

Chapitre 7

Conclusion

Au cours de cette thèse, nous avons abordé le problème de la perception de structures régulières à partir d'une détection de contours dans des images d'intensité lumineuse.

A partir d'une étude bibliographique de la perception visuelle, nous avons souligné les différentes sources d'ambiguïtés qui font de la vision par ordinateur un problème d'une extraordinaire complexité. En particulier, nous nous sommes intéressés aux problèmes que pose l'interprétation de scènes de contours ainsi qu'à différentes approches proposées en vision artificielle pour traiter ce type de scènes.

Le choix des contours comme support de notre travail est délibéré. Le propos n'est pas de réduire l'analyse d'images aux seuls contours. Ce choix doit être placé dans un contexte plus général d'un système de vision par ordinateur qui mettrait en commun les résultats d'analyse d'images selon divers indices visuels, dont les contours.

Enfin, nous avons étudié le rôle du groupement perceptuel pour réduire la complexité de cette tâche et nous avons conclu par la proposition d'une méthodologie de structuration progressive des contours. Afin de faire face aux nombreuses sources d'ambiguïté posées par la détection de contours avec un minimum d'hypothèses sur le type de scène observée, nous proposons une analyse qualitative des contours de l'image. L'utilisation de principes de groupement perceptuel permet de repousser le plus loin possible dans la chaîne de traitements l'intervention de méthodes d'analyse précises, plus sensibles aux erreurs de détection.

Une première phase détecte les structures curvilignes les plus régulières à l'aide de réseaux de saillances. Il s'agit de définir des critères de régularité pour des groupements possibles entre éléments de contour, de mettre en valeur les structures les plus régulières afin d'en extraire les principaux groupements. En plus d'apporter une approche générique pour ce type d'optimisation, notre contribution à ce niveau de traitement inclut un nouveau formalisme pour évaluer la régularité d'un groupement, un algorithme différent pour assurer la convergence du réseau vers des structures stables et un ensemble d'heuristiques pour l'extraction des meilleurs groupements après optimisation.

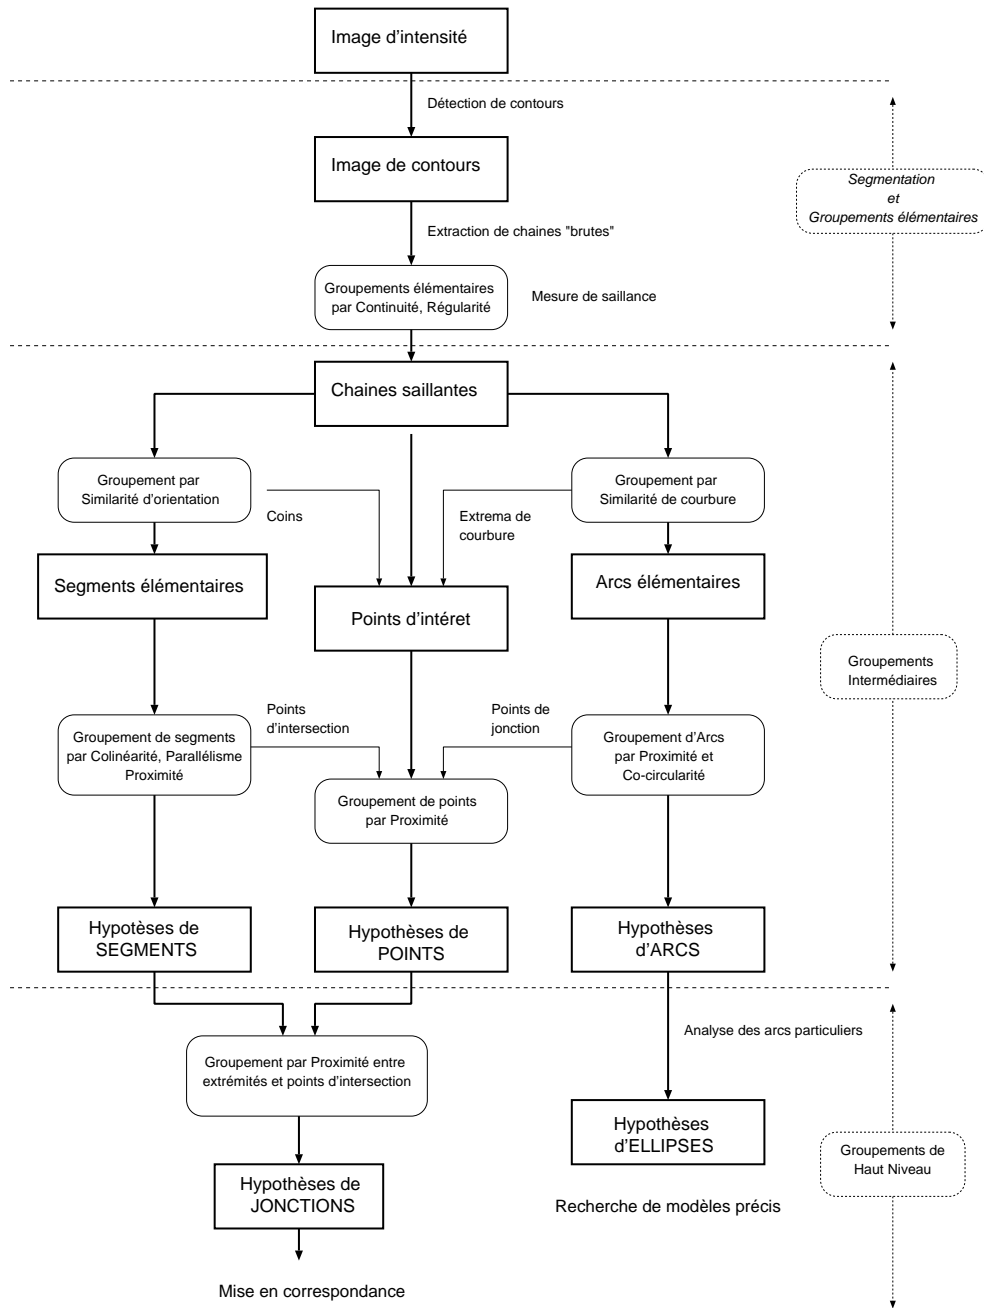


Figure 7.1 - Récapitulatif des trois niveaux d'organisation perceptuelle.

Les groupements saillants ainsi détectés jouent un rôle de centre d'attention pour l'extraction d'éléments visuels représentatifs des contours de l'image. Ils permettent ainsi de réduire la complexité en ne conservant que les hypothèses les plus régulières. Notre approche est hiérarchique et modulaire. Les éléments visuels sont extraits progressivement, sous forme d'hypothèses de groupements de plus en plus complexes.

Chaque niveau est ouvert aux contributions d'autres détections. Par exemple, le groupement par réseau de saillance peut être enrichi par la détection de frontières entre régions, dans la définition de la fonction de qualité ou encore lors de l'extraction des meilleurs groupements. De même, les hypothèses de points d'intérêts peuvent être complétées par une détection directe de coins si l'application le demande.

Le résultat de cette méthodologie est un ensemble d'éléments visuels représentatifs des structures curvilignes de l'image. L'utilisation de groupements selon des hypothèses de plus en plus complexes offre de nombreux avantages. En tolérant une certaine part de redondance, les hypothèses permettent l'interprétation de contours selon des échelles différentes. Elles apportent à la méthode une plus grande robustesse devant les discontinuités et les fausses détections. Elles peuvent être enfin utilisées directement au sein de structures plus complexes, comme nous l'avons montré avec la mise en correspondance de jonctions, ou bien servir de point de départ à une analyse plus précise par l'application de modèles déformables.

Nous avons enfin implanté chaque niveau de groupement en insistant sur l'application de notre méthode à de nombreuses images complexes (scènes artificielles, urbaines et naturelles), sur des plateformes usuelles¹. Par comparaison, la majorité des travaux antérieurs portent sur des types d'images particuliers ou bien nécessitent une mise en oeuvre sur des machines parallèles. En ce sens, notre approche est comparable, par sa généralité, aux démarches de [Mohan et Nevatia, 1992] et de [Sarkar et Boyer, 1994].

Malgré la qualité des résultats obtenus, un certain nombre de problèmes persistent. Un grand nombre de paramètres, propres à chaque phase de détection et de groupement, restent encore définis de manière empirique. En pratique, ces paramètres sont réutilisables pour une même classe d'images en produisant des résultats similaires. Nous avons privilégié l'étude qualitative d'ensemble du système à une étude quantitative en profondeur de chacune de ses composantes. Bien qu'il soit envisageable de confronter les résultats de manière automatisée avec des images de référence, ce dernier aspect pose en particulier le délicat problème d'une estimation quantitative de la qualité visuelle d'un groupement.

La sélection semi-automatique des structures saillantes offre un meilleur confort d'utilisation, en évitant à l'utilisateur de choisir manuellement les points de départ des chaînes saillantes. Elle suppose cependant une recherche manuelle des seuils de sélection. L'analyse des groupes saillants ne tient compte que d'un seul paramètre d'échelle, fixé par l'utilisateur. Il serait utile d'automatiser l'analyse à différentes

1. Les résultats d'analyse sont de l'ordre de 5 à 20 minutes, tous traitements compris, sur stations de travail SUN Sparc-10 et PC, pour des images de tailles inférieures à 800×600 pixels.

échelles, en recherchant les structures les plus stables et en définissant des critères de qualité pour les hypothèses.

Les ambiguïtés de la mise en correspondance de jonctions, encore trop nombreuses, pourraient être réduites en validant les hypothèses finales d'appariement à l'aide des voisinages de chaque jonction.

Enfin, la limitation la plus récurrente vient de l'implantation elle-même. Le grand nombre d'hypothèses entraîne des besoins en ressources mémoires encore trop importantes et limite les performances en temps de calculs. Une implantation plus efficace à l'aide de techniques adaptées à de grands nombres d'hypothèses, comme des méthodes d'indexation par exemple, pourrait résoudre ce problème.

