

ÉCOLE DOCTORALE SCIENCES ET TECHNOLOGIES

Institut PRISME

THÈSE présentée par :

Tien Sy NGUYEN

Soutenue le 30 novembre 2010

Pour obtenir le grade de : **Docteur de l'Université d'Orléans**

Discipline : **Informatique**

**Extraction de structures fines sur des
images texturées : application à la détection
automatique de fissures sur des images de
surface de chaussées**

THÈSE dirigée par :

Youssef TOURE Professeur, Université d'Orléans

RAPPORTEURS :

Jean-Marc OGIER Professeur, Université de La Rochelle

Pierre BONTON Professeur, Université Blaise Pascal

JURY :

Youssef TOURE
Jean-Marc OGIER
Pierre BONTON
Mohamed SLIMANE
Rachid HARBA
Sylvie CHAMBON
Manuel AVILA
Stéphane BEGOT

Professeur
Professeur
Professeur
Professeur
Chargée de recherche
Maître de Conférences
Maître de Conférences

Université d'Orléans
Université de La Rochelle
Université Blaise Pascal
Université de Tours
Université d'Orléans
LCPC, Nantes
Université d'Orléans
Université d'Orléans

Directeur de thèse
Rapporteur
Rapporteur
Président du jury
Examineur
Co-encadrant
Co-encadrant

Remerciements

Je tiens à exprimer tout d'abord mes remerciements à Messieurs Manuel AVILA et Stéphane BEGOT, mes co-encadrants, pour leurs conseils de recherche, de rédaction mais également pour leur soutien humain.

Je tiens également à adresser mes plus vifs remerciements à mon directeur de thèse, Monsieur Youssoufi TOURE, pour avoir dirigé mes travaux et à Madame Christine ROUSSELLE, directrice de l'Institut PRISME, pour m'avoir accueilli.

J'exprime mes sincères remerciements à Monsieur Pierre BONTON et Monsieur Jean-Marc OGIER pour l'intérêt qu'ils ont bien voulu me porter en acceptant le rôle de rapporteur dans mon jury de thèse.

J'adresse toute ma reconnaissance aux membres du jury qui ont accepté d'évaluer mon travail de thèse.

Je remercie très chaleureusement Monsieur Philippe RAILLAT, directeur général de la société Vectra, pour le sujet de thèse qu'il m'a proposé, mais aussi pour son soutien financier.

Je voudrais remercier Madame Sylvie CHAMBON et Monsieur Jean DUMOULIN, chargés de recherche du Laboratoire Central Des Ponts et Chaussées, pour les échanges et la base de données qu'ils m'ont fournie. Ces échanges ont été particulièrement constructifs et valorisants pour moi.

Je tiens aussi à remercier mes collègues de l'IUT l'Indre du site de Châteauroux et de la société Vectra pour leur soutien durant ses trois années passées avec eux, mais aussi pour leur convivialité. Merci à Monsieur Jean-Christophe BARDET, directeur de l'IUT de l'Indre pour m'avoir accueilli dans son établissement.

Je remercie très chaleureusement Madame Nicole STRIDE et Monsieur Florent DUCULTY pour la relecture de mon manuscrit. Leurs remarques et leurs suggestions m'ont permis d'apporter des améliorations à la qualité de ce dernier.

Merci à Monsieur Pascal VRIGNAT, ami doctorant et collègue de bureau avec qui j'ai partagé humainement une très belle expérience. Merci pour ses encouragements.

Un remerciement particulier pour une amie très spéciale, Mademoiselle Phuong Minh NGUYEN pour nos deux ans inoubliables à Châteauroux.

Finalement j'adresse un grand merci à toute ma famille qui a toujours été présente lorsque j'en ai eu besoin, en particulier à mon frère, mon père et ma mère.

Table des matières

TABLE DES MATIERES.....	I
INTRODUCTION GENERALE.....	1
CHAPITRE 1 PROBLEMATIQUE ET ETAT DE L'ART	7
1.1 LE RELEVÉ DE DÉGRADATIONS DE SURFACE DE CHAUSSEES	9
1.1.1 <i>Dégradations de surface de chaussées</i>	9
1.1.1.1 Les dégradations de « type fissure »	10
1.1.1.2 Les autres dégradations.....	10
1.1.2 <i>Méthodologies pour le relevé de dégradations</i>	11
1.1.2.1 Inspection visuelle sur site.....	11
1.1.2.2 Inspection manuelle en laboratoire	12
1.1.2.3 Inspection automatique & semi-automatique.....	13
1.1.3 <i>Paramètres d'acquisition d'images</i>	15
1.2 ETAT DE L'ART SUR LES METHODES DE DETECTION AUTOMATIQUE DE FISSURES SUR DES IMAGES DE CHAUSSEES	17
1.2.1 <i>Généralités sur des méthodes pour la détection de défauts sur la surface des chaussées</i>	20
1.2.1.1 Hypothèses concernant la fissure.....	20
1.2.1.2 Les étapes pour la détection et la classification de défauts	21
1.2.2 <i>Segmentation</i>	22
1.2.2.1 Approches seuillages	22
1.2.2.2 Approche Morphologie.....	24
1.2.2.3 Approche basée sur le filtrage adapté	25
1.2.2.4 Approches fondées sur la transformée en ondelettes continues	27
1.2.2.5 Approches basées sur la segmentation par Champs de Markov.....	28
1.2.3 <i>Prétraitement</i>	31
1.2.4 <i>Extraction des attributs</i>	31
1.2.5 <i>Classification</i>	33
1.3 CONCLUSIONS	34
CHAPITRE 2 SEGMENTATION D'IMAGES DE LA CHAUSSEE PAR L'ANISOTROPIE CONDITIONNELLE DE TEXTURE	37
2.1 INTRODUCTION.....	39
2.2 RAPPEL SUR L'ANISOTROPIE CONDITIONNELLE DE TEXTURE	40

2.2.1	<i>Définition de la CTA</i>	40
2.2.2	<i>Mise en œuvre de la CTA par F. Roli</i>	41
2.2.2.1	Extraction du vecteur d'attributs.....	42
2.2.2.2	Estimation de la densité conditionnelle de probabilité.....	43
2.2.2.3	Méthode de détection.....	43
2.2.3	<i>Résultats et discussion</i>	44
2.2.3.1	Résultats de segmentation pour des surfaces faiblement texturées	44
2.2.3.2	Résultats de segmentation pour des surfaces fortement texturées.....	45
2.2.3.3	Conclusion.....	47
2.3	LA CTA POUR LA SEGMENTATION D'IMAGES DE CHAUSSEES	47
2.3.1	<i>Configuration de l'orientation</i>	48
2.3.2	<i>Choix d'attributs de texture et estimation de vraisemblance par une approche associée à la théorie des possibilités</i>	49
2.3.2.1	Modélisation de la texture par une source d'information imprécise	49
2.3.2.2	Degré de cohérence entre deux sources	50
2.3.2.3	Texture "sans défaut" définie localement	52
2.3.3	<i>Binarisation par seuillage à deux niveaux</i>	53
2.3.3.1	Seuillage à deux niveaux	53
2.3.3.2	Détermination automatique de seuils.....	54
2.4	ANALYSE DES RESULTATS	55
2.4.1	<i>Les vérités terrains</i>	56
2.4.1.1	Images de fissures de synthèse	56
2.4.1.2	Images de fissures réelles	56
2.4.2	<i>Critères d'évaluation</i>	57
2.4.2.1	Bonne détection, fausse alarme, détecté et non détecté	57
2.4.2.2	Critère de la distance entre classes de Delagnes [3].....	58
2.4.2.3	Proportion de Bonne Détection (PBD)	59
2.4.2.4	Précision (Pr)	59
2.4.2.5	Degré de Discontinuité (DD).....	59
2.4.3	<i>Comportement de la CTA selon la distance</i>	60
2.4.4	<i>Résultats sur l'image réelle</i>	63
2.5	CONCLUSION	65
CHAPITRE 3 FREE-FORM ANISOTROPY.....		67
3.1	INTRODUCTION.....	69
3.2	MODELISATION DE L'IMAGE ET DE LA FISSURE.....	70
3.2.1	<i>Hypothèse concernant la fissure</i>	70
3.2.2	<i>Généralités sur les graphes</i>	70
3.2.3	<i>Modélisation de l'image</i>	72
3.2.4	<i>Chemin minimum</i>	74

3.2.5	<i>Modélisation de la fissure</i>	76
3.3	FREE FORM ANISOTROPY	76
3.3.1	<i>Définition</i>	76
3.3.2	<i>Exemple de calcul de la FFA</i>	77
3.3.3	<i>Discussion sur les configurations de chemin minimum</i>	79
3.3.4	<i>Algorithmes pour trouver le chemin minimum</i>	80
3.3.4.1	Croissance de courbe	80
3.3.4.2	La recherche gloutonne.....	81
3.3.4.3	Méthode incrémentale	81
3.3.5	<i>Exemples de chemins minima sur une image</i>	84
3.3.6	<i>Connexion de composantes connexes</i>	86
3.4	ANALYSE DES RESULTATS	88
3.4.1	<i>Complexité calculatoire</i>	88
3.4.2	<i>Influence du paramètre d</i>	88
3.4.3	<i>Influence du type de chaussées sur la méthode</i>	90
3.4.4	<i>Sélection du paramètre d</i>	92
3.4.5	<i>Résultats sur images réelles</i>	92
3.5	CONCLUSION	95
CHAPITRE 4 IMPLEMENTATION ET RESULTATS EXPERIMENTAUX.....		97
4.1	INTRODUCTION.....	99
4.2	DETECTION ET CLASSIFICATION DE LA FISSURE	100
4.2.1	<i>Prétraitement</i>	100
4.2.2	<i>Extraction d'attributs</i>	102
4.2.2.1	Attributs orientation globale dans l'espace de Hough.....	103
4.2.2.2	Longueur d'une composante.....	103
4.2.2.3	Attributs d'orientation locale	104
4.2.3	<i>Détection et Classification de défauts</i>	105
4.2.3.1	Image sans défaut	105
4.2.3.2	Extraction du faïençage	106
4.2.3.3	Extraction de la fissure longitudinale et transversale.....	107
4.3	BASES D'IMAGES DE TEST.....	108
4.3.1	<i>Base d'images du LCPC</i>	108
4.3.2	<i>Base d'images acquises par le véhicule AMAC®</i>	108
4.3.2.1	Description du dispositif de prise de vue	108
4.3.2.2	Caractéristiques des images obtenues	109
4.3.2.3	Sélection d'images de tests	110
4.4	RESULTATS EXPERIMENTAUX.....	110
4.4.1	<i>Résultats comparatifs sur la base de données du LCPC</i>	110

4.4.1.1	Performances sur des images de laboratoire	111
4.4.1.2	Comparaison des performances sur des images capturées en mode statique sur route	114
4.4.1.3	Discussion.....	118
4.4.2	<i>Résultats sur bases de données d'images capturées par AMAC.....</i>	<i>118</i>
4.4.2.1	Discussion.....	126
4.5	CONCLUSION	127
CHAPITRE 5 CONCLUSION ET PERSPECTIVE		129
5.1	CONCLUSION	129
5.2	PERSPECTIVES	132
ANNEXE A BASE D'IMAGE DU LCPC		135
A.1	IMAGES "REALISEES" EN LABORATOIRES	135
A.2	IMAGES ACQUISES EN STATIQUE.....	136
ANNEXE B AUTRES RESULTATS COMPARATIFS		139
PUBLICATIONS DE L'AUTEUR.....		143
BIBLIOGRAPHIES		145

Introduction générale

Détection automatique des dégradations de surface de chaussées : le contexte

Les dégradations de surface de chaussées est un indicateur important de l'état et de l'évolution d'un réseau routier. Ces dégradations peuvent évoluer en problèmes plus graves et plus coûteux à réparer. C'est pourquoi, les gestionnaires routiers ont besoin de les détecter le **plus tôt possible**. En France, des milliers kilomètres de routes doivent ainsi être auscultées chaque année.

Dans le passé, des agents étaient envoyés sur la route pour observer et noter les dégradations. Par cette méthode, seule une partie des routes pouvait être examinée à cause de la faible vitesse d'inspection et l'insécurité des agents.

Depuis les années 80s, plusieurs recherches ont été initiées pour concevoir des systèmes capables de relever et d'analyser ces informations de manière automatisée. Ces systèmes doivent répondre aux contraintes de vitesse de déplacement minimale sur une autoroute (80 km/h) et en même temps, être capables de capturer des défauts de petites tailles (1 à 2 mm de large). De nos jours, pour respecter ces contraintes, les capteurs de vision sont les seules solutions satisfaisantes. Un tel système peut se décomposer en deux parties : **une partie acquisition** d'images et **une partie analyse** de ces images, plus ou moins automatiquement.

La partie concernant l'acquisition des images a bien progressé ces dernières années. Par contre ce n'est pas vraiment le cas de l'automatisation de l'analyse des images. Plusieurs systèmes d'acquisition sont utilisés par les gestionnaires routiers. Ils sont capables d'acquérir des images de chaussées de bonne qualité et à haute vitesse. Cependant, l'analyse des dégradations sur ces images est, la plupart du temps, réalisée par des opérateurs en laboratoire (Figure 0-1). En effet, il existe bien des systèmes, dans le monde, permettant de faire automatiquement l'acquisition et le traitement d'images, mais ceux ci ne fonctionnent que sur certains types de chaussées (faiblement texturées) ou avec les exigences limitées de certains gestionnaires routiers (qui ne demandent que la reconnaissance de fissures assez grandes).

Actuellement, aucun système automatisé ne répond aux exigences et conditions françaises. C'est pourquoi l'inspection manuelle en laboratoire reste la seule solution. Souvent, dans le monde, elle reste la méthode la plus utilisée car les chaussées fortement texturées sont de plus en plus fréquentes sur les réseaux routiers mondiaux.




Figure 0 - 1 : Méthode actuelle de relevé de dégradations de surfaces de chaussées en France.

L'inspection manuelle, en laboratoire, est plus avantageuse que celle faite sur les routes, surtout en ce qui concerne la sécurité des opérateurs. Cependant, le travail de visualisation de milliers de kilomètres d'images de chaussées reste coûteux, subjectif et lent. En effet, chaque opérateur ne peut traiter que les images d'une vingtaine de kilomètres de routes par jour et, de plus, le résultat dépend aussi de l'état de fatigue de cet opérateur.

C'est pour cela qu'une méthode fiable et automatique de détection de ces défauts est l'objet de recherche de nombreuses équipes dans le monde et plus particulièrement en France. C'est aussi l'objet de ce travail de thèse.

Détection automatique de dégradations dans des images de surface de chaussées : problématique

Durant les dernières décennies, plusieurs méthodes d'analyse de textures et de segmentation d'images ont été appliquées pour la détection automatique de défauts sur des surfaces texturées dans les domaines de production de textile (textures périodiques), de bois, de métaux (gros défauts). Malheureusement, ces domaines ont des contraintes bien moindres en termes de texture ou de taille de défaut et ne sont donc pas spécialement adaptées aux images de chaussée.

La difficulté de la détection automatique, dans ce domaine, a trois raisons principales. D'une part, la texture de chaussée varie fortement, d'autre part, les conditions d'acquisition en extérieur présentent souvent des facteurs non-contrôlables et enfin la taille des défauts à détecter est assez petite.

Il faut noter que les défauts de type "fissure" sont les seuls types de défauts considérés dans plusieurs pays et, en France, ce type est le défaut prédominant. Afin que les défauts soient détectés le plus tôt possible, on doit détecter les fissures à partir de 1 à 2 millimètres de largeur (soit 1 à 2 pixels pour la résolution habituelle des images). Un tel défaut, particulièrement sur des chaussées à forte rugosité, est difficile à distinguer du bruit et des variations de texture de fond.

Les approches existantes pour la détection de fissures dans des images de surface de chaussée (Seuillage, Morphologie, Transformée en Ondelettes Continues, Filtrage adapté, Segmentation par Champs de Markov) utilisent les caractéristiques **luminosité** et **forme** de fissure dans leur modèle pour la segmentation. Dans ces approches ces deux caractéristiques sont utilisées l'une après l'autre. La luminosité est utilisée pour une étape de binarisation, afin d'extraire des pixels pouvant appartenir à une fissure. Ensuite, la caractéristique de forme est utilisée dans l'étape de connexion afin de réduire les bruits. Pour des images de chaussées fortement texturées, les résultats de ses méthodes contiennent un bruit important apporté par la texture de fond. Ainsi, bien que les méthodes de la littérature présentent des idées prometteuses, selon des publications récentes [1, 2], aucune de celles-ci n'est largement applicable, surtout pour des chaussée fortement texturée comme celles que l'on trouve en France. Avec ce type de chaussées, le problème est difficile car les caractéristiques de fissures sont, localement, très proches de celle de la texture, notamment de l'espace inter-granulats.

Objectifs de la thèse

On se propose, dans ce travail, d'étudier et de développer une méthode de détection automatique des dégradations dans des images de surfaces de chaussées. On s'intéresse plus particulièrement aux défauts de type "fissure".

On souhaite pouvoir traiter des fissures de différentes tailles, sur différents types de chaussées et particulièrement sur des chaussées fortement texturées comme celles que l'on trouve en France. Les méthodes devront être testées sur une base de données de taille importante pour prouver leurs performances.

On a observé que, les attributs locaux de fissures ne sont pas forcément différents de ceux de la texture de fond sauf si ils sont calculés le long de la fissure et ce, sur une longueur assez importante. Suite à l'étude de la littérature, on souhaite, d'une part, trouver une méthode permettant de prendre en compte la forme de la fissure lors de l'étape de binarisation et d'autre part, trouver un modèle plus réaliste de la fissure afin de la distinguer du bruit, notamment celui généré par l'espace inter-granulats.

Organisation du mémoire

Le premier chapitre, présente le contexte du travail et un état de l'art sur les techniques d'acquisition ainsi que sur les méthodes de traitement d'images publiées. Les objectifs de ce chapitre sont au nombre de deux. Le premier est de donner une vue globale du problème, par une brève étude montrant la relation entre le système d'acquisition et les défauts présents sur les images afférentes. Le second, qui est le principal, est l'analyse des méthodes de traitement d'images existantes afin de comprendre leurs points faibles et leurs points forts.

Dans le deuxième chapitre, nous présenterons l'étude de l'Anisotropie Conditionnelle de Texture (CTA) en vue de l'utiliser dans le problème de détection des fissures sur la surface de chaussées. Cette méthode a retenu notre attention car elle permet d'utiliser, simultanément pour une segmentation, les deux caractéristiques de la fissure (luminosité et forme). Après un rappel sur la

méthode CTA "originale", nous présentons une adaptation de celle ci fondée sur une nouvelle modélisation de la texture de chaussées.

Nous définissons aussi, dans ce chapitre, des critères permettant d'évaluer et de comparer les résultats de détection. Ils seront utilisés pour l'étude des paramètres de la méthode et pour comparer les résultats des différentes méthodes développées dans ce travail.

Dans le troisième chapitre, nous présentons une nouvelle méthode fondée sur une hypothèse plus complète de la fissure en conservant l'idée de la méthode CTA. Nous abordons une modélisation de l'image par des graphes qui permet d'y rechercher un chemin optimal. Cet outil est utilisé pour cette nouvelle méthode que l'on a nommée « Free Form Anisotropy » (FFA). Une étude de son comportement pour les différents types de chaussées est aussi présentée dans ce chapitre.

Le quatrième chapitre a pour but d'évaluer les performances de ces méthodes sur les différentes bases de données en les comparant avec les méthodes de la littérature. Après une présentation des méthodes utilisées pour les étapes de prétraitement, d'extraction d'attributs et de classification, nous donnons une comparaison des résultats sur différents types d'images de chaussées et de défauts.

Enfin, nous concluons ce travail et proposons des perspectives.

Chapitre 1

Problématique et état de l’art

CONTENU

1.1	LE RELEVÉ DE DEGRADATIONS DE SURFACES DE CHAUSSEES	9
1.1.1	<i>Dégradations de surfaces de chaussées</i>	9
1.1.1.1	Les dégradations de « type fissure »	10
1.1.1.2	Les autres dégradations.....	10
1.1.2	<i>Méthodologies pour le relevé de dégradations</i>	11
1.1.2.1	Inspection visuelle sur site.....	11
1.1.2.2	Inspection manuelle en laboratoire	12
1.1.2.3	Inspection automatique & semi-automatique.....	13
1.1.3	<i>Paramètres d'acquisition d'images</i>	15
1.2	ETAT DE L’ART SUR LES METHODES DE DETECTION AUTOMATIQUE DE FISSURES SUR DES IMAGES DE CHAUSSEES.	17
1.2.1	<i>Généralités sur des méthodes pour la détection de défauts sur la surface des chaussées</i>	20
1.2.1.1	Hypothèses concernant la fissure.....	20
1.2.1.2	Les étapes pour la détection et la classification de défauts	21
1.2.2	<i>Segmentation</i>	22
1.2.2.1	Approches seuillages	22
1.2.2.2	Approche Morphologie.....	24
1.2.2.3	Approche basée sur le filtrage adapté	25
1.2.2.4	Approches fondées sur la transformée en ondelettes continues	27
1.2.2.5	Approches basées sur la segmentation par Champs de Markov.....	28
1.2.3	<i>Prétraitement</i>	31
1.2.4	<i>Extraction des attributs</i>	31
1.2.5	<i>Classification</i>	33
1.3	CONCLUSIONS	34

Un système automatisé de relevé de dégradations de surfaces de chaussées contient normalement un système d'acquisition d'images et des algorithmes pour détecter automatiquement ces défauts présents sur les images acquises.

Le but de ce chapitre est de donner une vision globale du problème de l'automatisation du relevé de dégradations de surfaces de chaussées.

Dans un premier temps, nous présentons les défauts que l'on doit détecter, la méthodologie existant en France et dans le monde pour le relevé de ces dégradations.

Ce chapitre se termine par une présentation de l'état de l'art sur les méthodes de traitement d'images pour la détection de défauts dans des images de surface de chaussées.

1.1 Le relevé de dégradations de surface de chaussées

1.1.1 Dégradations de surface de chaussées

Comme nous l'avons tous vu sur les routes, des dégradations apparaissent à la surface de la couche de roulement (Figure 1-1). Cette couche protège la chaussée et ses altérations présentent l'état des autres couches de la chaussée. C'est pourquoi les gestionnaires routiers ont besoins de relever ces dégradations régulièrement afin d'en assurer l'entretien au bon moment.




Figure 1-1 : Différentes couches de la chaussée

Parmi les diverses dégradations qui peuvent exister sur la surface des chaussées, les plus importantes sont celles de « type fissure » [3]. L'intérêt porté par les gestionnaires routiers vient d'une part que ce type de défaut est le plus fréquent et d'autre part, qu'une fissure non réparée risque de développer des altérations de la voie encore plus graves.

Il est donc important de présenter d'abord le type de dégradations qui nous intéresse le plus. Les autres dégradations sont abordées par la suite.

1.1.1.1 Les dégradations de « type fissure »

Les fissures sont des failles de faible profondeur. Selon le catalogue des dégradations [4], on distingue trois types de fissures :

- La fissure longitudinale : orientée sensiblement parallèlement à l'axe de la chaussée,
- La fissure transversale : orientée perpendiculairement à l'axe de la chaussée,
- Le faïençage : ensemble de fissures entrelacées ou maillées formant une série de polygones et localisées le plus souvent sur la bande de roulement.




Figure 1-2 : Illustration des différentes classes de fissures

1.1.1.2 Les autres dégradations

D'autres dégradations de la couche de roulement existent. Elles se caractérisent par une modification locale de la constitution de la chaussée [3]. Parmi elles, on trouve :

- La réparation : traitement local de la chaussée,
- La pontée : une réparation d'un défaut de « type fissure »,
- Le joint : la frontière d'une réparation ou de deux bandes de roulement,
- La pelade : arrachement par plaque de la couche,
- Le ressuage : remontée de liant à la surface de la chaussée.

Comme ces dégradations sont moins significatives que les fissures pour le diagnostic de l'état de la chaussée, nous nous concentrons, dans ce travail, sur la dégradation de « type fissure ».

1.1.2 Méthodologies pour le relevé de dégradations

La Figure 1-3 illustre un bilan des méthodologies pour réaliser ce travail dans le monde et plus spécifiquement en France.




Figure 1-3 : Mise en œuvre du relevé de dégradation des surfaces de chaussées en France et dans le monde.

1.1.2.1 Inspection visuelle sur site

La saisie des dégradations se fait visuellement, à pied ou à bord d'un véhicule parcourant la chaussée à faible vitesse (entre 5 et 7 km/h). Les deux inconvénients majeurs de cette méthode sont la vitesse faible lors de l'inspection et l'insécurité pour les agents et les usagers de la route.

Pour éviter d'envoyer des agents sur la route, l'idée est de leur apporter les images de la surface des chaussées dans leur laboratoire par l'intermédiaire de photos ou de vidéos.

1.1.2.2 Inspection manuelle en laboratoire

Cette deuxième méthode se décompose en deux étapes. La première consiste à acquérir et à sauvegarder les données de surface de la chaussée (photos ou vidéos). La deuxième étape, le relevé de dégradations, est effectuée en consultant ces données à l'aide d'un ordinateur et de logiciels permettant de visualiser et de noter les dégradations.

L'appareil SIRANO¹ est le premier système utilisé en France pour acquérir des images de la surface de chaussées. Ce système utilise des caméras analogiques avec des pellicules argentiques. L'image est capturée de nuit avec un éclairage de scène artificiel et constant. Le SIRANO reste limité à des opérations nocturnes. De plus, son matériel devient obsolète. Il a été remplacé par l'Appareil Multifonction d'Auscultation des Chaussées (AMAC®) [5].

Pour l'AMAC®, développé par la société Vectra, la partie prise d'images est réalisée à l'aide du système LRIS (Laser Road Imaging System) de l'Institut National d'Optique du Canada (INO). Cette solution permet l'acquisition d'images numériques de très haute résolution de la surface des chaussées indépendamment des conditions d'éclairage naturel.

La Figure 1-4 illustre un exemple d'interface logicielle pour l'inspection manuelle en laboratoire sur des images de chaussées. L'opérateur fait l'inspection en observant les images de chaussées ainsi que les images d'environnement correspondantes.




Figure 1-4: Exemple d'inspection manuelle en laboratoire

¹ SIRANO : Système d'Inspection des Routes par Analyses Numériques et Optiques

Les conditions d'inspection sont grandement améliorées mais des inconvénients demeurent avec cette méthode. Ce travail nécessite une forte intervention humaine : la méthode est donc coûteuse, subjective et peu rapide. En effet, chaque opérateur ne peut traiter qu'une vingtaine de kilomètres de chaussées par jour. De plus, la pénibilité de l'examen des images en laboratoire introduit une fatigue chez l'opérateur. Et, il est notable que l'exactitude et la fiabilité de l'inspection sont dépendantes de cet état de fatigue et de l'opérateur lui même.

Malgré ces inconvénients, ce type d'inspection manuelle en laboratoire est la seule solution exploitée en France et la plus courante dans le monde.

1.1.2.3 Inspection automatique & semi-automatique

Depuis la fin des années 80, beaucoup d'efforts ont été faits pour réaliser des systèmes capables de détecter et d'évaluer automatiquement les dégradations de chaussée. Une bonne étude de ces systèmes de part le monde a été présentée dans le rapport de Schmidt en 2003 [6]. Nous citons trois exemples de ces systèmes dans la Figure 1-3.

Le premier système automatisé dans le monde a été développé par la multinationale japonaise Komatsu à la fin des années 80 (Fukuhara [7]). Ce système comprend un véhicule d'acquisition et un système informatique embarqué pour mesurer la fissuration. La résolution maximale, de 2048x2048, est obtenue à la vitesse de 10 km / h. Bien que novateur, il présentait des inconvénients. D'une part, il ne fonctionnait que la nuit (afin de contrôler les conditions d'éclairage) et d'autre part, il ne distinguait pas les types de fissures. Il a été utilisé pour les chaussées japonaises.

Le deuxième exemple est le système RoadCrack [8], développé par le CSIRO (Commonwealth Scientific and Industrial Research Organisation) et le RTA (Road and Traffic Authority). Ce système automatise la détection et la classification de défauts de type fissure. Il peut détecter des fissures à partir d'une largeur de 1 mm avec une vitesse moyenne du véhicule de l'ordre de 100km/h. Ces performances ont été obtenues sur des chaussées australiennes.

