Vers un système de détection et caractérisation par caméra de conditions météo critiques pour la sécurité routière

Nicolas Hautière, Jérémie Bossu, Erwan Bigorgne, Didier Aubert

Université Paris-Est, IFSTTAR, IM, LEPSIS 58 boulevard Lefebvre, F-75015 Paris {nicolas.hautiere,didier.aubert}@ifsttar.fr

RÉSUMÉ. La présence d'une distance de visibilité réduite sur un réseau routier (épais brouillard, pluie forte, etc.) affecte la sécurité de celui-ci. Nous avons conçu un système de bord de voies qui vise à détecter des situations critiques telles que le brouillard dense ou les fortes chutes de pluie à l'aide d'une caméra vidéo. Les différents traitements d'image sont présentés, en particulier l'estimation de la distance de visibilité, la détection de brouillard, ainsi que la détection de pluie. En se fondant sur les principes sous-jacents de ces algorithmes, une caméra est ensuite spécifiée pour répondre aux besoins exprimés par la norme NF P 99-320 sur la météorologie routière. Des résultats expérimentaux sont présentés ainsi que des perspectives de validation à plus grande échelle.

ABSTRACT. The presence of a reduced visibility distance on a road network (thick fog, heavy rain, etc.) affects its safety. We designed a roadside system on which aims to detect critical situations such as dense fog or heavy rain with a simple CCTV camera. Different image processing are presented, particularly the estimation of visibility distance, the detection of fog, and the detection of rain. Based on the principles underlying these algorithms, a camera is specified to meet the needs expressed by the standard NF P 99-320 on highway meteorology. Experimental results are presented as well as prospective validation at a bigger scale.

MOTS-CLÉS : système de vision, sécurité routière, vidéosurveillance, visibilité, brouillard, pluie, caméra, calibrage, soustraction de fond.

KEYWORDS: machine vision, road safety, visual surveillance, visibility, fog, rain, camera, calibration, background subtraction.

DOI:10.3166/TS.28.575-603 © 2011 Lavoisier

Extended Abstract

The occurrence of visibility impairment weather conditions on a road network alters traffic safety. In such conditions, drivers are instructed to slow down. For example in France, the speed limit is reduced to 50 km/h whenever the visibility is less than 50 m. Unfortunately, weather centers are not able to accurately monitor low visibility areas because fog is a very local phenomenon. To achieve this goal, road operators may equip their networks with dedicated optical sensors. When located in areas where fog is recurrent (MacHutchon, Ryan, 1999), these road sensors provide information that can be relayed to vehicles or displayed on variable message signs. Unfortunately, these sensors are expensive and are sensitive to the heterogeneity of fog because of a too small measurement volume (Hautière, Labayrade, Aubert, 2006). To improve detection of fog along the roads, camera-based approaches are being developed (Bush, Debes, 1998 ; Hagiwara *et al.*, 2006 ; Hallowell *et al.*, 2007 ; Hautière *et al.*, 2008 ; Lagorio *et al.*, 2008), because the cameras are multifunctional sensors, which are already heavily deployed along the roads to monitor traffic and to detect incidents.

Based on the NF-P-99-320 standard on road weather (AFNOR, 1998), we present in this paper a camera-based system for detecting and characterizing weather conditions which are critical for road safety. It determines the visibility range and also detects the presence of fog or rain. It only requires an accurate geometrical calibration of the camera without prior learning phase.

Visibility Estimation

The meteorological visibility distance is the greatest distance at which a black object of suitable dimensions can be seen against the sky at the horizon. The International Commission on Illumination adopted a value of 5% for the minimum visible contrast (CIE, 1987). Different methods to estimate the meteorological visibility distance have been developed in the field of transportation. One family of methods estimates the contrast of objects in the scene and assigns a distance, usually assuming the road is flat. Bush et Debes (1998) use a wavelet transform to detect the highest edge in the image with a contrast above 5% in a region of interest which encompasses the road pavement. However, the presence of vertical objects, such as a truck, in their area of interest biases the estimation. Similarly, the accuracy of their method strongly depends on the characteristics of the camera. A system for estimating the meteorological visibility distance with the same principles is proposed by Zhao-Zheng *et al.* (2009), except that it uses the algorithm proposed by (Hautière, Aubert, Jourlin, 2006) to estimate the contrast.

Our approach belongs to this family of methods. Unlike Hallowell *et al.* (2007); Hagiwara *et al.* (2006), it takes into account the 3-D structure of the scene thanks to the detection of the circulated area. Contrary to Bush et Debes (1998); Zhao-Zheng *et al.* (2009), moving objects in the region of interest are filtered out using a background subtraction method. The accuracy of the system is discussed with respect to the characteristics of the camera. In particular, a camera is specified to fulfill the requirements expressed in the NF-P-99-320 standard (AFNOR, 1998).

Detection of Fog and Rain

In the literature on video surveillance, detection of fog is not explicitly addressed. Generally, it is indirectly done by means of a simple threshold applied to the visibility distance (see previous paragraph). In the area of road weather, a threshold of 400 m is used as a standard (AFNOR, 1998). In the field of meteorological observation, a threshold of 1000 m is commonly used. These distances correspond to a reaction time in case of an unexpected obstacle respectively on the road and the runway. In order to develop a fog detection method using fixed camera, we propose to adapt a method, which was originally dedicated to driver assistance (Hautière, Tarel *et al.*, 2006). This method is based on a daytime fog model, namely Koschmieder's law whose parameters are dynamically instantiated. In this aim, a region within the image that displays minimal line-to-line gradient variation when browsed from bottom to top is identified thanks to a region growing process. A vertical band is then selected in the detected area. Finally, taking the median intensity of each segment yields the vertical variation of the intensity of the image and the position of an inflection point, whose relative position with respect to the horizon line is proportional to the fog density.

The detection of rain is rarely discussed in the literature as well. Existing works focus more on the segmentation of raindrops for image rendering applications (Hase et al., 1999; Zhang et al., 2006; Garg, Nayar, 2007; Barnum et al., 2010). These methods generally lead to an oversegmentation of rain pixels which cause false detections in the absence of rain. Therefore, they cannot be used alone to detect the presence of rain or snow. To circumvent these limitations, we developed a method based on robust local descriptors. Selection rules based on photometry and size are proposed in order to select the potential rain streaks. Then a Histogram of Orientations (HOS) of rain or snow Streaks, estimated with the method of geometric moments, is computed, which is assumed to follow a model of Gaussian uniform mixture. The Gaussian distribution represents the orientation of the rain or the snow whereas the uniform distribution represents the orientation of the noise. An algorithm of expectation maximization is used to separate these two distributions. Following a goodness-of-fit test, the Gaussian distribution is temporally smoothed and its amplitude allows deciding the presence of rain or snow. This approach can be seen as a generalization of the median temporal filter proposed by Hase et al. (1999), the temporal classification algorithm tested by Zhang et al. (2006) and the photometric constraints proposed by Garg et Nayar (2007).

1. Introduction

La présence d'une zone de visibilité réduite sur un réseau routier (épais brouillard, pluie forte, etc.) affecte la sécurité de celui-ci. Dans une telle situation, le code de la route prévoit un abaissement de la limite de vitesse autorisée. Par exemple en France, une limitation de la vitesse à 50 km par heure est prescrite à chaque fois que la distance de visibilité est inférieure à 50 m. Malheureusement, les centres météorologiques ne sont pas en mesure d'observer avec précision les zones de visibilité réduite car le brouillard est un phénomène très local. Pour atteindre cet objectif, les opérateurs routiers équipent parfois leurs réseaux de capteurs optiques dédiés. Si ceux-ci sont situés dans des endroits où le brouillard est récurrent (MacHutchon, Ryan, 1999), ces capteurs routiers peuvent fournir des informations susceptibles d'être communiquées aux véhicules ou affichées en bord de voies à l'aide de panneaux à message variable. Malheureusement, ces capteurs sont coûteux et sont sensibles à l'hétérogénéité du brouillard à cause d'une trop petite taille du volume de mesure (Hautière, Labayrade, Aubert, 2006). Pour permettre une meilleure détection du brouillard à l'échelle des itinéraires routiers, des approches à base de caméra sont en cours de développement (Bush, Debes, 1998; Hagiwara et al., 2006; Hallowell et al., 2007; Hautière et al., 2008; Lagorio et al., 2008), car les caméras routières sont des capteurs multifonctions qui sont déjà fortement déployés le long des routes pour surveiller le trafic et détecter la présence d'incidents.