Ces observations permettent de dégager deux axes de recherche principaux pour prolonger notre travail. Les hypothèses d'éléments visuels peuvent être validées et ajustées précisément en servant de point de départ à des méthodes précises selon un cycle de prédiction-vérification. A l'inverse, elles peuvent être directement groupées selon des règles plus complexes (parallélisme, symétrie, similarité, convexité) et formuler ainsi des hypothèses de plus en plus structurées.

A plus long terme, l'objectif d'un tel système est bien entendu une coopération avec d'autres processus d'analyse au sein d'une application plus vaste. Citons, à titre d'exemple, l'aide à l'indexation automatique de modèles. Les hypothèses géométriques produites par ce type d'approche pourrait s'insérer naturellement dans la construction de "modèles d'apparence" tels que les ont définis A. Pope et D. Lowe².

2. Cf. [Pope et Lowe, 1993] , page 74.

Annexes

Annexe A

Réseaux de saillance de Shashua et Ullman

Malgré des définitions très différentes, les mesures de saillance proposées dans la littérature ont en commun l'application des principes Gestaltistes de continuité et de "bonne forme". Elles tiennent compte, selon les cas, de mesures de courbure, de proximité, d'orientations ou encore de co-circularité. Elles se distinguent surtout par leur mécanisme de calcul, qui peut aller de l'optimisation combinatoire sous toutes ses formes à l'application directe d'un filtre adapté par convolution.

A.1 Mesures de saillance structurelle

On pourra également trouver dans [Williams et Thornber, 1997] une étude comparée de différentes mesures de saillance. Notons qu'une conséquence intéressante des mesures de saillance est la fermeture des discontinuités. Elles sont souvent appliquées à l'élaboration d'hypothèses sur la perception de contours fictifs.

A.1.1 Optimisation combinatoire

En théorie, une fois définie une fonction de qualité entre éléments de contours à grouper, toute méthode d'optimisation combinatoire adaptée aux problèmes NP-complets peut être envisagée.

- Recuit simulé et variantes - [Hérault, 1991]

Cette démarche constitue un exemple significatif de ce type d'approche. Le problème posé est le suivant :

“Etant donnés des points de contours dans l'image et connaissant le gradient en chaque point, quels sont les points par lesquels passent des courbes saillantes dans l'image ?”

Il s'agit donc de mesurer la saillance de points de contours sous forme d'une classification binaire entre les points des structures linéaires et les points de perturbations. Deux critères de sélection sont choisis pour évaluer l'appartenance possible de deux points de contours à une structure courbe.

- **La co-circularité** qui mesure la probabilité pour qu'un cercle passe par deux points et leurs tangentes associées. Ce critère tient compte de l'erreur de quantification sur la localisation des points et l'orientation des tangentes.

Formellement, deux points de contours i et j avec leurs tangentes associées T_i et T_j , sont sur un même cercle, si et seulement si :

$$\lambda_i + \lambda_j = \pi$$

où λ_i et λ_j désignent respectivement les angles formés par le segment S_{ij} et les tangentes T_i et T_j . Si on note: $\Delta_{ij} = |\lambda_i + \lambda_j - \pi|$, le coefficient de co-circularité est donné par :

$$c_{ij}^{cocirc} = \left(1 - \frac{\Delta_{ij}^2}{\Pi^2}\right) \cdot \exp\left(-\frac{\Delta_{ij}^2}{k}\right)$$

Le paramètre k est choisi de façon à ce que le coefficient de co-circularité décroisse rapidement pour des configurations non co-circulaires.

- **La proximité** qui permet de favoriser les interactions locales entre éléments de contours. En notant d_{ij} la distance entre les deux points, ce coefficient donne :

$$c_{ij}^{prox} = \exp\left(-\frac{d_{ij}^2}{2\sigma_d^2}\right)$$

où σ_d est l'écart type de la distribution des distances entre les tangentes.

Ces deux critères permettent de définir une énergie de co-circularité de la manière suivante. A chaque point i est associée une variable binaire x_i , qui vaut 1 si le point fait partie d'une structure courbe, et 0 s'il s'agit d'un point de bruit. Une structure aura une forte co-circularité globale si elle maximise sur les variables x_i la valeur suivante :

$$E_{cocirc} = \sum_{i=1}^N s_i \cdot x_i = \sum_{i=1}^N \left(\sum_{j=1}^N c_{ij}^{cocirc} \cdot c_{ij}^{prox} \cdot x_j \right) \cdot x_i$$

Le terme s_i mesure le degré de saillance de la tangente en i .

Afin d'éviter une solution triviale pour laquelle tous les x_i seraient égaux à 1, cette énergie est associée à une énergie de contrainte sur la taille de l'ensemble de points recherché :

$$E_{max} = \left(\sum_{i=1}^N x_i \right)^2$$

Le problème d'optimisation revient donc à minimiser, pour les variables x_i la quantité : $E = -(E_{cocirc} + \lambda \cdot E_{max})$, λ étant un paramètre positif ajusté expérimentalement.




Figure A.1 - Exemple de groupement perceptuel par recuit simulé. Sur les 1000 segments de départ, 352 ont été sélectionnés parmi les plus saillants. Exemple tiré de [Hérault et Horaud, 1992].

Ce problème est finalement codé sous la forme d'un réseau de neurones de Hopfield, puis optimisé en comparant différentes méthodes telles que l'approximation du champ moyen (inspirée d'un modèle physique de ferromagnétisme), le recuit simulé simple (inspiré d'un modèle thermique), et du recuit en champ moyen [Hérault et Horaud, 1992].

Cette approche est bien représentative de la construction d'une mesure de qualité, puis du codage et de l'optimisation de cette mesure. Elle donne des résultats intéressants sur images synthétiques et a été appliquée à des images réelles simples. Les structures saillantes sont bien conservées et une certaine quantité de bruit est éliminée. Le temps de calcul est, quand à lui, relativement long¹.

1. De l'ordre de 30 minutes à 3 heures sur un Cray pour un traitement sur 1000 segments, selon les méthodes d'optimisation.

Enfin, cette méthode se concentre uniquement sur une classification des éléments de contour en 'bruit' et 'forme', sans reconstituer les structures après détection. Héroult propose d'utiliser des processus de classification pour séparer les structures entre elles.

– Relaxation - [Parent et Zucker, 1989]

Par une méthode en deux étapes, Parent et Zucker soulignent l'importance d'une séparation entre des mesures locales nécessairement erronées et une détection des courbes par optimisation globale de critères visuels.

Un premier niveau de traitement établit une estimation grossière des tangentes présentes dans l'image. Cette estimation est réalisée à l'aide d'une convolution de l'image avec un ensemble de filtres linéaires selon des orientations prédéfinies. Ces opérateurs, semblables à des détecteurs de contours, mettent en valeur la présence de tangentes dans l'image.

Ces mesures étant dépendantes de mesures limitées à un voisinage relativement réduit, elles sont sensibles au bruit présent dans l'image de contours. Une seconde étape d'optimisation est donc nécessaire pour éliminer les fausses détections de tangentes et renforcer les orientations appartenant à courbes communes. Cette étape optimise, à l'aide d'un processus de relaxation, une mesure de saillance des tangentes.

Comme pour l'exemple précédent, cette mesure intègre des contraintes de proximité, de co-circularité et continuité de courbure. Ces contraintes sont définies dans un voisinage de chaque point de contour. Pour des raisons d'efficacité, ce voisinage décrit sept classes de courbures, correspondant à une discrétisation d'arcs de cercles tangents au contour.

Cette méthode ne se contente pas de séparer les points de bruit de ceux des courbes. En plus de mettre en valeur les structures courbes de l'image, elle produit un champ de tangentes et de courbures optimisées. Afin d'extraire les structures courbes de ces champs de tangentes, une méthode de chaînage est également proposée par les mêmes auteurs. En définissant un champ de potentiels à partir des tangentes, ce groupement de plus haut niveau procède par optimisation de contours actifs. Ces contours, initialisés le long des tangentes, convergent dans le champ de potentiel vers un ensemble de courbes saillantes. [Zucker *et al.*, 1989]

Les résultats sur des images artificielles et réelles sont nombreux et démontrent une robustesse en s'appliquant à différentes situations (images satellitaires, médicales et empreintes digitales). L'algorithme de détection des courbes est entièrement parallèle mais présente des temps de calculs très longs².

2. Jusqu'à 12 heures sur un DEC VAX 11/780

A.1.2 Mesures 'directes'

L'un des principaux reproches faits aux méthodes précédentes est leur incompatibilité avec l'expérience biologique de la perception visuelle. En effet, la convergence itérative vers une solution approchée est un modèle peu satisfaisant pour un mécanisme aussi immédiat que la perception de contours saillants dont les temps de réponse sont de l'ordre de la centaine de milli-secondes. Ces observations suggèrent des méthodes plus directes dont les exemples suivants sont représentatifs.

- Champs d'extensions - [Guy et Medioni, 1996]

Cette mesure de saillance est définie comme la somme de compromis entre les réponses de filtres directionnels appliqués aux éléments de contours de l'image. Ces filtres, qu'ils nomment "champs d'extensions" (*extension fields*) représentent la probabilité de relier l'extrémité d'une courbe incomplète à partir du point d'application. Ils tiennent compte à la fois de la tangente au point de contour et de la forme globale de la courbe, en définissant la contribution de ce point pour ses voisins en termes de longueur et d'orientation.




Figure A.2 - Aspect d'un champ d'extension. La figure (a) représente la distribution des orientations autour d'un élément de contour. La figure (b) représente la variation de l'amplitude du champ en fonction de la distance et de l'orientation. Exemple tiré de [Guy et Medioni, 1996].

Une forme analytique de ce type de champ peut être définie par :

$$\overline{EF}(x, y) = \begin{cases} e^{-Ax^2} (1, 0)^T & , y = 0 \\ (e^{(-Ax^2 + B \cdot \arctan(|y|, |x|)^2)} (\frac{x}{R}, \frac{y}{R} - 1)^T & , y \neq 0 \end{cases}$$

avec :

$$R(x, y) = \frac{(x^2 + y^2)}{2y}$$

Le paramètre A contrôle l'atténuation due à la distance et B contrôle l'atténuation due au changement de courbure. Ces paramètres permettent d'influer sur la forme du champ. Celle-ci est donc une fonction qui décroît exponentiellement selon la distance et le rayon de l'arc circulaire défini à partir de l'origine. Le choix de la forme du champ permet de détecter différents types de structures (jonctions ou courbes). Par construction, les champs d'extension intègrent des contraintes de co-circularité, de continuité de courbure, et de proximité.

