

Champs de Markov pour le traitement d'images catadioptriques

Markov Random Fields for Catadioptric Image Processing

Cédric Demonceaux^{1,2}, Pascal Vasseur¹

¹C.R.E.A., EA 3299, 7, rue du Moulin neuf, 80000 Amiens, France
cedric.demonceaux@u-picardie.fr,

²L.A.M.F.A., UMR 6140, 33, rue Saint-Leu, 80039 Amiens Cedex 1, France,
pascal.vasseur@u-picardie.fr

Manuscrit reçu le 24 janvier 2005

Résumé et mots clés

Les images produites par les capteurs catadioptriques présentent des distorsions importantes qui empêchent l'utilisation systématique de traitements conventionnels. Ainsi les champs de Markov dont l'utilité n'est plus à démontrer en traitement d'images perspectives, ne sont pas utilisables directement sur les images omnidirectionnelles. Dans cet article, nous proposons une adaptation des Champs de Markov aux images catadioptriques. La méthode consiste alors à redéfinir la notion de voisinage en utilisant le théorème de l'équivalence des capteurs catadioptriques centraux. Nous montrons l'intérêt de cette adaptation dans le cas de la segmentation supervisée en niveau de gris et de la détection de mouvement.

Vision omnidirectionnelle, champs de Markov, voisinage.

Abstract and key words

Images obtained with catadioptric sensors contain significant deformations which prevent the direct use of classical image treatments. Thus, Markov Random Fields (MRF) whose usefulness is now obvious for projective image processing, can not be used directly on catadioptric images because of the inadequacy of the neighborhood. In this article, we propose to define a new neighborhood for MRF by using the equivalence theorem developed for central catadioptric sensors. We show the importance of this adaptation for segmentation and motion detection.

Omnidirectional vision, Markov random field, Neighborhood.

1. Introduction

L'attrait de la vision omnidirectionnelle a conduit au développement de différents systèmes d'acquisition tels que les réseaux de caméras, les caméras tournantes ou les capteurs catadioptriques [3]. La vision catadioptrique consiste à associer un miroir convexe avec une caméra dont l'axe optique est confondu avec l'axe de révolution du miroir (Fig 1). L'avantage prin-

cipal de ces capteurs réside dans l'acquisition d'une image omnidirectionnelle en une seule prise. Cependant l'image acquise contient des distorsions importantes dues à la géométrie du miroir [5]. Ces déformations ont alors des répercussions significatives sur les traitements possibles et l'application directe d'opérateurs conventionnels ne peut fournir des résultats satisfaisants. Alors que depuis les années 80 les champs markoviens ont permis de résoudre de nombreux problèmes en traitement d'images tels que la segmentation d'images, la restaura-




Figure 1. Caméra omnidirectionnelle et image omnidirectionnelle.

tion d'images, l'estimation du mouvement etc., il devient impossible de les appliquer directement en imagerie omnidirectionnelle. En effet, les champs de Markov utilisent une dépendance locale entre pixels à partir d'un voisinage prédéfini qui est totalement à reconsidérer à cause des distorsions dans l'image omnidirectionnelle.

Certains auteurs ont déjà souligné cette incompatibilité des traitements classiques avec les images catadioptriques. Dans le cas de la mise en correspondance, [9] et [12] adaptent la taille et la forme du voisinage d'un point en fonction de sa position dans l'image. Pour cela, après avoir défini le voisinage directement sur la surface du miroir, ils projettent celui-ci sur le plan catadioptrique pour définir leur fenêtre de traitement. D'autres solutions consistent à employer le théorème de l'équivalence [7] pour définir l'espace où les opérations seront effectuées. Ainsi Daniilidis et Makadia proposent d'utiliser la sphère d'équivalence comme nouvel espace de traitement afin d'effectuer une convolution avec une gaussienne et de calculer sa dérivée [5]. Plus récemment, Strauss et Comby ont proposé dans [11] une adaptation des traitements morphologiques de base pour les images catadioptriques. Pour cela, ils projettent des noyaux géométriques définis à partir d'un cylindre englobant sur le plan catadioptrique connaissant les paramètres intrinsèques du système omnidirectionnel. Une approche alternative consisterait finalement à reconstruire l'image perspective à partir de l'image catadioptrique de façon à pouvoir utiliser les méthodes classiques. Néanmoins, comme ceci fut souligné dans [5] et [11], cette solution ne peut être satisfaisante car d'une part elle nécessite des interpolations qui sont coûteuses en temps de calcul et qui modifient le contenu de l'image et d'autre part un rééchantillonnage devient nécessaire afin de redéfinir une grille régulière de pixels.