En se fondant sur la norme NF-P-99-320 sur la météorologie routière (AFNOR, 1998), nous présentons dans cet article un système de détection et caractérisation par caméra de conditions météorologiques critiques pour la sécurité routière. Il estime la classe de visibilité routière et détecte également la présence de brouillard ou de pluie. Il nécessite uniquement un calibrage géométrique précis de la caméra sans phase d'apprentissage préalable. Voici quelques éléments bibliographiques permettant de situer la proposition.

1.1. Estimation de la visibilité

La distance de visibilité météorologique est la plus grande distance à laquelle un objet noir de dimension convenable peut être vu sur le ciel à l'horizon. La Commission internationale de l'éclairage a adopté une valeur moyenne de 5 % pour le seuil de contraste de visibilité (CIE, 1987).

Différentes méthodes d'estimation de cette grandeur ont été développées dans le domaine des transports. Une première famille de méthodes, que l'on peut qualifier d'approche directe, estime le contraste des objets dans la scène et leur attribue une distance, généralement en supposant que la route est plane. Ainsi, Bush et Debes (1998) détectent, à l'aide d'une transformée en ondelettes, le contour le plus élevé présentant un contraste supérieur à 5 % dans une région d'intérêt comprenant la route. Toutefois, la présence d'objets verticaux, comme un camion, dans leur région d'intérêt biaise les mesures. De même, la précision de leur méthode dépend fortement des caractéristiques de la caméra, ce qui est nullement évoqué dans l'article. Un système d'estimation de

la distance de visibilité reprenant les mêmes principes que ceux proposés par Bush et Debes (1998) est proposé par Zhao-Zheng *et al.* (2009), à la différence qu'il utilise l'algorithme proposé par Hautière, Aubert et Jourlin (2006) pour estimer le contraste. Kwon (2004) a effectué des tests en utilisant des cibles à distance fixe. Cependant, le déploiement de telles cibles à chaque emplacement de caméra serait coûteux.

Une deuxième famille de méthodes, qualifiée d'indirecte, établit une fonction de transfert entre la visibilité estimée par un visibilimètre ou des observateurs humains et le score d'un estimateur lié à l'image courante. Ainsi, Hagiwara *et al.* (2006) ont proposé un estimateur dans le domaine fréquentiel. Hallowell *et al.* (2007) ont proposé un algorithme qui détecte les contours naturels dans l'image (l'horizon, les lignes d'arbres, routes, bâtiments) et effectue une comparaison de chaque image avec une image composite historique. Toutefois, Hallowell *et al.* (2007) ; Hagiwara *et al.* (2006) ne tiennent pas compte de la structure 3-D de la scène pour estimer la visibilité, ce qui rend leurs méthodes sensibles à la présence d'objets verticaux dans la scène.

En outre, les différentes méthodes ne détectent pas la cause de la réduction de la visibilité. Notre approche appartient à la première famille de méthodes. Contrairement à Hallowell *et al.* (2007); Hagiwara *et al.* (2006), elle prend en compte la structure 3-D de la scène par la détection de l'espace roulable. Contrairement à Bush et Debes (1998); Zhao-Zheng *et al.* (2009), les objets en mouvement dans la région d'intérêt sont filtrés à l'aide d'une soustraction d'arrière-plan et la précision du système est étudiée vis-à-vis des caractéristiques de la caméra employée.

1.2. Détection de la présence de brouillard et de pluie

Dans la littérature traitant de la vidéosurveillance, la détection de brouillard n'est pas abordée explicitement. Généralement, elle s'effectue indirectement à l'aide d'un simple seuil sur la distance de visibilité (cf. paragraphe précédent). Dans le domaine de la météorologie routière, un seuil de 400 m est utilisé de façon standard (AFNOR, 1998). Dans le domaine de la météorologie aérienne, c'est un seuil de 1 000 m qui est utilisé. Ces distances sont les traductions en termes de distance d'une durée d'anticipation en cas d'apparition d'un obstacle inattendu sur la chaussée de la route ou de la piste d'aviation. Afin de disposer d'une méthode de détection de brouillard routier par caméra fixe, nous proposons d'adapter une méthode dédiée initialement aux assistances à la conduite (Hautière, Tarel *et al.*, 2006).

La détection de pluie est également rarement abordée dans la littérature. Les travaux existants se focalisent davantage sur la segmentation de gouttes de pluie pour des applications de rendu d'images (Hase *et al.*, 1999; Zhang *et al.*, 2006; Garg, Nayar, 2007; Barnum *et al.*, 2010). À cause des critères de détection utilisés, ces méthodes conduisent généralement à une sursegmentation des pixels de pluie, ainsi qu'à de nombreuses fausses détections en l'absence de pluie. Par conséquent, elles ne peuvent pas être utilisées seules pour détecter la présence de la pluie ou de neige. Pour contourner ces limitations, nous avons développé une méthode fondée sur des descripteurs locaux robustes, un histogramme global d'orientation des gouttes, ainsi qu'un suivi temporel des paramètres de celui-ci. En particulier, nous nous appuyons sur une méthode classique de soustraction d'arrière-plan pour segmenter les pixels potentiels de pluie. Cette façon de procéder peut être vue comme une généralisation de la médiane temporelle proposée par Hase *et al.* (1999), de l'algorithme temporel de classification testé par Zhang *et al.* (2006) et de la contrainte photométrique de Garg et Nayar (2007).

1.3. Organisation de cet article

L'article est organisé comme suit. Dans la première partie, nous analysons les enjeux de sécurité routière, spécifions les performances attendues du système envisagé et justifions l'approche qui en découle. Dans la deuxième partie, nous détaillons notre méthode d'estimation de la visibilité. Dans les troisième et quatrième parties, nous abordons successivement la détection du brouillard et de la pluie. Dans la cinquième partie, nous proposons une méthode de spécification de la caméra pour répondre aux exigences attendues, ainsi que les méthodes de calibrage idoines. Finalement, dans la dernière partie, nous illustrons les performances de notre système par des résultats expérimentaux et concluons.

2. Un capteur « temps présent » fondé sur une caméra de bord de voie

Aujourd'hui, les capteurs de brouillard et de pluie sont des capteurs équipés de dispositifs électro-optiques dédiés qui restent coûteux. En outre, les capteurs de brouillard existants ont des problèmes de fiabilité en cas de brouillard dense ou hétérogène. Par comparaison, le volume de mesure des caméras plus important les rend moins sensibles aux hétérogénéités du brouillard. Ensuite, il est plus simple d'ajouter des nouvelles fonctionnalités au logiciel d'analyse d'images d'un système existant de vidéosurveillance du trafic routier. De cette façon, le gestionnaire routier n'a pas de matériel supplémentaire à installer et à maintenir sur le bord de la route. Dans le cas d'une installation nouvelle, multiplier les fonctions supportées par les caméras permet d'en réduire les coûts d'installation et de maintenance puisque les bénéfices sont supérieurs. Pour ces raisons, nous avons choisi de développer un capteur de visibilité routière en nous fondant sur l'utilisation de caméras. Il convient néanmoins de bien spécifier la caméra utilisée à cet effet.

2.1. Les requis d'un capteur de visibilité routière

La visibilité offerte à un usager en un point d'une infrastructure routière dépend à la fois de la géométrie de celle-ci, de ses propriétés photométriques, de l'éclairage et des conditions météorologiques. Selon AFNOR (1998), la visibilité routière est définie comme la visibilité horizontale déterminée à 1,2 m au-dessus de la chaussée. Elle peut être réduite à moins de 400 m par le brouillard ou les précipitations. Quatre classes de visibilité sont définies et détaillées dans le Tableau 1. Sur la base de ces définitions, un capteur de visibilité routière se doit d'affecter la distance de visibilité dans l'une de ces quatre classes et de détecter l'origine de la réduction de visibilité.

Index de la classe de visibilité	Distance de visibilité horizontale (m)
1	200 à 400
2	100 à 200
3	50 à 100
4	< 50

Tableau 1. Classes de visibilité routière

2.2. Principe général de fonctionnement

Communément, les systèmes de vidéosurveillance du trafic se fondent sur des méthodes de modélisation de l'arrière-plan de la scène, où chaque image est comparée à une référence pour identifier les objets en mouvement. À cause des changements d'illumination ou des changements à « long terme » dans la scène, il est nécessaire d'actualiser constamment ce modèle d'arrière-plan. Généralement, les constantes de temps sont choisies à une valeur proche du temps que nécessite un objet mobile pour traverser la scène. Selon la nature micro-physique des conditions météorologiques, celles-ci ont des dynamiques temporelles différentes. Le brouillard est généralement considéré comme un phénomène relativement stable (supérieur à la minute), alors que la pluie ou la neige sont des phénomènes à la dynamique temporelle plus élevée (inférieur à la seconde). Sur la base de ces considérations, nous avons choisi de nous appuyer sur un algorithme de séparation arrière-plan et avant-plan. L'arrière-plan peut ainsi être utilisé pour détecter et estimer la densité de brouillard alors que l'avant-plan, en plus de servir à détecter les objets mobiles dans la scène, est utilisé pour détecter la présence de pluie ou de neige. Dans la suite du document, nous détaillons les différents algorithmes d'analyse d'images développés pour ce faire.

