

Ondelettes pour la détection de caractéristiques en traitement d'images

Applications à la détection de régions d'intérêt

C. Damerval

Laboratoire Jean Kuntzmann, Grenoble

7 mai 2008



Directeurs : S. Meignen et C. Schmid

Plan

- 1 Détection de régions d'intérêt en vision par ordinateur
- 2 Rappels sur les lignes de maxima
- 3 Applications à la détection de structures remarquables

Mots clés : ondelettes, *Scale-Space*, représentations multiéchelles, lignes de maxima, invariance ou robustesse à des transformations de l'image, détection de régions d'intérêt, calcul de grandeurs caractéristiques.

Problèmes en vision par ordinateur

Appariement d'images

- Savoir si deux images correspondent à une même scène
- Calcul de déformations géométriques




Source : LEAR, Inria Rhône-Alpes

Problèmes en vision par ordinateur

Reconnaissance d'objets

- Identifier une entité particulière dans une image
- Décider si une image correspond à tel ou tel modèle d'objet




Source : U. Leuven / Pascal Database

Problèmes en vision par ordinateur

Méthodologie

- Détection de structures remarquables : mise en évidence de régions d'intérêt
- Calcul de descripteurs : description quantitative du contenu de ces régions
- Utilisation de ceux-ci dans les applications comme primitives de plus haut niveau



Exemples de régions d'intérêt

Invariance, robustesse

Dans les applications, il est nécessaire que les caractéristiques extraites (descripteurs) soient invariantes ou robustes vis à vis de certaines transformations de l'image :

- géométriques : changement d'échelle, déformations affines
- ajout de bruit, changement d'illumination ou de contraste
- Caractère essentiel de l'étape de détection
- Extraction de caractéristiques locales prenant en compte les déformations géométriques (Lindeberg'98, Schmid'04)
- Performance des détecteurs évaluée grâce à la notion de répétabilité

Approche issue du Scale-Space (Lindeberg)

- Théorie du *Scale-Space* (Witkin'83, Lindeberg'94)
- Image f , noyau Gaussien isotrope $G_t(x, y) = \frac{1}{2\pi t^2} \exp\left(-\frac{x^2+y^2}{2t}\right)$
- Représentation espace-échelle linéaire de f (dans $\mathbb{R}^2 \times \mathbb{R}_+^*$)

$$L(x, y, t) = f * G_t$$

- Utilisation d'un opérateur défini à partir des dérivées de L , comme

$$\Delta L = \partial_{xx} L + \partial_{yy} L$$

Approche issue du Scale-Space (Lindeberg)


- Introduction d'une normalisation : $t^\gamma \Delta L$, $\gamma > 0$
- Sélection de maxima locaux en espace et en échelle :

$$(x, y, t) \mapsto t^\gamma \Delta L(x, y, t)$$


- Pour un maximum local de $t^\gamma \Delta L$ en (x^*, y^*, t^*) , région d'intérêt associée : cercle centré en (x^*, y^*) de rayon $s^* = \sqrt{t^*}$

Approche issue du Scale-Space (Lindeberg)

- Intérêt de cette approche : adéquation entre la région d'intérêt et un objet présent dans l'image

Gaussienne 2D G_{σ_1}

$$s_1^* \propto \sigma_1$$


Gaussienne 2D G_{σ_2}

$$s_2^* \propto \sigma_2$$

- s^* : échelle caractéristique (lien avec la notion d'invariance)
- Ici, dans le cas de l'opérateur $t^\gamma \Delta L$, les structures de l'image associées à de tels maxima sont appelées *blobs*

Approche issue du Scale-Space (Lindeberg)

Détection de blobs : maxima en espace et en échelle de ΔL
(code issu de l'équipe LEAR, Inria Rhône-Alpes)



Problème de caractérisation des objets : nature des objets détectés ?