Le troisième exemple, et le système développé par le groupe Roadware (Canada). Il comprend un véhicule pour l'acquisition de données (l'ARAN [9] : Automatic Road Analyser) et un logiciel de détection de fissure nommé Wisecrux [9]. L'acquisition des données est faite avec l'ARAN à une vitesse moyenne de l'ordre de 80 km/h. Les fissures dont la largeur est supérieure à 3 mm sont

détectées par traitement d'images après paramétrage par un opérateur. ARAN et Wisecrux ont été utilisés pour des chaussées d'Amérique du nord.

Dans ces trois systèmes, le Komatsu et le Roadcrack sont des systèmes d'inspection automatique, (sans l'intervention humaine) et en ligne (des données sont traitées "en ligne" sans sauvegarde). Par contre, la solution de Roadware est semi-automatique (besoin d'une intervention humaine) et hors-ligne (sauvegarde de données, traitement en différé).

Le système idéal est un système qui n'a plus besoin de l'intervention humaine. Il doit pouvoir acquérir les images de chaussées à haute vitesse dans toutes les conditions d'éclairage naturel et par la suite, il doit être en mesure de détecter tous les types de dégradations de surfaces de chaussées possibles et sur toutes les natures de chaussées envisageables.

Toutefois, selon Schmidt [6], après des années de recherche et d'expérimentation, la plupart des administrations routières relèvent encore manuellement les dégradations de la surface de leurs chaussées. Deux raisons à cela. D'une part, les exigences des gestionnaires routiers sont souvent différentes d'une région du monde à l'autre. Et d'autre part, les types de chaussées, leurs dégradations prédominantes et leur importance varie aussi énormément d'une route à l'autre. Ainsi, on comprend bien que le système adapté à un gestionnaire ne satisfera peut être pas un autre.




Figure 1-5 : Exemple de fissures sur des chaussées différentes.
(a) Chaussée australienne (issue de [8]), (b) chaussée française.

Etant donné notre contexte, nous nous intéressons particulièrement aux réseaux routiers français. Ces derniers emploient des couches de roulement fortement texturées (Figure 1-8) alors que la largeur de fissure détectable exigée par les gestionnaires routiers en France est de 1 mm. Certains systèmes automatiques ont été testés sur les réseaux français, [8, 9], mais à notre connaissance, il n'existe pas encore de système automatisé adapté aux types de chaussées françaises et aux exigences des gestionnaires routiers français.

Dans le cas où la détection n'est pas possible en automatique, l'approche semi-automatique est préférée et le résultat de la détection automatique est utilisé pour améliorer l'inspection manuelle.

L'approche semi-automatique consiste donc à automatiser une partie du traitement tout en laissant un minimum d'intervention humaine pour réaliser les opérations non automatisables (comme les systèmes ARAN & Wisecrack [9]). C'est donc une approche intermédiaire plus coûteuse financièrement que l'approche automatique mais offrant plus de garantie au final.

1.1.3 Paramètres d'acquisition d'images

Nous introduisons ici les paramètres et les contraintes d'un système pour l'acquisition de données et pour le relevé des dégradations de surfaces de chaussées.

Pourquoi la détection est-elle faite par vision ?

Pour répondre à cette question, il faut considérer les contraintes portant sur la vitesse du véhicule d'inspection, sur la résolution et sur la dynamique de capteurs.

L'acquisition des données de surfaces de chaussées ne doit avoir aucune incidence sur la vitesse des autres usagers de la route, en particulier sur les routes à circulation dense. Pour satisfaire cette condition, c'est à dire, permettre au véhicule d'acquisition de capturer les données à haute vitesse (moyenne 80 km/h), les capteurs doivent être obligatoirement basés sur des technologies "sans contact" [7]. La résolution de ces capteurs devrait aussi être assez importante pour permettre de détecter les fissures. Plusieurs technologies "sans contact" peuvent être utilisées : les capteurs lasers (profilomètre), les capteurs ultrasonores ou des capteurs de type vision. Mais selon Wang et al [10], seuls les capteurs de type vision peuvent satisfaire à ces conditions. Par conséquent, la collecte de données de dégradations de surfaces par des capteurs de vision est toujours la méthode préférée.

Type de caméras

Plusieurs types de caméras peuvent être utilisés à savoir la caméra analogique, la caméra numérique matricielle et la caméra linéaire (numérique). D'après des recherches dans ce domaine [6, 11], la caméra linéaire est considérée comme la plus adaptée pour l'acquisition d'images en mode dynamique à haute résolution donc, ce contexte d'acquisition d'images.

Système d'illumination et configuration des positions caméras-illuminateurs

Pour l'acquisition, le véhicule se déplace à haute vitesse et la fissure est souvent très petite (quelques millimètres de large). Dans ces conditions, un éclairage de bonne qualité se révèle très important. L'acquisition d'images en haute résolution à grande vitesse ne laisse qu'un temps très court d'exposition pour la caméra. Avoir un temps d'exposition si faible exige une haute intensité de l'éclairage pour obtenir des images de bonne qualité. Selon Schmidt [6], un dispositif d'éclairage stroboscopique est approprié pour les caméras matricielles, mais seuls les illuminateurs lasers peuvent satisfaire à ce type d'exigence pour des caméras linéaires. De plus, un système d'éclairage performant est nécessaire pour éliminer les effets liés aux conditions d'éclairage naturel et pour pallier les effets du travail nocturne.

La position de l'éclairage par rapport aux caméras est aussi un facteur déterminant pour la détection de défauts. Normalement, il est configuré pour détecter les fissures en créant une ombre à la place de la fissure. La configuration choisie favorise la détection des fissures longitudinales d'un côté mais réduit le contraste pour les fissures transversales de l'autre. Une illustration de cette configuration se trouve à la Figure 1-6.




Figure 1-6 : Exemple de position de caméra-illuminateur qui favorise la détection de fissures longitudinales. (a) position de caméra-illuminateur, (b) modèle de réflexion de lumière sur une fissure longitudinale.

Maintenant que nous avons présenté le contexte du travail concernant tous les aspects physiques du problème, nous allons étudier le cœur du sujet de ce chapitre, qui est l'état de l'art sur les méthodes de traitement d'images pour la détection de défauts.

1.2 Etat de l'art sur les méthodes de détection automatique de fissures sur des images de chaussées

La Figure 1-7 positionne le problème de la détection de fissures sur des surfaces de chaussées dans un contexte plus général qui est la détection de défauts dans les images texturées. Ce problème est un sujet important du cadre de l'analyse de texture et de la segmentation d'images.

Nous divisons le problème selon trois critères : le type de la texture inspectée, la dimension du défaut analysé par rapport à la granularité de la texture et la condition de la prise de vue d'images. Une variation sur un de ces critères peut conduire à adopter des approches totalement différentes.




Figure 1-7 : Position du problème de détection automatique de fissures dans des images de surfaces de chaussées.

La Tableau 1-1 dresse un bilan des méthodes de la littérature pour la détection des défauts (objets) dans les images texturées. Elles sont classées par approche **statistique**, approche **spectrale** et approche **fondée sur un modèle**.

Approche	Méthode	Références
Statistique	1. Dimension fractale	[12]
	2. Seuillage à deux niveaux	[13-16]
	3. Morphologie mathématique	[17-21]
	4. Détection de contour	[22]
	5. Fonction de corrélation croisée	[23]
	6. Matrice de cooccurrence	[24-28]
	7. Transformées linéaires locales	[29-31]
Spectrale	1. Transformée de Fourier	[15, 32-34]
	2. Représentation de Gabor	[35, 36]
	3. Transformée d'ondelettes	[1, 2, 37-40]
Fondée sur un modèle	1. Champ de Markov aléatoire	[1, 39, 41, 42]
	2. Modèle de Poisson	[43]
	3. Filtrage optimale	[1, 3]

Tableau 1-1 : Bilan des méthodes pour la détection des défauts dans les images texturées.

La plupart des méthodes existantes pour la détection de défauts dans les images texturées se trouvent dans le contrôle de la qualité pour la production du textile. Les textures d'images du textile sont périodiques (Figure 1-8(a)) et les conditions de prise de vue sont bien plus favorables puisqu'effectués en intérieur. Dans ces conditions, le type de texture inspectée est souvent connu à priori et les conditions d'éclairage sont parfaitement contrôlées. Ainsi, les méthodes appliquées dans ce domaine, pour détecter le défaut, sont souvent basées sur les attributs "stables" de la texture comme la fréquence et l'orientation des motifs de textures. La présence d'un défaut se manifeste alors par un changement de ces attributs "stables". Dans ces méthodes, l'apprentissage d'une texture dite "normale" ou "sans défaut" est souvent réalisé pour calculer les attributs "normaux" de la texture (paramètres statiques, paramètres fréquentiels ou paramètres du modèle), ou pour rechercher le paramètre du filtre utilisé pour supprimer le fond (Filtre Gabor).

Le contrôle de qualité se retrouve aussi dans d'autres domaines que le textile. Dans les travaux [18, 25, 28, 44], on trouve des cas de détection de défauts sur des images de surface de bois et de céramique. Ces surfaces sont à texture aléatoire, cependant les prises de vue sont réalisées en intérieur et les défauts à détecter sont plutôt de "grande" taille (Figure 1-8(b)). Dans ces conditions, une approche région d'analyse de texture, par exemple par l'attribut de matrice de co-occurrence comme dans [28], peut détecter la présence de défauts (les rectangles noirs dans la Figure 1-8 (b)).




Figure 1-8 : Exemple de défauts sur différentes surfaces. (a) défaut de textile, issu de A. Kumar [45], (b) défaut sur bois issu de P. Cavalin [28], (c) défaut de surfaces de chaussée.

Ces méthodes sont adaptées à leur contexte mais leur application dans le domaine des chaussées semble limitée. Selon des recherches [3, 41, 46-48] et par notre analyse des données, la difficulté de la détection de fissures, dans des surfaces de chaussées, vient des trois raisons suivantes :

- La forte **variation de textures** de la surface des chaussées : cette variation peut être causée par la grande variété des matériels et des techniques utilisés pour construire les chaussées. L'effet de trafic est aussi responsable de cette variation. Il est notable que la variation apparaît non seulement sur des images différentes mais également dans des zones différentes d'une même image.
- Les fissures sont, en général, **plus minces** que les granulats et l'espace inter-granulaire sur les chaussées. Généralement, les fissures ne représentent qu'une très petite partie de l'image (inférieur à 1,5% des pixels [1, 15]). Ainsi, il est difficile de distinguer une répartition inhabituelle des granulats d'une présence de fissure.
- La **condition prise de vue en extérieur** présente des facteurs non contrôlables : traces de pneus, bandes de peinture, ombres, taches d'huile, humidité... Toutes ces petites imperfections perturbent les opérations de traitement d'images.

En effet, sur la surface de chaussées, il n'existe pas de région ou d'objet dit "normal". Les variations se trouvent dans toutes les régions de l'image et certaines d'entre elles peuvent être définies comme des défauts. Par conséquent, les méthodes de détection automatique de fissures exposées dans la littérature ne sont pas basées sur des attributs "stables" de la texture "sans défaut" mais sur la caractérisation de la fissure. C'est ainsi que nous trouvons la définition de la fissure. Du

point de vue du traitement du signal, la fissure est alors considérée comme un signal tandis que la texture de fond est considérée comme un bruit [3, 41].

1.2.1 Généralités sur des méthodes pour la détection de défauts sur la surface des chaussées

Avant d'analyser les méthodes existantes, nous présentons la définition d'une fissure que l'on trouve dans la littérature. Elle traduit les hypothèses concernant les caractéristiques d'une fissure.

1.2.1.1 Hypothèses concernant la fissure

Nous citons ici la définition de la fissure de Chambon et al [39] :

*«Fissure : il s'agit d'un ensemble de pixels avec un niveau de gris **plus foncé** que le fond de l'image. De plus, une fissure peut être vue comme un ensemble de petits **segments** avec des orientations différentes et connectés entre eux »*

Cette définition décrit deux caractéristiques de la fissure. La première concerne les niveaux de gris des pixels appartenant à la fissure : on l'appelle la caractéristique "**luminosité**". La deuxième concerne **la forme** de la fissure, ou la relation spatiale des pixels de fissures : on appelle cette dernière la caractéristique "**forme**" de la fissure.

Les méthodes existantes dans le domaine posent les mêmes hypothèses concernant la fissure avec les deux caractéristiques ci-dessus. On rappelle que la disposition des caméras et des illuminateurs dans les systèmes d'acquisition d'images de surfaces des chaussées est aussi conçue pour rendre **plus foncés** les pixels de fissures.

Bien que ces deux caractéristiques soient utilisées pour détecter des fissures, elles ne semblent pas refléter parfaitement la réalité dans les conditions réelles :


- Concernant l'hypothèse "luminosité", les auteurs dans [41, 49] ont montré que, en pratique, la rugosité de la surface de la chaussée crée des ombres et engendre des niveaux de gris de pixels de fond (notamment l'espace inter-granulaire) de même grandeur que ceux appartenant à une fissure. Les histogrammes des images de chaussées sont habituellement uni-modaux et ce, même en cas de présence de fissures. Dans ces conditions il est donc quasiment impossible de détecter la présence d'une fissure à partir de l'histogramme de l'image.

- Concernant la caractéristique "forme" des fissures, on constate que les fissures présentent souvent des discontinuités et se présentent alors comme une succession de petites "portions" de fissure. Ce phénomène est surtout vrai dans le cadre des chaussées de type béton bitumineux (chaussée française).

Ainsi, dans les approches récentes, ces deux caractéristiques sont souvent utilisées combinées afin de compenser mutuellement leur défaillance.

1.2.1.2 Les étapes pour la détection et la classification de défauts

Une méthode pour détecter et classer les fissures sur des images de surfaces de chaussées comprend un ensemble de phases. Ces dernières peuvent être au nombre de quatre [47] ou de cinq [39] suivant le formalisme. Dans cette partie, nous analysons les méthodes existantes en considérant les quatre étapes suivantes :



La tâche la plus importante consiste à déterminer et à séparer les pixels de fissures des pixels de fond. Elle est réalisée par la segmentation.

Nous présentons tout d'abord les approches pour cette étape. En effet, le prétraitement est dépendant de la nature de l'image traitée et de la méthode de segmentation adoptée. Les méthodes pour extraire des attributs et pour la classification, sont développées par rapport aux résultats obtenus par l'étape de segmentation.

1.2.2 Segmentation

La plupart des méthodes existantes pour la segmentation d'images de chaussées comprend deux sous-étapes : la **binarisation** et la **connexion** (binarisation et segmentation comme dans [39]). La binarisation est là pour extraire les pixels qui pourraient appartenir à une fissure. La deuxième sous-étape consiste à connecter des petits segments de fissure et à supprimer le bruit apporté par le fond afin de trouver la forme entière de la fissure. La binarisation est fondée sur la caractéristique luminosité des fissures, tandis que la connexion est souvent fondée sur l'hypothèse concernant la forme des fissures.

On résume les approches pour l'étape de segmentation que l'on peut trouver dans la littérature dans le Tableau 1-2. Les méthodes grisées sont les approches de l'équipe de recherche « Fissures » du Laboratoire Central des Ponts et Chaussées (LCPC), qui travaillent sur les chaussées françaises.

Méthode	Références
1. Seuillage fixe	[49-53]
2. Seuillage adaptatif	[54-57]
3. Morphologie mathématique	[16, 17]
4. Filtrage optimale	[1-3, 39, 58, 59]
6. Transformée en Ondelettes Continues	[1, 2, 38, 39, 41]
7. Champ de Markov aléatoire	[1-3, 39, 58, 59]

Tableau 1-2 : Approches existantes pour la segmentation d'images de surfaces de chaussées.

1.2.2.1 Approches seuillages

Ces méthodes basées sur des seuillages viennent naturellement après l'hypothèse "luminosité" de fissure. Cette approche est la plus fréquente et la plus traditionnelle dans le domaine. Le problème de détermination du seuil est fortement dépendant de l'hypothèse de distinction de l'objet (fissure) par rapport au fond.

Seuillages fixes

Dans le travail de D. Meignen et al [53], un seuillage à deux niveaux est réalisé. Il suppose qu'il y a trois groupes de pixels sur une image contenant des fissures : pixels noirs (pixels de fissures),

pixels sombres (pixels de fissures ou de fond), et pixels brillants (fond). Selon cette hypothèse, un seuillage à deux niveaux a été réalisé pour binariser l'image de cette façon :

« Un pixel est un pixel de fissure s'il est noir ou sombre connecté à un pixel noir ».

L'hypothèse caractérisant trois groupes de pixels dans une image de défaut est assez proche du modèle de distribution de gris de la chaussée. Le seuillage à deux niveaux permet ainsi de réduire les bruits. Cependant, comme la nature de la texture de chaussée varie, l'approche seuil fixe [49-53] est difficile à mettre en œuvre avec l'objectif d'automatisation de la méthode.

Seuillages par logique floue et entropie

Les auteurs dans [54, 55] posent la même hypothèse que D. Meignen et al [53] sur les trois groupes de pixels de l'image. Ils considèrent que les pixels "sombres" présentent une incertitude quant à leur appartenance aux classes "brillant" ou "noir".

Cette hypothèse conduit à la modélisation de l'image I par un ensemble flou $(\Omega, h(x), \mu(x))$. Où Ω est l'ensemble des niveaux de gris présents dans I, $h(x)$ est l'histogramme, $\mu(x)$ est la fonction d'appartenance. Cette fonction associe un élément x de Ω à un nombre réel $\mu(x)$ dans l'intervalle $[0,1]$, et ainsi, quantifie le degré d'appartenance de l'élément x au groupe "brillant" (fond).

Dans [54, 55], $\mu(x)$ est modélisé par la fonction S définie par :

$$\mu_{bri}(x) = S(x; a, b, c) = \begin{cases} 0, & x \leq a \\ \frac{(x-a)^2}{(b-a)(c-a)}, & a \leq x \leq b \\ 1 - \frac{(x-a)^2}{(b-a)(c-a)}, & b \leq x \leq c \\ 1, & x \geq c \end{cases} \quad (1.1)$$

x est la valeur du pixel, a et c sont des paramètres qui déterminent la forme de la fonction S ; $b = (a+c)/2$.

Par cette modélisation, le seuillage devient la détermination des paramètres a et c . Ils sont obtenus, en maximisant l'entropie définie comme suit :

$$H(x) = \frac{-1}{MN(\ln 2)} \sum_{x \in \Omega} \{ \mu_{bri}(x) \ln(\mu_{bri}(x)) + [1 - \mu_{bri}(x)] \ln(1 - \mu_{bri}(x)) \} \times h(x) \quad (1.2)$$

Cette approche permet d'obtenir automatiquement le seuil par un modèle qui s'adapte à la distribution des pixels sur des images de surface de chaussées. Cependant, comme toutes les méthodes basées sur le seuillage, la limitation de cette méthode vient du fait que l'image est binarisée en se basant seulement sur la luminosité des pixels. Selon Chambon et al [1], les approches seuillages sont les approches les plus sensibles aux bruits apportés par la texture.

Avec le seuillage, une étape de connexion concernant des recherches de linéarité des pixels segmentés est souvent appliquée après la binarisation [54, 60]. Des opérations morphologiques, (dilatation, ouverture, et fermeture) [7] ou filtre médian [53], sont aussi fréquemment proposées comme sous-étape de connexion. Mais les résultats finaux sont dépendants du rapport signal sur bruit après la binarisation. Une telle opération peut supprimer des bruits mais aussi des petites régions de fissures [47].

1.2.2.2 Approche Morphologie

En utilisant des outils de morphologie mathématique, Tanaka et al [17] propose une méthode, qui prend en compte plusieurs caractéristiques de fissure pour la segmentation.

Ils ont supposé que la fissure avait trois propriétés :

- Une fissure est plus sombre que le fond,
- Une fissure est une succession de points de col,
- Une fissure a un attribut linéaire ou directionnel.

Par conséquent, une image de chaussée est binarisée suivant 3 étapes successives :

- Étape 1 : recherche de l'image des pixels noirs $B(x)$ par seuillage fixe.
- Étape 2 : recherche de l'image de points de cols $T(x)$ par une transformation en chapeau haut de forme ("top-hat"). Cette transformation morphologique a pour but d'extraire les pics dont l'épaisseur est inférieure à l'élément structurant (20 pixels dans ce travail).
- Étape 3 : à partir des images de pixels noirs et de points de cols, $S_{mix}(x) = B(x) \cap T(x)$, une recherche de linéarité dans les 4 orientations 0° , 45° , 90° et 135° permet de supprimer des bruits et ainsi de connecter les segments de fissures.

Un exemple de binarisation par outils morphologiques est illustré à la Figure 1-10.




Figure 1-10 : Illustration d'une segmentation par approche morphologique.

L'avantage de cette approche est d'exploiter plusieurs caractéristiques de fissure pour la segmentation, la caractéristique luminosité (par extraction des pixels noirs) et les caractéristiques de forme qui traduisent la direction et la taille des fissures (point cols). Les résultats présentés dans cet article semblent être moins bruités que ceux obtenus par une approche seuillage.


Les inconvénients de cette méthode, selon les auteurs, est qu'un ensemble de paramètres doit être déterminé manuellement afin de l'adapter à la nature de la chaussée ainsi qu'à la taille des fissures recherchées. Ces paramètres correspondent au seuil utilisé pour déterminer l'image de pixels noirs ($B(x)$) et aux paramètres de tailles des éléments structurant utilisés pour les opérations morphologiques ou de distance pour la recherche directionnelle. L'usage de trop de paramètres à régler manuellement rend toujours difficile l'automatisation d'une méthode.

1.2.2.3 Approche basée sur le filtrage adapté

Cette approche, proposée par P. Delagnes et al [61], est la première d'une série de travaux du LCPC [1, 2, 39, 41]. Ces recherches sont basées sur une binarisation par un filtrage adapté et un raffinement de la binarisation par une segmentation fondée sur un modèle de Markov. Il faut noter que ces travaux ont été effectués avec des images de chaussées françaises. Nous résumons ci-après les grandes lignes du principe de cette méthode.

Selon P. Delagnes, du point de vue local, les fissures apparaissent sous forme d'une *structure linéaire*, c'est-à-dire, de traits élémentaires plus sombres que la texture, de longueur variable et de faible largeur.

Sur le plan perpendiculaire à la direction θ d'une fissure (quatre directions : 0° , 45° , 90° et 135° sont considérées), la fissure est modélisée comme un signal rectangulaire (équation(1.3)) ou une gaussienne (équation(1.4)).



De plus, la texture de la chaussée a été modélisée comme un bruit venant s'ajouter à un fond uniforme où peuvent également apparaître des fissures. Avec ces modélisations, sur une direction donnée θ , une image de chaussée est considérée comme un signal $f^\theta(x)$ qui est composé d'un signal déterministe $s^\theta(x)$ noyé dans une bruit $b^\theta(x)$:

$$f^\theta(x) = s^\theta(x) + b^\theta(x) \quad (1.5)$$

La détection de fissure revient alors à chercher la présence de signaux déterministes (fissure) connus au sein d'un bruit (texture). Selon la théorie des filtres adaptés, il cherche les filtres de type FIR (Filtre à réponse impulsionnelle finie) avec la réponse impulsionnelle h^θ qui maximisent le

rapport signal sur bruit (SNR^θ , relation (1-6)) lors de la détection des traits (signal $s(x)$) selon une direction θ) avec quatre orientations.

$$SNR^\theta = \frac{|h^\theta * s^\theta|}{\sqrt{E(|h^\theta * b^\theta|^2)}} \quad (1-6)$$

Les résultats de cette binarisation, sortie du filtre adapté, sont utilisés pour initialiser des Champs de Markov, qui effectuent ensuite la segmentation.

Plusieurs nouveaux concepts ont été introduits dans ce travail. Cela crée une base qui permet d'appliquer des méthodes de traitement du signal d'une façon plus formelle.

Cependant, dans ce travail, l'indisponibilité de systèmes d'acquisition gêne la validation de ces concepts et la méthode sur une base d'images réelles.

1.2.2.4 Approches fondées sur la transformée en ondelettes continues

L'utilisation de la Transformation en Ondelettes Continues (TOC) dans ce domaine, a été présentée par P. Subirat [41], et suivie dans le travail de S. Chambon [2, 38, 39] au sein du LCPC.

Ils partent des modélisations de Delagnes de la formule (1.5) et se basent sur le principe de filtrage adapté. Dans [2, 38, 39], les ondelettes (mère), à différentes échelles et facteurs de décalage, sont utilisées comme réponses impulsionnelles h des filtres adaptés pour l'extraction du signal déterministe (fissure) noyé dans le bruit (texture de fond).

Dans un premier temps, une TOC est effectuée sur l'image ($f^\theta(x) = s^\theta(x) + n^\theta(x)$) pour générer un rehaussement du signal (fissure) par rapport au bruit (fond)). Puis, des cartes de coefficients d'ondelettes sont constituées sur les différentes échelles.

Dans un deuxième temps, la binarisation est réalisée directement par la recherche des minima locaux dans des cartes de coefficients [38] ou par des champs de Markov initialisés par ces cartes [1, 39, 41].

La transformée en ondelettes directionnelles d'une fonction $f \in L^2(\mathbb{R}^2)$ avec une ondelette (mère) ψ est définie telle que :

$$Wf(s, \vec{u}, \theta) = \iint_{R^2} f(\vec{x}) \psi_{(s, \vec{u}, \theta)}^*(\vec{x}) d\vec{x} = \frac{1}{a} \iint_{R^2} f(\vec{x}) \psi\left(R^{-\theta} \frac{(\vec{x} - \vec{u})}{s}\right) d\vec{x} \quad (1.7)$$

s est le paramètre d'échelle d'ondelettes ψ , $\vec{u}$ est le paramètre de décalage, θ est la direction 1D du signal ($0^\circ, 45^\circ, 90^\circ, 135^\circ$).

Selon S. Chambon [1], une des difficultés principales quand on applique la TOC est le choix de l'ondelette mère. Ce choix revient à déterminer le type d'ondelette ainsi que ses paramètres (s et $\vec{u}$ dans la relation (1.7)). Il est fait par principe de filtrage optimal, en faisant maximum la SNR^θ dans la relation (1-6). Il est dépendant de la modélisation de la fonction du signal s (fissure) et du bruit b (texture). Dans ces travaux, le bruit b est supposé centré, stationnaire au second ordre et caractérisé par la fonction d'autocorrélation.

Dans les travaux de P. Subirat [41], la fissure est modélisée par un signal rectangle (formule (1.3)).

Selon S. Chambon [2, 39], cette modélisation ne correspond pas à une représentation réaliste de la fissure. Elle a donc choisi la modélisation gaussienne (relation (1.4)).

L'avantage des approches par la transformée en ondelettes continues (TOC) est de permettre l'analyse multi-échelle des images de chaussées. Par contre, il reste des hypothèses à vérifier :

- La modélisation du signal de fissure s : quel est le signal (rectangle, gaussien ou autre) le plus approprié pour la modélisation de fissures ? De plus, il faut vérifier aussi que le modèle d'une fissure est localement similaire pour l'espace entre granulats.
- La supposition sur la stationnarité de la texture de fond et l'adaptation des paramètres d'ondelettes mères selon sa fonction d'autocorrélation : comment trouver ces paramètres quand on a une forte variation de la texture dans différentes zones de l'image ?

1.2.2.5 Approches basées sur la segmentation par Champs de Markov

Selon P. Subirat, la méthode de binarisation directe à partir des cartes de coefficients de TOC est sensible aux bruits ([41]). La segmentation devrait alors être réalisée après la TOC par une méthode qui prend en compte la relation spatiale des pixels de fissures (caractéristique forme de fissures).

Dans ces conditions, la modélisation par champs de Markov peut servir comme un outil de la segmentation. Une image est alors modélisée comme un graphe, ce qui permet de présenter la relation spatiale des pixels de l'image.

Les grandes lignes de la segmentation par Champs de Markov sont présentées ci-dessous.

* L'image est modélisée par un graphe qui prend en compte les concepts de sites (pixels), de voisinage (la relation des sites) et de clique (ensemble des pixels voisins mutuellement).

* Sur ce graphe (image), deux champs de variables aléatoires sont associés :

Champ des observations $Y = (Y_s)_{s \in S}$: l'image Y (les valeurs du site s) est considérée comme une réalisation de Champ des observations. Par exemple, un sommet est un pixel et (Y_s) sont des niveaux de gris.

Champ des descripteurs $L = (L_s)_{s \in S}$: l'image de résultat L (la carte d'étiquettes) est considérée comme la réalisation de Champ des descripteurs. Les descripteurs prennent leur valeur dans un ensemble de Ω . Par exemple, $\Omega = 1$ si un pixel appartient à une fissure, 0 dans le cas contraire.