L'objectif de ce papier est donc de proposer une adaptation des champs de Markov aux images omnidirectionnelles à partir de la définition d'un nouveau système de voisinage tenant compte des distorsions. Ce voisinage est obtenu à partir de l'équivalence entre l'image omnidirectionnelle et la projection des points de la scène sur une sphère [7]. Nous ferons dans un premier temps, un bref rappel sur les champs de Markov en traitement d'images et nous verrons pourquoi la définition classique du

voisinage ne peut pas convenir aux images omnidirectionnelles. Ensuite, à l'aide de l'équivalence entre la projection catadioptrique centrale et la projection sur une sphère, nous proposerons un nouveau système de voisinage adapté aux images omnidirectionnelles. Enfin, nous validerons notre méthode sur un problème de segmentation supervisée d'images omnidirectionnelles et sur un problème de détection de mouvement.

2. Les champs de Markov en traitement d'images

Les champs de Markov spatiaux ont été introduits par Besag [4] et popularisés en traitement d'images par Geman et Geman [6]. Ces modèles sont définis à partir d'un graphe. Considérons donc un graphe simple $\mathcal{G} = (\mathcal{S}, \mathcal{U})$ où $\mathcal{S} = \{s_1, s_2, \dots, s_N\}$ est l'ensemble des sommets (dit ensemble des sites dans le cas des champs de Markov) et \mathcal{U} l'ensemble des arêtes.

Définition 1 (Voisin). Deux sites s_i et s_j sont dits voisins s'il existe une arête $u_{ij} \in \mathcal{U}$ entre eux. L'ensemble des voisins d'un site s est noté \mathcal{V}_s .

Définition 2 (Voisinage). $\mathcal{V} = \{\mathcal{V}_s | s \in \mathcal{S}\}$ est un système de voisinage pour \mathcal{G} si :

- $s \notin \mathcal{V}_s$
- $\forall (s, t) \in \mathcal{S} \quad s \in \mathcal{V}_t \Leftrightarrow t \in \mathcal{V}_s$

À partir de \mathcal{V} , nous définissons l'ensemble \mathcal{C} dont les éléments c (Fig 2), appelés cliques, sont les parties de \mathcal{S} vérifiant

$$\begin{cases} \exists s \in \mathcal{S} \text{ tel que } c = \{s\} \\ \text{ou} \\ \forall \{s, t\} \subset c, \quad t \in \mathcal{V}_s \end{cases}$$

Considérons un champ aléatoire $\mathcal{X} = \{X_1, \dots, X_N\}$ de réalisation $\omega = \{\omega_1, \dots, \omega_N\}$

Définition 3. \mathcal{X} est un champ de Markov par rapport à \mathcal{V} si :

- (i) $\forall \omega \quad P(\mathcal{X} = \omega) > 0$
- (ii) $\forall (s, \omega) \quad P(X_s = \omega_s | X_r = \omega_r, r \neq s) = P(X_s = \omega_s | X_r = \omega_r, r \in \mathcal{V}_s)$ (1)

La définition des champs de Markov est très locale. Un champ de Markov est un champ aléatoire où chaque site n'est influencé que par ses sites voisins. Utiliser la caractérisation (1) ne permet pas d'avoir une expression simple de la distribution jointe $P(\mathcal{X} = \omega)$. Cependant, cette distribution peut être facilement obtenue à partir du théorème de Hammersley-Clifford [4] établissant l'équivalence entre les champs de Markov et les champs de Gibbs.




Figure 2. Système de voisinage et cliques associées.
(a) et (c) Voisinage d'ordre 1, (b) et (d) Voisinage d'ordre 2.

