

ADEL ZIADI

**ANALYSE D'IMAGE VISIBLES ET PROCHE
INFRAROUGES : CONTRIBUTIONS À
L'ÉVALUATION NON-DESTRUCTIVE DU
PERSILLAGE DANS LA VIANDE DU BŒUF**

Thèse présentée
à la Faculté des études supérieures et postdoctorales de l'Université Laval
dans le cadre du programme de doctorat en génie électrique
pour l'obtention du grade de Philosophiæ doctor (Ph.D.)

DÉPARTEMENT DE GÉNIE ÉLECTRIQUE ET DE GÉNIE INFORMATIQUE
FACULTÉ DES SCIENCES ET DE GÉNIE
UNIVERSITÉ LAVAL
QUÉBEC

2011

Résumé

Le persillage (gras intramusculaire) dans la viande de bœuf est l'un des critères les plus importants pour l'évaluation de la qualité, notamment sa jutosité, dans les systèmes de classification de la viande. Le processus chimique, méthode destructive, est l'unique moyen officiellement utilisé pour évaluer la proportion du persillage dans la viande. C'est une méthode destructive, complexe et qui n'offre aucune information sur la distribution du persillage dans la viande.

Cette thèse porte sur le développement d'une méthode originale destinée à l'évaluation non-destructive de la proportion volumétrique du persillage dans la viande du bœuf. Cette nouvelle méthode, qui pourrait être intégrée dans un système de vision artificielle (*machine vision*), est une première expérience pour ce genre d'application. À notre meilleure connaissance, aucune méthode semblable n'a été élaborée. De ces travaux de doctorat quatre contributions sont identifiées: la technique proposée, deux méthodes de segmentation d'images et une méthode non-destructive pour estimer la proportion volumétrique du persillage.

La technique proposée permet d'avoir deux types d'images : une visible qui illustre la surface de la viande et une proche infrarouge qui est la projection orthogonale de l'échantillon de la viande (3D) en une image d'ombre (2D). Compte tenu de la complexité d'analyse des images, nous avons développé une méthode efficace de segmentation permettant d'identifier les régions homogènes les plus (ou les moins) claires dans une image à niveaux de gris. Cette méthode, qui est relativement générale, est basée sur un modèle mathématique permettant d'évaluer l'homogénéité des régions, qui lui-même a été introduit dans cette thèse. La généralisation de cette méthode pour la segmentation du persillage a démontré des résultats satisfaisants face aux objectifs attendus. Étant donné, que la forme volumétrique du persillage est aléatoire et que celle-ci dépend de la façon dont le persillage est déposé entre les fibres musculaires, ce qui est imprévisible, nous avons combiné les résultats de la segmentation de deux types d'images pour estimer le volume du persillage. L'intégration de l'ensemble des approches précédentes nous a permis de développer une nouvelle méthode non-destructive pour estimer la proportion volumétrique du persillage.

Les résultats obtenus par la méthode proposée (non-destructive) ont été comparés aux résultats obtenus par une méthode chimique (destructive) comme étant la vérité-terrain (*gold standard*). Les résultats expérimentaux confirment les propriétés attendues de la méthode proposée et ils illustrent la qualité des résultats obtenus.

Abstract

Marbling (intramuscular fat) in beef meat is one of the most important criteria for quality evaluation, including its juiciness, in meat classification systems. A chemical analysis, which is a destructive method, is the unique official means used to evaluate the proportion of marbling in meat. It is a destructive and complex method, which does not give any information about the marbling distribution in the meat.

This thesis focuses on the development of an original method for the non-destructive evaluation of the volumetric proportion of marbling in beef meat. This new method, which could be integrated into a system of artificial vision (machine vision), is a first experience for this kind of application. To the best of our knowledge, no similar method has been developed. From this doctoral work, four contributions are identified: the proposed technique, two image segmentation methods and a non-destructive method to estimate the volumetric proportion of marbling.

The proposed technique provides two types of images: one is visible that illustrates the surface of the meat, and the other is a near infrared which is the orthogonal projection of the sample of meat (3D) into a shadow image (2D). Given the complexity of image analysis, we developed an efficient segmentation method to identify homogeneous regions the most (or least) clear in the gray level image. This method, which is relatively general, is based on a mathematical model to evaluate the homogeneity of the regions, which itself was introduced in this thesis. The generalization of this method for the segmentation of marbling has shown satisfactory results which meet the expected goals. Given that the volumetric shape of the marbling is random and it depends on how the marbling is deposited between muscles, which is unpredictable, we combined the result segmentation of the two images to estimate the amount of marbling. The integration of all previous approaches allowed us to develop a new non-destructive method to estimate the volumetric proportion of marbling.

The results obtained by the proposed method (non-destructive) were compared with results obtained by a chemical method (destructive) as the gold standard. The experimental results confirm the expected properties of the proposed method and illustrate the quality of the results obtained.

Avant-propos

J'aimerais sincèrement remercier et en même temps exprimer toute ma reconnaissance envers le professeur Xavier Maldague qui a dirigé cette thèse avec enthousiasme et qui m'a soutenu avec fierté sur tout les plans tout au long de ces dernières années. J'aimerais également remercier la professeure Linda Saucier qui a codirigé cette thèse et qui m'a assisté avec inspiration durant mes travaux de recherches.

J'aimerais également remercier toute ma famille, et ceux et celles qui m'ont aidé, de proche ou de loin tout au long de cette thèse, tout particulièrement : les professionnels de recherche et les professeurs du laboratoire de vision, le professeur Carl Duchesne, le professeur Ryan Gosselin et mes partenaires dans ma compagnie VISIOOIMAGE INC. (Matthieu, Clemente et Marc).

Sans nommer personne, je tiens également à remercier mes amis qui sont souvent autour de moi.

À la mémoire de mes frères Mohsen & Zouhair.

Table des matières

Résumé	i
Abstract.....	ii
Avant-propos	iii
Table des matières.....	v
Liste des tableaux	viii
Liste des figures	ix
Nomenclature.....	xi
1 Introduction.....	1
2 Transmission de la lumière proche infrarouge dans la viande de bœuf et évaluation qualitative du persillage en utilisant l'imagerie visible et proche infrarouge.....	7
2.1. Technique proposée	9
2.1.1. Étude spectrale (matériel et méthode)	13
2.1.2. Approche proposée	21
2.2. Résultats et discussion	23
2.3. Diverses configurations de la technique proposée et résultats	29
2.3.1. Effets des diffuseurs	30
2.3.2. Effets de l'éclairage sur l'image de surface.....	31
2.3.3. Effets de la longueur d'onde.....	32
2.3.4. Effets de la réflexion, de l'absorption et de la transmission.....	33
2.4. Conclusion	35
3 Segmentation d'image : approches et problématiques.....	37
3.1 Segmentation d'image par classification de pixels.....	39
3.1.1 Seuillage par l'histogramme de l'image	39
3.1.2 Seuillage par classification de pixels.....	44
3.1.3 Méthodes statistiques.....	48
3.1.4 Seuillage entropique (<i>Entropy Thresholding</i>)	53
3.1.5 Réseaux de Neurones.....	58
3.2 Segmentation d'image en régions.....	59
3.2.1 Division et Fusion (<i>split and merge</i>)	59
3.2.2 Croissance de régions (<i>region growing</i>).....	59
3.3 Segmentation d'image en contours.....	60
3.4 Segmentation d'image par méthode hybride	60
3.5 Évaluation de la qualité de la segmentation	61
3.5.1 Évaluation qualitative de la segmentation	61
3.5.2 Évaluation quantitative de la qualité de segmentation.....	62
3.6 Conclusion	66

4 Extraction des régions homogènes en niveaux de gris en utilisant l’algorithme ‘FCE’	67
4.1 Modèles et algorithme	68
4.1.1 Homogénéité de la classe c	74
4.2 Résultats et discussion (cas de la figure 4.2)	78
4.3 Divers résultats et évaluation qualitative-quantitative	83
4.3.1 Résultats des images proches infrarouges	83
4.3.2 Résultats sur des images visibles	86
4.3.3 Résultats de détection de défauts dans les planches du bois	87
4.3.4 Résultats sur des images de scènes naturelles	90
4.4 Évaluation quantitative	93
4.5 Conclusion	98
5 Segmentation d’images visible et proche infrarouge dans un environnement à faible contraste: application à la détection du persillage en utilisant l’imagerie visible proche infrarouge	99
5.1 Vue d’ensemble sur l’algorithme FCE	101
5.2 Méthode proposée	105
5.2.1 Généralisation de l’algorithme FCE pour une segmentation locale	107
5.2.2 Processus de fusion et d’agrandissement des régions	108
5.2.3 Résultats de la segmentation locale	108
5.2.4 Algorithme	110
5.3 Résultats et discussion (cas de la figure 5.1)	118
5.4 Étude comparative entre l’image visible et l’image proche infrarouge	120
5.5 Évaluation de la qualité de la segmentation	122
5.5.1 Évaluation qualitative	122
5.5.2 Évaluation quantitative	124
5.6 Conclusion	133
6 L’analyse d’images visible et proche infrarouge en vision artificielle : une nouvelle méthode flexible pour l’évaluation non-destructive du gras intramusculaire dans la viande de bœuf	134
6.1 Approche proposée pour l’acquisition d’images	138
6.2 Isolation du persillage par segmentation d’image	140
6.3 Mise en correspondance et reconnaissance de forme	143
6.4 Catégorisation des régions du persillage	146
6.5 Méthode proposée	150
6.5.1 Mise en correspondance et mesure de similarité	152
6.5.2 Estimation volumétrique du persillage	160
6.6 Résultats et discussion	168
6.7 Méthode chimique	169
6.8 Évaluation quantitative de la méthode proposée	169
6.8.1 Calibrage des résultats et évaluation quantitative	172
6.9 Conclusion	176

7 Conclusion	177
❖ Contributions	178
❖ Perspectives de recherches futures	182
Bibliographie	184
Annexe A : la viande de bœuf et ses caractéristiques	191
Annexe B : procédure expérimentale et mise en registre des images	195
Annexe C : diverses illustrations expérimentales	199

Liste des tableaux

Tableau 2.1. Intensités moyennes des pixels du persillage et du muscle	35
Tableau 4.1. Mesure de l'uniformité des régions détectées.....	96
Tableau 5.1. Évaluation de la qualité de la segmentation par le critère de Borsotti.....	128
Tableau 5.2. Évaluation quantitative de l'efficacité de détections des régions du persi....	130
Tableau 6.1. Estimation des proportions volumétrique du persillage.....	168
Tableau 6.2. Proportions du volume de persillage obtenu par la méthode.....	171
Tableau A.1 Caractéristiques des grades de qualité de la viande bovine au Canada.....	192
Tableau B.1. Proportions du volume de persillage obtenu.....	198

Liste des figures

Figure 2.1. Spectre de la lumière.....	10
Figure 2.2. Illustration graphique des trois régions proche infrarouge.....	11
Figure 2.3. Illustration graphique du mécanisme de transfectance	12
Figure 2.4. Représentation schématique du système d'imagerie hyperspectral utilisé.....	15
Figure 2.5. Profils des spectres des régions de pixels de muscle et de persillage	16
Figure 2.6. Absorption monochromatique selon la loi de Beer-Lambert.	18
Figure 2.7. Spectres d'absorbance du persillage et du muscle de la viande de bœuf.	19
Figure 2.8. Dispositif expérimental de l'approche proposée.....	21
Figure 2.9. Détection du persillage dans la viande de bœuf.....	24
Figure 2.10. Fonctions de densité de probabilités des intensités de pixels.....	26
Figure 2.11. Images couleurs de la face et de la face opposée de l'échantillon.	28
Figure 2.12. Effets des diffuseurs.....	30
Figure 2.13. Effets de l'éclairage sur l'image de surface.	31
Figure 2.14. Effets de la longueur d'onde.	32
Figure 2.15. Effet de l'absorbance à partir des images visibles et proches infrarouges.	34
Figure 3.1. Allure de la vallée en fonction des niveaux de gris de deux classes à séparer...	41
Figure 3.2. Images visible et proche infrarouge (940 nm).....	42
Figure 3.3. Histogrammes des images visible et proche infrarouge.....	42
Figure 3.4. Classification en trois classes de pixels par l'algorithme de fuzzy k-means.....	46
Figure 3.5. Classification en cinq classes de pixels par l'algorithme de fuzzy k-means.....	46
Figure 3.6. Classification en trois classes de pixels par l'algorithme de EM.....	52
Figure 3.7. Classification en cinq classes de pixels par l'algorithme d'EM.....	53
Figure 3.8. Entropie floue appliquée à la courbe d'histogramme.....	57
Figure 4.1. Illustration de la clique de pixels.....	69
Figure 4.2. Image proche infrarouge de la viande de bœuf.	72
Figure 4.3. Variation de la distance D_{cq} en fonction des itérations.	73
Figure 4.4. Variations de l'homogénéité H de la classe c et l'histogramme de l'image	76
Figure 4.5. Homogénéité H de la région la moins claire dans l'image synthétique.	77
Figure 4.6. Détection des régions les moins claires par l'algorithme FCE.	78
Figure 4.7. Distribution des pixels des régions détectées par l'algorithme FCE.....	79
Figure 4.8. Résultats comparatifs de la segmentation.	81
Figure 4.9. Distributions des pixels des régions détectées	82
Figure 4.10. Résultats sur des images proches infrarouges.	84
Figure 4.11. Divers résultats sur des images visibles.	86
Figure 4.12. Détection de défauts dans les planches de bois.....	88
Figure 4.13. Résultats sur des images de scènes naturelles.....	90
Figure 4.14. Résultats avec des images infrarouges.....	92
Figure 4.15. Résultats de segmentation obtenus sur des images synthétiques et naturelles.....	96
Figure 5.1. Images visible et proche infrarouge d'une surface de viande de bœuf..	103
Figure 5.2. Variations de l'homogénéité H et des histogrammes.....	103
Figure 5.3. Détection des régions homogènes par l'algorithme FCE.....	104
Figure 5.4. Segmentation itérative des images en régions par l'algorithme FCE.	106
Figure 5.5. Résultats de la segmentation locale.....	109

Figure 5.6. Protocole de découpage de l'image en imagerie.....	114
Figure 5.7. Généralisation de l'algorithme FCE pour la segmentation	116
Figure 5.8. Résultats de la méthode de la segmentation.....	118
Figure 5.9. Illustration du persillage détecté par les deux types d'images.	121
Figure 5.10. Évaluation qualitative de la méthode de la segmentation.	123
Figure 5.11. Évaluation qualitative de la méthode de la segmentation.	127
Figure 5.12. Illustration des critères de mesure	130
Figure 5.13. Illustration des quelques résultats supplémentaires de segmentation.	132
Figure 6.1. Dispositif expérimental de l'approche proposée.	138
Figure 6.2. Images visibles et proches infrarouges.....	141
Figure 6.3. Détection du persillage à partir des images visibles et proches infrarouges. ...	142
Figure 6.4. Représentations géométriques des régions de persillage.	145
Figure 6.5. Variation de la distribution des pixels du persillage à la surface	148
Figure 6.6. Détection du persillage proche de la surface.....	149
Figure 6.7. Exemple de probabilité de distribution de pixels	152
Figure 6.8. Mise en correspondance entre les régions.....	158
Figure 6.9. Mise en correspondance des régions de persillage.....	159
Figure 6.10. Illustration 3D des deux faces de l'échantillon de la viande.	161
Figure 6.11. Modèle de deux régions misent en correspondance.....	161
Figure 6.12. Modèle d'une région isolée du persillage.	165
Figure 6.13. Illustration graphique de la proportion de persillage	172
Figure 6.14. Distribution conjointe de la proportion du gras intramusculaire.....	174
Figure A.1. Les quatre catégories de qualité de la viande.	191
Figure A.2. Spectre de réflectance d'une région de muscle et d'une région de gras.....	193
Figure A.3. Illustration d'un spectre d'absorbance du gras pur chez les mammifères.....	193
Figure A.4. Spectre d'absorbance d'une viande de bœuf.	194
Figure B.1. Montage utilisé pour l'acquisition d'images.	195
Figure B.2. Image visible d'un échantillon de viande.	196
Figure B.3. Image proche infrarouge d'un échantillon de viande.	197
Figure C.1. Illustration par imagerie d'ultrasons du dépôt du persillage chez les porcs....	199
Figure C.2. Illustrations macroscopique et microscopique d'une coupe transversale.....	200
Figure C.3. Illustration d'un exemple de différentes catégories de persillage	201

Nomenclature

Afin d'éviter les redondances des définitions mathématiques, des nomenclatures cohérentes ont été adoptées tout au long de la thèse. Les principales nomenclatures qui sont utilisées sont énumérées ci-dessous. Aussi, d'autres nomenclatures sont parfois utilisées dans le texte. Chaque fois qu'une nouvelle nomenclature est utilisée elle sera ainsi définie.

Abréviation	Signification (définition)
c	Centre de classe
E	Entropie
FCE	First Class Extraction
h	Histogramme
H	Homogénéité
NIR	Proche Infrarouge (<i>Near Infrared</i>)
I	Image
i	Intensité de pixel
L	Intensité maximale dans l'image (Luminance)
λ	Longueur d'onde
μ	Moyenne
N	Nombre de pixels dans l'image
P	Pixel
ROI	Région d'intérêt (<i>Region Of Interest</i>)
R_i	Région numéro i, i entier
σ	Écart type
t	Seuil (<i>threshold</i>)
X,Y	Dimensions de l'image (Largeur, Hauteur)
Imagette	Une image de petite taille (petite fenêtre d'une image)
Face 1	Face de dessus de l'échantillon de viande
Face 2	Face de dessous de l'échantillon de viande
Non destructive	Signifie que l'échantillon de viande ne sera pas endommagé en cas de mesure expérimentale selon les normes sanitaires des aliments (ex : la salubrité).

Chapitre 1

Introduction

Dans le domaine de la vision par ordinateur, l'emploi des systèmes de vision artificielle (machine vision) comme une solution pour accomplir certaines tâches dans plusieurs applications a suscité beaucoup d'intérêt dans la communauté scientifique au cours de ces dernières années. Les méthodes et approches issues de ce domaine de recherche n'ont pas cessé de s'imposer comme étant une solution affirmative et alternative à l'intervention humaine dans plusieurs applications telles que la médecine, la surveillance et le contrôle de qualité en industrie [1]. L'objectif principal réside dans l'analyse et l'interprétation automatique de l'image d'une scène prise par un système d'acquisition d'image (une caméra par exemple), afin de réaliser certaines tâches. On peut citer, entre autre, la reconnaissance d'une cible bien spécifique au niveau de l'image. En pratique, cette application se réalise par un système de vision artificielle. Un tel système est souvent composé de quatre modules : (1) l'acquisition d'image ; (2) la segmentation d'image ; (3) l'extraction des caractéristiques ; (4) la reconnaissance et l'interprétation de l'image, ceci souvent pour obtenir des mesure quantitatives. La performance du premier module est souvent liée à la qualité du système d'acquisition d'image utilisé (ex : la caméra) et aux contraintes d'applications telles que la vitesse d'acquisition, l'éclairage, la position du capteur par rapport à la cible, etc. Les performances des autres modules dépendent essentiellement de la complexité de la scène à étudier. Cependant, on ne peut pas garantir une bonne performance d'un système de vision artificielle si la segmentation n'est pas efficace, car les résultats des modules subséquents dépendent de la performance de cette dernière. La segmentation d'image constitue alors une étape cruciale pour la perfection globale d'un système de vision.

Cette thèse porte sur le développement d'une méthode originale destinée à l'évaluation volumétrique non-destructive du persillage (gras intramusculaire) dans la viande du bœuf. Cette nouvelle méthode, qui pourrait être intégrée à un système de vision artificielle, permet d'estimer de manière non-destructive la proportion volumétrique du persillage dans un échantillon de viande de bœuf. Les quatre modules mentionnés ci-dessus, font d'ailleurs l'objet de développement dans cette thèse.

La motivation derrière ce projet de recherche est due d'une part à l'originalité de sa problématique et d'autre part aux défis à relever pour surmonter les difficultés affrontées au cours du développement d'une telle méthode. Cette nouvelle méthode, qui pourrait être intégrée dans un système de vision artificielle (machine vision), est une première expérience pour ce genre d'application. Selon notre recherche bibliographique, aucune méthode semblable n'a été élaborée. Au-delà de l'évaluation quantitative du persillage, la méthode proposée permet aussi d'extraire plusieurs autres informations pertinentes à l'étude de la qualité de la viande, telles que la distribution et l'architecture du persillage réparti à travers l'échantillon de la viande. Le processus chimique, méthode destructive, est la méthode officielle utilisée pour évaluer la quantité volumétrique du persillage dans la viande du bœuf. C'est une méthode destructive, qui prend du temps, est complexe et qui n'offre aucune information sur la distribution du persillage dans la viande. La méthode proposée dans le cadre de nos travaux de recherche est par contre non-destructive, rapide et efficace. Aucun produit chimique n'est utilisé. De plus, la mesure du persillage se fait de façon précise ce qui nous permet d'extraire plusieurs informations supplémentaires telles que la nature de la distribution du persillage dans la viande en surface et en profondeur. Ces avantages sont indispensables pour évaluer la qualité de la viande.

Les originalités qui découlent de ce projet se manifestent au niveau de la technique proposée ainsi qu'au niveau des fondements scientifiques associés pour solutionner ce problème. Par ailleurs, nous allons démontrer dans cette thèse (chapitres 2 et 6), que l'emploi de la lumière proche infrarouge (*Near Infrared*) en mode transmission permet de détecter le persillage non seulement sur la surface comme dans le cas traditionnel d'une image visible [4] mais aussi en profondeur à travers l'échantillon de la viande. De plus, l'emploi d'une seule caméra à la fois dans le spectre visible pour l'image de la surface et

dans le spectre proche infrarouge pour l'image de profondeur du persillage permet d'offrir un système de vision artificielle hybride. L'intégration industrielle de ce système constitue une avancée majeure dans la façon d'effectuer une estimation volumétrique non-destructive du persillage contenu dans un échantillon de viande.

Quant aux difficultés rencontrées pour la mise en œuvre de l'approche développée, on peut citer la segmentation d'images et la reconnaissance du persillage à travers les muscles d'une part ; puis l'estimation de la proportion volumétrique du persillage dans la viande d'une autre part. Pour résoudre le problème de la segmentation, nous avons élaboré une méthode de modélisation de distribution d'intensités des régions homogènes en niveaux de gris. Cette méthode permet la détection des régions les moins (ou les plus) claires dans une image à niveaux de gris. Un des avantages de cet algorithme est la prise en compte de la sensibilité aux faibles variations de l'ombre dans l'image et au bruit des pixels isolés, ce qui cadre bien avec notre application. La généralisation de cet algorithme pour une segmentation appliquée aux images visibles et proche infrarouge pour identifier les régions du persillage a démontré des résultats satisfaisants face aux objectifs attendus. Quant à l'estimation de la proportion volumétrique du persillage dans l'échantillon de la viande, celle-ci a été développée en deux étapes : une catégorisation des régions de persillage en fonction de leurs positions en profondeur et de leurs similarités (régions de surface, régions en correspondance entre les deux faces et régions qui sont à l'intérieur de l'échantillon). Cette catégorisation est suivie par des modélisations géométriques des régions du persillage permettant ainsi d'estimer la proportion volumétrique du persillage dans la totalité de l'échantillon de la viande.

La suite de cette thèse est organisée comme suit :

Dans le deuxième chapitre, nous avons introduit une nouvelle technique d'acquisition d'images destinée à l'estimation volumétrique du persillage dans la viande de bœuf. Nous avons alors mis en évidence les fondements scientifiques associés à cette nouvelle technique. Des études expérimentales sur des échantillons de viande de bœuf sont réalisées afin d'établir une comparaison entre les méthodes traditionnelles proposées en littérature pour la détection du persillage dans la viande et la technique que nous présentons. Nous démontrons également dans ce chapitre les contributions de notre technique en évaluation

quantitative non-destructive de persillage dans la viande de bœuf. Ce chapitre nous révèle également les défis à relever pour solutionner les problèmes à résoudre au cours de nos travaux de recherche. La conclusion de ce chapitre nous guide dans le choix de la méthodologie à suivre pour le développement et la mise en œuvre de la méthode non-destructive proposée.

Au troisième chapitre, les principales méthodes de segmentation d'images ont été examinées dans le cadre d'une revue de la littérature. Ces méthodes ont été regroupées en quatre catégories : (1) la segmentation par classification de pixels ; (2) la segmentation en régions ; (3) la segmentation en contours et (4) la segmentation hybride. Cette revue, met en évidence les avantages et les inconvénients des méthodes de segmentation existantes. À la lumière de cette étude de littérature, nous avons orienté nos travaux de recherche pour le développement d'une méthode de segmentation d'image en régions adéquate pour notre application. Cette méthode permet à la fois la segmentation des images visibles et proches infrarouges, et l'identification directe des régions du persillage dans les deux types d'images (en surface et en dessous de la surface).

Les travaux réalisés au deuxième chapitre ont révélé la nature des images à traiter pour la détection du persillage dans la viande. Pour les deux types d'images visibles et proches infrarouges, les régions du persillage sont de tailles (surfaces) variables allant de minuscule (quelques pixels par région) à plus importantes, de la même manière au point de vue de l'épaisseur des régions. Par conséquent, le contraste en niveaux de gris entre les régions de persillage et les muscles pourrait être considérable dans le cas des grandes régions de persillage et souvent faible dans le cas de petites régions et aussi pour les régions ayant de petites épaisseurs. Dans le cas des images proches infrarouges, les images sont affectées par l'ombre, ainsi que par les régions qui occultent d'autres régions, ce qui pourrait causer une ambiguïté entre les régions du persillage et les zones de muscles affectées par l'ombre. L'ensemble de ces facteurs nous a indiqué les défis à relever pour segmenter les images en régions afin de détecter le persillage. La revue de littérature sur les méthodes de segmentation d'image présentées au troisième chapitre nous a conduit à développer une méthode de segmentation d'images en régions qui s'adapte le mieux possible à notre application. Pour ce faire, dans le chapitre quatre, une méthode efficace de segmentation

permettant d'identifier les régions homogènes les plus claires (ou les moins claires) dans une image à niveaux de gris a été proposée. Cette nouvelle méthode, qui est relativement générale, est basée sur une nouvelle définition métrique, qui est décrite par un modèle mathématique, permettant d'évaluer l'homogénéité des régions en niveaux de gris, elle-même est définie dans le même chapitre. L'implémentation de cette méthode par un algorithme nommé "*First Class Extraction*" (FCE) a démontré que la simplicité conceptuelle de la méthode proposée la rend efficace à la corruption du bruit. De plus, les expériences réalisées sur différentes catégories d'images démontrent la qualité des résultats obtenus.

La généralisation de cette méthode pour la segmentation en régions des images visibles et proches infrarouges de la viande de bœuf a été élaborée au chapitre cinq. À l'issue de cette étape, les régions du persillage en surface et en profondeur de l'échantillon sont identifiées par un processus de reconnaissance. Les résultats de la segmentation obtenus démontrent que cette méthode est satisfaisante face aux objectifs attendus.

Étant donné que la forme volumétrique d'une section de persillage est aléatoire et complexe, et que celle-ci dépend de la façon dont le persillage est déposé entre les fibres musculaires, ce qui est imprévisible même en anatomie animale à notre connaissance, nous avons combiné les résultats de la segmentation de deux types d'images des deux faces de la viande pour estimer le volume du persillage. Ainsi, dans le chapitre six une nouvelle méthode non-destructive d'évaluation volumétrique du persillage dans la viande de bœuf est proposée. Cette méthode a été élaborée en deux étapes : la première consiste en une catégorisation des régions du persillage segmentées en fonction de leurs positions en profondeur (région de la surface, proche de la surface ou de l'intérieur). Ainsi nous avons proposé une méthode de mesure de similarité entre les régions de chaque face qui a permis d'identifier les régions en correspondance entre les deux faces en une nouvelle catégorie. Pour la deuxième étape, nous avons proposé des modélisations géométriques pour chaque catégorie de région du persillage, permettant ainsi l'estimation de la proportion volumétrique du persillage dans la totalité de l'échantillon de la viande. Finalement, le chapitre sept, qui est la conclusion, clôture la thèse.

Les résultats obtenus par la méthode proposée (non-destructive) dans cette thèse pour l'estimation de la proportion volumétrique du persillage dans la viande de bœuf ont été comparés aux résultats obtenus par une méthode chimique (destructive) comme étant vérité-terrain (*gold standard*). Ces résultats démontrent la validité de la méthode proposée.

En terminant, il faut remarquer que notre méthode, même si elle est “non-destructive” empêche cependant la consommation ultérieure de la viande, pour des raisons de manipulation et de salubrité de l'instrumentation employées dans le cadre de cette thèse cela pourrait éventuellement être modifié ultérieurement dans un appareil commercial.

Chapitre 2

Transmission de la lumière proche infrarouge dans la viande de bœuf et évaluation qualitative du persillage en utilisant l'imagerie visible et proche infrarouge

Le persillage (tissu adipeux intramusculaire) dans la viande de bœuf est un critère important pour la détermination de la qualité de la viande, notamment la jutosité, dans le système de classement de la viande de bœuf de l'Agence canadienne de classement du bœuf (ACCB). De plus, le persillage est un facteur essentiel pour l'industrie bovine canadienne afin de mieux satisfaire les demandes des consommateurs [6]. L'ACCB est accréditée par l'Agence canadienne d'inspection des aliments (ACIA) pour fournir les services de classement des carcasses à l'industrie bovine. L'inspection visuelle de la surface de la viande est la manière commune pour l'attribution d'un niveau de classement de qualité de la viande. Cette tâche est accomplie par un expert autorisé qui est le classificateur, appelé en anglais "grader". Dans le système canadien de classement de la qualité de la viande de bœuf, il existe 13 catégories [6] qui sont : le Canada A, Canada AA, Canada AAA, Canada Prime, Canada B1, Canada B2, Canada B3, Canada B4, Canada D1, Canada D2, Canada D3, Canada D4, et le Canada E. Les quatre premières catégories : Canada A/AA/AAA/Prime sont les plus élevés. Aussi, ils représentent 88% de toute la viande classée. Les critères de qualité pour ces quatre catégories sont identiques, avec la seule exception du degré de persillage, ce qui démontre bien l'importance de ce critère dans l'évaluation de la qualité de la viande. Ainsi, pour faire la distinction entre les catégories A, AA, AAA, et Prime, le classificateur évalue le niveau du persillage observé à la surface d'une section de viande de façon subjective. La figure A.1 (voir annexe A) illustre graphiquement ces quatre catégories en fonction du niveau du persillage observé à la surface de la viande. Le tableau A.1 (voir annexe A) décrit les caractéristiques des

catégories de viande bovine au Canada. En général, plus la quantité et la distribution du persillage est uniforme en surface de la viande, meilleure est la qualité. Dans le processus de classement officiel, le persillage est évalué à partir du muscle Longissimus dorsi soit la longe dorsale exposée entre la 12^{ième} et la 13^{ième} côte.

