîne.

L'équation 4.31 donne directement la valeur initiale des variables d'état de chaque élément de connexion. La relation de récurrence pour chaque terme de la fonction de qualité est tout aussi immédiate : Soit, pour l'une des deux branches, avec $n \neq 0$:

$$\begin{cases} \mathcal{T}^{n+1}(C, v) = \mathcal{T}_0(C, v) + \rho_t \cdot \mathcal{T}^n(C_i, \phi(v)) \\ \mathcal{K}^{n+1}(C, v) = \mathcal{K}_0(C, v) + \rho_k \cdot \mathcal{K}^n(C_i, \phi(v)) \\ \mathcal{D}^{n+1}(C, v) = \mathcal{D}_0(C, v) + \rho_d \cdot \mathcal{D}^n(C_i, \phi(v)) \\ \mathcal{O}^{n+1}(C, v) = \mathcal{O}_0(C, v) + \rho_o \cdot \mathcal{O}^n(C_i, \phi(v)) \end{cases} \quad (4.32)$$

avec C_i , chaîne reliée à C par l'élément v . Les coefficients d'atténuation sont, ici aussi, identiques : $\forall i, \rho_i = 0.9$.

Le nombre de chaînes dans une image étant considérablement plus faible que le nombre de pixels, l'optimisation d'un réseau de chaînes permet d'obtenir des temps de calculs considérablement réduits. En pratique, ces temps sont de l'ordre de la

seconde par itération, pour un résultat comparable au groupement de pixels. Les résultats présentés plus loin permettent de mieux comparer les deux méthodes de groupement.

L'algorithme d'extraction et de sélection des meilleures courbes présente peu d'adaptations spécifiques aux chaînes. L'absence de groupements avec des éléments virtuels permet d'éviter les cycles parasites en fin de courbe ouverte que présentait le groupement de pixels. La construction des chaînes et le découpage préalable autour des extrémités rend impossible toute intersection entre chaînes autrement que par le biais d'un élément de connexion. Cette propriété permet de limiter la recherche de cycles éventuels aux seules courbes de liaison entre chaînes.

Seules les définitions des critères de saillance locale et globale dépendent réellement du choix du type de primitive à grouper. Dans le cas des chaînes, la saillance locale est définie comme la somme des gradients le long d'une chaîne, normalisée par sa longueur. Soit, en notant $\{P_1, \dots, P_m\}$ les pixels d'une chaîne et $I(P_i)$ l'intensité de l'image d'origine en P_i :

$$\mathcal{L}(\Gamma_C) = \frac{\sum_{k=1}^n \sqrt{\left(\frac{\partial I(P_k)}{\partial x}\right)^2 + \left(\frac{\partial I(P_k)}{\partial y}\right)^2}}{L_C \cdot G_{max}}$$

où L_C est la longueur de la courbe et G_{max} la valeur maximale de la norme du gradient sur toute l'image.

La mesure de saillance globale d'un groupement est calquée sur celle utilisée pour les pixels. La seule différence est la manière de mesurer la proportion de discontinuité le long de la chaîne. Soit $L_{chaînes}$ la somme des longueurs des chaînes du groupement et L_{liens} la somme des longueurs des éléments de connexion entre ces chaînes. La saillance globale est alors définie par :

$$\mathcal{Q}(\Gamma_C(v, \bar{v})) = \frac{L_{chaînes}}{1 + L_{liens}} \cdot \left[\sum_{k=0}^{n-1} S^n(\bar{s}_k, \phi(\bar{s}_k)) + \sum_{k=0}^{n-1} S^n(s_k, \phi(s_k)) \right]$$

4.4.6 Résultats et perspectives

Par soucis de comparaison, nous avons appliqué le groupement de chaînes au même type de scènes que pour le groupement de pixels. Les résultats ont été obtenus, ici encore, avec un même jeu de paramètres pour la fonction de qualité. Les seules variations de paramètres concernent la taille de l'espace de recherche pour la construction du réseau⁸. D'autres types de scènes permettent ensuite d'illustrer le comportement de notre approche dans des situations variées.