3. Outils pour l'estimation de la classe de visibilité routière

3.1. Modélisation d'une caméra dans un environnement routier



Figure 1. Modélisation d'une caméra dans un environnement routier. v_h : ligne de l'image correspondant à la ligne d'horizon dans l'image

582 Traitement du signal. Volume 28 – nº 5/2011

La Figure 1 montre la modélisation d'une caméra dans un environnement routier. Dans le plan image, la position d'un pixel est donnée par ses coordonnées (u, v). Les coordonnées du centre optique de l'image sont désignées par (u_0, v_0) . θ est l'angle de tangage de la caméra, tandis que v_h représente la position verticale de la ligne d'horizon. Les paramètres intrinsèques de la caméra sont sa longueur focale f et la taille t_p d'un pixel. Nous avons également fait usage ici de $\alpha = \frac{f}{t_p}$. Sur la base de (Hautière, Tarel *et al.*, 2006), en supposant que la route est localement plane, la distance d peut être exprimée par :

$$d = \frac{\lambda}{(v - v_h)} \text{ si } v > v_h \tag{1}$$

où $\lambda = \frac{H\alpha}{\cos \theta}$ et $v_h = v_0 - \alpha \tan(\theta)$. La relation entre la distance d au sol et la distance D provenant du même point M à la caméra est la suivante :

$$D = \sqrt{H^2 \cos^2 \theta + (d - H \sin \theta)^2} \tag{2}$$

3.2. Exploitation de l'atténuation atmosphérique

Pour estimer la classe de visibilité routière, nous proposons, à l'instar des méthodes existantes (Bush, Debes, 1998; Zhao-Zheng *et al.*, 2009), d'estimer la distance à l'objet visible le plus éloigné appartenant à la surface de la route. Pour estimer si un objet est visible, nous appliquons un algorithme de calcul du contraste local, fondé sur la technique de segmentation de Köhler et détaillé dans (Hautière, Aubert, Jourlin, 2006), en lui appliquant le seuil de 5 % recommandé par la Commission internationale de l'éclairage (CIE, 1987). La carte de contraste obtenue contient alors les objets visibles dans la scène routière filmée par la caméra. En supposant une route plane, le long d'une ligne de haut en bas de la carte des contrastes locaux, les objets rencontrés se rapprochent de la caméra. Par conséquent, l'algorithme consiste à trouver le point culminant de la carte de contraste ayant un contraste local de plus de 5 %. v_c désigne la ligne image correspondante. La distance de ce point peut alors être estimé en utilisant (1), ce qui permet d'estimer la visibilité V:

$$V = \frac{\lambda}{v_c - v_h} \tag{3}$$

où v_h désigne la ligne image correspondant à l'horizon et λ désigne un paramètre de la caméra (cf. section 6). Cependant, l'image peut également contenir des objets verticaux, qui ne respectent donc pas l'hypothèse monde plan et mettent en défaut la méthode. C'est le cas dans la Figure 4(b), où les phares du véhicule sont détectés plus haut dans l'image que les éléments à la même distance appartenant à la surface de la route. Une autre étape est donc nécessaire pour filtrer les objets verticaux et estimer correctement la distance de visibilité. Cette tâche peut être réalisée en utilisant une séparation avant-plan et arrière-plan. C'est l'objet du paragraphe suivant.

3.3. Séparation avant-plan et arrière-plan

Le système doit disposer de la surface de la route pour fonctionner correctement. Grâce aux techniques de séparation avant-plan et arrière-plan, il est possible de segmenter les objets en mouvement. L'arrière-plan est ensuite utilisé pour calculer la distance de visibilité et l'avant-plan pour détecter les objets mobiles et construire l'espace roulable.

La forme la plus simple de modélisation de l'arrière-plan consiste à effectuer une moyenne temporelle des images. Une telle approche souffre de nombreux problèmes et nécessite une période d'initialisation en l'absence d'objets mobiles. En outre, elle ne peut pas faire face aux changements progressifs d'illumination de la scène. En raison des changements d'illumination et des changements à « long terme » au sein de la scène, il est nécessaire de constamment réestimer le modèle d'arrière-plan. Un certain nombre de méthodes modélisant l'arrière-plan a été proposé pour estimer ces signaux lentement variables. Cheung et Kamath (2004) ont proposé une comparaison de différentes méthodes. L'utilisation d'une mixture de gaussiennes (MoG) par pixel s'est révélée une bonne approche (Stauffer, Grimson, 2000). KaewTraKulPong et Bowden (2001) en ont proposé une variante qui est plus rapide en termes d'initialisation du modèle. C'est cette dernière que nous avons retenue pour le système. Dans celle-ci, chaque pixel de la scène est modélisé par un mélange de K distributions gaussiennes. La probabilité qu'un pixel ait une valeur X_t au temps t peut être écrite comme :

$$P(X_t) = \sum_{k=1}^{K} \omega_k \mathcal{N}(X_t | \mu_{k,t}, \sigma_{k,t})$$
(4)

où ω_k est le poids de la kième composante gaussienne notée $\mathcal{N}(X|\mu_k, \sigma_k)$ et qui s'exprime par :

$$\mathcal{N}(X|\mu_k, \sigma_k) = \frac{1}{\sigma_k \sqrt{2\pi}} e^{-\frac{1}{2}\sigma_k^{-2}(X-\mu_k)^2}$$
(5)

où μ_k est la moyenne et σ_k est l'écart type de la kième distribution. Les K distributions sont ordonnées selon leur finesse $\frac{\omega_k}{\sigma_k}$ et les B premières distributions sont utilisées comme modèle d'arrière-plan de la scène. B est estimé par :

$$B = \underset{b}{\operatorname{argmin}} \left(\sum_{j=1}^{b} \omega_j > T \right)$$
(6)

Le seuil *T* est la fraction minimale du modèle de base. En d'autres termes, il représente la probabilité minimale *a priori* d'observer un pixel d'arrière-plan. La soustraction d'arrière-plan est effectuée par le marquage comme avant-plan de tout pixel qui est plus de 2,5 écarts types éloigné de l'une des B distributions. Les différentes composantes gaussiennes sont mises à jour grâce aux équations suivantes :

$$\begin{aligned}
\omega_{k,t} &= (1 - \gamma_1)\omega_{k,t-1} + \gamma_1(M_{k,t}) \\
\mu_{k,t} &= (1 - \gamma_1)\mu_{k,t-1} + \rho X_t \\
\sigma_{k,t}^2 &= (1 - \gamma_1)\sigma_{k,t-1}^2 + \rho (X_t - \mu_{k,t})^2 \\
\rho &= \gamma_1 \mathcal{N}(X_t | \mu_{k,t}, \sigma_{k,t}) \\
M_{k,t}) &= \begin{cases} 1; \text{ si } \omega_k \text{ est la première composante à correspondre} \\
0; \text{ sinon} \end{cases}
\end{aligned}$$
(7)

où ω_k est le poids de la kième composante gaussienne. $\frac{1}{\gamma_1}$ définit la constante de temps qui détermine le changement. Seuls deux paramètres, γ_1 et T doivent être réglés.



Figure 2. Illustration du calcul d'un modèle d'arrière-plan : (a) échantillon d'une séquence vidéo de 14 secondes acquise par temps de brouillard ; (b) modèle d'arrière-plan résultant qui inclut le voile lumineux causé par le brouillard

Même si des résultats récents (Dhome *et al.*, 2010) tendent à démontrer que de nouvelles méthodes sont parfois plus performantes que celle de KaewTraKulPong et Bowden (2001) en terme de détection d'objet mobile, ce modèle d'arrière plan donne satisfaction. Cependant, rien n'interdit de substituer ce modèle, compte tenu de la modularité du système. Des exemples de réalisation sont présentés sur la Figure 2, ainsi que sur les Figure 10 et Figure 11.