La segmentation d'images revient alors à estimer le Champ des descripteurs donnés par le Champ des observations. Cette estimation est réalisée en minimisant le coût global d'une fonction qui est la somme de tous les potentiels déterminés localement sur des cliques.

$$\hat{l} = \min_l \sum_{s \in S} \left\{ V_{0,s}(l, y) + \sum_{s' \in V_s} V_1(s, s') \right\} \quad (1.8)$$

V_s est l'ensemble des voisins de s. V_1 est la fonction de potentiel locale (sur une clique) qui impose les tendances structurelles internes du champ des descripteurs. V_0 définit la relation entre l'observation $y(s)$ et les descripteurs l_s .

Ces fonctions de potentiel sont déterminées par les valeurs de sites (niveaux de gris ou autre valeurs) et la relation des sites (orientations de deux sites).

Dans ces travaux [1, 2, 38, 39, 41], les valeurs des cartes des coefficients (de la TOC) sont utilisées pour estimer des sites (de taille 3x3 pixels dans la Figure 1-12) du graphe. Chaque site est associé à une "configuration" qui correspond aux valeurs de pixels (valeur des coefficients). Les potentiels

sont déterminés par un tableau de valeurs définies par rapport aux orientations de deux sites. Dans [41], P. Subirat utilise 4 configurations (Figure 1-12, en gris). Dans une version récente de S. Chambon [1, 39], il est ajouté 12 autres configurations pour améliorer la modélisation de la relation spatiale de sites (Figure 1-12, en noir).




Figure 1-12 : Les configurations pour modéliser les relations spatiales des sites, issue de [39]

Les trois points principaux de cette méthode sont donc l'initialisation du graphe (valeurs des coefficients de la TOC), la détermination du potentiel (les configurations et valeurs attachées à chaque paire de configuration) et la condition d'arrêt des estimations. Une bonne définition de configuration avec une bonne condition d'arrêt peut réduire le bruit initialisé par la TOC, cependant, une mauvaise initialisation rend difficile l'obtention d'un bon résultat final.

La validation de la première version de cette approche [41] montre que la méthode est sensible aux bruits apportés par la texture de fond. Une amélioration récente apportée par S. Chambon [39] permet d'obtenir un meilleur résultat, mais le bruit présent dans les images est encore important. Cependant, il faut noter que ces travaux sont testés sur des chaussées françaises, d'où des fissures petites et des chaussées fortement texturées.




Figure 1-13 : Illustration du résultat des méthodes de S. Chambon, issues de [39] :
(a) Image originale 1, (b) Résultat pour l'image 1, (c) Image originale 2, (d) Résultat pour l'image 2.

1.2.3 Prétraitement

Le but du prétraitement est de réduire les effets de facteurs non-contrôlables, (non-uniformité de l'éclairage, degré d'humidité ou variation de la texture), qui pourraient perturber les résultats de la segmentation.

L'égalisation de l'histogramme est généralement indispensable dans une approche à seuillage fixe et pour des images acquises avec des conditions de non-uniformité de l'éclairage [49-53].

Des normalisations du contraste sont appliquées dans [55] [57] et [51] afin de corriger la non-uniformité des niveaux de gris causée par les variations de texture dans différentes zones d'images.

On peut constater que le prétraitement n'est pas indispensable. Il dépend de la nature de l'image et de la méthode de segmentation adoptée. Pour certaines approches comme pour celles du LCPC, aucun prétraitement n'a été proposé.

1.2.4 Extraction des attributs

L'étape segmentation donne une image binaire contenant des groupes de pixels noirs sur un fond blanc (ou vice versa). Il faut maintenant prendre la décision de l'appartenance à une fissure des pixels sachant que la décision sur la nature de l'éventuelle fissure viendra par la suite. En effet les pixels noirs peuvent n'être que du bruit, et les fissures segmentées peuvent être discontinues. Il est alors nécessaire d'extraire des attributs pour finaliser l'étape segmentations et donc prendre une décision.

Il est à noter qu'un post-traitement recherchant les composantes connexes est souvent utilisé avant l'extraction des attributs.

Les attributs utilisés dans la littérature peuvent être rangés en deux groupes distincts : les attributs individuels propres à chaque composante connexe, et les attributs extraits sur la globalité de l'image segmentée.

Attribut local de chaque composante

Les attributs de chaque composante peuvent qualifier sa position, sa forme ou sa longueur [51]. On peut exploiter des moments [60] (moments de Hu [62], de Bamieh[63] et de Zernike [64]).

Les attributs globaux peuvent être des projections ou des attributs dans l'espace de Hough.

Attributs des projections

Dans [38, 51, 54], l'image binaire obtenue après l'étape de segmentation est projetée dans plusieurs directions (normalement sur les 4 directions traditionnelles $0^\circ, 45^\circ, 90^\circ$ et 135°). Une recherche des maxima dans ces directions permet d'obtenir des signatures pour déterminer la présence de fissure et ses orientations.

C'est un procédé simple, rapide et facile à mettre en œuvre. La faiblesse de cette approche est qu'elle n'est pas capable de reconnaître les composantes qui ne sont pas orthogonales aux directions des projections. Pour surmonter cette limitation, la transformée de Hough est souvent employée.

Attribut dans l'espace de Hough

La Transformée Standard de Hough (TSH) permet de transposer une image binaire dans un espace paramétrique de droites. La valeur d'accumulation d'une droite dans l'espace de Hough (représentée par $\rho = x \cos \theta + y \sin \theta$) correspond du nombre de pixels dans l'espace image qui appartiennent à cette droite (Figure 1-14).




Figure 1-14 : Principe de la transformée standard de Hough

L'espace de Hough est représenté par une matrice d'accumulation $MA(\rho, \theta)$. En recherchant les valeurs maximales accumulées, on peut en déduire les valeurs paramétriques des droites de l'image, surtout leur orientation.

Par exemple, les auteurs dans [41] [51, 65] utilisent les maxima de la matrice d'accumulation présents sur des secteurs d'orientations différentes (Figure 1-15) pour caractériser les attributs d'orientation de l'image segmentée.




Figure 1-15 : Type de fissures en fonction de l'angle dans l'espace de Hough issu de [41]

L'avantage de ces deux attributs globaux (Projection et Hough) est qu'ils peuvent détecter les orientations même en cas de discontinuité des fissures. Par contre, on touche aux limites de cette approche dès que les fissures ne sont plus rectilignes.

1.2.5 Classification

Le but de cette étape est d'extraire les défauts et de les classer suivant les différentes catégories possibles. Le nombre de ces catégories à classer varie d'une publication à l'autre. Il n'est donc pas aisé d'en tirer des conclusions. Le catalogue de défauts publié par le LCPC [4] est souvent utilisé. On y trouve trois types de fissures qui sont la fissure longitudinale, la fissure transversale et le faïençage.

Bien que la classification des défauts soit indispensable, il n'y a pas beaucoup de publications concernant la détection automatique de fissures sur des images de chaussées. Chambon [39] affirme que pour la plupart des méthodes, l'étape de classification est une opération triviale puisque tous les attributs liés aux catégories sont bien connus et par conséquent, faciles à discriminer.

Il faut noter aussi que le résultat de la classification est fortement dépendant du résultat de la segmentation, surtout de l'importance du bruit à cette étape et du degré de discontinuité des fissures segmentées.

Classification basée sur des critères prédéterminés :

Ces méthodes sont très fréquemment utilisées dans ce domaine d'application.

Dans [38], les fissures sont extraites puis classifiées en se basant sur les projections. S'il y a un pic sur la projection longitudinale, l'image est classifiée comme une image de fissure transversale, s'il n'existe aucun pic dans les 4 projections, l'image est classifiée comme une image sans défaut.

Dans [41], la classification est fondée sur la matrice d'accumulation dans l'espace de Hough. Une image est classée comme image de défauts quand la valeur maximum d'accumulation est supérieure à un seuil. Pour la classification longitudinale ou transversale, il relève juste l'angle pour cette valeur maximale. Pour la décision du faïençage, il procède de la même manière que pour l'auteur précédent, c'est-à-dire que la présence simultanée de fissures longitudinale et transversale reste le critère de choix.

Réseaux de neurones

La classification des images de chaussées peut être réalisée grâce à un réseau de neurones [55, 60, 65]. Un réseau multicouche (back-propagation) à trois couches est utilisé dans ces publications. Dans ce réseaux, le nombre de nœuds de la couche d'entrée correspond au nombre d'attributs utilisés. Dans [60], 17 moments (Hu [62], de Bamieh [63] et de Zernike [64]) avec 1 valeur de partialité sont utilisés pour la couche d'entrée, tandis que la couche de sortie contient 7 nœuds correspondant aux 7 catégories retenues de défauts : fissure longitudinale, fissure transversale, combinaison des deux types de fissures, fissure diagonale (45°), fissure diagonale (135°), faïençage et sans défaut.

Dans [53], la couche de sortie ne contient que 4 nœuds et la couche d'entrée correspond à 5 paramètres des N composantes connexes les plus grandes (en nombre de pixels).

Pour mener à bien cette technique de classification, il faut un nombre important d'images de référence et le temps de calcul est assez conséquent.

1.3 Conclusions

Dans ce chapitre, nous avons étudié le contexte du travail, concernant la nature du problème et nous avons listé un panel des solutions existantes dans le monde en général et en France en particulier.

Après avoir présenté les dégradations à relever ainsi que les mises en œuvre actuelles de ce processus, nous avons montré que ce travail est actuellement réalisé par des opérateurs qui visualisent les images de la chaussée. Cette technique "manuelle" de relevé des dégradations a des

limitations concernant la subjectivité du résultat et la faible vitesse du relevé des dégradations. Ainsi nous avons montré l'intérêt d'une solution pour réaliser ce travail de façon automatique ou semi-automatique.

Une telle solution concerne deux sous-systèmes : la première est le système pour l'acquisition des images de chaussées et le deuxième est le système implémenté qui rassemble des algorithmes pour détecter automatiquement ces défauts sur les images de chaussées.

Plusieurs systèmes d'acquisition d'images de chaussées ont été développés à travers le monde. Ils emploient différents types de caméra et d'éclairage, mais les systèmes équipés de caméras linéaires et d'illuminateurs lasers sont considérés par la communauté comme les plus adaptés, aujourd'hui, pour réaliser l'acquisition de ces images en répondant aux exigences de qualité et de résolution d'images en mode dynamique. Le système AMAC® est un tel système et a servi pour l'acquisition des images de notre travail.

Dans un second temps, nous avons parcouru les références bibliographiques traitant des méthodes existantes dans ce domaine.

Depuis les années 90, même si plusieurs des systèmes de détection automatique de fissures ont été proposés, aucune méthode n'a été largement applicable. La petite taille des fissures à détecter, la forte texture du fond et l'ensemble des facteurs non-contrôlables venant des conditions extérieures lors de l'acquisition rendent ce problème difficile.

Les méthodes implémentées dans les systèmes commerciaux ne sont pas publiées pour des raisons de confidentialité, pendant que les méthodes publiées sont testées dans des conditions différentes et surtout, selon R. Howe [47], avec des bases de données insuffisantes. C'est pourquoi l'évaluation de la performance de ces méthodes est parfois difficile. On peut observer aussi que les images, montrées en exemples pour illustrer les résultats dans les publications, sont souvent des fissures ayant une largeur importante ou avec des types de chaussées faiblement texturées.

Bien qu'une comparaison de ces méthodes soit difficile à réaliser, certaines de ces idées sont prometteuses : la modélisation des distributions de niveaux de gris de l'image par approche de logique floue, l'utilisation de plusieurs caractéristiques de fissures pour la segmentation (luminosité et forme) ou celle évaluant la linéarité des relations spatiales des pixels de fissure.

Les approches sont principalement basées sur la caractéristique luminosité des fissures pour la segmentation (approches seuillages). Mais, sur des chaussées fortement texturées, la seule «luminosité» des fissures n'est pas suffisante.

Des approches récentes [17, 39, 59] tentent d'utiliser en même temps la luminosité et un critère de forme de la fissure pour cette segmentation. Mais elles utilisent ces deux caractéristiques l'une après l'autre, la luminosité étant utilisée pour la binarisation et la forme de la fissure étant prise en compte pour la connexion. Cependant, d'après les résultats publiés pour ces méthodes, on peut noter qu'un résultat de binarisation trop bruité rend difficile l'obtention d'un bon résultat avec la connexion.

A notre connaissance, sur les surfaces fortement texturées, le modèle d'illumination d'un pixel de fissure est similaire à celui de l'espace inter-granulats, au moins pour une distance égale à la taille du granulat. Dans ce cas, la luminosité de la fissure se différenciera de celle du fond que si on la calcule en suivant la forme de la fissure avec une distance suffisamment grande. On peut traduire cela par le besoin de prendre en compte la forme de la fissure lors de la phase de binarisation pour distinguer ces bruits de fond des pixels de fissures.

Les méthodes que nous exposons par la suite sont basées sur cette nouvelle hypothèse.

Chapitre 2

Segmentation d'images de la chaussée par l'Anisotropie Conditionnelle de Texture

CONTENU

2.1	INTRODUCTION.....	39
2.2	RAPPEL SUR L'ANISOTROPIE CONDITIONNELLE DE TEXTURE	40
2.2.1	Définition de la CTA.....	40
2.2.2	Mise en œuvre de la CTA par F. Roli	41
2.2.3	Résultats et discussion	44
2.3	LA CTA POUR LA SEGMENTATION D'IMAGES DE CHAUSSEES	47
2.3.1	Configuration de l'orientation.....	48
2.3.2	Choix d'attributs de texture et estimation de vraisemblance par une approche associée à la théorie des possibilités	49
2.3.3	Binarisation par seuillage à deux niveaux.....	53
2.4	ANALYSE DES RESULTATS	55
2.4.1	Les vérités terrains.....	56
2.4.2	Critères d'évaluation	57
2.4.3	Comportement de la CTA selon la distance.....	60
2.4.4	Résultats sur l'image réelle	63
2.5	CONCLUSION	65

2.1 Introduction

L'exposé des méthodes existantes montre qu'une fissure est détectée par l'intermédiaire de sa caractéristique "luminosité" et de ses attributs de forme. Par exemple, dans les travaux [17, 39, 41, 59], la fissure est supposée avoir une forme "linéaire" (forme de "traits"). Avec une telle forme, la fissure dispose donc d'une direction dominante qui est utilisée après binarisation, pour distinguer les pixels de fissures de ceux de fond. Ces approches prennent bien en compte les caractéristiques de luminosité et de forme mais l'une après l'autre. En conséquence, pour les images fortement texturées des chaussées françaises, les résultats finaux restent sensibles aux bruits apportés par la texture de fond [41].

Il était donc tentant d'imaginer une méthode qui peut prendre en compte ces deux caractéristiques simultanément pour la segmentation. L'Anisotropie Conditionnelle de Texture (CTA¹), proposée par F. Roli [15] nous a semblé être une bonne méthode.

Dans un premier temps (partie 2.2), nous présentons le principe de la méthode CTA "originale" tel que F. Roli l'a exposé dans [15] ainsi que l'implémentation que l'on a réalisée pour évaluer ses performances.

Dans la partie suivante, une nouvelle méthode est exposée. Elle s'appuie sur l'idée de F. Roli mais nous l'avons développée pour mieux répondre aux problématiques des textures aléatoires que sont celles de chaussées.

La partie 2.4 traite de l'évaluation des différentes versions de CTA sur des images de chaussées.

Enfin, nous concluons sur les avantages et les limitations des méthodes.

¹ Conditional Texture Anisotropy

2.2 Rappel sur l'Anisotropie Conditionnelle de Texture

L'Anisotropie Conditionnelle de Texture (CTA) a été introduite par F. Roli [15, 66] pour détecter des fissures dans des surfaces texturées (des dalles de granite dans ces travaux). Il a constaté que les fissures occupent généralement un très faible pourcentage (1% ou moins) de la surface texturée et qu'elles présentent une orientation dominante. Par conséquent, une fissure n'affecte pas fortement les attributs de la texture dans sa globalité. En fait, elle influence les attributs de la texture le long de son orientation dominante. Cette observation conduit à l'idée de chercher une mesure qui fournit une petite valeur dans une orientation (celle de la fissure) et des valeurs plus grandes dans les orientations restantes. La CTA fonctionne sur ces principes.

2.2.1 Définition de la CTA

La CTA a été définie comme suit :

- $C = \{C_1, \dots, C_N\}$ est l'ensemble de toutes les classes de textures inspectées. N est le nombre de types de textures,
- Pour une classe de texture donnée C_i , il existe deux catégories attachées, w_1 : catégorie des pixels sans défaut et w_2 : catégorie des pixels de fissures,
- Chaque pixel l est caractérisé par m attributs de texture. Chaque attribut est calculé le long de n orientations différentes. Donc, la texture de chaque pixel l est représentée par un vecteur d'attributs : $X^l = (x_1^l, x_2^l, \dots, x_n^l)$ avec chaque sous-vecteur $x_\theta^l = (x_{\theta 1}^l, x_{\theta 2}^l, \dots, x_{\theta m}^l)$, $\theta = 1 \dots n$ contenant m attributs calculés suivant chaque orientation θ .

F. Roli a choisi la vraisemblance de classe de texture sans défaut w_1 comme la mesure à calculer suivant les différentes orientations. La vraisemblance de classe w_1 est la *densité de probabilité conditionnelle (DPC)* $p(x_\theta^l / l \in w_1)$. Elle exprime la probabilité conditionnelle que l'attribut d'une texture sans défaut w_1 calculé suivant l'orientation θ soit x_θ^l . Donc, celui ci variera fortement le long de l'orientation de la fissure.

Si l est un pixel de fissure et α est l'orientation dominante de cette fissure, la fonction $p(x_\alpha^l / l \in w_1)$ prend une faible valeur. La fonction $p(x_\theta^l / l \in w_1)$ prend une grande valeur pour les autres orientations $\theta \neq \alpha$. Pour caractériser le degré d'appartenance à une fissure de chaque pixel l , la CTA est définie par la formule suivante :

$$CTA(X^l) = \frac{\max_{\theta} \{p(x_\theta^l / l \in w_1)\} - \min_{\theta} \{p(x_\theta^l / l \in w_1)\}}{\max_{\theta} \{p(x_\theta^l / l \in w_1)\}} \quad (2.1)$$

La CTA (X_l) est calculée comme une fonction non-linéaire de X_l qui effectue une transformation de l'espace des attributs dimensionnels ($n \times m$) vers un espace 1D. À partir de cette définition donnée par l'équation (2.1), on peut déduire que :

- La fonction $CTA(X^l)$ fournit des valeurs comprises entre 0 et 1,
- La fonction $CTA(X^l)$ prend une faible valeur (proche de 0) pour les pixels "sans-défaut", car les probabilités pour que ces pixels appartiennent à la classe de texture sans défaut w_1 sont très proches pour toutes les orientations.
- La fonction $CTA(X^l)$ prend une grande valeur (proche de 1) pour des pixels de la fissure, car la fonction $p(x_\alpha^l / l \in w_1)$ prend des valeurs proches de 0 suivant l'orientation de la fissure alors qu'elle prend des valeurs proches de 1 le long des autres orientations.

Cette mesure d'Anisotropie Conditionnelle de Texture est dite "conditionnelle", car elle fournit une mesure qui prend en compte le type de texture à inspecter. Pour calculer $CTA(X^l)$, il faut estimer $p(x_\theta^l / l \in w_1)$ pour chaque orientation θ en utilisant une image sans défaut qui appartient à la classe de texture C_i inspectée.

2.2.2 Mise en œuvre de la CTA par F. Roli

Afin de calculer la CTA selon la définition formulée en (2.1), les attributs de texture X et la vraisemblance $p(x_\theta^l / l \in w_1)$ doivent être déterminés.

2.2.2.1 Extraction du vecteur d'attributs

Les attributs de texture d'un pixel l , ou bien, de la région autour d'un pixel l , caractérisent la façon dont les niveaux de gris sont distribués dans cette région. Cette caractéristique peut être déterminée dans le domaine spatial ou dans le domaine fréquentiel. F. Roli a utilisé des attributs de texture dérivés de l'espace des fréquences. Ceux ci ont été introduits par Bajcsy [67]. Cette méthode utilise une variante des filtres en anneau (Figure 2-1(a)) ou à bandes orientées (Figure 2-1(b)) dans le domaine de Fourier pour extraire les attributs de la texture. Les attributs sont respectivement les sommes des puissances dans l'anneau ou le secteur de l'espace du spectre de puissance.

F. Roli a utilisé un filtre qui est la combinaison de ces deux filtres comme le montre la Figure 2-1(c). L'espace du spectre de puissance est divisé en 4 bandes de fréquence où chaque bande correspond à un attribut de texture. Chaque attribut est ensuite calculé suivant les 4 orientations : $0^\circ, 45^\circ, 90^\circ$ et 135° . Par exemple, les attributs le long de l'orientation 45° sont illustrés dans la Figure 2-1(c) (remarquez la symétrie par l'origine).




Figure 2-1 : Spectre de puissance Fourier (a) filtre en anneau avec 4 bandes de fréquence, $N/4 \leq r \leq 3N/8$; (b) filtre angulaire avec $22.5^\circ \leq \theta \leq 67.5^\circ$; (c) le masque pour calculer les attributs.

La Figure 2-1(c) montre le masque que l'on a utilisé pour calculer le vecteur des attributs dans le domaine des fréquences. La taille de ce masque est identique à celui de la fenêtre utilisée pour calculer la transformée de Fourier. Elle est de 16×16 dans [15, 66].

2.2.2.2 Estimation de la densité conditionnelle de probabilité

Une fois les attributs déterminés, la DPC¹ $p(x_\theta^l / l \in w_1)$ doit être estimée pour calculer la valeur de la CTA selon la formule (2.1). L'estimation de $p(x_\theta^l / l \in w_1)$ peut être évaluée par des approches paramétriques ou non-paramétriques [68]. L'estimation paramétrique est basée sur la supposition que la DPC a une distribution dont la forme est connue. F. Roli suppose que $p(x_\theta^l / l \in w_1)$ a une forme gaussienne. Le problème devient alors classique, c'est-à-dire, estimer les paramètres de cette distribution à partir des échantillons d'apprentissage. Dans [15, 66], Roli détermine ces échantillons à partir des pixels d'une image sans défaut, par la technique du Maximum de Vraisemblance.

2.2.2.3 Méthode de détection

La détection (ou plus précisément la segmentation) des fissures a été réalisée en deux étapes : étape d'apprentissage et étape de détection.




Figure 2-2 : Schéma de la méthode CTA de F.Roli

Étape d'apprentissage : à partir d'une image sans défaut appartenant à la classe de texture C_i inspectée, les DPCs $p(x_\theta^l / l \in w_1)$ sont estimées, puis les valeurs de $CTA(X^l)$ sont calculées pour tous les pixels de cette image. La distribution de la mesure de CTA pour les pixels sans défaut est également supposée être une gaussienne. La moyenne M_{CTA} et la variance σ_{CTA}^2 des mesures de CTA (X^l) pour tous les pixels l de cette image d'apprentissage sont calculées.

¹ DPC : Densité de Probabilité Conditionnelle

Étape de détection : la décision d'appartenance ou non d'un pixel à une fissure est faite en mesurant la distance de Mahalanobis [69] de cette valeur de CTA avec la distribution de CTA calculée à la phase précédente. Pour chaque pixel l de l'image inspectée, la distance de Mahalanobis $d_M(l)$ est calculée de la manière suivante :

$$d_M(l) = \frac{(CTA(X^l) - M_{CTA})^2}{\sigma_{CTA}^2} \quad (2.2)$$

Où M_{CTA} et σ_{CTA}^2 sont la moyenne et la variance de la distribution de la CTA sur l'image sans défaut.

Les images Mahalanobis présentées dans la suite de ce chapitre sont les images des distances de Mahalanobis ramenées à l'échelle de 0 à 255.

Enfin, l'image est binarisée par un seuillage à deux niveaux sur l'image des distances Mahalanobis.

2.2.3 Résultats et discussion

Nous avons implémenté la méthode CTA "originale" avec les paramètres publiés dans F. Roli [15]. L'estimation par Maximum de Vraisemblance de $p(x_\theta^l / l \in w_i)$ est effectuée sur une région sans défaut sélectionnée manuellement sur les images inspectées (illustré par le rectangle vert de la Figure 2-3 (a)). Le détail des étapes de seuillage est présenté dans la section 2.3.3.

2.2.3.1 Résultats de segmentation pour des surfaces faiblement texturées

La Figure 2-3 montre des résultats de la CTA pour deux images faiblement texturées. La Figure 2-3(a) présente l'image d'une dalle de granite contenant une fissure longitudinale. La Figure 2-3(d) présente l'image de la surface d'une chaussée¹ contenant une fissure diagonale.

Ces fissures issues des images apparaissent visiblement continues. La rugosité de ces textures est faible en comparaison avec la largeur de la fissure. De plus, il n'y a pas de forte variation de texture dans les différentes zones de l'image. Par conséquent, le rehaussement du contraste des pixels de la fissure par rapport aux pixels de fond est bien effectué dans la Figure 2-3(b,e). Ainsi le résultat de segmentation dans la Figure 2-3(c,f) contient peu de bruit (fausses détections), les fissures sont bien localisées.

¹ Cette image appartient à la base de données du LCPC, présenté dans l'annexe A




Figure 2-3 : Exemple de segmentation par la méthode CTA "originale" de F. Roli sur des images de surfaces faiblement texturées contenant des fissures. Les rectangles verts sont les zones utilisées pour l'apprentissage.

2.2.3.2 Résultats de segmentation pour des surfaces fortement texturées

La Figure 2-4(a) est l'image d'une fissure sur la surface d'une chaussée. Sur ce type d'image, la fissure apparaît visiblement comme discontinue. La granularité de la texture est plus grande que la largeur de la fissure. On peut remarquer qu'il y a une forte variation de la texture entre la région située à gauche (servant à l'apprentissage) et celle de droite.

Il est notable que dans l'analyse de chaussées, cet exemple est très fréquent et donc représentatif de la problématique à traiter.

Sur la Figure 2-4(b,c,d,e), on trouve les résultats de la CTA avec différentes tailles N^1 (8, 16, 32 et 64). On peut constater que la fissure n'est pas détectée quelque soit la valeur de N .

Pour N valant 8 et 16 (Figure 2-4(b,c)), les résultats s'expliquent par les petites valeurs de N , en comparaison avec la taille moyenne des granulats (près de 16 pixels), qui ne permettent pas de caractériser la texture.

¹ N : taille de fenêtre qui sert pour le calcul de la transformée de Fourier




Figure 2-4 : Exemple de calcul de la CTA de F. Roli sur une image de surface de chaussée fortement texturée. Le rectangle vert est la zone utilisée pour l'apprentissage

Pour $N = 32$ et 64 (Figure 2-4 (d,e)), la zone d'apprentissage (zone gauche) a de faibles valeurs de CTA (elle est bien identifiée comme le fond). Par contre, on peut voir que la zone droite (qui appartient aussi au fond) donne de fortes valeurs de CTA (signe de la présence d'un défaut). En fait, la texture a changé et la méthode montre sa sensibilité aux variations de texture entre la zone d'apprentissage et la zone inspectée. Cela traduit une limitation de ces approches basées sur un apprentissage de texture dite "sans défaut".

Dans les approches "région", le problème de la taille de la fenêtre analysée est traditionnel. Quand la fenêtre est petite, elle ne considère pas suffisant d'informations pour caractériser la texture et quand la fenêtre est grande, la variation de la texture aléatoire est beaucoup plus forte que celle qui traduit la présence d'une fissure.

Les mauvais résultats de détection s'expliquent aussi par l'inadaptation des attributs de Fourier (et autres attributs fréquentiels) dans des cas de signaux non stationnaires et de textures à forte granularité [3].

2.2.3.3 Conclusion

Le calcul de la CTA prend bien en compte la caractéristique de forme des fissures (orientation dominante). Les résultats de F. Roli [15], sur la segmentation des images de la Figure 2-3 sont mis en évidence en présence de peu de bruit avec des fissures détectées sur toute leur continuité.

L'idée de base de la CTA "originale" est donc intéressante mais son utilisation dans le cadre des textures aléatoires comme celles des chaussées n'est pas satisfaisante pour les trois raisons suivantes :

- Les attributs de Fourier sont plutôt adaptés pour caractériser des textures périodiques ou pour des textures faiblement texturées,
- La méthode nécessite de connaître a priori le type de texture inspectée pour l'apprentissage. Cela restreint son application pour le cas des textures aléatoires non prédictibles,
- Le choix de la taille de la fenêtre pour la transformée de Fourier est sensible au changement de taille des granulats présents sur la surface de la chaussée. C'est une difficulté supplémentaire pour la mise en œuvre dans le cadre d'une inspection automatique de surfaces de chaussées.