4.4.6.1 Images synthétiques

Ces images confirment la résistance de la méthode au bruit structuré. Contrairement à la méthode précédente, le bruit ponctuel joue ici un rôle minime étant donné

⁸. Implémentation en C sur une station de travail Ultra-SPARC et sur PC.

l'élimination des chaînes de petite taille avant la construction du réseau. Dans chacune de ces scènes, les groupements ont été sélectionnés à l'aide des seuils de qualité. Les groupements solutions sont présentés en noir et les chaînes rejetées en gris.

Le première scène, figures 4.47 et 4.48, illustre les différentes étapes du groupement, depuis la construction du réseau jusqu'à l'extraction des meilleurs groupes. Le cercle bruité de la figure 4.50 montre l'intérêt de superposer les meilleurs groupes pour en extraire une forme saillante.

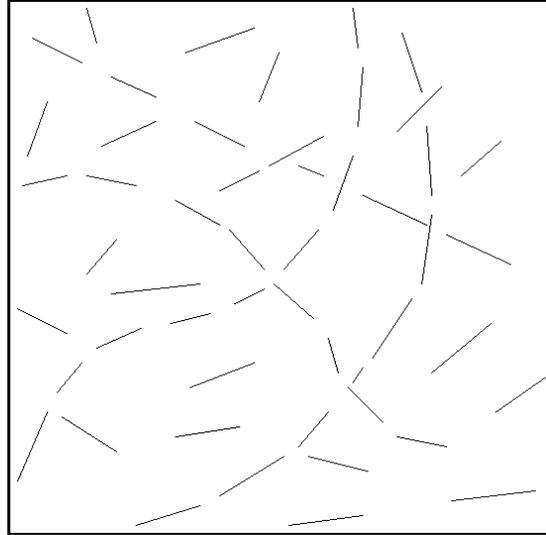


Figure 4.47 - *Chaines de départ*

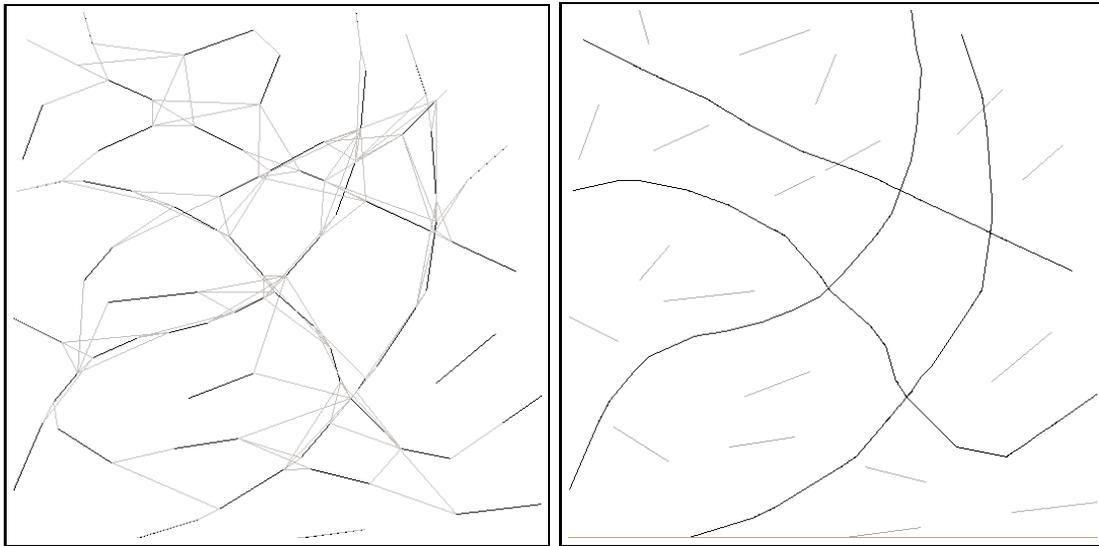


Figure 4.48 - *Graphe de connexions et Sélection automatique des 4 meilleurs groupes*