4. Détection du brouillard

(

4.1. Effets visuels du brouillard

L'atténuation de la luminance dans l'atmosphère a été étudiée par Koschmieder (Middleton, 1952) qui a proposé une équation reliant la luminance apparente ou radiance L d'un objet situé à une distance d à sa valeur de luminance intrinsèque L_0 :

$$L = L_0 e^{-kd} + L_f (1 - e^{-kd})$$
(8)

où k est le coefficient d'extinction de l'atmosphère et L_f la luminance du ciel. En présence de brouillard, il correspond à la luminance du fond sur lequel la cible peut

être détectée (cf. Figure 3). Sur la base de cette équation, Duntley (Middleton, 1952) a mis au point une loi d'atténuation du contraste, selon laquelle un objet situé à proximité présentant un contraste C_0 avec l'arrière-plan est perçu à une distance d avec le contraste suivant :

$$C = \left(\frac{L - L_f}{L_f}\right)e^{-kd} = C_0 e^{-kd} \tag{9}$$

Cette expression sert de base pour la définition d'une dimension standard appelée « distance de visibilité météorologique » V_{met} , à savoir la plus grande distance à laquelle un objet noir ($C_0 = -1$) de dimension appropriée peut être vu sur fond de ciel à l'horizon, avec un contraste seuil fixé à 5 % (CIE, 1987). La distance de visibilité météorologique est donc une dimension standard qui caractérise l'opacité d'une couche de brouillard. Cette définition donne l'expression suivante :

$$V_{met} = -\frac{\ln(0,05)}{k} \approx \frac{3}{k} \tag{10}$$



Figure 3. La luminance du brouillard est due à la diffusion de la lumière du jour. La lumière venant du soleil est dispersée par les particules atmosphériques vers la caméra. Celle-ci augmente avec la distance. La lumière émanant de l'objet est atténuée par la diffusion le long de la ligne de vue. La transmission directe quant à elle décroît avec la distance

En supposant la fonction de réponse de la caméra linéaire, on peut assimiler les intensités à des luminances. L'intensité *I* d'un pixel peut s'exprimer par :

$$I = Re^{-kd} + A_{\infty}(1 - e^{-kd})$$
(11)

où R est l'intensité intrinsèque du pixel, c'est-à-dire l'intensité correspondant à la valeur de luminance intrinsèque de l'objet correspondant dans la scène et A_{∞} l'intensité du ciel à l'horizon.

4.2. Détection et caractérisation du brouillard

À la suite d'un changement de variable d selon v, d'après (1), (11) devient :

$$I(v) = R - (R - A_{\infty})(1 - e^{-\frac{k\lambda}{v - v_h}})$$
(12)

En prenant la dérivée seconde de I par rapport à v, on obtient ce qui suit :

$$\frac{\partial^2 I}{\partial v^2}(v) = k\varphi(v)e^{-\frac{k\lambda}{v-v_h}}\left(\frac{k\lambda}{v-v_h}-2\right)$$
(13)

où $\varphi(v) = \frac{\lambda(R-A_{\infty})}{(v-v_h)^3}$. L'équation $\frac{\partial^2 I}{\partial v^2} = 0$ a deux solutions. La solution k = 0 n'est d'aucun intérêt. La seule solution utile est donnée dans (14) :

$$k = \frac{2(v_i - v_h)}{\lambda} \tag{14}$$

où v_i désigne la position du point d'inflexion de I(v). De cette manière, si $v_h > v_i$, du brouillard diurne est détecté et le paramètre k est obtenu. Nous déduisons V_{met} à l'aide de (10) :

$$V_{met} = \frac{3\lambda}{2(v_i - v_h)} \tag{15}$$

Pour mettre en œuvre cette propriété mathématique, la surface de la route qui est présente du pied de la caméra à l'horizon est appropriée. Pour segmenter celle-ci, on recherche dans l'image la région qui possède un minimum de variation de gradient de ligne à ligne. Celle-ci est identifiée grâce à un processus de croissance de région dont les germes sont situés en bas de l'image. Une bande verticale est alors sélectionnée dans la zone détectée. Enfin, en prenant l'intensité médiane de chaque ligne, on estime la variation verticale de l'intensité de l'image et par la suite la position du point d'inflexion. Les détails de la méthode sont donnés dans (Hautière, Tarel *et al.*, 2006) dans le cas d'une caméra embarquée à bord d'un véhicule. Il a été appliqué à une scène routière. Le résultat est illustré sur la Figure 4(a). Même s'il y a de nombreux véhicules dans l'image originale, la méthode est capable de les contourner et de détecter la présence de brouillard, ainsi que d'estimer sa densité. Néanmoins, l'utilisation de l'image d'arrière-plan permet de faciliter le travail de l'algorithme et surtout permet de stabiliser ses sorties. Un exemple de réalisation est présenté sur la Figure 10(e) dans la section dévolue aux résultats expérimentaux.

5. Détection de la présence de pluie

5.1. Principe

Pour détecter la pluie, les différentes composantes en mouvement dans la scène sont extraites de l'image d'avant-plan. Nous construisons ensuite un histogramme d'orientation de ces différentes composantes (le HOS). Celui-ci est modélisé par la mixture d'une loi uniforme et d'une loi gaussienne. Un algorithme de maximisation de l'espérance permet ensuite d'en estimer les différents paramètres. À l'aide d'un filtre de Kalman, nous en effectuons un suivi temporel et cherchons la présence d'un éventuel pic stable dans le temps (Bossu *et al.*, 2009). Un exemple de réalisation est présenté sur la Figure 11.



Figure 4. Algorithmes de détection appliqués à une scène de brouillard :
(a) la courbe verticale représente l'instantiation de la loi de Koschmieder. La ligne horizontale représente l'estimation de la distance de visibilité. Les segments verticaux représentent les limites de la bande verticale analysée ;
(b) carte des contrastes locaux de plus de 5 %

5.2. Construction et modélisation du HOS

Sur l'image d'avant-plan, deux traitements complémentaires sont appliqués successivement pour segmenter les composantes potentielles de pluie. Le premier traitement consiste à sélectionner les pixels plus clairs que le fond, comme proposé par Garg et Nayar (2007). Le deuxième, à l'aide d'un algorithme d'étiquetage en composantes connexes, consiste à éliminer les objets ayant une taille trop grande pour correspondre à une goutte de pluie. Une méthode de dimensionnement d'un tel gabarit est proposée par Brewer et Liu (2008). Ensuite, pour chaque région *i* conservée de l'image d'avantplan, nous calculons son orientation μ_i à laquelle nous associons un poids w_i et une incertitude $d\mu_i$ liés à ses dimensions en utilisant les moments géométriques d'ordre 0, 1 et 2 (Safee-Rad *et al.*, 1992). Un histogramme d'orientation $h(\theta)$ pour $\theta \in [0, \pi]$ est alors calculé sur l'ensemble des éléments restant de l'image de premier plan par une technique de type Parzen :

$$h(\theta) = \sum_{i=1}^{P} w_i \mathcal{N}_i(\theta | \theta_i, d\theta_i)$$
(16)

avec P le nombre de blobs de l'image.

Il arrive souvent que l'image des objets en mouvement soit un mélange de segments de pluie et de bruit. La distribution de l'orientation des segments de pluie, par hypothèse, suit une loi normale alors que la distribution d'orientation du bruit suit une loi uniforme. Un modèle pour représenter l'histogramme h obtenu est donc la mixture d'une loi normale et uniforme notée comme suit :

$$y(\theta) \sim \Pi \mathcal{N}(\theta | \mu, \sigma) + (1 - \Pi) \mathcal{U}_{[0,\pi]}(\theta)$$
(17)

où θ est un angle dans $[0, \pi]$ et $y(\theta)d\theta$ est la probabilité d'observer $[\theta, \theta + d\theta]$. Il correspond à la surface de la loi gaussienne $\mathcal{N}(\theta|\mu, \sigma)$ de moyenne μ et d'écart type σ . $\mathcal{U}_{[0,\pi]}$ désigne la distribution uniforme sur l'intervalle $[0,\pi]$.

5.3. Estimation et suivi temporel des paramètres du HOS

Afin d'évaluer les paramètres de ces deux lois, nous utilisons un algorithme de maximisation de l'espérance (EM), par exemple (Dean, Raftery, 2005). L'algorithme usuel suppose un échantillonnage aléatoire. L'angle θ est quantifié comme $(\theta_i)_{i=1...N}$ et pour chaque θ_i nous avons y_i échantillons. De fait, nous avons adapté l'algorithme pour prendre en compte le fait que θ est quantifié. L'algorithme est toujours itératif. La kième étape d'espérance est donnée par :

$$\hat{z}_{i}^{k} = \frac{(1 - \hat{\Pi}^{k-1})\mathcal{U}_{[0,\pi]}(\theta_{i})}{\hat{\Pi}^{k-1}\mathcal{N}(\theta_{i}|\hat{\mu}^{k-1}, \hat{\sigma}^{k-1}) + (1 - \hat{\Pi}^{k-1})\mathcal{U}_{[0,\pi]}(\theta_{i})}$$
(18)

où i = 1, ..., N.