Approche proposée dans cette thèse

Objectif : recherche de structures remarquables dans une image

- Points de contours (structures 1D)
- Structures 2D associées à des régions d'intérêt telles que des objets de type blob, délimités par des singularités
- Pour une même scène, les objets détectés ne doivent pas dépendre des conditions d'observation (notion de caractéristique)

Outil : lignes de maxima associées à des décompositions en ondelettes

- Détection de points de contours et caractérisation par la régularité associée
- Mise en évidence d'objets de type blob et calcul de grandeurs caractéristiques associées


- 1 Détection de régions d'intérêt en vision par ordinateur
- 2 Rappels sur les lignes de maxima
 - Cadre 1D
 - Cadre 2D
- 3 Applications à la détection de structures remarquables
 - Transformée en ondelette d'un signal (1D), d'une image (2D)
 - Lignes de maxima associées (Mallat)
 - Construction numérique de lignes de maxima

Notion d'ondelette


- Ondelette : fonction $\psi : \mathbb{R} \longrightarrow \mathbb{R}$, $\psi \in L^2$, vérifiant la condition

$$C_\psi = \int_0^\infty \frac{|\hat{\psi}(\omega)|^2}{\omega} d\omega < \infty$$


- Propriétés de régularité, support compact, décroissance rapide, ...



Ondelette
de Haar



Dérivée première
de Gaussienne




Ondelette Sombrero


Transformée en Ondelette Continue (TOC)

TOC normalisée L^1 de $f : \mathbb{R} \rightarrow \mathbb{R}$ ($f \in L^2$) utilisant l'ondelette ψ

$$Wf(u, s) = \frac{1}{s} \int_{\mathbb{R}} f(t) \psi \left(\frac{t - u}{s} \right) dt \quad \forall u \in \mathbb{R}, \forall s > 0$$



Signal




TOC
(ondelette Sombrero)

Modules Maxima de la TOC (Mallat)

Module maximum : point de l'espace-échelle (u_0, s_0) tel que $u \mapsto |Wf(u, s_0)|$ est localement maximum en $u = u_0$

- MM associés à des singularités (discontinuités, maxima locaux de la courbure, ...)
- Notion de Maxima Line : pour certaines ondelettes, les MM se propagent vers les échelles fines (Hummel, Poggio, Yuille)



Ensemble des ML

Transformée en ondelette et régularité Lipschitzienne

- $f : \mathbb{R} \rightarrow \mathbb{R}$ α -Lipschitz en t_0 ($\alpha \in]0, 1[$)

$$|f(t) - f(t_0)| \leq K|t - t_0|^\alpha \quad \forall t \in \mathbb{R}$$

- Propriété de la TOC d'une fonction α -Lipschitz (Arneodo, Jaffard)

$$|Wf(u, s)| \leq As^\alpha \quad \forall u \in \mathbb{R}, \forall s > 0$$

Estimation de la régularité Lipschitzienne par ondelettes

Différentes approches quant à la régularité Lipschitzienne α

- Etude de la répartition globale des régularités
Applications à l'étude de signaux multifractaux (Arneodo'98)
- Estimation en certains points singuliers, par régression linéaire aux fines échelles le long de Maxima Lines
Applications : détection et caractérisation de singularités (Mallat'92)

Lignes de maxima en 2D

- A chaque échelle s , maxima dans l'espace \mathbb{R}^2 (en un certain sens)
- Pour certains types de maxima, propriété de persistance à mesure que l'échelle diminue
- Courbes connexes de l'espace-échelle $\mathbb{R}^2 \times \mathbb{R}_+^*$ appelées lignes de maxima : $(x(s), y(s))_{s>0}$


Cadre 2D, différentes lignes

- Maxima Lines, associées aux modules maxima d'une TOC 2D
- Lignes de Canny, permettant de suivre des points de contour en fonction de l'échelle


Transformée en ondelette continue 2D

- Ondelette 2D $\Psi : \mathbb{R}^2 \rightarrow \mathbb{R}$, image d'intensité $f : \mathbb{R}^2 \rightarrow \mathbb{R}$
- TOC 2D (normalisée L^1)


$$Wf(x, y, s) = \frac{1}{s^2} \int_{\mathbb{R}^2} f(u, v) \Psi \left(\frac{u-x}{s}, \frac{v-y}{s} \right) dudv$$



Ondelette ΔG



Image



TOC 2D

Notion de Maxima Line en 2D

- Maxima Line (ML) : courbe connexe formée de modules maxima d'une TOC 2D

$$ML : (x(s), y(s), s, Wf(x(s), y(s), s))$$

où pour tout $s > 0$, $(x(s), y(s))$ est un maximum local de $|Wf(., ., s)|$


- Pour l'ondelette ΔG , existence de ML se prolongeant jusqu'aux échelles les plus fines (principe du maximum)
- Propriété de conservation des ML, sous l'effet d'une déformation affine ou d'un changement d'échelle