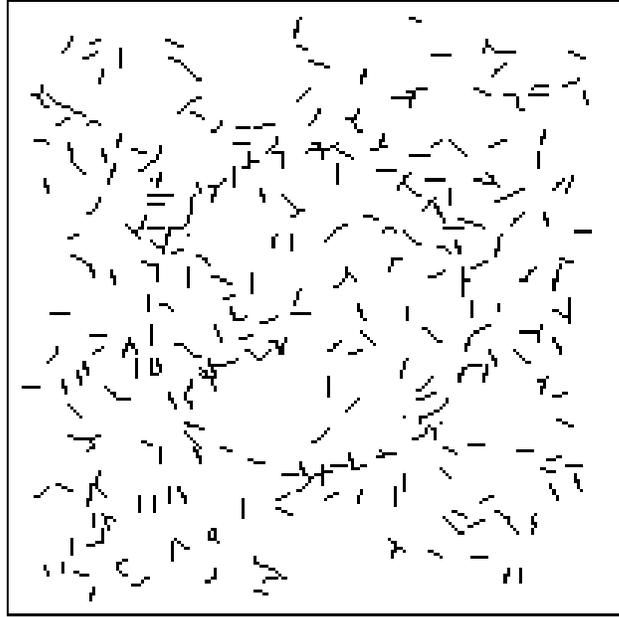


Figure 4.49 - *Cercle avec bruit directionnel - segments orientés aléatoirement*

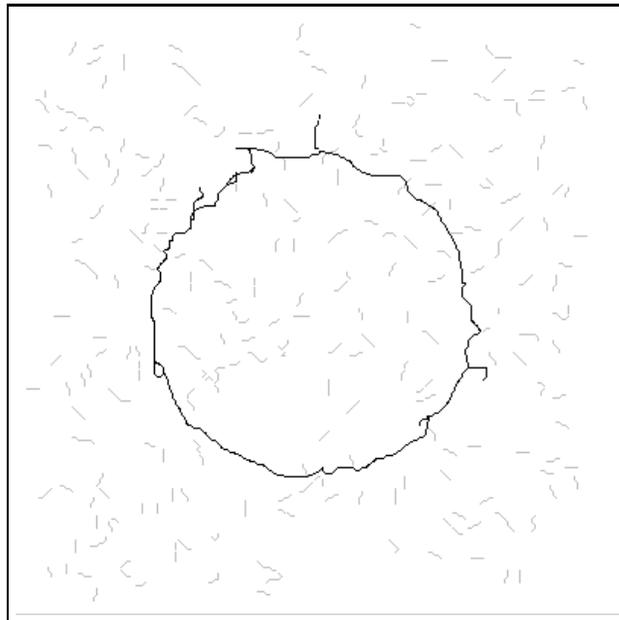


Figure 4.50 - *Superposition de 11 groupements, après seuillage selon les trois critères de sélection.*

4.4.6.2 Images réelles

Nous reprenons à la page 157 l'une des scènes de détection de réseaux fins utilisées pour le groupement de pixels. Le groupement de chaînes permet d'obtenir des résultats d'une qualité comparable dans un temps de calcul beaucoup plus court : 0.5 secondes par itération contre 40 secondes à 2 minutes par itération pour le groupement de pixels.

La différence d'aspect entre les courbes, plus lisses pour les groupements de pixels que de chaînes, s'explique par l'influence des éléments de connexion "virtuels". En effet, les voisins immédiats des pixels de contours permettent de lisser le tracé des groupements. Dans le cas des groupements par chaînes, l'extraction de courbes "lisses" est reléguée aux niveaux supérieurs d'organisation afin de permettre une interprétation des groupements selon plusieurs échelles de lissage.

On peut noter dans la figure 4.51 que les branches du croisement situé en bas, à gauche, ont été correctement reconstituées. L'utilisation des chaînes comme primitive de groupement permet de réduire considérablement les effets de "basculement" du suivi d'une structure à l'autre en cas de contours parallèles.

Les scènes des pages suivantes, pages 158 à 268, montrent comment les principes génériques de groupement peuvent être appliqués à des situations aussi différentes qu'une façade de bâtiment ou un objet manufacturé. Ces derniers exemples illustrent l'utilité du groupement perceptuel pour mettre en évidence des structures régulières, en général associées aux contours des objets, tout en écartant les courbes trop sinueuses et qui correspondent plus souvent à du bruit ou bien des surfaces texturées.