L'optimisation sur l'ensemble des points de contours de l'image est mise en oeuvre par une technique semblable à la transformée de Hough. Chaque point de contour p reçoit des votes de la part de tous les autres points dont le champ d'extension traverse p . Chaque vote est un vecteur, défini par une intensité et une orientation. Appliqué à tous les autres points, ce processus est comparable à une convolution entre les points de l'image et un masque défini par le champs d'extension. A la seule différence que le résultat de la convolution n'est pas un scalaire mais un vecteur.

Après application de tous les votes, chaque point de contour est le site d'une accumulation de vecteurs dont il suffit d'extraire les directions privilégiées. L'analyse statistique des moments de ce système de vecteurs permet de définir en chaque point une ellipse dont les axes correspondent aux directions des moments principaux. Si on note λ_{min} et λ_{max} les valeurs propres de la matrice de co-variance correspondant à ces moments, une mesure de la saillance d'un point de contour peut être définie par la simple différence $(\lambda_{max} - \lambda_{min})$. Sans entrer dans les détails, λ_{max} est fonction croissante du nombre de votes accumulés sur un site et λ_{min} est d'autant plus faible que les vecteurs accumulés sur ce site ont une direction proche.

Le résultat de cette méthode est à la fois une carte d'éléments orientés, et une mesure de la saillance des points de contours. Cette approche permet ainsi de définir une mesure de saillance globale, chaque point recevant une contribution de la part de tous les autres. Par opposition, les méthodes d'optimisation combinatoire cherchent à optimiser globalement des mesures locales.

Les résultats sur des images synthétiques et quelques images réelles montrent une bonne mise en valeur des structures globales ainsi que des applications possibles pour la détection de jonctions et la fermeture de contours fictifs. Les auteurs suggèrent une extraction possible des structures saillantes en suivant les crêtes de la carte de saillance et ses vecteurs associés. Ils restent cependant peu clairs sur le traitement des intersections entre courbes ainsi que sur les zones de saillance homogène.

– Champs stochastiques de fermeture - [Williams et Jacobs, 1994]

Cet autre exemple de mesure directe de saillance peut être vu comme une approche rigoureuse, d'un point de vue statistique, des idées avancées par

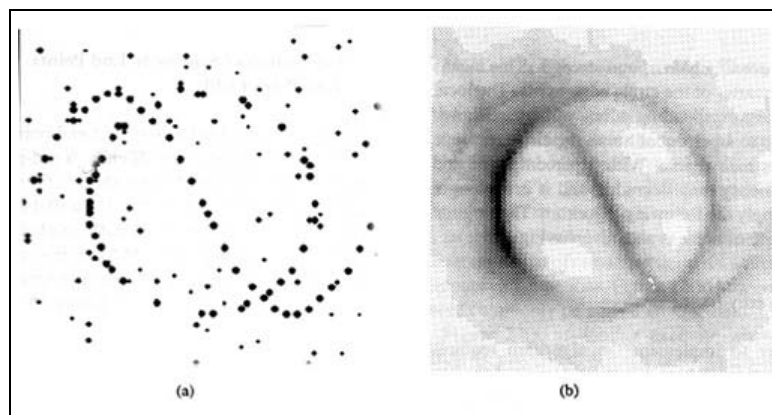


Figure A.3 - Exemple de carte de saillance obtenue à l'aide de champs d'extension. L'intensité est d'autant plus faible que la saillance des points est plus grande. (a) Image d'origine. (b) Carte de saillance. Exemple tiré de [Guy et Medioni, 1996].

Guy et Medioni. Tout comme la mesure précédente, celle-ci définit un champ de vecteurs autour de chaque point de contour.

Désigné par “Champ stochastique de fermeture” ou *Stochastic Completion Fields*, ce champ représente une distribution de tous les chemins possibles partant d'un point selon une direction initiale. Cette distribution est modélisée par un mouvement de particules selon certaines contraintes de position, d'orientation et vitesse (mouvements Browniens).




Figure A.4 - Exemple de champ stochastique de fermeture. La figure de droite représente le mouvement aléatoire d'une particule. La figure de gauche montre la distribution des trajectoires d'un ensemble de particules. Exemple tiré de [Williams et Jacobs, 1994].

Dans ce cas, la saillance d'un élément de contour p est la probabilité qu'une particule passe par p en suivant un mouvement stochastique reliant deux autres

éléments de contours.

La généralisation de cette mesure sur l'ensemble des éléments de contours est ici aussi un produit de convolution entre champs de vecteurs. Elle revient à chercher les courbes d'énergie minimale parmi les distributions stochastiques de tous les chemins possibles. Pour des raisons d'efficacité, ces distributions sont pré-calculées sur un ensemble de positions et orientations.

[Thornber et Williams, 1997] ont proposé depuis une variante de cette mesure en considérant une somme de mouvements stochastiques sur des chemins reliant plusieurs éléments de contours entre eux. Par comparaison, la mesure précédente se concentre sur un seul mouvement de particule entre deux éléments de contours. La saillance est définie alors par la fraction de chemins stochastiques fermés passant par un élément de contours donné.

Dans les deux cas, l'application privilégiée est la fermeture de contours, et la perception de contours illusoires. Les résultats sont particulièrement intéressants sur les contours illusoires, de part leur similarité avec les observations psycho-visuelles sur ces mêmes contours. Ils restent cependant limités à des images artificielles.

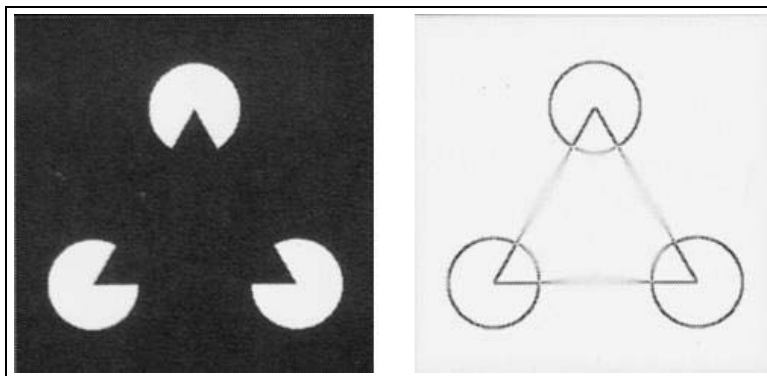


Figure A.5 - *Résultat de fermeture de contours fictifs par application de champs stochastiques. Exemple tiré de [Williams et Jacobs, 1994].*

A.2 Réseaux de Saillance de Shashua et Ullman

Les réseaux de saillances, tels que définis par [Shashua et Ullman, 1988] offrent un formalisme original pour l'optimisation globale d'une mesure de saillance à partir de calculs locaux. Afin de faciliter la comparaison avec notre propre approche, nous présentons les réseaux de saillance de Shashua avec un formalisme semblable à celui du chapitre 4.

A.2.1 Définitions et notations

Comme la plupart des autres mesures de saillance, celle-ci concerne le groupement de pixels de contours selon des courbes visuellement importantes tout en éliminant les pixels de bruit. Elle s'applique donc à une image de détection de contours.

Soit un pixel P de cette image. Son intensité vaut 1 s'il s'agit d'un point de contour et 0 sinon.

L'image est considérée comme un réseau de pixels inter-connectés. Chaque pixel P est relié à k voisins notés N_i , $i \in [0, k]$. Ce voisinage, noté $\mathcal{V}(P)$, définit ainsi k éléments d'orientations v_i . Ces éléments sont dits "réels" si le voisin relié est un point de contours, et "virtuels" sinon. Ce réseau peut être vu comme un graphe pour lequel les pixels sont les noeuds et les éléments d'orientation les arcs.

Soit $\Gamma_N(P, v, \bar{v})$ une courbe de $2N$ éléments traversant P . Cette courbe arrive en P par la direction d'un élément \bar{v} et en repart dans la direction de $v \neq \bar{v}$. On note $\gamma_N(P, v)$ la branche de cette courbe composée des éléments de connexion $\{e_1, e_2, \dots, e_N\}$, et $\gamma_N(P, \bar{v})$ la branche composée des éléments de connexion $\{e_{-1}, e_{-2}, \dots, e_{-N}\}$.

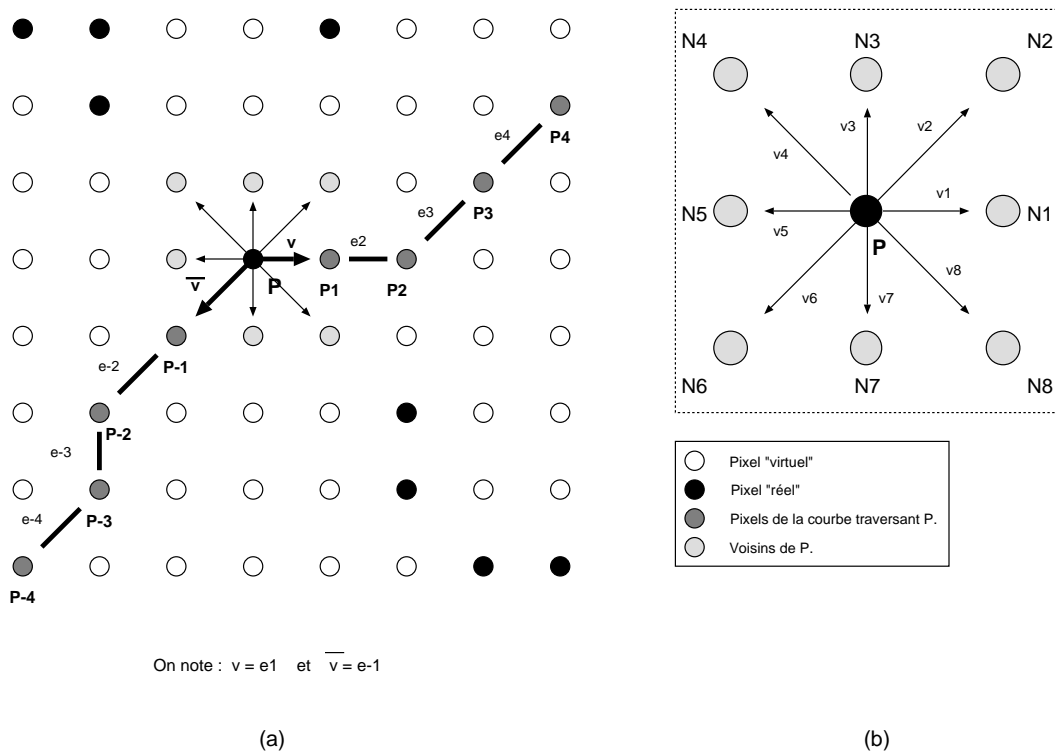


Figure A.6 - (a) Notations pour une courbe traversant un pixel P - (b) Exemple de voisinage en 8 connexité. Dans cet exemple, $e_1 = v_1$ et $e_{-1} = v_6$.