Dans la partie suivante, nous présentons notre adaptation de la CTA pour parer à ces limitations et ainsi l'adapter aux cas des images de chaussées.

2.3 La CTA pour la segmentation d'images de chaussées

Nous présentons, dans cette partie, notre mise en œuvre de la méthode CTA adaptée au problème de segmentation de textures aléatoires, plus précisément celles de chaussées. Nous relevons trois points importants pour calculer la CTA définie par la relation (2.1) :

- Configuration de l'orientation : les attributs doivent-ils être calculés le long d'un "segment " ou sur des régions orientées ?

- La sélection des attributs : quels sont les attributs appropriés pour caractériser des fissures sur des surfaces de chaussées ?
- L'estimation de la vraisemblance $p(x_\theta^l / l \in w_l)$: comment estimer cette fonction sans avoir besoin de faire l'apprentissage à partir d'une image de référence sans défaut ?

2.3.1 Configuration de l'orientation

Nous analysons deux configurations possibles pour le calcul des attributs. Elles sont illustrées dans la Figure 2-5.




Figure 2-5 : Deux configurations de l'orientation : (a) Configuration "segment" : des attributs sont calculés le long des segments, (b) configuration régions : des attributs sont extraits des pixels appartenant aux régions d'orientations différentes.

Localement, une fissure peut avoir la forme d'une structure linéaire, autrement dit un segment ("trait") [17, 39, 41, 59], et les attributs de texture devraient fortement changer le long de ce segment. Cette hypothèse conduit à la première configuration dite configuration "segment". Selon cette configuration, les attributs x_θ^l autour d'un pixel l vont être calculés suivant différents segments passant par l , avec une longueur $N = 2*d+1$ et avec un angle θ suivant l'axe horizontal de l'image.

Pour la deuxième configuration, dite configuration "région" (Figure 2-5(b)), la valeur de tous les pixels d'un secteur, suivant l'orientation considérée, est prise en compte. Cette configuration laisse supposer que la présence d'une fissure va agir sur la texture ($N \times N$ pixels autour d'un pixel l) en mettant en évidence l'orientation de la fissure. Cette supposition est utilisée dans la méthode CTA "originale" de F. Roli et dans d'autres approches classiques basées sur des attributs régions de texture [57, 65].

2.3.2 Choix d'attributs de texture et estimation de vraisemblance par une approche associée à la théorie des possibilités

Nous cherchons des attributs adaptés aux images de chaussées. Notons que nous ne les cherchons pas pour classifier des textures. L'objectif est de sélectionner ceux qui permettent de calculer une CTA qui changera fortement le long de l'orientation de la fissure.




Figure 2-6 : Illustration du calcul d'attributs dans le domaine spatial sur un pixel de fissure : (a) Configuration segment, (b) Configuration région.

Les attributs peuvent être déterminés dans le domaine fréquentiel, comme cela a été présenté dans la session 2.2.2.1, ou dans le domaine spatial. L'extraction des attributs sur le domaine spatial peut être réalisée suivant 4 orientations traditionnelles 0° , 45° , 90° et 135° comme dans la Figure 2-6.

On rappelle que la caractéristique *luminosité* : "le pixel d'une fissure est plus sombre que le pixel de fond" est importante pour la détection de fissures. Nous cherchons donc des attributs qui prennent en compte cette caractéristique.

Une approche basée sur la *théorie des possibilités* exploitant la théorie des ensembles flous proposée par Dubois et Prade [70] a été adoptée pour l'estimation de la vraisemblance $p(x_\theta^l / l \in w_l)$.

2.3.2.1 Modélisation de la texture par une source d'information imprécise

Rappelons que la texture d'un pixel l est caractérisée par la distribution des intensités des pixels autour de l . Nous avons modélisé la texture autour du pixel l (en considérant les voisins de l le long d'un segment orienté, ou d'une région secteur) comme une source imprécise. D'où chaque valeur s correspondant au niveau de gris d'une pixel de cette région, est considérée comme une observation de la source X . X est représentée par une *distribution de possibilité* π_X (Zadeh[71]).

On appelle $\pi_X(s)$ le «*degré de possibilité*» pour que $X = s$. Avec les conventions suivantes : $\pi_X(s) = 0$ indique l'impossibilité que X vaut s . En revanche, $\pi_X(s) = 1$ indique que X vaut s .

Les valeurs telles que $\pi_X(s) > 0$ forment l'ensemble des valeurs (plus ou moins) possible de X (Dubois et Prade [70]). Du point de vue de la théorie des ensembles flous, la source X peut être représentée sous la forme d'un nombre flou défini par la fonction d'appartenance π_X (F. Duculty [72]). La *distribution de possibilité* π_1 associée à la source X_1 peut être représentée par la moyenne μ_1 des valeurs observées et l'écart-type σ_1 comme illustrée dans la Figure 2-7.




Figure 2-7 : Représentation de la distribution de possibilité associée à X_1 issue de F. Duculty [72].

2.3.2.2 Degré de cohérence entre deux sources

Avec la représentation de la Figure 2-7, le degré de cohérence (ou degré de similarité) entre deux sources π_1 et π_2 est défini par le niveau de consensus (Dubois et Prade [70]) :

$$h(\pi_1, \pi_2) = \sup \{ \min(\pi_1, \pi_2) \} \quad (2.3)$$




Figure 2-8 : Principe sup-min pour la mesure du niveau de consensus entre deux sources.

Sur la Figure 2-8, le $\min(\pi_1, \pi_2)$ est illustré par la courbe en rouge.

La fonction $h(\pi_1, \pi_2)$ donne une notion de similarité entre deux sources. Elle prend des valeurs entre 0 et 1, si π_1 et π_2 sont proches alors $h(\pi_1, \pi_2) = 1$, dans le cas où il n'y a aucune cohérence

entre π_1 et π_2 , alors $h(\pi_1, \pi_2) = 0$. Donc le niveau de consensus, entre une *source* sans défaut : π_{fond} et une *source* qui caractérise la texture suivant l'orientation θ : π_θ , peut remplacer la "vraisemblance" $p(x_\theta^l / l \in w_1)$.

Nous avons donc choisi la *distribution de possibilité* de niveau de gris sur 4 orientations 0° , 45° , 90° et 135° comme des "attributs à analyser". Ces distributions sont déterminées par la valeur moyenne et l'écart-type des niveaux de gris. Nous voyons sur la Figure 2-9 que la présence d'une fissure affecte fortement la valeur moyenne et l'écart type de leurs pixels le long de son orientation dominante (90° dans ce cas).




Figure 2-9 : Variation de moyenne et écart-type sur des pixels de fissures : (a) Ensemble des pixels sélectionnés pour l'analyse des attributs, en rouge : les pixels de fissures, (b) Évolution des moyennes sur 4 orientations, (c) Évolution de l'écart-type sur 4 orientations.

La «vraisemblance» $p(x_\theta^l / l \in w_1)$ est estimée par les niveaux de consensus de la distribution π_θ avec la distribution d'une "texture sans défaut" π_{fond} .

Traditionnellement, la «texture sans défaut» peut être définie à partir d'une image d'apprentissage dite «sans défaut de texture type C_i » comme celle présentée dans la méthode CTA "originale". Malheureusement, la texture de la surface des chaussées varie fortement. On rappelle que l'approche qui consiste à connaître le type de texture inspectée est difficile à mettre en œuvre dans le cadre d'une inspection automatique.

Pour que la fonction $p(x_\theta^l / l \in w_1)$ ne dépende pas d'une texture de référence, il faut trouver une approximation de la valeur moyenne et de l'écart type de la texture dite "sans défaut" de façon locale.

2.3.2.3 Texture "sans défaut" définie localement

On rappelle l'hypothèse : «la fissure n'affecte que la texture de fond sur son orientation dominante ». De ce fait, la distribution π_{fond}^l d'une texture sans défaut autour d'un pixel l peut être approximée par la distribution des pixels rencontrés suivant les orientations en excluant celle dont la moyenne est la plus faible. Cette approximation est réalisée quel que soit le pixel l appartenant ou non à la fissure.

Exemple de calcul de valeurs de CTA

Nous donnons ici, un exemple de calcul de valeurs de CTA par la formule (2.1) d'un pixel de fissure l_1 et d'un pixel de fond l_2 marqués sur la Figure 2-9(a). Le calcul a été réalisé à partir de la configuration "segment", avec comme paramètre $d = 8$ (soit $N=17$).

Le Tableau 2-1 illustre les valeurs moyennes et les écart-types calculés autour de ces deux pixels suivant les 4 orientations ($0^\circ, 45^\circ, 90^\circ, 135^\circ$). La valeur "sans défaut" de l_1 a été obtenue à partir des pixels de 3 orientations $0^\circ, 45^\circ$, et 135° . La valeur "sans défaut" de l_2 a été obtenue à partir des pixels de 3 orientations $0^\circ, 45^\circ$, et 90° . Les valeurs grisées correspondent aux orientations dont la moyenne est la plus faible.

	l_1 (fissure)		l_2 (fond)	
	Moyenne	Ecart type	Moyenne	Ecart type
0°	92,41	36,4	145,3	56,9
45°	108,35	51,7	154,53	56,2
90°	31,71	10,7	165,06	50,1
135°	91	49,05	142,41	50,56
«Sans défaut »	97,25	45,94	154,96	54

Tableau 2-1 : Valeurs moyenne et écart type calculées autour des pixel l_1 et l_2




Figure 2-10 : Illustration du calcul de la CTA de l_1 et l_2 par la méthode CTA dans la configuration segment avec $d = 8$.

Remarque :

Dans cette implémentation de la CTA, nous gardons l'idée générale de la CTA de F. Roli soit : « une mesure qui est minimale dans l'orientation de la fissure ». La vraisemblance est remplacée par $h(\pi_1, \pi_2)$ et la valeur de la CTA ne dépend plus du type de texture inspectée.

2.3.3 Binarisation par seuillage à deux niveaux

Dans ce chapitre, nous nous concentrons sur la segmentation et sur l'étude du comportement des méthodes CTA. Le prétraitement, l'extraction de caractéristiques ou la classification ne sont pas traitées dans ce chapitre. Pour obtenir la carte de segmentation, nous appliquons un seuillage à deux niveaux présenté ci-dessous.

2.3.3.1 Seuillage à deux niveaux

Après le calcul de l'image de la CTA, on recalibre les valeurs de CTA de 0 ... 1 à 0...255. Nous appliquons ensuite un seuillage à deux niveaux tel que :

- Les pixels $< \text{seuil}_B$ sont mis à 0,
- Les pixels $> \text{seuil}_H$ sont mis à 255,
- Les pixels entre seuil_B et seuil_H sont mis à 255 s'ils sont connexes à un pixel $> \text{seuil}_H$ par un chemin passant par des pixels $> \text{seuil}_B$.

Une illustration de ce seuillage est montrée sur la Figure 2-11.

Avec l'image CTA de la Figure 2-11(b), notre méthode (présentée par la suite) a trouvé $seuil_B = 20$ et $seuil_H = 180$. La Figure 2-11(c) illustre trois types de pixels : les pixels noirs comme des pixels avec le niveau de gris $< seuil_B$, les pixels blancs comme des pixels avec le niveau de gris $> seuil_H$ et les pixels gris comme des pixels disposant d'un niveau de gris entre $seuil_B$ et $seuil_H$. Le résultat du seuillage est l'image binaire présentée dans la Figure 2-11(d).




Figure 2-11 : Illustration du seuillage à deux niveaux.

2.3.3.2 Détermination automatique de seuils

Le $seuil_H$ doit être représentatif de la classe de pixels ayant une grande valeur de CTA, donc une grande possibilité d'appartenance aux fissures. Le $seuil_B$ doit représenter la classe de pixels ayant une faible valeur de CTA donc appartenant très probablement au fond. La troisième classe ayant

des valeurs de CTA comprises entre seuil_B et seuil_H , représente les pixels de fissures à faible contraste ou des pixels de fond ressemblant aux fissures.

Pour déterminer les seuil_B et seuil_H nous avons utilisé la méthode d'Otsu [73]. Le principe du seuillage d'Otsu est de trouver les seuils pour qu'ils maximisent la variance inter-classe [73].

La variance inter-classes de deux classes est définie par :

$$\sigma_{\text{inter}}^2 = \omega_1(t)(\mu_1(t) - \mu_T)^2 + \omega_2(t)(\mu_2(t) - \mu_T)^2 \quad (2.4)$$

Avec t le seuil, $\omega_1(t)$ et $\omega_2(t)$: les probabilités des classes 1 et 2 déterminées par t à partir de l'histogramme de l'image. μ_T est la moyenne de l'ensemble des pixels de l'image, $\mu_1(t)$ et $\mu_2(t)$ sont les moyennes des pixels de classe 1 et 2.

Pour le cas multi classe, les seuils t_i^* sont déterminés par la relation suivante :

$$\{t_1^*, t_2^*, \dots, t_{M-1}^*\} = \underset{0 \leq t_1 < \dots < t_{M-1} < L}{\text{Arg Max}} \left\{ \sum_{k=1}^M \sigma_{\text{iner}}^2(t_k) \right\} \quad (2.5)$$

Dans notre cas de seuillage à deux niveaux : $M = 3$ classes, et $L = 255$ niveaux de gris.

Nous avons limité le seuil_H à la valeur 127 (soit $\text{CTA} > 0.5$). Cette condition est nécessaire dans le cas d'une image sans défaut.

2.4 Analyse des résultats

Pour simplifier la lecture, nous allons donner à chaque version de la méthode les noms suivants :

- Méthode CTA_F : CTA originale de F. Roli avec les attributs calculés sur le domaine de Fourier et l'apprentissage est effectué sur une région sans défaut sélectionnée manuellement,
- Méthode CTA_R : notre méthode CTA avec la configuration région,
- Méthode CTA_S : notre méthode CTA avec la configuration segment.

2.4.1 Les vérités terrains

Afin d'évaluer qualitativement les résultats de segmentation et l'influence du paramètre d , nous utilisons des images dont on connaît la vérité terrain.

2.4.1.1 Images de fissures de synthèse

L'utilisation d'images de synthèse permet de connaître parfaitement la taille, la localisation et l'orientation des fissures. Nous avons choisi une image de surface de chaussée ne contenant aucun défaut mais disposant d'une variation de texture sur certaines régions (Figure 2-12(a)). Sur cette image, nous avons ajouté des fissures synthétiques de manière numérique. Les pixels appartenant aux fissures ont été créés avec des niveaux de gris aléatoires et voisins de ceux de la texture (comme dans la fissure réelle). Dans l'image de la Figure 2-12(b), le niveau de gris des pixels appartenant aux fissures de synthèse prend des valeurs comprises entre 50 et 70 (Figure 2-12(d)).




Figure 2-12 : (a) Image de chaussée sans défaut. (b) Image avec des fissures aux formes droites avec des largeurs variant entre 1 et 4 pixels, (c) Image binaire des positions de fissures, (d) Un profil transversal.

2.4.1.2 Images de fissures réelles

Sur des images de fissures réelles, les fissures sont déterminées par des experts en traçant des courbes de couleur rouge (Figure 2-13(b)). Puis à partir de ces images, des images dites de vérité

terrain, qui présentent clairement la location des fissures (Figure 2-13(c)), sont produites. L'exemple d'une telle image avec une fissure longitudinale et sa vérité terrain est présenté dans la Figure 2-13.




Figure 2-13 : Création des vérités terrains : (a) Fissure longitudinale, (b) Sélection de la fissure par un expert, (c) Image binaire de positionnement des fissures.

2.4.2 Critères d'évaluation

2.4.2.1 Bonne détection, fausse alarme, détecté et non détecté

A partir des régions de fissures V dans la vérité terrain, nous avons créé des zones de fissures V_e . Les V_e ont été déterminées en épaississant V d'une largeur δ_v pixels. Les zones restantes sont considérées comme étant les zones de fond (Figure 2-14(a)). De la même manière, nous avons créé la zone R_e à partir de l'image résultat R en l'épaississant d'une largeur δ_R pixels.

On considère deux types de pixel dans l'image résultat :

- Un pixel $l \in (R \cap V_e)$ est un *pixel de bonne détection* s'il appartient aux régions des fissures R dans l'image résultat et aux zones de fissure, V_e , dans la vérité terrain (Figure 2-14(c)).
- Un pixel $l \in (R \setminus V_e)$ est un *pixel fausse alarme (ou pixel bruit)* s'il appartient à R mais n'appartient pas à V_e .

On considère deux types de pixel dans la vérité terrain :

- Un pixel $l \in (V \cap Re)$ est un pixel détecté, s'il appartient aux régions de fissures V (non épaissies) dans la vérité terrain et aux régions de fissures Re (épaissies) dans l'image résultat,
- Un pixel $l \in (V \setminus Re)$ est non détecté, s'il appartient à V mais n'appartient pas à Re .




Figure 2-14 : (a) Image des zones de fond et des zones de fissures $\delta_v=8$,
 (b) Exemple d'une image binaire, le seuillage a été réalisé pour qu'il présente un bruit,
 (c) Pixels "fausse alarme" (bruit) et pixels de fissures, (d) Pixel détecté et pixel non détecté $\delta_v=3$.

Nous avons adopté ensuite les critères d'évaluation suivants.

2.4.2.2 Critère de la distance entre classes de Delagnes [3]

Par ce critère, nous avons défini deux valeurs :

- Valeur CTA moyenne $CTA_{fissure}$ des pixels $l \in V$ (les pixels correspondent aux positions de la vérité terrain),
- Valeur CTA moyenne CTA_{fond} des pixels $l \notin Ve$ appartenant à la zone de fond.

La valeur $|CTA_{fissure} - CTA_{fond}|$ est un indicateur de la distance entre les deux classes, classe "fissure" et classe "fond". Ce critère permet d'évaluer la méthode de transformation (ici des méthodes CTA) en terme de rehaussement du contraste entre les fissures et le fond.

2.4.2.3 Proportion de Bonne Détection (PBD)

Ce critère est similaire à celui proposé par Chambon et al [1] pour qualifier la sensibilité de la segmentation. Nous l'avons définie comme suit :

$$PBD = \frac{card_{pixels}(R \cap Ve)}{card_{pixels}R} \quad (2.6)$$

$$= \frac{\text{nombre de pixels bonne détection}}{\text{nombre de pixels bonne détection} + \text{nombre de pixels de fausse alarme}}$$

Le PBD varie de 0 à 1, plus le PBD est faible, plus il est difficile de distinguer les images sans défaut des images avec défauts. Si le PBD vaut 1 alors cela veut dire qu'il n'y a pas de fausses alarmes.

2.4.2.4 Précision (Pr)

Ce critère qualifie la précision de la segmentation. Nous l'avons définie comme suit :

$$Pr = \frac{card_{pixels}(R \cap V)}{card_{pixels}(R)} = \frac{\text{Nombre de pixels détectés}}{MAX(\text{Nombre de pixels de vérités terrains}, 1)} \quad (2.7)$$

Pr varie entre 0 à 1.

2.4.2.5 Degré de Discontinuité (DD)

Ce critère qualifie le niveau de discontinuité (sur segmentation) des fissures segmentées. Nous l'avons défini comme suit :

$$DD = \frac{card_{régions}(R \cap Ve)}{card_{régions}(V)} = \frac{\text{nombre de régions bonnes détections}}{MAX(\text{nombre de régions de fissures}, 1)} \quad (2.8)$$

Avec la région de bonne détection, une composante connexe trouvée sur des pixels de bonne détection. DD = 1 lorsque le nombre de régions bonnes détections est égal au nombre de fissures.

2.4.3 Comportement de la CTA selon la distance

Le paramètre qui influence le plus les méthodes CTA est le paramètre de distance d . Pour la CTA_R, la taille de la fenêtre est $N = 2*d+1$ et pour la CTA_S, la longueur du segment est $N = 2*d+1$. Pour évaluer l'influence de celle-ci sur le résultat de la méthode, nous utilisons une image de synthèse (Figure 2-12 (b)) afin de connaître parfaitement la position des fissures.

CTA_S sur une image de synthèse :

La Figure 2-15 montre l'évolution des valeurs de CTA calculées pour la configuration "segment".




Figure 2-15 : Évolution de la CTA selon la distance d pour la méthode CTA_S

La courbe verte représente l'évolution de la CTA des pixels de fond CTA_{fond} . Lorsque le voisinage considéré est suffisamment important ($d \geq 8$), la valeur de la CTA évolue faiblement, ce qui correspond à la disparition du fond texturé (Figure 2-16(c)). La courbe rouge représente l'évolution de la valeur $CTA_{fissure}$. Pour de petites valeurs de d , $CTA_{fissure}$ prend des valeurs proches de CTA_{fond} . Ces valeurs augmentent avec d pour atteindre un maximum quand $d = 8$. Elle évolue faiblement avec d quand celle-ci est supérieure à 8. Lorsque d est suffisamment important $CTA_{fissure}$ et $|CTA_{fissure} - CTA_{fond}|$ ont la même évolution avec d . On peut noter que, dans ces conditions, la valeur de distance $|CTA_{fissure} - CTA_{fond}|$ est assez peu sensible au changement de d . Cela permettra de choisir une distance d assez facilement et de s'assurer de la stabilité de la méthode.

La Figure 2-16 illustre la capacité de la méthode (avec $d = 8$) de rehausser le contraste entre la fissure et le fond. Tandis que la Figure 2-17 montre les résultats de la méthode CTA_S avec différentes valeurs de d .




Figure 2-16 : Exemple de CTA_S calculé sur un profil transversal : (a) Un profil transversal de l'image originale, (b) Tracé de ce profil, (c) Tracé de ce profil sur l'image CTA, $d = 8$.




Figure 2-17 : Résultats pour différentes distances d sur une image de synthèse.
Haut – Les profils transversaux : valeurs des pixels sur une ligne (rouge) des images CTA,
Milieu – Résultats de la CTA calculés par la méthode CTA_S,
Bas – Résultats de la segmentation par seuillage à deux niveaux.

Sur la Figure 2-17, quand $d \geq 8$, on voit bien que les fissures qui ont une orientation favorable (0° , 45° , 90°) sont bien détectées avec peu de bruit.

Par contre, on remarque que les fissures ayant une orientation défavorable (ici 102.5°) sont moins facilement détectables. Avec $d = 8$, on arrive à détecter ces fissures larges (≥ 2 pixels de largeur), mais pas celle de 1 pixel de largeur. Dès que d augmente, on ne détecte plus rien.

CTA_R sur une image de synthèse :

La Figure 2-18 montre l'évolution des valeurs de la CTA calculées pour la configuration "région".




Figure 2-18 : Evolution de la CTA selon la distance d pour la méthode CTA_R

Sur cette courbe la distance $|CTA_{fissure} - CTA_{fond}|$ atteint un maximum pour $d = 6$. On remarque que pour le fond, cela ne change pas énormément par rapport à la méthode CTA_S. Par contre pour la $CTA_{fissure}$, on constate une grande dépendance de sa valeur avec la distance d et surtout que, quand d est grande, la distance $|CTA_{fissure} - CTA_{fond}|$ devient très faible.




Figure 2-19 : Résultats de la CTA calculés par la méthode CTA_R selon d sur une image de synthèse.

Les résultats de la Figure 2-19 montrent que la configuration "région" est plus efficace pour les orientations dites "défavorables" mais qu'elle est plus dépendante de la distance d et de la largeur de la fissure. Les variations de moyenne et d'écart-type, qui ont pour origine la présence d'une fissure sur une région orientée, ne sont plus significatives à cause des variations de la texture dans cette région.

2.4.4 Résultats sur l'image réelle

Les résultats, présentés dans cette partie, permettent d'étudier le comportement, les avantages et inconvénients des méthodes. L'évaluation complète, sur différentes bases d'images et en comparant avec d'autres méthodes, sera présentée dans le Chapitre 4.

Nous présentons, dans la Figure 2-20, un exemple de la segmentation d'une image réelle de chaussée. L'image originale dans la Figure 2-20(a) est de taille 512x512, de fond fortement contraste¹. L'image contient deux fissures longitudinales de largeurs variant de 1 à 8 mm.

La Tableau 2-2 présente l'évaluation des différentes méthodes pour les cas $d = 8$, selon les critères proportion de bonne détection (PBD), précision (Pr) et degré de discontinuité (DD) définis dans la partie 2.4.2.

Méthode	Bonne détection (PBD) (%)	Précision (Pr) (%)	Discontinuité
CTA_F (Roli)	19	3,6	2.5
CTA_R	85	19,1	4.5
CTA_S	100	72	5

Tableau 2-2 : Comparaison des segmentations selon les critères PBD, Pr et DD pour $d = 8$

La méthode CTA_F ne fonctionne pas avec ce type de chaussées, il obtient une très faible proportion de bonne détection (19,1%) et précision (3,6%).

La CTA_R ne détecte que des portions très épaisses.

La CTA_S donne les meilleurs résultats avec très peu de fausse alarme (0% dans ce cas) et une bonne précision (72%). Par contre, on peut observer la limitation concernant l'orientation

¹Attributs contraste d'Haralick = 1038

défavorable (ou la forme libre) de la fissure, particulièrement sur des portions de fissures très fines (près de 1-2 mm de large).




Figure 2-20 : Résultats des différentes versions de la CTA sur une image de chaussée de type fortement texturée

2.5 Conclusion

Dans ce chapitre, nous avons étudié l'idée de prendre en compte à la fois, pour la segmentation, **des attributs** et la **relation spatiale** des pixels de fissures.

Nous avons présenté la méthode de F. Roli [15] telle qu'il l'a présentée (méthode "originale"). Cette méthode offre de bonnes perspectives pour la détection de fissures. L'idée générale est de calculer des attributs le long de la forme de la fissure.

Après l'avoir testée sur des images de surface de chaussées, on montre que, la mise en œuvre de F. Roli a des limitations dans le contexte de textures aléatoires. Ces limitations viennent de l'utilisation d'attributs de Fourier et de la nécessité d'apprentissage de la texture "sans défaut".

Nous avons développé deux versions de CTA pour pallier ces limitations.

En considérant la caractéristique "luminosité" d'une fissure, nous avons modélisé la texture par des sources imprécises et utilisé la méthode sup-min [70] pour estimer les attributs le long de 4 orientations. L'apprentissage n'est plus nécessaire car la mesure de CTA ne prend alors en compte que l'information locale autour de chaque pixel inspecté.

Nous avons testé deux configurations orientées correspondant aux hypothèses de fissures dans la littérature : configuration "segment" (CTA_S) et configuration "région" (CTA_R).

La méthode CTA_S permet d'obtenir de bons résultats dans le cas d'orientation favorable des fissures. Si les attributs "luminosité" sont bien calculés le long d'une forme qui suit la fissure, cette méthode obtient de bons résultats avec peu de fausse alarme. CTA_S utilisant la configuration "segment" ne peut détecter les portions fines de fissures à orientations défavorables. Cette limitation est due au choix de voisinages explorés pour le calcul des attributs (0° , 45° , 90° et 135°).

La configuration "région" est moins sensible aux variations d'orientations des fissures. Cependant, elle nécessite un fort contraste entre les fissures et le fond pour assurer la détection. En effet, une fissure trop fine ou peu marquée sera "noyée" dans la région considérée.

La méthode idéale devrait permettre d'exploiter les avantages de la méthode segment (CTA_S) mais sans être limitée par l'orientation ou la forme de la fissure. C'est l'objet de la méthode proposée au chapitre suivant.