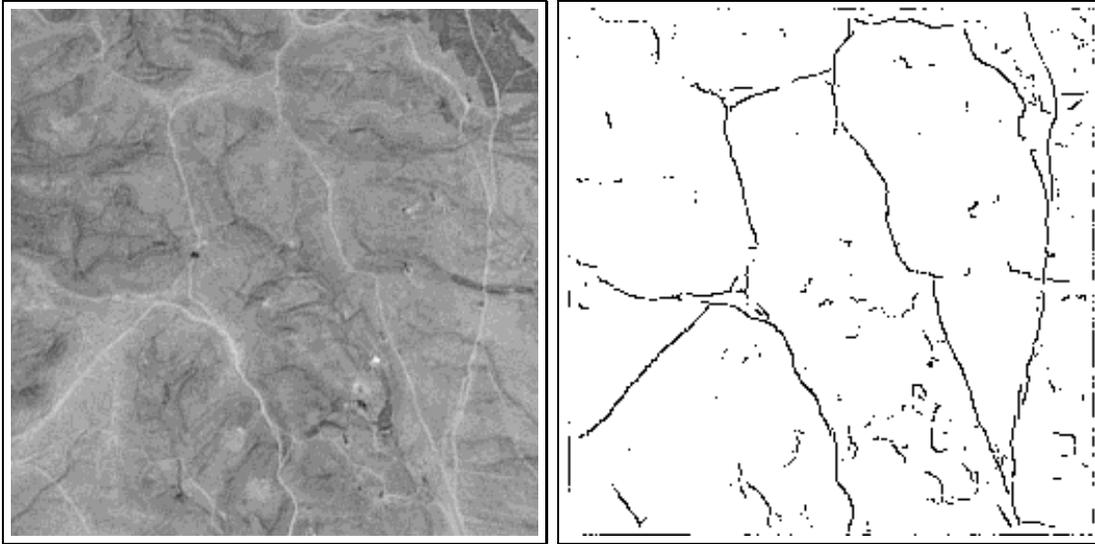


Figure 4.51 - *Image SPOT 256 × 256 pixels - Détection de réseau fin - 344 chaînes*

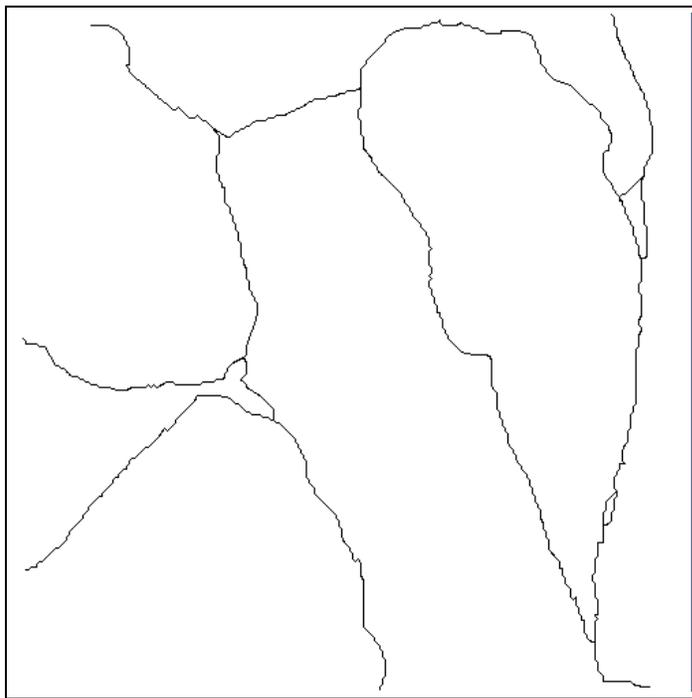


Figure 4.52 - *Détection de routes - Extraction de 9 groupements saillants - 50 itérations (0,3 sec / itération)*