Les problèmes de restauration, classification, segmentation d'images peuvent se schématiser de la façon suivante: à partir d'observations (informations connues) sur l'image ou sur la séquence d'images (niveaux de gris, couleurs, contours, déplacements...), on souhaite trouver un jeu d'étiquettes (informations cachées) qui pourrait être à l'origine de ces observations. La résolution de ces problèmes nécessite d'explicitier la relation entre les étiquettes et les observations que l'on définit à partir d'un modèle dit d'*attache aux données*. Cependant, ces modèles à eux seuls ne suffisent pas à résoudre ces problèmes inverses. En effet, à cause de la perte d'information intervenant lors de la formation des images et du bruit sur les observations, ces problèmes inverses sont en général mal posés au sens de Hadamard. Nous devons donc faire une hypothèse supplémentaire sur le jeu d'étiquettes recherché. C'est pourquoi nous ajoutons une contrainte au problème appelée connaissance *a priori* qui contraint le jeu d'étiquettes à être markovien.

Posons Y le champ aléatoire d'observations $y = \{y_r, r \in \mathcal{R}\}$ définies sur l'ensemble des sites $\mathcal{R} = \{r_1, r_2, \dots, r_M\}$ et Φ l'ensemble des configurations d'observations. Notons Ω l'ensemble des configurations d'étiquettes $x = \{x_s, s \in \mathcal{S}\}$ définies sur $\mathcal{S} = \{s_1, s_2, \dots, s_N\}$ du champ aléatoire d'étiquettes X . Les deux ensembles de sites \mathcal{R} et \mathcal{S} peuvent être confondus.

L'estimation bayésienne va nous permettre de modéliser conjointement les étiquettes et les observations grâce au champ aléatoire couplé (X, Y) de distribution de probabilité P_{XY} .

Si on prend l'exemple de l'estimateur bayésien Maximum a Posteriori (MAP), le champ d'étiquettes markovien x recherché est solution de

$$\min_{x \in \Omega} U(x, y) = \min_{x \in \Omega} (U_1(x, y) + U_2(x)) \quad (2)$$

où U_1 est le terme d'attache aux données qui exprime la relation entre les observations y et les étiquettes x et où U_2 décrit l'*a priori* markovien du champ d'étiquettes et se décompose en somme de potentiel local dépendant du système de voisinage:

$$U_2(x) = \sum_{\langle s, s' \rangle \in \mathcal{C}} V_2(s, s'). \quad (3)$$

Dans le cas d'images classiques, les systèmes de voisinage utilisés sont définis par les plus proches pixels (Fig 2). Or, ce type de voisinage n'est pas adapté aux images catadioptriques à cause des déformations engendrées par le miroir. En effet, un pixel distant de d d'un pixel p n'a pas la même influence sur celui-ci si p est situé au centre de l'image ou à la périphérie (Fig 3).




Figure 3. $d(P1, P2) = d(P3, P4)$ alors que $P1$ n'a physiquement pas la même influence sur $P2$ que $P3$ sur $P4$.

3. Champs de Markov adaptés aux images catadioptriques centrales

3.1. Équivalence sur la sphère

Baker et Nayar ont classé les capteurs catadioptriques en deux catégories en fonction du nombre de points de vue [1]. Ainsi, les capteurs avec un point de vue unique, nommés capteurs catadioptriques centraux, permettent une reconstruction géométriquement correcte de l'image perspective à partir de l'image omnidirectionnelle originale. Cette catégorie est constituée des miroirs paraboloides associés à une caméra orthographique et

des miroirs hyperboloïdes, ellipsoïdes ou plans avec une caméra perspective. La seconde catégorie comportant plusieurs points de vue différents possèdent des caractéristiques géométriques beaucoup moins remarquables et se compose de toutes les autres possibilités d'association miroir-caméra. Nous nous intéressons ici aux capteurs centraux pour lesquels Geyer et Daniilidis ont démontré l'équivalence avec une double projection via une sphère [7]. Cette sphère de rayon unitaire est centrée sur le foyer du miroir. La double projection consiste alors dans un premier temps à considérer le point sur la sphère qui résulte de l'intersection entre la droite projective passant par le centre de la sphère O_c et le point 3D du monde P_w que l'on veut projeter sur l'image. La seconde étape consiste à projeter le point de la sphère P_s sur le plan image à partir d'un point O_p situé sur l'axe perpendiculaire au plan image et passant en son centre (Fig 4). Les positions du second point de projection O_p et du plan image sont déterminées par calibrage.