Ces dernières années, plusieurs travaux de recherche ont été proposés afin d'introduire la vision par ordinateur comme un nouvel outil d'évaluation de la qualité de la viande [7]. Dans ces études, cette évaluation est exclusivement fondée sur l'analyse des images visibles de surface de la viande. F. Yoshikawa *et al.* [7] ont proposé un système de classement automatisé du persillage basé sur la segmentation d'image. Dans ce travail, les auteurs évaluent le persillage en termes de quantité et de distribution des régions et des particules de gras en surface. Ainsi, la méthode statistique d'Otsu [9], qui est un algorithme de segmentation, est proposé pour traiter une image de niveaux de gris de la viande de bœuf en régions de persillage et de muscles. Étant donné que la méthode de segmentation est basée uniquement sur des calculs statistiques sur la moyenne et de la variance des pixels, la performance des résultats est sensible au bruit et à la non uniformité de l'exposition de la source d'éclairage. Dans [10], on présente une méthode d'évaluation de la qualité de la viande, basée sur la densité et la distribution du gras dans la région du faux-filet "*rib-eye*". Dans cette méthode, les régions de gras sont identifiées par une méthode de segmentation par analyse de texture. À la lecture de cet article scientifique, il apparaît que la méthode proposée est limitée à des cas particuliers et il n'est pas certain qu'elle puisse être généralisée. Plus récemment, d'autres approches utilisant la lumière à différentes longueurs d'ondes, en particulier, celles du proche infrarouge ont été proposées [11]. Les résultats intéressants issus de ces travaux sont la combinaison de l'information obtenue à partir de chaque longueur d'ondes. Selon notre revue, la conclusion la plus commune de ces travaux est la suivante : en comparaison avec les méthodes traditionnelles utilisant un système de vision visible, la lumière proche infrarouge réfléchi à la surface de la viande contient diverses informations et détails supplémentaires autres que ceux apportés par l'image visible, comme sur les propriétés biochimiques de l'échantillon de la viande à analyser. Par ailleurs, Naganathan *et al.* [13] ont suggéré l'utilisation de l'imagerie hyperspectrale pour prédire la tendreté de la viande de bœuf. Dans ces travaux, les auteurs ont utilisé différentes longueurs d'ondes (400 – 1000 nm) pour analyser les images. Dans [14], une méthode

utilisant un réseau de neurones pour évaluer la qualité de la viande de porc est présentée. Cette méthode, qui emploie un système d'imagerie hyperspectrale, a été utilisée pour classifier la viande, selon sa tendreté, en quatre catégories [14] : RFN (*reddish pink, firm and non-exudative*), PFN (*pale, firm and non-exudative*), PSE (*pale pinkish gray, very soft and exudative*) et RSE (*redish, soft and exudative*). Dans cette approche, la classification est basée sur la couleur et la texture de la viande qui ont été servis en tant que données pour entraîner le réseau de neurones. Faucitano et *al.* [5], ont appliqué une méthode d'analyse d'image pour mesurer les caractéristiques du persillage dans la viande de porc. Dans [15], un système utilisant un spectre de réflectance dans le proche infrarouge pour prédire la tendreté de la viande est proposé. Dans ce travail, un spectromètre est utilisé pour collecter la lumière dans le visible et le proche infrarouge (400 – 2500 nm). Il n'y a pas d'analyse d'image dans cette dernière méthode, les résultats sont interprétés statistiquement à partir des données spectrométriques.

Cette revue, qui présente l'essentiel des travaux récents dans ce domaine, démontre que l'utilisation de la lumière proche infrarouge pour analyser la viande est une approche intéressante pour mieux caractériser certaines propriétés de la viande et de sa qualité. Par ailleurs, nous allons démontrer dans les sections suivantes (2.1 et 2.2) que la lumière proche infrarouge (850 à 950 nm) est profondément pénétrante dans la viande de bœuf, en comparaison avec la lumière visible (380-720 nm). De plus, l'utilisation de celle-ci en mode transmission, permet d'extraire de l'information sur la structure interne de la viande telle que l'architecture dans laquelle le persillage est déposé, ce qui n'est pas possible dans un système utilisant le visible. De plus, à notre connaissance, aucune publication scientifique n'existe sur l'utilisation de la lumière proche infrarouge en mode transmission pour l'évaluation ou l'étude du dépôt de persillage intramusculaire.

2.1. Technique proposée

Dans le spectre du rayonnement électromagnétique, la lumière proche infrarouge se situe approximativement entre 720 et 2500 nm [16]. Au point de vue perception, dans ce domaine, l'œil humain est insensible à ces rayonnements. La lumière proche infrarouge est

la plus proche, en terme de la longueur d'onde, de la lumière visible comme le montre la figure 2.1.



Figure 2.1. Spectre de la lumière.

La lumière proche infrarouge fournit une réponse spectrale assurant des mesures quantitatives dans divers domaines tels que l'agriculture, la médecine, les aliments, les produits pharmaceutiques, et les textiles, pour ne citer que quelques-uns [20]. Dans plusieurs applications comme en médecine, la lumière proche infrarouge est par ailleurs reconnue comme profondément pénétrante dans les tissus biologiques, en comparaison avec la lumière infrarouge ou visible. Par ailleurs, elle rend possible la détection de structures et molécules chimiques situées sous la surface, telles que la myoglobine et l'hémoglobine [22].

La bande proche infrarouge présente une combinaison d'harmoniques spectrales selon les bandes d'absorbance dues principalement à trois liaisons chimiques, à savoir : C-H (graisses, huiles, hydrocarbures), O-H (eau, alcool) et N-H (protéines) [17]. D'autres liaisons chimiques peuvent présenter des bandes harmoniques, mais elles sont généralement trop faibles pour être considérées pour l'analyse d'un mélange complexe tel que les aliments. Il y a beaucoup de chevauchement dans les signaux, c'est donc pour cette raison que les chercheurs travaillant dans la région du proche infrarouge utilisent plusieurs longueurs d'onde pour traiter l'information. Ainsi, la région du proche infrarouge pourrait être subdivisée en trois parties [17]: 1) transfectance (combinaison d'une réflectance, d'une absorbance et d'une transmission), 2) transmission et 3) réflectance.

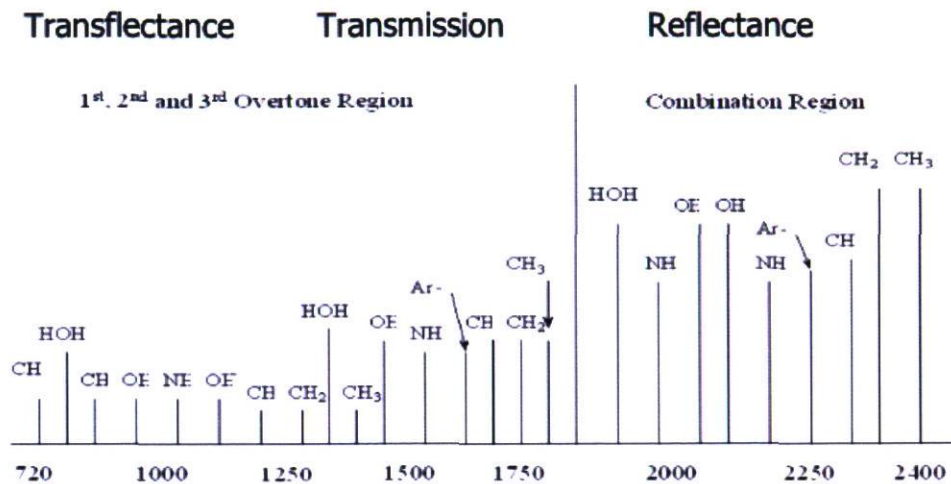


Figure 2.2. Illustration graphique des trois régions proche infrarouge [29].

1. Transflectance : 720 à 1100 nm. Cette section, qui est la combinaison d'une réflectance, absorbance et d'une transmission, est la plus adaptée pour la transflectance à travers les échantillons épais, tels que les semences, les liquides et les pâtes.
2. Transmission : 1100 à 1850 nm. Cette section pourrait être utilisée pour les applications de transmission de la lumière à travers les liquides ainsi que la teneur en eau dans certains échantillons.
3. Réflectance : 1850 à 2500 nm. Cette section est principalement utilisée pour effectuer des mesures de la diffusion de réflectance hors sol ou des matériaux solides. Les bandes d'absorption incluses dans cette région sont dues aux combinaisons des bandes de transflectance et de transmission.

La lumière proche infrarouge est un moyen très intéressant d'analyse dans plusieurs champs d'applications car elle permet de produire de l'information quantitative sur l'application en question. Pour la viande, plusieurs travaux de recherche démontrent que celle-ci est utilisable pour mesurer l'humidité et le persillage [22]. Dans ce contexte, la

région de transfectance est particulièrement intéressante car la lumière proche infrarouge peut facilement pénétrer dans le muscle ou à travers le persillage car elle se réfléchit et se transmet par les particules de gras. La réflexion causée par le persillage dévie le parcours de la lumière, en conséquence ce phénomène pourrait être une source d'information importante sur la distribution du persillage à l'intérieur (invisible) d'un échantillon de viande. La figure 2.3 est une image synthétique qui montre une illustration graphique du mécanisme de transfectance de la lumière proche infrarouge à travers un échantillon de viande.




Figure 2.3. Illustration graphique du mécanisme de transfectance à travers un échantillon de viande.

La figure 2.3 illustre la façon dont la lumière est fortement diffusée (dispersée) et déviée par les particules de gras de la viande à travers l'échantillon avant d'atteindre finalement l'autre côté de l'échantillon. Une faible partie de cette lumière pourrait traverser le tissu sans être interrompue (elle est transmise). Parallèlement à ce processus, une faible partie de la lumière est réfléchie à la surface tandis qu'une autre partie est absorbée. Ainsi, la lumière proche infrarouge se diffuse à travers la viande et se transmet d'un côté à l'autre par un mécanisme de transfectance; lequel est considéré dans cette thèse comme une combinaison d'une réflectance, absorbance et d'une transmission, comme illustré dans la figure 2.3.

Les propriétés combinées de forte diffusion et de faible absorption dans le tissu de la viande permettent à la lumière de pénétrer profondément dans la viande. Nous avons d'ailleurs

expérimenté ce phénomène sur des échantillons de viande de bœuf (*steak*) d'épaisseur allant jusqu'à 15 mm. Ce fait démontre que l'on peut extraire l'information en profondeur sur la structure interne de la viande et ceci de manière non-destructive. La profondeur de pénétration du rayonnement dans la viande dépend sans doute de plusieurs paramètres tels que : la longueur d'onde utilisée, la direction de la diffusion de la lumière et d'une façon générale la qualité technologique du matériel utilisé lors de l'expérimentation.

L'avantage majeur de la technique de transfectance, comparativement à la technique de réflectance (réflexion), vient du fait que le spectre de celle-ci comporte de l'information sur les variations de la structure du persillage sur toute la profondeur de l'échantillon et non seulement à la surface. Avec la réflectance, seule la surface contribue à presque à 100% à la formation du spectre car la lumière réfléchiée à partir de la profondeur de la viande est plutôt faible. Étant donné que la distribution de la matière est non uniforme à la surface de l'échantillon (ex : humidité en surface, gras...etc.), le spectre de réflectance obtenu ne peut représenter l'échantillon au complet.

Ainsi, la transfectance est une technique non-destructive permettant d'obtenir de l'information en profondeur, entre autres, sur le persillage à travers l'échantillon de la viande à inspecter. Dans cette thèse nous avons adopté cette technique pour développer une méthode originale et non-destructive pour estimer la proportion volumétrique du persillage dans un échantillon de viande de bœuf. Autrement, à notre connaissance, l'unique méthode de référence utilisée officiellement jusqu'à maintenant pour évaluer la quantité volumétrique du persillage dans la viande est une méthode chimique qui est destructive.

2.1.1. Étude spectrale (matériel et méthode)

Nous avons démontré dans la section précédente que la lumière proche infrarouge (720 - 2500 nm) est un outil intéressant pour obtenir de l'information sur la structure de dépôt et la dispersion du persillage à travers le tissu musculaire de la viande. Toutefois, la performance de la pénétration de la lumière proche infrarouge en profondeur dépend, entre autres, de la longueur d'onde utilisée. Par exemple, une réponse spectrale à 800 nm n'est pas la même qu'à 900 nm. Par ailleurs, il y a beaucoup de chevauchement (*overlap*) dans

les signaux, c'est pourquoi les chercheurs qui travaillent dans la région du proche infrarouge utilisent plusieurs longueurs d'onde pour optimiser l'information. Dans ce contexte, l'étude des propriétés spectrales de la viande de bœuf (réflexion, absorption et transmission) est essentielle afin de maximiser l'information obtenue sur le contenu de la viande. Pour ce faire, un système d'imagerie hyperspectral a été utilisé pour obtenir les spectres du persillage et du muscle d'un échantillon de viande de bœuf. Ce système [18], est composé de deux spectroscopes d'imageries linéaire (line-scan) visibles et proches infrarouges, couvrant les spectres allant de 400 à 1000 nm pour le visible et allant de 900 à 1700 nm pour le proche infrarouge. En combinant les deux spectres, le système d'imagerie hyperspectral pourrait balayer un large spectre visible-proche infrarouge allant de 400 à 1700 nm.

Le système d'imagerie visible exploré dans cette thèse est composé d'une caméra Hamamatsu C8484-05G d'une résolution de 960x1024 pixels. Celle-ci est couplée à un spectroscope ImSpector V10E de marque Specim Spectral Imaging Ltd. Le système proche infrarouge est composé d'une caméra XEVA-USB-FPA d'une résolution de 256x320 pixels. Celle-ci est couplée avec un spectroscope ImSpector N17E de la même marque que celui du visible. Les deux spectroscopes ayant une fente de taille de 30 μ mX14.3mm. La figure 2.4 illustre le système d'imagerie hyperspectral utilisé.

Pour chaque ligne imagée, "scannée" de l'échantillon de viande, la lumière transmise est dispersée à travers le spectroscope et ainsi captée par une rangée (ligne) du CCD de la caméra. Le balayage de toute l'image forme alors une image spatiale/spectrale comme démontré à la figure 2.4-c.




Figure 2.4. Représentation schématique du système d'imagerie hyperspectral utilisé [18]. (a) système d'imagerie hyperspectral; (b) image spectrale; et (c) profil spectral.

Ainsi, à chaque pixel de la ligne de l'échantillon (ex : un axe spatial x) correspond un spectre de lumière de différentes longueurs d'ondes (ex : un axe spectral λ). La résolution spatiale/spectrale est alors déterminée par la résolution de la caméra. Sur l'échantillon de la viande, les résolutions effectives d'une ligne scannée (line scan) est équivalente à 0,14 mm/pixel pour la résolution spatiale et 0,62 nm/pixel pour la résolution spectrale, ceci pour le système visible. Pour le système proche infrarouge, la résolution est de 0,5 mm/pixel en ce qui concerne la résolution spatiale et de 3,12 nm/pixel pour la résolution spectrale.

Le système hyperspectral balaie l'échantillon ou une partie de l'échantillon en se déplaçant à une vitesse programmée gérée par un système motorisé. Ce dernier est contrôlé par un interface de LabView 8.0 (National Instruments). Ainsi, après le balayage de plusieurs lignes tout au long de l'échantillon (axe y), un cube 3D d'images hyperspectrales est obtenu.

Afin d'avoir des mesures plus réalistes et d'éviter l'effet de la variation de la lumière, le système d'acquisition d'images a été calibré. Pour ce faire, une image noire est obtenue en couvrant la lentille du système avec un couvercle noir et une image blanche est acquise à

partir d'une plaque blanche de calibration (Gigahertz-Optik) ayant une réflectance standard de 99%. Les nouveaux pixels, calibrés, sont calculés selon l'équation 1.

$$r_{xy\lambda} = \frac{i_{xy\lambda} - n_{x\lambda}}{b_{x\lambda} - n_{x\lambda}} \quad (1)$$

où :

- $r_{xy\lambda}$ pixel calibré; $i_{xy\lambda}$ pixel non calibré ; $n_{x\lambda}$ et $b_{x\lambda}$ sont les pixels respectifs des images de calibration noir et blanc.

Ainsi, les réflectances du persillage et du muscle de l'échantillon de la viande du bœuf sont, respectivement, calculés comme une valeur moyenne de la réflectance sur une "Region Of Interest" (ROI) du persillage et du muscle sur tout le cube 3D d'images hyperspectrales obtenu. La figure 2.5 montre les spectres obtenus par le système d'imagerie visible du persillage et du muscle en question.




Figure 2.5. Profils des spectres des régions de pixels de muscle et de persillage d'un échantillon de viande de bœuf.

La figure 2.5 montre que dans la région spectrale visible, les variations des deux spectres de réflectance sont similaires. La présence des pics dans la région 500-600 nm est signalée par les myoglobines, protéines musculaires, qui contiennent des pigments hèmes responsables de la couleur de la viande [22]. Le maximum de réflexion, pour les deux régions du persillage et du muscle, est autour de 750 nm. Toutefois, le meilleur contraste entre les deux régions se situe autour de 700 nm. Ainsi, une caméra visible est un excellent moyen pour la détection du persillage visible à la surface.

Le système d'imagerie visible fournit de l'information de premier choix sur le persillage et le muscle, notamment sur la quantité et la façon dont laquelle le persillage est distribué. Cependant, cette information est limitée à la surface de l'échantillon. Dans cette situation, l'information obtenue par une image visible dépend de l'emplacement de la coupe. Autrement dit, d'une coupe à l'autre, l'information obtenue sur la quantité et/ou la distribution du persillage n'est pas nécessairement la même. Il est donc difficile d'obtenir des détails précis sur le contenu intérieur de la viande en utilisant l'imagerie visible. Ce qui pourrait se faire plus efficacement, comme on le verra dans le domaine spectral du proche infrarouge.

L'étude spectrale présentée dans cette section nous permet de fournir de l'information directe sur la réflectance de la lumière. Toutefois, il est possible d'établir une relation empirique reliant la réflectance et l'absorbance de la lumière par les milieux qu'elle traverse. Selon la loi de Beer-Lambert [20], l'absorption d'un faisceau lumineux monochromatique dans un milieu homogène est proportionnelle à la longueur du trajet optique suivi par ce faisceau et à la concentration molaire du milieu absorbant [20]. La figure 2.6 illustre l'absorption d'un faisceau lumineux par un milieu homogène.




Figure 2.6 Absorption monochromatique selon la loi de Beer-Lambert [21].

La loi de Beer-Lambert pourrait s'exprimer ainsi [20]:

$$A_{\lambda} = -\log_{10} \frac{I_{1\lambda}}{I_{0\lambda}} = \varepsilon_{\lambda} l C \quad (2)$$

où:

- $I_{1\lambda}$ est l'intensité de la lumière incidente et $I_{0\lambda}$ est l'intensité de la lumière sortante;
- $I_{1\lambda} / I_{0\lambda}$ est la transmittance de la solution (sans unité);
- A est l'absorbance à une longueur d'onde λ (sans unité);
- ε est l'absorptivité molaire, exprimée en $\text{L} \cdot \text{mol}^{-1} \cdot \text{cm}^{-1}$. Elle dépend de la longueur d'onde, la nature chimique de l'entité et de la température;
- l est la longueur du trajet optique dans le milieu absorbant (en cm);
- C est la concentration molaire du milieu (en $\text{mol} \cdot \text{L}^{-1}$). Dans le cas d'un gaz, C peut être exprimée comme une densité (unités de longueur réciproque au cube, cm^{-3}).

Ainsi, de l'équation 2, les mesures des réflectances obtenues par le système d'imagerie hyperspectral utilisé (figure 2.4), pourraient être représentées en termes d'absorbance,

lequel est le logarithme décimal de l'inverse de la réflectance mesurée. Ceci est exprimé par l'équation 3.

$$A(\lambda) = \log_{10}\left(\frac{1}{R(\lambda)}\right) \quad (3)$$

où :

- $A(\lambda)$ est l'absorbance; $R(\lambda)$ est la réflectance moyenne sur une ROI de l'image.

Les résultats des deux spectres obtenus par le système d'imagerie hyperspectral (figure 2.4) utilisé sont illustrés à la figure 2.7.

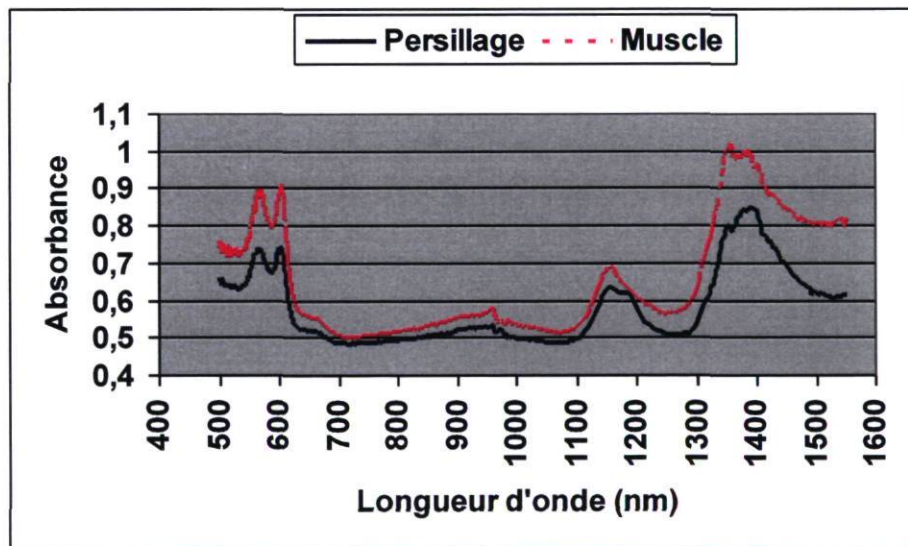


Figure 2.7. Spectres d'absorbance du persillage et du muscle de la viande de bœuf.

L'analyse de la figure 2.7 montre que les variations des deux spectres en fonction de la longueur d'onde ont des allures similaires avec des minimums locaux autour de 700, 800, 1000 et 1300 nm. La présence des pics dans la région de 600 nm est signalée par les

myoglobines [22]. Typiquement, les deux spectres montrent de larges bandes d'absorbances. Les caractéristiques des bandes de l'eau sont observables à différentes régions des longueurs d'ondes du spectre, typiquement autour de 1400-1450 nm [20]. Lorsque le signal tend vers les harmoniques plus hautes (troisième et quatrième harmonique), la puissance du signal en réflexion devient plus faible, c'est pourquoi le spectre d'absorbance est plus fort à 1400-1500 nm. L'eau a une forte absorbance dans le proche infrarouge, approximativement autour de 1450 et 1200 nm tel que cité en [20] et en [21]. Le maximum local situé approximativement à 950 nm est dû en particulier au gras intramusculaire (persillage) [22]. Par ailleurs, dans une étude spectroscopique effectuée sur le gras pur de différentes mammifères [25], celle-ci a démontré que le gras (persillage) a un fort signal d'absorbance à 930 nm (figure A.3 de l'annexe A). Aussi, selon [26], dans cette région, le persillage contribue d'avantage à l'absorption de la lumière. Les figures A.2, A.3 et A.4 de l'annexe A illustrent quelques résultats des spectres de la viande obtenus dans diverses études. Ainsi, la distribution et l'architecture (la forme) dont le persillage est déposé à travers l'échantillon de la viande affectent le chemin de la pénétration de la lumière dans les muscles. Cela se traduit souvent par des variations significatives du spectre. Ainsi, la lumière proche infrarouge est un indicateur de distribution du persillage à travers l'échantillon de la viande.

Contrairement à la diminution évidente de l'intensité spectrale dans la région visible, il y a une augmentation considérable dans le spectre proche infrarouge. Par conséquent, la spectroscopie visible semble être utile pour la caractérisation de la couleur de la viande (caractérisation de surface). Alors que le spectre proche infrarouge révèle des informations complémentaires à celles révélées par le spectre visible, telle que la distribution du persillage à travers la totalité de l'échantillon de la viande ce qui pourrait conduire à l'estimation volumétrique de la quantité du persillage dans l'échantillon de la viande.

2.1.2. Approche proposée




Figure 2.8. Dispositif expérimental de l'approche proposée.
(a) dispositif expérimental ; (b) représentation schématique du mécanisme de transfectance de la lumière proche infrarouge à travers la viande.

La figure 2.8-(b) montre le mécanisme de transfectance de la lumière proche infrarouge à travers l'échantillon de la viande. Au moment où la lumière pénètre l'échantillon, une partie du rayonnement est réfléchi et/ou déviée par les particules de gras à travers l'échantillon de viande pour atteindre finalement l'autre côté. Une partie des rayonnements est absorbée et/ou réfléchi en rebroussant chemin.

Un des objectifs de ce travail est de démontrer l'intérêt de l'application de la lumière proche infrarouge en mode de transmission pour l'évaluation volumétrique du persillage dans la viande de bœuf. Pour ce faire, un système de vision artificielle hybride a été conçu. La figure 2.8-(a) illustre le montage du système proposé. Celui-ci est composé de quatre éléments :

1. une caméra CCD de marque Phoenix (MuTech Corporation) avec une résolution de 1280x1024 pixels, munie d'une connexion USB servant à transférer l'image à l'ordinateur;
2. un dispositif pour placer l'échantillon de la viande devant la caméra, ce dernier est composé de deux plaques de plexiglas, une en bas comme support de l'échantillon et l'autre en haut comme diffuseur du rayonnement vers une direction privilégiée. Le fondement scientifique de cette dernière est que celle-ci oriente la surface de la viande parallèlement au CCD de la caméra. Ce qui permet de maximiser la réflexion de la viande et d'avoir ainsi une surface beaucoup plus spéculaire (diffusion des rayons lumineux vers une seule direction). Étant donné qu'il est difficile d'avoir un échantillon de viande d'épaisseur uniforme, les deux plaques de plexiglas sont attachées l'une à l'autre, par des vis, pour avoir une épaisseur plus uniforme que possible, permettant ainsi d'améliorer la qualité des images obtenues. La contribution du diffuseur en plexiglas placé au dessus de l'échantillon est particulièrement intéressante grâce à la technique développée. La figure 2.12 (section 2.3) démontre l'amélioration de l'apparence de l'image apportée par le diffuseur en question.
3. un diffuseur de lumière proche infrarouge pour assurer un éclairage uniforme; et
4. une source de lumière proche infrarouge.

Au cours des expérimentations, deux types de sources de lumières d'éclairage ont été utilisées: pour l'acquisition des images visibles (mode réflexion), l'éclairage fluorescent du laboratoire placé au plafond a été utilisé. Ceci assure à la fois un éclairage uniforme et une perception naturelle de la surface de l'échantillon. Cependant, pour l'acquisition des images

proches infrarouges (mode transmission), plusieurs sources de différentes longueurs d'ondes ont été utilisées. Toutefois, compte tenu de la forte absorption du persillage dans la zone de 900-1000 nm, en particulier proche de 930 nm, un projecteur leds de 940 nm de puissance ajustable par un variateur de courant a été retenu pour les étapes subséquentes de ces travaux de recherche. Celui-ci a été jugé comme source optimale disponible pour nos expériences. Finalement, afin d'utiliser la même caméra pour les deux types d'acquisition, le filtre proche infrarouge de celle-ci a été enlevé. Cette stratégie permet d'avoir l'avantage de conserver la même résolution pour les deux types d'image, visible et proche infrarouge puis d'avoir ainsi un système plus robuste, en particulier lors de la phase de mise en registration¹ d'images (voir figure B.2 et description à l'annexe B).

2.2. Résultats et discussion

Dans ce travail de recherche, la technique développée (section 2) pour la détection du persillage en surface et en profondeur de la viande de bœuf a été validée expérimentalement sur un grand nombre d'échantillons, on dénombre dans notre base de données une centaine d'échantillons. Ces échantillons ont été obtenus sur une longue période de temps (2 ans) à partir des tablettes des magasins spécialisés en boucherie. Ces magasins s'approvisionnent de plusieurs fermes bovines de différentes régions. Ces fermes n'ont pas nécessairement les mêmes races d'animaux ni le même système d'élevage. Ces différentes gestions d'élevage influencent la qualité et la quantité du persillage déposé entre et dans les muscles [28], ce qui nous permet, relativement, de généraliser notre étude (ex : éviter de travailler sur une seule race d'animal). Nos expériences ont été réalisées sur des échantillons de différentes épaisseurs allant de 5 à 10 mm. La figure 2.9 est un exemple représentatif qui illustre les résultats obtenus avec deux types d'éclairage : visible et proche infrarouge (projecteur leds de longueur d'onde 850 nm et de 940 nm). Ces résultats permettent d'évaluer, qualitativement, le persillage observé moyennant différentes conditions expérimentales (voir section 2.3). Nous démontrons également, dans les sections suivantes, l'originalité de la technique proposée dans le cadre de ce travail de recherche par rapport aux méthodes traditionnelles.

¹ Mettre en correspondance les pixels de deux faces dans un même système de coordonnées.




Figure 2.9. Détection du persillage dans la viande de bœuf.
(a) image visible ; (b) image proche infrarouge à 850 nm ;
et (c) image proche infrarouge à 940 nm.

L'évaluation visuelle de la figure 2.9 permet la distinction des points suivants:

- Tout le persillage, ou presque, à la surface de l'échantillon de viande est clairement identifiable et ceci pour les trois types d'acquisitions. Dans les images proches infrarouges, le tissu musculaire est plus transparent comparativement au persillage (moins clair), ce qui confirme l'interprétation présentée dans la première section stipulant que la lumière proche infrarouge est réfléchiée par le persillage pour finalement être transmise par un mécanisme de transfectance à travers l'échantillon de la viande (Figure 2.3).
- Contrairement au persillage, le tissu musculaire absorbe plus de lumière, ce qui se traduit par des régions claires pour le muscle et des régions moins claires pour le persillage. Le persillage est tout simplement observable à partir de son ombre;

- Les images proches infrarouges montrent plus de détails par rapport à l'image visible. Par exemple, dans les zones identifiées par des cercles, le persillage en dessous de la surface est détecté ce qui n'est pas possible avec l'image visible. D'une façon générale, on observe que la taille du persillage présenté par l'image proche infrarouge est souvent plus large par rapport au même persillage observé sur une image visible;
- En comparant les deux images proches infrarouges, on constate que le contraste et le degré d'apparence (pour un observateur) du persillage sont meilleurs dans l'image (c) par rapport à l'image (b);
- Les images proches infrarouges sont affectées par l'éclairage, il doit donc être maintenu constant. Ce problème, qui est un inconvénient majeur dans ce projet, est dû en particulier à deux phénomènes : premièrement, l'épaisseur de la viande qui n'est pas uniforme sur tout l'échantillon; et deuxièmement, la distribution volumétrique de la quantité du persillage déposé à travers les muscle n'est pas la même (non-uniforme) partout dans l'échantillon;
- Quantitativement, la fonction de densité de probabilité des intensités de pixels des images (a), (b) et (c) de la figure 2.9 nous révèlent d'autres informations pertinentes (Figure 2.10).