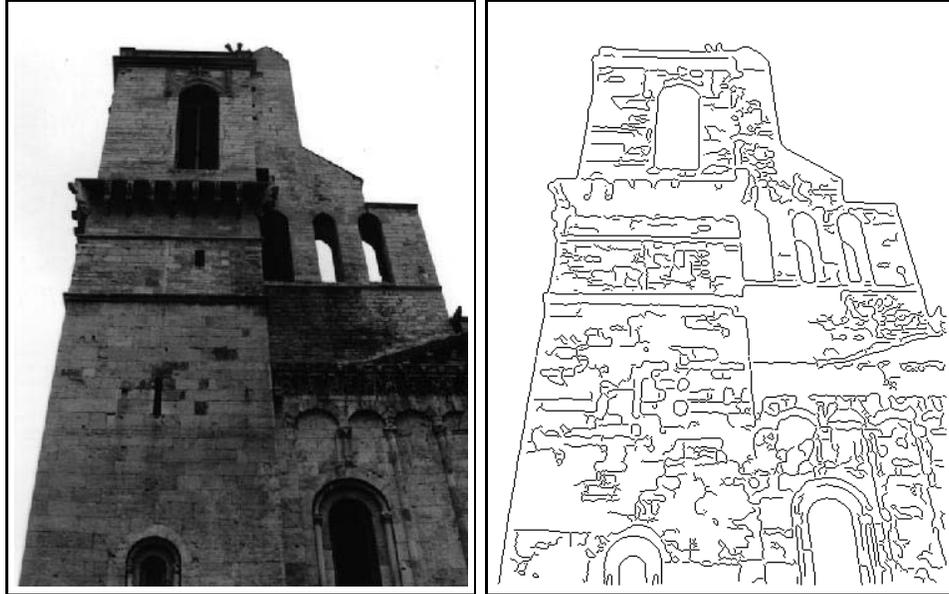


Figure 4.53 - *Cathédrale 360 × 460 pixels - Détection de contours*

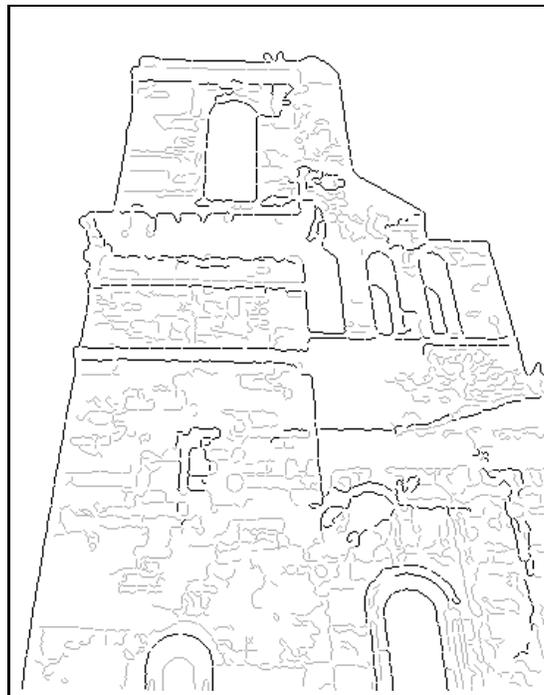


Figure 4.54 - *165 chaînes saillantes sur 2397 chaînes - 50 itérations (0,8 sec / itération)*