Cette équivalence est très intéressante dans la mesure où elle permet de changer d'espace pour effectuer certains traitements en tenant compte des déformations induites par le capteur. De nombreux auteurs ont ainsi utilisé ce changement d'espace afin de réaliser la dérivée d'une image omnidirectionnelle [5], le calcul de pose du capteur [10] ou encore la détection de droites catadioptriques [2][13]. C'est dans cette même optique que nous proposons d'utiliser la sphère d'équivalence afin de déterminer le voisinage le plus approprié dans le cadre d'images catadioptriques centrales.




Figure 4. Équivalence entre la projection catadioptrique centrale et la double projection sur la sphère.

$$\theta = \arccos \left(\frac{\Lambda D^2 - (\xi + \varphi) \sqrt{(\xi + \varphi)^2 + D^2(1 - \Lambda^2)}}{D^2 + (\xi + \varphi)^2} \right) \quad (4)$$

avec $\Lambda = \frac{\xi}{R}$.

Ce changement d'espace permet de contourner les déformations induites par le capteur. Pour créer une dépendance spatiale entre les points, il paraît donc plus naturel de considérer les points P_s à la place des points P_i en associant à ces points un voisinage défini sur la sphère équivalente.

Notons Π la projection qui à un site s (pixel de l'image omnidirectionnelle) associe son point équivalent P_s en coordonnées sphériques sur la sphère équivalente S^2 (Fig 4),

$$\Pi : \begin{matrix} S & \rightarrow & S^2 \\ s = (u, v) & \mapsto & (R, \theta_s, \phi_s) \end{matrix} \quad (5)$$

On définit alors le nouveau voisinage de la façon suivante (Fig 5):



Figure 5. (a) Voisinage à la périphérie de l'image, (b) Voisinage au centre de l'image.

$$\forall s \in \mathcal{S}, \Pi(s) = (R, \theta_s, \phi_s)$$

$$\mathcal{V}_s = \left\{ t \in \mathcal{S}, t \neq s \quad \Pi(t) = (R, \theta_t, \phi_t) \text{ tel que } |\theta_t - \theta_s| \leq \frac{1}{N} \right.$$

$$\left. \text{et } (|\phi_t - \phi_s| \leq \frac{1}{M} \text{ ou } |\phi_t - \phi_s| \geq 2\pi - \frac{1}{M}) \right\}, \tag{6}$$

où N et M sont deux constantes fixées qui définissent l'ordre du voisinage.

Remarquons que nous n'effectuons aucun rééchantillonnage des points sur la sphère équivalente. En effet, le nouveau voisinage n'est défini qu'à partir des points de la sphère correspondants à des pixels de l'image omnidirectionnelle.

4. Expérimentation

Dans cette partie, nous présentons les résultats obtenus à partir d'une modélisation markovienne adaptée aux images omnidirectionnelles sur deux problèmes importants en traitement des images: la segmentation et la détection de mouvement. Dans l'ensemble des expérimentations, nous minimisons les énergies markoviennes à l'aide d'un algorithme déterministe I.C.M. [6]. En théorie, les paramètres intrinsèques et extrinsèques du capteur omnidirectionnel doivent être estimés par une phase de calibrage. L'expérience montre que cette étape n'est pas prépondérante dans les résultats. En effet, de faibles perturbations des paramètres de calibration engendrent d'infimes modifications sur le voisinage et ne modifient pas les résultats. En fait, seules les constantes N et M de l'équation (6) jouent un rôle important dans la définition du voisinage. Ces constantes sont choisies telles que notre système de voisinage soit identique au voisinage d'ordre 1 au centre de l'image.