Chapitre 3

Free-Form Anisotropy

CONTENU

3.1	INTRODUCTION.....	69
3.2	MODELISATION DE L'IMAGE ET DE LA FISSURE.....	70
3.2.1	<i>Hypothèse concernant la fissure.....</i>	70
3.2.2	<i>Généralités sur les graphes</i>	70
3.2.3	<i>Modélisation de l'image</i>	72
3.2.4	<i>Chemin minimum.....</i>	74
3.2.5	<i>Modélisation de la fissure.....</i>	76
3.3	FREE FORM ANISOTROPY	76
3.3.1	<i>Définition</i>	76
3.3.2	<i>Exemple de calcul de la FFA.....</i>	77
3.3.3	<i>Discussion sur les configurations de chemin minimum</i>	79
3.3.4	<i>Algorithmes pour trouver le chemin minimum.....</i>	80
3.3.5	<i>Exemples de chemins minima sur une image.....</i>	84
3.3.6	<i>Connexion de composantes connexes</i>	86
3.4	ANALYSE DES RESULTATS	88
3.4.1	<i>Complexité calculatoire.....</i>	88
3.4.2	<i>Influence du paramètre d.....</i>	88
3.4.3	<i>Influence du type de chaussées sur la méthode.....</i>	90
3.4.4	<i>Sélection du paramètre d.....</i>	92
3.4.5	<i>Résultats sur images réelles.....</i>	92
3.5	CONCLUSION	95

3.1 Introduction

Dans la littérature, une fissure est supposée avoir la forme de segments prenant une des quatre orientations dites traditionnelles ($0^\circ, 45^\circ, 90^\circ, 135^\circ$) [15, 17, 39, 61]. Cette hypothèse peut être satisfaisante pour la détection de fissures assez larges. Cependant, dans le chapitre précédent, nous avons montré que ces hypothèses nous limitent dans le cas d'orientation défavorable ou de forme libre ("free-form") de fissures. Cette *structure linéaire*¹ est une approximation de la fissure et cette hypothèse est incomplète.

Dans ce chapitre, nous proposons une nouvelle approche. Nous considérons une hypothèse plus générale pour la fissure, qui prend en compte la "forme libre" et l'orientation arbitraire de la fissure. La structure linéaire reste un cas particulier de cette nouvelle hypothèse.

Après avoir rappelé les notions de base sur la théorie des graphes et la modélisation d'images par des graphes, nous définirons les notions de *chemin minimum* et la modélisation des fissures par cet outil. Cet outil permettra de remplacer les configurations d'orientations "segment" et "région" par la configuration chemin minimum. Les attributs de texture de chaque orientation seront calculés le long du chemin minimum.

Par la suite, nous présenterons une mesure que nous avons appelée "Free-Form Anisotropy" (FFA) basée sur les configurations de chemins minima. Nous verrons également comment s'applique cette méthode pour la segmentation de fissures sur la surface de chaussées.

Nous présenterais ensuite, l'algorithme incrémental utilisé pour la recherche de chemins minima qui permettra de mettre en œuvre la méthode FFA. Une méthode de segmentation utilisant la FFA et l'opération de connectivité seront présentées à la fin de ce chapitre.

¹ Structure linéaire : désigne les structures globales composées de primitives de type segment

3.2 Modélisation de l'image et de la fissure

3.2.1 Hypothèse concernant la fissure

Dans ce chapitre, on pose les hypothèses suivantes pour une fissure :

- 1) Une fissure est une structure fine dont la longueur est beaucoup plus grande que la largeur.
- 2) Une fissure, ou cette structure fine, peut avoir une orientation quelconque et une forme arbitraire.
- 3) Le niveau de gris moyen calculé à partir des pixels d'une fissure est plus faible que celui calculé sur la texture dite "sans défaut".

Cette hypothèse présente deux points différents en comparaison avec celle dans la littérature. La première concerne la forme et l'orientation libre de la fissure. La deuxième concerne la caractéristique "luminosité" des fissures. Selon cette hypothèse, nous ne considérons pas isolément que les *pixels* de fissures soient plus sombres que les pixels de fond, mais que les *niveaux de gris moyens de N pixels de fissures* sont plus sombres que les niveaux de gris moyens de *N pixels de fond*.

Afin de pouvoir traduire ces hypothèses et permettre de les coder sous forme algorithmique, nous avons utilisé une représentation des images par des graphes. Cette représentation, présentée dans la partie qui suit, va nous permettre de rechercher les configurations s'approchant de l'hypothèse "idéale" de fissures.

3.2.2 Généralités sur les graphes

Définition d'un graphe :

Un graphe $G=(S, A)$ est défini par deux ensembles :

- S : Ensemble dont les éléments sont appelés des *sommets* ou des *nœuds*,
- $A \subset S \times S$: Ensemble d'*arcs* ou *arêtes* (arête est la notion pour le graphe non orienté tandis que arc est celle pour le graphe orienté).

Graphe orienté/non orienté :

Un graphe est orienté si ses arcs sont définis par leur origine et leur extrémité, c'est-à-dire munis d'un sens. Dans le cas contraire, il est dit non orienté.

Graphe valué :

Un graphe $G = (S, A)$ (orienté ou non) est valué, si il est muni d'une application :

$$\begin{aligned} v: A &\rightarrow R \\ (s_i, s_j) &\mapsto v(s_i, s_j) \end{aligned}$$

v sera appelée valuation. Intuitivement, un graphe valué est le graphe qui pour chaque *arc / arête* a une valeur associée. La Figure 3-1 montre deux exemples de graphes valués.




Figure 3-1 : Exemple de graphes valués : (a) Graphe non-orienté, (b) Graphe orienté

Chemin et valuation d'un chemin :

Dans un graphe orienté, un chemin d'origine s_i et d'extrémité s_j est défini par une suite finie d'arcs consécutifs permettant de relier s_i à s_j . La notion correspondante dans les graphes non orientés est celle de chaîne.

Soit $G = (S, A, v)$ un graphe valué. La *valuation d'un chemin* (ou d'une chaîne) est la somme des valuations de chacun des arcs (arêtes) qui le composent.

Par exemple, sur la Figure 3-1 (a), la valuation du chemin $\{s_1, s_2, s_3, s_4\} = 1 + 5 + 0 = 6$.

Longueur d'un chemin :

La longueur du chemin est le nombre d'arcs utilisés, où le nombre de sommets moins un. Par exemple, sur la Figure 3-1(a), la longueur de chemin $\{s_1, s_2, s_3, s_4\} = 3$.

Plus court chemin :

On appelle *plus court chemin* / *plus courte chaîne* de s_i à s_j tout *chemin* / *chaîne* dont la *valuation* est égale au minimum des valuations des chemins / chaînes allant de s_i à s_j .

3.2.3 Modélisation de l'image

Une image peut être modélisée comme un graphe. Par cette approche, l'image n'est pas simplement vue comme une matrice mais comme un *graphe valué* $G=(S, A)$. Cela nécessite de préciser les notions de base.

Sommets et arêtes

L'image I est considérée comme un ensemble fini de *sommets*, noté $S = \{s_1, \dots, s_N\}$, Généralement, un sommet correspond à un pixel. A est l'ensemble des *arêtes* entre deux sommets.

Voisinages directionnels

Le voisinage permet de définir l'ensemble A des arêtes / arcs. Dans un graphe non-orienté, l'ensemble A peut être traditionnellement déterminé par un *voisinage* 4-connexe ou 8-connexe. Dans le but de modéliser et de rechercher des fissures, nous n'utilisons pas des voisinages traditionnels 8- ou 4- connexe mais des voisinages que l'on qualifie de *voisinages directionnels*, chaque voisinage définira un type de graphe correspondant. On peut trouver l'illustration de ce type de voisinage à la Figure 3-2.




Figure 3-2 : Voisinage directionnel selon la direction / le parcours

Les graphes non-orientés sont utilisés par la suite pour représenter les chemins, tandis que les graphes orientés sont utilisés pour la recherche de chemins comme illustré dans la Figure 3-3 .

Chemins dans des graphes déterminés par des voisinages directionnels

La Figure 3-3 illustre un exemple de 2 types de chemins : deux chemins ayant pour origine un sommet l (sur deux graphes orientés), et un chemin passant par un sommet l (sur un graphe non-orienté).

La recherche d'un chemin ayant pour origine ou passant par un sommet l , dans un graphe défini par un voisinage directionnel, sera limitée à une région correspondant au type de voisinage.




Figure 3-3 : Exemple de chemin correspondant à différents voisinages/graphes :

- (a) Un chemin longueur 7, d'origine le pixel l dans un graphe du voisinage direction vers la gauche,
- (b) Un chemin longueur 7, d'origine le pixel l dans un graphe du voisinage direction vers la droite,
- (c) Un chemin longueur 14 passant par un pixel l dans le graphe non-orienté parcours transversal.

Valuation des graphes :

Nous voulons faire la valuation des graphes pour que les valuations de ces chemins soient rationnelles avec la somme des niveaux de gris de ses pixels (sommets). Ainsi, nous attachons à chaque arc /arête, qui connecte deux sommets (pixels) l_1 et l_2 , une valeur qui est la somme des niveaux de gris de ces deux pixels (Figure 3-4).




Figure 3-4 : Illustrations de valuations d’une image modélisée comme des graphes : (a) Graphe orienté valué correspondant au voisinage direction vers la gauche, (b) Graphe orienté valué, correspondant au voisinage direction vers la droite, (c) Graphe non-orienté, correspondant au voisinage parcours transversal.

Dans la partie suivante, on définit un autre concept pour les graphes, celui de chemin minimum. Ce concept est utilisé pour modéliser des *structures fines*¹[39] et en particulier, les fissures.

3.2.4 Chemin minimum

Nous présentons le *chemin minimum* en partant du concept de *plus court chemin*.

Exemple : on modélise chaque ville de France comme un sommet et chaque autoroute qui connecte deux villes comme une arête. La valuation d’une arête pourra être le coût pour passer sur cette autoroute. Le *plus court chemin entre Paris et Orléans* est alors celui qui minimise ce coût sans considération sur le nombre de villes à traverser ou d’autoroutes à emprunter.

Le chemin minimum est un autre type de chemin optimum choisi avec un critère différent. Pour l’exemple précédent, la question pour la recherche du chemin minimum devient alors : *Quel est le chemin à emprunter qui permet de partir de Paris et de traverser N autres villes différentes sans considération pour la destination, mais en minimisant la somme à payer ?*

On appellera ce type de chemin le *chemin minimum* qui est défini :

¹ Structure fine : structure dont la longueur est beaucoup plus importante que la largeur.

Sur un graphe orienté valué :

- Un *chemin minimum d'origine l et de longueur d* est tout chemin d'origine l dont la longueur est égale à d et dont la valuation est minimale.

Sur un graphe non-orienté valué :

- Un *chemin minimum passant par l et de longueur $2*d$* est tout chemin qui prend l pour sommet central en ayant une valuation minimale.

Illustration de chemin minimum

La recherche de chemins minima sur un graphe non-orienté 8- ou 4 connexe risque de déboucher sur des *chemins "retours"* (Figure 3-5(a)) ou des *chemins "bouclés"* (contenant des *cycles*¹) (Figure 3-5(b)). Le chemin espéré est celui de la Figure 3-5(c).




Figure 3-5 : Différents types de chemins : (a) Chemin "retour", (b) Chemin "bouclé", (c) Chemin espéré.

En utilisant les voisinages directionnels (Figure 3-2) et les graphes orientés, chaque pixel a trois voisins au lieu de 8. Cela permet d'éviter les chemins inappropriés (*chemins "bouclés"* et *chemins "retours"*).

Comme l'illustre la Figure 3-3, un chemin minimum passant par l , sur un graphe non-orienté pour un parcours donné (transversal, longitudinal...), sera trouvé en recherchant le chemin minimum d'origine l sur les deux graphes orientés correspondants.

Pour chaque pixel l , 4 chemins minima passant par l sont trouvés correspondant à 4 parcours (Figure 3-6).

¹ Un cycle est une suite d'arêtes (arcs) consécutifs dont les deux sommets extrémités sont identiques.




Figure 3-6 : Illustration des chemins minima de 4 parcours passant par l : (a) Parcours transversal, (b) Parcours longitudinal, (c) Parcours oblique 135° , (d) Parcours oblique 45° .

Notons que deux parcours, par exemple transversal et longitudinal, peuvent couvrir l'ensemble des sommets. Mais cela présente des limitations pour les chemins à la frontière des parcours (45° et 135°). L'utilisation de 4 parcours permet d'éviter ces limitations.

3.2.5 Modélisation de la fissure

Nous modélisons une fissure comme suit :

« Une fissure est un chemin minimum passant par ses pixels. Elle prend des longueurs différentes avec une largeur de 1 ».

Cette modélisation correspond à la représentation de la fissure des gestionnaires routiers. On peut remarquer que la largeur d'une fissure est considérée pour répondre à la question « à partir de quelle largeur une fissure peut-elle être détectable ? ». Une fois que la fissure est détectée, elle est représentée par un chemin de largeur 1 (pixel).

3.3 Free Form Anisotropy

3.3.1 Définition

En partant de l'hypothèse concernant la fissure et de la modélisation définies précédemment, si une fissure est présente sur un parcours (orientation) et si un pixel l appartient à cette fissure on constate que :

- 1) Cette fissure est le chemin minimum passant par l trouvé dans ce parcours.

- 2) Le chemin minimum passant par l trouvé sur le parcours de la fissure est de plus faible valuation que le chemin minimum passant par l trouvé dans les parcours qui ne contiennent pas de fissure.

En considérant les chemins minima passant par un pixel l trouvés selon les 4 parcours :

- On appelle *parcours min*, le parcours selon lequel le chemin minimum trouvé a la valuation minimale. On appelle également ce chemin le *chemin min*.
- On appelle *parcours max*, le parcours selon lequel le chemin minimum trouvé a la valuation maximale. On appelle ce chemin le *chemin max*.

Pour la détection d'une fissure, nous avons défini une nouvelle mesure que l'on appelle «Free Form Anisotropy » - FFA, telle que :

$$FFA(l) = 1 - h(\pi_{\min}, \pi_{\text{fond}}) \quad (2.9)$$

Avec :

- $\pi_{\min}$ la distribution de niveaux de gris des pixels le long du *chemin min*. Dans le cas de l appartenant à une fissure, $\pi_{\min}$ est calculée le long de la fissure.
- π_{fond} est la distribution de niveaux de gris suivant le *chemin max*.
- $h(\pi_{\min}, \pi_{\text{fond}})$ traduit le degré de cohérence des deux *distributions de possibilité* $\pi_{\min}$ et π_{fond} (cf. chapitre précédent).

Une illustration de ces chemins (π_{fond} et $\pi_{\min}$) est visible sur la Figure 3-7.

3.3.2 Exemple de calcul de la FFA

Maintenant, nous allons voir l'utilisation des chemins minima pour le calcul de la FFA sur deux pixels, un pixel appartenant à une fissure (pixel l_4) et un pixel appartenant au fond (pixel l_6). Le positionnement de ces pixels peut être visualisé sur la Figure 3-12. Dans la figure qui suit (Figure 3-7), nous présentons des zooms autour des pixels considérés ainsi que la valeur du degré de cohérence calculée pour ces pixels (cf. section 2.3.2).

Sur la Figure 3-7(a)(c), les parcours verts sont les chemins max, et les parcours rouges sont les chemins min (rappelons que le chemin max est le chemin minimum trouvé selon le parcours max). Dans le cas des pixels de fissures, il y a de grandes différences de niveaux de gris entre ces deux chemins (cohérence faible). Tandis que, dans le cas de pixels de fond, cette différence est moindre (cohérence forte). Pour le pixel de fissures (Figure 3-7(b)), le degré de cohérence entre $\pi_{\min}$ et π_{fond} est de 0.09 qui donne une valeur de la FFA de 0.91. Cette valeur de FFA tombe à 0.17 si elle est calculée pour un pixel de fond (Figure 3-7(d)).




Figure 3-7 : Exemple de calcul de la FFA sur l_4 (pixel de fissure) et l_6 (pixel de fond) avec $d = 30$:
(a) Zoom autour du pixel l_4 et la configuration pour calculer la FFA, (b) Degré de cohérence h de $\pi_{\min}$ avec π_{fond} de l_4 ,
(c) Zoom autour du pixel l_6 et la configuration pour calculer la FFA, (d) Degré de cohérence h de $\pi_{\min}$ avec π_{fond} de l_6 ,

Un autre exemple de calcul de FFA est illustré dans la Figure 3-8. Dans cet exemple, on présente un profil transversal sur une image de chaussée avec une fissure longitudinale ainsi que le même profil sur l'image des valeurs de la FFA.




Figure 3-8 : Analyse d'un profil transversal d'une image de fissure longitudinale : (a) Image fissure longitudinale, (b) Image FFA, $d = 30$, (c) Profil transversal de l'image originale, (d) Profil transversal de l'image FFA.

Sur la Figure 3-8(c), on voit que la présence de la fissure est noyée dans les variations de texture. Les taches sombres présentent des minima locaux importants sur le signal du profil. La position de la fissure dans le profil est impossible à mettre en évidence dans ces conditions. Dans le cas de l'image obtenue à partir du calcul par la méthode FFA, le même profil présente une grande valeur qu'en cas de présence de la fissure. Sur la Figure 3-8(d), on voit bien un pic significatif correspondant à la position de la fissure.

3.3.3 Discussion sur les configurations de chemin minimum

La Figure 3-9 illustre la configuration du chemin minimum en comparaison avec la configuration "segment" et la configuration "région" du chapitre précédent.




Figure 3-9 : Illustration de trois configurations de $\pi_{\min}$: (a) Configuration segment, (b) Configuration région, (c) Configuration chemin minimum.

Dans la configuration "segment", nous étions limités pour des orientations et des formes défavorables de fissures. Pour la configuration "région", la limite se situait au niveau des variations de la texture de ces régions (par exemple, la présence des pixels brillants). La configuration chemin minimum peut pallier à ces limitations.

3.3.4 Algorithmes pour trouver le chemin minimum

Bien qu'il n'y ait pas de contraintes temps réel fortes, il y a un nombre de données très important à traiter et le temps de traitement reste tout de même limité pour l'analyse routière. Ainsi l'algorithme pour trouver des chemins minima pour chaque pixel doit avoir un *coût* de calcul acceptable.

On rappelle que les chemins minima de longueur $2*d$, passant par l dans les graphes non orientés, sont trouvés par les chemins minima de longueur d , d'origine l des graphes orientés. Les algorithmes suivants sont pour la recherche des chemins minima de longueur d , d'origine l sur un graphe orienté, avec l le sommet de ces graphes.

3.3.4.1 Croissance de courbe

Le concept de croissance de courbe vient naturellement pour la recherche des chemins "Free-Form". Par cette approche, le chemin est obtenu par croissance à partir du sommet l . A chaque étape, le sommet "minimum", parmi les trois voisins, est sélectionné pour s'ajouter au chemin. C'est une approche simple et le chemin trouvé n'est pas le chemin minimum.

Il faut se souvenir que les fissures sont souvent discontinues. De plus, le *minimum* ne doit pas être considéré à partir d'un pixel mais bien à partir de la moyenne totale de d pixels. A une étape t , un parcours passant par un pixel, qui n'est pas le minimum des trois, peut être pointé comme appartenant à la branche avec la valuation totale minimum. L'illustration de "mauvais" chemins, trouvés par croissance de courbe, est présentée sur la Figure 3-10. En (a) on trouve la représentation en graphe des deux parcours, en (b) le mauvais chemin (qui ne suit pas la fissure) obtenu par accroissement de courbe et en (c) le chemin correct (qui suit la fissure).




Figure 3-10 : Illustration des chemins : (a) Principe sur un arbre trinaire,
 (b) Chemin «croissance de courbe » d'origine un pixel de fissure d'une image, $d = 50$ moyenne = 96,34,
 (c) Chemin minimum d'origine un pixel de fissure, $d=50$, moyenne = 52.

3.3.4.2 La recherche gloutonne


La première approche pour trouver le chemin minimum est l'algorithme glouton. Cette approche consiste à traverser tous les chemins possibles sur le graphe afin de trouver les parcours minima. A chaque pixel l et sur un graphe orienté, le problème consiste à traverser un *arbre trinaire* de hauteur d (Figure 3-10(a)). La complexité de l'algorithme est exponentielle $O(3^d N)$ et le temps d'exécution devient excessif quand d augmente. Sur notre implémentation gloutonne, avec une longueur $d = 8$ et une image de taille 512 par 512 pixels, la méthode a besoin d'environ 3 jours pour obtenir le résultat. Cette approche est donc difficilement exploitable.

Le *chemin minimum* devrait être trouvé avec un *coût* beaucoup plus acceptable. Il existe dans la littérature l'algorithme de Dijkstra [74]. Il permet de trouver le plus court chemin entre deux sommets (deux pixels) avec un coût de $O(N \ln(N))$. Cependant, le chemin minimum est différent du plus court chemin. Cet algorithme ne peut donc pas être appliqué dans notre cas.

Nous avons donc été dans l'obligation de trouver un algorithme spécifiquement adapté à notre besoin. Voici, notre méthode pour trouver ce chemin minimum.

3.3.4.3 Méthode incrémentale

L'idée de notre méthode incrémentale est de calculer le chemin minimum de longueur d à partir du chemin minimum de longueur $d-1$. Pour cela, nous avons besoin de définir une structure de données telle que :



Cette structure de donn es permet de m moriser le chemin minimum depuis le sommet origine pour des longueurs de 0   d. Au lieu de m moriser seulement la valeur de niveau de gris des pixels, nous allons m moriser les *valu s* des chemins minima et les positions (code de Freeman) du voisin correspondant au *chemin minimum*.

Algorithme : Recherche du chemin minimum

Donn es :

- $G = \langle S, A \rangle$ Graphe orient  et valu , mod lisant l'image inspect e pour une direction donn e. Avec S^k le tableau   deux dimensions de sommets de m me taille que l'image inspect e. A est d fini par un voisinage directionnel.

R sultat : Tableaux S^d contenant des chemins minima d'origine s_l de longueur 0...d pour tous les sommets $s_l \in S^d$ avec s_l le sommet correspondant au pixel l .

Initialiser tableaux S^0 pour que chaque sommet $s_l^0 \in S^0$:

$s_l^0.valu [0] = \text{niveau de gris du pixel } l$

$s_l^0.voisin_min[0] = s_l^0$

Pour longueur $k = 1$   d **faire**

Pour chaque sommet $s_l^k \in S^k$ **faire**

Chercher le voisin $vs_l \in Voisin \text{ de sommet } s_l$ qui a le valu  minimum de chemin minimum d'origine vs_l longueur k-1

$vs_{l,min} = \underset{vs_l}{\operatorname{argmin}} (vs_l.valu [k-1])$

Mis   jour s_l^k :

$s_l.valu [k] = l + vs_{l,min}.valu [k-1]$

$s_l.voisin_min[k] = vs_{l,min}$

Fin

Fin

Fin d'algorithme

Le principe est simple, le chemin minimum ayant pour origine le sommet s_i de longueur k , est calculé en déterminant quel est le voisin vs_l de s_l disposant du chemin minimum d'origine vs_l de longueur $k-1$ minimum.

Complexité de l'algorithme

Pour trouver le chemin minimum de longueur d , cet algorithme a besoin d'une boucle de d étapes pour des longueurs allant de 1 à d . Le coût de chaque étape est constant et linéaire ($O(N)$). A l'étape k , l'algorithme passe chaque sommet avec seulement 3 opérations de comparaison (comparer trois voisins calculés à la longueur $k-1$). Par conséquent, l'algorithme permet de trouver le chemin minimum de longueur d avec un coût de $O(d*N)$.

Preuve de l'algorithme

Il convient de prouver que cet algorithme fonctionne correctement, c'est à dire, que le chemin trouvé est bien le chemin minimum.

- Pour $k=0$, les tableaux S^0 contiennent les chemins minima forcément corrects. Le valué $s_i^0 \in S^0$ est initialisé par les valeurs de pixels correspondant au sommet s_i , les chemins minima contiennent un seul sommet. C'est correct également pour $k = 1$, où les chemins contiennent 2 sommets.
- En considérant la distance k quelconque, on suppose que les chemins minima trouvés, du tableau S^{k-1} sont corrects. Le chemin minimum à la longueur k , d'origine $s_i^k \in S^k$ sera trouvé en ajoutant s_l^k au chemin minimum "min" choisi parmi les trois chemins minima d'origine, le sommet voisin de s_l^k de longueur $k-1$. Les chemins du tableau S^{k-1} étant corrects, le chemin de S^k est forcément correct.

Un exemple du fonctionnement de l'algorithme pour une longueur de 3 est illustré à la Figure 3-11. L'algorithme met à jour tous les sommets, mais sur la figure, seuls les sommets liés au sommet 0 ont été présentés. Sur cette figure, le valué du chemin (en rouge) d'un graphe est mis à jour par la valeur du pixel l (en noir) et le valué calculé sur le graphe précédent (en rouge).




Figure 3-11 : Illustration du calcul du chemin minimum de longueur $d=3$, (a) Initialisation $k=0$, (b) Chemin minimum pour $k=1$, (c) Chemin minimum pour $k=2$, (d) Chemin minimum pour $k=3$

On peut noter que, pour le sommet 0, le $\text{voisin}_{\min}$ à la longueur $k=1$ et le $\text{voisin}_{\min}$ à la longueur $k=2$ sont différents.

Remarque :

- Une fois trouvé le chemin à la longueur d , on a toute l'information pour les longueurs allant de 1 à d .
- En connaissant le chemin minimum passant par le pixel l d'une image, on connaît les orientations locales pour chaque pixel.

3.3.5 Exemples de chemins minima sur une image

La Figure 3-12 donne un exemple de chemin min passant par 4 pixels de fissure : $l_1 \dots l_4$ et 2 pixels de fond l_5 et l_6 , sélectionnés manuellement.




Figure 3-12 : Exemple des chemins min trouvés sur une image avec fissure longitudinale :
 (a) Image originale, (b) Image de vérité terrain tracée par un expert,
 (c) Chemins minima passant par 6 pixels, $d = 60$, (d) Chemins minima passant par 6 pixels, $d = 200$.

L'image inspectée (Figure 3-12(a)) est une image de chaussée avec deux fissures longitudinales. Ces fissures présentent des discontinuités et sont composées de segments très fins (1 pixel de largeur). La Figure 3-12(b) représente l'image binaire de vérité terrain tracée par un expert en considérant la forme globale des fissures.

Sur la Figure 3-12 (c) et (d), nous avons représenté en vert les chemins min (selon parcours min) passant par des pixels de fond. Les chemins rouges représentent les chemins min passant par des pixels de fissures. Cela confirme notre hypothèse concernant la fissure.

On voit que les chemins suivent la fissure quand il y en a une. Si la distance est suffisante ($d=200$, Figure 3-12(d)), on peut constater aussi que le chemin minimum ressemble à la fissure tracée par l'expert.

Il est intéressant de noter que les chemins minima passant par les pixels de la même fissure tentent de se connecter même s'il existe des discontinuités entre ces segments de fissure.

Remarque :

- La figure nous donne l'impression que les fissures sont parfaitement détectables en se basant seulement sur le chemin min. Ce n'est malheureusement pas vrai car on ne connaît pas à l'avance la nature des pixels (dans cet exemple, ils sont déterminés manuellement !!).
- La mesure de FFA nous aide donc à déterminer la nature des pixels, en comparant le chemin min et le chemin max (cf. degré de cohérence).
- L'idée d'accroître indéfiniment la distance d peut être tentante mais les coûts de calcul augmentent avec d .

Dès que l'on a déterminé la nature des pixels (binarisation par FFA), le chemin minimum peut donc nous aider à trouver la forme entière de la fissure. C'est l'objet de la méthode qui suit, qui réalise la connexion de composantes connexes.

3.3.6 Connexion de composantes connexes

Comme nous l'avons déjà vu, en pratique, les fissures présentent des discontinuités qui traduisent que la fissure est un ensemble de portions de fissures (Figure 3-13(a)). Lors de la détection manuelle, ces portions de fissure sont détectées comme étant une fissure continue (Figure 3-13(b)). Le but de cette phase est de connecter les composantes connexes afin d'obtenir la forme entière de la fissure, après seuillage à deux niveaux et étiquetage des composantes connexes (Figure 3-13 (d)).




Figure 3-13 : Binarisation d'une image de chaussée :
(a) Image originale, (b) Vérité terrain, (c) Image FFA calculée avec $d = 30$, (d) Résultat du seuillage à deux niveaux.

On remarque qu'après avoir calculé les chemins minima avec $d=d_{\max}$ par l'algorithme incrémental d'une image I , on a les informations suivantes :

- Tous les chemins minima d'origine l ($\forall l \in I$) de longueur de 0 à $d_{\max}$,
- Les orientations locales de tous les pixels l déterminés par le parcours de chemin minimum «min » passant par l .

Nous proposons une méthode pour connecter les éléments de fissures telle que :

- Étape 1 : pour chaque composante connexe cc_i , on trouve les pixels extrémités. Un pixel extrémité l est un pixel pour lequel le voisin suivant le chemin min passant par l est un pixel l' n'appartenant pas à cette composante connexe ($l' \notin cc_i$).
- Étape 2 : pour chaque paire de composante connexe cc_i et cc_j , on considère que les deux points extrémités $l_i \in cc_i$ et $l_j \in cc_j$. cc_i et cc_j vont être connectés si on rassemble les conditions suivantes :
 - ♦ l_i et l_j n'ont pas des orientations locales contraires : si le chemin minimum min passant par l_i est un parcours transversal et que celui passant par l_j est longitudinal, alors les orientations locales de l_i et l_j seront considérées comme contraire.
 - ♦ Le chemin min d'origine l_i de longueur $d_{\max}$ contient des pixels $\in cc_j$.
 - ♦ Le chemin min d'origine l_j de longueur $d_{\max}$ (l_i et l_j) contient des pixels $\in cc_i$.