Comme le montre la figure A.6, les éléments e_1 et e_{-1} sont définis par : $e_1 = v$ et $e_{-1} = \bar{v}$.

On parlera par la suite indifféremment de groupements et de courbes.

A.2.2 Mesure de saillance

Shashua et Ullman définissent une mesure de saillance qui doit favoriser la formation de courbes longues et uniformes, répondant à des critères visuels. Cette mesure doit de plus se conformer à l'algorithme d'optimisation choisi.

Dans un premier temps, ils dérivent une fonction de qualité à partir de critères de courbures et de longueurs. Ces critères doivent récompenser les courbes lisses, présentant peu de discontinuités. Cette fonction de qualité est ensuite exprimée sous une forme adaptée à la méthode d'optimisation.

Ils distinguent de plus deux types de saillances. D'une part, la saillance d'un élément d'orientation v est définie comme la valeur maximale des qualités des courbes partant de P dans la direction de v . L'ensemble des courbes possibles de longueur N partant de P dans la direction de v est noté $\delta^N(v)$. On peut remarquer que $\delta^1(v)$, noté $\delta(v)$, correspond aux éléments voisins du pixel P_v , à l'exception de l'élément v .

D'autre part, la saillance d'un pixel est définie comme la valeur maximale des saillances des courbes traversant ce pixel. C'est cette valeur qui est utilisée pour constituer une carte de saillance de l'image.

A.2.2.1 Fonction de qualité

Cette fonction étant définie pour une courbe $\Gamma_N(P, v, \bar{v})$, chaque terme de saillance est exprimé pour un seul des deux brins, $\gamma_N(P, v)$.

Longueur

Le terme de longueur représente la contribution des éléments e_j , $j \in [1, N]$ à la saillance de la courbe. Cette contribution est d'autant plus faible que le nombre d'éléments virtuels entre le départ de la courbe et e_j est grand. Soit $\rho_{1,j}$ la contribution individuelle de chaque e_j .

$$\rho_{1,j} = \rho^{g_{1,j}}, \quad \text{avec } \rho < 1$$

Le nombre d'éléments virtuels entre e_1 et e_j est noté $g_{1,j}$.

Le terme de longueur est défini par la somme :

$$\sum_{j=1}^N \sigma_j \cdot \rho_{1,j}$$

avec :

$$\sigma_j = \begin{cases} 1, & \text{si } e_j \text{ est réel} \\ 0, & \text{si } e_j \text{ est virtuel} \end{cases}$$

Le facteur σ_j assure que seuls les éléments réels apportent une contribution à la saillance de la courbe.

Courbure

Le terme de courbure accumule les contributions de courbure locale entre éléments consécutifs depuis le début de la courbe. Dans sa forme continue, ce terme est défini par :

$$\mathcal{C}_{1,j} = e^{-\int_{e_1}^{e_j} \kappa^2(s) ds}$$

où $\kappa(s) = \left(\frac{d\theta}{ds}\right)$ est la courbure à l'abscisse curviligne s le long de la courbe. Cette mesure est bornée, et inversement liée à la courbure de la courbe. Elle vaut en effet 1 pour une ligne droite et décroît vers 0 lorsque la courbure globale tend vers l'infini.




Figure A.7 - Estimation de la courbure entre deux éléments de connexion consécutifs e_k et e_{k+1} .

La courbure peut être évaluée de manière discrète entre deux éléments consécutifs e_k et e_{k+1}

$$K_{k,k+1} = \frac{2\theta_k \tan \frac{\theta_k}{2}}{\Delta s}$$

On note $\theta_k = \widehat{e_k, e_{k+1}}$ la différence d'orientation entre les deux éléments et Δs la longueur totale des deux éléments.

L'approximation de la courbure totale le long des éléments e_1, e_2, \dots, e_{j-1} est donnée par :

$$C_{1,j} = \prod_{k=1}^{j-1} f(e_k, e_{k+1}) = \exp^{-\sum_{k=1}^{j-1} K_{k,k+1}} \quad (\text{A.1})$$

avec :

$$f(e_k, e_{k+1}) = e^{-K_{k,k+1}}$$

La fonction $f(e_k, e_{k+1})$ est, par construction, un ensemble de constantes d'appariement entre deux éléments d'orientation consécutifs. Ces constantes peuvent être évaluées au préalable à partir des combinaisons possibles entre éléments d'orientation.

La fonction de qualité de $\gamma_N(P, v)$ est définie par la somme des contributions locales σ_j de chaque élément, pondérées par la saillance de chaque élément en termes de longueur et de courbure :

$$\mathcal{F}(\gamma_N(P, v)) = \sum_{j=1}^N \sigma_j \cdot \rho_{1,j} \cdot C_{1,j} \quad (\text{A.2})$$

Cette définition assure à la fonction de qualité une croissance monotone en fonction de la longueur des groupements et une décroissance monotone en fonction de son énergie (terme de courbure). Elle pénalise la présence de discontinuités (éléments virtuels) ainsi que les courbes trop sinueuses.

A.2.2.2 Forme récursive et fonctions extensibles

L'originalité de la méthode de Shashua et Ullman est d'exprimer la mesure de saillance sous une forme récursive. Ainsi, pour des courbes de longueur N partant dans la direction de l'élément v , la saillance φ_N de cet élément est fonction de la qualité des courbes de longueur $(N - 1)$ partant de chacun de ses éléments voisins (figure A.8).

$$\varphi_N(v) = \mathbf{Max}_{e_k \in \delta(v)} F(P, v, \varphi_{N-1}(e_k))$$

La fonction F est définie à partir de φ_{N-1} et de constantes représentant la saillance propre des pixels P et P_v . On peut considérer que $\varphi_{N-1}(e_k)$ représente la contribution de l'élément e_k pour la saillance du pixel P .

Afin de calculer cette valeur maximale sans avoir à parcourir exhaustivement l'ensemble des courbes possibles partant de P dans la direction de v , Shashua et Ullman définissent une certaine classe de fonctions, dites *fonctions extensibles*, par la propriété suivante.




Figure A.8 - L'élément d'orientation relie les pixels P et P_v . La saillance du meilleur chemin de longueur N partant du pixel P dans la direction de v , est une fonction de la saillance du meilleur chemin de longueur $N - 1$ partant du pixel P_v dans la direction de $e_k \in \delta(v)$.

Définition : Une fonction $\psi_N(\cdot)$, définie sur N valeurs $e_i, e_{i+1}, \dots, e_{i+N}$ est dite *extensible* si elle vérifie la relation :

$$\mathbf{Max}_{\delta^N(e_i)} \psi_N(e_i, e_{i+1}, \dots, e_{i+N}) = \mathbf{Max}_{\delta(e_i)} \psi_1(e_i, \mathbf{Max}_{\delta^{N-1}(e_{i+1})} \psi_{N-1}(e_{i+1}, \dots, e_{i+N})) \quad (\text{A.3})$$

Cette définition, empruntée à la programmation dynamique [Montanari, 1971], permet de réduire l'espace de recherche pour une courbe de longueur N partant de v à $(k-1) \cdot N$ possibilités au lieu de $(k-1)^N$. Rappelons que $(k-1)$ est le nombre d'orientations possibles autour de l'élément v à partir d'un pixel P . Ce type de fonction assure une construction récursive de courbes optimales autour de chaque pixel.

La fonction F est définie sous la forme suivante :

$$F(P, v, \varphi_{N-1}(e_k)) = \sigma_v + \rho_v \cdot C_{1,k} \cdot \varphi_{N-1}(e_k)$$

Ce qui donne, par récursivité :

$$\varphi_N(v) = \sigma_v + \rho_v \mathbf{Max}_{e_k \in \delta(v)} \{f(v, e_k) \varphi_{N-1}(e_k)\}$$

Définie ainsi, $\varphi_N(v)$ représente bien la meilleure saillance parmi les courbes possibles partant de P dans la direction de v .

On peut définir de même la saillance $\varphi_N(\bar{v})$ du brin opposé. La mesure de saillance à optimiser est donc la somme de ces deux mesures latérales.

$$\Phi N(v, \bar{v}) = \varphi_N(v) + \varphi_N(\bar{v})$$

Cette forme récursive ne demande que des calculs locaux à chaque pixel. L'aspect global intervient dans la contribution de chaque voisin au calcul de la valeur de saillance.

A.2.3 Optimisation récursive

Soit un pixel P et les éléments d'orientation qui en dépendent. On associe à chaque élément v une variable d'état $S_v^{(n)}$. Cette variable représente la saillance de la meilleure courbe de longueur n partant de P dans la direction v .

La variable d'état est initialisée par la saillance locale de l'élément v :

$$S_v^{(0)} = \sigma_v$$

En reprenant l'expression récursive de la mesure de saillance, la valeur de $S_i^{(n)}$ est mise à jour, pour chaque nouvelle itération. Cette mise à jour revient à établir la paire d'éléments (v, e_k) , $e_k \in \delta(v)$ qui maximise l'état de v

$$S_v^{(n+1)} = \sigma_v + \rho_v \cdot \mathbf{Max}_{e_k \in \delta(v)} \{f(v, e_k) S_{e_k}^{(n)}\} \quad (\text{A.4})$$

L'élément e_k choisi est celui qui contribue le plus à l'état de v pour une itération donnée.