La kième étape de maximisation est donnée par :

$$\hat{\mu}^{k} = \frac{\sum_{i=1}^{N} (1 - \hat{z}_{i}^{k}) \theta_{i} y_{i}}{\sum_{i=1}^{N} (1 - \hat{z}_{i}^{k}) y_{i}}$$

$$(\hat{\sigma}^{k})^{2} = \frac{\sum_{i=1}^{N} (1 - \hat{z}_{i}^{k}) (\theta_{i} - \hat{\mu}^{k})^{2} y_{i}}{\sum_{i=1}^{N} (1 - \hat{z}_{i}^{k}) y_{i}}$$

$$\hat{\Pi}^{k} = \frac{\sum_{i=1}^{N} (1 - \hat{z}_{i}^{k}) y_{i}}{\sum_{i=1}^{N} y_{i}}$$
(19)

Pour initialiser l'algorithme, $\hat{\mu}^0$, $\hat{\sigma}^0$ et $\hat{\Pi}^0$ doivent être approchés. Ils le sont en calculant la valeur de la médiane horizontale de l'histogramme que l'on soustrait à chaque échantillon pour ne garder que la partie supérieure de la loi gaussienne.

Finalement, après convergence de l'algorithme, on vérifie si la distribution ajustée est en accord avec la distribution observée à l'aide d'un test d'adéquation. Le test compare la fonction de distribution cumulée de l'histogramme observée $F_o(x)$ à la distribution cumulée $F_e(x)$ obtenue par l'algorithme EM. La distance maximale entre les fonctions observée et ajustée est calculée comme suit :

$$D = \sup_{x \in [0,\pi]} |F_e(x) - F_o(x)|$$
(20)

Si cette distance excède une distance seuil D_c , l'ajustement n'est pas bon. Dans le cas contraire, l'image est conservée pour la suite du traitement qui examine la cohérence temporelle du modèle.

5.4. Décision sur la présence de pluie

La décision sur la présence ou l'absence de pluie est prise en se fondant sur les images où le modèle est valide, c'est-à-dire les images où le test d'adéquation est positif. Ensuite, si la pluie est présente dans la scène, l'aire de la distribution normale estimée par l'algorithme EM doit rester assez élevée dans le temps. S'il ne pleut pas, l'aire de la distribution normale doit rester faible dans le temps.

Pour chaque image où le test d'adéquation au modèle est positif, un filtre de Kalman (Kalman, Bucy, 1961), utilisé pour calculer un modèle temporellement lissé du HOS, est mis à jour. Si le test est négatif, le filtre n'est pas mis à jour. En effet, en l'absence de rafales de vent, l'orientation de la pluie est relativement stable dans le temps. L'objectif du filtre de Kalman est de tirer parti de cette stabilité temporelle en lissant les paramètres du HOS et d'être robuste en présence d'images où le nombre de gouttes détectées est faible (à cause de nombreux mobiles dans la scène par exemple). Inversement en l'absence de pluie, les objets détectés ne présentent pas une orientation stable temporellement, ce qui empêche le filtre de converger correctement, ce qui réduit d'autant le nombre de faux positifs.

Enfin, un seuil sur l'aire de la distribution normale lissée est utilisé pour prendre la décision sur la présence ou l'absence de pluie. Si l'aire est supérieure à un seuil noté A_N , la pluie est réputée être présente dans la scène. Si ce n'est pas le cas, on ne détecte pas de pluie. Dans la section 7, dévolue aux résultats expérimentaux, nous montrons l'effet de chaque étape du processus de décision grâce à une validation expérimentale complète.

6. Spécification et calibrage de la caméra

La caméra qui va alimenter les algorithmes de détection doit maintenant être précisée. Pour cela, ses paramètres intrinsèques et extrinsèques doivent être choisis. Par la suite, la caméra doit être calibrée et les hypothèses qui ont été faites pour mettre au point les méthodes d'estimation doivent être vérifiées.

6.1. Spécification de la caméra

Grâce à l'équation (1), la surface couverte par un pixel à la distance d peut être calculée :

$$\Delta(d) = \frac{\lambda}{\lfloor v_h + \frac{\lambda}{d} \rfloor - v_h} - \frac{\lambda}{\lceil v_h + \frac{\lambda}{d} \rceil - v_h}$$
(21)

où $\lfloor x \rfloor$ désigne la partie entière de x et $\lceil x \rceil$ l'entier supérieur ou égal à x.

Premièrement, nous proposons que cette surface représente moins de 10 % de d_{max} :

$$\Delta(d_{max}) < 0, 1d_{max} \tag{22}$$

Deuxièmement, le système doit détecter le brouillard. Sur la base de la section 4.2, la ligne d'horizon doit être dans l'image. Troisièmement, le système doit pouvoir détecter des visibilités inférieures à d_{min} . Pour fonctionner correctement, l'emplacement correspondant du point d'inflexion doit se situer dans la partie supérieure de

l'image, c'est-à-dire que v_i doit être inférieure à v_0 . Par conséquent, les contraintes supplémentaires sur le capteur sont les suivantes :

$$v_h > 0 \tag{23}$$

$$v_h + \frac{3\lambda}{d_{min}} > v_0 \tag{24}$$

D (pouce)	1/3	2/3	1/2
<i>H</i> (m)	5-6	5-6	6
f (mm)	4,2	4,8	4,5
$t_p (\mu m)$	4,65	6,45	4,65
$dim_y(pix)$	1040	1024	1360
θ (degrés)	31-38	29-64	28-29
$\chi = \frac{f}{t_p \cos(\theta)}$	1023	851	1096

Tableau 2. Solutions techniques



Figure 5. Erreur relative théorique entre la distance sur le terrain et la distance réelle entre un point de scène et la caméra

Des contraintes (23) et (24), l'inéquation suivante par rapport à θ est obtenue :

$$\sin^{-1}\left(\frac{H}{3d_{min}}\right) < \theta < \tan^{-1}\left(\frac{v_0}{\alpha}\right) \tag{25}$$

Les solutions admissibles de (25) peuvent alors être utilisées pour résoudre l'équation (22). Selon les requis énoncés dans le paragraphe 2.1, le système doit pouvoir détecter des visibilités comprises entre 50 m et 400 m, ce qui signifie $d_{min} = 50$ m et $d_{max} = 400$ m. Des solutions techniques sont données dans le Tableau 2. Pour choisir entre les différentes solutions, nous avons calculé le paramètre noté χ qui exprime le grossissement de la caméra par rapport à son angle de tangage. Nous avons acquis une caméra correspondant à la troisième solution du Tableau 2. Grâce à ces données techniques, nous sommes en mesure de calculer l'équation (2) et de tracer la Figure 5 qui exprime l'erreur relative entre la distance au sol et la distance réelle entre un point de

la scène et la caméra. Sur la base de cette courbe, compte tenu que les deux distances sont très proches au-delà de 50 m, nous pouvons considérer que $D \approx d$. Ce résultat est important dans le cas du brouillard car l'atmosphère n'est pas transparente. Dans le cas où l'atmosphère est transparente, ce résultat importe moins.

6.2. Calibrage de la caméra

6.2.1. Calibrage géométrique

Dans le paragraphe précédent, la caméra a été supposée parfaite. Une première tâche consiste donc à vérifier si la caméra respecte les hypothèses énoncées précédemment et à estimer ses différents paramètres. Tout d'abord, l'objectif d'une caméra présente habituellement une distorsion importante, notamment dans le cas d'une courte focale comme la nôtre. Dans le modèle suivant, les deux premiers termes de distorsion radiale sont considérés. Soit (u, v) les coordonnées du pixel idéal (non observables dans l'image) et (\breve{u}, \breve{v}) les coordonnées réelles du même pixel dans l'image observée. Ces points sont la projection idéale de points de la scène à l'aide du modèle sténopé. De même, (x, y) et (\breve{x}, \breve{y}) sont les coordonnées idéales (sans distorsion) et réelles (déformées) en coordonnées images normalisées. Nous avons :

$$\ddot{x} = x + x \left[k_1 (x^2 + y^2) + k_2 (x^2 + y^2)^2 \right] \breve{y} = y + y \left[k_1 (x^2 + y^2) + k_2 (x^2 + y^2)^2 \right]$$
(26)

où k_1 et k_2 sont les coefficients de la distorsion radiale. Le centre de la distorsion radiale est le même que le point principal (u_0, v_0) . De $\breve{u} = u_0 + \alpha \breve{x} + c\breve{y}$ et $\breve{v} = v_0 + \beta \breve{y}$, nous déduisons :

$$\vec{u} = u + (u - u_0) \left[k_1 (x^2 + y^2) + k_2 (x^2 + y^2)^2 \right] \vec{v} = v + (v - v_0) \left[k_1 (x^2 + y^2) + k_2 (x^2 + y^2)^2 \right]$$
(27)

La procédure classique de calibrage consiste à prendre des images d'un échiquier dans des orientations et des positions différentes. La détection des caractéristiques (généralement les coins) dans les images permet d'estimer les paramètres d'homographie entre le plan de l'échiquier et le plan de l'image, et d'en déduire les paramètres intrinsèques de la caméra (dont les paramètres de distorsion) à l'aide de techniques d'optimisation non linéaire (Z. Zhang, 2000). Le logiciel CalLab a été utilisé pour effectuer cette procédure (Strobl *et al.*, s. d.). Des exemples de résultats sont présentés sur la Figure 6.