4.1. Segmentation en niveau de gris

Pour vérifier l'utilité de la modification du voisinage pour le traitement des images omnidirectionnelles, nous avons comparé la méthode que nous proposons dans cet article avec une méthode markovienne utilisant un voisinage d'ordre 1 (Fig 2(a)) sur un problème de segmentation supervisée d'image omnidirectionnelle. Pour ce faire, nous avons utilisé une image de synthèse (Fig 7(a)) composée de trois couleurs différentes (blanc, gris et noir) bruitée à l'aide d'un bruit blanc gaussien (Fig 7(b)). Considérons le champ d'étiquettes $E = \{e_s, s \in \mathcal{S}\}$ où e_s peut prendre trois valeurs différentes (0 = noir, 1 = gris et 2 = blanc). Le problème de la segmentation est d'attribuer à chaque site l'étiquette correspondant à sa véritable couleur en fonction des observations $O = \{o_s, s \in \mathcal{S}\}$. Ces observations correspondent au niveau de gris de chaque pixel. Notons $\mathcal{C}_{ss'} = \{c \in \mathcal{C} | s \in c \text{ et } s' \in c\}$, nous définissons l'énergie markovienne associée à ce problème de la façon suivante:

$$U(e, o) = \sum_{s \in \mathcal{S}} f(e_s, o_s) + \lambda \sum_{\langle s, s' \rangle \in \mathcal{C}} \frac{1}{\text{card}(\mathcal{C}_{ss'})} (1 - \delta(e_s, e_{s'})) \tag{7}$$

où

$$f(e_s, o_s) = 1 - \frac{1}{1 + e^{20 \left(\frac{|o_s - I(e_s)|}{256} \right)^{-0.3}}}$$

$$I(e_s) = \begin{cases} 0 & \text{si } e_s = 0 \\ 128 & \text{si } e_s = 1 \\ 255 & \text{si } e_s = 2 \end{cases} \quad \text{et} \quad \delta(x, y) = \begin{cases} 1 & \text{si } x = y \\ 0 & \text{si } x \neq y \end{cases}$$

Le premier terme de l'énergie mesure l'erreur entre l'observation en chaque point et son étiquette, il autorise une différence de niveau de gris de 30% (Fig 6). Le second terme oblige le champ d'étiquettes à être le plus homogène possible.

Nous avons testé notre méthode en fonction du bruit dans l'image traitée et du facteur λ qui caractérise l'influence du voisinage sur le résultat. Plus celui-ci est grand, plus l'influence des étiquettes des sites voisins est importante. La figure 7 montre les résultats de la segmentation markovienne lorsque nous ajoutons un bruit blanc d'écart type 78 dans l'image initiale. Les résultats (c), (e), (g) correspondent à la minimisation de (7) avec un voisinage d'ordre 1 (Fig 2) alors que les résultats (d), (f) et (h) sont obtenus à partir du voisinage proposé dans cet article. Si $\lambda = 0.3$, l'influence des voisins est peu important et les résultats de la segmentation sont similaires. Cependant, l'interaction entre les voisins n'est pas suffisante pour obtenir une segmentation correcte. Augmenter le terme de pénalisation λ montre qu'un voisinage classique n'est pas adapté aux images omnidirectionnelles. En effet, même si les pixels sont mieux étiquetés que pour une valeur faible de λ , cette segmentation est moins correcte qu'avec le voisinage adapté. Ceci est confirmé par les courbes de la figure 8 qui donnent l'erreur de segmentation en fonction du bruit dans l'image et de l'influence du terme




Figure 6. Terme d'attache aux données.




Figure 7. (a) Segmentation d'image omnidirectionnelle. (a) Image de synthèse, (b) Image bruitée par un bruit blanc gaussien d'écart type 78. Colonne de gauche : segmentation markovienne classique avec (c) $\lambda = 0.3$, (e) $\lambda = 0.5$, (g) $\lambda = 1$. Colonne de droite : segmentation markovienne adaptée avec (d) $\lambda = 0.3$, (f) $\lambda = 0.5$, (h) $\lambda = 1$.

de pénalisation λ . Lorsque le bruit dans l'image est faible, les deux méthodes donnent des résultats quasi identiques. En effet, dans ce cas, le terme d'attache aux données (U_1) permet déjà d'obtenir une bonne segmentation et le terme de régularisation (U_2) n'a alors que peu d'influence. De plus, on remarque que pour une faible dépendance entre les voisins (Fig 8(a)), les deux

types de segmentation donnent des résultats comparables. L'augmentation de λ permet de réduire l'erreur de segmentation. Dans ce cas, cette erreur est bien plus faible gr,ce au voisinage proposé. Cela montre bien que notre voisinage est plus approprié que le voisinage classique pour le traitement des images omnidirectionnelles.