Construction numérique des Maxima Lines en 2D


- A chaque échelle, calcul d'une TOC et détermination des MM
- Règles de chaînage d'une échelle à une autre
- Construction numérique en $N \log(N)$ (N : taille des données)



Image *Barbara*



Echelle fine



Echelle intermédiaire

Notion de ligne de Canny

- Singularités spécifiques au cadre 2D : points de contour
- Maxima au sens de Canny (MC) : lieux où, suivant la direction du gradient, le module du gradient est localement maximum
- Formulation multiéchelles (Mallat)

Gradient $\nabla(f * \Lambda_s)$ où Λ_s est un noyau de lissage 2D

Module du gradient $Mf(x, y, s)$ et orientation de celui-ci $Af(x, y, s)$

- Ligne de Canny : courbe connexe formée de MC

$$LC : (x(s), y(s), s, Mf, Af)$$


- Résultat empirique, construction des lignes

Construction numérique des lignes de Canny


- Règles de chaînage conduisant à des lignes de Canny (LC)
- Construction numérique en $N \log(N)$ (N : taille des données)



Image *Barbara*



Echelle fine



Echelle intermédiaire

Estimation de la régularité α grâce aux lignes de maxima

- Régularité Lipschitzienne $\alpha \in \mathbb{R}$: régularité locale de l'image
- Cette régularité $\alpha \in \mathbb{R}$ caractérise le type de singularité

$$\left\{ \begin{array}{ll} \text{Frontière} & \alpha = 0 \\ \text{Ligne} & \alpha = -1 \\ \text{Point isolé} & \alpha = -2 \end{array} \right.$$

- Estimation par régression linéaire en des points particuliers : origines des lignes de maxima

$$\log M_s \leq \alpha \log s$$

avec $M_s = Wf(x(s), y(s), s)$ pour les ML

et $M_s = Mf(x(s), y(s), s)$ pour les LC

Synthèse sur les lignes de maxima

Deux types de lignes

- Maxima Lines : modules maxima de l'ondelette ΔG
- Lignes de Canny : maxima de Canny (gradient), points de contour

Applications à la détection de caractéristiques locales ou ponctuelles

- Origines des lignes : localisation de certaines singularités
- Aux plus petites échelles : caractérisation du type de singularité (régularité Lipschitzienne)
- Spécificité des ML
 - Echelle associée à un maximum local de la réponse : échelle caractéristique associée à un certain objet
 - Caractérisation d'objets par les ML associées

- 1 Détection de régions d'intérêt en vision par ordinateur
- 2 Rappels sur les lignes de maxima
- 3 Applications à la détection de structures remarquables
 - Caractérisation de singularités ponctuelles
 - Détection de blobs par ML

Détection de singularités ponctuelles par lignes de maxima

- Sélectionner des lignes pertinentes
 - traversant suffisamment d'échelles
 - ne correspondant pas à du bruit
- Origine des lignes : singularités (MM, MC)
- Caractérisation de ces singularités : régularité $\alpha \in \mathbb{R}$
- Invariance, robustesse de la régularité $\alpha \in \mathbb{R}$, sous l'influence de transformations de l'image ?

Influence d'une déformation géométrique sur α

- Image originale f
- Image déformée g

$$f(X) = g(BX), B \in GL_2 \text{ (déformation affine)}$$

Pour $\alpha \in [0, 1[$, f α -Lipschitz $\implies g$ α -Lipschitz

Interprétation : tant qu'une déformation ne change pas la nature d'une singularité, la régularité Lipschitzienne associée n'est pas modifiée.