Enfin, une courbe traversant P par les directions v et \bar{v} , donne à ce pixel la saillance :

$$\Phi^{(n+1)}(\gamma_{n+1}(P, v)) = S_v^{(n+1)} + \bar{S}_{\bar{v}}^{(n+1)}$$

Au long de l'optimisation, les éléments présents le long d'une structure courbe reçoivent des contributions fortes dans la direction des tangentes à la courbe. A l'inverse, les éléments isolés reçoivent des contributions d'autant plus faibles que le nombre d'éléments virtuels de leur voisinage est important.

En fin d'optimisation, la saillance de chaque pixel P est la valeur maximale des mesures de saillance des courbes traversant P , soit :

$$\mathcal{S}(P) = \mathbf{Max}_{v_i \in \mathcal{V}(P)} \Phi(\Gamma(P, v_i, \bar{v}_i)) \quad (\text{A.5})$$

Shashua et Ullman apportent la preuve de la convergence de ce type de fonction par un raisonnement sur une courbe fermée. En pratique, le nombre d'itérations dépend de la longueur maximale de discontinuités à remplir. Il faut n itérations pour que deux éléments séparés par n autres puissent contribuer à leurs états mutuels.

A.2.4 Extraction des structures saillantes

De la même manière que pour la mesure directe de Guy et Medioni, cette méthode offre la propriété intéressante d'établir, en plus d'une carte de saillance, une carte de connectivité entre pixels. Les groupements optimaux peuvent être reconstitués en suivant, de proche en proche, les paires d'éléments définies au cours de l'optimisation.

Un pixel, servant de point de départ pour un groupement, définit deux directions privilégiées selon la paire d'éléments de son voisinage qui présente la plus forte

saillance. Le suivi des paires d'éléments, dans chaque direction, permet ainsi de combler les discontinuités. Plusieurs conditions d'arrêt au suivi sont envisageables, comme par exemple la présence d'un cycle ou bien la sortie des limites de l'image.

L'optimisation assure l'existence d'une courbe optimale passant par chaque pixel de l'image. L'ensemble des groupements possibles dans l'image est donc réduit à une seule courbe par pixel. En pratique, les pixels de contours présentant une forte saillance constituent des points de départ suffisants pour la reconstitution des groupements.

Malgré une réduction considérable de l'espace de recherche, l'optimisation par réseau de saillance ne résout pas le problème de l'extraction de groupements significatifs à partir de leur réseau de saillance. En effet, les pixels situés le long d'une structure courbe sont autant de points de départ pour des groupements de saillance semblable. Il en est de même pour tout point de bruit immédiatement voisin d'un contour saillant.

Dans [Shashua et Ullman, 1991], les auteurs apportent un début de solution en recherchant des groupements optimaux sous la forme d'un ensemble de parcours disjoints dans le réseau d'éléments connectés. Ils démontrent en particulier comment obtenir cette partition en choisissant soigneusement les paires de voisins définies autour de chaque pixel.

En optimisant la saillance sur toutes les courbes possibles traversant chaque point, l'étape précédente définit des paires d'éléments pour des courbes non nécessairement disjointes. Un second niveau d'optimisation est donc nécessaire pour ajuster ces paires de manière à former des groupes disjoints. Ce niveau reprend le même mécanisme d'optimisation en ne changeant que le choix des paires d'éléments et la formule de mise à jour de l'état des éléments.

Une variable d'état $F_v^{(0)}$ est initialisée pour chaque élément d'orientation :

$$F_v^{(0)} = \sigma_v$$

La valeur de cet état est mise à jour en définissant, localement à chaque pixel, une partition de $\frac{k}{2}$ paires d'éléments dans son voisinage. Les paires sont constituées par ordre décroissant sur les saillances déjà calculées à l'étape n .

Notons $\delta^*(v)$ l'ensemble des voisins de l'élément v qui n'ont pas été appariés. On choisit alors l'élément $e_k \in \delta^*(v)$ tel que :

$$f(v, e_k)F_{e_k}^{(n)} = \mathbf{Max}_{e_j \in \delta^*(v)} \{f(v, e_j)F_{e_j}^{(n)}\}$$

La contribution pour la mise à jour est alors :

$$F_v^{(n+1)} = \sigma_v + \rho_v \cdot \{f(v, e_k)F_{e_k}^{(n)}\}$$

avec (v, e_k) paire disjointe au voisinage de P .

Ce mécanisme est reproduit jusqu'à ce que les nouvelles saillances $F_v^{(n)}$ soient suffisamment proches des saillances optimales $S_v^{(n)}$ calculées préalablement.




Figure A.9 - Exemple de carte de saillance et d'extraction du meilleur groupement à partir d'un cercle bruité. Exemple tiré de [Alter et Basri, 1996].

Cette méthode simple permet de construire dynamiquement les groupes optimaux de l'image. Elle permet également de propager les décisions d'appariement le long de courbes de saillance optimale et d'influencer les décisions d'appariement à l'itération suivante. Si elle donne des résultats satisfaisants en pratique, Shashua et Ullman admettent toutefois qu'elle ne garantit pas une convergence vers une solution optimale.

A.2.5 Discussion

La méthode proposée par Shashua et Ullman est intéressante et originale à plusieurs points de vues.

Le réseau de saillance réduit la complexité du problème de groupement à une optimisation rapide de mesures locales propagées globalement. Sa complexité algorithmique ne dépend que du nombre d'arcs et de sommets constituant le réseau. Dans le cas présent, pour une image de $n \times m$ pixels et un voisinage de k éléments autour de chaque pixel, cette complexité est de l'ordre de $\mathcal{O}(n \cdot m \cdot k^2)$ par itération.

L'optimisation d'une mesure de saillance dense sur l'image, à la fois sur les éléments de contours et les éléments virtuels, permet de fermer les discontinuités des contours. Une conséquence intéressante de cette optimisation est la détection, en chaque point de l'image, de directions privilégiées issues de contributions globales des éléments environnants. Ces directions permettent de guider la reconstitution de groupements par simple suivi de proche en proche.

Il est intéressant de remarquer ici que le résultat de cette optimisation est très proche de celui obtenu avec la mesure globale de Guy et Medioni. En plus d'une valeur de saillance structurelle, chaque point de l'image se retrouve associé à un ensemble de vecteurs, correspondant aux influences des points environnants. La principale différence entre les deux méthodes réside dans la discrétisation des orientations d'influence et le mode de calcul de celles-ci. L'approche de Guy et Medioni demande un vote de la part de tous les pixels, alors que l'optimisation de Shashua et Ullman ne tient compte que de calculs locaux propagés globalement.

A.2.5.1 Applications des réseaux de saillance

Les réseaux de saillance ont fait l'objet de plusieurs extensions et applications, à commencer par Shashua et Ullman. Ceux-ci suggèrent en effet l'extension de la méthode à d'autres fonctions de qualité, en particulier une mesure de saillance reposant sur une différence de courbure.

$$H_v^{(n+1)} = \sigma_v + \rho_v \cdot \mathbf{Max}_{e_k \in \delta(v)} \{ \ell(v, e_k, e_l) H_{e_k}^{(n)} \}$$

La fonction $l(v, e_k, e_l)$ est similaire à $f(v, e_k)$ à ceci près que l'angle θ_k est ici une différence sur trois orientations successives. La comparaison des deux mesures donne des résultats similaires.

Ils proposent également de lisser les groupements en cours d'optimisation en ajustant la position des sommets du réseau. On pourra se reporter à [Shashua, 1988] pour plus de détails sur la méthode et ses applications.

Parmi les applications des réseaux de saillance à d'autres types de problèmes, on peut citer [Subirana-Vilanova et Sung, 1992] avec une extension de la méthode à la définition de squelettes de régions saillantes et [Merlet et Zerubia, 1996] avec une approche semblable adaptée à la recherche de structures courbes sur des images satellites.

A.2.5.2 Problèmes non résolus et remarques

La robustesse des réseaux de saillance et leur simplicité font de cette méthode une bonne approche pour notre premier niveau de groupements. Malgré leurs nombreux avantages, les réseaux de saillance présentent un certain nombre de problèmes qui peuvent en limiter l'utilisation. On pourra trouver dans [Alter et Basri, 1996] une étude quantitative et qualitative des réseaux de saillance. Cette étude concerne en particulier leur stabilité et complexité.

C'est en apportant une réponse à chacun de ces problèmes que nous avons abouti à la méthodologie de groupement par réseau de saillance qui fait l'objet du chapitre 4. Notre contribution à ce type de groupement porte en particulier sur un nouveau formalisme pour la fonction de qualité, une différente procédure d'optimisation et enfin, une heuristique pour l'extraction des groupes les plus importants après optimisation.

Choix du voisinage

Les réseaux de saillance sont définis, à l'origine, à partir de pixels interconnectés. Le choix de la forme du voisinage de ces pixels et le nombre d'éléments d'orientation par voisinage est déterminant pour assurer des groupements suffisamment précis. Ainsi, un voisinage trop petit ne pourra pas garantir une reconstruction fidèle des courbes de l'image. À l'inverse, un voisinage trop grand pèse lourdement sur la complexité de l'optimisation. Chaque pixel

doit en effet garder en mémoire l'état des k éléments d'orientations de son voisinage. Un voisinage trop important entraîne des besoins de mémoire tels qu'il rend la méthode inapplicable pour des images de taille importante.

Ces problèmes de complexité peuvent être réduits de manière significative en généralisant cette méthode d'optimisation à un réseau de chaînes de pixels connectées par leurs extrémités et dotées d'un voisinage dynamique afin de ne conserver que les connexions utiles au groupement.

Mesure de saillance structurelle

La mesure de saillance dépend uniquement de termes de longueur et de courbure, critères géométriques qui se montrent insuffisants dans de nombreuses situations. De nombreuses ambiguïtés apparaissent en particulier lorsque les éléments de contours sont répartis uniformément, ou bien forment des zones de bruit relativement denses par rapport aux structures saillantes. L'ajout de critères de co-circularité ou d'orientation des tangentes permet un contrôle plus important sur le type de courbes détectées.