Ayant les paramètres intrinsèques, les paramètres extrinsèques doivent être estimés. En plus de l'estimation de la position de la ligne d'horizon v_h , une simple estimation de la valeur du paramètre λ permet de calibrer la caméra. Pour effectuer cette étape, connaître la distance réelle $d_1 - d_2$ entre deux points et leurs coordonnées v_1 et v_2 dans l'image s'avère suffisant. En vertu de (1), nous sommes en mesure d'obtenir ce qui suit :

$$\lambda = \frac{d_1 - d_2}{\frac{1}{v_1 - v_h} - \frac{1}{v_2 - v_h}}$$
(28)



Figure 6. Correction de la distorsion radiale de la caméra spécifiée: (a) échiquier original; (b) échiquier corrigée; (c) image de la route d'origine; (d) image de la route corrigée

6.2.2. Calibrage radiométrique

La radiométrie de la caméra doit maintenant être calibrée. La fonction de réponse de la caméra a pour l'instant été supposée linéaire. En utilisant le logiciel RASCAL (Mitsunaga, Nayar, 1999) et différentes images d'une mire GretagMacbeth Color-Checker DC prises avec des temps d'intégration différents, nous avons pu estimer la fonction de réponse de la caméra de notre caméra. Cette fonction est linéaire de sorte que nous pouvons maintenant considérer que l'intensité des pixels peut être assimilée à une luminance. Toutefois, cette caméra est une caméra CCD 8-bit, de sorte que sa dynamique est assez limitée. En outre, elle ne dispose ni d'un connecteur pour autoiris, ni d'un algorithme d'auto-exposition (AE). Par conséquent, les images produites par cette caméra sont saturées ou sous-exposées en permanence dès lors qu'elle est utilisée en milieu extérieur. Pour optimiser la qualité d'image, nous avons développé notre propre algorithme AE comme suit. Celui-ci est composé de deux étapes. Une première étape consiste à calculer le temps d'exposition optimal α^* à l'initialisation du capteur, ce en maximisant l'intégrale de l'histogramme haute dynamique dans les limites de la plage de fonctionnement de la caméra (voir Figure 7) :

$$\alpha^* = \operatorname*{argmax}_{\alpha} \int_{l_{min}}^{l_{max}} p(l) dl \tag{29}$$

Une deuxième étape consiste à contrôler cette valeur au cours du temps. L'algorithme de commande suivant est utilisé :

$$\begin{cases} \alpha_0 = \alpha^* \\ |\alpha_{t+1} - \alpha_t| = g[I_m(t-1) - I_m(t)]. \end{cases}$$
(30)

où g est un correcteur proportionnel avec les propriétés suivantes :

x

$$g(0) = 0$$

$$g'(x) = 0$$

$$\lim_{d \to +\infty} g(x) = ax + b$$
(31)

x représente l'écart absolu entre la moyenne de l'image courante et l'image précédente. Ce correcteur est conçu de façon à calculer une correction du temps de pose uniquement dans le cas où cet écart est supérieur à un seuil donné. Une solution pour g ainsi que de plus amples détails sont donnés dans (Hautière *et al.*, 2009). Le vignettage, quant à lui, n'est pas corrigé car il n'influe que très peu sur l'intensité au centre de l'image, qui est notre principale zone d'intérêt.



Figure 7. Histogramme haute dynamique p(l) d'une scène

7. Validation expérimentale

7.1. Estimation de la classe de visibilité routière

7.1.1. Vérification des spécifications de la caméra

Tout d'abord, une expérience a été réalisée pour vérifier si nous sommes capables d'atteindre les spécifications avec la caméra retenue. Dans ce but, des cônes ont été placés sur une section plane de route suivant le dispositif expérimental schématisé sur la Figure 8(a). En utilisant l'équation (28) et les positions des différents cônes, nous sommes capables de calibrer géométriquement la caméra :

$$(\lambda, v_h) = \underset{n=1..7}{\operatorname{argmin}} \sqrt{\sum_{i=1}^n \left(d_i - \frac{\lambda}{v_i - v_h} \right)^2}.$$
(32)

L'erreur quadratique est tracée sur la Figure 8(b) en fonction du nombre de paires de points pris en compte dans le processus de calibrage. En ne prenant que trois paires de points, soit quatre points sur le terrain, nous sommes en mesure d'obtenir une erreur quadratique qui est inférieure à 2 % à d = 136 m. Cette erreur est en accord avec l'erreur théorique à la même distance représentée sur la Figure 8(c) et permet d'envisager un protocole de calibrage simple à mettre en œuvre sur route ouverte.



Figure 8. Vérification expérimentale des spécifications de la caméra : (a) dispositif expérimental ; (b) erreur quadratique du calibrage par rapport au nombre de paires de points considérés ; (c) erreur intrinsèque théorique sur l'estimation de la distance au sol en raison de la taille en pixels

7.1.2. Mise en œuvre du système

Le système complet d'acquisition a été installé dans une camionnette équipée d'un mât pneumatique durant l'hiver 2009. Grâce à l'utilisation de ce dispositif, nous avons acquis des séquences d'images en présence de brouillard au lever du jour. Des images issues d'un épisode de brouillard sont présentées sur la Figure 9(a). La distance de visibilité a été estimée et est représentée sur la Figure 9(b) en fonction du temps. La classe de visibilité routière est déduite et est représentée sur la Figure 9(c) en fonction du temps. Comme on peut le voir, la distance de visibilité augmente ainsi que l'illumination globale de la scène. Le comportement du système est cohérent, sauf vers 10 h, lorsque la visibilité redescend en dessous de 400 m. Cela est dû au fait que le temps d'exposition est momentanément trop élevé, ce qui a pour conséquence une surexposition des images et donc des contrastes détériorés. L'algorithme AE parvient

rapidement à proposer un nouveau réglage et la visibilité augmente à nouveau jusqu'à atteindre sa valeur maximale en absence de brouillard, qui est estimée comme supérieure à 400 m, ce que l'on souhaitait.



Figure 9. Mise en œuvre du système d'acquisition d'images conçu : (a) exemples d'images acquises lors d'un épisode de brouillard; (b) distance de visibilité estimée pendant cet épisode de brouillard; (c) classe de visibilité routière correspondante

7.2. Détection du brouillard

Le système comprenant la détection du brouillard et l'estimation de la distance de visibilité a été testé sur une même intersection urbaine par différentes conditions météorologiques. Nous avons utilisé une heure de brouillard et une heure de différentes autres conditions météorologiques de jour (nuageux, ensoleillé, ombres portées). Des échantillons des séquences vidéo sont présentées sur la Figure 10, accompagnés d'illustrations du processus temporel de construction de l'espace roulable. De bons résultats ont été obtenus en termes de détection de brouillard sur ces séquences, même si celles-ci étaient bruitées (les séquences ont été acquises en 1995 et numérisées à partir de cassettes VHS). Les résultats sont résumés dans le Tableau 3. On peut voir une précision du système proposé égale à 100 %. La distance de visibilité a également été estimée. Cependant, comme les paramètres de caméra ne sont pas connus, le calibrage est approximatif. Nous ne présentons donc pas de courbe de mesure, contrairement au paragraphe précédent.