Qualité de l'estimation de α 


Image	(1)	(2)	(3)
Frontière ($\alpha = 0$)			
α_{ML}	0.15	-0.04	0.09
α_{LC}	0.08	0.08	0.04
Ligne ($\alpha = -1$)			
α_{ML}	-0.98	-0.90	-0.74
α_{LC}	-1.00	-0.97	-0.87
Point Isolé ($\alpha = -2$)			
α_{ML}	-1.98	-1.74	-1.87
α_{LC}	-2.00	-1.91	-1.78

Globalement, les LC conduisent à une estimation de α légèrement meilleure que les ML

Qualité de l'estimation de la régularité α






Nombre de MM et de MC
en fonction de l'échelle
(bruit blanc Gaussien 2D)



Histogramme des régularités α
(image *Barbara*)

- Quantitativement : plus de LC que de ML
- Qualitativement : meilleurs résultats pour les LC que les ML
- Sur *Barbara*, nombreuses régularités comprises entre -1 et 0.5 , où l'estimation est satisfaisante (en dépit d'un certain biais)
- Robustesse de l'estimation par les LC ?

Robustesse de l'estimation de α (rotation)



Estimation robuste à la rotation (existence d'un biais)



Robustesse de l'estimation (déformation affine)

- Deux images, originale et déformée (déformation affine connue)
- Estimation de régularité en des points
 - issus de l'image originale $p_O^i = (x_O^i, y_O^i) : \alpha_O^i$
 - issus de l'image déformée $p_D^j = (x_D^j, y_D^j) : \alpha_D^j$
- Connaissant la déformation, appariements du type (p_O^i, p_D^j)
- Calcul de la différence $d_\alpha = |\alpha_O^i - \alpha_D^j|$
- La proportion d'appariements pour lesquels $d_\alpha < 0.2$ représente
 - 80% pour l'image *Barbara*
 - 97% pour une image géométrique représentant un carré

Illustration sur une image naturelle

2 images, originale et déformée (changement d'échelle et rotation)

Estimation de régularités ponctuelles par les LC



Bleu $\alpha \approx 0$
(frontières)

Vert $\alpha \approx -1$
(lignes)

Rouge $\alpha \approx -2$
(points)

Conclusion sur la régularité Lipschitzienne

- Les lignes de Canny apparaissent comme mieux adaptées à l'estimation de la régularité Lipschitzienne α
- Cette estimation de α en des points singuliers s'avère robuste à des déformations géométriques
- Autres tests, robustesse vis à vis de l'ajout de bruit
- Existence d'un certain biais par rapport aux valeurs attendues sur une image géométrique

Approche originale pour la détection de blobs par ML

- Liens entre Scale-Space et ondelettes
- Nouveau mécanisme de sélection d'échelle fondé sur les ML
- Détecteur de régions d'intérêt par ML
- Caractérisation des objets détectés par ML

Liens entre Scale-Space et ondelettes

	<i>Scale-Space</i>	Ondelettes
Echelle	\sqrt{t}	s
Opérateur	Fonction des dérivées de $L = f * G_t$	TOC 2D $Wf(x, y, s)$

- Généralisations permises par les ondelettes (fonction échelle 2D Φ au lieu d'un noyau Gaussien)
- Originalité de l'approche par ondelettes : lignes de maxima

Liens entre Scale-Space et ondelettes

Remarque sur l'opérateur Laplacien

- Détection de structures 2D de type blob
- Opérateur $t^\gamma \Delta L$, $L = f * G_t$
- Pour $\gamma = 1$, $t^\gamma \Delta L = t \Delta L = t \Delta f * G_t = f * (\Delta G)_t$

Conséquence : égalité entre

- la TOC 2D $Wf(x, y, \sqrt{t})$, ondelette ΔG , normalisation L^1
- l'opérateur Laplacien issu du Scale-Space $t \Delta L(x, y, t)$

Pertinence des lignes de maxima

- Liens entre Scale-Space et ondelettes
- Existence de lignes de maxima
- Comportement des lignes vis à vis de déformations géométriques
- Construction numérique de lignes de maxima


Pertinence des lignes de maxima issues de transformées en ondelettes pour la détection de structures remarquables
lesquelles pourront être associées à des régions d'intérêt

Nouveau mécanisme de sélection d'échelle


- Détection de structures 2D de type blob
- Sélection de maxima le long de ML
(maximum local en échelle de la réponse le long d'une ML)
- Comparaison avec la sélection classique
(maximum en espace et en échelle)
- Conditions sur les propriétés des ML plutôt que sur un seuillage
- Existence de jonction de ML