Notons que l'on a besoin des conditions 2 et 3 en simultanée pour éliminer la connexion de deux fissures différentes ou d'une région de fond avec une fissure. On rappelle qu'un chemin min de pixel de fond "tentera" de se connecter à un chemin min de fissure mais que l'inverse n'est pas vrai, d'où le besoin de la réciprocité de connexion.

La Figure 3-14 montre le résultat, étape par étape, de la connexion sur l'image de la Figure 3-13.




Figure 3-14 : Résultat étape par étape de la méthode de connexion :
 (a) Points d'extrémités (en rouge), (b) Les chemins qui satisfont les conditions pour connecter (en vert),
 (c) Image binaire après la connexion.

3.4 Analyse des résultats

3.4.1 Complexité calculatoire

Sur la machine séquentielle où la méthode ci-dessous a été implémentée (Dell Precision PWS670, processeur Xeon 3.6 GHz, 4 Go de RAM) le temps moyen d'exécution est le suivant (pour des images originales de taille 2048x2048 pixels) :

- Calculer le chemin minimum avec $d=30$: 19188 ms,
- Calculer l'image de FFA avec $d = 30$: 1625 ms,
- Réaliser le seuillage à deux niveaux : 250 ms,
- Réaliser l'opération de connexion avec $d = 30$: (~ 125 ms dépendant du nombre de régions segmentées)
- Total : 21188 mms (soit 21 secondes).

3.4.2 Influence du paramètre d

Pour comparer avec la méthode CTA_R et CTA_S, l'influence des paramètres d est étudiée sur la même image de synthèse du chapitre précédent.

La Figure 3-15 montre l'influence de la distance sur la recherche de fissures à partir d'une image de synthèse. La Figure 3-15(a) représente l'évolution de valeur FFA_{fissure} , FFA_{fond} et $|FFA_{\text{fissure}} -$

FFA_{fond} selon d . Avec cette méthode FFA, après la valeur " $d_{optimal}$ " ($d=8$ pour cette image), les courbes sont toujours stables quand la valeur d augmente et les valeurs de FFA de fond sont très faibles par rapport aux valeurs de FFA de fissure. Le résultat de test de la Figure 3-15 montre que les fissures sont détectables pour toutes les valeurs de $d > 8$ (ce n'était pas le cas avec CTA_S et CTA_R). C'est-à-dire que cette méthode FFA est plus résistante au changement de valeur de d .

On peut noter que les fissures détectées sont plus épaisses que les fissures de la vérité terrain. L'origine de ce phénomène est que les pixels très proches (dépendant entre autre de d) de la fissure tentent de la rejoindre.




Figure 3-15 : Influence du paramètre d sur une image de synthèse.

3.4.3 Influence du type de chaussées sur la méthode.

A partir de la base d'images de AMAC®, nous avons extrait des portions d'image sans défaut de taille 512x512 de différents types de chaussées. La sélection est faite en considérant la rugosité (granulométrie), le contraste et la corrélation de textures (voir Tableau 3-1). Les deux derniers sont les attributs de texture d'Haralick extraits sur la matrice de cooccurrence (GLCM¹)([75] page 418).

Image N°	granulométrie (mm) min/max	Contraste	Corrélation	Entropie
1	0/4	308.1	0,001	8,7
2	0/10	537,3	0,0005	9,38
3	0/13	612,4	0,0032	9,4
4	0/18	876,72	0,00031	9,9

Tableau 3-1 : Attributs de textures d'images sélectionnées.




Figure 3-16 : Exemples d'images de synthèse avec différents types de chaussées.

Pour évaluer l'influence, nous avons créé 4 fissures de synthèse, 2 pixels de largeur, la forme et l'orientation de chaque fissure est différente. Ces fissures de synthèse sont ajoutées sur les images de textures sélectionnées de la même façon que dans le chapitre précédent (le niveau de gris des fissures de synthèse est aléatoire et noyé dans la texture). L'utilisation de fissures synthétiques permet de fixer le "facteur" fissure (forme, largeur, degré de discontinuité) pour évaluer le facteur de changement de textures.

La Figure 3-17 présente les résultats de la méthode FFA sur la segmentation de ces 4 images. Pour voir l'influence de la texture nous n'appliquons pas l'étape de connexion dans ce test.

¹ GLCM: Grey Level Co-occurrence Matrix




Figure 3-17 : Résultats de segmentation des fissures de synthèse sur différents types de chaussées par la méthode FFA "tout chemin minimum".

Les résultats montrent que la méthode est très stable sur différents types de texture.

Pour $d = 4$ et $d = 8$, le résultat des images 3 et 4, qui présente plus de rugosité, est moins bon que pour les images 1 et 2. Mais pour $d > 16$, les résultats sont presque identiques. Pour $d = 32$, toutes les fissures sont détectables sans aucun bruit. L'efficacité de la FFA sur le changement de chaussées peut s'expliquer par la configuration de π_{fond} et π_{min} pour le chemin minimum, qui naturellement rejette les pixels «très brillants» de son parcours. L'implémentation de la FFA avec π_{fond} par configuration "région" est beaucoup moins stable à la variation de texture (Figure 3-18).




Figure 3-18 : Résultats de la méthode FFA avec π_{fond} implémenté par configuration régions.

3.4.4 Sélection du paramètre d

La méthode fonctionne bien avec une valeur $d > d_{\text{optimal}}$. Pour éviter l'apprentissage de d , nous avons choisi d égal 30, correspondant à d_{optimal} max sur tous les types de chaussées. La chaussée française ayant une granulométrie max proche de 18 mm (18 pixels). L'image 4 (Figure 3-16) sur notre base de données correspond à ce cas.

La Figure 3-19 montre la même étude que celle de la Figure 3-15, sur l'image 4. $d = 30$ correspond à la valeur max de $|\text{FFA}_{\text{fissure}} - \text{FFA}_{\text{fond}}|$.




Figure 3-19 : Evolution de FFA sur l'image 4 de la Figure 3-16

3.4.5 Résultats sur images réelles

Nous analysons, dans cette partie, des résultats de la méthode FFA en comparant avec les méthodes du Chapitre 2. La Figure 3-20(a) est une image de chaussée faiblement texturée comportant une fissure diagonale. L'image (Figure 3-20(b)) est une image fortement texturée contenant deux fissures longitudinales avec des largeurs variant de 1 à 8 pixels. La dernière image, présentée dans la Figure 3-20(c) est l'image de surface la plus texturée, contenant une fissure longitudinale très fine (1-2 pixels en largeur).




Figure 3-20 : Trois exemples d'images de chaussées utilisées pour les tests.

Les résultats des 4 méthodes : CTA de Roli (CTA_F), CTA configuration "région" (CTA_R), CTA configuration segment (CTA_S) et la méthode FFA sont présentés dans la Figure 3-21. Dans ce test, les paramètres sont les suivantes (CTA_F : $N = 16$, CTA_R et CTA_S : $d = 8$, FFA : $d = 30$).

On observe que, pour les trois images, les résultats de la méthode FFA sont meilleurs avec peu de bruits, moins de discontinuité des fissures segmentées et plus de précision.

	Image 1			Image 2			Image 3		
	PBD (%)	Pr (%)	DD	PBD (%)	Pr (%)	DD	PBD (%)	Pr (%)	DD
CTA_F	91,5	97,7	6	19	7,3	2.5	25	3,1	2
CTA_R	59,2	51	27	85	19,1	4.5	16	1,5	7
CTA_S	100	68,2	13	100	72	5	82	19,3	3
FFA	100	100	1	100	100	1	100	74,2	1

Tableau 3-2 : Résultats de la segmentation selon les critères Proportion de bonne détection (PBD), Précision (Pr) et degré de discontinuité (DD).




Figure 3-21 : Résultats des 4 méthodes sur la segmentation des images de la Figure 3-20.

3.5 Conclusion

Dans ce chapitre, nous avons présenté une nouvelle méthode de segmentation de fissures dans des images de chaussées. Notre approche est basée sur des hypothèses plus complètes sur les fissures que ce que l'on trouve dans les méthodes existantes. Nous avons supposé que la fissure peut prendre des formes très variables et des orientations quelconques, d'où l'appellation Free-Form.

Dans un premier temps, nous avons rappelé les notions de base sur la théorie des graphes et notamment la modélisation des images par ce biais. Nous avons utilisé des graphes valués pour représenter les images, les pixels étant les sommets, les arêtes étant valuées avec les niveaux de gris.

A partir de cette représentation en graphe, nous avons développé une méthode de recherche de chemins minima qui a permis d'étendre la méthode CTA à la version Free-Form (FFA). Cette recherche de chemins minima est à la base du calcul de la FFA à partir des chemins "min" et "max". Les résultats obtenus montrent que notre approche permet de segmenter des fissures fines et discontinues. Ces résultats ont été confirmés sur différents types de texture de chaussées.

L'influence des paramètres de la méthode a été étudiée sur différents types de texture et avec différents types de fissure (forme et épaisseur). Ces essais ont montré la très bonne capacité de la méthode à assimiler la texture de chaussées, pour en isoler les défauts, à partir d'une zone de texture analysée suffisamment grande. Ces tests ont également montré la robustesse de la méthode pour les différentes textures testées.

Nous avons également présenté une version incrémentale de l'algorithme. Elle permet de mettre en œuvre la méthode avec une complexité acceptable. Le principe de l'algorithme consiste à calculer l'image de la FFA pour une distance d à partir de l'image de la FFA de distance $d-1$. Le bénéfice en temps de calculs nécessite en contre partie de disposer de plus de mémoire vive pour stocker les données liées aux différentes distances d .

Dans le chapitre suivant, les méthodes évoquées seront intégrées dans un système complet permettant de valider les méthodes sur différentes bases d'images. Ces bases ayant été traitées, au préalable, par des opérateurs experts, nous disposons d'une vérité terrain nous permettant de comparer les résultats de nos algorithmes. Nous présenterons l'application des différentes méthodes de segmentation pour la détection et la classification des défauts de surface de chaussées : fissures, pontées, joints, etc.

Chapitre 4

Implémentation et Résultats Expérimentaux

CONTENU

4.1	INTRODUCTION.....	99
4.2	DETECTION ET CLASSIFICATION DE LA FISSURE	100
4.2.1	<i>Prétraitement</i>	<i>100</i>
4.2.2	<i>Extraction d'attributs.....</i>	<i>102</i>
4.2.3	<i>Détection et Classification de défauts.....</i>	<i>105</i>
4.3	BASES D'IMAGES DE TEST.....	108
4.3.1	<i>Base d'images du LCPC.....</i>	<i>108</i>
4.3.2	<i>Base d'images acquises par le véhicule AMAC®.....</i>	<i>108</i>
4.4	RESULTATS EXPERIMENTAUX.....	110
4.4.1	<i>Résultats comparatifs sur la base de données du LCPC.....</i>	<i>110</i>
4.4.2	<i>Résultats sur bases de données d'images capturées par AMAC.....</i>	<i>118</i>
4.5	CONCLUSION	127

Préambule :

L'objet de cette étude porte essentiellement sur la mise en œuvre d'un opérateur performant permettant la mise en valeur des défauts. Les méthodes de classification présentées n'ont pas fait l'objet d'études approfondies. Elles nous permettent, cependant, de comparer les différentes méthodes de segmentation.

4.1 Introduction

Comme évoqué dans le Chapitre 1, l'un des manques pour les méthodes trouvées dans la littérature est l'absence de tests sur une base importante d'images, contenant une variété de types de chaussées et de défauts, permettant de valider ces méthodes. Le but de ce chapitre, est d'évaluer les méthodes développées sur différentes bases conséquentes d'images offrant un panel représentatif des différents types de chaussées et de défauts.

Dans un premier temps, nous présenterons les méthodes implémentées pour les étapes de prétraitement, d'extraction d'attributs et de classification de défauts. Elles sont utilisées avec la segmentation par CTA et FFA dans une chaîne complète de traitement pour évaluer le résultat final.

Dans un deuxième temps, les bases d'images que l'on a utilisées pour les tests seront détaillées. Elles sont au nombre de trois, les deux premières, sont constituées d'images du Laboratoire Central des Ponts et Chaussées de Nantes (LCPC). Elles sont utilisées afin de comparer les résultats de la CTA et de la FFA avec ceux présentés dans les publications du LCPC (approches basées sur la Transformée en Ondelettes Continues et Champs de Markov [39, 41]). Ensuite, nous présentons les résultats de notre méthode sur une troisième base constituée d'images capturées par le système AMAC®.

Nous présenterons, à la fin, les limites de nos approches.

4.2 Détection et Classification de la fissure

Comme nous l'avons vu dans le Chapitre 1, la segmentation s'inscrit dans une chaîne de traitement dont nous trouvons l'illustration avec la Figure 4-1.

L'étape la plus importante est évidemment celle de la segmentation mais les autres parties de cette chaîne de traitement conditionnent les résultats. Dans cette partie, nous détaillons donc ces autres étapes de la chaîne que sont le prétraitement, l'extraction d'attributs et la classification.




Figure 4-1 : Chaîne de traitement pour la détection de fissures.

4.2.1 Prétraitement

Comme les images capturées par AMAC® n'ont pas de problème de non uniformité d'éclairage, la normalisation de contraste n'est pas nécessaire dans notre contexte.

Les contours de marquages peuvent être détectés comme un défaut (surtout pour la CTA_R et la CTA_S), il est donc nécessaire d'appliquer une étape de détection de marquages.

La détection de marquages sur des images de chaussées (Figure 4-2(b)) est plus simple que celle sur des images d'environnement (Figure 4-2(a)). Sur des images de chaussées (vue du dessus), les marquages présents sont clairs, bien droits et de plus, il n'y a pas de problème d'occultation ou de non uniformité de l'éclairage des marquages.




Figure 4-2 : Exemple de marquages sur une image d'environnement et sur une image de chaussée :
(a) Image d'environnement, (b) Image de chaussée.

Pour détecter ces marquages, nous avons, dans un premier temps, appliqué un seuillage pour obtenir une image binaire (les pixels blancs ont une valeur supérieure à $\text{seuil}_{\text{blanc}}$). Une Transformée de Hough Probabiliste¹ (THP) (Gamlabos [76]) est utilisée pour détecter les lignes sur cette image binaire. Finalement, les marquages sont détectés. Si des marquages sont présents dans l'image inspectée, les régions de ces marquages (par exemple, le rectangle noir dans la Figure 4-3(d)) ne seront pas prises en compte pour la détection des défauts.

Un exemple de détection de marquage présent sur la Figure 4-2(b), est illustré à la Figure 4-3.

Sur la Figure 4-3(a), on peut voir l'histogramme de l'image originale. Le $\text{seuil}_{\text{blanc}}$ est déterminé en détectant la première vallée à la droite de cet histogramme. Pour cet exemple, $\text{seuil}_{\text{blanc}}$ vaut 253. Après avoir fait la THP de l'image illustrée à la Figure 4-3(b), on ne garde que les droites ayant une orientation proche de 90° , et ayant une accumulation supérieure à 50 pixels (Figure 4-3 (c)).

¹ Nous utilisons l'implémentation de la méthode dans la bibliothèque OpenCv.

Après avoir supprimé toutes les droites isolées, le marquage est détecté comme on peut le voir sur la Figure 4-3(d).




Figure 4-3 : Illustration de l'étape de détection du marquage:
(a) Histogramme de l'image analysée, (b) Seuillage pour obtenir des pixels très brillants,
(c) Détections des droites par THP, (d) Résultat.

4.2.2 Extraction d'attributs

Cette étape suit celle de segmentation. Les attributs sont des mesures sur des objets ou sur des ensembles de pixels de l'image.

Pour classifier les images de fissures, nous avons calculé des attributs globaux et locaux. Les attributs globaux sont extraits sur l'ensemble des pixels de l'image binaire (résultat de la segmentation). Ils sont particulièrement utiles quand le résultat de segmentation est morcelé. Les attributs globaux permettent ainsi de décider si une image contient ou non un défaut.

Des attributs locaux permettent de caractériser chaque composante connexe, ou chaque zone d'image pour sa classification.

Trois attributs sont extraits, un global (attributs de Hough) et deux locaux (longueur d'une composante et orientations locales d'une région).

4.2.2.1 Attributs orientation globale dans l'espace de Hough

Comme nous l'avons présenté dans la partie 1.2.4, la Transformée Standard de Hough (TSH) permet d'extraire les attributs d'orientation globale de l'image binaire.

Nous appliquons donc une TSH à l'image binaire avec une résolution angulaire θ de 1 degré, et une résolution distance $\rho = 1$. Les orientations sont trouvées en recherchant les maxima dans la matrice d'accumulations MA (ρ, θ).




Figure 4-4 : Exemple d'extraction d'attributs d'orientations globales sur une image segmentée par la méthode CTA_S.

Sur cet exemple, l'image de la Figure 4-4(a) est segmentée par la méthode CTA_S avec peu de bruits, mais la fissure est discontinue (Figure 4-4(b)). Dans ce cas, on trouve la valeur d'accumulation maximale ($265 > 50$ pixels) dans l'espace de Hough correspondant à un angle de 44° . Puisque la valeur d'accumulation est supérieure à un seuil (ici 50 pixels dont l'explication sera donnée plus tard), on peut affirmer qu'il y a un défaut de chaussée pour cette image même si toutes les composantes connexes détectées ont des longueurs faibles.

Les attributs de Hough permettent d'analyser l'alignement au niveau global. Mais ils demeurent difficiles à mettre en œuvre pour l'analyse d'attributs au niveau local (sur une zone ou sur chaque composante connexe), surtout quand les fissures ne sont pas bien rectilignes.

4.2.2.2 Longueur d'une composante

Cet attribut local nous permet de déterminer si une composante connexe est suffisamment grande pour être directement considérée comme une fissure.

Nous avons choisi la longueur de la diagonale, du rectangle englobant une composante, comme longueur de cette composante (Figure 4-5). Cette détermination simple de la longueur a été utilisée

dans la plupart des travaux [46, 55, 65]. Elle permet d'extraire rapidement la longueur globale d'une composante connexe sans avoir besoin de faire de grand calcul pour déterminer l'ellipse approchante [57].




Figure 4-5 : Longueur de la composante.

4.2.2.3 Attributs d'orientation locale

Cet attribut local nous permet de savoir si un défaut est unidimensionnel ou bidimensionnel (faiénçages).

On réduit l'épaisseur du défaut avant d'extraire des orientations locales par une recherche de squelette. Avant cela, il est indispensable de remplir les petits trous dans les composantes afin d'éviter les bruits (les cercles) sur le squelette (M. Cychoz [77]). Une illustration est donnée à la Figure 4-6.




Figure 4-6 : La squelettisation : (a) Résultat de segmentation par FFA
(b) Résultat de remplissage des petits trous, (c) Squelette.

L'orientation locale d'un pixel est définie comme suit :

- Pour la méthode FFA : l'orientation locale d'un pixel est l'orientation du chemin min passant par ce pixel.

- Pour la méthode CTA_S et CTA_R, l'orientation locale d'un pixel est l'orientation de la configuration min (droite ou région orientée).

Ces orientations peuvent être 0° , 45° , 90° ou 135° . Notons que par cette définition, l'orientation d'un pixel est différente de celle déterminée par la position de son voisin dans l'image du squelette. Cela permet d'éviter les fausses orientations causées par des petits segments de bruit dans l'image du squelette (Figure 4-7).




Figure 4-7 : Image d'orientations locales superposées à l'image du squelette (rouge).
(Noir : 0° , gris moyen 45° , blanc 90° , gris clair 135° .)

4.2.3 Détection et Classification de défauts

Les gestionnaires routiers français ont adopté une catégorisation provenant du catalogue publié [4]. Les fissures sont classifiées comme longitudinales, transversales ou de type faïençage (bidimensionnel), selon leur longueur et leur orientation.

4.2.3.1 Image sans défaut

Le premier critère intéressant pour les gestionnaires de réseaux routiers est de savoir si une portion de route contient des défauts ou non, sans forcément connaître la nature du défaut. Dans ce contexte, nous avons, dans premier temps, étiqueté les images comme ayant ou non un défaut.

Ils ne considèrent que les fissures dont la longueur est supérieure à 20 cm (équivalent à 200 pixels pour les images d'AMAC®). En considérant le fait que les fissures peuvent être morcelées, nous avons choisi 25% de cette longueur, soit 50 mm (équivalent à 50 pixels), comme seuil à partir duquel, une composante sera considérée comme étant une fissure.

Les composantes segmentées peuvent être continues ou non dans l'image résultante de la segmentation.

Pour décider si un défaut est présent ou non dans l'image, on analyse l'image résultat comme suit :

- 1) SI cette image contient une composante dont la longueur est supérieure à 50 pixels ALORS l'image est classifiée comme image de défaut.
- 2) SINON ALORS on analyse l'alignement dans l'espace de Hough (car soit l'image ne contient pas de défaut, soit la segmentation de ces défauts est trop morcelée).
 - ♦ SI le maximum accumulé est plus grand que 50 pixels ALORS l'image est classifiée comme image de défaut,
 - ♦ SINON, elle est considérée, définitivement, comme une image sans défaut.

Remarque : on évite la Transformée de Hough pour les images où des défauts sont bien segmentés avec des composantes longues.

4.2.3.2 Extraction du faïençage

Les faïençages (réseaux de fissures) sont extraits par une recherche dimensionnelle. On analyse une famille de fenêtres réparties régulièrement sur l'image. Sur chaque zone définie par ces fenêtres, on analyse des accumulations d'orientations locales de pixels "candidat-fissure" présents dans la zone (pixel obtenu lors de l'étape de segmentation).



SI l'orientation locale θ correspond à la valeur d'accumulation maximale acc_θ et que $acc_\alpha > 50$ avec $\alpha = (\theta \pm \frac{\pi}{2})$ ALORS cette zone est considérée comme *bidimensionnelle* SINON elle est *unidimensionnelle*.

Notons que si un pixel a une orientation α , cette orientation traduit celle des $2*d$ autres pixels autour de lui dans l'image originale.

Une image sera classifiée comme contenant du faïençage si elle contient des zones bidimensionnelles.

On a choisi une taille de fenêtre de 512x512 pour analyser le faïençage. Un exemple d'extraction du faïençage est illustré dans la Figure 4-8. Les orientations locales mesurées pour la fenêtre

rouge, dans la Figure 4-8(b), sont représentées dans la Figure 4-8(c). Dans cette fenêtre, sont présentes les 4 orientations. De ce fait, cette fenêtre est considérée comme une zone de faïençage.



(c) Orientations locales de la fenêtre rouge dans (b)

Figure 4-8 : Extraction du faïençage

4.2.3.3 Extraction de la fissure longitudinale et transversale

Pour décider de la présence de la fissure longitudinale ou transversale sur l'image, on analyse chaque composante connexe, extérieure d'une zone de faïençage. SI la largeur du rectangle englobant une composante est plus grande que sa longueur ALORS cette composante est *longitudinale*, SINON elle est *transversale*.

4.3 Bases d'images de test

4.3.1 Base d'images du LCPC

A côté de notre base d'images capturées par AMAC®, l'utilisation de la base d'images du LCPC nous permet, d'une part, de comparer notre résultat avec leurs méthodes [41] et d'autre part, de vérifier nos résultats sur plusieurs types d'images. Cette base d'images a été utilisée dans [39, 41]. Ces images se rangent en deux catégories distinctes, les images "réalisées" en laboratoire et les images de chaussées capturées en mode statique. Nous les présentons dans l'Annexe A.

4.3.2 Base d'images acquises par le véhicule AMAC®

C'est une base de données réelles d'images sur laquelle les opérateurs de la société Vectra ont relevé des dégradations. Les milliers de kilomètres d'images de voie (dont la plupart capturées sur autoroute) qui constituent cette base sont acquises par le véhicule AMAC® sur les réseaux routiers français à la vitesse moyenne de 80 km/h.

4.3.2.1 Description du dispositif de prise de vue

La Figure 4-9 nous montre le principe de la prise d'images de l'AMAC®. Ce système dispose d'une paire "caméras linéaires - éclairage lasers". Pour visualiser toute la largeur d'une voie d'autoroute (4 m), chaque caméra capture 2 m de chaussée (moitié d'une voie). Pour chaque caméra, des images 2D de taille 2048x2048 sont reconstituées avec une résolution de 1 millimètre par pixel.

Position des caméras :

Les caméras sont positionnées perpendiculairement à l'axe transversal et avec un angle de 30° par rapport à l'axe longitudinal de la chaussée. La Figure 4-9(b) illustre la position de la caméra et l'éclairage laser selon l'axe transversal. La Figure 4-9(c) explique le modèle d'illumination sur une fissure longitudinale. La forme de la fissure se dessine sur l'image par l'absence de réflexions du rayonnement laser en direction des caméras. Ceci crée le contraste entre la fissure et la texture. L'éclairage laser se fait sous incidence normale à la surface de la chaussée pour accroître le contraste des fissures (surtout pour les fissures longitudinales). Le laser de gauche éclaire la scène observée par la caméra de droite et vice versa. Le positionnement oblique des caméras par rapport à l'axe longitudinal de la chaussée permet d'augmenter le contraste pour les fissures transversales.

On peut remarquer que cette configuration favorise la perception des fissures longitudinales par rapport à celle qui sont transversales (ce qui permettra d'expliquer les résultats de détection). Il est notable que les fissures longitudinales sont plus fréquentes que les fissures transversales.




Figure 4-9 : Système AMAC® et principe de prise de vues :
 (a) Véhicule AMAC avec deux paires de caméras linéaires et l'éclairage lasers,
 (b) Principe de LRIS sur la caméra à gauche, (c) Modèle de réflexion de lumière sur une fissure longitudinale.

4.3.2.2 Caractéristiques des images obtenues

La Figure 4-10 donne 4 exemples d'images capturées en mode dynamique.




Figure 4-10 : Images acquises en mode dynamique par AMAC® : (a) Fissure longitudinale, (b) Fissure transversale, (c) Faïençage, (d) Image sans défaut.

Les deux paramètres importants sur cette base d'images sont l'uniformité de l'éclairage et le degré important de morcellement des fissures.

4.3.2.3 Sélection d'images de tests

Sur les milliers de kilomètres de routes qui ont été capturés par AMAC®, il a été réalisé un relevé de dégradation par des opérateurs. Le type de défauts, la texture de chaussée ou les niveaux de dégradations sont très variables d'une portion à l'autre.

Pour les besoins de nos tests, nous avons construit une base d'images à partir d'images de défauts présents dans 5 sessions d'acquisition de l'AMAC® sur autoroutes avec une longueur totale de 275 kilomètres. Cette base contient aussi 1000 images sans défaut sélectionnées aléatoirement dans ces 5 sessions afin d'évaluer les fausses alarmes. Les images sont étiquetées (par des opérateurs), comme dans le Tableau 4-1.

Images sans défaut	1000
Images de fissures longitudinales	14335
Images de fissures transversales	833
Faïençages	605
Total	16773

Tableau 4-1 : Base d'images AMAC® sélectionnées avec type de défauts.

Remarque :

Il existe une session (sur les 30 sessions que nous avons analysées) où la taille moyenne et la visibilité des fissures sont semblables à celles des images statiques du LCPC. Mais dans la plupart des cas, les défauts sont moins visibles que sur les images statiques. Nous n'avons pas sélectionné cette session "très dégradée" dans ces bases de test.

4.4 Résultats expérimentaux

4.4.1 Résultats comparatifs sur la base de données du LCPC

Nous allons présenter ici des résultats de détection à partir d'images de la base de données du LCPC.

Ces résultats sont exposés en les comparant avec ceux obtenus grâce à une approche classique par seuillages [16]. On l'appellera par la suite méthode seuillages.

Nos résultats sont également comparés à ceux obtenus par une approche récente du LCPC. Elle utilise la Transformation en Ondelettes Continue 2D suivie d'une segmentation par champs de Markov (cf. chapitre 1). Les fissures sont détectées par des valeurs accumulées d'orientations dans

l'espace de Hough. On l'appelle, par la suite, méthode TOC&Markov. Les résultats de cette méthode TOC&Markov ont été publiés dans la thèse de P. Subirats [41].