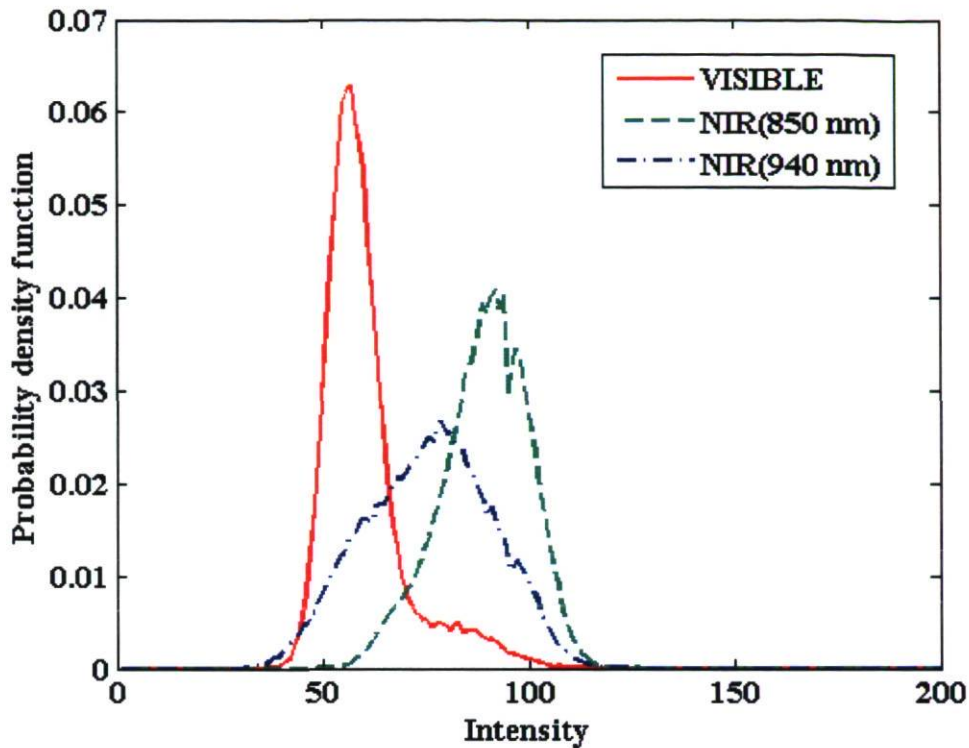


Figure 2.10. Fonctions de densité de probabilités des intensités de pixels.
(cas des images de la figure 2.9).

La figure 2.10 montre différentes caractéristiques entre les trois courbes et en particulier :

- Les spectres de variation des intensités de pixels pour les deux images proches infrarouges sont plus larges par rapport au spectre de l'image visible. Ceci pourrait se traduire par le fait que l'information contenue ou délivrée par les images proches infrarouges est plus importante que celle de l'image visible. En considérant que l'image est une source d'information, l'entropie E de Shannon s'exprime comme suit :

$$E = -\sum_i P_i \log_2 P_i \quad (4)$$

où :

- P_i est la probabilité du niveau de gris i .

Le calcul d'entropie de chaque image donne le résultat suivant : l'entropie de l'image visible est de 3,50; celles des images proches infrarouges (850 et 940 nm) sont respectivement 3,75 et 4,12. Ce qui donne une différence significative entre l'entropie de l'image visible et celle des proches infrarouges. Celle-ci montre qu'effectivement l'image proche infrarouge est porteuse de plus d'information que l'image visible.

- Dans les deux courbes de densité de probabilités des intensités de pixels des images proches infrarouges, on observe une vallée qui pourrait partager (diviser) les pixels en deux groupes : les claires sont les muscles et les noirs représentent le persillage. Dans les deux courbes, le partage créé par les vallées ne sont pas les mêmes pour les deux images, ceci pourrait s'expliquer par la différence de contraste entre les deux images proches infrarouges. On pourra d'ailleurs observer (qualitativement) que le contraste du persillage dans l'image (c) est meilleur que celui de l'image (b). Ceci démontre que l'utilisation de la lumière proche infrarouge à 940 nm (plus loin du visible), par opposition à une lumière de 850 nm (proche du visible) facilite la détection du persillage, ce qui démontre d'une autre façon l'avantage de la lumière proche infrarouge pour cette application.
- Les deux images proches infrarouges sont plus bruitées par rapport à l'image visible. Ceci est causé en partie par la qualité de la caméra utilisée qui est moins sensible à ces longueurs d'ondes.

Ces expériences et interprétations confirment que les images proches infrarouges montrent plus de détails sur le persillage, comparativement à l'image visible, tel qu'illustré à la figure 2.9. De plus, la combinaison multispectrale des trois images de la figure 2.9 fournit une image de couleur représentant la face de la viande. Cette représentation est obtenue de la même façon qu'une représentation dans l'espace de couleur RGB en superposant les trois images de la figure 2.9 et en considérant qu'une seule image est une bande. La figure 2.11 montre les images couleurs obtenues des deux faces de l'échantillon de viande.




Figure 2.11. Images couleurs de la face et de la face opposée de l'échantillon.
(l'échantillon qu'à la figure 2.9).

(a) image de face (du dessus); (b) image de la face opposée (du dessous).
A: couleur de la face (a); B: couleur de la face opposée (b).

La figure 2.11 est une image couleur qui illustre simultanément le contenu des trois images (visible et deux proches infrarouges). Du point de vue perception (pour un observateur), il est évident que cette illustration est meilleure que celle présentée par une image à niveau de gris (Figure 2.9). Aussi, en combinant les représentations des deux faces de l'échantillon de la viande (Figure 2.11-c), il devient possible d'établir diverses relations entre les deux faces telle que la continuité entre les régions du persillage. Ceci pourrait contribuer à l'estimation du volume du persillage contenu dans la totalité de l'échantillon de la viande et non seulement en surface comme dans le cas des méthodes traditionnelles. Cette étude est élaborée au chapitre 6.

Ainsi, nos résultats en proche infrarouge démontrent que contrairement aux résultats obtenus avec des images visibles, lesquels se limitent à la détection du persillage à la surface de l'échantillon, qu'il est possible d'étendre la détection du persillage sous la surface. Par ailleurs, la lumière proche infrarouge (720-2500 nm) pénètre dans le tissu assez

profondément, en comparaison avec la lumière visible (380-720 nm). Elle rend ainsi possible la détection de structures situées plus loin de la surface, telles que les structures du persillage. Cependant, l'analyse d'image proche infrarouge s'avère difficile à cause du faible contraste du persillage à travers la viande et de l'effet de diffusion de la lumière à travers celle-ci. Ainsi, la combinaison de deux types d'images visible et proche infrarouge facilite, sans doute, le processus du traitement. Aussi, en combinant les analyses des deux faces de la viande, il sera possible par exemple d'estimer la proportion volumétrique du persillage à travers la viande.

2.3. Diverses configurations de la technique proposée et résultats

Au cours des expérimentations, diverses configurations de la technique proposée ont été examinées afin de surmonter quelques difficultés, telle que l'amélioration de la qualité de l'image proche infrarouge. Ces configurations ont contribué au fondement scientifique ainsi qu'à la configuration optimale de la technique proposée, tel que démontré dans la première section (figure 2.8). La plupart de ces configurations sont associées à des effets physiques tels que le choix et la technique d'éclairage. Quelques configurations essentielles qui ont été validées par plusieurs expériences sont présentées dans cette section.

2.3.1. Effets des diffuseurs




Figure 2.12. Effets des diffuseurs.

(a) image sans diffuseur au-dessus de la surface; (b) image avec diffuseur au-dessus de la surface; et (c) image avec appui partiel du diffuseur au-dessus de la surface.

La figure 2.12 montre trois images visibles de surfaces de viande prises sous différentes configurations. La figure 2.12-a a été prise sans plaque de plexiglas (diffuseur) placée au-dessus de la surface. On pourra constater que cette image est affectée par la réflexion de la lumière qui est due au non planarité de la surface de la viande et à la présence de l'eau à la surface. Ces problèmes ont été réglés par le diffuseur, plaque de plexiglas, placé directement sur l'échantillon à inspecter (figure 2.12-b). De plus, ce diffuseur a, également, deux autres fondements scientifiques associés à l'approche proposée :

1. maximiser la réflexion spectrale du persillage et du muscle en orientant les surfaces de ceux-ci perpendiculairement vis-à-vis le CCD de la caméra; et,
2. évacuer l'eau en surface de l'échantillon, et donc réduire le taux d'absorbance de la lumière proche infrarouge par l'eau.

Comme le montre la figure 2.12-b, la qualité de l'image est alors nettement meilleure visuellement, surtout en ce qui concerne le contraste entre le persillage et le muscle qui est nettement plus élevé que celui de l'image sans diffuseur. La figure 2.12-c illustre un appui partiel du diffuseur sur une pièce de viande.

2.3.2. Effets de l'éclairage sur l'image de surface




Figure 2.13. Effets de l'éclairage sur l'image de surface.
(a) éclairage avec une lumière visible (tube fluorescent);
(b) éclairage avec une lumière proche infrarouge à 850 nm.

La figure 2.13 montre deux images de la même surface de viande prises sous deux différentes conditions d'éclairage (deux éclairages en réflexion). Les deux images nous révèlent, en particulier, ce qui suit :

1. l'appréciation visuelle (contraste) est plus importante dans le cas d'un éclairage avec une lumière visible;
2. étant donné que la lumière proche infrarouge est plus pénétrante dans le tissu que la lumière visible, ceci crée deux phénomènes : d'une part certaines régions du persillage sont perçues comme plus larges dans l'image proche infrarouge que dans l'image visible, et d'autre part le contraste de certaines petites régions de persillage est réduit dans l'image proche infrarouge. Ces deux phénomènes sont identifiés respectivement par des cercles sur la figure 2.13.

L'image proche infrarouge de surface (éclairage en réflexion) ne représente pas ce que l'œil perçoit de la surface de l'échantillon car, apparemment, elle transmet aussi de l'information qui est en-dessous de la surface et non uniquement celle de la surface de la viande à l'instar de l'image visible.

2.3.3. Effets de la longueur d'onde




Figure 2.14. Effets de la longueur d'onde.
(a) image proche infrarouge à 940 nm ; (b) image proche infrarouge à 850 nm; et (c) image à éclairage multi-spectrale.

La figure 2.14 montre trois images proches infrarouges de la même surface d'un échantillon de viande. Les trois images ont été prises avec trois types d'éclairage en mode transmission. Au cours des expérimentations, uniquement l'éclairage présenté dans le montage à la figure 2.8 a été changé. L'analyse qualitative des qualités des images obtenues montre que le meilleur contraste muscle/persillage est illustré à la figure 2.14-a, celle qui correspond à la longueur de 940 nm. Par ailleurs, on pourra observer plus de détails sur cette image par rapport aux deux autres images. Les deux autres images (figure 2.14-b-c) sont relativement comparables au point de vue contraste. Cependant, l'image de la figure 2.14-c est affectée par l'éclairage qui est dû, probablement, au type d'éclairage utilisé (lampe multi-spectrale).

Pour faire une évaluation quantitative du contraste muscle/persillage, le rapport du niveau de gris muscle/persillage a été calculé à partir des trois ROIs montrées à la figure 2.14. Les trois valeurs des trois contrastes obtenus pour les trois images (figures 2.14-a, 2.14-b et 2.14-c) sont respectivement de : 1,15; 1,09; et 1,04. Pour un observateur, ces valeurs sont raisonnablement en cohérence avec l'appréciation visuelle de la qualité des images.

2.3.4. Effets de la réflexion, de l'absorption et de la transmission

Afin d'étudier les effets de la réflexion, de l'absorption et de transmission de la lumière proche infrarouge par le persillage et par les fibres musculaires d'un échantillon de viande de bœuf, nous avons comparé les valeurs des intensités moyennes des pixels transmises uniquement par le persillage et celles transmises uniquement par les muscles, des deux faces. Pour ce faire, dans un premier temps, les régions du persillage ont été segmentées (par notre algorithme présenté au chapitre 5) pour être identifiées. Ceci est illustré dans le cas des images visibles et proches infrarouges (à 940 nm) pour les deux faces d'un échantillon (Figure 2.15). L'épaisseur de l'échantillon est de l'ordre de 6 mm. La figure 2.15 illustre les images des deux faces de l'échantillon. Par ailleurs, on peut remarquer que la segmentation d'image permet d'identifier des régions homogènes de persillage et de muscle.




Figure 2.15. Effet de l'absorbance à partir des images visibles et proches infrarouges.

- (a) image visible face 1; (b) image visible face 2;
- (c) image proche infrarouge à 940 nm face 1;
- (d) image proche infrarouge à 940 nm face 2.

La méthode proposée se résume comme suit :

- à partir des deux images proches infrarouges, calculer la valeur moyenne de tous les pixels observés simultanément (même position de pixel) sur les deux images visibles comme des pixels de persillage;
- à partir des deux images proches infrarouges, calculer la valeur moyenne de tous les pixels observés simultanément (même position de pixel) sur les deux images proches infrarouges comme des pixels de muscle;

Le tableau 2.1 illustre les résultats obtenus pour l'exemple de la figure 2.15. Il montre que les valeurs des intensités moyennes des pixels, transmises uniquement par le persillage des deux faces sont relativement comparables, en particulier pour le cas de persillage. De la même manière pour celles transmises uniquement par les muscles. La différence entre les valeurs trouvées (75 et 72, puis 133 et 141) est expliquée par la non homogénéité de la matière (persillage et muscles) qui affecte la transmission de la lumière.

Tableau 2.1. Intensités moyennes des pixels du persillage et du muscle

Persillage		Muscle	
Face 1	Face 2	Face 1	Face 2
75	72	133	141

2.4. Conclusion

Dans ce chapitre une technique destinée à l'évaluation non-destructive de la proportion du persillage dans la viande de bœuf est proposée. La mise en œuvre de cette nouvelle technique est réalisée par un système de vision artificielle hybride (visible et proche infrarouge). Ce système combine à la fois les avantages de la lumière visible et proche infrarouge sans pour autant partager leurs inconvénients. Compte tenu des caractéristiques biologiques et physiologiques du persillage et du muscle, la lumière proche infrarouge peut pénétrer profondément dans le tissu de la viande. Ainsi, nous avons démontré que l'utilisation de la lumière proche infrarouge en mode transmission par un mécanisme de transfectance permet d'observer et de mesurer le persillage en-dessous de la surface, ce qui n'est pas possible par les systèmes de visions traditionnels. Nous avons par ailleurs expérimenté ce phénomène sur des échantillons de viande de bœuf d'épaisseurs allant jusqu'à 15 mm.

Les propriétés combinées de forte diffusion et de faible absorption dans le tissu de la viande fait du proche infrarouge un rayonnement idéal pour l'étude des caractéristiques

physiologiques du persillage de manière non-destructive. La profondeur de pénétration du rayonnement dans la viande dépend sans doute de plusieurs paramètres tels que : la longueur d'onde utilisée, la puissance, la direction de la diffusion de la lumière et d'une façon générale du matériel utilisé lors de l'expérimentation. Ainsi, étant donné que la région proche infrarouge (1000-2500 nm) est une région de forte absorption d'eau et compte tenu de l'absorption remarquable du persillage dans la région de 900-1000 nm ainsi que la nature du matériel disponible pour les réalisations expérimentales, nous avons privilégié de développer la suite de ces travaux de recherche dans la région du visible et du proche infrarouge, approximativement, allant de 720 à 1000 nm. Un projecteur leds de 940 nm et à puissance ajustable a été ainsi retenu pour les étapes subséquentes de nos travaux de recherche.

L'étude de la technique d'acquisition d'images proposée sous diverses configurations démontre que cette technique est prometteuse pour évaluer le persillage non seulement à la surface de la viande à l'instar des méthodes traditionnelles proposées dans la littérature, mais aussi en profondeur pour avoir une estimation non-destructive de la proportion du persillage contenu dans l'échantillon. En outre, la technique proposée fournit plus de détails sur le persillage et d'une façon générale des informations sur les propriétés biochimiques et des caractéristiques biologiques et physiologiques de la viande de bœuf.

Selon la recherche bibliographique effectuée et au meilleure de notre connaissance, aucune technique ou méthode semblable n'a été élaborée. L'analyse chimique (méthode destructive) est l'unique méthode officielle (« *gold standard* ») utilisée jusqu'à maintenant pour évaluer la proportion du persillage dans la viande du bœuf. C'est une méthode destructive, complexe et elle n'offre aucune information sur la distribution du persillage dans la viande bien que cette distribution soit importante pour le consommateur du point de vue gustatif.

Comme il est difficile d'identifier le persillage par traitement d'image dans le domaine proche infrarouge en raison du faible contraste du persillage et de l'ombre à travers l'échantillon de viande en test, il est intéressant de combiner les images visibles de la surface de la viande et les images proches infrarouges pour cette analyse.

Chapitre 3

Segmentation d'image : approches et problématiques

L'interprétation automatique de l'information visuelle est un domaine de recherche et développement qui suscite de plus en plus l'intérêt des scientifiques dans plusieurs domaines. Dans ce contexte, plusieurs applications telles que la médecine et la reconnaissance automatisée ont été proposées ces dernières décennies. Dans cette thèse, on s'intéresse surtout aux systèmes de vision artificielle. Souvent, ces systèmes sont composés principalement de trois sous-systèmes : (i) lecture ; (ii) interprétation et (iii) action. Le sous-système de lecture contient un système d'éclairage et une caméra, celui de l'interprétation est composé d'un ensemble de logiciels dédiés à l'application désirée (ex. : segmentation d'image et reconnaissance d'objet), et le sous-système d'action est souvent composé d'un système mécanique automatisé. Ce dernier produit des actions, parfois physiques, résultant des interprétations faites par le deuxième sous-système. Dans le cadre de ce travail de recherche, notre intérêt s'est porté entre autre sur le sous-système d'interprétation, plus spécifiquement, sur la segmentation d'image en régions.

Pour une image donnée, la segmentation d'image est un traitement qui consiste à partitionner l'image de la scène en régions distinctes et homogènes et ce, selon un ou plusieurs critères tels que le niveau de gris ou la couleur, la texture, la couleur et la texture en même temps ou tout autre critère spécifié par l'utilisateur. Il s'agit alors de trouver les frontières (les contours) des régions dans la scène selon un ensemble de critères préétablis. L'union des régions segmentées forme bien sûr l'image source.

Soit I une image en niveaux de gris à segmenter en régions $R_1, R_2, R_3, \dots, R_N$, et H une fonction mesurant l'homogénéité d'un ensemble de pixels. Une bonne segmentation devrait respecter les deux conditions suivantes:

$$A. I = \bigcap R_i \text{ et } R_i \cap R_j = \emptyset, \quad \forall i \neq j;$$

et

$$B. H(R_i) = 1, \quad \forall i \text{ et } \quad H(R_i \cap R_j) = 0 \text{ si } R_i \text{ et } R_j \text{ sont adjacentes.}$$

La première condition signifie que la segmentation couvre la totalité de l'image et que les régions segmentées sont spatialement disjointes alors que la deuxième condition signifie que les régions segmentées sont homogènes et disjointes.

Le processus de segmentation de l'image en régions est un domaine qui est à la fois très large et complexe. C'est pour cela que la plupart des méthodes proposées dans la littérature sont valables selon divers critères. Une fois complétée, une telle opération facilite l'analyse et l'interprétation de l'ensemble ou d'une zone d'intérêt de l'image. Citons par exemple la distinction entre les objets et le fond de l'image, la localisation d'une cible d'intérêt, la compréhension d'un phénomène quelconque, etc. Chaque approche proposée dans la littérature est souvent accompagnée d'un ensemble de contraintes qui doivent être respectées pour une utilisation correcte et judicieuse tels que : la nécessité d'un éclairage uniforme, l'absence du vignettage dans l'image, un bon contraste en niveaux de gris entre les régions adjacentes, la connaissance a priori du contenu de la scène de l'image. Cela peut être complexe pour plusieurs applications. Il est en effet parfois difficile de trouver des indices de reconnaissance d'une cible d'intérêt autre que son niveau de gris car la forme et/ou la position, par exemple, sont aléatoires.

Il est donc indispensable de réaliser une ségrégation robuste en niveaux de gris (ou en couleur). Le problème est le suivant : dans le cas où le contraste de la cible dans la scène est élevé, c'est-à-dire que la cible est facilement observable, la ségrégation est alors commode. Dans le cas contraire, la confusion se manifeste entre la cible et les autres éléments de la scène, en particulier lorsque celle-ci est encombrée, ce qui résulte en une ségrégation ardue

et souvent inefficace. Ces observations démontrent clairement l'ampleur des difficultés rencontrées par la communauté scientifique dans ce domaine de recherche et la difficulté de proposer une méthode de segmentation générique : les méthodes proposées sont souvent spécifiques à une application particulière.

Dans la littérature (à la section suivante seront données les références pertinentes), il existe plusieurs méthodes de segmentation d'images. Selon la technique employée, ces méthodes pourraient être regroupées en quatre catégories : (1) segmentation d'image par classification de pixels; (2) segmentation d'image en régions; (3) segmentation d'image en contours et (4) segmentation d'image hybride. Chacune de ces quatre catégories possède ses avantages propres et se heurte, en même temps, à plusieurs difficultés. Aucune méthode n'offre de solution globale et satisfaisante pour la segmentation d'image.

La suite de ce chapitre est organisée comme suit : d'abord une revue de littérature des quatre catégories de méthodes de segmentation mentionnées plus haut est présentée. Des résultats de quelques exemples de segmentation d'images sont illustrés en application de ces méthodes. Cette étape nous guidera dans la stratégie à adopter pour la résolution du problème de la segmentation rencontré dans cette thèse et ainsi proposer une méthode de segmentation qui s'adapte mieux à notre application. À savoir, la segmentation d'images visible et proche infrarouge appliquée à la détection du persillage dans la viande de bœuf. Les différentes méthodes d'évaluation de la qualité des résultats de la segmentation seront discutées par la suite. Finalement, une conclusion décrivant les perspectives des travaux de recherche clôture ce chapitre.

3.1 Segmentation d'image par classification de pixels

3.1.1 Seuillage par l'histogramme de l'image

Le seuillage par histogramme des niveaux de gris de pixels est l'une des méthodes les plus populaires en segmentation d'image. Grâce à sa simplicité et sa rapidité, cette méthode trouve de vastes applications dans divers domaines. Plusieurs stratégies sont utilisées pour effectuer la segmentation [30]. Les stratégies sont souvent semblables: chercher des seuils potentiels à partir de l'histogramme de l'image. Le principe général de ces stratégies est le

suivant : à partir de l'histogramme de l'image, les vallées (minima locaux) dans l'histogramme sont identifiées. À chaque nouvelle vallée correspond une nouvelle classe de niveaux de gris de pixels, ce qui correspond souvent à des régions ou des parties de régions dans l'image. Les positions des vallées représentent les points de seuillage.

L'avantage de cette méthode est qu'elle est à la fois simple et rapide, mais son efficacité est limitée aux cas particuliers. Par exemple, que le contraste entre les régions adjacentes dans l'image soit suffisant pour créer une vallée et qu'il n'y ait pas beaucoup de bruit dans l'image. Le nombre total de classes trouvées sera égal au nombre de vallées plus un.

Le problème majeur de cette méthode est la détection de vallées, surtout dans le cas où l'histogramme est bruité. Dans ce cas, il y a souvent une confusion entre une vallée réelle et une fausse vallée (vallée due au bruit). En conséquence, la détection erronée d'une vallée génère une mauvaise segmentation. Pour pallier à ce problème, l'application d'un filtre de lissage à l'histogramme a été proposée. Toutefois, l'efficacité de cette solution demeure limitée, car le lissage de l'histogramme entraîne parfois la disparition du signal de la vallée. Aussi, dans le cas où la distribution de l'histogramme de l'image est de nature uni-modale (un seul pic, aucune vallée), la détection du seuil s'avère impossible. Prenons l'exemple de deux classes de pixels. Dans le cas où les centres de deux classes sont assez éloignés, la détection de seuil est évidente puisqu'on observe une vallée. Dans le cas contraire, la détection de seuil est non triviale. La figure 3.1 montre une simulation d'un mélange de deux classes de pixels à niveaux de gris construites sous l'hypothèse d'une répartition gaussienne.

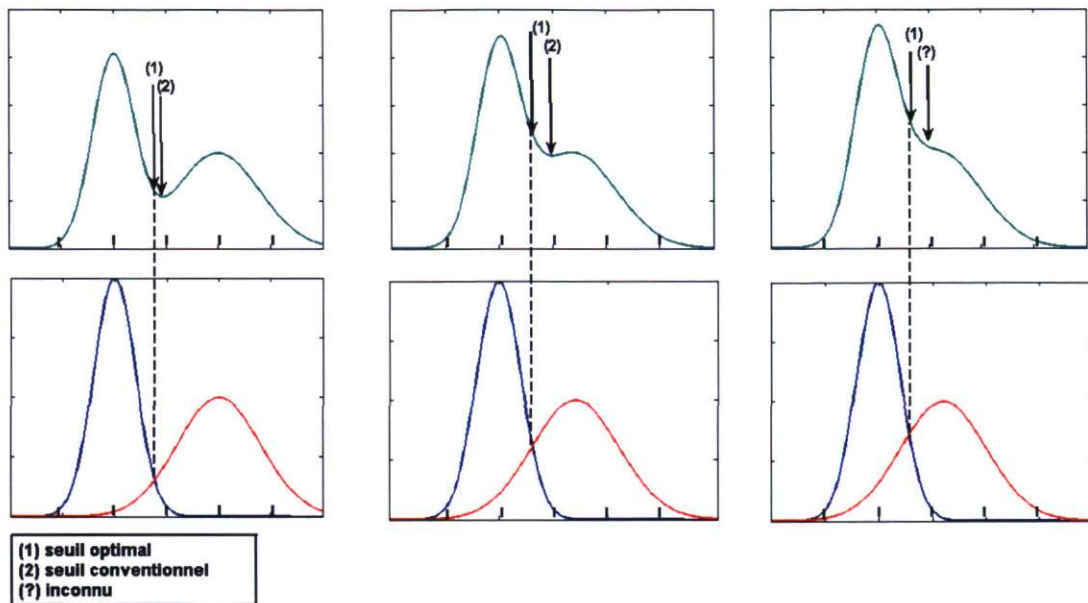


Figure 3.1. Allure de la vallée en fonction des niveaux de gris de deux classes à séparer. (en haut : histogrammes du mélange ; en bas : histogrammes de deux classes).

La figure 3.1 montre que la localisation du seuil ne correspond pas nécessairement au minimum local de l'histogramme (position de la vallée) même dans le cas d'un histogramme bimodal. Il s'agit alors d'une limitation supplémentaire de cette technique de seuillage.

Les images de la figure 3.2 sont un exemple d'images à traiter dans le cadre de ce travail de recherche. Elles illustrent respectivement une image visible et proche infrarouge (940 nm) prises selon la technique d'acquisition proposée au chapitre 2 (figure 2.8). La figure 3.3 illustre les histogrammes des deux images.




Figure 3.2. Images visible et proche infrarouge (940 nm).

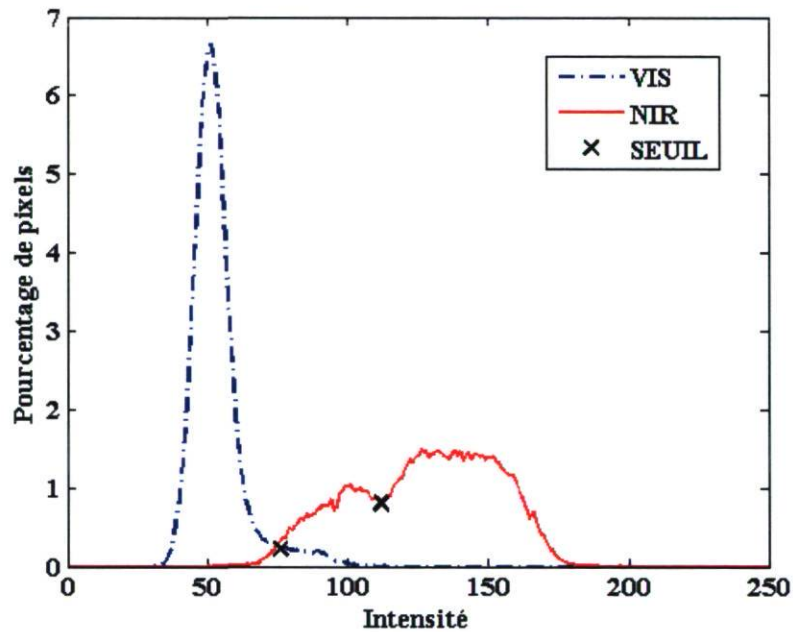


Figure 3.3. Histogrammes des images visible et proche infrarouge.
(cas de la figure 3.2).

L'image de la figure 3.3 illustre les histogrammes de l'image visible et proche infrarouge de la figure 3.2. Il ressort de cette illustration que l'histogramme de l'image visible est presque unimodal (une seule catégorie d'intensités de pixels dominante dans toute l'image).

Ainsi, l'identification d'un seuil n'est pas précis à cause de la continuité rapprochée de niveau de gris entre les pixels. L'histogramme de l'image proche infrarouge est plutôt bimodal mais il est plus affecté par le bruit que celui de l'image visible. Sur chaque histogramme nous avons identifié manuellement un seuil afin de segmenter le persillage, les résultats de ceci n'étaient pas satisfaisants en particulier pour l'image proche infrarouge car celle-ci est affectée par l'ombre causé par les régions du persillage. Dans ces conditions, pour segmenter l'image, il faudrait plusieurs seuils afin de définir les régions du persillage, en plus du post-traitement après le processus de seuillage.

Plusieurs autres techniques ont été proposées dans la littérature pour réaliser un seuillage en utilisant l'histogramme. Tseng *et al.* [33] suggèrent un seuillage par histogramme circulaire "Circular Histogram Thresholding" pour la segmentation d'images couleurs. L'histogramme est d'abord extrait de la transformation teinte (hue, en référence à l'espace couleur IHS [33]). Par la suite, un filtre de lissage est utilisé pour extraire les seuils de l'histogramme.

L'approche proposée dans [34] consiste à fusionner deux par deux les trois bandes de l'espace RGB avant d'extraire les seuils à partir de l'histogramme 2D de chaque paire de bandes. La segmentation se fait alors pour chaque paire de bandes fusionnées. La fusion de trois résultats génère la segmentation finale.

En conclusion, l'histogramme reste toujours un outil fondamental en traitement d'image. Néanmoins, les méthodes de seuillage par histogramme sont souvent employées à cause de leur rapidité algorithmique. Dans la plupart des cas, leurs applications sont conditionnées par plusieurs contraintes ce qui limite leur champ d'application (connaissance à priori de la valeur du seuil, résolution, éclairage, vignettage, etc.). Ces méthodes ont été développées pour traiter des cas simples de segmentation, comme la binarisation (segmentation en deux classes). Leur généralisation à des cas réels ayant une multitude de classes demeure cependant difficile.