Figure 10. Détection du brouillard et estimation de la visibilité par traitement d'images issues d'une caméra de surveillance du trafic urbain : (a) intersection urbaine par beau temps pendant la journée ; (b) même intersection par temps de brouillard ; (c) espace roulable déterminé au fur et à mesure par l'accumulation temporelle de l'image d'avant-plan ; (d) ligne d'horizon et estimation de la distance de visibilité (ligne inférieure) ; (e) détection de brouillard (point d'inflexion matérialisé par la ligne noire)

Tableau 3. Résultat de l'algorithme de détection du brouillard avec 55 000 images

		Classe attribuée	
		Brouillard	Sans brouillard
Classe initiale	Brouillard	25 000	0
	Sans brouillard	0	30 000

7.3. Détection de pluie et de neige

Pour évaluer la capacité de l'algorithme à détecter correctement la présence de pluie, nous avons utilisé, entre autres, deux vidéos différentes de la même scène avec et sans pluie. Elles ont été acquises au même endroit et présentent une artère urbaine contenant beaucoup d'objets en mouvement comme des voitures, tramways, piétons, etc. Chaque séquence vidéo est constituée de 6 000 images. Un échantillon de la scène en présence de pluie est présenté sur la Figure 11(a). Tout d'abord, une évaluation qualitative de la méthode est proposée. Deuxièmement, une évaluation quantitative est ensuite effectuée. Une matrice de confusion (Kohavi, Provost, 1998) ainsi que la courbe ROC (Swets, 1988) sont utilisées pour évaluer la méthode. Dans notre cas, pour un problème à deux classes (présence et absence de pluie), la matrice de confusion est exprimée avec quatre termes (Tableau 4). TP est le nombre de vrais positifs. FP est le nombre de faux positifs. TN est le nombre de vrais négatifs. FN est le nombre de faux négatifs.

Tableau 4. Matrice de confusion pour la détection de présence / absence de pluie

		Classe attribuée	
		Pluie	Pas pluie
Classe initiale	Pluie	TP	FN
	Pas pluie	FP	TN

À partir de cette matrice, deux termes sont habituellement définis : le taux de vrais positifs $TPR = \frac{TP}{TP+FN}$ et le taux de faux positifs $FPR = \frac{FP}{FP+TN}$. Les courbes ROC sont obtenues en traçant le TPR en fonction du FPR pour différentes valeurs des paramètres du détecteur considéré. Si les échantillons positifs et négatifs possèdent un effectif du même ordre de grandeur, la précision (AC) du détecteur peut s'exprimer par :

$$AC = \frac{TP + TN}{TP + FP + FP + TN}.$$
(33)

Dans nos tests, nous essayons de maximiser la précision en faisant varier les paramètres du processus de décision.

7.3.1. Résultats qualitatifs

Le processus de décision a été obtenu après de nombreux tests. En effet, il est relativement facile de détecter la présence de pluie dans des séquences d'images. Il est, en revanche, plus difficile de ne pas détecter la présence de la pluie en présence de bonnes conditions météorologiques. Le test d'adéquation est utile pour détecter les images qui ne suivent pas le modèle normale-uniforme. Toutefois, par temps clair, des contours dont l'orientation suit celle d'une distribution normale peuvent être détectés sur une seule image. Ces détections sont des événements ponctuels et possèdent généralement des orientations différentes dans les images suivantes. En présence de pluie, l'orientation des gouttes de pluie est plus cohérente. Par conséquent, un filtre temporel permet de distinguer les deux événements. Enfin, une distribution uniforme est susceptible d'être assimilée à une distribution plane normale. Pour éviter ce genre d'erreur, un seuil sur la taille de la distribution normale est très utile. La combinaison de ces trois critères donne les meilleurs résultats comme indiqué dans les tests quantitatifs.



Figure 11. Détection de pluie appliquée à une vidéo : (a) image originale ; (b) détection des objets en mouvement par soustraction de l'image d'arrière-plan à l'image courante ; (c) segmentation de pixels de pluie obtenue par l'application des règles de taille et de photométrie ; (d) histogramme d'orientation des gouttes de pluie (HOS) par accumulation de l'orientation des différents composantes connexes calculée par la méthode des moments géométriques. La décision sur la présence de pluie est prise en se fondant sur la stabilité temporelle du HOS

7.3.2. Résultats quantitatifs

Pour voir l'effet de chacun des paramètres du processus de décision, nous avons tracé la courbe ROC pour différentes configurations, de la plus simple à la plus complexe. Tout d'abord, nous n'utilisons que le test d'adéquation, de manière à définir la valeur du seuil critique D_c . La courbe verte (+) de la Figure 12 donne la courbe ROC du détecteur de pluie pour différentes valeurs de D_c . Le meilleur résultat est obtenu pour $D_c = 0,06$, où TPR = 73 % et FPR = 55 %, ce qui correspond à une précision AC = 59 %. La matrice de confusion correspondante est donnée dans le Tableau 5.

		Classe attribuée	
		Pluie	Pas pluie
Classe initiale	Pluie	4361	1638
	Pas pluie	3289	2709

Tableau 5. Résultats obtenus à l'aide du seul test d'adéquation

Deuxièmement, nous utilisons le test d'adéquation associé à un seuil sur l'aire de la distribution normale. La courbe bleue (o) de la Figure 12 donne la courbe ROC du détecteur de pluie pour différentes valeurs du seuil A_N . Le meilleur résultat est obtenu pour $D_c = 0,06$ et $A_N = 0,4$, où TPR = 74 % et FPR = 7 %, ce qui correspond à une précision AC = 84 %. La matrice de confusion correspondante est donnée dans le Tableau 6.



Figure 12. Courbe ROC pour différents niveaux de complexité du processus de décision sur la présence de pluie : la courbe (+) montre les effets du seul test d'adéquation, la courbe (o) montre l'effet du test d'adéquation couplé au seuil A_N et la courbe (*) montre l'effet du processus complet (avec le suivi temporel) pour différentes valeurs du seuil A_N

Tableau 6. Résultats obtenus à l'aide du test d'adéquation couplé avec le seuil A_N

	Classe attribuée		e attribuée
		Pluie	Pas pluie
Classa initiala	Pluie	4419	1581
Classe Illitiale	Pas pluie	396	5603

Troisièmement, nous utilisons le processus de décision complet. Par rapport à la configuration précédente, nous avons donc ajouté un filtre de Kalman entre le test d'adéquation et le test sur A_N . La courbe (*) de la Figure 12 donne la courbe ROC du détecteur de pluie pour différentes valeurs du seuil A_N . Le meilleur résultat est obtenu pour $D_c = 0,06$ et $A_N = 0,35$, où TPR = 97 % et FPR = 7 %, ce qui correspond à une précision AC = 95 %. La matrice de confusion correspondante est donnée dans le Tableau 7. Dans ces tests, les paramètres du filtre de Kalman sont les

suivants : la variance du bruit de processus est égal à 0,01 et la variance du bruit de mesure est égal à 0,1. Le réglage de ces paramètres a été réalisé de façon empirique, à nouveau en maximisant la précision du détecteur de pluie. À la vue des différents tests réalisés, la sensibilité à ces paramètres n'est pas très importante. Les résultats définitifs sont donc tout à fait satisfaisants.

Tableau 7. Résultats de détection obtenus à l'aide du processus de décision complet

		Classe attribuée	
		Pluie	Pas pluie
Classe initiale	Pluie	5790	210
	Pas pluie	396	5603

Malgré une précision de 95 %, certaines erreurs subsistent et peuvent être expliquées. Dans plusieurs images de la séquence vidéo, de nombreux objets en mouvement (piétons, voitures, tramway) sont simultanément présents dans la scène, ce qui fait apparaître de nombreuses composantes de bruit après le processus de filtrage. Dans le même temps, la surface utile pour la détection de la pluie est réduite, ce qui rend la pluie plus difficile à détecter. Cela explique le nombre de faux négatifs. Dans d'autres cas, quand il ne pleut pas, il arrive parfois que le bruit soit structuré avec la même orientation pendant quelques images (artefacts causés par exemple par la compression ou le sous-échantillonnage des images). Cela explique le nombre de faux positifs.

Par ailleurs, la méthode a été testée avec succès sur d'autres vidéos acquises par différentes conditions météorologiques : pluie, orage, neige, etc. En revanche, la méthode n'est pas capable de détecter les pluies fines, mais cela vient principalement du fait qu'il est difficile de filmer les traînées de pluie quand celle-ci est peu intense. Nous avons mis un exemple de détection de neige sur la Figure 13.