Intérêt : association entre ML et objets présents dans l'image


Notion de jonction de ML (1D)



Signal



Ondelette Sombrero




Ensemble des ML


- Lignes associées à du bruit
- Lignes isolées
- Lignes impliquées dans une jonction

Notion de jonction de ML (1D)


Réponses $|Wf(u(s), s)|$ associées à différentes ML ($u(s), s$)



ML bruit



ML isolée



ML impliquée
dans une jonction

Notion de jonction de ML (1D)

Lignes remarquables : ML ayant la double propriété


- jonction en (u^*, s^*)
- maximum local de la réponse $u \mapsto |Wf(u(s), s)|$ en $s = s^*$

Mise en évidence de certains objets : jonction de ML


- délimités par des singularités, en u_0 et u_1
- associés à une jonction de ML (u^*, s^*)

Jonction de ML en 2D – Objets associés


- Lien empirique entre jonction de ML et maximum local de la réponse le long de ces ML
- Les jonctions permettent une association entre des ML et certains objets présents dans l'image (délimités par des singularités)



ML extérieures



ML intérieures



Réponse associée
à une ML intérieure

Détecter des objets en 2D (Damerval, Meignen)

- Construire toutes les ML associées à une image
- Sélectionner un certain nombre de ML L_i pour lesquelles la réponse admet un maximum en (x_i^*, y_i^*, s_i^*)
- Regrouper celles ayant les mêmes (x_i^*, y_i^*, s_i^*)
- Mise en évidence d'un objet caractérisé par les ML associées
 - Jonction de ML (x^*, y^*, s^*)
 - Origines des ML (x_i^0, y_i^0)

Notion d'échelle caractéristique – Rappel

- Approche globale, échelle caractéristique moyenne (Luo'07)
- Approche locale, échelle caractéristique d'un objet (Lindeberg'98)
- Image originale f , image déformée f_1 , définie par
$$f(x, y) = f_1(\lambda x, \lambda y) \quad (\lambda > 0)$$
- $L = f * G_t$, $L_1 = f_1 * G_t$
- Si $(x, y, t) \mapsto t\Delta L(x, y, t)$ admet un maximum local en (x^*, y^*, t^*)
alors $t\Delta L_1(x, y, t)$ admet un maximum local en $(\lambda x^*, \lambda y^*, \lambda^2 t^*)$
et les réponses associées sont identiques
- $s^* = \sqrt{t^*}$: échelle caractéristique d'un objet présent dans l'image
localisé en (x^*, y^*)

Echelle caractéristique par ML

- Pour un point d'intérêt (x^*, y^*, s^*) , échelle caractéristique classique s^*
- Pour une ML dont la réponse admet un maximum local en (x^*, y^*, s^*) et dont l'extrémité est localisée en (x_0, y_0)


$$S^* = \sqrt{(x^* - x_0)^2 + (y^* - y_0)^2}$$

- Pour une jonction de plusieurs ML L_i


$$S^* = \text{médiane}\{S_i^*\}$$

- En pratique, $S^* \approx 2s^*$


Echelle caractéristique par ML – Illustration



ML associées
à une jonction




Echelles caractéristiques
 S_i^* associées aux ML




Echelle caractéristique
 S^* associée à l'objet

Echelle caractéristique par ML - Robustesse

- Image représentant un disque, différents niveaux de bruit
- Echelle caractéristique par ML robuste au bruit




Nombre de ML




Echelle \mathcal{S}^*

Détecteur par ML sur des images géométriques





Cas non bruité



Cas bruité


Détecteur par ML sur des images naturelles



Nécessité de quantifier si le détecteur par ML permet de détecter différentes régions d'intérêt indépendamment des conditions d'observation (et ainsi d'extraire des caractéristiques invariantes par la suite)

Performance d'un détecteur – Notion de répétabilité

- Deux images I_1 et I_2 , associées à n_1 et n_2 régions d'intérêt
- Connaissant la déformation, mesurer les erreurs de recouvrement
- Déterminer un certain nombre de correspondances entre régions
- Score de répétabilité $RS = \frac{nbCorrespondances}{\min(n_1, n_2)}$ ($0 \leq RS \leq 1$)