3.1.2 Seuillage par classification de pixels

Sans doute, on ne peut pas parler de la segmentation d'images sans faire la discrimination entre les pixels en fonction de leurs niveaux de gris ou couleurs. En effet, l'objectif ultime de la segmentation est le regroupement de pixels en plusieurs classes uniformes et disjointes. Dans la plupart des cas, le niveau de gris d'un pixel est pris comme un critère de discrimination. On distingue deux principales approches de classification : une dont on connaît à l'avance le nombre de classes issues de la segmentation et l'autre dont le nombre de classes est inconnu. Dans les deux cas, la classification est généralement non supervisée; elle est achevée sans aucune connaissance a priori sur les centres de classes. Cette catégorie de classification suit aussi le principe général de la segmentation, c'est-à-dire qu'il n'y a pas d'intersection entre n'importe quelles deux classes et que l'union de l'ensemble de classes reconstruit l'image source.

Plusieurs approches ont été proposées dans la littérature dans le cadre de la segmentation d'images par classification de pixels [7, 8]. La méthode la plus populaire est l'algorithme des nuées dynamiques qui est une généralisation de l'algorithme k-means ou c-means [38], où k fait référence au nombre de classes (ou de régions). Il s'agit d'un algorithme de partition rigide, c'est-à-dire que le degré d'appartenance d'un pixel à une classe (région dans notre cas) est "vrai" ou "faux" soit $\{0, 1\}$. L'algorithme de k-means est largement utilisé dans d'autres applications que la segmentation d'images (ex. : initialisation pour d'autres algorithmes de classification, quantification et compression de données). C'est un algorithme simple et rapide d'exécution, mais vu qu'il est itératif, il devient instable en présence de bruit. Pour remédier à ce problème, une version "floue" de cet algorithme a été proposée : le fuzzy k-means ou le k-means flou [39]. Avec l'utilisation du fuzzy k-means, la partition des pixels n'est plus rigide : le degré d'appartenance d'un pixel à une classe est plutôt variable dans l'intervalle $\{0, 1\}$ (flou) au lieu d'être un élément du couple $\{0, 1\}$. Ce nouveau concept permet de mieux adapter l'algorithme de k-means à l'application désirée sans pour autant résoudre les problèmes d'instabilité lié au bruit. Une autre variante de l'algorithme fuzzy k-means a été introduite par la suite: le "*possibilistic k-means*" [40]. Cet algorithme est un peu plus performant que le fuzzy k-means en présence de bruit, mais engendre un risque d'instabilité ou même de non convergence en cas d'une mauvaise initialisation. C'est pour cette raison, qu'il est recommandé de commencer avec

un fuzzy k-means qui est plus performant à l'initialisation avant d'utiliser le "*possibilistic k-means*". Dans la littérature, l'algorithme "*possibilistic k-means*" n'est pas populaire, c'est plutôt le fuzzy k-means qui est le plus utilisé compte tenu de sa performance combinée avec sa simplicité par rapport aux deux autres algorithmes.

Lors de nos travaux de recherche nous avons appliqué l'algorithme de fuzzy k-means aux images visible et proche infrarouge de la figure 3.2. L'objectif de cette application était de faire une classification entre différentes catégories de pixels de l'image, à savoir entre ceux du persillage et ceux du muscle. Pour ce faire, nous avons utilisé un code MATLAB, puisque l'algorithme de fuzzy k-means est déjà codé (par la fonction `fcm.m`). Cette fonction prend comme paramètre d'entrée le nombre de classes désirées par l'utilisateur. Nous avons constaté lors des tests de classification que pour un petit nombre de classes (ex : 2 pour l'image visible et <5 pour l'image proche infrarouge) les résultats étaient une sous-classification (plusieurs régions de persillage étaient fusionnées aux régions des muscles). Un grand nombre de classes produira une sur-classification (plusieurs régions de même catégorie sont classées différemment). Les figures 3.4 et 3.5 illustrent respectivement les résultats de classification de pixels que nous avons obtenus avec deux tests : à savoir, classification en trois et en cinq classes de pixels par les deux types d'images de la figure 3.2.




Figure 3.4. Classification en trois classes de pixels par l'algorithme de fuzzy k-means. (a) image visible; (b) image proche infrarouge. (chaque couleur représente une catégorie de classe de niveau de gris. Les couleurs ont été choisies arbitrairement à titre représentatif.)




Figure 3.5. Classification en cinq classes de pixels par l'algorithme de fuzzy k-means. (a) image visible; (b) image proche infrarouge. (chaque couleur représente une catégorie de classe de niveau de gris. Les couleurs ont été choisies arbitrairement à titre représentatif.)

Autre que les nuées dynamiques, Otsu [35] a introduit une nouvelle méthode de segmentation d'images par classification de pixels en deux classes. En considérant le fait que l'image soit composée de deux régions : objet et fond (*background and foreground*),

Otsu a introduit une nouvelle méthode qui maximise la variance inter-classe σ_B entre l'objet et l'arrière plan. σ_B est utilisé pour faire un seuillage en deux classes d'une image en niveaux de gris [35].

$$\sigma_B = \omega_0(\mu_0 - \mu)^2 + \omega_1(\mu_1 - \mu)^2 \quad (1)$$

$$\sigma_B = \omega_0\omega_1(\mu_0 - \mu_1)^2 \quad (2)$$

où :

- $\omega_0 = \sum_{i=1}^t p_i$; $\omega_1 = 1 - \omega_0$; $\mu = \omega_0\mu_0 + \omega_1\mu_1$;
- $\mu_0 = \sum_{i=1}^t \frac{i \cdot p_i}{\omega_0}$ et $\mu_1 = \sum_{i=t+1}^L \frac{i \cdot p_i}{\omega_1}$;
- t : seuil ;
- L : niveau de gris maximal dans l'image ;
- p_i : fonction de densité de probabilité des pixels.

Le seuil optimal est obtenu lorsque σ_B atteint son maximum. Il est obtenu d'une façon itérative en faisant varier le seuil t dans l'intervalle $\{1, L\}$. Cette approche donne de bons résultats lorsque les deux classes sont proches en nombre de pixels (équiprobables).

La technique d'Otsu a aussi été utilisée pour faire une segmentation totale de l'image en faisant une recherche exhaustive de tous les seuils possibles. Cependant, elle n'a pas eu beaucoup de succès à cause du nombre exorbitant d'itérations, ce qui n'est pas pratique. La méthode d'Otsu demeure, par ailleurs, l'une des méthodes souvent utilisées en segmentation d'images par seuillage.

La segmentation d'images par une technique de classification de pixels est une tâche assez compliquée, car d'une part la partition des pixels ne tient pas compte des relations de

voisinage lors de formation des classes (des régions) et d'autre part, la plupart des algorithmes ont besoin de paramètres dont le réglage nécessite l'intervention humaine, ce qui ne favorise pas le traitement automatique. De plus, le résultat de la segmentation est dans la plupart des cas une sur-segmentation car le nombre de classes est souvent prédéfini. C'est pour cette raison que l'utilisation de ces algorithmes pour la segmentation est souvent accompagnée par d'autres algorithmes pour améliorer les résultats obtenus de la segmentation initiale.

3.1.3 Méthodes statistiques

Les méthodes statistiques de segmentation d'images sont considérées parmi les méthodes les plus complexes dans ce domaine. Dans ces méthodes, l'image est souvent modélisée avec un modèle statistique caractérisé par un ensemble de paramètres tels que la probabilité, la moyenne et la variance. La tâche la plus complexe est d'estimer ces paramètres ainsi que le nombre de régions.

Les méthodes de segmentation d'images basées sur les champs de Markov [64] sont plutôt considérées comme des méthodes de classification que comme des méthodes de segmentation. La segmentation obtenue est souvent une sur-segmentation ou une sous-segmentation à cause du bruit, des problèmes d'estimations et d'optimisation des paramètres du modèle de segmentation et du nombre prédéterminé de classes des régions. Les méthodes de segmentation d'image par les champs de Markov sont peu utilisées en segmentation d'image en particulier dans les processus nécessitant une exécution rapide de l'algorithme à cause de leur complexité algorithmiques qui implique de très longs temps de calcul.

Parmi les autres méthodes statistiques de segmentation d'images, il y en a une qui est très populaire, c'est celle de l'algorithme "*Expectation Maximisation*" (EM) proposé par Dempster *et al.* [65]. C'est un algorithme de classification non supervisé permettant de trouver, entre autres, le maximum de vraisemblance des paramètres de modèles probabilistes connus. Étant donné que l'image est composée de plusieurs régions, donc de plusieurs classes de niveaux de gris ou de couleurs, celles-ci sont souvent modélisées par

un mélange des distributions gaussiennes. Dans ces cas, l'algorithme EM s'applique bien pour estimer les paramètres du modèle.

Supposons que le nombre K des classes est connu dans le modèle de mélange des gaussiennes. La densité de probabilité de ce mélange est alors définie par [65]:

$$f(X) = \sum_{k=1}^K \pi_k f(x / \theta_k) \quad (3)$$

où :

- π_k est la probabilité a priori de la $k^{\text{ième}}$ gaussienne et $\sum_{j=1}^K \pi_k = 1$;
- $\theta_k = (\mu_k, \sigma_k)$ qui respectivement la moyenne et l'écart-type de la $k^{\text{ième}}$ gaussienne;
- f est la densité de probabilité de chaque gaussienne :

$$f(x / \theta_k) = \frac{1}{\sqrt{(2\pi)^{2d} \det \Sigma_k}} \exp\left(-\frac{1}{2}(x - \mu_k)^T \Sigma_k^{-1} (x - \mu_k)\right) \quad (4)$$

où :

- d est la dimension du modèle (dans le cas d'une image couleur $d = 3$) ;
- μ_k est un vecteur moyen et Σ_k est la matrice de covariance.

$$\mu_k = \begin{pmatrix} \mu_{k1} \\ \mu_{k2} \\ \vdots \\ \mu_{kd} \end{pmatrix} ; \quad \Sigma_k = \begin{pmatrix} \sigma_{11}^2 & \dots & \sigma_{1d}^2 \\ \sigma_{21}^2 & \dots & \sigma_{2d}^2 \\ \vdots & & \vdots \\ \sigma_{kd}^2 & \dots & \sigma_{dd}^2 \end{pmatrix}.$$

Les paramètres du mélange gaussien définis dans l'équation (4) sont ainsi estimés par l'algorithme EM en maximisant le critère de log-vraisemblance [65]. L'algorithme EM est itératif, il nécessite l'initialisation des paramètres du mélange et le nombre K de ce mélange

qui définit le nombre de régions dans l'image. Ce nombre est souvent déterminé en se basant sur des connaissances a priori, ainsi les probabilités a priori sont initialisées d'une façon équiprobable ($\pi_k = 1/K$), la matrice de covariance est initialisée par la matrice identité, et finalement le vecteur moyen est initialisé par les centres des gaussiennes qui sont souvent estimés par un nuée dynamique tel que le k-means.

L'algorithme EM est itératif, il est composé de deux étapes :

- Étape E, "Expectation", de prédiction;

Dans cette étape on estime les probabilités $t_k^m(x_i)$ du pixel x_i qui appartient à la classe k de la $m^{\text{ième}}$ itération.

$$t_k^m(x_i) = \frac{\pi_k^m f(x_i / \theta_k^m)}{\sum_{k=1}^K \pi_k^m f(x_i / \theta_k^m)} \quad (5)$$

- Étape M, "Maximisation", qui est la mise à jour des paramètres.

On recalcule pour l'itération $m+1$, les probabilités a priori, les moyennes et la matrice de covariances de chaque gaussienne (ou classe) comme suit [71]:

$$\pi_k^{m+1} = \frac{1}{N} \sum_{i=1}^N t_k^m(x_i) \quad (6)$$

$$\mu_k^{m+1} = \frac{\sum_{i=1}^N x_i t_k^m(x_i)}{\sum_{i=1}^N t_k^m(x_i)} \quad (7)$$

$$\sum_k^{m+1} = \frac{\sum_{i=1}^N t_k^m(x_i)(x_i + \mu_k^{m+1})(x_i - \mu_k^{m+1})^T}{\sum_{i=1}^N t_k^m(x_i)} \quad (8)$$

Ainsi, l'algorithme EM itère tant que ces variables (mises à jour) changent significativement. Pour se faire, une solution consiste à calculer la log-vraisemblance définie dans l'équation (9) pour chaque itération. La valeur de la log-vraisemblance augmente d'une itération à l'autre, une fois que celle-ci se stabilise ou augmente avec une valeur très minime (ex : <1%), l'algorithme EM converge alors. Cette technique est connue dans la littérature sous le nom du maximum de vraisemblance (*Maximum Likelihood (ML)*) [71]:

$$\log(L) = \log\left(\prod_{k=1}^N f(x)\right) \quad (9)$$

Une fois que l'algorithme EM a convergé, on applique la règle de Bayes qui attribue à chaque pixel x_i une étiquette correspondant à la classe k , parmi les K classes, à qui il appartient. Ceci se traduit par la valeur de la probabilité a posteriori du pixel x_i qui appartient à la classe k . La règle de Bayes s'applique comme suit [71]:

$$k(x_i) = \text{Arg}[\max\{\pi f(x_i / \theta_k)\}] \text{ avec } 1 \leq k \leq K \quad (10)$$

L'algorithme EM produit des résultats satisfaisants, mais à condition que le nombre de régions K soit optimal, que l'initialisation des paramètres du mélange soit bonne et que le contraste entre les régions adjacentes ne soit pas trop faible, ce qui n'est pas le cas dans le

monde réel. Dans le cas où l'image est affectée par le bruit ou le non uniformité de l'éclairage, la performance de l'algorithme EM est considérablement réduite. Nous avons appliqué l'algorithme EM sur les images visible et proche infrarouge de la figure 3.2 pour classifier les pixels à l'instar de la classification réalisée par l'algorithme de fuzzy k-means. Les figures 3.6 et 3.7 illustrent respectivement les résultats de classification de pixels que nous avons obtenus avec deux tests : à savoir, classification en trois et en cinq classes des pixels de deux types d'images de la figure 3.2.




Figure 3.6. Classification en trois classes de pixels par l'algorithme de EM.
(a) image visible; (b) image proche infrarouge.
(chaque couleur représente une catégorie de classe de niveau de gris. Les couleurs ont été choisies arbitrairement à titre représentatif.)




Figure 3.7. Classification en cinq classes de pixels par l'algorithme d'EM.
 (a) image visible; (b) image proche infrarouge.
 (chaque couleur représente une catégorie de classe de niveau de gris. Les couleurs ont été choisies arbitrairement à titre représentatif.)

Les figures 3.6 et 3.7 démontrent que les résultats de segmentation dépendent du nombre de classes choisi et que ces résultats nécessitent des traitements additionnelles afin de réduire le bruit et d'améliorer la qualité de la segmentation (ex : réduire la sous-segmentation dans le cas de l'image proche infrarouge).

3.1.4 Seuillage entropique (*Entropy Thresholding*)

Le seuillage entropique est une technique de classification qui est introduite pour la segmentation d'image. Elle est dérivée de la théorie de l'information, spécifiquement de l'entropie de Shannon [41] :

Soit une variable aléatoire $X = \{x_1, x_2, x_3, x_4, x_5, \dots, x_n\}$. Shannon définit son entropie E comme étant l'information contenue dans la variable aléatoire X [41] :

$$E = - \sum_{i=1}^n p(x_i) \log_2 p(x_i) \quad (11)$$

où :

- $p(x_i) = P_r(X = x_i)$ est la probabilité de la $i^{\text{ème}}$ réalisation de X .

En considérant l'histogramme de l'image comme une fonction de densité de probabilité, les seuils sont déterminés de manière à ce que l'entropie E , résultante du découpage de l'histogramme en plusieurs classes, soit maximale. L'entropie mesure la quantité d'information contenue dans un groupe (ou une classe). Pour un seuil fixe, on cherche à obtenir que le groupe (la classe) résultant du seuillage porte le maximum d'information. Autrement dit, que son entropie E est maximale. Plusieurs techniques de seuillage inspirées de l'entropie ont été proposées dans la littérature [41]. Ces techniques utilisent d'une façon à une autre le concept de l'entropie de Shannon. Ainsi, pour une image à niveaux de gris, la probabilité de distribution de l'image entière a été considérée comme la somme de deux probabilités de distribution : une pour l'objet (*foreground*) et l'autre pour le fond (*background*). Le seuil optimal de seuillage est obtenu lorsque la somme individuelle de deux entropies est maximale.

L'entropie croisée (*cross-entropy*) a également été rapportée dans la littérature [45]. Il s'agit de minimiser l'entropie totale de l'image (objet et fond) pour trouver le seuil optimal du seuillage. Ce concept est basé sur une mesure théorique de distance entre deux distributions de probabilité : $P = \{p_1, p_2, p_3, \dots, p_N\}$ et $Q = \{q_1, q_2, q_3, \dots, q_N\}$. Cette mesure est la distance de Kullback-Leibler [45], qui est définie comme suit :

$$D(Q, P) = \sum_{k=1}^N q_k \log \frac{q_k}{p_k} \quad (12)$$

La distance de Kullback est alors interprétée comme étant une mesure théorique de l'information entre deux distributions de probabilité P et Q .

Étant donné que l'entropie croisée est une mesure permettant de quantifier la distance, et donc le degré de ressemblance (ou de dissemblance) entre deux distributions de probabilités, celle-ci est alors utilisée pour mesurer le degré de dissemblance entre l'image observée et l'image seuillée pour obtenir le seuil optimal. En application de l'équation (12), Li *et al.* [45] ont démontré que pour un seuillage d'une image I en deux classes A et B (objet et fond), le seuil optimal est déterminé par la minimisation de l'expression suivante :

$$\eta(t) = \sum_{p \leq t} p \cdot \log\left(\frac{p}{\mu_1}\right) + \sum_{p \geq t} p \cdot \log\left(\frac{p}{\mu_2}\right) \quad (13)$$

où :

- p : valeur du pixel;
- t : seuil;
- μ_1 et μ_2 sont respectivement les moyennes des pixels inférieurs et supérieurs à t .

L'entropie floue (*fuzzy entropy*) est une autre technique employée pour segmenter l'image en régions et est utilisée comme un filtre de lissage de l'histogramme. Un tel lissage facilite la détection des centres de classes et/ou de seuils. L'application de l'entropie floue est souvent accomplie par une fonction caractéristique (*membership function*) qui mesure le degré d'appartenance d'un pixel x de l'image I à une catégorie quelconque. La fonction standard "*S-function*" est typiquement choisie à cet égard [41]. Sa forme générale est définie comme suit [41]:

$$\mu(x) = S(x, a, b, c) = \begin{cases} 0, & x \leq a \\ k(x - a / c - a)^2, & a \leq x \leq b \\ 1 - k(x - c / c - a)^2, & b \leq x \leq c \\ 1, & x \geq c \end{cases} \quad (14)$$

où :

- x est le niveau de gris de pixel ;
- $b = (a+c)/2$;
- $[a, c]$ définit la région floue de largeur de bande $\Delta b = b - a = c - b$;

- $k = 2$.

$\mu(x)$ représente le degré de luminosité (brightness) de x . Ainsi, en notation floue, l'image I pourrait être exprimée de la manière suivante : $I = \{(x, \mu(x))\}$.

L'entropie floue de l'image I est calculée de la manière suivante [41]:

$$E_f(I) = \frac{1}{XY \log 2} \sum_{m=1}^X \sum_{n=1}^Y S_n(\mu(x)) = \frac{1}{XY \log 2} \sum_{i=1}^N S_n(\mu(x)) h(i) \quad (15)$$

S_n est la fonction de Shannon (équation 11) appliquée pour $n = 2$.

$$S_n(x) = -\mu(x) \log \mu(x) - (1-\mu(x)) \log (1-\mu(x)), \quad 0 < x < n-1 \quad (16)$$

Le résultat de l'application de l'équation (15) à l'histogramme de la courbe d'histogramme de l'image proche infrarouge (figure 3.2-b) est illustré dans la figure 3.8.

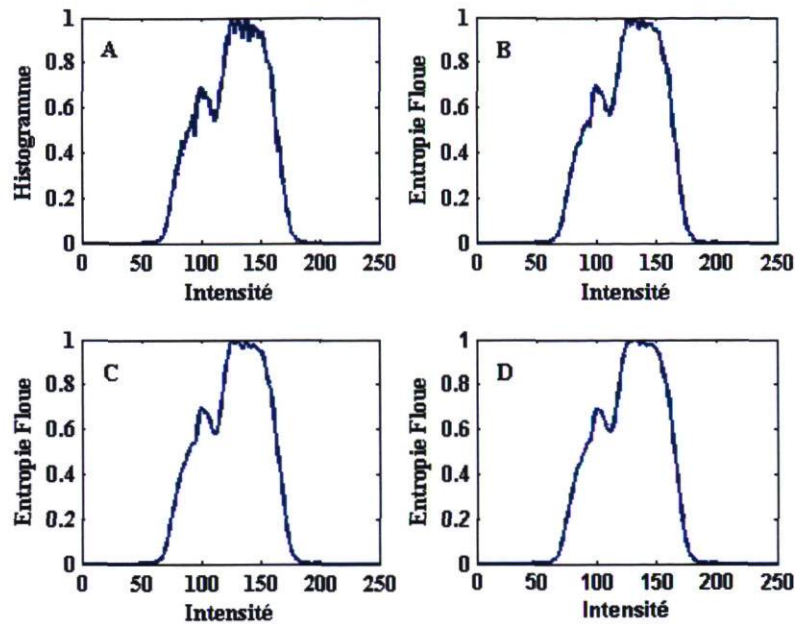


Figure 3.8. Entropie floue appliquée à la courbe d'histogramme.
(cas de l'image proche infrarouge, figure 3.2).

A : courbe d'histogramme; B : entropie floue ($\Delta b = 2$);

C : entropie floue ($\Delta b = 3$); D : entropie floue ($\Delta b = 4$).

La figure 3.8 illustre la courbe de l'histogramme de l'image proche infrarouge (figure 3.2-b) et les résultats de l'entropie floue appliquée au même histogramme avec trois largeurs différentes. La figure 3.8 montre que plus la largeur de bande est grande plus la courbe de l'histogramme est lissée. Selon nos expérimentations réalisées sur plusieurs courbes d'histogrammes de différents types d'images, une valeur de Δb égale à 3 est un bon compromis entre le lissage de la courbe en question et la conservation de l'information.

Plusieurs autres techniques de seuillage inspirées de l'entropie ont été proposées dans la littérature. En effet, Althouse et Chang [48] ont comparé deux types d'entropie : l'entropie locale et l'entropie relative. Dans leurs expériences, ils ont montré que l'entropie locale fournit plus de détails que l'entropie relative. Dans [49], le Fuzzy entropie est utilisée pour une segmentation initiale d'image couleur dans l'espace RGB. Toutefois, chaque bande de couleur est traitée d'une façon individuelle.

D'une façon générale, la segmentation par seuillage entropique a été proposée pour la segmentation des images à niveaux de gris. Spécifiquement, un seul seuil est choisi pour découper la scène en deux régions : objet et fond (en théorie de l'information, on parle de deux sources d'information). Dans ce cas, la qualité de l'image résultante de la segmentation est moins bonne que celle obtenue par une autre technique de seuillage utilisant plusieurs seuils. La généralisation de certaines méthodes entropiques pour une segmentation globale de l'image n'a pas donné de résultats satisfaisants. Une interprétation de l'entropie sous un autre angle sera plus judicieuse. À titre d'exemple, il sera intéressant de considérer que l'image est réellement composée d'un mélange de classes de couleurs dont chacune est caractérisée par sa propre entropie. L'intérêt d'une telle interprétation réside dans le fait que chaque classe est considérée comme une seule source d'information indépendante.

3.1.5 Réseaux de Neurones

Les réseaux de neurones sont une stratégie populaire utilisée pour la segmentation d'images couleurs par classification de pixels. Ils sont souvent formés par plusieurs couches de neurones. Chaque couche est composée de plusieurs éléments (les entrées) qui sont connectés à d'autres neurones du réseau. Un poids variable est associé à chaque neurone. La relation entre les entrées et le poids de chaque neurone produit une sortie résultante d'une certaine fonction de transfert [50]. Les réseaux de neurones sont largement utilisés en reconnaissance de formes à cause de leur non-linéarité et puisqu'ils répondent bien aux problèmes de classification. Cependant, leur complexité limite leur intérêt, leur utilisation et leur efficacité.

Le réseau de Kohonen: The Self-Organizing Map (SOM) [52] est un excellent algorithme de classification. Cependant, il est moins performant que le Fuzzy k-means décrit plus haut. Du fait qu'il déploie la carte sur tout le réseau, en présence de bruit, les centres de classes seront alors affectés. Dans leur algorithme, Ji et Park [53] ont utilisé une méthode basée sur le principe de ligne de partage des eaux pour faire une segmentation initiale. Ils ont employé par la suite le réseau de Kohonen (SOM) pour résoudre le problème de sur-segmentation (*over segmentation*).

3.2 Segmentation d'image en régions

3.2.1 Division et Fusion (*split and merge*)

Split and merge sont souvent utilisés ensemble [66]. C'est un processus qui se décompose en deux étapes. Au départ, l'image entière est considérée comme une seule région, si celle-ci ne satisfait pas aux critères d'homogénéité, elle sera divisée en quatre sous-régions (quatre blocs rectangulaires), c'est l'étape de division. Puis, un test de similarité est réalisé sur chacune des deux régions adjacentes selon un prédicat défini (variance, min-max,...). Ainsi, deux régions adjacentes qui satisfont aux critères de similarité seront fusionnées, c'est alors l'étape de fusion. Récursivement, on divise les régions non homogènes (toujours en quatre sous-régions), et on regroupe par la suite les régions adjacentes et homogènes. Le processus se répète jusqu'à ce que la région à diviser soit homogène ou ait une taille minimale. La méthode la plus connue pour ce principe est le quadtree.

La segmentation en utilisant la méthode "Division et Fusion" permet d'obtenir des régions avec des frontières non lisses (plutôt de régions rectangulaires) nécessitant alors une étape de post-traitement. Ainsi, un lissage pour éliminer les formes rectangulaires des régions est alors recommandé. La performance de cette technique est conditionnée à l'efficacité de tests de similarité entre les régions qui sont eux-mêmes sujets à la perception visuelle.

3.2.2 Croissance de régions (*region growing*)

Le principe de cette technique est comme suit : on fixe un pixel de départ (ou une région homogène) qui est la région initiale. Cette région est aussi considérée comme le germe de la région cherchée. Par une procédure récursive : tout pixel voisin de la région initiale vérifiant certains critères d'homogénéité (ex : intensité de pixel comprise entre deux seuils) sera ajouté à la région initiale. Ainsi la région cherchée croît (grow) tant qu'il y a un pixel voisin qui vérifie les critères d'homogénéité [54]. Souvent la segmentation est accompagnée de petites régions isolées (trous). Pour résoudre ce problème, ces régions sont éliminées par une phase de fusion qui clôture la segmentation. Le principal avantage offert par ce genre de technique est que les régions obtenues sont compactes.

Tremeau et Borel [56] ont proposé un algorithme de segmentation d'images couleurs qui combine deux techniques en même temps soient la croissance et la fusion. Au départ, l'algorithme génère des régions connectées avec un processus de croissance puis une phase de fusion est appliquée à toutes les régions qui ont une distribution colorimétrique similaire.

Deng et Manjunath [57] ont adopté la croissance de régions dans leur algorithme JSEG pour la segmentation d'images couleur. Dans [58], les auteurs proposent un algorithme de segmentation d'images couleur composé de deux étapes soient la classification non-supervisée et la croissance de régions.

3.3 Segmentation d'image en contours

La segmentation en contours consiste à extraire les contours des objets dans la scène. Elle utilise la technique de la variation brusque des pixels entre les régions (gradient). Plusieurs techniques ont été développées et les plus populaires sont ceux de: Sobel, Prewitt, Robert et Canny [59]. Ces techniques sont initialement proposées pour les images à niveaux de gris. Pour une image couleur, le même processus s'applique séparément trois fois (Ex : une pour chaque bande, R, G, et B). Le résultat final est la réunion des résultats des trois bandes. Xu et Shi [60] proposent une méthode de segmentation d'images couleur. Dans cette méthode, les contours sont calculés "*in terms of high phase congruency in the gray level image*". L'algorithme de k-means [38] y est utilisé pour classer les longues lignes en se basant sur l'information couleur des objets. Les lignes courtes sont fusionnées en se basant sur leurs positions.

3.4 Segmentation d'image par méthode hybride

La segmentation hybride est basée sur des méthodes utilisant simultanément deux méthodes de segmentation, par exemple contours et régions [61].

3.5 Évaluation de la qualité de la segmentation

La segmentation d'images est une étape essentielle pour l'interprétation de la scène visuelle. Toutefois, cette interprétation n'est garantie que par la performance des résultats de la segmentation. De nombreuses méthodes de segmentation ont été proposées ces dernières décennies. Elles sont basées sur différents paramètres : couleur, texture, régions, contour, etc. Devant la diversification des méthodes proposées en littérature et l'exigence de la perfection, l'évaluation de la qualité de segmentation devient primordiale. Traditionnellement, l'efficacité d'une nouvelle méthode est jugée par l'illustration de quelques résultats de segmentation. Ceci ne garantit pas toujours une évaluation objective des performances d'une telle méthode. Des critères d'évaluation de la qualité de segmentation sont alors indispensables. D'abord, la qualité de segmentation sera mieux évaluée car on pourra effectuer des comparaisons entre différentes méthodes. Ensuite, il sera possible d'ajuster par exemple les paramètres de l'algorithme pour mieux l'optimiser si on considère les critères d'évaluation comme indices de confiance.

Ainsi, plusieurs critères d'évaluation de segmentation ont été proposés dans la littérature [62], mais aucun d'entre eux n'est absolu ou générique pour effectuer l'évaluation de la qualité de la segmentation. De façon générale, deux types d'évaluation devraient être effectués pour une meilleure évaluation: qualitative et quantitative.

3.5.1 Évaluation qualitative de la segmentation

Il n'y a pas de règles spécifiques pour faire une évaluation qualitative d'une segmentation. Cette dernière est plutôt basée sur un jugement visuel, c'est-à-dire sur l'appréciation et l'intuition humaine. Une segmentation est tout simplement jugée bonne si toutes les régions de couleurs différentes sont isolées (le mot "différentes" dépend aussi de la perception humaine). Ce genre d'évaluation est simple et rapide car aucun réglage de paramètres n'est nécessaire. Par ailleurs, il n'offre pas des résultats précis sur la qualité de segmentation, d'où la nécessité de recourir aux règles mathématiques et statistiques pour établir des critères quantitatifs.

3.5.2 Évaluation quantitative de la qualité de segmentation

Plusieurs critères d'évaluation ont été avancés sur ce sujet et sont généralement basés sur des calculs statistiques. Selon la procédure d'évaluation, ces critères peuvent être regroupés en deux catégories : (i) critères exploitant des connaissances a priori sur le résultat de la segmentation. Idéalement ces connaissances sont une image de référence comme la vérité-terrain "*ground truth*" (évaluation supervisée); et (ii) des critères ne nécessitant aucune connaissance a priori du résultat de la segmentation (évaluation non supervisée).

3.5.2.1 Évaluation supervisée

Dans un contexte supervisé, l'évaluation de la qualité de segmentation s'effectue grâce à une vérité-terrain (souvent image segmentée manuellement par un expert). Ainsi, l'évaluation sera faite en comparant quantitativement les deux résultats de segmentation [67].