Figure 8. Nombre de points mal étiquetés en pourcentage en fonction du bruit. Segmentation markovienne classique en pointillé et segmentation markovienne adaptée aux images omnidirectionnelles en trait plein. (a) $\lambda = 0.3$, (b) $\lambda = 0.5$, (c) $\lambda = 1$.

4.2. Détection de mouvement

Considérons deux images consécutives $I(t)$ et $I(t+1)$ d'une séquence d'images prise à partir d'un capteur omnidirectionnel immobile. Le problème est de détecter dans l'image les zones en mouvement entre les instants t et $t+1$. Pour cela, posons $E = \{e_s, s \in S\}$ le champ d'étiquettes où e_s est à valeurs dans $\{0, 1\}$ (0 = site immobile, 1 = site mobile) et $O = \{o_s, s \in S\}$ le champ d'observations. On considère l'énergie markovienne suivante:

$$U(e, o) = \sum_{s \in S} f(e_s, o_s) + \lambda \sum_{\langle s, s' \rangle \in \mathcal{C}} \frac{1}{\text{card}(\mathcal{C}_{ss'})} (1 - \delta(e_s, e_{s'})) \quad (8)$$

où

$$f(e_s, o_s) = \begin{cases} 1 - \frac{1}{1 + \exp(|I(s, t) - I(s, t+1)| - \alpha)} & \text{si } e_s = 0 \\ \frac{1}{1 + \exp(|I(s, t) - I(s, t+1)| - \alpha)} & \text{si } e_s = 1, \end{cases}$$

Cette fonction f favorise une étiquette $e_s = 0$ (site immobile) si la différence d'intensité entre les deux images consécutives est inférieure à α et une étiquette $e_s = 1$ (site mobile) sinon.

Nous avons une nouvelle fois comparé notre modélisation markovienne adaptée aux images omnidirectionnelles avec une modélisation à partir de voisinage classique d'ordre 1 (Fig 2(a)). Nous avons posé $\alpha = 3$ (seuil à partir duquel on considère les pixels en mouvement). Entre les instants t et $t+1$, trois personnes bougent devant la caméra. Le maximum de vraisemblance est donné figure 9(b). Pour $\lambda = 0.6$, la dépendance entre les voisins n'est pas suffisante pour éliminer le bruit. Comme dans le cas de la segmentation, en considérant une dépendance plus importante entre les sites voisins ($\lambda = 1.2$), le voisinage adapté aux images omnidirectionnelles permet d'éliminer toutes les fausses alarmes contrairement au voisinage classique. De plus, on remarque un effet bloc dans les résultats dans le cas d'un voisinage d'ordre 1.




Figure 9. (a) Image à l'instant t , (b) Maximum de Vraisemblance, (c) markov classique $\lambda = 0.6$, (d) markov omni $\lambda = 0.6$, (e) markov classique $\lambda = 1.2$, (f) markov omni $\lambda = 1.2$.

5. Conclusion et perspectives

Dans ce papier, après avoir rappelé brièvement le principe des champs de Markov et leur utilité en traitement d'images, nous avons observé que cette modélisation n'était pas appropriée

pour le traitement des images omnidirectionnelles. En effet, à cause de la projection catadioptrique, deux pixels de l'image ayant la même distance euclidienne n'ont pas la même interaction s'ils sont situés à la périphérie ou au centre de l'image. C'est pourquoi, à l'aide de l'équivalence entre la projection catadioptrique et la projection sur une sphère, nous avons proposé un nouveau système de voisinage mieux adapté aux images omnidirectionnelles. Les expérimentations, sur des pro-

blèmes de segmentation supervisée d'images et de détection de mouvement, ont montré des résultats nettement plus corrects en utilisant un voisinage adapté aux images traitées qu'avec un voisinage d'ordre 1. Cependant, comme dans le cas classique, la minimisation de l'énergie markovienne peut poser certains problèmes. En effet, la minimisation exacte de l'énergie nécessite l'utilisation d'algorithmes stochastiques trop coûteux en temps de calcul. En revanche, l'utilisation d'algorithmes déterministes qui sont plus rapides, ne nous permet pas de trouver le minimum global de l'énergie. Pour remédier à ce problème, il serait intéressant de développer une méthode multirésolution afin de réduire la sensibilité des algorithmes déterministes à l'initialisation et d'accélérer la méthode comme l'ont proposé Heitz *et al* [8] dans le cas des images classiques.