Performance d'un détecteur – Tests de répétabilité


- 8 séquences de 6 images : effet de déformations géométriques, ...
- Mesure pratique : score de répétabilité (exprimé en %)



Image de référence



Image déformée




Courbes de répétabilité


Source : Robotics Research Group, Oxford

Performances du détecteur ML

- Résultats corrects, mais inférieurs aux meilleurs détecteurs actuels
- Diversité des objets 2D, les ML permettent d'en mettre en évidence une partie (conditions strictes imposées par les ML, objets délimités par des singularités)



Changement d'échelle
et rotation



Changement de perspective

Estimation de la forme d'un objet

- Problème : déterminer une forme sommaire de l'objet associé à un point d'intérêt
- Approche classique : estimation d'une ellipse par un algorithme de *Shape Adaptation* (Lindeberg)
- Convergence dans 50% des cas en pratique
- Approche par ML
 - Origines des ML $(x_k^0, y_k^0)_{k \in K}$: singularités
 - Estimation d'une ellipse


Estimation la forme d'un objet par ML

- Point d'intérêt $(x^*, y^*, \mathcal{S}^*)$
- Estimation d'une ellipse : $F_\alpha(x, y) = 0$ avec


$$\begin{aligned} F_\alpha & : \mathbb{R}^2 \longrightarrow \mathbb{R} \\ F_\alpha(x, y) & = \alpha_1 x^2 + \alpha_2 y^2 + \alpha_3 xy + \alpha_4 x + \alpha_5 y + \alpha_6 \end{aligned}$$

- Estimation des paramètres à partir des origines des ML $(x_k^0, y_k^0)_{k \in K}$
- Possibilité de fixer le centre en (x^*, y^*)
- Possibilité de normaliser l'aire de l'ellipse à $\pi \mathcal{S}^{*2}$

Estimation la forme d'un objet par ML



Point d'intérêt
(x^* , y^* , S^*)



Ellipse estimée
(centre fixé, aire normalisée)

- Estimation robuste au bruit pourvu qu'il y ait suffisamment de ML
- Importance du nombre de ML impliquées dans une jonction

- Mécanisme de sélection d'échelle, utilisant les propriétés des ML plutôt qu'un seuillage
- Grandeurs caractéristiques robustes
 - Régularité Lipschitzienne associée à des points singuliers
 - Echelle caractéristique de l'objet, fondée sur une distance
- Estimation de la forme de l'objet par ML (ellipse)
alternative à l'algorithme de *Shape Adaptation* (Lindeberg)

- Jonction de ML et maximum local de la réponse le long de celle-ci
- Cadre d'existence de lignes de maxima plus générales
- Utilisation de lignes de maxima plus générales (caractère complémentaire des ML et des LC)
- Test de répétabilité portant sur la régularité Lipschitzienne
- Caractérisation des structures 2D, comme par ex.

blob, détecteur ML, $\left\{ \begin{array}{l} \text{ML impliquées dans une jonction} \\ \text{régularités Lipschitziennes} \\ \text{échelle caractéristique } \mathcal{S}^* \\ \text{estimation de la forme par ML} \end{array} \right.$



A. Almansa, T. Lindeberg.

Fingerprint enhancement by shape adaptation of scale-space operators with automatic scale-selection.
IEEE Transactions on Image Processing, 12(9) :2027-2042, 2000.



C. Damerval, S. Meignen.

Blob detection with wavelet maxima lines.
IEEE Signal Processing Letters, 14(1) :39-42, 2007.



C. Damerval, S. Meignen.

Computation of blob-like structures characteristic scale with wavelet maxima lines.
Proceedings of the 6th Conference on Curves and Surfaces, pp. 111-120. Nashboro Press, June 29 - July 5, 2006.



T. Lindeberg.

Feature detection with automatic scale selection.
International Journal of Computer Vision, 30(2) :77-116, 1998.



K. Mikolajczyk, T. Tuytelaars, C. Schmid, A. Zisserman, J. Matas, F. Schaffalitzky, T. Kadir, L. V. Gool.

A comparison of affine region detectors.
International Journal of Computer Vision, 62(1) :43-72, 2005.



K. Mikolajczyk, C. Schmid.

Scale and affine invariant interest point detectors.
International Journal of Computer Vision, 60(1), 2004.

Merci de votre attention