3.5.2.2 Évaluation non supervisée

Dans un contexte non supervisé et en absence de connaissances a priori sur le résultat de la segmentation (ex : une "vérité-terrain"), deux types de critères d'évaluation peuvent être utilisés : critères analytiques basés sur la technique utilisée pour la segmentation (stabilité de l'algorithme, complexité, etc.) et critères de qualité basés sur des données quantitatives et sur la cohérence entre les différents résultats [62].

3.5.2.2.1 Évaluation par critères analytiques

Les critères d'évaluation analytique concernent spécifiquement l'algorithme utilisé pour la segmentation. En analysant ses principes et ses propriétés (paramètres, complexité, convergence, etc.), il est possible de quantifier les performances de l'algorithme. L'utilisation de ces critères permet, d'une part d'éviter l'implantation de l'algorithme et, d'une autre part, de s'affranchir de l'influence qui pourrait être causée par l'implantation. La diversité du domaine de segmentation d'images qui requiert beaucoup de connaissances théoriques complique davantage l'établissement de critères généraux pour faire une

évaluation analytique. C'est pour cette raison que les critères d'évaluation analytique n'ont pas reçu beaucoup d'attention de la part de la communauté scientifique.

3.5.2.2.2 Évaluation par critères de qualité

Comme son nom l'indique, ces critères reposent sur des facteurs de qualité calculés à partir du résultat de segmentation. Ces critères sont souvent établis par l'impression humaine parmi un ensemble de critères à remplir pour une meilleure segmentation. L'algorithme à l'essai est ainsi jugé selon certaines critères comme l'uniformité, l'homogénéité, les contours, les contrastes entre les régions, etc.

Plusieurs critères d'évaluation ont été avancés dans la littérature. Deux critères mesurant la qualité de segmentation seront présentés en particulier : le premier basé sur le contraste est proposé par Zeboudj [62] et le deuxième basé sur la taille de régions, leurs formes et leurs homogénéités est proposé par Liu et Yang [70] et par Borsotti [63].

a) Contraste de Zeboudj

Le contraste de Zeboudj [62] prend en considération le contraste intérieur et le contraste extérieur aux régions mesurées au voisinage de chaque pixel.

Notons : $W(s)$ le voisinage d'un pixel p , L maximum des intensités, et $C(p_1, p_2)$ le contraste entre les deux pixels p_1 et p_2 est donné par [62] :

$$C(p_1, p_2) = \frac{|p_1 - p_2|}{L - 1} \quad (17)$$

Le contraste intérieur (C_i) et extérieur (C_e) d'une région R_i , respectivement sont définis comme suit :

$$C_i = \frac{1}{A_i} \sum_{p_1 \in R_i} \max\{C(p_1, p_2), p_2 \in W(p_1) \cap R_i\} \quad (18)$$

$$C_e = \frac{1}{l_i} \sum_{p_1 \in F_i} \max\{C(p_1, p_2), p_2 \in W(p_1), p_2 \notin R_i\} \quad (19)$$

où :

- A_i et F_i sont respectivement la surface et la bordure de la région R_i , l_i la longueur de F_i .

Le contraste de la région R_i est :

$$C(R_i) = \begin{cases} 1 - C_i / C_e, & \text{si } 0 \leq C_i \leq C_e \\ C_e, & \text{si } C_i = 0 \\ 0, & \text{autrement} \end{cases} \quad (20)$$

Le contraste global de toute l'image est :

$$C_z = \frac{1}{A} \sum_i A_i C(R_i) \quad (21)$$

b) Critère de Liu et Yang

Liu et Yang [70] proposent de mesurer la qualité de la segmentation par un critère qui prend en compte à la fois l'homogénéité des régions segmentées en termes de niveaux de gris et le nombre des régions segmentées. La fonction d'évaluation empirique est définie comme suit :

$$F(I) = \frac{1}{1000(X * Y)} \sqrt{R} \sum_{i=1}^R \frac{e_i^2}{\sqrt{A_i}} \quad (22)$$

où :

- I est l'image segmentée;

- R est le nombre de régions segmentées ;
- XY sont les dimensions de l'image ;
- e_i est la somme des distances euclidiennes en niveau de gris entre les pixels de la région R_i ;
- $R(A_i)$ est le nombre de régions ayant une aire égale à A_i .

Une faible valeur de $F(I)$, signifie que les régions sont homogènes et que la segmentation est de bonne qualité étant donnée que la dispersion de niveaux de gris entre les pixels d'une même région est faible, celle-ci est mesurée par la somme des distances euclidiennes e_i .

c) Critère de Borsotti

L'un des premiers critères pouvant servir à qualifier un résultat de segmentation est la mesure de l'uniformité intra-région. Borsotti [63] a proposé un critère basé sur le nombre de régions, l'aire des régions et la couleur moyenne, dans l'espace RGB :

$$Q(I) = \frac{\sqrt{R}}{1000XY} \sum_{i=1}^R \left[\frac{e_i^2}{1 + \log A_i} + \left(\frac{R(A_i)}{A_i} \right)^2 \right] \quad (23)$$

où :

- R est le nombre de régions segmentées ;
- XY sont les dimensions de l'image ;
- e_i est la somme des distances euclidiennes entre les vecteurs couleurs des pixels de la région R_i et le vecteur couleur attribué à la région R_i dans l'image segmentée (en général la moyenne des couleurs de la région) ;
- $R(A_i)$ est le nombre de régions ayant une aire égale à A_i .

L'équation (23) est composée en somme de deux termes : le premier terme favorise les régions homogènes. Alors que le deuxième terme a une valeur élevée quand il y a beaucoup de petites régions, ce qui pénalise les images sur-segmentées en beaucoup de régions de même taille. Les régions d'un résultat de segmentation doivent en effet :

- être homogènes ;
- contenir peu de petits trous ;
- avoir des caractéristiques d'homogénéité significativement différentes pour les régions adjacentes.

3.6 Conclusion

Dans ce chapitre, les principales méthodes de segmentation proposées dans la littérature ont été présentées. Ces méthodes pourraient être regroupées en deux catégories : (i) méthodes qui ne tiennent compte que des relations en niveaux de gris entre les pixels lors de formation des régions, et (ii) d'autres méthodes qui tiennent compte à la fois des relations de voisinage et de niveaux de gris entre les pixels pour former les régions. Les deux types de méthodes nécessitent souvent le réglage de certains seuils et paramètres, tels que les critères d'arrêt de l'algorithme ou de similarité entre les pixels. L'ajustement de ces paramètres, qui est dans la plupart des cas lié à des contraintes très restrictives, est très délicat, ce qui résulte souvent en une sur-segmentation ou en une sous-segmentation de l'image. Il s'avère aussi que les résultats de la segmentation dépendent de l'initialisation comme par exemple le choix des germes (cas des méthodes de croissance de régions) ou la connaissance préalable du nombre de classes issues de la segmentation. D'une façon générale, la performance des méthodes de segmentation est conditionnée au niveau du contraste entre les régions adjacentes, plus le contraste est élevé plus la segmentation est commode.

Par ailleurs, nous avons appliqué l'algorithme de fuzzy k-means et l'algorithme d'EM pour segmenter les deux types d'images visibles et proche infrarouge (figure 3.2), figures obtenues par la technique d'acquisition d'image proposée au chapitre 2. Ainsi, les résultats de cette étude nous a conduit à proposer une nouvelle méthode de segmentation qui s'adapte bien à notre application, à savoir la segmentation du persillage dans les images visibles et proches infrarouges. Ceci fera l'objet des chapitres 4 et 5.

Chapitre 4

Extraction des régions homogènes en niveaux de gris en utilisant l'algorithme 'FCE'

Dans le deuxième chapitre une nouvelle technique pour l'évaluation volumétrique du persillage a été présentée. Cette technique a révélé la nature des images à traiter pour la détection du persillage dans la viande. La revue de littérature sur les méthodes de segmentation d'image présentée au troisième chapitre nous a amené à privilégier le développement d'une méthode de segmentation d'image en régions qui s'adapte adéquatement avec notre application. Pour ce faire, dans ce chapitre une méthode efficace de segmentation permettant d'identifier les régions homogènes les plus claires (ou les moins claires) dans une image à niveaux de gris a été développée. Cette nouvelle méthode, qui est relativement générale, est basée sur une nouvelle définition métrique permettant d'évaluer l'homogénéité des régions en niveaux de gris, elle-même est définie dans ce chapitre. Elle consiste à former des régions directement à partir des relations de niveaux de gris des pixels et indirectement des relations spatiales entre les pixels lors de la formation des régions. La simplicité conceptuelle de cette méthode lui permettra d'éviter d'implanter trop de seuils et de paramètres, qui sont difficiles à ajuster, pour établir les relations de proximité entre les pixels lors de la formation des régions.

Cette méthode est basée sur l'hypothèse stipulant que : les pixels ne sont pas accidentellement regroupés ou en voisinage pour former une région, mais devraient être issus d'une même catégorie de niveaux de gris, de régions ou des objets présents dans la scène. Ainsi, les régions de l'image peuvent être formées en considérant qu'une région est de niveaux de gris homogène, formée d'un groupe de pixels perceptuellement (pour un observateur) similaires dont les valeurs de leurs niveaux de gris se concentrent autour de sa valeur moyenne.

Dans ce cadre, il est proposé de mesurer l'homogénéité d'une région par une mesure accumulative de la distance de niveaux de gris entre le centre de la classe qui définit la région et les pixels. Cette distance, qui est introduite dans ce chapitre, traduit le degré de ressemblance (ou de similarité) entre le centre de la classe et les pixels, par conséquent entre l'ensemble des pixels qui forment une région. Du point de vue perception, deux régions de niveaux de gris ayant une certaine distance devraient être proportionnellement considérées par l'œil humain (pour un observateur) comme ayant la même différence de niveau de gris.

La suite de ce chapitre est organisée comme suit : la section 2 présente un nouvel outil, qui est un modèle mathématique, qui mesure la distance théorique de similarité de niveau de gris entre un pixel et un groupe de pixel. En se basant sur cette distance, un nouvel algorithme appelé FCE "*First Class Extraction*" est présenté. Cet algorithme permet d'extraire les régions les plus (ou les moins) claires dans l'image de luminance. La section 3 présente les résultats expérimentaux de cet algorithme. Dans la section 4, une étude comparative entre notre méthode et quelques méthodes modernes de segmentation d'image est présentée. La section 5 présente différents résultats obtenus par notre méthode sur différentes catégories d'images. Finalement, la conclusion est fournie à la section 6.

4.1 Modèles et algorithme

Une image quelconque est composée d'un mélange de classes de niveaux de gris différentes. Ces classes sont principalement caractérisées par deux paramètres : la distribution et l'homogénéité des niveaux de gris. La distribution est souvent approximée par une forme gaussienne [75]. Elle est essentiellement caractérisée par deux paramètres : la moyenne et la variance des pixels composant la classe de niveaux de gris. Cependant, l'homogénéité est souvent liée à la sensation visuelle. Sa mesure quantitative est difficile à préciser. Par exemple, il est difficile de préciser jusqu'à quelle limite une classe de niveaux de gris est homogène ou de mettre des critères précis définissant son homogénéité. Dans ce contexte, une nouvelle approche permettant d'extraire une classe particulière à partir de ce mélange est proposée. C'est à l'instar des techniques utilisant l'entropie pour segmenter

l'image en deux classes (deux régions, objet et fond) [76]. L'algorithme proposé, donne aussi naissance à deux types de classes de niveau de gris : une qui est homogène (ex : l'objet), le reste de l'image étant la deuxième classe, celle-ci est considérée comme le fond de l'image. Il s'agit d'un algorithme qui permet d'identifier la classe extrême en termes de niveaux de gris dans l'image. Cette classe pourrait alors être la plus ou la moins lumineuse.

L'idée de cette nouvelle approche est basée sur un nouveau concept de calcul dynamique (en fonction des itérations) de la variation de la distance, en termes de niveau de gris, entre le centre C_c de la classe c à identifier et le centre C_q de la clique de pixels q la plus éloignée du même centre (Figure 4.1 & Équation 3). Cette distance est calculée en termes d'exponentielles. La mesure de la distance entre le centre de la classe et la clique de pixels en question traduit le degré de ressemblance et donc d'appartenance de cette clique de pixels q à la classe c . Du point de vue perception, ceci se traduit par le fait que deux niveaux de gris proches en distance le sont aussi pour l'œil humain. La figure 4.1 illustre le concept de la clique de pixels.

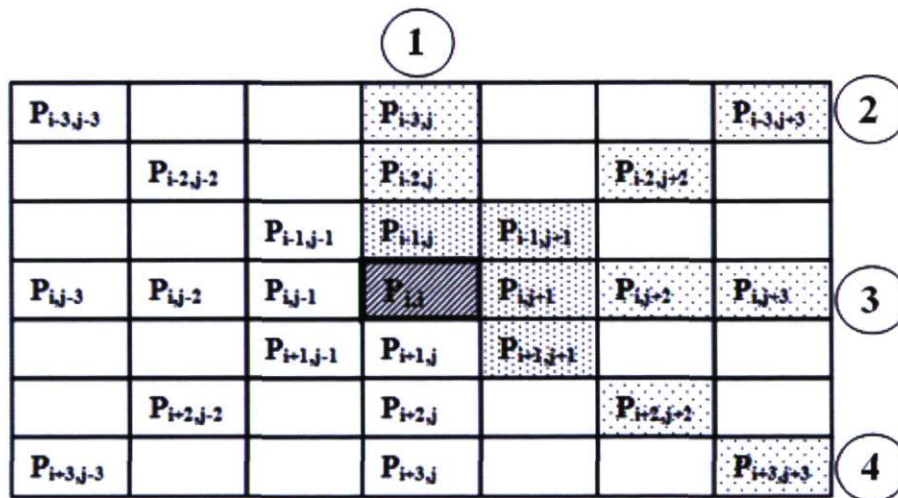


Figure 4.1. Illustration de la clique de pixels.

où :

- p_{ij} sont les pixels dans l'image aux coordonnées i et j .

Dans ce chapitre, “une clique de pixels” est définie comme un regroupement de n pixels connexes connectés dans une seule direction. Par exemple, considérant le pixel $p_{i,j}$ (qui est au centre de la figure 4.1) comme point origine dans l’image (i et j sont les coordonnées du pixel p dans l’image), conformément à la figure 4.1, il y a huit (8) directions possibles à partir de $p_{i,j}$ pour former la clique de pixels q . Toutefois, ces huit directions sont symétriques, ils pourraient être alors réduits à quatre (4) directions tel que illustré à la figure 4.1. Dans ce travail, on se limite à deux pixels par clique et à quatre directions pour composer la clique de pixels : une clique est donc formée par le pixel $p_{i,j}$ et ses pixels voisins dans les quatre directions. Ainsi, dans chaque direction, la distance euclidienne est calculée, la clique de pixels candidate devrait avoir la distance minimale entre tous les pixels dans la même direction pour les quatre directions. Cette clique est définie comme suit :

$$q = \min \left(\sum_{k=1}^n |p_{i,j} - p_{i-k,j}|, \sum_{k=1}^n |p_{i,j} - p_{i-k,j+k}|, \sum_{k=1}^n |p_{i,j} - p_{i,j+k}|, \sum_{k=1}^n |p_{i,j} - p_{i+k,j+k}| \right) \quad (1)$$

où :

- q est la distance minimum entre tous les pixels dans la même direction pour les quatre directions ; $p_{i',j'}$ sont les pixels voisins du pixel $p_{i,j}$ dans une même direction; et n est le nombre de pixels voisins au pixel $p_{i,j}$ dans une même direction.

Le centre de la clique de pixels est défini comme la moyenne des pixels dans une seule direction; ceci est décrit par l’équation suivante :

$$C_q = \frac{1}{n} \sum_{i,j} p_{i,j} \quad (2)$$

où :

- C_q est le centre de la clique ; n est le nombre des pixels voisins $p_{i,j}$ dans une même direction, c ’est le nombre de pixels de la clique.

Plusieurs techniques utilisant le concept de distance de niveaux de gris pour calculer la similarité en niveaux de gris entre deux régions ont été proposées [41]. La distance Euclidienne est généralement l'approche privilégiée pour calculer la distance en niveaux de gris ou couleur d'une façon plus générale [41]. Par exemple, pour une image couleur l'espace couleur $L^*a^*b^*$ est le choix populaire dans plusieurs applications [81]. Également, la Commission Internationale de l'Éclairage (CIE) propose d'utiliser la distance Euclidienne pour mesurer la différence entre deux niveaux de luminances.

Dans ce travail de recherche, un nouveau modèle mathématique pour mesurer la distance théorique en niveaux de gris est proposé. Cette distance exploite la notion mathématique d'exponentielle de la distance euclidienne entre deux niveaux de gris. Soit D_{cq} la distance à mesurer entre le centre C_c de la classe c et le centre C_q de la clique de pixels q . Cette distance est définie comme suit :

$$D_{cq} = 1 - \exp(-|C_c - C_q|) \quad (3)$$

où :

- C_c est le centre la classe c ; C_q est le centre de la clique de pixels sélectionnés comme définie dans l'équation 2.

Lorsque le niveau de gris du pixel p est proche de celle de la classe c ($C_c \cong C_q$), l'expression $\exp(-|C_c - C_q|)$ est maximale, elle est proche de 1. D_{cq} est alors proche de zéro. Dans ce cas, la clique de pixels q , et la classe c , laquelle généralement représente des régions, sont similaires en terme de niveaux de gris. Au fur et à mesure que le centre de la clique de pixels C_q s'éloigne du centre de la classe C_c , la distance D_{cq} augmente. Lorsque C_q est assez loin de C_c , l'expression $\exp(-|C_c - C_q|) \rightarrow 0$ et la distance D_{cq} tend vers 1. À cette limite, le niveau de gris de la clique de pixels q n'est plus similaire au niveau de gris à la classe c .

Afin d'illustrer le concept de l'algorithme FCE, la figure 4.2 est utilisée comme un exemple représentatif. Elle montre l'image proche infrarouge d'un échantillon de viande de bœuf obtenue par une caméra CCD tel que décrit par le montage expérimental présenté au chapitre 2 et au [83]. Dans cette application, le but de l'application de l'algorithme FCE est pour détecter les régions les moins claires dans l'image présentée. Ces régions (les moins claires), correspondent aux régions les moins claires des régions du persillage (gras entre les fibres musculaire) dans la viande de bœuf. Ainsi, pour calculer la distance D_{cq} comme étant une fonction variable en fonction des valeurs d'intensités de pixels, les itérations de l'algorithme débutent à la valeur minimale de l'image : au cours de la première itération, C_q est égale à C_c , ($C_q = C_c$), laquelle est égale à la valeur minimale d'intensité de clique de pixels dans l'image. Dans la prochaine itération, C_q va décroître car l'intensité des pixels sera incrémentée par 1 et C_c sera égale à la valeur de la nouvelle moyenne de tous les pixels inférieurs ou égaux à C_q . Ainsi, à chaque nouvelle itération, la valeur de D_{cq} sera calculée de nouveau jusqu'à ce que toute l'image soit balayée. La variation de la distance D_{cq} comme fonction des itérations est illustrée à la figure 4.3. D_{cq} est alors une mesure de distance théorique de ressemblance entre la clique de pixels q et la classe c en terme de niveaux de gris. L'équation 3 est toujours positive, et varie entre $[0, 1]$. Elle est composée de deux termes: le premier terme, qui est constant est égale à 1; le second terme, qui est variable dépend de la différence en niveaux de gris entre c et q (ceci est la distance relative entre c et q).




Figure 4.2. Image proche infrarouge de la viande de bœuf.




Figure 4.3. Variation de la distance D_{cq} en fonction des itérations.
(Note : la petite variation dans la courbe est causée par le bruit)

La mesure de la distance entre le centre de la classe c et la clique de pixels q traduit le degré de ressemblance (ou de dissemblance) entre la classe c et la clique de pixels q . Cette distance représente aussi le degré de similarité (ou dissimilarité) entre la clique de pixels q et la classe c . Ainsi, cette mesure contient de l'information relative à l'uniformité ou l'homogénéité de la classe c en terme de niveau de gris. En effet, initialement la classe c est compacte et homogène car les pixels de la classe ont des niveaux de gris assez rapprochés. Au cours des itérations, la taille de la classe c s'agrandit "grows", son homogénéité est alors décroît à cause des hétérogénéités des récents pixels qui sont intégrés à la classe. À la limite, la classe c deviendra très hétérogène lorsque D_{cq} se rapproche assez de 1, l'homogénéité de la classe c deviendra minimum. Elle est alors la limite de l'uniformité (ou de l'homogénéité) de la classe c en terme de niveaux de gris. Cette limite est alors un indicateur de seuillage pour la classe c .

Ainsi, le problème se réduit donc à trouver cette limite avec un seuil qui identifie la classe c . Ce problème pourrait être résolu par une nouvelle définition de l'homogénéité comme cela est exposé à la sous-section suivante.

4.1.1 Homogénéité de la classe c

Dans le dernier paragraphe on a démontré le lien entre l'homogénéité en niveau de gris de la classe c et la variation de la distance D_{cq} . De plus, on a démontré qu'il est possible d'établir un seuil qui optimise l'agrandissement (la taille) de la classe c en fonction du niveau de l'homogénéité. Ce seuil permet de définir la classe la plus large possible, en termes de nombres de pixels, avec l'homogénéité optimale. Pour ce faire, il est possible d'obtenir ce seuil à partir de la courbe de la distance D_{cq} . Dans ces conditions, ce seuil pourrait être établi à partir des valeurs des itérations lorsque la valeur de D_{cq} se rapproche de 1. Cependant, en se basant sur nos tests en application de cette technique, nous avons constaté que celle-ci n'est pas une technique fiable pour trouver le seuil optimal.

Pour établir un meilleur lien entre l'homogénéité de la classe c et la variation de la distance D_{cq} , une bonne approche consiste à accumuler, en fonction des itérations, les distances relatives entre le centre de la classe c et le centre de la clique de pixels q . Il s'agit de la valeur de l'expression $\exp(-|C_c - C_q|)$. Ceci est le cas pour toutes les cliques de pixels dont les valeurs qui sont inférieures ou égale à C_q .

Définissons H comme la valeur des accumulations obtenues (H en référence à l'homogénéité de la classe c en terme de niveaux de gris). Ainsi, cette homogénéité pourrait être calculée en utilisant la fonction de densité de probabilité estimée des cliques de pixels calculées de l'image comme suivants :

$$F_q(i) = \frac{1}{N} \sum C_q(q = i) \quad (4)$$

où:

- F_q est la fonction de densité de probabilité estimée des cliques de pixels calculées de l'image;
- C_q est le centre de la clique (équation 2);
- N est le nombre total des cliques de pixels dans l'image;
- i est le niveau de gris.

La densité de probabilité cumulative estimée des cliques de pixels dans l'image est définie comme suit :

$$F_{qc}(i) = \sum_{t=0}^{t=i} F_q(t) \quad (5)$$

où:

- t est l'itération.

Ainsi, l'homogénéité H en niveaux de gris de la classe c est exprimée comme suit:

$$H(i) = F_{qc}(i) \exp(-|C_c - C_q|) \quad (6)$$

L'équation (6) est composée d'un produit de deux fonctions monotones. La première fonction " F_{qc} " accroît (augmente) avec les itérations des intensités de niveaux de gris. Elle contient de l'information quantitative sur les cliques de pixels en fonction des intensités. Contrairement, la deuxième fonction " $\exp(-|C_c - C_q|)$ " décroît au cours des itérations des intensités i . Cette dernière contient de l'information sur la distance en niveaux de gris entre le niveau de gris de la classe c et le niveau de gris de la nouvelle candidate clique de pixels. Ce produit de deux fonctions augmente en cas d'un nombre significatif de clique de pixels proches en distance (cliques de pixels proches en niveaux de gris ou appartenant à la même classe de niveau de gris). Cet accroissement est visible à partir du premier groupe significatif des cliques de pixels rencontrées au cours des itérations. Par exemple, dans le cas des régions les moins claires dans l'image. La deuxième fonction décroît quand le niveau de gris des cliques de pixels décroît en similarité (devient de plus en plus claire).

À cause du terme exponentiel, lequel décroît rapidement, le produit des deux fonctions décroît lorsque la distance de niveaux de gris entre la classe c et la nouvelle clique de pixels

q est significative. En fait, il tend vers zéro signifiant que la classe c n'est plus homogène (Figure 4.4). Ainsi, l'approche utilisant la distance cumulative inter-cliques de pixels favorise la formation des régions homogènes.

La figure 4.4 montre les variations, en fonction d'intensité en niveau de gris, de l'homogénéité de la classe c et de l'histogramme de l'image normalisés entre $[0, 1]$, ceci pour le cas de l'image de la figure 4.2.

Pour filtrer le bruit présent dans la courbe de l'homogénéité H , l'entropie floue (*the fuzzy entropy*) [74] est utilisée comme un filtre de lissage pour la courbe de l'homogénéité H . Par ailleurs, nous avons démontré au chapitre 3 (paragraphe 3.1.4) l'avantage de ce genre de filtre. Un tel lissage supprime les petites perturbations sans "presque" changer le signal, facilitant ainsi la détection du centre de la classe et/ou du seuil de la classe.

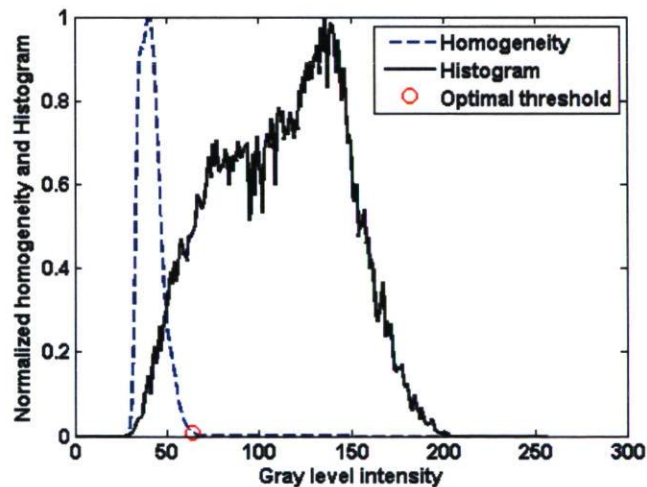


Figure 4.4. Variations de l'homogénéité H de la classe c et l'histogramme de l'image. (cas de l'image de la figure 4.2).

La figure 4.4 montre que la courbe de l'homogénéité H est composée d'une mode principale, dont le maximum signale la présence du centre des régions les moins claires dans l'image. Ceci correspond à la Première Classe (*First Class*) à Extraire d'où le nom de (*First Class Extraction* "FCE") donné à cet algorithme. Comme montre la figure 4.4, il est

difficile d'identifier un seuil optimal en se basant sur l'histogramme dans cette zone à cause du bruit et aussi parce qu'il n'existe pas nécessairement une vallée précise proche de cette zone.

Par ailleurs, la figure 4.5 est une image synthétique ayant quatre régions qui illustre plus clairement, que l'image 4.2, le concept de l'algorithme FCE. La figure 4.5 montre que l'homogénéité H est composée d'un mode principal synchronisé avec celui de l'histogramme. Ce premier mode indique le centre de la région la moins claire dans l'image (première classe), suivie par plusieurs vagues de faible amplitude. Quand s'éloigne du premier mode, les ondulations de l'homogénéité H décroissent et tendent vers zéro.

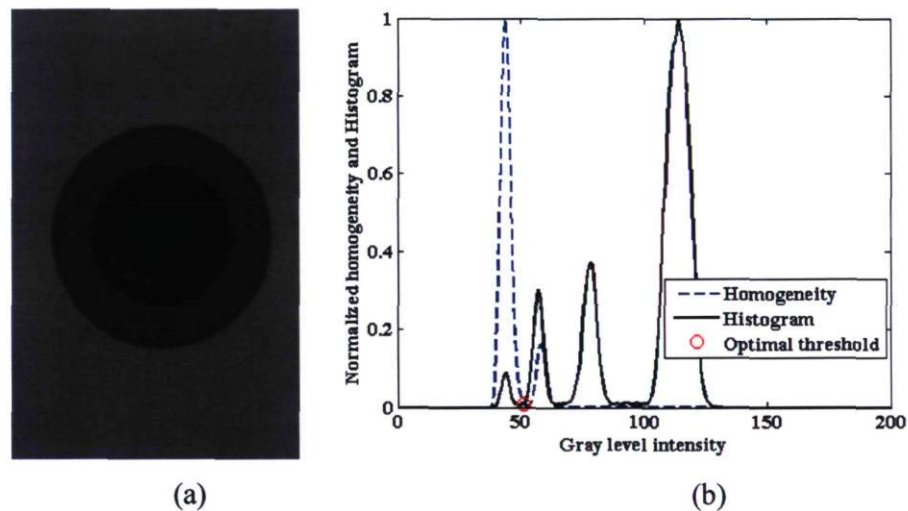


Figure 4.5. Homogénéité H de la région la moins claire dans l'image synthétique. (a) image synthétique; (b) homogénéité H .

Cette étude montre que l'homogénéité H maximise la probabilité d'apparition de la "première classe". Dans cette application, il s'agit des régions les moins claires dans la figure 4.2, mais le principe est aussi valide pour les régions les plus claires dans l'image. Ainsi, l'homogénéité H est un bon indicateur du centre de la classe à identifier. La dernière étape consiste alors à trouver le niveau de seuil optimal t pour identifier la classe en question. Dans cette étude, la valeur du seuil t est obtenue à partir du minimum local

suivant le maximum de l'homogénéité comme montre les figures 4.4 et 4.5. Ainsi, l'implémentation de l'algorithme FCE pourrait se résumer en deux étapes:

1. à partir de l'équation (6) trouver le seuil optimal t comme décrit dans cette section, ce qui pourrait se faire à partir de la courbe d'homogénéité H lissée par l'entropie floue ; et
2. le processus de seuillage des cliques de pixels (de segmentation) devrait respecter la condition du principe de la clique des pixels comme défini par l'équation (1).

4.2 Résultats et discussion (cas de la figure 4.2)

Dans cette section, nous allons appliquer l'algorithme FCE pour extraire les régions les moins claires dans l'image proche infrarouge de l'échantillon de la viande de la figure 4.2. Le résultat obtenu est illustré à la figure suivante.



Figure 4.6. Détection des régions les moins claires par l'algorithme FCE.
(cas de la figure 4.2).

La figure 4.6 montre qu'effectivement l'algorithme FCE permet d'identifier les régions les moins claires à travers toute l'image. Les régions détectées correspondent à des catégories

de régions de persillage. Ce sont les régions de persillage de forte densité, observées généralement à la surface de l'échantillon de la viande.