Les résultats de la méthode CTA_F (CTA original de F.Roli) ne sont pas présentés dans ce chapitre car, d'une part elle a besoin d'un apprentissage de la texture "sans défaut" et d'autre part, cette méthode n'est pas adaptée aux surfaces fortement texturées comme celle des chaussées. On trouve donc les résultats des méthodes CTA_S (CTA configuration "segment"), CTA_R (CTA configuration "région") et FFA.

4.4.1.1 Performances sur des images de laboratoire

Nous présentons ici les résultats de détection sur deux images, exposées dans les travaux de thèse de P. Subirats [41]. On trouvera plus de résultats dans l'annexe B.

Ces deux images de laboratoire ont une résolution de 1.2mm par pixel. La texture dans la Figure 4-11(a) est à faible contraste (contraste¹ = 65) alors que celle présentée dans la Figure 4-11(b) est à plus fort contraste (contraste = 112.5). Les largeurs des fissures qui se trouvent dans ces deux images sont suffisamment grandes pour la détection par la méthode TOC&Markov. Elles sont 3mm pour l'image de la Figure 4-11(a) et de 4mm pour l'image de la Figure 4-11(b).

Les résultats de la Figure 4-11 sont des images binaires issues de la segmentation.

Le Tableau 4-2 présente les évaluations des résultats de ces méthodes, sur ces deux images, en se basant sur les critères définis dans la partie 2.4.2.

Méthode	Image 1				Image 2		
	Bonne détection PBD (%)	Précision Pr (%)	Degré de Discontinuité DD		PBD (%)	Pr (%)	DD
TOC&Markov	26,5	89	18		28,8	65	27
Seuillage	25,6	99	4		38	90	13
CTA_R	82,9	36,4	7		70,5	48	8
CTA_S	45,3	89,5	2		100	94,3	2
FFA	100	100	1		100	100	1

Tableau 4-2 : Evaluation de la segmentation sur l'image 1 et l'image 2.

¹ Valeur de contraste de Haralick calculée par matrice de cooccurrence.




Figure 4-11 : Résultats comparatifs sur deux images de laboratoire, les images de la méthode TOC&Markov sont issues de [41]

Les deux approches, seuillage et TOC&Markov, sont les plus sensibles au bruit apporté par la texture de fond. Bien que les fissures soient détectées avec une bonne précision (99% et 89%), les discontinuités et le ratio entre les fausses alarmes et les bonnes détections, sont aussi très importants. Dans une telle image binaire, la fissure est difficile à localiser. La décision de savoir si l'image est celle d'un défaut ou non est donc difficile à prendre.

Notons que le résultat de la méthode TOC&Markov est le résultat final après la recherche de la relation spatiale des pixels "binarisés" par une transformation en ondelettes. En fait, si l'étape de binarisation produit trop de bruits (les fausses alarmes), il devient difficile de réaliser une "bonne" connexion dans ces conditions. Une dilatation ou une ouverture morphologique peut effectivement supprimer les petites régions de bruit mais elles le feront aussi avec les petites régions de fissures.

La méthode CTA_R donne un résultat assez médiocre. Elle présente moins de bruit mais elle ne détecte que des petites portions de fissure. La CTA_R est la méthode ayant la précision la plus faible.

Les résultats de la méthode CTA_S sont satisfaisants pour l'image 2 avec peu de bruits et une bonne continuité de la segmentation de fissure. On voit peu d'effet causé par l'orientation défavorable. Cela s'explique par la largeur assez importante des fissures dans ces deux exemples (3mm et 4mm) et par le fait que la texture a un contraste relativement faible. Par contre, on peut observer que la méthode CTA_S est sensible à la présence d'objets très blancs (l'image 1).

Avec la méthode FFA, la fissure est continue et on ne voit aucun bruit venant de la texture.

La continuité et le faible bruit des méthodes CTA et FFA viennent de la façon de les calculer. Leurs approches permettent de réaliser la connexion en même temps que la binarisation.

Afin de mieux appréhender les limites de chacune de ces méthodes, nous avons recherché la largeur minimum de fissure détectable, pour les deux types de chaussées.

Pour cela nous avons des séries d'images de la même chaussée avec une fissure de même forme mais avec des largeurs différentes. Une fissure est considérée comme détectable si la valeur maximale d'accumulation dans l'espace de Hough est supérieure à 50 pixels.

Ces limites de détection pour les fissures sur les deux types de chaussées (dont sont extraites les images de la Figure 4-11) sont présentées dans le Tableau 4-3.

Méthodes Chaussée	TOC&Markov	Seuillages	CTA_R	CTA_S	FFA
Chaussée 1	$\geq 3\text{mm}$	$\geq 3\text{mm}$	$\geq 3\text{mm}$	$\geq 3\text{mm}$	$\geq 2\text{mm}$
Chaussée 2	$\geq 4\text{mm}$	$\geq 4\text{mm}$	$\geq 3\text{mm}$	$\geq 3\text{mm}$	$\geq 3\text{mm}$

Tableau 4-3 : Détection limite en terme de largeur de fissures sur deux images de laboratoire.

4.4.1.2 Comparaison des performances sur des images capturées en mode statique sur route

Nous présentons ensuite le résultat des méthodes sur la base d'images statiques. Cette base comporte 65 images de défauts (17 longitudinaux, 17 transversaux et 31 faïençages) et 9 images sans défaut. La Figure 4-12 présente le résultat comparatif d'images binaires finales de ces 5 méthodes sur trois images exemples. Les évaluations selon les critères se trouvent dans le Tableau 4-4.

Méthode	Image 1				Image 2				Image 3 (sans défaut)		
	PBD (%)	Pr (%)	DD		PBD	Pr	DD		PBD	DD	Pr
TOC&Markov	23,8	37	122		38,5	58	272		0/3256	-	-
Seuillage	34,5	75	113		39	50	311		0/6351	-	-
CTA_R	33,7	39	29		84,7	37	24		0/79	-	-
CTA_S	78,7	63	7		94	65	21		0/195	-	-
FFA	100	96	1		99,5	92	3		0/0	-	-

Tableau 4-4 : Evaluation de la segmentation d'images acquises en statique.

Les résultats sont cohérents avec ceux obtenus avec les images de laboratoire. Les plus bruités et discontinus sont ceux obtenus par seuillage et TOC&Markov. La méthode qui a la plus faible précision Pr est la CTA_R (effet région). Les résultats obtenus par la CTA_S et la FFA sont moins morcelés et peu bruités. L'utilisation de $d_{\max} = d = 30$ ne permet pas à la méthode FFA de connecter des portions de fissures sur une longue distance (Figure 4-12(r)), d'où une valeur DD différente de 1. Les résultats de la méthode TOC&Markov sont ceux publiés par les auteurs dans [41].




Figure 4-12 : Résultats comparatifs sur trois images capturées en mode statique.

Le Tableau 4-5 présente les résultats statistiques pour les 5 méthodes.

Pour nos méthodes, CTA_R, CTA_S et FFA, le seuil limite d'un défaut sur cette base est de 25 pixels (au lieu de 50 pour l'image AMAC®) car la résolution est de 2mm par pixel, soit la moitié de celle des images de l'AMAC®.

On considère qu'une détection est bonne si la méthode a détecté un défaut et qu'il y a un défaut sur l'image originale. On considère qu'il y a une fausse alarme si l'image ne comporte pas de défaut mais que la méthode en a détecté un. Le taux de classification est calculé sur les images après la détection.

Méthode	Taux de bonne détection (sur 65 images)	Taux de fausses alarmes (sur 9 images)	Taux de bonne classification
TOC&Markov	65%	22%	79%
Seuillage	61%	33,3%	-
CTA_R	39%	0%	49%
CTA_S	76%	22%	70%
FFA	95,5%	11% (1 image)	85%

Tableau 4-5 – Résultats de détection et de classification sur les images acquises en statique

Les fausses classifications pour cette base viennent du défaut de type faïençage, comme illustré sur la Figure 4-13(a). Dans ce cas, le faïençage est de très petite taille et a un contraste très faible. La méthode FFA ne détecte qu'une partie longitudinale et le défaut a été classifié comme une image de fissure longitudinale. La qualité de la classification dépend du résultat de la segmentation (bruit/signal, degré de discontinuité et précision).

La méthode qui obtient le meilleur résultat est la FFA. Sur la Figure 4-13(c), on peut voir un cas de fausse alarme par la méthode FFA. La présence des taches noires longues et bien alignées a été détectée comme étant une fissure longitudinale ce qui n'est pas le point de vue de l'expert (ce n'est pas évident pour un œil profane).

Les cas non détectables sont voisins de celui présenté sur la Figure 4-13(e). On rappelle que cette base est constituée d'images capturées par un appareil photo matriciel, monté perpendiculairement à la chaussée. Ainsi, il n'y a aucune ombre causée par la fissure transversale. Ainsi, les méthodes

qui prennent en compte l'hypothèse de "luminosité" minimum (toutes les méthodes) ne sont pas capables de détecter les fissures sur ce type d'image. En fait, dans ce cas, les fissures sont des pixels plus brillants que ceux du fond. Une FFA basée sur des chemins "maxima" peut détecter cette fissure (Figure 4-14). Cependant, nous n'avons pas mis en œuvre le chemin "maximum" car ce type d'image de fissures est rare et que la présence d'autres objets ayant des maxima locaux sur des images de chaussées (lignes blanches, alignement des granulats) générerait des fausses alarmes.




Figure 4-13 : Exemples de mauvaise classification, de fausse alarme et de non détection.



Figure 4-14 : Résultat de la FFA de chemin "maximum" de l'image dans la Figure 4-13 (d).

4.4.1.3 Discussion

Sur les tests ci-dessus, la méthode CTA_R a obtenu de mauvais résultats. Dans ce contexte, il est logique qu'une approche "région" sur des textures fortement aléatoires avec des défauts de petite taille ne donne rien de bon.

Les résultats de la CTA_S et de la FFA sont assez bons en comparaison de ceux des autres méthodes. Cela confirme que l'idée de prendre en compte en même temps la luminosité et la forme des fissures pour la détection est une bonne approche.

Dans la partie suivante, nous présentons des tests sur une plus grande base d'images en comparant avec l'avis de l'expert.

4.4.2 Résultats sur bases de données d'images capturées par AMAC

Les images capturées en mode dynamique présentent généralement une texture très forte et des défauts très morcelés [41]. Pour cette raison, et selon l'auteur, la méthode TOC&Markov a obtenu dans de telles conditions, des résultats de segmentation peu satisfaisants pour permettre d'extraire les fissures ([41], pp 156,157).

La Figure 4-15 présente une image dynamique du LCPC d'une chaussée française capturée en mode dynamique par le système LRIS (système identique à celui de AMAC® et de même résolution, 1mm par pixel). On trouve ensuite les résultats de la méthode TOC&Markov (Figure 4-15(b)), l'image des valeurs de la FFA ainsi que les résultats de segmentation par cette même méthode (Figure 4-15(c), (d)).




Figure 4-15 : Résultats sur une image dynamique du LCPC (issus de[41]) : (a) Image d'une fissure longitudinale, (b) Résultat de TOC&Markov issu de [41], (c) Image valeur de FFA, (d) Résultat de segmentation par FFA, $d=30$.

Pour la suite, avec les images d'AMAC®, nous ne présentons les résultats que pour deux méthodes : CTA configuration "segment" (CTA_S) et «Free Form anisotropy» (FFA). En effet, elles ont déjà montré leur supériorité pour ce type d'images de chaussées.

Dans le cadre de cette étude, nous avons une base d'images très importante (plusieurs milliers d'images). De ce fait, nous n'avons à notre disposition qu'un avis d'expert lié aux demandes des gestionnaires routiers. Ces informations sont limitées à la présence ou non de défaut et à la qualification du défaut détecté par l'expert. Nous ne disposons pas d'une vérité terrain image par image.

Le Tableau 4-6 présente les résultats de ces deux méthodes sur 4 types d'image (trois types de fissure et des images sans défaut), notons que la détection et la bonne classification d'images sans défaut est la même.

	Nombre d'images	CTA_S			FFA	
		Bonne détection (%)	Bonne classification (%)		Bonne détection (%)	Bonne classification (%)
Images sans défaut	1000	72,4	-		86,3	-
Images de fissures longitudinales	14335	75,1	86,3		94,6	92,1
Images de fissures transversales	533	56,6	81,1		76,7	88
Faïençages	605	59	46,4		83	66,5
Total	16473	73,8	84,9		93,6	91,1

Tableau 4-6 : Résultats de détection et classification pour CTA_S et FFA sur les images AMAC®

Sur les chaussées françaises (particulièrement les autoroutes), le type de fissure le plus fréquent est la fissure longitudinale. Les défauts de type faïençage et fissures transversales ne sont que très rarement rencontrés.

Comme les deux méthodes recherchent des attributs sur les 4 orientations (CTA) ou sur toutes orientations (FFA), le fait qu'une fissure ait une orientation transversale ou longitudinale ne doit pas changer le résultat de détection et de classification. La grande différence en pourcentage de bonne détection et bonne classification entre ces trois types de fissure dans le Tableau 4-6 provient de la nature même des images. D'une part, le système ne favorise pas l'acquisition claire des défauts transversaux et d'autre part ces fissures transversales peuvent être de nature différente des autres (moins favorable pour la détection).

Des exemples de résultats sont présentés dans la Figure 4-16 (fissures longitudinales), Figure 4-17 (fissures transversales), Figure 4-18 (faïençages) et Figure 4-19 (images sans défaut).

Remarque :

- Pour la suite, les cas "normal" correspondront à des fissures dont la largeur moyenne est supérieure à 2 pixels. Ces défauts sont facilement visibles à "l'œil".
- Le cas "limite" correspondra à des images contenant des défauts inférieures à 2 pixels, avec des longueurs faibles et discontinues. Concernant la perception visuelle, ces défauts sont difficiles à observer et leur détection est délicate pour l'humain non expert. On

rappelle que les opérateurs détectent certains défauts assistés par des images d'environnement.

Fissures longitudinales

La Figure 4-16 (a) et (b) présente deux exemples de fissure longitudinale. La première (Figure 4-16 (a)) est le cas "normal" avec une largeur de fissures variant de 2 à 4 pixels. Sur la Figure 4-16 (b) se trouve une image d'une fissure longitudinale de cas "limite".

Cas normal : le résultat de CTA_S est morcelé avec peu de bruit (Figure 4-16(c)). La longueur maximum des composantes est de 85 pixels et la transformée de Hough donne un pic correspondant à $\theta = 88^\circ$ avec 144 pixels accumulés. On peut raisonnablement dire que ces fissures sont correctement détectées et bien classifiées par la CTA_S.

Pour la FFA (Figure 4-16(e)), la fissure détectée est bien continue avec une longueur maximum de composantes de 837 pixels. La méthode permet de déterminer que le défaut est unidimensionnel et longitudinal. Pour ce cas il n'y a aucun problème pour la détection et la classification.

Cas limite : la détection et la classification sont moins évidentes. Avec la CTA_S, la longueur maximum des composantes est seulement de 37 pixels. De plus, le pic maximum dans l'espace de Hough correspond à 90° avec seulement 48 pixels accumulés. L'image est donc classifiée comme sans défaut, elle est donc non détectée.

Pour la méthode FFA, (Figure 4-16(f)), la longueur maximum des composantes est de 87 pixels. La fissure est détectable, mais c'est très juste.




Figure 4-16 : Exemples de cas limites d'images de fissures longitudinales.

Sur la base d'images dynamiques, les fissures longitudinales sont les plus fréquentes (plus de 95% de fissures). Elles sont aussi plus facilement observables à l'œil que les faïençages et les fissures transversales. Malgré cela, les fissures longitudinales que l'on trouve sur les images AMAC sont généralement plus fines et plus discontinues que celles que l'on trouve dans la base d'images statiques.

Fissures transversales

Dans cette base, les fissures transversales sont les plus difficiles à percevoir même à l'œil (Figure 4-17(b)). Cela vient de la configuration caméras / illuminateurs laser qui favorise le défaut longitudinal et défavorise le défaut transversal.




Figure 4-17 : Exemples de cas limites d'images de fissures transversales.

Sur la Figure 4-17(a), la fissure transversale est large de 1 à 3 pixels sur une texture avec une granulométrie de 0 à 10 mm (0/10). Elle est bien détectée par la FFA et reste détectable par la CTA_S. Ce type de fissure est très rarement rencontré sur cette base d'images et malheureusement elle est souvent proche du cas limite Figure 4-17(b). C'est pourquoi, dans le Tableau 4-6, les taux de détection et de classification sont très faibles pour ce type de défaut.

Faïençage

La Figure 4-18(a) présente un faïençage développé à partir de fissures longitudinales non réparées. Dans ce cas, la taille des fissures varie de 2 à 8 pixels. Elles sont bien détectées par la CTA_S et la FFA. Pour la FFA (Figure 4-18(e)), 6 zones de faïençage sont détectées tandis que la méthode CTA_S (Figure 4-18(c)) ne trouve que 4 zones bidimensionnelles. Dans le cas "limite", le point faible de la CTA_S (orientation défavorable) ne lui permet pas de distinguer les images de faïençage avec celles de bruits. En effet, les fissures sont détectées par l'intermédiaire de petites composantes faiblement alignées, ce qui explique le faible pourcentage de détection et de classification de faïençage avec la CTA_S. La FFA donne de meilleurs résultats pour ce cas "limite" et donc pour la détection et la classification (respectivement 83% et 66,5% contre 59% et 46,4% pour la CTA_S).




Figure 4-18 : Exemples de faïençages

Le plus souvent, les faïençages sont plus faciles à détecter à l'œil que les fissures transversales. Cela explique leur taux de détection plus élevé que pour les fissures transversales. Cependant, les faïençages restent difficiles à classifier quand on s'approche du cas "limite". Pour cette raison, ce type de défaut peut se retrouver classifié comme fissure longitudinale ou transversale.

Images sans défaut

L'étude des images sans défaut est importante. Elle représente près de 60% des données et l'étiquetage sans défaut intéresse particulièrement les experts des chaussées. On va donc s'intéresser ici au comportement des méthodes en l'absence de défaut dans l'image.

Le pourcentage de fausses alarmes de la CTA et de la FFA est faible. Cela peut s'expliquer par le fait que ces méthodes ne détectent que des pixels plus sombres que leurs voisins avec un bon alignement sur une longueur $2*d+1$ assez importante (17 pixels pour CTA_S et 61 pixels pour FFA).

Sur la Figure 4-19(a), on peut observer des taches noires sur la chaussée. De la même manière sur la Figure 4-19(b), on trouve des objets "brillants" sur fond sombre.

On voit (Figure 4-19 (d) et (e)) que ces "bruits" génèrent des fausses détections quand on utilise la méthode CTA_S. Ceci n'est généralement pas le cas avec la FFA car les chemins min et chemins max ne sont pas différents pour ces types de "bruit".

Par contre, on peut remarquer que certains alignements de taches noires peuvent générer aussi des fausses alarmes avec la FFA (Figure 4-19(c) pour l'image et Figure 4-19(i) pour le résultat par FFA).

Remarque : on observera que la CTA_S ne voit pas ce pseudo défaut. Cela s'explique par le fait que ce "défaut" ressemble à une petite fissure, morcelée et n'est pas "détectable" par la CTA_S.




Figure 4-19 : Exemples de détection de fissures sur des images sans défaut.

4.4.2.1 Discussion

Le résultat de la CTA_S sur cette base d'images capturées en mode dynamique, est assez médiocre. Le degré de morcèlement des fissures, le faible contraste fissure-fond, la forte rugosité de la surface de chaussées, etc, toutes ces raisons affectent le fonctionnement de la méthode CTA_S. On voit bien les limites d'une telle approche et surtout de l'hypothèse pour "l'approximation" de la fissure.

Heureusement, la méthode FFA donne de meilleurs résultats par rapport à la CTA_S et cela quels que soient les essais.

Pour les fissures transversales, principalement pour les cas "limite", les méthodes, et même la FFA, montrent leur défaillance vis à vis de l'inspection de l'expert. Mais il est notable qu'un œil non averti (celui qui n'est pas un expert) n'identifiera pas forcément non plus ce défaut.

Dans le cas du faïençage, la FFA donne un résultat de détection satisfaisant. Le problème se complique quand il s'agit de classifier ce défaut comme étant un faïençage.

Enfin, on a observé que la FFA peut normalement détecter toutes les fissures qui sont observables "sans effort" par l'œil humain. De ce fait, elle permet d'obtenir un bon taux de détection et de classification pour les images de fissures longitudinales et cela avec un faible pourcentage de fausse alarme.

4.5 Conclusion

Dans ce chapitre, nous avons placé les méthodes de segmentation dans un système complet afin de pouvoir évaluer leur efficacité. Les différentes composantes de ce système n'ont pas fait l'objet d'une étude approfondie, l'objectif principal étant de comparer la segmentation du nouvel opérateur que nous proposons ; la FFA avec d'autres opérateurs classiques et la CTA que nous avons adaptée pour la chaussée. Les défauts recherchés sont les fissures qui sont les défauts les plus présents en proportion sur la route. Ces fissures peuvent être longitudinales, transversales ou de type faïençage.

Après une description succincte de la chaîne complète de traitement mise en œuvre autour des méthodes de segmentation, nous avons détaillés les méthodes de prétraitement, d'extraction des attributs et de classification des défauts qui la composent.

Des résultats ont ensuite été présentés sur différents types d'images de façon à qualifier progressivement la méthode proposée en la comparant avec des méthodes existantes.

Dans un premier temps, des comparaisons, avec les travaux publiés par le groupe Fissures du Laboratoire Central des Ponts et Chaussées de Nantes (LCPC), sont présentées sur deux bases d'images :

- des images obtenues en laboratoire et des images capturées en mode statique,
- des images réelles, capturées par le véhicule AMAC®, base de 16473 images.

Les images de laboratoire permettent d'évaluer les limites en termes de largeur de fissures détectables. Les images statiques permettent d'avoir un aperçu des performances de ces méthodes sur des images réelles avec différents types de défauts. Les tests sur ces deux bases ont montré que les résultats de la CTA_S et surtout de la FFA sont plus satisfaisants, en termes de proportion de bonne détection, de précision et de degré de discontinuité des fissures segmentées.

La base d'images réelles obtenues dynamiquement à l'aide de AMAC®, dispose d'une grande variété de type de chaussées et de type de défauts. La base est accompagnée d'un étiquetage, effectué par des experts, des images sur la présence et la nature des défauts. Ces experts relèvent les défauts à partir de 1 mm (1 pixel). Les textures de ces chaussées sont relativement fortes et les défauts plus morcelés par rapport à ceux des autres bases.

Nos méthodes CTA_S et FFA sont testées sur cette base et comparées avec l'étiquetage des experts. Les résultats présentés montrent que les performances de la CTA_S sont moyennes. On met d'ailleurs en évidence le point faible dans le cas d'orientations défavorables ou changeantes de fissures morcelées. Ce cas est malheureusement fréquent lors d'acquisition en mode dynamique. La méthode FFA obtient de meilleurs résultats, surtout sur les images de fissures longitudinales et de faïençages. Une fissure observable à l'œil "sans effort" peut être détectée par la FFA. Cependant, les fissures transversales restent difficiles à détecter mais ce type de défaut l'est aussi pour une personne sans formation car le système de prises de vue a tendance à « masquer » les défauts transversaux.

Dans la conclusion générale, nous présenterons les perspectives concernant la mise en œuvre du nouvel opérateur que nous proposons, dans le cadre du contexte routier ainsi que dans un cadre plus général.

La mise en œuvre d'un système totalement automatique nécessitera la mise en place de méthodes de classification plus élaborées. Il faudra également trouver une solution pour les défauts non détectables en modifiant si nécessaire le dispositif de prises de vue.

Chapitre 5

Conclusion et Perspective

5.1 Conclusion

Ce travail a abordé la détection automatique de fissures dans des images de surface de chaussées. Les difficultés du problème viennent que la fissure a localement des attributs très proches de ceux de la texture de chaussées, notamment des espaces inter-granulaires. Il n'existe pas dans la littérature de méthode largement généralisable dans ce contexte, surtout sur des images fortement texturées, comme c'est le cas des images de chaussées françaises.

Notre objectif est de développer une méthode qui permette de détecter des fissures de différentes largeurs et sur différents types de chaussée, notamment sur les chaussées fortement texturées.

Les idées générales de l'approche, dans ce travail, sont d'une part, de trouver une méthode permettant de prendre en compte la forme de la fissure lors de l'étape de binarisation et d'autre part, de trouver un modèle plus réaliste de la fissure que celui proposé par la littérature.

Dans le chapitre 2, nous avons exposé les premières méthodes basées sur l'Anisotropie Conditionnelle de Texture (CTA). Différentes de la plupart des méthodes existantes, ces approches permettent d'utiliser les attributs de forme et de luminosité des fissures simultanément pour la segmentation. Le point clé de cette approche est de calculer et de comparer les *attributs* des fissures suivant les différentes *configurations d'orientation*. Ces configurations d'orientation représentent l'hypothèse posée sur les fissures. Deux versions de la méthode CTA ont été développées pour tester ces hypothèses sur la fissure : la configuration "segment" correspondant à

l'hypothèse "structure linéaire" et la configuration "région" concernant l'hypothèse région des fissures. Nous avons modélisé des attributs "luminosité" par un modèle d'informations imprécises [70]. Ces attributs sont calculés suivant 4 orientations (0° , 45° , 90° et 135°).

Les résultats des différentes études de ce chapitre ont montré que, si le paramètre de distance est suffisamment important et si la configuration d'orientation correspond à la fissure, alors la méthode CTA permet de distinguer les pixels de fissures des variations du fond (contenant aussi l'espace inter- granulats). Ces résultats ont aussi confirmé que la modélisation de l'attribut "luminosité" est correct dans ce contexte.

Les résultats de la méthode CTA configuration "région" ont pointé la faiblesse du calcul des attributs texturés sur une région pour la détection de petits défauts (fissures) sur une surface texturée aléatoire.

L'étude de la CTA configuration "segment" a montré que cette méthode arrive à bien détecter des fissures à condition que la forme et l'orientation soient favorables aux calculs (forme segment, orientations proche des 4 orientations traditionnelles). Mais cela met en évidence la limite de cette méthode dans le cas d'orientations défavorables (différentes de 0° , 45° , 90° , 135°) ou de forme "libre" de fissure (non linéaire). Ainsi, on voit bien les limites de l'hypothèse qui consiste à approcher la forme des fissures par une "structure linéaire".

Le chapitre 3 présente une deuxième approche fondée sur une hypothèse de fissures plus complète. La modélisation des images par des graphes valués, nous permet de représenter la fissure par un chemin minium passant par un pixel (site) de fissure. Ce chemin peut avoir une forme libre (avec des orientations arbitraires). La recherche d'un minimum de luminosité n'est plus considérée sur chaque pixel mais sur une longueur suffisamment importante du chemin. On a supposé que c'est le mode de perception d'une fissure par l'œil. Le résultat du calcul de ces chemins passant par des pixels de "vérité terrain" de fissures a confirmé cette hypothèse.

On peut voir un obstacle à appliquer ce chemin pour la segmentation, car le temps de calcul pour la recherche des chemins minima évolue de manière exponentielle, et peut être de plusieurs jours pour le traitement d'une image de taille moyenne (512×512 pixels). Afin d'éviter ce problème, dans ce chapitre, nous avons présenté une approche incrémentale pour la recherche de ces chemins qui permet de réduire ce temps à quelques secondes.

Par la suite, nous avons développé une méthode nommée "Free Form Anisotropy" (FFA) qui se base sur la même idée que la méthode CTA en utilisant la configuration du chemin minimum.

L'étude de la méthode FFA montre qu'elle est en mesure de pallier aux inconvénients de la CTA en préservant toujours ses avantages. Les tests réalisés sur différents types de chaussées confirment l'intérêt de cette hypothèse.

Dans le chapitre 4, nous avons évalué et confirmé l'avantage des méthodes développées dans ce travail, et notamment la méthode FFA, pour la détection et la classification de fissures. Cela est réalisé, d'une part en comparant ces résultats avec ceux d'autres méthodes de la littérature sur des bases de données communes et d'autre part en travaillant sur une base de taille conséquente, d'images déjà traitées par des opérateurs.

Mais auparavant, nous avons présenté les différentes étapes précédant et suivant les méthodes CTA et FFA (prétraitement, extraction des attributs, classification) pour avoir un résultat final de détection et de classification des fissures.