De plus, la conjugaison des termes de courbure et de longueur au sein d'une même contribution rend difficile l'évaluation de l'influence de chacun de ces termes sur la fonction de qualité. L'un des effets indésirables de ce type de fonction est d'accélérer la convergence sur des structures localement saillantes et de ralentir de manière trop importante sur des structures plus globales. D'autre part, la multiplication des contributions par le facteur σ_i dans la fonction de qualité interdit toute distinction entre éléments de contours lorsque ceux-ci sont virtuels. Ainsi, deux éléments de connexion virtuels auront la même contribution, nulle, quel que soit leur courbure locale. Multiplier le terme de courbure par σ_i revient à ignorer la courbure des éléments virtuels et accorde une saillance forte à des groupements irréguliers (figure A.10).

L'utilisation d'une fonction de qualité additive, inspirée du formalisme des contours actifs, nous permet de mieux contrôler l'influence de chaque terme de saillance sur la mesure finale.

Reconstitution des groupements

La méthode originale de Shashua et Ullman donne des résultats intéressants dans le cas d'une seule structure saillante dans un environnement bruité. Les auteurs présentent peu de résultats sur le groupement après optimisation, en particulier sur des images réelles.

De nombreux problèmes apparaissent lorsque cette méthode est appliquée à des scènes contenant plusieurs structures d'intérêt. Le suivi des meilleures connexions n'est pas suffisant pour extraire des structures cohérentes depuis les contours de la scène. En particulier, le suivi d'un groupement optimisé peut aisément "sauter" d'une structure à l'autre en cas de jonctions, d'occlusions

ou bien de structures saillantes parallèles (figure A.11). Cette méthode est donc plus adaptée à la détection de “la” meilleure structure.




Figure A.10 - *En cas d'éléments de connexion virtuels, la courbure locale ne doit pas être ignorée. En multipliant les termes de saillance, les éléments virtuels e_1 et e_2 apportent ici une contribution nulle ($\sigma_1 = \sigma_2 = 0$) en P alors que pour Γ , Γ_2 est d'évidence un meilleur groupement que Γ_1 .*

L'application d'un second niveau d'optimisation pour extraire un ensemble de groupements disjoints ne répond qu'en partie aux problèmes de suivi. La méthode proposée impose des contraintes trop fortes sur les groupements, surtout autour d'intersections entre courbes. Une sélection automatique des groupes les plus représentatifs tenant compte de ces nombreux problèmes reste encore à définir.

Enfin, cette méthode présente un certain nombre d'incohérences avec des expériences psycho-visuelles qu'il serait bon de rectifier. La mesure de saillance est, par exemple, trop sensible à la taille et la répartition des discontinuités sur une courbe. Un cercle fragmenté régulièrement peut obtenir une saillance inférieure à un incomplet mais continu. Un autre exemple est donné par l'importance trop grande des contributions de voisinage. Des pixels de bruit proches d'un contour peuvent obtenir une saillance importante du fait de la proximité d'une structure linéaire.

Nous proposons enfin des critères de sélection des meilleurs groupements en




Figure A.11 - *Des structures linéaires rendent difficile le groupement par simple suivi des meilleurs éléments de connexion. Comme le montre cet exemple sur une image d'empreinte digitale, le parcours du graphe de connexions bascule indifféremment d'une structure à l'autre.*

fonction de leur qualité globale et de leur point de départ. Ces critères permettent une plus grande discrimination entre les structures réellement saillantes et les groupements bénéficiant de ces effets indésirables.

Chacun de ces aspects est exposé d'une manière plus détaillée dans le chapitre 4, consacré à la définition d'un formalisme générique pour les réseaux de saillance et son application au groupement de pixels et de chaînes de pixels.

Annexe B

Résultats complémentaires




Figure B.1 - Pièce industrielle - Cette scène est intéressante car elle présente des structures rectilignes et courbes à différentes tailles. La texture de la pièce et l'atténuation de l'arrière plan introduisent de plus de nombreuses perturbations - Photographie © Projet Syntim, INRIA.




Figure B.2 - *Détection de contours par filtre de Deriche - $\alpha = 1$ - 1408 chaînes élémentaires.*




Figure B.3 - *351 chaînes sélectionnées automatiquement après optimisation du réseau de saillance sur les chaînes de contours. Ces chaînes correspondent à 34 groupes saillants.*




Figure B.4 - *Détection de segments avant groupement - 489 segments - Seuil de découpage récursif $\epsilon^v = 3$*




Figure B.5 - *Après groupement - 239 segments*




Figure B.6 - *Détection de segments avant groupement - 282 segments - Seuil de découpage récursif $\epsilon^v = 11$*




Figure B.7 - *Après groupement - 161 segments*




Figure B.8 - *Détection d'arcs - 281 arcs élémentaires - Echelle de lissage $\alpha = 0,5$*




Figure B.9 - *Groupement de 80 paires d'arcs co-circulaires*




Figure B.10 - *Détection d'arcs - 220 arcs élémentaires - Echelle de lissage $\alpha = 0,125$*




Figure B.11 - *Groupement de 95 paires d'arcs co-circulaires*




Figure B.12 - *Détection d'arcs - 175 arcs élémentaires - Echelle de lissage $\alpha = 0,07$*




Figure B.13 - *Groupement de 97 paires d'arcs co-circulaires*




Figure B.14 - *Analyse des arcs élémentaires - détection de 87 arcs d'ellipse -
Echelle de lissage $\alpha = 0,5$*




Figure B.15 - *Les arcs les plus longs forment 7 hypothèses d'ellipses.*




Figure B.16 - *Préliminaire à la construction des hypothèses de jonctions. Détection et groupement de segments - 169 segments extraits à partir de 29 groupements sur 351 chaînes - Seuil de découpage récursif $\epsilon^{\vee} = 5$.*




Figure B.17 - *Détection de 744 jonctions élémentaires à partir de 169 segments.*




Figure B.18 - *Simplification des hypothèses de jonctions - 224 jonctions après groupement.*

Liste des figures

0.1	Marché d'esclaves avec buste invisible de Voltaire - Salvador Dali . . .	1
1.1	Illustration de la <i>Gestaltqualität</i> - cet arrangement de flèches noires représente quelque chose de plus que la somme de quatre flèches. . .	13
1.2	Cube de Necker et figures impossibles de Oscar Reutersvärd	16
1.3	Dalmatien - Exemple de séparation d'un objet familier avec un arrière plan complexe.	16
1.4	Influence de stimuli inconscients - Photo de Richard Gicewicz	17
1.5	Illusions géométriques - Dans chaque cas, les segments A et B ont la même longueur. De même, les cercles intérieurs ont le même rayon. . .	18
1.6	La présence d'un gradient de texture est un indice immédiatement utilisable concernant l'orientation de la surface. L'exemple (a) semble s'éloigner alors que (b) semble parallèle à l'observateur.	19
1.7	Exemple de modification apparente de la fréquence spatiale par le système visuel. Dans l'exemple de gauche, les disques ont la même orientation verticale - l'orientation de l'arrière plan semble dévier les disques dans le sens opposé. Dans le cas de droite, les disques ont la même fréquence spatiale - celui du haut paraît pourtant avoir une fréquence spatiale plus élevée.	21
1.8	Deux stéréo-grammes de points aléatoires. La superposition des deux images, à l'aide d'un stéréoscope par exemple, fait apparaître la forme d'un carré dont la profondeur est différente du reste de l'image.	25
2.1	Exemple de système visuel - tiré de "3D Mosaic Scene Understanding System" - Herman M. et Kanade, T. - 1986	40
2.2	Deux exemples de surfaces extraites à partir de l'illumination de la scène (<i>shape from shading</i>).	43
2.3	Déduction de la profondeur à partir de la disparité entre une paire stéréoscopique - ici, un stéréogramme.	44
2.4	Les contours permettent souvent d'interpréter les objets d'une scène et sa structure 3D.	48

2.5	Exemples simples d'étiquetage dans une scène de blocs et d'origami. Les (+) désignent des arêtes convexes les (-) des arêtes concaves. Les arêtes étiquetées par un \rightarrow signalent la présence de matière derrière la facette. Les flèches transversales désignent le cas particulier d'ombres.	49
2.6	Exemple de détection de contours	50
2.7	Ambiguïtés de projection (a) et d'occlusion (b).	51
2.8	Exemples classiques de contours d'intensité 1D - (a) marche, (b) rampe, (c) porte, (d) crête. La courbe en pointillés représente l'allure d'un contour réel, bruité.	53
2.9	Détection de contours par application du filtre de Canny	56
2.10	Détection de contours par application du filtre de Deriche.	56
2.11	Détection précise de coins - convergence d'un modèle de coin vers une position optimale (à droite) - Méthode de Blaszkza et Deriche.	59
2.12	Détection de réseaux fins sur une image satellitaire. Un paramètre d'échelle σ permet de définir la largeur maximale des structures détectées. Ici, $\sigma = 1$. - Méthode de Armande, Monga et Montesinos.	60
2.13	Comparaison entre une détection de contours avec filtre de Deriche (image de gauche) et l'extraction des frontières entre régions (image de droite).	61
2.14	Figures de Kanizsa - les "formes" fictives apparaissent d'une intensité plus grande que le fond.	62
2.15	Structuration de contours après détection - deux niveaux d'application.	63
2.16	Ambiguïtés entre segments et arcs en géométrie discrète	66
2.17	Modélisation de scène par représentation en fil de fer et par frontières. Le modèle "fil de fer" présente trop d'ambiguïtés pour représenter correctement la profondeur.	68
2.18	Graphes de caractéristiques visuelles construits lors de l'apprentissage du modèle - (a) segments et arcs, (b) jonctions, (c) groupes de segments, (d) segments parallèles.	73
2.19	Reconnaissance de l'objet malgré d'importantes oclusions - Méthode de Pope et Lowe, 1993	73
3.1	Séparation entre "figure" et "fond". La figure de gauche représente-t-elle un disque blanc sur un triangle noir? ou bien un triangle percé d'un cercle? La figure de droite représente-t-elle un vase noir ou bien deux visages blancs?	77
3.2	Les motifs de Marroquin révèlent le côté dynamique et continu des processus de groupements perceptuels.	78
3.3	Groupement par proximité - Toute chose égale par ailleurs, les éléments visuels de cette figure sont groupés par lignes ou par colonnes selon leurs distances respectives.	79