L'évaluation qualitative de ce résultat montre clairement que la segmentation obtenue par l'algorithme FCE est moins bruitée (ex : moins de pixels isolés) par rapport aux résultats obtenus par des algorithmes connus en segmentation d'image tels que l'algorithme Expectation maximisation (EM) et l'algorithme de fuzzy k-means (paragraphe 4.4, figure 4.8). La figure 4.6 montre aussi que les régions détectées sont naturellement unies d'uniformes niveaux de gris (homogène). Il n'y a pas beaucoup de pixels isolés ou des zones avec des trous vides. Un examen de la distribution de la classe de pixels identifiée (ou des régions) montre que les pixels de cette classe ont typiquement une distribution gaussienne normale, ce qui n'est pas le cas dans un seuillage traditionnel (voir figure 4.9). La figure 4.7 illustre les courbes de la distribution des pixels de la classe extraite en utilisant l'algorithme FCE, et les pixels restants de l'image.

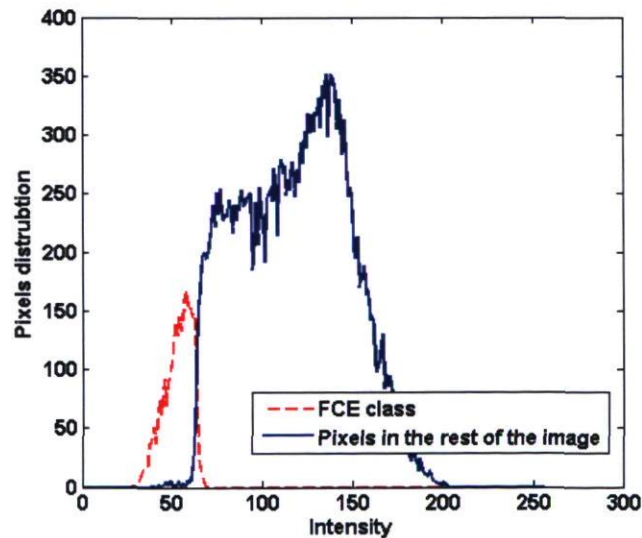


Figure 4.7. Distribution des pixels des régions détectées par l'algorithme FCE. et celle des pixels du reste de l'image (cas de la figure 4.2).

Afin de bien mener une évaluation objective de l'algorithme FCE, les résultats de l'algorithme proposé ont été comparés aux résultats obtenus avec d'autres algorithmes connus en littérature. À savoir : l'algorithme EM, fuzzy k-means et un seuillage classique (en considérant que le seuil utilisé pour faire le seuillage est le même que celle utilisé par l'algorithme FCE). Ainsi, les quatre méthodes ont été appliquées à l'image de la figure 4.2 comme suit :

1. L'algorithme FCE était appliqué pour extraire les régions les plus claires dans l'image;
2. Les algorithmes EM et fuzzy k-means ont été appliqués pour classifier l'image en six, sept et huit classes. Dans cette situation, les nombres de classes ont été choisis arbitrairement, après quelques tests pour obtenir les meilleures classifications proches de celle obtenue par l'algorithme FCE. À partir des classes obtenues, la classe de régions la moins claire est sélectionnée pour être comparée avec le résultat de l'algorithme FCE;
3. Un simple seuillage en utilisant la même valeur du seuil utilisé par l'algorithme FCE.

La figure 4.8 montre les résultats de segmentation des régions les moins claires obtenues par les quatre méthodes.




Figure 4.8. Résultats comparatifs de la segmentation.
(a1) image originale; (a2) résultat de l'algorithme FCE; (a3) résultat obtenu par un seuillage en utilisant le même seuil que celui de l'algorithme FCE; (b1, b2 & b3) les classes des régions les moins claires obtenues avec l'algorithme EM en segmentant l'image respectivement en 6, 7 & 8 classes; et (c1, c2 & c3) les classes des régions les moins claires obtenues avec l'algorithme fuzzy k-means en segmentant l'image respectivement en 6, 7 & 8 classes.

La figure 4.8 montre que les régions les moins claires dans l'image originale ont été détectées par les quatre méthodes: algorithme FCE, simple seuillage et les algorithmes EM et fuzzy k-means. Cependant, il y a des différences majeures entre les quatre résultats. L'évaluation qualitative des résultats obtenus montre que le résultat obtenu par l'algorithme FCE (figure 4.8-a2) est moins bruité (très peu de pixels isolés et peu de pixels manqués dans les régions détectées) par rapport aux autres résultats obtenus avec les autres algorithmes. En évaluation quantitative, le pourcentage des pixels manqués dans les régions détectées par le nombre total de pixels des régions détectées est de 2,63% pour l'algorithme FCE (figure 4.8-a2); 3,02% pour la méthode de seuillage (figure 4.8-a3); 2,90% pour l'algorithme EM (la moyenne des trois images, figures 4.8-(b1-b3)); et 2,90% pour le fuzzy k-means (moyenne des trois images, figure 4.8-(c1-c3)). Le résultat obtenu en utilisant notre méthode (figure 4.8-a2) requiert moins de traitements morphologiques, par rapport aux autres résultats, pour lisser les régions segmentées, ce qui est un avantage en temps de traitement.

Une autre méthode fiable pour évaluer le résultat obtenu par notre méthode est de comparer les distributions des pixels des régions (une classe de pixels de niveau de gris) obtenues par l'ensemble des quatre méthodes. Cette comparaison est illustrée à la figure 4.9.

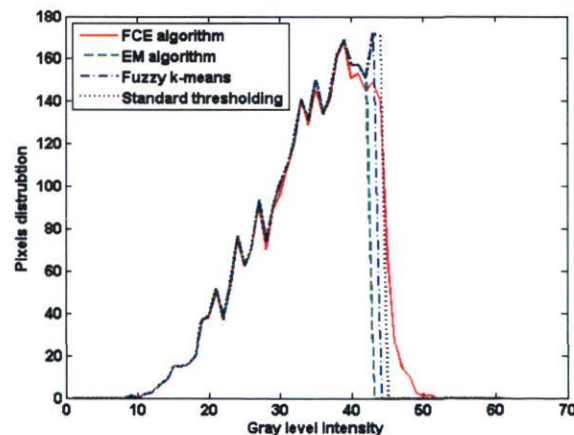



Figure 4.9. Distributions des pixels des régions détectées en utilisant les algorithmes FCE, EM, fuzzy k-means et le seuillage.

La figure 4.9 montre que les segmentations obtenues par les quatre algorithmes sont similaires. Cependant, nous pouvons voir que l'allure de la courbe de l'algorithme FCE (couleur rouge) traverse les autres courbes, celle-ci se comporte comme une moyenne des autres. La différence principale entre les quatre courbes est que les courbes des algorithmes EM, FCE et du seuillage sont fixes aux valeurs de seuils (lignes verticales). Au contraire, la courbe de l'algorithme FCE a une distribution typiquement gaussienne normale, laquelle est plus précise et réaliste.

4.3 Divers résultats et évaluation qualitative-quantitative

Nous avons également testé avec succès la méthode développée sur plus de 200 images de différentes catégories sélectionnées à partir de notre base de données. Certains des résultats sur diverses catégories d'images sont illustrés dans les paragraphes suivants : (a) diverses images proche infrarouge d'échantillons de viande de bœuf; (b) diverses images visibles d'échantillons de viande de bœuf; (c) diverses images visibles pour la détection des défauts dans l'industrie de bois; et (d) diverses image visibles des scènes naturelle. Toutes les images sont obtenues sous diverses conditions expérimentales : différentes longueurs d'ondes (visible, proche infrarouge et infrarouge), intensités d'éclairage et positions. Les résultats obtenus par l'algorithme FCE sont comparés avec ceux obtenus avec des algorithmes récents et connus dans la littérature.

4.3.1 Résultats des images proches infrarouges






Figure 4.10. Résultats sur des images proches infrarouges.
(a1-a6) résultats de l'algorithme FCE; (b1-b6) la classe de pixels la moins
claire obtenue par l'algorithme EM; et
(c1-c6) la classe de pixels la moins claire obtenue par l'algorithme fuzzy k-means.

La figure 4.10 montre les résultats des classes de pixels les moins claires obtenues par notre l'algorithme, l'algorithme EM et l'algorithme fuzzy k-means. Les algorithmes EM et fuzzy k-means ont été appliqués pour classifier, en fonction du niveau de gris, les pixels de l'image en sept classes. Dans cette application, le nombre de classes a été choisi arbitrairement après plusieurs tests pour obtenir la meilleure classification, proche de celle obtenue par l'algorithme FCE. Ainsi, à partir des classes obtenues, les classes les moins claires ont été identifiées pour être comparées par rapport aux classes obtenues avec l'algorithme FCE. Au cours des traitements, le même processus de traitement morphologique est appliqué aux trois algorithmes, il s'agit d'un simple traitement qui consiste de supprimer les pixels isolés ou inversement remplir les pixels manqués dans les régions.

La figure 4.10 montre en premier lieu que les résultats des trois méthodes sont comparables, sauf pour les cas où la précision (au point de vue perception pour un observateur) de certaines détections est différente. Par exemple, la figure 10-a3 montre que les régions détectées par l'algorithme FCE ne sont pas bien détectées comparativement aux régions obtenues avec les autres algorithmes (figure 4.10-b3 et figure 4.10-c3), toutefois ces résultats apparaissent visuellement sur-segmentés. Inversement dans la figure 4.10-b4 et la figure 4.10-c4, les résultats des algorithmes EM et fuzzy k-means sont sur-segmentés. Le changement du type du résultat obtenu par ces algorithmes pourrait être attribué à la difficulté de trouver le nombre optimal de classes de régions dans l'image qui est un paramètre indispensable pour les deux algorithmes. En revanche, la méthode proposée ne nécessite pas ce genre de paramètre ce qui est un avantage par rapport aux autres méthodes.

4.3.2 Résultats sur des images visibles




Figure 4.11. Divers résultats sur des images visibles.
 (a1-a5) résultats de l'algorithme FCE;
 (b1-b5) les classes les plus claires obtenues avec l'algorithme EM;
 et (c1-c5) les classes les plus claires obtenues avec l'algorithme fuzzy k-means.

Contrairement aux images proches infrarouges de l'application précédente, dans les images visibles de la figure 4.11, nous nous intéressons à l'identification des régions les plus claires, lesquelles sont plus précisément les zones les plus claires du persillage. Ainsi, les algorithmes EM et fuzzy k-means ont été appliqués pour classifier, en fonction du niveau de gris, les pixels de l'image en plusieurs classes afin de sélectionner la classe la plus claire dans chaque image. Dans cette application, le nombre de classes a été choisi arbitrairement égal à sept après plusieurs tests pour obtenir la meilleure classification, proche de celle obtenue par l'algorithme FCE. Ainsi, à partir des classes obtenues, les régions de la classe

la plus claire sont identifiées pour être comparées par rapport aux régions obtenues avec l'algorithme FCE.

Comme le montre la figure 4.11, les résultats obtenus par notre méthode (figure 4.11.a1-a5) ressemblent aux résultats obtenus par l'algorithme EM (figure 4.11.b1-b5). Une exception est notée à la figure 11-a3 : le résultat obtenu par notre algorithme est une sur-segmentation. Cet inconvénient pourrait être dû à la façon dont l'algorithme FCE est implémenté. Par exemple, pour les régions de petites tailles telles que celles obtenues par l'algorithme EM (figure 11-b3), notre algorithme considère que ces régions sont comme du bruit. Dans cette situation, le seuillage sera plus large ce qui dans certain cas peut aboutir en une sur-segmentation. Il s'agit d'une limitation de notre méthode, mais elle dépend de l'application finale. Il est intéressant de noter que la plupart des résultats obtenus avec l'algorithme fuzzy k-means sont une sur-segmentation par rapport aux résultats obtenus avec notre algorithme et l'algorithme EM. Ceci est probablement dû au problème d'instabilité de l'algorithme fuzzy k-means en présence du bruit [86].

4.3.3 Résultats de détection de défauts dans les planches de bois

Dans l'industrie de bois, la détection des défauts (ex : les nœuds, écorces, moisissure,...etc.) sur les planches de bois est une importante tâche dans le processus du contrôle de qualité [3]. Dans ce domaine, la plupart des types de défauts apparaissent comme des régions plus noires par rapport au bois sain, lesquelles sont des indications de la présence des défauts comme les nœuds, poches de résine, ou d'autres défauts. Ainsi, nous avons appliqué notre algorithme pour détecter les régions les moins claires sur quelques échantillons de planches de bois. La figure 4.12 illustre quelques images représentatives.




Figure 4.12. Détection de défauts dans les planches de bois.
 (a1-5) : résultats obtenus avec l'algorithme FCE;
 (b1-5) : résultats obtenus avec l'algorithme JSEG [87].

La figure 4.12 (a1-a5) illustrent les résultats obtenus avec l'algorithme FCE appliqué à la détection des défauts noirs (les moins clairs) dans les planches de bois. Les résultats indiquent que les défauts dans les images, tels que les nœuds sont bien partiellement segmentés. Comme l'algorithme FCE est appliqué pour détecter les régions les moins claires dans l'image, la majorité des nœuds sont partiellement détectés étant donné que le niveau de gris d'un nœud est souvent non homogène (ex. : figure 4.12-a1). Cependant, la signature de la présence d'un nœud dans les régions détectées (ex : formes partiellement circulaires) est raisonnablement indiquée. Ce qui est un avantage intéressant de l'algorithme proposé. Nous avons comparé les résultats de l'algorithme FCE avec les résultats de segmentation obtenus avec l'algorithme JSEG proposé par Deng *et al.* [87]. Pour ce faire, nous avons utilisé le logiciel des auteurs disponible sur leur site web [88]. Le logiciel a été exécuté avec les paramètres par défaut (ces paramètres sont aussi considérés comme optimaux pour notre application). La figure 4.12 (b1-b5) illustre les résultats obtenus par l'algorithme JSEG. La figure 4.12-b1 montre que l'image de la planche est segmentée en trois régions (deux nœuds et le fond de l'image), ce qui est un bon résultat, les autres planches sont sous-segmentées, ce qui montre l'instabilité de l'algorithme. Dans la figure 4.12-b3, il n'y a pas de nœuds détectés (ceux-ci ont été fusionnés au bois) et dans la figure 12-b5 les nœuds sont fusionnés de façon inappropriés aux autres défauts du bois. Ce problème est probablement causé par le processus de fusion "merging step" dans l'algorithme JSEG, qui utilise une valeur fixe de seuil. En changeant les paramètres du logiciel de l'algorithme JSEG, le même problème d'instabilité de l'algorithme se reproduira. En conclusion, d'une façon générale (sur plusieurs exemples de planches) l'algorithme de JSEG se heurte à plus de problèmes de sur-segmentation et/ou de sous-segmentation comparativement à notre algorithme.

4.3.4 Résultats sur des images de scènes naturelles




Figure 4.13. Résultats sur des images de scènes naturelles.
(a1-3) détection des régions les plus claires par l'algorithme FCE;
(b1-3) détection des régions les plus claires par l'algorithme de Richard *et al.* [89].

Dans cette catégorie d'images, l'algorithme FCE a été appliqué pour détecter les régions les plus claires dans diverses catégories d'images de scènes naturelles. Comme montre la figure 4.13, les régions d'apparence plus claires sont raisonnablement identifiées. Dans la figure 4.13-a3, nous pouvons observer que des petites régions qui devraient être identifiées ont été ignorées. Dans cette situation, notre algorithme considère que ces régions font partie d'autres régions plus larges. Cependant, ces résultats montrent que notre méthode n'est pas affectée par le bruit. Ceci est obtenu grâce au modèle mathématique proposé (équation 1)

qui stipule que l'intensité de niveaux de gris est prise en fonction de la valeur de la clique des pixels et non seulement d'un seul pixel. Ainsi, au cours du processus de classification le niveau de gris de pixels est à la fois pris en fonction des relations spatiales et en niveaux de gris entre les pixels, ce qui n'est pas le cas pour un seuillage ordinaire. Dans la méthode proposée, l'information dans l'image n'est pas fournie par un seul pixel, mais par la "masse" d'un ensemble de pixels connexes (voisins). Ainsi, un pixel dont la valeur de son niveau de gris est relativement éloignée de ceux de ses voisins est considéré comme un cas particulier (comme un bruit).

Les résultats de la méthode proposée sont comparés par rapport aux résultats obtenus avec une méthode moderne de segmentation. C'est une méthode basée sur une approche de fusion statistique entre les régions "*statistical region merging*" proposée par Richard *et al.* [89]. L'algorithme issu de cette méthode nécessite un paramètre pour le contrôle de l'échelle de la segmentation. Les détails et les recommandations pour le choix de ce paramètre sont donnés par l'auteur ([89], section 4.4). Après avoir testé l'algorithme sur plusieurs images nous avons programmé ce paramètre à une valeur de 1000 pour obtenir une segmentation fine (pour avoir des petites régions). Le résultat de la segmentation des images de scènes naturelles est illustré à la figure 4.13-(b1-b3). L'évaluation qualitative du résultat obtenu montre que la majorité des régions les plus claires sont détectées, mais quelques autres petites régions ont été ignorées. Celles-ci ont été classées autrement. Le résultat obtenu avec l'image des feuilles d'érable (figure 4.13-a2-b2) est similaire pour les deux algorithmes.

Nous avons également poursuivi nos expériences avec succès, en utilisant la méthode proposée, sur des images infrarouges prises de notre base de données. Dans cette application l'algorithme FCE était appliqué pour détecter les régions les plus chaudes dans l'image (image thermique). Ce sont souvent les régions d'intérêt dans le domaine de l'infrarouge. En termes de niveau de gris, ces régions correspondent aux régions les plus claires dans l'image (figure 4.14).




Figure 4.14. Résultats avec des images infrarouges.
 (a1-4) détection des régions les plus claires par l'algorithme FCE;
 (b1-4) détection des régions les plus claires par l'algorithme de Richard *et al.* [89].

La figure 4.14 montre que les régions les plus claires dans les images infrarouges sont raisonnablement détectées par les deux algorithmes. La similarité de détection est forte en particulier entre les figures (4.14-a1, 4.14-b1) et (4.14-a4, 4.14-b4). Pour les autres figures, nous observons que l'algorithme FCE prend en compte des petites régions comme montre la figure 14-a2. Ces régions correspondent à des petites régions aussi perceptuellement plus

claires dans l'image. En comparaison avec les résultats de segmentation obtenus par l'algorithme proposé dans [89], ces régions ont été fusionnées aux régions les plus proches en niveaux de gris. Ceci est dû au fait que dans [89], la segmentation est contrôlée par une valeur fixe de seuillage. Dans notre méthode la valeur de seuillage est calculée de façon dynamique en mesurant l'homogénéité, en termes niveau de gris, entre les pixels. Dans la figure 4.14-a3 le résultat obtenu avec notre méthode est relativement bruité comparativement à celui obtenu par la méthode dans [89]. Ce désavantage pourrait être évité par un processus de lissage de l'image.

4.4 Évaluation quantitative

Pour faire une évaluation objective de la méthode proposée, le critère de Liu et Yang [84] a été utilisée comme une méthode d'évaluation quantitative des résultats obtenus. La fonction d'évaluation empirique est définie comme suit [84]:

$$F(I) = \frac{1}{1000(X * Y)} \sqrt{R} \sum_{i=1}^R \frac{e_i^2}{\sqrt{A_i}} \quad (7)$$

où :

- I est l'image segmentée;
- R est le nombre de régions segmentées ;
- XY sont les dimensions de l'image ;
- e_i est la somme des distances euclidiennes en niveau de gris entre les pixels de la région R_i ;


Dans l'équation 7, la valeur du produit $X*Y$ est remplacée par la somme des aires des régions détectées pour être cohérent avec notre application. Nous avons utilisé le code MATLAB Ver 7 (R14) pour effectuer le calcul de l'équation 7. Le critère de Liu et Yang stipule que plus la valeur de $F(I)$ est petite, plus les régions sont homogènes et mieux la segmentation est faite. Les résultats de la segmentation de la méthode proposée sont

comparés aux résultats obtenus par des méthodes modernes de segmentation qui sont largement utilisées dans la littérature [89].

1. L'algorithme de segmentation proposé par Richard *et al.* [89], qui est une méthode moderne basée sur une approche de fusion statistique entre les régions "*statistical region merging*" (SRM). Cet algorithme nécessite un paramètre pour le contrôle de l'échelle de la segmentation. Les détails et les recommandations pour le choix de ce paramètre sont donnés par l'auteur ([89], section 4.4). Après avoir testé l'algorithme sur plusieurs images nous avons programmé ce paramètre à une valeur de 1000 pour obtenir une segmentation fine (pour avoir de petites régions).
2. L'algorithme de segmentation proposé par Felzenszwalb *et al.* [90], qui est une méthode moderne de segmentation basée sur une approche de Graphe "*graph-based algorithm*". Cet algorithme requière trois paramètres d'entrées : l'échelle de lissage "*smoothing scale*", un seuil "*thresholding*", et la taille minimum de région "*minimum region size*". En suivant les recommandations faites par les auteurs (section 3 et 5 dans [90]) et après avoir testé l'algorithme sur plusieurs images, nous avons opté pour les valeurs (0,5, 50 et 3) comme des paramètres optimaux pour notre application.

L'évaluation est effectuée en utilisant des images synthétiques et différentes catégories d'images sélectionnées à partir de notre base de données. Nous avons sélectionné quelques images représentatives pour illustrer les résultats (figure 4.15). Les régions les moins claires dans les images détectées par la méthode proposée sont évaluées par rapport aux régions obtenues par les deux autres méthodes.

Le tableau 4.1 illustre les résultats obtenus par les trois méthodes.




(a1)

(b1)

(c1)

(d1)




(a2)

(b2)

(c2)

(d2)




(a3)

(b3)

(c3)

(d3)



(a4)

(b4)

(c4)

(d4)




Figure 4.15. Résultats de segmentation obtenus sur des images synthétiques et naturelles. (a1-a6) images originales; (b1-b6) segmentation obtenue par la méthode proposée; (c1-c6) segmentation obtenue par la méthode de Graphe [90]; (d1-d6) segmentation obtenue par la méthode SRM [89]; (a1-a3) images synthétiques; (a4-a5) images naturelles.

Tableau 4.1 Mesure de l'uniformité des régions détectées en utilisant le critère de Liu et Yang

Méthode/ Image	Méthode SRM	Méthode Graphe	Méthode proposée
Image 1	0,03	0,02	0,06
Image 2	0,3	0,19	0,17
Image 3	0,09	0,02	0,07
Image 4	1,33	1,9	0,47
Image 5	0,7	0,60	0,52
Image 6	0,37	0,17	0,21

Le tableau 1 montre les valeurs obtenues de l'uniformité, en termes de niveau de gris, des régions détectées en utilisant le critère de Liu et Yang. L'évaluation visuelle (pour un observateur) des résultats illustrés dans la figure 4.15 montre que les régions les moins claires dans les images utilisées ont été détectées par les trois méthodes. Dans le cas des images synthétiques, les régions détectées correspondent, approximativement, aux vraies régions observées dans l'image. Pour les images naturelles, nous observons que les figures 4.15-c4 et 4.15-d4 sont sur-segmentées, ce qui n'est pas le cas pour la figure 4.15-b4 (segmentée par la méthode proposée). Le tableau 4.1 montre que pour le cas des images synthétiques, l'uniformité des régions identifiées par la méthode proposée est similaire à celle des autres régions trouvées par la méthode de Graphe. Toutefois, l'uniformité de ces régions est meilleure que celle trouvée par la méthode de SRM. Dans le cas des images naturelles, les résultats montrent que la segmentation obtenue par notre méthode est légèrement meilleure que la segmentation obtenue par d'autres méthodes. Cette différence pourrait s'expliquer par le fait que l'algorithme FCE détermine le niveau du seuil en se basant sur la mesure de distance entre les cliques de pixels qui appartiennent au même groupe de pixels ayant le même niveau de gris, ce qui n'est pas le cas avec les autres algorithmes. Ainsi, l'approche adaptée par l'algorithme FCE utilisant la mesure de distance cumulative inter-pixels favorise la formation des régions homogènes.

Le temps de calcul pour notre méthode dépend de la taille de l'image et non pas du nombre de classes de niveau de gris ou des régions dans l'image comme dans le cas des algorithmes EM et fuzzy k-means, ou des paramètres de l'algorithme comme dans l'algorithme de la méthode de Graphe ou de la méthode de SRM. Par exemple, dans le cas de la figure 4.2 le temps de traitement en utilisant un processeur Pentium 4 à 3,4 GHz est d'environ 2 secondes.

La complexité de calcul de l'algorithme proposé pourrait être résumée en deux étapes : d'abord le calcul de la fonction de probabilité cumulative estimée de la densité des cliques de pixels sur l'image (équation 6), et enfin l'étape de seuillage. La complexité de ces étapes est $O(n)$, où n est le nombre total de pixels de l'image.

4.5 Conclusion

Dans ce chapitre, une méthode originale pour l'extraction des régions homogènes en termes de niveau de gris est proposée. Les régions à extraire pourraient être les plus ou les moins claires dans l'image indépendamment de leurs formes. Pour ce faire un modèle mathématique pour mesurer la distance théorique de niveau de gris entre les pixels a été développé. La stratégie de développement de ce modèle est principalement basée sur un nouveau concept de mesure de la distance, en termes de niveau de gris, entre les cliques de pixels, lesquels forment naturellement des régions. Ainsi, l'information dans l'image n'est pas fournie par un seul pixel, mais plutôt par la "masse" d'un ensemble des cliques de pixels. Ainsi, un pixel dont la valeur de son niveau de gris est relativement éloignée de celles de ses voisins est considéré comme un cas particulier (comme un bruit). Ainsi, les régions formées devraient être homogènes en termes de niveaux de gris, naturellement issues d'une même catégorie de niveau de gris des régions ou des objets de la scène. L'algorithme FCE a été testé avec succès sur plusieurs catégories d'images sous diverses conditions expérimentales. Les résultats obtenus indiquent que la méthode présentée est efficace par rapport à certaines approches modernes bien connues dans le domaine de segmentation. La simplicité conceptuelle des modèles proposés ainsi que les résultats expérimentaux confirment les propriétés attendues de la méthode proposée et illustrent la qualité des résultats obtenus.

Chapitre 5

Segmentation d'images visible et proche infrarouge dans un environnement à faible contraste: application à la détection du persillage en utilisant l'imagerie visible proche infrarouge

Dans le troisième chapitre, les principales méthodes de segmentation d'images en régions ont été exposées sous forme de revue de littérature. Cette revue, qui est assez complète, a démontré que ces méthodes pourraient être regroupées essentiellement en deux catégories : (1) méthodes qui forment des régions à partir des relations du niveau de gris entre les pixels (méthodes qui privilégient l'aspect du niveau de gris de pixels par rapport à l'aspect spatial) ; et (2) méthodes qui forment des régions en se basant à la fois sur des relations spatiales et les niveaux de gris entre les pixels (méthodes qui privilégient l'aspect spatial par rapport à l'aspect du niveau de gris). La revue de littérature a aussi démontré que la performance de ces méthodes est conditionnée par plusieurs contraintes qui sont souvent trop restrictives vis-à-vis le monde extérieur. Ces méthodes sont souvent basées sur des calculs statistiques, sous un ensemble de critères pour former les régions, sans tenir compte de l'appréciation visuelle (pour un observateur) et de l'homogénéité des niveaux de gris des régions. Apparemment, ces stratégies se restreignent à un certain type d'images, donc à des applications particulières, leur généralisation s'avère ainsi difficile. Les deux catégories de méthodes de segmentation nécessitent souvent le réglage de certains seuils et paramètres tels que les critères d'arrêt d'itérations de l'algorithme et/ou de similarité entre les pixels. L'ajustement de ces paramètres est souvent lié à des contraintes très restrictives et délicats, ce qui résulte souvent en une sur-segmentation ou une sous-segmentation de l'image.

Généralement, l'utilisation de la première catégorie de ces méthodes résulte en une sur-segmentation qui est due aux difficultés de réglage des paramètres de similarité de niveaux

de gris entre les pixels. L'utilisation de la deuxième catégorie résulte souvent en une sur-segmentation ou une sous-segmentation: plusieurs petites régions homogènes en niveaux de gris (ou des larges régions fusionnées). Ceci dû aux difficultés de réglage des paramètres établissant les relations de voisinage entre les pixels. Ces deux catégories de méthodes déterminent des régions avec des contours qui ne respectent pas nécessairement la forme des régions ou d'objets présents dans la scène. Aussi, les résultats de la segmentation dépendent de l'initialisation des algorithmes comme le choix des germes dans les méthodes de segmentation par croissance de régions (*region growing*) ou la connaissance préalable du nombre de classes issues de la segmentation. La performance des méthodes de segmentation est généralement conditionnée par un niveau de contraste élevé entre les régions adjacentes.

Pour faire face aux problématiques de segmentations révélées au deuxième et troisième chapitre, cette étude nous a conduit à privilégier le développement d'une méthode de segmentation d'image en régions qui s'adapte le mieux possible à notre application : soit la segmentation d'images visible et proche infrarouge dans un environnement complexe. Ceci en application de la détection du persillage (gras entre les fibres musculaires) à la surface et à l'intérieur-même de l'échantillon de la viande de bœuf. Dans ce contexte, la détection du persillage se fait à partir de son ombre en utilisant l'imagerie visible proche infrarouge.

Par ailleurs, nous avons démontré au deuxième chapitre que le contraste en niveaux de gris entre les régions du persillage et celles des muscles est imprévisible; il est plutôt élevé dans le cas des grandes régions du persillage et faible dans le cas de petites régions.

Dans le cas des images NIR, les images sont affectées par l'ombre; des régions qui occultent d'autres régions, ce qui pourrait causer une ambiguïté entre les régions du persillage et les zones du muscle affectées par l'ombre. Pour faire face à ces contraintes, nous avons proposé au chapitre 4 une méthode qui s'adapte bien à ce genre de problématique. Cette méthode permet de détecter efficacement les régions les plus (ou les moins) claires dans l'image indépendamment de leurs formes et du contenu de l'image. L'implémentation algorithmique de la méthode proposée s'appelait l'algorithme FCE

(“*First Class Extraction*”). Les expérimentations réalisées dans le chapitre 4 sur diverses catégories d’images en application de cet algorithme, qui est relativement général, démontrent la capacité de l’approche à faire face à diverses conditions expérimentales et indiquent que la généralisation de celui-ci comme une méthode globale de segmentation d’image en régions est une approche intéressante. Dans le cadre de nos travaux de recherche, l’algorithme FCE est généralisé pour la segmentation d’image en régions afin de détecter le persillage dans les images visibles et proches infrarouges de la viande de bœuf obtenues par la technique proposée au chapitre 2.

La suite de ce chapitre est organisée comme suit : section 5.1, présente une vue d’ensemble sur l’algorithme FCE introduit au chapitre 4. À la section 5.2, une nouvelle méthode de segmentation d’images visible et proche infrarouge appliquée à la détection du persillage dans la viande de bœuf est proposée. Les résultats et discussion qui découlent de l’application de cette méthode sont présentés à la section 5.3. À la section 5.4 une étude comparative entre l’image visible et l’image proche infrarouge est présentée. La section 5.5 présente l’évaluation de la qualité des résultats de la segmentation obtenue. Finalement, la conclusion est présentée à la section 5.6.