Figure 13. Illustration de la détection de neige : (a) extrait de la séquence vidéo ; (b) HOS correspondant

8. Conclusion et perspectives

La présence d'une distance de visibilité réduite sur un réseau routier (brouillard dense, pluie forte, etc.) affecte la sécurité et devrait déclencher de fait une réduction des limites de vitesse légales. Dans cet article, en se fondant sur une norme de météorologie routière (AFNOR, 1998), nous présentons un système de détection et caractérisation par caméra de conditions météorologiques critiques pour la sécurité routière. Le système proposé estime la classe de visibilité routière et détecte également quand la réduction de visibilité est causée par du brouillard ou de la pluie. Il nécessite uniquement un calibrage précis de la caméra sans phase d'apprentissage préalable. Contrairement aux méthodes précédentes, le système tient compte de la structure de la scène 3-D et filtre les objets en mouvement dans la région d'intérêt par l'utilisation d'une méthode de soustraction d'arrière-plan. L'étude de la sensibilité des méthodes sous-jacentes conduit à une spécification des caractéristiques de la caméra requise pour le système. Le calibrage du système est étudié et les différents composants du système sont évalués expérimentalement à l'aide de séquences vidéos acquises en présence de différentes conditions météorologiques. Dans l'avenir, nous envisageons de tester notre système, globalement et à plus grande échelle, en partenariat avec des gestionnaires routiers, afin de compléter les solutions existantes de surveillance du trafic routier.

Bibliographie

- AFNOR. (1998). Road meteorology gathering of meteorological and road data terminology. NF P 99-320.
- Barnum P., Narasimhan S., Kanade T. (2010). Analysis of rain and snow in frequency space. International Journal of Computer Vision, vol. 86, nº 2-3, p. 256-274.
- Bossu J., Hautière N., Tarel J.-P. (2009). Utilisation d'un modèle probabiliste d'orientation de segments pour détecter des hydrométéores dans des séquences vidéo. In XXII Colloque GRETSI, Dijon, France.
- Brewer N., Liu N. (2008). Using the shape characteristics of rain to identify and remove rain from video. In *Joint IAPR International Workshop SSPR & SPR, Orlando, USA*, vol. 5342/2009, p. 451-458. Springer.
- Bush C., Debes E. (1998). Wavelet transform for analyzing fog visibility. *IEEE Intelligent Systems*, vol. 13, n° 6, p. 66–71.
- Cheung S.-C., Kamath C. (2004). Robust techniques for background subtraction in urban traffic video. In Video Communications and Image Processing, SPIE Electronic Imaging, p. 881-892.
- CIE. (1987). International lighting vocabulary nº 17.4.
- Dean N., Raftery A. (2005). Normal uniform mixture differential gene expression detection for cDNA microarrays. *BMC Bioinformatics*, vol. 6, nº 173.
- Dhome Y., Tronson N., Vacavant A., Chateau T., Gabard C., et al. (2010). A benchmark for Background Subtraction Algorithms in Monocular Vision : A Comparative Study. In *IEEE*

international Conference on Image Processing Theory, Tools and Applications (IPTA'10). France.

- Garg K., Nayar S. (2007). Vision and rain. International Journal of Computer Vision, vol. 75, nº 1, p. 3-27.
- Hagiwara T., Ota Y., Kaneda Y., Nagata Y., Araki K. (2006). A method of processing CCTV digital images for poor visibility identification. In *85th Transportation Research Board Annual Meeting*.
- Hallowell R., Matthews M., Pisano P. (2007, January). An automated visibility detection algorithm utilizing camera imagery. In 23rd Conference on IIPS, 87th AMS Annual Meeting, San Antonio, Texas, USA.
- Hase H., Miyake K., Yoneda M. (1999). Real-time snowfall noise elimination. In *IEEE International Conference on Image Processing*, vol. 2, p. 406-409.
- Hautière N., Aubert D., Jourlin M. (2006, Septembre). Mesure du contraste local dans les images, application à la mesure de distance de visibilité par caméra embarquée. *Traitement* du Signal, vol. 23, nº 2, p. 145-158.
- Hautière N., Bigorgne E., Aubert D. (2008). Visibility range monitoring through use of a roadside camera. In *IEEE Intelligent Vehicles Symposium, Eindhoven, Netherlands.*
- Hautière N., Bossu J., Brand C. (2009). Une solution d'acquisition d'images à multiples fonctions de réponse. In XXIIeme Colloque GRETSI, Dijon, France.
- Hautière N., Labayrade R., Aubert D. (2006). Estimation of the visibility distance by stereovision: a generic approach. *IEICE Transactions on Information and Systems*, vol. E89-D, nº 7, p. 2084-2091.
- Hautière N., Tarel J.-P., Lavenant J., Aubert D. (2006, April). Automatic fog detection and estimation of visibility distance through use of an onboard camera. *Machine Vision and Applications Journal*, vol. 17, nº 1, p. 8-20.
- KaewTraKulPong P., Bowden R. (2001). An improved adaptive background mixture model for real-time tracking with shadow detection. In 2nd European Workshop on Advanced Video-Based Surveillance Systems, Kingston, UK.
- Kalman R. E., Bucy R. S. (1961). New results in linear filtering and prediction theory. Transactions of the ASME - Journal of Basic Engineering, vol. 83, p. 95-107.
- Kohavi R., Provost F. (1998). Glossary of terms. Machine Learning, vol. 30, p. 271-274.
- Kwon T. M. (2004, July). *Atmospheric visibility measurements using video cameras: Relative visibility*. Rapport technique. University of Minnesota Duluth.
- Lagorio A., Grosso E., Tistarelli M. (2008). Automatic detection of adverse weather conditions in traffic scenes. In *IEEE International Conference on Advanced Video and Signal based Surveillance*, p. 273-279.
- MacHutchon K., Ryan A. (1999). Fog detection and warning, a novel approach to sensor location. In *IEEE African Conference, Cap Town, South Africa*, vol. 1, p. 43-50.
- Middleton W. (1952). Vision through the atmosphere. University of Toronto Press.
- Mitsunaga T., Nayar S. (1999). Radiometric self calibration. In *IEEE Conference on Computer* Vision and Pattern Recognition.

- Safee-Rad R., Smith K., Benhabib B., Tchoukanov I. (1992). Application of moment and fourier descriptors to the accurate estimation of elliptical-shape parameters. *Pattern Recognition Letters*, vol. 13, nº 7, p. 497-508.
- Stauffer C., Grimson W. (2000). Learning patterns of activity using real-time tracking. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, nº 8, p. 747-757.
- Strobl K., Sepp W., Fuchs S., Paredes C., Arbter K. (s. d.). DLR CalLab and DLR CalDe, Institute of Robotics and Mechatronics, German Aerospace Center (DLR), Oberpfaffenhofen, Germany. http://www.robotic.dlr.de/callab/
- Swets J. (1988, 3 june). Measuring the accuracy of diagnostic system. *Science*, vol. 240, nº 4857, p. 1285-1293.
- Zhang, Li H., Qi Y., Leow W. K., Ng T. K. (2006). Rain removal in video by combining temporal and chromatic properties. In *IEEE International Conference on Multimedia & Expo.*
- Zhang Z. (2000). A flexible new technique for camera calibration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 22, nº 11, p. 1330-1334.
- Zhao-Zheng C., Jia L., Qi-mei C. (2009). Real-time video detection of road visibility conditions. In WRI World Congress on Computer Science and Information Engineering, p. 472-476.

Article reçu le 4/01/2011 Accepté le 6/09/2011

Nicolas Hautière est ingénieur des Travaux publics de l'État (2002), Docteur en traitement d'images de l'université Jean-Monnet de Saint-Étienne (2005). En 2006, il a intégré les effectifs du Laboratoire central des ponts et chaussées. Depuis 2009, il est responsable de domaine au sein du Laboratoire Exploitation Perception Simulateurs et Simulations (LEPSiS) de l'Ifsttar.

Jérémie Bossu a obtenu le DEA et le doctorat en instrumentation et informatique de l'image de l'université de Bourgogne respectivement en 2004 et 2007. Ses recherches sont axées sur la vision par ordinateur et dans le traitement d'image dans différents domaines comme l'agriculture de précision, la vidéo-surveillance, les transports intelligents.

Erwan Bigorgne est docteur de l'université Pierre-et-Marie-Curie (septembre 2005) en robotique. Il est actuellement en charge du pôle Vision au sein de Majority Report. Ses domaines d'intérêt incluent la segmentation fond-forme, ainsi que l'analyse, le suivi et la reconnaissance de visages.

Didier Aubert a obtenu son doctorat en 1989 à l'Institut national polytechnique de Grenoble. De 2002 à 2009, il a été responsable de l'équipe Perception du LIVIC et directeur-adjoint du LIVIC de 2007 à 2010. Il est actuellement directeur de recherche et directeur du LEPSiS (Ifsttar). Il enseigne dans des universités (Paris VI, Paris XI, Paris XII, Évry, Versailles) et dans des grandes écoles (ENSMP, ENPC, ENST).