3.4	Groupement par continuité - Les figures distinctes de l'exemple (a) s'effacent au profit de figures plus continues dans l'exemple (b). Il est ainsi difficile de voir dans (b) autre chose qu'un cercle complet et un carré complet qui se superposent.	79
3.5	Groupement par symétrie - L'exemple (a) montre l'importance de la symétrie dans l'apparition de formes saillantes. L'exemple (b) montre comment l'importance de la proximité est atténuée par l'existence de symétries.	80
3.6	Groupement par fermeture	81
3.7	Groupement par contexte et par familiarité - Selon le sens de lecture, les éléments visuels "1" et "3" sont groupés pour former une lettre ou bien séparés pour former un nombre. L'autre figure représente une ambiguïté entre un groupe de personnes et un visage. Le visage est d'autant mieux perçu que son modèle, un buste célèbre de Voltaire, est connu des observateurs.	81
3.8	Le sens du mot "SYMETRIE" disparaît devant l'influence du groupement par continuité et par symétrie.	82
3.9	Principe de simplicité - En l'absence d'autres indices, la figure de gauche apparaît comme la projection 2D d'un cube 3D alors que celle de droite apparaît comme un motif uniquement 2D.	82
3.10	Triangle de Penrose. L'impression d'un "Tout" cohérent apparaît bien avant de remarquer que cette figure est physiquement impossible. La structure de chaque sommet, observée indépendamment des autres, est cohérente localement. L'agencement de chaque sommet est cohérent deux à deux, ce qui renforce l'illusion. L'instabilité de la figure est pourtant secondaire devant l'illusion d'un objet unique, et n'intervient que lorsqu'on interprète la figure plus en détail.	83
3.11	Extraction d'éléments de représentation par groupement perceptuel hiérarchique. Comparaison avec l'approche classique de structuration de contours.	96
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.	102
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.	103
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.	104

-
- 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. 109
- 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 ($n = 0$). 113
- 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. 113
- 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. 113
- 4.8 Exemples de groupements individuels - Image d'intensité et détection de contours. 114
- 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. 114
- 4.10 Allure de la fonction de "crédibilité" pour les éléments d'un groupement de longueur n 116
- 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. 117
- 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. 117
- 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. 118

-
- 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. 119
- 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. 120
- 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). 123
- 4.17 Notations pour l'estimation de la co-circularité entre trois éléments de connexions e_{k-1} , e_k et e_{k+1} 125
- 4.18 Notations pour le terme d'orientation entre deux éléments e_j et e_{j+1} . 126
- 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 $f(v, e_j) < 0.05$ 128
- 4.20 Détection des lignes de crête d'un fragment d'image satellite infrarouge. 130
- 4.21 Exemples de "boucles" indésirables en fin de suivi, après groupement des pixels de lignes de crête. 130
- 4.22 Ellipse 80×80 pixels avec 5% de bruit. Image d'intensité et évaluation des orientations locales. 133
- 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. 133
- 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 $\alpha_k = 0.9$ 133
- 4.25 Optimisation du réseau avec les termes de courbure et d'intensité: $\alpha_c = 0.6$, $\alpha_k = 0$, $\alpha_g = 0.9$, $\alpha_o = 0$ 134
- 4.26 Optimisation du réseau avec les termes de courbure, d'intensité et de co-circularité: $\alpha_c = 0.6$, $\alpha_k = 0.2$, $\alpha_g = 0.9$, $\alpha_o = 0$ 134
- 4.27 Optimisation du réseau avec tous les termes: $\alpha_c = 0.6$, $\alpha_k = 0.2$, $\alpha_g = 0.9$, $\alpha_o = 0.2$ 134
- 4.28 Ellipse 80×80 pixels avec 5% de bruit - 30 itérations (30 sec / itération) 135
- 4.29 Ellipse 80×80 pixels avec 10% de bruit - 25 itérations (30 sec / itération) 135
- 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. 135
- 4.31 Cercle et ellipse 256×256 pixels, avec bruit gaussien 136

4.32	Détection de contours - Cercle ($RSB = 5.8db$) et Ellipse ($RSB = 7.6db$)	
		136
4.33	Groupement - 10 itérations (1 min / itération)	136
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.	137
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.	137
4.36	Image SPOT 256×256 pixels - Détection de réseau fin	139
4.37	Détection de routes - Extraction de 16 groupements saillants - 18 itérations (40 sec / itération)	139
4.38	Angiographie du cerveau 400×400 pixels - Détection de réseau fin .	140
4.39	Extraction d'un réseau de 50 groupements - 30 itérations (2 min / itération)	140
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 $(C, \bar{v}, C_{-1}, e_{-2})$	142
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 $\mathcal{V}(C)$	143
4.42	Test de compatibilité entre une chaîne C_0 et un voisin possible C_1 . Ici, le test est négatif car $\lambda_{1,0} > \lambda_{seuil}$	145
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	146
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	147
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".	149
4.46	Mesures de longueurs et d'orientation entre deux chaînes et leur connexion.	150
4.47	Chaines de départ	154
4.48	Graphe de connexions et Sélection automatique des 4 meilleurs groupes	154
4.49	Cercle avec bruit directionnel - segments orientés aléatoirement . . .	155
4.50	Superposition de 11 groupements, après seuillage selon les trois critères de sélection.	155

4.51	Image SPOT 256 × 256 pixels - Détection de réseau fin - 344 chaînes	157
4.52	Détection de routes - Extraction de 9 groupements saillants - 50 itérations (0,3 sec / itération)	157
4.53	Cathédrale 360 × 460 pixels - Détection de contours	158
4.54	165 chaînes saillantes sur 2397 chaînes - 50 itérations (0,8 sec / itération)	158
4.55	Téléphone 500 × 328 pixels - Détection de contours	159
4.56	310 chaînes saillantes sur 2780 chaînes - 50 itérations (0,8 sec / itération)	159
5.1	Principes du niveau intermédiaire de groupements. Le but est d'analyser les chaînes saillantes afin d'en extraire des hypothèses élémentaires de segments, d'arcs et de points d'intérêt. Ces hypothèses sont ensuite simplifiées par groupement.	163
5.2	Initialisation du découpage récursif d'une chaîne de pixels. Après détection du point le plus éloigné de la droite Δ , l'opération est répétée à gauche et à droite du point de coupure jusqu'à ce l'écart maximal entre la chaîne et chaque segment soit inférieur à un seuil donné.	166
5.3	Scène de test et détection de contours.	168
5.4	Détection de segments pour les écarts $\epsilon^{\vee} = 1$ et $\epsilon^{\vee} = 11$. Les segments ont été extraits de la seule chaîne saillante issue du groupement élémentaire.	168
5.5	Critère de colinéarité et d'alignement entre deux segments.	170
5.6	Critère de proximité entre deux segments.	171
5.7	L'approximation des segments au sens des moindres carrés, et le groupement de segments par proximité introduisent des erreurs de localisation pour les extrémités des segments.	172
5.8	Energies d'intersection entre deux segments. Elles déterminent si la rectification de l'un ou l'autre segment doit avoir lieu, et si oui, dans quelle proportion.	173
5.9	Groupement de segments pour les écarts $\epsilon^{\vee} = 1$ et $\epsilon^{\vee} = 4$	177
5.10	Groupement de segments pour les écarts $\epsilon^{\vee} = 8$ et $\epsilon^{\vee} = 11$	177
5.11	Pièce en bois	178
5.12	Détection de contours et sélection des meilleurs groupes - 452 chaînes - 14 groupes	178
5.13	Groupement - 36 segments - $\epsilon^{\vee} = 1$	179
5.14	Groupement - 34 segments - $\epsilon^{\vee} = 3$	179
5.15	Groupement - 27 segments - $\epsilon^{\vee} = 11$	179
5.16	Téléphone	180
5.17	Détection de contours et sélection des meilleurs groupes - 560 chaînes - 23 groupes	180
5.18	Avant groupement - 179 segments - $\epsilon^{\vee} = 3$	181
5.19	Après groupement - 102 segments	181

5.20	Avant groupement - 132 segments - $\epsilon^{\vee} = 6$	182
5.21	Après groupement - 92 segments	182
5.22	Téléphone “bruité” - Détection de contours - 2780 Chaînes	183
5.23	Sélection des meilleurs groupes - Chaînes couvertes par 29 groupes	183
5.24	Approximation polygonale à partir des contours - 1311 segments - $\epsilon^{\vee} = 3$	184
5.25	130 segments après détection et groupement - $\epsilon^{\vee} = 3$. Cet exemple permet de comparer le résultat d’une détection de segments classique (par approximation polygonale des contours) avec les hypothèses de segments issues des structures saillantes.	184
5.26	Huit arcs élémentaires	186
5.27	La figure de droite représente l’estimation de la courbure d’une chaîne (figure de gauche) pour les échelles $\alpha = 0.2$ (en gris) et $\alpha = 0.09$ (en noir).	188
5.28	Segmentation de cercles - rayons 40 et 100 pixels - $\alpha = 0,125$	191
5.29	Segmentation d’ellipse inclinées - $\alpha = 0,125$. Le point supplémentaire sur l’ellipse de gauche vient du point de départ de la chaîne de contour.	191
5.30	Ellipses droites de tailles variables - $\alpha = 0,125$. Comme pour la figure précédente, les erreurs de localisation des points de la partie gauche des ellipses viennent du choix de point de départ sur chaque chaîne de contour.	192
5.31	Courbe quelconque - $\alpha = 0,2$. Les arcs en “gris” ont été classifiés en tant que segments rectilignes (classe LS).	192
5.32	Huit groupements élémentaires	194
5.33	Arcs élémentaires - $\alpha = 0,125$	197
5.34	Paires d’arcs co-circulaires et groupements.	197
5.35	Arcs élémentaires sur une courbe quelconque - $\alpha = 0,2$	198
5.36	Paires d’arcs co-circulaires	198
5.37	Téléphone - 105 arcs élémentaires - $\alpha = 0,15$	199
5.38	Téléphone - 90 arcs élémentaires - $\alpha = 0,07$	199
6.1	Principes des niveaux supérieurs de groupement. Les éléments visuels extraits par les niveaux inférieurs sont soit manipulés directement sous la forme de structures plus complexes (mise en correspondance structurelle), soit utilisés comme centre d’attention pour valider des hypothèses de manière plus précise (prédiction et vérification d’hypothèses).	208
6.2	Notations utilisées pour une intersection entre deux segments. Une marge d’erreur permet de définir des jonctions “réelles” et “virtuel- les”. Ici, la jonction entre S_1 et S_2 est virtuelle.	209
6.3	Catalogue des différentes classes de jonctions élémentaires entre deux segments.	211
6.4	Stabilité du groupement de jonctions en rotation - $\theta = 0$ et $\theta = \frac{\pi}{6}$	214