5.1 Vue d’ensemble sur l’algorithme FCE

L’algorithme FCE “*First Class Extraction*” est une méthode originale qui permet d’identifier les régions homogènes les plus (ou les moins) claires dans une image à niveaux de gris indépendamment de leurs tailles et/ou formes. Cette nouvelle technique, qui est relativement générale, est basée sur une nouvelle définition métrique permettant d’évaluer l’homogénéité des régions en termes de niveau de gris. Elle consiste à former des régions directement à partir des relations de niveau de gris (distance) et indirectement à partir des relations spatiales (voisinage) entre les pixels lors de la formation des régions. Le modèle mathématique permettant de mesurer ces relations lui-même a été développé dans le cadre de ce travail de recherche (chapitre 4).

Ainsi, l’homogénéité H des régions d’une classe c de niveau de gris est exprimée comme suit:

$$H(i) = F_{qc}(i) \exp(-|C_c - C_q|) \quad (1)$$

où :

- F_{qc} est la densité de probabilité cumulative estimée des cliques de pixels; C_c est le centre la classe c ; et C_q est le centre de la clique de pixels sélectionnés (voir chapitre 4 pour plus de détails).

L'équation 1 est composée du produit de deux fonctions monotones. La première fonction " F_{qc} " accroît (augmente) avec les itérations des intensités de niveaux de gris, donc en fonction des nombres des cliques de pixels. Elle contient l'information quantitative sur les cliques de pixels en fonction des intensités. Contrairement, la deuxième fonction " $\exp(-|C_c - C_q|)$ " décroît au cours des itérations et des intensités i . Cette dernière contient l'information sur la distance relative en niveaux de gris entre le niveau de gris de la classe c et le niveau de gris de la nouvelle candidate clique de pixels q . Le produit des deux fonctions (la fonction $H(i)$) augmente en cas d'un nombre significatif de cliques de pixels qui sont proches en distance (cliques de pixels proches en niveaux de gris ou appartenant à la même classe en termes de niveau de gris). Cet accroissement est visible à partir du premier groupe de cliques de pixels rencontrées. Par exemple, dans le cas des régions les moins claires dans l'image. Il décroît progressivement quand les niveaux de gris des cliques de pixels décroissent en similarité. À cause du terme exponentiel, lequel décroît rapidement, le produit des deux fonctions décroît forcément lorsque la distance de niveaux de gris entre la classe c et la nouvelle clique de pixels q est significative. Finalement, avec les itérations, la fonction $H(i)$ tend vers zéro. La figure 5.2 en illustre un exemple.

L'exemple de la figure 5.1, illustre un exemple d'application : il s'agit d'une image visible (figure 5.1-a) et une image proche infrarouge (figure 5.1-b) prises par le montage expérimental de la technique d'acquisition d'images proposée au chapitre 2. Cette application démontre, entre autres, l'intérêt de l'algorithme FCE proposé. Il s'agit d'identifier les régions du persillage de fortes densités observées dans un échantillon de viande de bœuf. Ces régions correspondent aux régions les plus claires (cas de l'image visible) et les régions les moins claires (cas de l'image proche infrarouge).




Figure 5.1. Images visible et proche infrarouge d'une surface de viande de bœuf. (a) image visible; (b) image proche infrarouge.

Les variations, en fonction de l'intensité de niveaux de gris, de l'homogénéité H (équation 1) des régions les plus claires (cas de l'image visible) et celle des régions les moins claires (cas de l'image proche infrarouge) sont illustrées à la figure 5.2. Les résultats de la détection de ces régions, en utilisant l'algorithme FCE, pour les deux types d'images sont illustrés à la figure 5.3.




Figure 5.2. Variations de l'homogénéité H et des histogrammes. (cas des images de la figure 5.1). (a) image visible; (b) image proche infrarouge.

La figure 5.2 illustre la variation (en fonction des intensités de niveaux de gris) de l'homogénéité de la classe c et de l'histogramme de l'image normalisés entre $[0, 1]$, ceci

pour le cas des images illustrées à la figure 5.1. Pour filtrer le bruit présent dans la courbe de l'homogénéité H , l'entropie floue [43] est utilisée comme un filtre de lissage pour la courbe de l'homogénéité H . Un tel lissage supprime les petites perturbations dans le signal sans trop l'affecter, ce qui facilite et améliore la précision de la détection du centre de la classe et/ou du seuil de la classe c .




Figure 5.3. Détection des régions homogènes par l'algorithme FCE.
(a) image visible (détection des régions les plus claires);
(b) image proche infrarouge (détection des régions les plus claires).

L'algorithme FCE n'a pas été conçu pour la segmentation de toute l'image, mais plutôt pour identifier les régions homogènes les plus (ou les moins) claires dans l'image indépendamment de leurs caractéristiques géométriques (forme et taille), tel qu'illustré dans l'exemple de la figure 5.3. La conception simple de la méthode développée la rend efficace pour détecter les régions homogènes et avec moins de bruit relativement à certains algorithmes connus à savoir : [8]. Les expériences sur des différentes catégories d'images présentées au chapitre 4 permettent de vérifier les propriétés attendues de l'algorithme proposé et démontrent la qualité des résultats obtenus. Ce qui nous amène à privilégier la généralisation de cet algorithme pour une segmentation complète des images visibles et proches infrarouges de la viande de bœuf.

5.2 Méthode proposée

Au chapitre 4, nous avons démontré que l'algorithme FCE est une approche intéressante pour identifier les régions homogènes en termes de niveaux de gris dans une image. Aussi, les résultats expérimentaux de cet algorithme sur diverses catégories d'images démontrent que les régions détectées par l'algorithme sont homogènes, formées par des pixels connexes de niveaux de gris uniforme. Les évaluations qualitatives et quantitatives des résultats obtenus sont raisonnablement proches de l'intuition humaine (l'observateur). Ceci démontre la cohérence du modèle mathématique proposé pour l'algorithme FCE. L'analyse statistique des régions obtenues montre que les pixels ont typiquement une distribution gaussienne normale [65], ce qui est une des raisons pour laquelle il est intéressant de généraliser l'algorithme FCE pour la segmentation totale de l'image en régions. Par ailleurs, dans le cas particulier d'une image composée de trois classes de niveaux de gris (une hypothèse), l'algorithme FCE lui-même pourrait être utilisé tel qu'il est pour la segmentation de toute l'image en régions. Ceci pourrait se faire de la manière suivante: on applique d'abord l'algorithme FCE pour la détection des régions les moins claires (ex : classe 1), et par la suite pour la détection des régions les plus claires (ex : classe 2). Les restes des régions dans l'image sont la troisième et la dernière classe de régions. Cette hypothèse, qui est relativement facile à valider, a été vérifiée avec succès sur quelques images. Toutefois, l'application itérative de l'algorithme FCE pour une segmentation générale et plus complexe, par exemple sur une image ayant plusieurs catégories de classes de régions, n'est pas adéquate. Dans ce contexte, le mot "itérative" signifie que l'algorithme FCE sera appliqué pour détecter les régions les plus (ou les moins) claires dans l'image, puis il sera appliqué itérativement sur le reste de l'image (sans considérer les régions détectés précédemment) jusqu'à la segmentation de toute l'image. La figure 5.4 illustre les résultats de la segmentation "itérative" de l'algorithme FCE appliquée aux images visible et proche infrarouge de la figure 5.1.




Figure 5.4. Segmentation itérative des images en régions par l'algorithme FCE.
(cas des images de la figure 5.1).

(a) image visible; (b) image proche infrarouge.

Comme montre la figure 5.4, la majorité des régions du persillage dans l'image proche infrarouge sont fusionnées à d'autres régions de l'image. Ce problème est dû en particulier à l'ombre, au faible contraste entre le persillage et les muscles et à la variation de l'éclairage.

Ainsi, pour aboutir à notre objectif, qui est le développement d'une méthode de segmentation d'image en région qui s'adapte bien à notre application, la stratégie qu'on a adoptée est de procéder à une segmentation en deux étapes :

1. généraliser l'algorithme FCE pour une segmentation locale en se limitant par exemple à des petites fenêtres de l'image (une ROI). Contrairement à toute l'image qui est plus large, dans cette situation, le nombre de classes est forcément réduit; et
2. en utilisant l'information globale de toute l'image, telles que les régions les plus (ou les moins) claires, ainsi que les résultats obtenus dans l'étape 1. L'algorithme FCE pourrait être généralisé pour la segmentation totale de l'image en régions. Afin d'aboutir à une segmentation robuste, les deux étapes 1. et 2. ont été appliquées à des ROIs de tailles variables, ce qui résulte finalement en une segmentation multi-hiérarchique.

5.2.1 Généralisation de l'algorithme FCE pour une segmentation locale

Dans cette étape l'algorithme FCE est appliqué récursivement à une région de taille réduite : c'est une ROI de l'image initiale à segmenter (une fenêtre). Cette fenêtre pourrait être vue aussi comme une petite image. Dans la suite du texte, le mot *imagerie* est utilisé pour désigner cette petite image. Dans ce travail, la taille (les dimensions : longueur*largeur) de l'*imagerie* est variable. Elle est contrôlée en temps réel lors de la segmentation selon deux critères: 1) le nombre de classes minimal de niveaux de gris estimé dans l'*imagerie* à segmenter; et 2) un seuil qui fixe la taille minimum de l'*imagerie*. La taille minimale est choisie arbitrairement selon l'application; elle dépend de la résolution. Par exemple dans notre application la taille minimale de l'*imagerie* est fixée à 15x15 pixels, ce qui correspond dans notre système proposé au chapitre 2 (figure 2.8) à une région de 2x2 mm (soit une résolution de 7,5 pixel/mm). Ce qui permet de chercher de fines particules de persillage.

Ainsi, l'algorithme FCE généralisé pour une segmentation locale se décrit selon les étapes suivantes :

1. appliquer l'algorithme FCE pour extraire les régions les plus claires dans l'*imagerie*.
Les régions détectées dans cette étape sont les régions segmentées;
2. appliquer l'algorithme FCE pour extraire les régions les moins claires dans l'*imagerie*;
3. mettre à jour les régions segmentées;
4. répéter l'étape 1. ou 2. jusqu'à ce que l'*imagerie* soit complètement segmentée;
5. fusionner les pixels isolés non classés aux régions voisines les plus probables. Cette étape, elle-même, est le processus de fusion et d'agrandissement des régions qui clôture l'algorithme de la segmentation locale.


Le résultat issu de cet algorithme est une carte de segmentation, qui est un ensemble de régions identifiées par des étiquettes (*labels*) numérotées (figure 5.5).

5.2.2 Processus de fusion et d'agrandissement des régions

Le processus de fusion et d'agrandissement des régions est une étape de traitement qui consiste à fusionner les régions adjacentes, jugées similaires selon un ou des critères prédéfinies (ex : niveau de gris et/ou forme). D'une façon générale, les petites régions et les pixels isolés sont fusionnés aux régions adjacentes les plus similaires. Ce processus permet à la fois d'agrandir des régions et d'éviter le problème de sur-segmentation. À cette étape de travail (segmentation locale sur une imagerie), le processus adopté consiste à intégrer (fusionner) les pixels isolés aux régions adjacentes les plus probables en voisinage : c'est-à-dire que l'intégration d'un pixel à une région adjacente ne dépend pas du niveau de gris des régions, mais plutôt du nombre des pixels des régions situés dans le voisinage du pixel à intégrer : un pixel isolé s'intègre tout simplement à la région dont le nombre de pixels voisins est plus élevé. Cette technique, permet d'obtenir des régions de persillage avec des contours plus doux et plus fidèles aux formes réelles des régions segmentées.

5.2.3 Résultats de la segmentation locale

La méthode de segmentation locale proposée ci-dessus a été appliquée sur un nombre important d'images (environ 500 images qui ont été obtenues à partir d'une trentaine d'images). La figure 5.5 illustre un exemple typique des résultats obtenus avec les deux images visible et proche infrarouge de la figure 5.1. Chaque image a été découpée en 16 images (4 en longueur et 4 en largeur).






Figure 5.5. Résultats de la segmentation locale.
 (a) imagettes visibles; (b) imagettes proches infrarouges;
 (c) cartes de la segmentation locale des imagettes visibles;
 (d) cartes de la segmentation locale des imagettes proches infrarouges.

La figure 5.5 montre les résultats de la segmentation locale appliquée aux deux images visible et proche infrarouge de la figure 5.1; les deux images sont découpées en imagettes. Le résultat de la segmentation (figure 5.5 c et d) est illustrée sous forme des cartes d'imagettes, les couleurs des cartes étant choisies arbitrairement à titre d'illustration des résultats. Dans le processus général de la segmentation, qui sera présenté à la section suivante, la taille de l'imagette sera variable et se calcule en temps réel lors de l'implémentation de l'algorithme.

Pour illustrer les résultats de la segmentation sur des imagettes, chaque classe de régions (classe de niveau de gris) est colorée individuellement, la première classe (étant la plus claire dans le cas de l'imagette visible, la moins claire dans le cas de l'imagette proche infrarouge) est colorée en blanc, la deuxième classe est en rouge, la troisième classe est en bleu et éventuellement le reste des classes est coloré avec une couleur aléatoire. Ce choix de coloration est arbitraire à titre d'illustration et de présentation des résultats de la segmentation.

L'évaluation qualitative de la segmentation locale montre que les résultats sont raisonnablement cohérents avec un jugement visuel (par rapport à l'observateur). Par

exemple, en comparant visuellement la première classe détectée (colorée en blanc) dans la carte de l'imagette segmentée par rapport à l'imagette originale. Celle-ci correspond effectivement aux régions les plus claires dans le cas de l'imagette visible et aux régions les moins claires dans le cas de l'imagette proche infrarouge. Dans certaines imagettes, la première et la deuxième classe (colorées respectivement en blanc et en rouge) sont similaires. Ces deux classes pourraient correspondre (les deux) aux régions de persillage mais pas nécessairement. Ces deux classes pourraient alors être fusionnées ensemble lors du processus de reconnaissance du persillage (voir la section suivante). Les autres classes, correspondent souvent à d'autres détails dans l'imagette de l'échantillon de viande. Dans notre application, il n'y a pas d'intérêt pour les analyser car on s'intéresse juste à la détection du persillage. Ainsi, dans ce contexte la qualité de la segmentation locale pourrait être jugée à la fois en se basant sur l'efficacité de l'algorithme FCE lui-même, laquelle a été démontrée dans le chapitre 4; puis sur l'efficacité de la segmentation finale de toute l'image, laquelle est démontrée plus bas à la section 5.5. Par ailleurs, la méthode proposée a été appliquée à un nombre important d'imagettes (on estime 500 imagettes obtenues à partir d'une trentaine d'images). Les résultats obtenus ont illustré la validité de l'approche proposée et démontrent que la méthode proposée est raisonnablement efficace et qu'elle est effectivement une bonne voie pour développer une méthode globale de segmentation d'image en régions.

5.2.4 Algorithme

Dans ce travail de recherche, l'objectif de la segmentation est d'isoler le persillage par rapport aux muscles dans la viande. Ceci pour les deux catégories d'images : visible et proche infrarouge. La figure 5.1 illustre un exemple typique d'images à segmenter. L'analyse du contenu de ces deux images, à savoir par histogramme, des intensités de pixels montre qu'il est difficile de trouver toujours des seuils permettant de bien identifier les particules du persillage. Ceci est particulièrement vrai pour l'image proche infrarouge. Nous avons par ailleurs démontré aux chapitres 2, 3 et 4 à travers plusieurs exemples que l'analyse de ce type d'image est souvent complexe. Cette complexité est due, entre autres, au faible contraste entre l'ombre des particules du persillage et le muscle. La similitude imprévue entre l'ombre du persillage (vrai ombre) et l'ombre causée par la variation de la

lumière en transmission à travers les muscles (fausse ombre) ajoute des difficultés additionnelles lors du processus de la segmentation. Comme ce phénomène n'existe pas dans le cas d'une image visible, et puisque le persillage observé dans l'image visible fait partie de celui observé dans l'image proche infrarouge, il est alors pertinent de bénéficier du résultat de la segmentation de l'image visible, malgré que le persillage se limite à la surface. Ceci facilite le processus de la segmentation de l'image proche infrarouge. Cette stratégie, à notre avis, permet de bénéficier de l'avantage de la segmentation de l'image visible sans pour autant partager ses inconvénients tout en ayant des meilleurs résultats. Ainsi, la méthode proposée pour la segmentation d'images se décompose en deux étapes :

1. généraliser l'algorithme FCE pour la segmentation de l'image visible; et
2. utiliser le résultat de la segmentation obtenu à l'étape 1. pour généraliser l'algorithme FCE pour la segmentation de l'image proche infrarouge.

Pour ce faire, nous allons procéder d'abord par la description de quelques processus de traitement qui font partie des architectures des algorithmes de segmentation. Ces processus sont : l'hypothèse à considérer lors de la segmentation, le processus de reconnaissance du persillage, le processus de relaxation des régions du persillage et finalement le protocole de découpage de l'image en imageries.

❖ Hypothèse

Cette hypothèse stipule que :

1. il existe toujours des régions et/ou des particules de persillage dans un échantillon de viande de bœuf quelque soit le grade de la viande;
2. dans une image visible, les régions les plus claires, en terme de niveau de gris, observées sur un échantillon de viande correspondent nécessairement à des régions et/ou à des particules de persillage.

❖ Processus de reconnaissance des régions du persillage

Le processus de reconnaissance des régions du persillage est une étape cruciale dans l'algorithme général de segmentation. L'objectif de ce processus est d'identifier les régions du persillage parmi les régions segmentées.

En se basant sur l'hypothèse que l'image visible est éventuellement composée de régions de persillage, qui sont les plus claires, et de régions musculaires ou autres, qui sont moins claires, le processus de reconnaissance des régions du persillage adopté suit un ensemble de critères qui dépend du type d'image à traiter. Pour ce faire, nous définissons les variables suivants :

- μ_r et σ_r sont respectivement la moyenne et la variance des régions du persillage identifiées par l'algorithme FCE dans l'image visible (les régions les plus claires);
- μ_v et σ_v sont respectivement la moyenne et la variance des régions du persillage identifiées par la segmentation globale de l'image visible (toutes les régions du persillage);
- m_v est la moyenne de pixels de la classe la plus claire (cas de l'image visible);
- m_p est la moyenne de pixels de la classe la moins claire (cas de l'image Proche infrarouge).

Ainsi, les critères de reconnaissance qui devraient être respectés sont :

a) Pour l'image visible :

1. le nombre de classes des régions dans l'imagerie issue de la segmentation locale doit être supérieur ou égale à trois;
2. $(m_v > \mu_r - 3*\sigma_r)$;
3. l'aire des régions du persillage ne dépasse pas la moitié de celle de l'imagerie.

b) pour l'image proche infrarouge :

1. le nombre de classes des régions dans l'imagerie issue de la segmentation locale doit être supérieur ou égale à quatre;

2. $(m_p < \mu_v + 3 * \sigma_v)$;
3. l'aire des régions du persillage ne dépasse pas la moitié de celle de l'imagette.

❖ Relaxation des régions du persillage

La relaxation des régions du persillage est une étape de traitement morphologique appliquée aux régions du persillage obtenues à l'issue de la segmentation. Elle permet, entre autres, d'avoir : des régions avec moins de trous (ex : pas de pixels vides à l'intérieurs des régions); des régions avec des contours plus doux, et; moins de risque pour le problème de sur-segmentation. Pour ce faire, le processus de relaxation des régions du persillage comprend les fonctions suivantes :

- les pixels et les régions trouées à intérieur d'une région du persillage sont intégrés à la même région;
- si un pixel appartenant au contour d'une région du persillage est vide et que dans un voisinage de 3 par 3 au moins 5 pixels font partie de la région du persillage, celui-ci sera intégré à la même région;
- les régions de taille minuscule (moins de 5 pixels) sont supprimées.

❖ Protocole de découpage de l'image en imagettes

Les analyses expérimentales réalisées au deuxième chapitre ont révélé la nature des images à segmenter pour l'isolation du persillage dans la viande du bœuf. En effet, pour les deux types d'images visible et proche infrarouge, les régions du persillage ont des tailles (surfaces) très variables allant de régions minuscules (particules de quelques pixels connexes) à des régions de tailles plus importantes. Ceci affecte le niveau du contraste entre les régions du persillage et celui du muscle. Dans ce contexte, une taille d'imagette fixe n'est pas souhaitable. De plus, compte tenu de ce que l'image proche infrarouge (image 2D) est une projection orthogonale de l'échantillon de la viande (volume 3D), les régions du persillage s'occultent les unes des autres, ce qui pourrait causer une ambiguïté entre les régions du persillage et les zones de muscle affectées par l'ombre.

Pour faire face à ces contraintes, nous avons adopté un protocole de découpage hiérarchique multiple de l'image en imagettes qui s'adapte bien à notre application (figure 5.6).




Figure 5.6. Protocole de découpage de l'image en imagettes lors du processus de la segmentation.

La figure 5.6 illustre graphiquement le protocole de découpage de l'image en imagettes. Chacune de ces imagettes est segmentée individuellement par l'algorithme FCE généralisé pour une segmentation locale (paragraphe 5.2.3). L'image ou l'imagette de départ est découpée (*split*) en quatre imagettes égales tel que illustré à la figure 5.6. Prenons par exemple l'image (A) de la figure 5.6. Celle-ci est découpée en quatre, donnant ainsi naissance à 10 imagettes qui sont : A1, A2, A3, A4, (A5 = A1&A2), (A6 = A3&A4), (A7 = A1&A3), (A8 = A2&A4), puis A9 et A10 qui sont la moitié de A, prises au milieu respectivement dans le sens horizontal et vertical de A. Cette stratégie offre l'avantage de faire une segmentation hiérarchique multiple de l'image. Ainsi, la stratégie de découpage adoptée permet, entre autres, de prendre en compte de fins détails dans l'image tels que les petites particules du persillage, et de faire une segmentation locale puisque la taille de l'imagette est réduite lors du processus de découpage. Le traitement multiple adopté (ex : traiter A1 seule, A2 seule, puis A1&A2 ensemble, aussi l'exemple de A9 et

A10) permet de mieux conserver les frontières des régions et d'éviter les problèmes d'avoir des régions avec des contours linéaires (avoir des lignes limitant les frontières des régions) qui pourraient avoir lieu lors de la segmentation. Aussi, comme la taille de l'imagette change, les régions de persillage à faible contraste seront plus faciles à segmenter. Ce protocole permet aussi d'éviter la sous-segmentation de l'image. Rappelons que le problème de sur-segmentation est contrôlé dans une première phase par le processus de fusion et d'agrandissement des régions (paragraphe 5.2.2), puis par le processus de reconnaissance du persillage. Le protocole de découpage s'achève une fois que la taille minimale de l'imagette est atteinte.

Ainsi, de ce protocole de découpage de l'image en imagettes, un algorithme de segmentation des imagettes par un processus de récurrence est proposé.

5.2.4.1 Algorithme de récurrence

Le processus de l'algorithme de segmentation des imagettes par récurrence se résume comme suit :

1. appliquer l'algorithme de segmentation locale présenté au paragraphe 5.2.1 sur l'imagette en cours. À cette étape, le résultat est une carte de régions segmentées tel qu'illustré à l'exemple de la figure 5.5.
2. appliquer le processus de reconnaissance du persillage sur l'imagette segmentée afin d'identifier les éventuelles régions de persillage.
3. mettre à jour les régions de persillage segmentées. Lors de cette étape, les régions segmentées s'agrandissent au fur et à mesure, au cours du processus de découpage et de segmentation.
4. Retourner à l'étape 1 si les critères de la fin de segmentation ne sont pas établis.

L'algorithme de segmentation des imagettes s'applique récursivement sur toutes les imagettes découpées selon le protocole de découpage illustré à la figure 5.6. L'algorithme achève la segmentation de toute l'image une fois que toutes les imagettes sont parcourues.

L'algorithme global de segmentation qui est un algorithme hybride, qui combine les segmentations des deux types d'images : visible et proche infrarouge, est illustré à la figure 5.7.

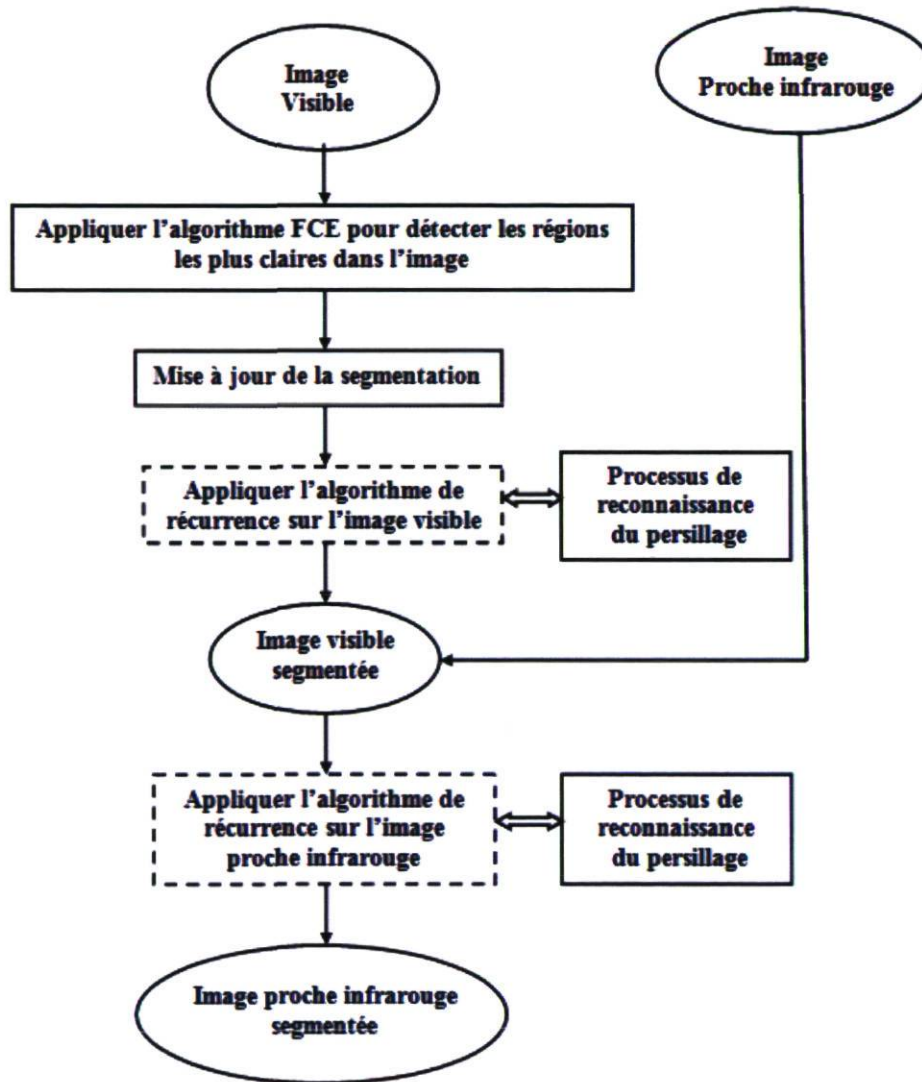


Figure 5.7. Généralisation de l'algorithme FCE pour la segmentation des images visible et proche infrarouge.

La figure 5.7 illustre l'approche proposée pour la segmentation des images visible et proche infrarouge appliquée à l'isolation du persillage dans la viande de bœuf. L'approche adoptée

consiste, entre autres, à segmenter l'image visible en premier lieu étant donné que la segmentation de celle-ci est relativement facile par rapport à la segmentation de l'image proche infrarouge. Afin de bénéficier de cet avantage, le résultat de la segmentation de l'image visible est utilisé comme une source d'information par l'algorithme pour segmenter l'image proche infrarouge. En effet, le persillage détecté par l'image visible est intégré initialement au processus de segmentation de l'image proche infrarouge.

Ainsi, l'algorithme de segmentation des images visible et proche infrarouge se résume comme suit : initialement, l'algorithme FCE est appliqué pour isoler les régions les plus claires dans l'image visible. Ces régions, correspondent nécessairement à des régions et/ou des particules de persillage telle que stipulé dans l'hypothèse ci-haut mentionnée. À cette étape, la moyenne et la variance des régions de persillage identifiées sont calculées pour être utilisés dans le processus de reconnaissance des régions du persillage (voir processus de reconnaissance du persillage). Les régions segmentées du persillage sont ainsi mises à jour. À la suite de cette étape, l'algorithme de récurrence (ci-haut présenté) est déclenché pour segmenter les imagerie visible en régions du persillage et du muscle. À la fin de ce processus, l'image visible est complètement segmentée. Le processus de relaxation des régions du persillage décrit plus haut est appliqué.

À la suite de cette étape, le processus de la segmentation de l'image proche infrarouge se déclenche. Ainsi, le résultat de la segmentation de l'image visible est utilisé comme une source d'information par l'algorithme lors du processus de reconnaissance du persillage à partir de l'image proche infrarouge. L'algorithme de récurrence est déclenché, cette fois pour segmenter les imagerie proche infrarouge. À la fin de ce processus, le processus de relaxation des régions du persillage est appliqué. Le résultat final issu de cet algorithme est une segmentation de deux types d'images, visible et proche infrarouge, en régions de persillage et de muscle.

Malgré la complexité de la segmentation, dans certaines situations telle que le cas des régions du persillage à faible contraste, en particulier pour le cas de l'image proche

infrarouge, les résultats obtenus démontrent que le processus adopté pour la segmentation est efficace. Le paragraphe 5.3 illustre le résultat obtenu avec les images de la figure 5.1.

5.3 Résultats et discussion (cas de la figure 5.1)

La méthode de segmentation proposée pour l'isolation du persillage dans la viande de bœuf a été appliquée sur un nombre important d'images visibles et proches infrarouges prises de notre base de données. Plus de 100 images ont été testées. Ces images, ont été prises sous différentes conditions d'acquisition avec le montage expérimental de la technique proposée au chapitre 2 (figure 2.8). Dans cette section, le résultat de la segmentation obtenue avec les images de la figure 5.1 est présenté. Toutefois, divers résultats représentatifs sont présentés à la section 5.5. Cette dernière est consacrée à l'évaluation de la qualité de la segmentation obtenue par la méthode proposée. Par ailleurs, la figure 5.8 illustre le résultat de la segmentation obtenu avec les deux images visible et proche infrarouge de la figure 5.1.




Figure 5.8. Résultats de la méthode de la segmentation.
(a) image visible; (b) image proche infrarouge.

La figure 5.8 illustre le résultat de la segmentation des deux images visible et proche infrarouge de la figure 5.1. L'évaluation visuelle de la segmentation de l'image visible (figure 5.8-a) montre que toutes les régions du persillage sont raisonnablement détectées. Ces régions sont de tailles variables allant de petites régions, composées de quelques pixels, à des régions de tailles plus importantes. De plus, le contraste en niveaux de gris entre les

régions et le muscle est largement variable. Par exemple, dans certaines zones de l'image, les régions du persillage sont similaires à celles du muscle. Ce qui complique le processus de segmentation.