Des résultats sont donnés à partir d'une base d'images du Laboratoire Central des Ponts et Chaussées (LCPC). La comparaison est faite avec une méthode classique (seuillage fixe) et une méthode plus récente qui est basée sur un ensemble d'outils (principe de filtrage adapté, transformation en ondelettes et segmentation par Champs de Markov : méthode TOC&Markov). Les résultats présentés pour illustrer cette méthode sont ceux qui ont été publiés dans la thèse [41] tandis que la méthode seuillage a été implémenté lors des travaux initiaux de cette thèse.

L'analyse des résultats montre que, sur toutes les images de cette base, la FFA donne les meilleurs résultats, en considérant le critère de proportion de bonnes détections, de précision et le niveau de continuité des fissures détectées. Sur la base de données réalisée en laboratoire (où on connaît la vérité terrain exacte), la FFA permet de détecter des fissures de 1 pixel de large (résolution de 2mm et 1.2 mm par pixel). Sur l'autre base, constituée d'images capturées en mode statique, le résultat est de 95% de bonne détection et de 11% de fausses alarmes.

Une deuxième série de tests a été exposé dans ce chapitre. Elle a été effectuée sur une base de 16473 images dont on connaît la vérité de l'expert (inspection manuelle d'un opérateur). Les opérateurs ont classé les images en 4 catégories d'images : sans défaut, fissure longitudinale, fissure transversale et faïençage. Il faut noter que cette expertise n'est pas sans erreur et que le

système d'acquisition ne permet pas de mettre en relief les fissures transversales. Ceci explique, en partie, les mauvaises classifications pour les images de faïençage (66,5% de bonnes classifications). La FFA obtient un taux global élevé (93,6% de bonnes détections, 91,1% de bonnes classifications et 13,6% de fausses alarmes). Elle permet de bien détecter des fissures assez petites (2 - 4 pixels) sur des textures fortement texturées. De plus, les grandes fissures (fissures ≥ 4 chaussée fortement texturée ou non) ainsi que les petites fissures (1-2 pixels) sur des chaussées faiblement texturées (dont celles que l'on trouve sur des chaussées anciennes) sont facilement détectées par la FFA.

Pour conclure, ce travail avait pour objectif de trouver une méthode permettant la détection de fissures de différentes largeurs et pour différents types de chaussées. Nous avons montré que nous avons atteint cet objectif avec la méthode FFA. Nous espérons que cette méthode ouvrira des perspectives d'automatisation à 100% ou en partie du relevé des dégradations sur les chaussées.

5.2 Perspectives

Des améliorations sont possibles pour ces méthodes dans les cas "limite" qui sont évoqués dans le chapitre 4. Dans ces cas, la FFA peut détecter des petites portions de défauts mais les attributs et méthodes de classification actuelles ne permettent pas de distinguer ces petites portions avec certains alignements de bruits. Cette tâche ne peut encore être réalisée que par l'expert. Une méthode plus heuristique, utilisée après la segmentation par la FFA, peut certainement améliorer les résultats dans ces cas. Pour les fissures transversales, elles restent très difficiles à voir, même à l'œil, pour une personne qui n'est pas experte. La détection de ces défauts nécessitera, probablement, une modification de dispositif de prise d'images.

Il faut rappeler que, dans ce travail, nous nous sommes concentrés sur les défauts de type "fissure" qui constituent la grande majorité des dégradations. La FFA pourrait être utilisée dans le cadre d'une application 100% automatique de détection de dégradation pour les gestionnaires dans certains pays (où seule la détection de la fissure est exigée). En France, il est nécessaire de détecter d'autres types de défauts en plus des fissures. La méthode FFA est également en mesure de détecter d'autres types de défauts que la fissure, entre autres ceux qui ont un caractère filiforme. Par exemple, si on prend une grande valeur pour la distance d , la méthode peut détecter les joints,

les pontées ou les réparations (présentés dans la Figure 5-1). Cependant, certaines familles de défauts ont besoin d'une autre méthode pour être détectées (Figure 5-2). Cette problématique peut être l'objectif d'autres travaux de recherche sur l'approche algorithmique ou l'aspect technologie d'acquisition (caméras 3D ou stéréovision). En effet, la forte ressemblance de ces défauts avec des éléments de texture dans l'image 2D peut nécessiter une recherche d'informations dans d'autres dimensions.




Figure 5-1 : Exemple de détection de défauts différents des fissures par la méthode FFA.




Figure 5-2 : Exemples de types de défauts pas encore détectables

Cependant, l'automatisation de la détection de fissures et des défauts filiformes ouvre de bonnes perspectives pour une solution semi-automatique pour la détection de dégradations de surfaces de chaussées françaises. En ne proposant que les images contenant probablement des défauts à l'opérateur, cela lui permettrait d'augmenter sa vitesse de travail en diminuant son état fatigue.

Application dans d'autres domaines

En considérant les hypothèses de la méthode FFA et du chemin minimum, on remarque que ces hypothèses ne sont pas valables uniquement que pour les fissures sur des surfaces de chaussées. Elles sont aussi correctes pour d'autres structures fines dans des images plus ou moins texturées. La structure fine, ou la structure filiforme, est un objet dont la longueur est beaucoup plus grande que son épaisseur. L'extraction de structures fines peut être utilisée dans le domaine de l'extraction de routes sur des images satellites [78] ou pour le suivi de vaisseaux dans des images médicales [79, 80]. Dans ces cas, la "texture" de fond est normalement plus faible que celle des chaussées et on peut espérer que la méthode FFA est aussi efficace sur ce type d'images. Deux résultats de la FFA, dans ces cas, sont illustrés à la Figure 5-3.



(a) une image rétinienne



(b) segmentation des vaisseaux sanguins dans l'image (a) par la méthode FFA



(c) une image de satellite



(d) segmentation de routes dans des images (c) par la méthode FFA

Figure 5-3 : Test de la méthode FFA sur d'autres types de structures fines

Annexe A

Base d'image du LCPC

A.1 Images "réalisées" en laboratoires

Pour ces images, toutes les conditions sont maîtrisées (l'éclairage, l'ouverture des fissures, le type de chaussée).

Type de chaussée	Enduit superficiel (ES), Béton Bitumineux Semi Grenu (BBSG), Béton Bitumineux lisse de type angle saxon (BB)
Granulométrie	Assez faible granularité
Contraste de texture	Faible 48 – 115 calculé par attributs contraste de GLCM ¹
Résolution	1.2 mm/pixel, 3.1 mm/pixel
Taille échantillons	400x300 mm
Largeur de fissures	De 1 à 6mm
Degrée de morcellement	Faible (non morcelée)
Composition de type d'images	images des fissures longitudinales seulement
Nombre d'images	20

Tableau 5-1 : Caractéristiques des images de laboratoire

Les échantillons de chaussées ont été fabriqués au LCPC et se présentent sous forme de plaques rectangulaires de 400x300mm. Les fissures sont créées en cassant ces plaques. L'opérateur contrôle la largeur de la fissure en modifiant le pas de déplacement des deux parties de la plaque cassée. Une image de la plaque est alors prise.

Le système de prise de vue se compose d'une caméra matricielle monochrome et d'un éclairage avec 4 tubes fluorescents de 36 watts.

¹ GLCM : Grey Level Co-occurrence Matrix




Figure 5-4 : Principe d'acquisition des images de laboratoire issu de [41].




Figure 5-5 : Images de surface de chaussées prises en laboratoire [41].

Ces images permettent de tester les limites des méthodes étudiées en maîtrisant l'ouverture de fissures. En regardant les images de la figure 5-4, on peut constater que les fissures ainsi produites sont continues et longitudinales. Dans les images réelles, il peut y avoir des fissures discontinues qui sont plus difficiles à traiter et surtout qui peuvent avoir d'autres formes de fissures.

A.2 Images acquises en statique

Cette base dispose d'images réelles de chaussées. Elles sont capturées sur des routes en mode statique (la caméra n'est pas en mouvement pendant l'acquisition). La prise de vue a été réalisée

avec un appareil photo numérique Kodak DC260 positionné perpendiculairement à la route. L'acquisition a été réalisée sur une même portion de route avec peu de changement de type de chaussée, par beau temps et en évitant tout problème d'ombre. Les images obtenues sont du format JPEG.

Type de chaussée	Béton bitumineux, béton bitumineux épais
Granulométrie	Pas d'information précise
Contraste	Assez Forte >1000 calculé par GLCM
Résolution	2mm par Pixel
Taille d'image	768x512 Pixels
Largeur de fissures	Pas d'information précise
Degré de morcellement	Moyen
Composition d'images	Fissures longitudinales, fissures transversales, faïençages, images sans défaut
Nombre d'images	74

Tableau 5-2 : Caractéristiques des images capturées en mode statique.

La figure suivante présente 4 exemples d'images acquises en mode statique avec une résolution de 2mm par pixel.




Figure 5-6 : Images obtenues en mode statique : (a) Fissure longitudinale, (b) Fissure transversale, (c) Faïençage (d) surface sans défaut.

Cette base offre une plus grande variété de défauts. La texture de la chaussée a un contraste plus important. Mais il n'y pas une grande variété de texture, on ne dispose que 10 images sans défauts et on ne connaît pas précisément la largeur de fissures.

Annexe B

Autres résultats comparatifs







Figure 5-7 : Résultat comparatif de la FFA avec la méthode TOC&Markov sur des images de fissure de 1 pixel de large.




(a) image “laboratoire”



(b) résultat d’une méthode basée sur la stéréovision, issu de [81]




(c1) image de valeur FFA, $d = 30$




(c2) résultat de la FFA


Figure 5-8 : Résultat comparatif de la FFA avec une méthode basée sur la stéréovision [81]




(a) image originale, issue de [82]



(b) résultat de la méthode de LI, issu de [82]




(c1) image de valeur FFA, $d = 30$




(c2) résultat de la FFA, $d = 30$


Figure 5-9 : Résultat comparatif de la FFA avec une méthode basée sur l'histogramme différence [82]




(a) image originale, issue de [83]



(b) résultat de la méthode
de H. Oliveira et al, issu de [83]



(c1) image de valeur FFA, $d = 30$



(c2) image résultat de la FFA, $d = 30$

Figure 5-10 : Résultat comparatif de la FFA avec le méthode de H. Oliveira et al [83]

Publications de l'auteur

- **Tien Sy NGUYEN**, Pascal VRIGNAT, Manuel AVILA, Stephane BEGOT, Florent DUCULTY “ Détection de défauts sur la surface de chaussées par système de vision ”, 21ème Colloque GRETSI, Troyes, France, septembre 2007.
- **Tien Sy NGUYEN**, Manuel AVILA, Stephane BEGOT et Jean Christophe BARDET “Detection of defects in road surface by a vision system” MELECON 2008. The 14th IEEE Mediterranean, Ajaccio, France, may 2008.
- **Tien Sy NGUYEN**, Manuel AVILA, Stephane BEGOT , “Automatic defect detection on road pavement using anisotropy measure”, 17th European Signal Processing Conference (EUSIPCO 2009), Glasgow, Scotland, August 24-28, 2009.
- **Tien Sy NGUYEN**, Manuel AVILA, Stephane BEGOT, Florent DUCULTY et Jean Christophe BARDET, “Étude d'un algorithme de détection de défauts sur des images de chaussées”, 22ème colloque GRETSI, Dijon, France, septembre 2009.
- **Tien Sy NGUYEN**, Stephane BEGOT, Florent DUCULTY, Jean Christophe BARDET et Manuel AVILA “Pavement Cracking Detection using an Anisotropy Measurement”, IASTED Conference on Computer Graphics and Imaging, Innsbruck, Austria 2010.

Bibliographies

1. Chambon, S., et al. *Road crack extraction with adapted filtering and Markov model-based segmentation*. in *International Joint Conference on Computer Vision Theory and Applications, VISAPP*. may, 2010. Angers, France.
2. Coudray, N., et al., *Multi-resolution approach for fine structure extraction - Application and validation on road images*, in *International Joint Conference on Computer Vision Theory and Applications, VISAPP*. 2010: , Angers, France.
3. Delagnes, P., *Etraction d'informations dans les images texturées fixes et animées*. 1996, Ecole doctorale sciences pour l'ingénieur de Nantes.
4. Bertrand, L. and P. Lepert, *Catalogue des dégradations de surface des chaussées : Méthode d'essai n° 52*. 1998, Laboratoire Central Des Ponts et Chaussées (LCPC).
5. Vectra's Amac specification , <http://www.vectra.fr>.
6. Schmidt, B., *Automated Pavement Cracking Assessment Equipment - State of the Art*. 2003, World Road Association (PIARC).
7. Fukuhara, T., et al., *Automatic Pavement-Distress-Survey System*, in *Journal of Transportation Engineering*. 1990. p. pp. 280-286.
8. CSIRO, *CSIRO' Road Crack Specification*, <http://www.csiro.au>.
9. Roadware, *Roadware*, Ontario, Canada *ARAN Wise Crack specification*, website www.roadware.com.
10. Wang, K.C.P., *Designs and implementations of automated systems for pavement surface distress survey*, in *Journal of Infrastructure Systems*. 2000. p. pp. 24-32.
11. Wang, K.C.P., *Automated Pavement Distress Survey through Stereovision*. 2004, Transportation Research Board.
12. Aura, C. and P. Claudia Belmiro, *A fractal image analysis systems for fabric inspection based on a box-counting method*. 1998, Elsevier Science Publishers B. V. p. 1887-1895.
13. Norton Wayne, L., M. Bradshaw, and A.J. Jewell, *Machine Vision Inspection of Web Textile Fabric*, in *#BMVC92#*. 1992. p. xx-yy.
14. L.Norton-wayne, M. Bradshaw, and A.J. Jewell. *Machine vision for the automated inspection of web materials*. in *Proc. SIPE* 1989.
15. Roli, F., *Measure of texture anisotropy for crack detection on textured surfaces*, in *Electronics Letters*. 1996. p. 1274--1275.
16. Nguyen , T.S., et al., *Detection of defects in road surface by a vision system*, in *Proc. 14th IEEE Mediterranean Electrotechnical Conference MELECON 2008*. 2008. p. 847--851.
17. Tanaka, N. and K. Uematsu, *A Crack Detection Method in Road Surface Images Using Morphology*, in *MVA*. 1998. p. 154-157.

18. Elbehriy, H., A. Hefnawy, and M. Elewa, *Surface Defects Detection for Ceramic Tiles Using Image Processing and Morphological Techniques*, in *WEC (5)*, C. Ardil, Editor. 2005, Enformatika, Çanakkale, Turkey. p. 158-162.
19. Zhang, X.F. and R.R. Bresee, *Fabric defect detection and classification using image analysis*. Textile Research Journal, 1995. **65**(3): p. 123-130.
20. Huart, J. and J.-G. Postaire. *Integration of computer vision onto weavers for quality control in the textile industry*. in *Proc SPIE*. 1989.
21. Jean, S., *Image Analysis and Mathematical Morphology*. 1983: Academic Press, Inc.
22. Conci, A. and C.B. Proença, *A Computer Vision Approach for Textile Inspection*,. Textile Research Journal, 2000. **70**(4): p. 347-350. .
23. Bennamoun, M. and A. Bodnarova. *Automatic visual inspection and flaw detection in textile materials: past, present and future*. in *Proc.IEEE conf.SMC*. 1998.
24. Siew, L.H., R.M. Hodgson, and E.J. Wood, *Texture Measures for Carpet Wear Assessment*, in *IEEE Trans. Pattern Anal. Mach. Intell.* 1988, IEEE Computer Society. p. 92--105.
25. Connors, R.W., et al., *Identifying and locating surface defects in wood: Part of an automated lumber processing system*. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1983. **PAMI-5**(6): p. 573-583.
26. Amet, A.L., A. Ertuzun, and A. Ercil. *Texture defect detection using subband domain co-occurrence matrices*. in *Proc. IEEE Southwest Symposium on Image Analysis and Interpretation*. 1998.
27. Hepplewhite, L. and T.J. Stonham. *Surface inspection using texture segmentation*. in *IEE Colloquium. Texture Classification: Theory and Applications*. 1994.
28. Cavalin, P., et al. *Wood Defect Detection using Grayscale Images and an Optimized Feature Set*. in *IECON 2006 - 32nd Annual Conference on IEEE Industrial Electronics*. Nov. 2006. Paris.
29. Ade, F., N. Lins, and M. Unser. *Comparison of various filter sets for defect detection in textiles*. in *Proc. 7th Intl. Conf. Pattern Recognit.* 1984. Montreal.
30. Unser, M., *Local linear transform for texture measurements*. Signal Processing, 1986. **11**(1): p. 61-79.
31. Unser, M. and M. Eden, *Multiresolution Feature Extraction and Selection for Texture Segmentation*. 1989, IEEE Computer Society. p. 717-728.
32. Tsai, D.-M. and T.-Y. Huang, *Automated surface inspection for directional textures* Image and Vision Computing, 1999. **18**(1): p. 49-62.
33. Bruzzone, L., F. Roli, and S.B. Serpico, *Crack Detection by a Measure of Texture Anisotropy*, in *ICIAP '95: Proceedings of the 8th International Conference on Image Analysis and Processing*. 1995, Springer-Verlag: London, UK. p. 743--747.
34. Casasent, D.P. and D.F. Clark, *Practical optical Fourier analysis for high speed inspection* Optical Engineering, 1988. **27**(05): p. 365-371.
35. Kumar, A., *Automated defect detection in textured materials*. 2001, University of Hong Kong.
36. Escofet, J., et al., *Detection of local defects in textile webs using Gabor filters*. Optical Engineering, 1998. **37**(8): p. 2297-2307.
37. Warren, J.J., J.G. Stephen, and H. Potlapalli, *Texture characterization and defect detection using adaptive wavelets* Optical Engineering, 1997. **35**.

38. Subirats, P., et al., *Automation of Pavement Surface Crack Detection using the Continuous Wavelet Transform*, in *Proc. IEEE International Conference on Image Processing*. 2006. p. 3037--3040.
39. Chambon, S., J. Dumoulin, and P. Subirats, *Introduction of a wavelet transform based on 2D matched filter in a Markov Random Field for fine structure extraction: Application on road crack detection*, in *SPIE Conference on Image Processing: Machine Vision Applications II, San Jose, United-States*. 2009.
40. Jasper, W.J., S.J. Garnier, and H. Potlapalli, *Texture characterization and defect detection using adaptive wavelets*, in *Optical Engineering*. 1996, SPIE. p. 3140-3149.
41. Subirats, P., *Conception et validation de méthodes de traitement d'images appliquées à la détection de fissures sur les images de surface de chaussées*. 2006, Université de Nantes.
42. George Robert, C., *Markov random field texture models*. 1980, Michigan State University. p. 198.
43. Brzakovic, D.P., N.S. Vujovic, and A. Liakopoulos. *Approach to quality control of texture web materials* in *Proc. SIPE* 2597. 1995.
44. Connors, R.W., et al., *Identifying and locating surface defects in wood: Part of an automated lumber processing system*, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1983. p. 573-583.
45. Kumar, A., *Neural network based defection of local textile defects*. *Pattern Recognition*, 2003. **36**: p. 1645-1659.
46. Wang, K.C.P. and W. Gong, *Automated Pavement Distress Survey: A Review and A New Direction*, in *Pavement Evaluation Conference*. 2002.
47. Howe, R. and G.C.a. Gerardo, *An assessment of the feasibility of developing and implementing an automated pavement distress survey system incorporating digital image processing*. 1997, The Virginia Transportation Research Council.
48. Timm, D.H. and J.M. McQueen, *A Study of Manual vs. Automated Pavement Condition Surveys*. 2004, Auburn University Highway Research Center.
49. Chua, K.M. and L. Xu, *Simple Procedure for Identifying Pavement Distresses from Video Images*, in *J. Transp. Engrg.* 1994. p. pp. 412-431.
50. Dumoulin, J., et al., *Détection de fissures de surface de chaussées par techniques d'imagerie dans le visible*. 2003.
51. Fundakowski, R.A., et al., *Video image processing for evaluating pavement surface distress*, in *Transportation Research Board*. 1991.
52. Kalikiri, V.K., G.N. W, and A.L.E. K, *Image-processing methods for automated distress evaluation*, in *Transportation research record*. 1994. p. pp. 45-51.
53. Meignen, D., M. Bernadet, and H. Briand, *One Application of Neural Networks for Detection of Defects Using Video Data Bases: Identification of Road Distresses*, in *Proceedings of the 8th International Workshop on Database and Expert Systems Applications*. 1997, IEEE Computer Society.
54. Cheng, H.D., et al., *Novel Approach to Pavement Cracking Detection Based on Fuzzy Set Theory*, in *Journal of Computing in Civil Engineering*. 1999. p. pp. 270-280.
55. Chou, J., W.A. O'Neill, and H. Cheng, *Pavement distress evaluation using fuzzy logic and moment invariants*, in *Transportation research record*. 1995. p. pp. 39-46.

56. Oliveira, H. and P.L. Correia. *Automatic Road Crack Segmentation Using Entropy and Image Dynamic Thresholding*. in *proc European Signal Processing Conf. - EUSIPCO*. 2009. Glasgow, United Kingdom.
57. Oliveira, H. and P. Lobato Correia, *Identifying and retrieving distress images from road pavement surveys*, in *Proc. 15th IEEE International Conference on Image Processing ICIP 2008*. 2008. p. 57--60.
58. Delagnes, P. and D. Barba, *A Markov random field for rectilinear structure extraction in pavement distress image analysis*, in *Proc. International Conference on Image Processing*. 1995. p. 446--449 vol.1.
59. Delagnes, P. and D. Barba, *Rectilinear structure extraction in textured images with an irregular, graph-based Markov random field model*, in *Proc. 13th International Conference on Pattern Recognition*. 1996. p. 800--804 vol.2.
60. Chou, J., W.A. O'Neill, and H.D. Cheng, *Pavement distress classification using neural networks*, in *Proc. IEEE International Conference on Systems, Man, and Cybernetics 'Humans, Information and Technology'*. 1994. p. 397--401 vol.1.
61. Delagnes, P. and D. Barba, *A Markov random field for rectilinear structure extraction in pavement distress image analysis*, in *Proc. International Conference on Image Processing*. 1995. p. 446--449 vol.1.
62. Hu, M.K., *Visual Pattern Recognition by Moment Invariants*. . IRE Transaction on Information Theory, 1962. **8**(2): p. 179-187.
63. Belkasim, S.O., M. Shridhar, and M. Ahmadi, *Pattern recognition with moment invariants: a comparative study and new results*. 1991, Elsevier Science Inc. p. 1117-1138.
64. Teague, M.R., *Image analysis via the general theory of moments*. Optical Society of America, Journal, 1980. **70**: p. 920-930.
65. Cheng, H.D., et al., *Automated real-time pavement distress analysis*, in *Transportation research record, Journal of the Transportation Research Board*. 1999. p. pp. 55-64.
66. Lorenzo, B., R. Fabio, and B.S. Sebastiano, *Crack Detection by a Measure of Texture Anisotropy*, in *Proceedings of the 8th International Conference on Image Analysis and Processing*. 1995, Springer-Verlag.
67. Bajcsy, R., *Computer description of textured surfaces*, in *IJCAI'73: Proceedings of the 3rd international joint conference on Artificial intelligence*. 1973, Morgan Kaufmann Publishers Inc.: San Francisco, CA, USA. p. 572--579.
68. Richard, O.D., E.H. Peter, and G.S. David, *Pattern Classification (2nd Edition)*. 2000: Wiley-Interscience.
69. Mahalanobis, P.C. *On the generalised distance in statistics*. in *Proceedings of the National Institute of Sciences of India*. 1936.
70. Dubois, D. and H. Prade, *La fusion d'informations imprécises*, in *Traitement du Signal*. 1994. p. 447-458.
71. Zadeh, L.A., *Fuzzy sets as a basis for a theory of possibility*. 1999, Elsevier North-Holland, Inc. p. 9-34.
72. Duculty, F., *Détection, suivi et positionnement des obstacles sur la chaussée par fusion de données multisensorielles dans le cadre de la théorie des possibilités*. 1999, Université Blaise Pascal Clermont-Ferrand.
73. Otsu, N., *A Threshold Selection Method from Gray-Level Histograms*, in *Systems, Man and Cybernetics, IEEE Transactions on*. 1979. p. 62 - 66.

74. Thomas, H.C., et al., *Introduction to Algorithms*. 2001: McGraw-Hill Higher Education.
75. Theodoridis, S. and K. Koutroumbas, *Pattern Recognition, Fourth Edition*. 2008: Academic Press.
76. Galambos, C., J. Kittler, and J. Matas, *Progressive Probabilistic Hough Transform for Line Detection*. 1999, IEEE Computer Society: Los Alamitos, CA, USA. p. 1554.
77. Joseph, M.C., *Efficient binary image thinning using neighborhood maps*, in *Graphics gems IV*. 1994, Academic Press Professional, Inc. p. 465-473.
78. Geman, D., et al., *An Active Testing Model for Tracking Roads in Satellite Images*, in *IEEE Transactions on Pattern Analysis and Machine Intelligence*. 1995. p. 1--14.
79. O'Meara, J., T. Miller, and P. Echevarria, *Blood Vessel Segmentation in Retinal Images*. 2004, Stanford University.
80. Chaudhuri, S., et al., *Detection of blood vessels in retinal images using two-dimensional matched filters*, in *IEEE Transactions on Medical Imaging*. 1989. p. 263--269.
81. Chambon, S. *Detection of road cracks with multiple images*. in *International Joint Conference on Computer Vision Theory and Applications, VISAPP*. 2010. Angers, France.
82. Li, Q. and X. Liu, *Novel Approach to Pavement Image Segmentation Based on Neighboring Difference Histogram Method*, in *Proc. Congress on Image and Signal Processing CISP '08*. 2008. p. 792--796.
83. Oliveira, H. and P.L. Correia. *Automatic Crack Detection on Road Imagery Using Anisotropic Diffusion and Region Linkage*. in *Proc European Signal Processing Conf. - EUSIPCO*. August, 2010. Aalborg, Denmark.

Extraction de structures fines sur des images texturées : application à la détection automatique de fissures sur des images de surface de chaussées

Résumé : La dernière décennie a vu l'exploitation d'application d'inspection automatique dans plusieurs domaines grâce à l'avancé des capteurs de vision et des méthodes d'analyse de texture et de segmentation d'images. Cependant, la nature difficile des images de chaussées (fortement texturée), la petite taille des défauts (fissures) conduisent au constat que l'inspection dans ce domaine est réalisée manuellement. Chaque année, en France, des opérateurs doivent visualiser des milliers de kilomètres d'images de route pour y relever des dégradations. Cette façon de faire est coûteuse, lente et a un résultat plutôt subjectif. L'objectif de ce travail de thèse est de développer une méthode permettant la détection et la classification des fissures automatiquement sur ces images de chaussées.

Le cœur de la thèse est une nouvelle méthode de segmentation, la Free Form Anisotropy (FFA). D'une part, elle permet de prendre en compte simultanément les attributs concernant la forme et l'intensité des pixels d'une fissure pour la détection. D'autre part, une nouvelle modélisation est utilisée en recherchant des chemins minima dans des graphes (images) afin de trouver la forme de la fissure dès qu'elle est présente dans l'image.

Après la segmentation, l'extraction et la classification de défauts sont réalisées par une transformée de Hough et par le calcul de l'orientation locale des pixels. Les résultats expérimentaux ont été obtenus à partir de plusieurs bases d'images et comparés avec des méthodes existantes.

Mots clés : segmentation d'images, détection de défauts, extraction de structures fines, anisotropie, chemin minimum.

Fine structure extraction in textured images: application on automatic road crack detection

Summary: These last decades have seen application of automatic inspection in many fields thanks to advanced vision sensors and image analysis methods. However, the difficult nature of pavement images, the small size of defects (cracks) lead to the fact that inspection in this area is done mostly manually. Each year in France, operator must view images of thousands kilometers of roads to detect these degradations. This method is expensive, slow and has a rather subjective result. The objective of this thesis is to develop a method for the detection and the classification of cracks on these pavement images automatically.

In this thesis, a new method of segmentation has been developed: the Free Form Anisotropy (FFA). On one hand, this method allows to take into account both the features concerning form and intensity of cracks, for the detection. On the other hand, a new model is used to search minimum paths in graphs (images). This minimum path follows crack form when crack is present.

After segmentation, extraction and classification of defects are performed by the Standard Hough Transform and by calculating local orientation of pixels. Experimental results have been obtained from different image databases and compared with other existing methods.

Keywords : image segmentation, defect detection, anisotropy, crack, fine structure extraction, minimum path

Institut PRISME

EQUIPE : Images et Signaux pour les Systèmes

Site IUT de l'Indre

2 Avenue François Mitterrand, 36000 Châteauroux