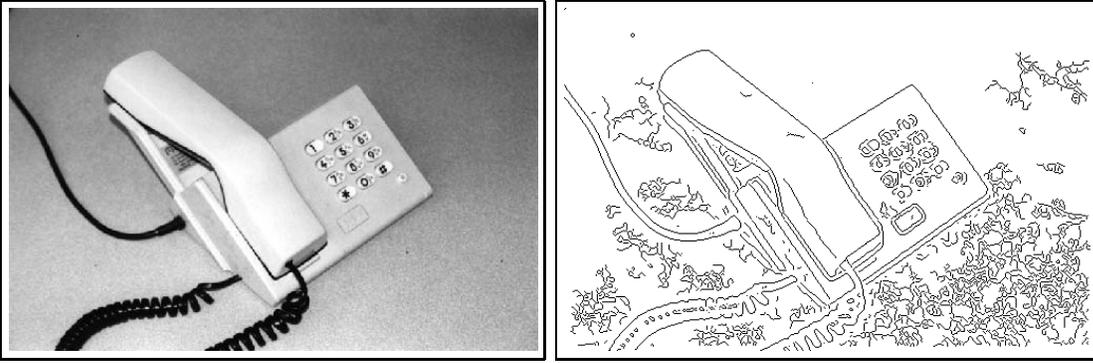


Figure 4.55 - Téléphone 500×328 pixels - Détection de contours

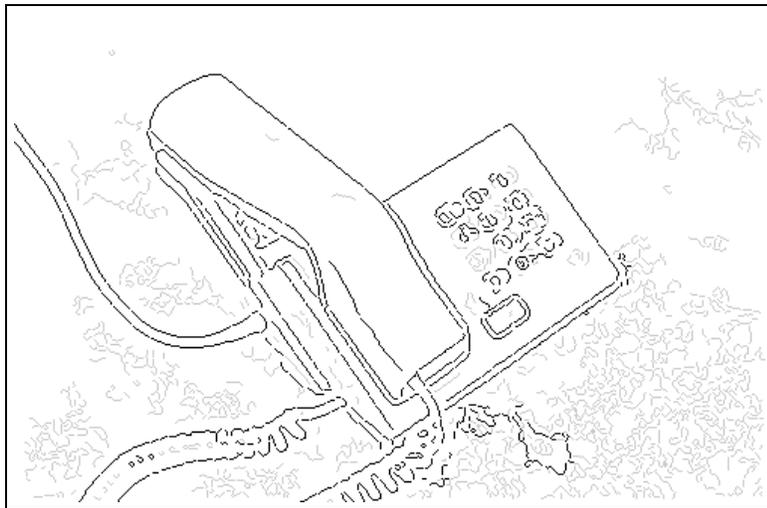


Figure 4.56 - 310 chaînes saillantes sur 2780 chaînes - 50 itérations (0,8 sec / itération)

4.4.6.3 Conclusion

Nous venons de montrer les avantages qu'offrent les chaînes de contours pour le groupement à partir d'un réseau de saillance. Le nombre de chaînes étant considérablement inférieur au nombre de pixels d'une image, la complexité algorithmique de l'optimisation de la mesure de saillance est réduite de manière significative. Les temps de calculs sont ainsi considérablement réduits.

Les chaînes apportent des informations plus globales sur les contours, ce qui contribue à stabiliser d'autant plus les résultats du groupement. En particulier, le groupement par proximité des pixels d'une même chaîne permet d'éviter les phénomènes de "basculement" entre structures proches, constatés pour le groupement de pixels.

Enfin, le choix d'un voisinage variable permet d'adapter la densité du maillage établi entre les contours, ce qui permet de combler des discontinuités plus importantes que dans le cas de groupement de pixels.

Comme c'était le cas pour l'application au groupement de pixels, les extensions possibles au groupement de chaînes portent sur le type de voisinage et l'extraction finale des meilleures courbes. Dans chacun de ces exemples, la plus grande partie du temps de calcul est consacrée à la construction du voisinage. Bien que sa durée reste inférieure à 10 minutes (pour une image contenant environ chaînes 3000 chaînes), cette étape constitue un frein pour une application éventuelle sur des problèmes concrets.

Malgré ces limitations, le gain de temps obtenu pour le groupement de chaînes rend enfin possible l'utilisation des réseaux de saillance pour extraire rapidement les contours les plus réguliers dans des images de l'ordre de 500×500 pixels. Il en résulte un premier niveau de groupement perceptuel, répondant à des critères génériques de régularité, dont la fonction est d'attirer l'attention sur les contours les plus saillants.

Le produit de ce niveau préliminaire est un ensemble de chaînes saillantes. Ces chaînes sont considérablement moins nombreuses que le nombre d'éléments de contours initialement détectés. Elles représentent des fragments de contours, dont la somme couvre la majeure partie des structures linéaires de l'image. Ce sont les hypothèses à partir desquelles sont extraits les segments, arcs et points d'intérêt du niveau de groupement présenté au chapitre suivant.