Références

- [1] S. BAKER and S.K. NAYAR, A Theory of Single-Viewpoint Catadioptric Image Formation, *Int. Journal on Computer Vision*, 35 (2): 175-196, Novembre 1999.
- [2] J.P BARRETO . and H. ARAUJO, Direct Least Square Fitting of Paracatadioptric Line Images, *Proc. Workshop on Omnidirectional Vision and Camera Networks* , OMNIVIS03, Madison, Wisconsin, Juin 2003.
- [3] R. BENOSMAN and S.B. KANG, *Panoramic Vision: Sensors, Theory, Applications*, Springer, 2001.
- [4] J. BESAG, Spatial Interaction and the Statistical Analysis of Lattice Systems, *RoyalStat*, B-36(2):192-236, 1974.
- [5] K. DANIILIDIS, A. MAKADIA. and T. BÜLOW, Image Processing in Catadioptric Planes: Spatiotemporal Derivatives and Optical Flow Computation, In *Proc. Workshop on Omnidirectional Vision, OMNIVIS02*, pages 3-10, Copenhagen, Danemark, Juin 2002.
- [6] S. GEMAN and D. GEMAN, Stochastic Relaxation, Gibbs Distributions, and the Bayesian Restoration of Images, *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 6(6): 721-741, Novembre 1984.
- [7] C. GEYER. and K. DANIILIDIS, Catadioptric Projective Geometry, *Int. Journal on Computer Vision*, 45(3):223-243, Decembre2001.
- [8] F. HEITZ, P. PEREZ. and P. BOUTHEMY, Multiscale Minimization of Global Energy Functions in Some Visual Recovery Problems, *CVGIP: Image Understanding*, 59(1):125-134, Janvier1994.
- [9] S. IENG, R. BENOSMAN and J. DEVARS, An Efficient Dynamic Multi-Angular Feature Points Matcher for Catadioptric Views, *Proc. Workshop on Omnidirectional Vision and Camera Networks, Omnivis03*, Madison, Wisconsin, Juin 2003.
- [10] A. PAULINO and H. ARAÚJO, Pose Estimation for Central Catadioptric Systems: An Analytical Approach, In *Proc. Int. Conf. on Pattern Recognition, ICPR02*, pages 696-699, Québec, Canada, Août 2002.
- [11] O. STRAUSS. and F. COMBY, Opérations morphologiques floues pour images omnidirectionnelles, *12^{èmes} Rencontres Francophones sur la Logique Floue et ses Applications (LFA'04)*, Nantes, France, Novembre2004.
- [12] T. SVOBODA. and T. PAJDLA, Matching in Catadioptric Images with Appropriate Windows, and Outliers Removal, *Int. Conf. on Computer Analysis of Images and Patterns CAIP01*, Warsaw, Poland, pages 733-740, Septembre 2001.
- [13] P. VASSEUR and E.M. MOUADDIB, Central Catadioptric Line Detection, In *Proc. British Machine Vision Conference, BMVC 04*, pages 57-66, Septembre 2004.



Cédric Demonceaux

Cédric Demonceaux est maître de conférences à l'Université de Picardie Jules Verne. Il a soutenu son Doctorat en Mathématiques Appliquées aux Traitements des Images en Décembre 2004 au CREA EA 3299 et au LAMFA UMR 6140. Ses activités de recherche, au sein de l'équipe perception en Robotique du CREA EA 3299, concernent l'analyse du mouvement dans les séquences d'images (estimation / détection / segmentation) mais aussi le traitement des images omnidirectionnelles.



Pascal Vasseur

Pascal Vasseur est maître de conférences à l'IUT Informatique de l'Université de Picardie Jules Verne depuis 1999. Ses activités de recherche s'effectuent au sein de l'équipe Perception en Robotique du Centre de Robotique, d'Électrotechnique et d'Automatique (CREA - EA 3299) d'Amiens. Ses thèmes de recherche concernent le traitement des images et la vision omnidirectionnelle.