6.5	Stabilité du groupement de jonctions en rotation - $\theta = \frac{2\pi}{6}$ et $\theta = \frac{\pi}{2}$	214
6.6	Scène de bureau	215
6.7	Scène de bureau - Détection et groupement de segments - 144 segments extraits à partir de 54 groupements sur 440 chaînes (note : les discontinuités des segments en blanc sont dues à un défaut d'impression).	215
6.8	Scène de bureau - Détection de 718 jonctions doubles	216
6.9	Scène de bureau - Groupement de jonctions - restent 229 jonctions groupées	216
6.10	Téléphone - Détection et groupement de segments - 101 segments extraits à partir de 22 groupements sur 550 chaînes	217
6.11	Téléphone - Détection de 482 jonctions doubles	218
6.12	Téléphone - Groupement de jonctions - restent 101 jonctions groupées	218
6.13	Voisinages <i>Temporels</i> et <i>Perceptuels</i> pour une jonction J .	219
6.14	Le voisinage perceptuel d'une jonction J est constitué des jonctions dont le centre se trouve aligné avec l'une des branches de J .	221
6.15	Incohérence dans les voisinages perceptuels d'une jonction J et d'un correspondant possible L . Dans cette situation, le déplacement de Lv_1 par rapport à L est cohérent avec celui de Jv_1 et de J . La jonction Lv_2 se comporte de manière incohérente - elle doit donc être retirée du voisinage de L .	222
6.16	Exemple de différences de groupement d'une même jonction dans deux images différentes. La mesure de similarité doit être suffisamment tolérante pour accepter ce genre de distorsion.	223
6.17	Alignement de deux jonctions par rapport à une direction de référence commune. Les jonctions sont initialement exprimées par rapport à l'axe horizontal (repère de l'image). La partie en gris signale la zone de comparaison entre les deux jonctions.	224
6.18	Similarité entre une jonction J et quatre candidats J_1 à J_4 . Les directions de référence sont les branches marquées d'une flèche. Dans chaque cas, la zone de comparaison est signalée en gris. Les jonctions sont classées par ordre décroissant de similarité.	226
6.19	Configuration entre deux jonctions J_1 et J_2 . Chaque jonction est alignée avec le vecteur $J_1 \rightarrow J_2$. Les zones de comparaison sont ici encore signalées en gris.	227
6.20	Comparaison entre hypothèses d'appariements. En supposant que Lv_1 est apparié avec Jv_1 , dans quelle mesure peut on considérer que J est associé à L ?	230
6.21	Comparaison entre hypothèses de groupements. En supposant que L est groupée avec L_1 , dans quelle mesure peut on considérer que J est groupée à Jv_1 ?	232
6.22	Appariement simple - rectangles	234

6.23	Appariement simple - rectangles - appariements	234
6.24	Appariement simple - rectangles - vecteurs de déplacement	234
6.25	Appariement complexe - maison	235
6.26	Appariement complexe - maison - détection de contours	235
6.27	Appariement complexe - maison. On peut noter l'appariement correct de la jonction 13 dans les deux images, malgré les différences d'orientation des branches. Les jonctions virtuelles 9 et 11 sont superposées dans l'image de droite.	236
6.28	Appariement complexe - maison - vecteurs de déplacement	236
6.29	Appariement de jonctions - cube	237
6.30	Appariement de jonctions - cube - détection de contours	237
6.31	Appariement de jonctions - cube - hypothèses de segments après groupement	237
6.32	Appariement de jonctions - cube. On peut noter l'appariement correct de la jonction 10 malgré le passage de 3 à 2 branches d'une scène à l'autre. Les jonctions 1 et 3 sont superposées dans l'image de droite. La jonction 6 est une jonction virtuelle.	238
6.33	Appariement de jonctions - cube - vecteurs de déplacement	238
7.1	Récapitulatif des trois niveaux d'organisation perceptuelle.	242
A.1	Exemple de groupement perceptuel par recuit simulé. Sur les 1000 segments de départ, 352 ont été sélectionnés parmi les plus saillants. Exemple tiré de [Hérault et Horaud, 1992].	249
A.2	Aspect d'un champ d'extension. La figure (a) représente la distribution des orientations autour d'un élément de contour. La figure (b) représente la variation de l'amplitude du champ en fonction de la distance et de l'orientation. Exemple tiré de [Guy et Medioni, 1996].	251
A.3	Exemple de carte de saillance obtenue à l'aide de champs d'extension. L'intensité est d'autant plus faible que la saillance des points est plus grande. (a) Image d'origine. (b) Carte de saillance. Exemple tiré de [Guy et Medioni, 1996].	253
A.4	Exemple de champ stochastique de fermeture. La figure de droite représente le mouvement aléatoire d'une particule. La figure de gauche montre la distribution des trajectoires d'un ensemble de particules. Exemple tiré de [Williams et Jacobs, 1994].	253
A.5	Résultat de fermeture de contours fictifs par application de champs stochastiques. Exemple tiré de [Williams et Jacobs, 1994].	254
A.6	(a) Notations pour une courbe traversant un pixel P - (b) Exemple de voisinage en 8 connexité. Dans cet exemple, $e_1 = v_1$ et $e_{-1} = v_6$	255
A.7	Estimation de la courbure entre deux éléments de connexion consécutifs e_k et e_{k+1}	257

- A.8 L'élément d'orientation relie les pixels P et P_v . La saillance du meilleur chemin de longueur N partant du pixel P dans la direction de v , est une fonction de la saillance du meilleur chemin de longueur $N - 1$ partant du pixel P_v dans la direction de $e_k \in \delta(v)$ 259
- A.9 Exemple de carte de saillance et d'extraction du meilleur groupement à partir d'un cercle bruité. Exemple tiré de [Alter et Basri, 1996]. . . 262
- A.10 En cas d'éléments de connexion virtuels, la courbure locale ne doit pas être ignorée. En multipliant les termes de saillance, les éléments virtuels e_1 et e_2 apportent ici une contribution nulle ($\sigma_1 = \sigma_2 = 0$) en P alors que pour Γ_1, Γ_2 est d'évidence un meilleur groupement que Γ_1 265
- A.11 Des structures linéaires rendent difficile le groupement par simple suivi des meilleurs éléments de connexion. Comme le montre cet exemple sur une image d'empreinte digitale, le parcours du graphe de connexions bascule indifféremment d'une structure à l'autre. . . . 266
- B.1 Pièce industrielle - Cette scène est intéressante car elle présente des structures rectilignes et courbes à différentes tailles. La texture de la pièce et l'atténuation de l'arrière plan introduisent de plus de nombreuses perturbations - Photographie © Projet Syntim, INRIA. . . . 267
- B.2 Détection de contours par filtre de Deriche - $\alpha = 1$ - 1408 chaînes élémentaires. 268
- B.3 351 chaînes sélectionnées automatiquement après optimisation du réseau de saillance sur les chaînes de contours. Ces chaînes correspondent à 34 groupes saillants. 268
- B.4 Détection de segments avant groupement - 489 segments - Seuil de découpage récursif $\epsilon^\vee = 3$ 269
- B.5 Après groupement - 239 segments 269
- B.6 Détection de segments avant groupement - 282 segments - Seuil de découpage récursif $\epsilon^\vee = 11$ 270
- B.7 Après groupement - 161 segments 270
- B.8 Détection d'arcs - 281 arcs élémentaires - Echelle de lissage $\alpha = 0,5$. 271
- B.9 Groupement de 80 paires d'arcs co-circulaires 271
- B.10 Détection d'arcs - 220 arcs élémentaires - Echelle de lissage $\alpha = 0,125$ 272
- B.11 Groupement de 95 paires d'arcs co-circulaires 272
- B.12 Détection d'arcs - 175 arcs élémentaires - Echelle de lissage $\alpha = 0,07$ 273
- B.13 Groupement de 97 paires d'arcs co-circulaires 273
- B.14 Analyse des arcs élémentaires - détection de 87 arcs d'ellipse - Echelle de lissage $\alpha = 0,5$ 274
- B.15 Les arcs les plus longs forment 7 hypothèses d'ellipses. 274
- B.16 Préliminaire à la construction des hypothèses de jonctions. Détection et groupement de segments - 169 segments extraits à partir de 29 groupements sur 351 chaînes - Seuil de découpage récursif $\epsilon^\vee = 5$. . . 275

B.17 Détection de 744 jonctions élémentaires à partir de 169 segments. . .	276
B.18 Simplification des hypothèses de jonctions - 224 jonctions après grou- pement.	276

Liste des tableaux

- 1.1 Comparaison entre les paradigmes “reconstructifs” et “intentionnels”,
d’après Y. Aloimonos (1990) 29

- 5.1 Propriétés de variations des fonctions d’une courbe. M^+ et M^- définissent respectivement une croissance et une décroissance monotone. On note c une valeur constante et N/A une valeur non définie. . . . 187
- 5.2 Propriétés de variations des fonctions d’une courbe. Max^+ et Min^- définissent respectivement un extremum positif et un extremum négatif. 189

Liste des Algorithmes

4.1	Optimisation de réseau de saillance	109
4.2	Appariement et mise à jour des valeurs de saillance	112
4.3	Préparation d'un réseau de saillance de chaînes	147
5.1	Rectification des intersections	174
6.1	Coopération entre Groupement Perceptuel et Mise en Correspondance - algorithme principal	221
6.2	Relaxation temporelle	230
6.3	Relaxation perceptuelle	232