Quant à la segmentation de l'image proche infrarouge, l'évaluation visuelle de la qualité de la segmentation montre également que les régions du persillage sont raisonnablement toutes détectées quelque soient leurs catégories (de forme, de taille, de contraste, de profondeur, et même celles de petites tailles). Toutefois, on dénombre deux fausses détections de régions du persillage. Ceci démontre que la méthode de segmentation développée est, raisonnablement, robuste compte tenu de la complexité du traitement associé à l'image proche infrarouge. Plusieurs phénomènes contribuent à la complexité de la segmentation de l'image proche infrarouge, entre autres : a) l'effet de l'ombre sur la qualité de l'image causé par les particules du persillage qui sont déposées à différentes profondeurs de l'échantillon de la viande. Ceci provoque une similitude imprévue entre l'ombre des régions du persillage (vrai ombre) et l'ombre causé par la variation de la lumière en transmission à travers les muscles (faux ombre); b) la variation du contraste entre les muscles et les régions du persillage; et finalement, c) la variation de la profondeur des régions du persillage. La performance de la méthode de segmentation proposée se manifeste aussi au niveau de la détection des petites régions du persillage en dessous de la surface. Cette efficacité, est entre autres, due à la méthode de segmentation locale proposée dont laquelle la taille de l'imagette est variable.

Traditionnellement, les méthodes de segmentation sont accompagnées par une méthode de fusion des régions pour éviter le problème de sur-segmentation [91]. Les concepts de ces algorithmes sont souvent basés sur des mesures de similarité en niveaux de gris entre les régions à fusionner. Les résultats de ces algorithmes sont soit une sur-segmentation ou une sous-segmentation. Ceci est dû aux paramètres (ex : seuils) à fixer lors du processus de fusion : ceux-ci sont difficiles à ajuster. Dans notre méthode de segmentation et de détection, les régions de persillage sont identifiées au fur et à mesure dans le processus de la segmentation, puis elles sont fusionnées ensemble pour construire des régions plus

complètes de persillage. Cette tâche est accomplie par un processus de fusion et d'agrandissement des régions segmentées.

Dans cette section, l'évaluation qualitative-visuelle du résultat de la segmentation des images visible et proche infrarouge (images typiques de ce travail de recherche) montre que la méthode proposée est efficace pour la segmentation du persillage dans la viande. Toutefois, une évaluation qualitative et quantitative de la qualité des résultats de la segmentation accompagnée par divers résultats est présentée à la section 5.5.

5.4 Étude comparative entre l'image visible et l'image proche infrarouge

Les résultats de la segmentation obtenus au paragraphe précédent démontrent que la lumière proche infrarouge est une bonne technique pour faire une évaluation préliminaire non-destructive du persillage contenu dans l'échantillon de viande en test. Ces résultats démontrent qu'il est possible de détecter le persillage non seulement à la surface comme les méthodes traditionnelles en vision [8], mais aussi en profondeur de la viande. L'image visible est relativement commode à traiter alors que l'analyse d'image proche infrarouge est complexe, mais elle est plus riche en information par rapport à l'image visible (voir chapitre 2, paragraphe 2.2). Par ailleurs, le résultat de la segmentation d'image pourrait fournir aussi d'autres types d'information, de nature quantitative sur l'avantage de l'image proche infrarouge par rapport à l'image visible. Pour ce faire, moyennant le résultat de segmentation de deux images : visible et proche infrarouge, des calculs statistiques permettent d'extraire des informations pertinentes sur la quantité du persillage dans la viande. La figure 5.9 illustre le persillage détecté dans les deux types d'images.




Figure 5.9. Illustration du persillage détecté par les deux types d'images.
(rouge : détection par l'image visible; blanc détection par l'image proche infrarouge)

La figure 5.9 montre l'image proche infrarouge de l'échantillon de viande de bœuf (figure 5.1-b). Sur cette image, les régions du persillage obtenues par la segmentation de l'image visible (contours rouges), et par la segmentation de l'image proche infrarouge (contours blancs) sont identifiées. L'analyse visuelle (pour un observateur) des régions du persillage détectées moyennant l'image proche infrarouge montre que les régions détectées par l'image visible sont moins claires que celles détectées uniquement par l'image proche infrarouge. Ces régions sont à la surface de la viande, souvent se prolongent en profondeur de l'échantillon. Ainsi, ce type de régions, absorbe d'avantage la lumière proche infrarouge en transmission par rapport aux autres régions. Les mesures quantitatives du persillage détecté par les deux types d'images sont exprimées de la manière suivante :

- L'Aire de toutes les régions de persillage obtenu par l'image Visible (AV) = 7658 pixels, soit une proportion de 11,11% de la surface de l'image ;
 - L'Aire de toutes les régions de persillage obtenu par l'image proche Infrarouge (AI) = 23950 pixels, soit une proportion de 34,75% de la surface de l'image.
- Ainsi, on introduit la formule suivante :

$$\left(\frac{AI - AV}{AI} \right) * 100 \approx 68\% \quad (2)$$

Ces statistiques montrent l'importance de la quantité de persillage caché sous la surface par rapport à la quantité du persillage observé traditionnellement en surface.

5.5 Évaluation de la qualité de la segmentation

La segmentation d'image est une étape cruciale dans un processus d'interprétation visuelle. Toutefois, la performance de cette interprétation elle-même n'est garantie que par la performance des résultats de la segmentation. Traditionnellement, l'efficacité d'une méthode de segmentation est évaluée qualitativement par l'illustration de quelques résultats de traitement. Cette évaluation est essentielle car elle permet de faire un jugement rapide basé sur l'expertise de l'expérimentateur. Toutefois, elle est plutôt basée sur un jugement visuel, c'est-à-dire sur l'appréciation et l'intuition humaine. Par conséquent, des critères d'évaluation de la qualité de segmentation sont alors nécessaires. Ainsi, une évaluation qualitative et quantitative de la qualité de la segmentation est alors indispensable.

5.5.1 Évaluation qualitative

Afin de faire une évaluation objective et démontrer les avantages de la méthode proposée, les résultats de la segmentation sont comparés aux résultats obtenus avec d'autres algorithmes connus en littérature, à savoir : l'algorithme de fuzzy k-means [92] et l'algorithme EM "*Expectation Maximisation*" [65]. Les deux algorithmes sont alors appliqués pour segmenter les deux types d'images en régions : persillage et muscle. Pour ce faire, le même protocole de segmentation générale suivi par la méthode proposée est utilisé (figure 5.7). Ainsi, au cours du processus de traitement, l'image a été découpée en imasettes en respectant le même protocole de découpage de l'image utilisé par la méthode proposée (figure 5.6). Les algorithmes de fuzzy k-means et EM nécessitent de fixer le nombre de classes désirées comme un paramètre d'entrée. Nous avons utilisé le même nombre de classes (pour chaque imasette) calculé par l'algorithme FCE lors de la segmentation locale des imasettes. Ce choix nous permet de faire une comparaison plus judicieuse entre les trois algorithmes. Ainsi, à partir de la segmentation de chaque imasette les éventuelles régions du persillage sont fusionnées aux autres régions obtenues à partir des autres imasettes en respectant aussi le même processus de reconnaissance du persillage utilisé par la méthode proposée. La figure 5.10, illustre les résultats de la segmentation des images visible et proche infrarouge de la figure 5.1 obtenus par les trois algorithmes : algorithme proposé, fuzzy k-means et l'algorithme EM.




Figure 5.10. Évaluation qualitative de la méthode de la segmentation.
gauche: image visible; droite: image proche infrarouge;
(a1,b1) méthode proposée; (a2,b2) algorithme fuzzy k-means et (a3,b3)
algorithme EM.

La figure 5.10 montre le persillage détecté dans les images visible et proche infrarouge en utilisant trois méthodes différentes. Comme le montre la figure 5.10, les résultats sont différents pour les trois méthodes. Dans le cas de l'image visible, le persillage en surface a été segmenté (détecté) par les trois méthodes avec des différences mineures. Dans l'image segmentée par l'algorithme fuzzy k-means (figure 5.9-a2), on voit qu'il y a des petites régions détectées comme des régions de persillage et que certaines régions de persillage détectées sont un peu plus larges que les régions réelles du persillage observées dans l'image. L'image visible est alors sur-segmentée par l'algorithme fuzzy k-means. Ce phénomène est moins important avec l'algorithme EM (figure 5.9-a3). Pour l'image proche infrarouge, les deux algorithmes fuzzy k-means et EM (figure 5.9-b2 et Figure 5.9-b3) produisent des résultats sur-segmentés. Ceci est possiblement dû au problème d'initialisation des algorithmes. Aussi, dans ces algorithmes, au cours du processus de classification, la décision de classification de chaque classe dépend de la probabilité de classification des autres classes, ce qui n'est pas le cas pour la méthode de segmentation proposée dans le cadre de ce travail de recherche.

La segmentation produite par la méthode proposée est moins bruitée comparativement aux deux autres méthodes (moins de fausses détections pour les régions minuscules de persillage). Ceci est dû au concept de cliques de pixels lors du processus de seuillage de l'algorithme FCE, qui stipule que la classification de pixels ne dépend pas seulement du niveau de gris du pixel lui-même, mais aussi de celui de ses voisins.

5.5.2 Évaluation quantitative

L'évaluation qualitative de la qualité de la segmentation est une approche simple et rapide car elle ne requiert pas l'implémentation d'une méthode d'évaluation. Mais, elle n'offre pas de résultats précis qualitatifs sur la qualité de la segmentation car elle est subjective et dépend de l'expérimentateur et de son expérience. De ce fait, l'utilisation des règles mathématiques et statistiques pour établir des critères qualitatifs d'évaluation de la qualité de la segmentation s'avère nécessaire. Ainsi, plusieurs critères d'évaluation de la qualité de la segmentation ont été proposés dans la littérature [93]. Ils sont généralement basés sur des calculs statistiques, mais aucun d'entre eux n'est absolu ou générique pour achever la

tâche d'évaluation. Afin de procéder à une évaluation qualitative et démontrer les avantages de la méthode proposée, les résultats de la segmentation obtenus par notre méthode sont comparés avec les résultats obtenus avec d'autres méthodes courantes issues du domaine de la segmentation d'images, à savoir : la méthode proposée par Felzenszwalb *et al.* [90] et celle proposée par Richard *et al.* [89] :

1. la méthode proposée par Felzenszwalb *et al.* [90], est une méthode moderne de segmentation basée sur une approche de Graphe "*graph-based algorithm*". L'algorithme de cette méthode requiert trois paramètres d'entrées : l'échelle de lissage "*smoothing scale*", un seuil "*thresholding*", et la taille minimum de région "*minimum region size*". En suivant les recommandations faites par les auteurs (section 3 et 5 dans [90]) et après avoir testé l'algorithme sur plusieurs images, nous avons opté pour les valeurs (1,5, 100 et 1) comme des paramètres optimaux pour notre application.
2. la méthode proposée par Richard *et al.* [89], est une méthode moderne basée sur une approche de fusion statistique entre les régions "*Statistical Region Merging*" (SRM). Cet algorithme nécessite un paramètre pour le contrôle de l'échelle de la segmentation. Les détails et les recommandations pour le choix de ce paramètre sont donnés par l'auteur ([89] section 4.4). Après avoir testé l'algorithme sur plusieurs images nous avons programmé ce paramètre à une valeur de 1000 pour obtenir une segmentation fine (obtenir de petites régions).

Les deux méthodes (Graphe et SRM) sont appliquées pour segmenter les imagerie en respectant le même protocole de découpage de l'image en imagerie (figure 5.6), en suivant le même processus de reconnaissance du persillage adopté par la méthode proposée et en appliquant le même principe pour la segmentation générale des images visible et proche infrarouge utilisé par la méthode proposée (figure 5.7).

Ainsi, les résultats obtenus avec divers échantillons de viande de bœuf sont évalués quantitativement (numériquement) dépendamment des régions détectées en utilisant le critère de Borsotti [93]. Ce critère, qui ne requiert aucun ajustement des paramètres, est raisonnablement proche du jugement visuel, il pourrait servir pour qualifier le résultat de la

segmentation et la mesure de l'uniformité intra-région. La fonction d'évaluation empirique de Borsotti est définie comme suit [93] :

$$Q(I) = \frac{\sqrt{R}}{1000.XY} \sum_{i=1}^R \left[\frac{e_i^2}{1 + \log A_i} + \left(\frac{R(A_i)}{A_i} \right)^2 \right] \quad (3)$$

où :

- R est le nombre de régions segmentées ;
- XY sont les dimensions de l'image ;
- e_i est la somme des distances euclidiennes entre les vecteurs couleurs des pixels de la région R_i et le vecteur couleur attribué à la région R_i dans l'image segmentée (en général la moyenne des couleurs de la région) ;
- $R(A_i)$ est le nombre de régions ayant une aire égale à A_i .

L'équation (3) est composée en somme de deux termes : le premier terme favorise les régions homogènes. Alors que le deuxième terme a une valeur élevée quand il y a beaucoup de petites régions, ce qui pénalise les images sur-segmentées en beaucoup de régions de même taille. Les régions d'un résultat de segmentation doivent être homogènes, contenir peu de petits trous, et avoir des caractéristiques d'homogénéité significativement différentes pour les régions adjacentes. Ce critère, stipule que plus la valeur obtenue est petite, plus la segmentation est uniforme et les régions sont homogènes.

La figure 5.11 illustre les résultats obtenus par les trois méthodes de segmentation et le tableau 5.1 présente les valeurs calculées par le critère de Borsotti pour les trois méthodes.




Figure 5.11. Évaluation qualitative de la méthode de la segmentation.
à gauche: image visible; à droite: image proche infrarouge.
(a1, b1) méthode proposée; (a2, b2) méthode de Graphe [90]; et
(a3, b3) méthode SRM [89].

Tableau 5.1. Évaluation de la qualité de la segmentation par le critère de Borsotti.

Méthode/image	visible	proche infrarouge
Graphe	0,86	70,15
SRM	0,53	14,85
<i>Méthode proposée</i>	0,98	9,30

L'évaluation visuelle (pour un observateur) des résultats présentés à la figure 5.11 permet de déduire les interprétations suivantes :

- les régions de persillage dont les contrastes par rapport au muscle sont relativement élevés sont détectées par les trois méthodes;
- les régions de persillage de taille considérable sont détectées par les trois méthodes;
- les résultats de la segmentation pour l'image visible sont comparables pour les trois méthodes, sauf pour les régions de tailles minuscules;
- le résultat de la méthode de Graphe est sur-segmenté pour le cas de l'image proche infrarouge; souvent les régions sont plus larges que leurs tailles réelles (figure 5.11-b2);
- le résultat de la méthode SRM, dans le cas de l'image proche infrarouge (figure 5.11-b3), se rapproche de celui obtenu par la méthode proposée (figure 5.11-b1), exception faite des petites régions de persillage;

La méthode proposée a été comparée avec plusieurs images par rapport aux méthodes de Graphe et de SRM, les interprétations sont analogues à celles qui viennent d'être citées dans les points ci-dessus. De plus, d'une façon générale, la méthode proposée détecte les régions avec des contours raisonnablement plus fidèles pour les régions observées par rapport aux deux autres méthodes.

Par ailleurs, les évaluations qualitatives obtenues au tableau 5.1 démontrent que les performances des trois méthodes sont comparables pour l'image visible. Pour cette

catégorie d'image, la méthode SRM est plus efficace que la méthode proposée, mais l'image est sous-segmentée. Cependant, les résultats obtenus avec l'image proche infrarouge démontrent qu'effectivement la segmentation obtenue par la méthode proposée est plus uniforme et que les régions du persillage sont plus homogènes par rapport aux régions obtenues par les deux autres méthodes.

La bonne performance de la méthode proposée pourrait être aussi expliquée par le fait que celle-ci a été développée spécifiquement pour ce projet de recherche. Les deux autres méthodes sont plus générales, ce qui est un avantage par rapport à la méthode proposée.

Afin de s'assurer que notre algorithme est efficace pour la segmentation du persillage et que celui-ci s'adapte au faible contraste entre les régions du persillage et le muscle et à la variation de l'éclairage, une évaluation quantitative "directe" par rapport aux régions de persillage est pertinente. Cette évaluation pourrait se faire en établissant des calculs statistiques sur toutes les catégories des régions de persillage identifiées par l'algorithme par rapport à l'image observée. Ceci de la même manière pour les régions de persillage omises par l'algorithme. Comme on ne dispose pas d'une image de référence comme une vérité-terrain "*ground truth*", dans ces circonstances, chaque image elle-même est considérée comme une vérité-terrain sur laquelle on peut vérifier le résultat de la segmentation.

Pour ce faire, nous proposons trois critères de mesure qui nous permettent à la fois d'évaluer l'efficacité de notre algorithme pour la segmentation et de mesurer la précision pour la détection du persillage. Ces critères se calculent en fonction du type de défaut, ils sont :

1. le pourcentage des régions réelles du persillage partiellement détectées par l'algorithme. Ces régions sont appelées : "*détection positive*";
2. le pourcentage des fausses régions de persillage identifiées par l'algorithme comme régions de persillage. Ces régions sont appelées : "*fausse détection*"; et
3. le pourcentage des régions réelles de persillage détectées par l'algorithme. Ces régions sont appelées : "*détection ratée*".

Ces pourcentages se calculent par rapport au nombre total des régions du persillage réellement existantes dans l'image. Toutefois pour faciliter cette tâche nous avons ignoré les régions de tailles minuscules (<100 pixels). Ces régions n'ont pas beaucoup d'influence dans notre application. Ainsi, le comptage du nombre total des régions détectées est effectué par l'algorithme et le comptage des défauts est effectué de façon manuelle.

La figure 5.12 illustre les trois critères (trois types de régions).



Figure 5.12. Illustration des critères de mesure de l'efficacité de la méthode proposée.

(1) détection positive; (2) fausse détection; et (3) détection ratée.


Nous avons évalué l'efficacité de notre algorithme sur plusieurs types d'images visible et proche infrarouge prises par le montage expérimental présenté au chapitre 2 (figure 2.8). Nos essais expérimentaux ont été réalisés sur divers échantillons de viande de bœuf dont les épaisseurs varient de 5 à 6.5 mm. La figure 5.13 en illustre quelques exemples. Le tableau 5.2 montre les résultats obtenus sur 10 images proches infrarouges.

Tableau 5.2. Évaluation quantitative de l'efficacité de détections des régions du persillage.

Catégorie/Image	1	2	3	4	5	6	7	8	9	10	T	%
Nbre de régions	46	65	83	60	63	46	51	67	47	42	570	-
Détection positive	0	1	4	3	1	4	5	3	2	1	24	4,2
Fausse détection	1	1	3	1	2	3	4	2	3	0	20	3,5
Détection ratée	0	1	0	0	1	2	0	1	1	2	8	1,4

T : total.

Le tableau 5.2 montre les pourcentages pour chaque type de défaut (détection positive, fausse détection et détection ratée) obtenues sur 10 images proches infrarouges (notons que la segmentation de l'image visible est relativement facile par rapport à l'image proche infrarouge). Les pourcentages obtenus démontrent que la méthode de segmentation proposée est raisonnablement efficace face aux trois types de défauts. La figure 5.13 en illustre quelques résultats supplémentaires de segmentation.






Figure 5.13. Illustration des quelques résultats supplémentaires de segmentation. (à gauche image visible et à droite image proche infrarouge)

Dans cette section, les évaluations qualitatives et quantitatives de la qualité des résultats de la segmentation obtenus sur des images visible et proche infrarouge par la méthode proposée ont été présentées. Ces résultats démontrent que la méthode proposée est efficace pour la segmentation du persillage dans la viande, et ceci pour les deux types d'images : visible et proche infrarouge. Ces deux catégories d'images ont été prises par la technique d'acquisition d'image que nous avons proposée au chapitre 2. Cette technique a été proposée pour développer une méthode d'évaluation non-destructive de la proportion volumétrique du persillage dans la viande du bœuf. Ceci fera l'objet du chapitre 6. Par ailleurs, les résultats de segmentation obtenus démontrent que la méthode de segmentation proposée est un choix judicieux pour l'implémentation d'une méthode non-destructive d'estimation de la proportion du persillage contenu dans un échantillon de viande de bœuf.

Le temps de calcul pour notre méthode dépend de la taille de l'image et donc du nombre d'images et non pas du nombre de classes de régions de niveaux de gris ou de nombre d'itérations comme dans le cas des algorithmes EM et fuzzy k-means. Le temps de calcul ne dépend pas non plus des paramètres de l'algorithme comme pour le cas de la méthode de Graphe ou de SRM. Étant donné que le temps de calcul n'est pas un critère primordial pour

notre application, nous n'avons pas estimé le temps de calcul. Toutefois, la complexité de calcul de l'algorithme proposé dépend essentiellement de la complexité de l'algorithme FCE et de la taille de l'image qui affecte le nombre des imagerie. Rappelons que la complexité de l'algorithme FCE (chapitre 4) est $O(n)$, où n est le nombre total de pixels de l'image.

5.6 Conclusion

Dans ce chapitre, une nouvelle méthode de segmentation d'images en régions appliquées à la détection du persillage dans la viande de bœuf est proposée. Le concept de cette méthode est basé sur l'algorithme FCE, un nouvel algorithme qui est relativement général et développé au chapitre 4. Ainsi, la méthode de segmentation a été développée en vue d'être appliquée à la détection du persillage dans la viande de bœuf. Cependant, elle pourrait être aussi adaptée à d'autres applications.

L'application de la méthode proposée pour la segmentation du persillage dans la viande de bœuf, à la surface à partir d'une image visible, tout comme en profondeur à partir d'une image proche infrarouge démontre que la méthode proposée produit des résultats satisfaisants pour les deux types d'images. Les évaluations qualitatives et quantitatives de la qualité de la segmentation sur divers types d'images montrent que la méthode proposée est conforme aux attentes prévues, à savoir l'efficacité de détections des régions du persillage dans un environnement relativement complexe (ex : image à faible contraste et/ou affectée par l'ombre). Par ailleurs, nous avons aussi évalué la méthode proposée directement par rapport aux types des régions de persillage détectées : détection positive, fausse détection et détection ratée. Les résultats quantitatifs obtenus démontrent que la méthode proposée est efficace et satisfaisante face aux objectifs attendus.

La méthode proposée est évaluée qualitativement et quantitativement sur des images prises par notre système d'acquisition d'images hybride proposé dans ce travail de doctorat. La qualité des résultats obtenus démontre que la méthode de segmentation proposée pourrait être utilisée afin de développer une méthode non-destructive pour l'estimation de la proportion volumétrique du persillage contenu dans un échantillon de viande de bœuf.

Chapitre 6

L'analyse d'images visible et proche infrarouge en vision artificielle : une nouvelle méthode flexible pour l'évaluation non-destructive du gras intramusculaire dans la viande de bœuf

La qualité de la viande dans l'industrie bovine canadienne est un élément clef pour la réussite de cette industrie, en particulier pour satisfaire le consommateur. Par ailleurs, c'est dans cette optique que l'Agence canadienne de classement du bœuf (ACCB) a été créée [95]. L'ACCB est accréditée par l'Agence canadienne d'inspection des aliments pour fournir des services de classement (en anglais “*grading*”) des carcasses en usine. Le persillage, soit le gras intramusculaire (ou gras entre les fibres musculaires), est un facteur important dans le classement à la viande. D'une façon générale, une plus grande quantité de persillage dans la viande conduit à une meilleure qualité de viande. Plus spécifiquement, une bonne quantité et une bonne distribution du persillage offre une meilleure qualité, notamment au niveau de la saveur et la jutosité.

Traditionnellement, le processus de classement est accompli visuellement (subjectivement) par une personne qualifiée et entraînée, nommé classificateur. Toutefois, récemment l'emploi de la technologie de l'intelligence artificielle basée sur la vision numérique comme solution (objective) alternative à l'action humaine a suscité beaucoup d'intérêt dans la communauté scientifique [5]. L'avantage de cette technique, qui est accomplie par un système de vision artificielle, est que celui-ci est à la fois précis et objectif comparativement à une intervention humaine. En plus, la solution obtenue par un système de vision est rentable économiquement puisqu'elle est implantée dans un système automatisé. Ainsi, dans ce contexte, plusieurs approches ont été proposées dans la littérature pour étudier la qualité de la viande en fonction du persillage notamment dans le boeuf. Selon la revue de la littérature qui a été faite, nous pourrions classer ces approches

en trois catégories : 1) approches exploitant l'information visuelle à partir d'une image visible [7]; 2) approches exploitant l'information proche infrarouge ou multispectrale provenant souvent d'une mesure de type "spectrométrie" [14]; et 3) approches qui combinent à la fois les deux dernières approches (visible et proche infrarouge) [13]. Dans cette dernière catégorie, l'information proche infrarouge pourrait être fournie par une caméra numérique. Dans toutes ces catégories, les solutions proposées jusqu'à maintenant pour mettre en œuvre ces méthodes sont souvent développées pour étudier le persillage à la surface d'un échantillon de viande et non dans la totalité de l'échantillon. En conséquence, étant donné que la distribution du gras n'est pas homogène dans toute la profondeur du muscle, les résultats affirmés par ces méthodes ne pourraient pas être précis. Par exemple, à la surface d'une pièce de viande, il pourrait y avoir un certain pourcentage de persillage alors qu'un autre échantillon prélevé ailleurs dans le muscle pourrait avoir un autre pourcentage différent. De ce fait, l'information obtenue uniquement à la surface ne pourrait pas être représentative et précise de la totalité de l'échantillon. Par ailleurs, l'analyse chimique (méthode destructive), est la méthode de référence (en anglais « *gold standard* ») utilisée pour évaluer la teneur en lipides intramusculaires de la viande (voir paragraphe 6.7).

Dans ce travail de doctorat, une méthode originale non-destructive pour l'évaluation du persillage dans la viande de bœuf est proposée. En effet, nous avons démontré au deuxième chapitre que l'emploi de la lumière proche infrarouge en mode transmission nous permet d'avoir de l'information sur le persillage, non seulement à la surface mais aussi en profondeur. Ainsi, un système original de vision artificielle hybride pour évaluer la quantité du persillage dans un échantillon de viande de bœuf a été également proposé au chapitre 2. Au meilleur de notre connaissance, aucun système ou méthode semblable à celle présentée ici n'a été proposée. L'analyse chimique du gras intramusculaire [97] est une méthode destructive, fastidieuse, coûteuse et n'offre aucune information sur la distribution du persillage à l'intérieur du muscle (voir paragraphe 6.7 pour plus de détails). Contrairement à la méthode chimique, la méthode que nous proposons dans cette thèse est non-destructive, rapide et ne requiert aucun produit chimique. Ainsi, au-delà de l'évaluation quantitative du persillage, la méthode proposée permet d'extraire plusieurs informations supplémentaires,

qui sont indispensables à l'étude de la qualité de la viande, telles que la distribution et l'architecture avec laquelle le persillage est déposé dans le muscle. Cette nouvelle méthode, qui pourrait être intégrée industriellement dans un système de vision (*machine vision*), est une première expérience d'amorçage pour ce genre d'application. On retrouve dans la littérature quelques travaux de recherche sur l'évaluation non-destructive de persillage dans la viande [102]. Dans [99] une méthode utilisant les ultrasons pour la prédiction du pourcentage du gras intramusculaire dans la viande du porc est proposée. Dans cette méthode, l'évaluation du persillage se fait à partir des ROIs (100x100 pixels) des images ultrasons entre la 10^{ème} et de la 11^{ème} côte de l'animal vivant. Un technicien formé analyse les ROIs sélectionnés afin de déterminer la proportion du persillage. Elle est donc une technique de mesure locale pour prédire une estimation globale du persillage dans la viande de porc. Avila *et al* [100] ont proposé une méthode de reconstruction 3D du persillage afin d'estimer le volume du persillage dans un échantillon de viande de porc. L'approche proposée dans cette méthode est basée sur une technique de reconstruction numérique de surface 3D à partir des images de résonance magnétique (RM) d'une série de tranches minces (2 mm) de viande et avec l'assistance d'un expert. Il s'agit d'une méthode complexe et qui se limite à de petites épaisseurs de tranche de viande. Dans un contexte commercial, la compagnie FOSS [101], a développé un analyseur appelé "*FoodScan*", qui utilise la technologie proche infrarouge pour mesurer plusieurs paramètres de la viande tels que les taux d'humidité, de protéines et de matières grasses. Pour prédire la proportion du persillage dans la viande, l'échantillon doit être haché pour faire une pâte relativement homogène. Ainsi, cette méthode ne peut pas être qualifiée de non-destructive. En fonctionnement, la machine doit être, entre autres, préalablement calibrée avec des échantillons standards de composition connue. Selon notre recherche, peu de travaux ont été repérés dans la littérature. Ceci pourrait être dû à la nature complexe du problème qui pose des limites sur le plan technologique et analytique.

Dans le contexte de ce travail de recherche, nous avons proposé au chapitre 5 une méthode de segmentation d'image permettant d'isoler et d'identifier le persillage par rapport au muscle. Cette méthode permet, entre autres, de mesurer la quantité du persillage existante à la surface de l'échantillon de la viande. L'application de cette méthode pour la

segmentation des images visible (persillage à la surface) et proche infrarouge (persillage à la surface et en profondeur de l'échantillon) a démontré des résultats satisfaisants. Ainsi, nous allons utiliser cette méthode dans ce chapitre pour développer une méthode globale permettant d'évaluer la proportion du persillage dans tout échantillon de viande. Les résultats obtenus seront comparés à ceux obtenus par l'analyse chimique, qui est en fait la méthode de référence (voir paragraphe 6.7 pour la description de la méthode chimique).

La suite de ce chapitre est organisé comme suit : section 6.1 présente une vue d'ensemble de la technique expérimentale proposée au chapitre 2. Nous allons démontrer ainsi les fondements scientifiques associés à la technique proposée. La section 6.2 présente une vue d'ensemble de la méthode de segmentation d'image à utiliser pour l'identification du persillage dans la viande de bœuf, laquelle a été proposée au chapitre 5. La section 6.3 introduit une méthode de catégorisation des régions du persillage segmentées. Ces régions sont classifiées en trois classes : régions de persillage en correspondance entre les deux faces de l'échantillon; régions de persillage de surface; et finalement régions de persillage à l'intérieur de l'échantillon. Ainsi, nous introduisons à la section 6.4 la méthode proposée pour l'évaluation non-destructive de la proportion du persillage dans la viande de bœuf. La méthode chimique, méthode de référence, à laquelle la méthode proposée est comparée sera présentée à la section 6.5. La section 6.6 illustre les résultats obtenus par la méthode proposée. La section 6.7 présente l'évaluation quantitative de la méthode proposée vis-à-vis les résultats obtenus par la méthode chimique et finalement la section 6.8 présente la conclusion.

6.1 Approche proposée pour l'acquisition d'images




Figure 6.1. Dispositif expérimental de l'approche proposée.
(a) dispositif expérimental ; (b) représentation schématique de la transmission de la lumière proche infrarouge à travers la viande.

La figure 6.1 illustre le dispositif expérimental de la technique d'acquisition d'images visible et proche infrarouge proposée au chapitre 2. Tel qu'illustré à la figure 6.1-(b), la même caméra assure l'acquisition des deux types d'images : l'image visible de la surface de l'échantillon (donc une mesure par réflectance) et l'image proche infrarouge qui est à la fois l'image de la surface et de dessous de la surface (une mesure par transmittance). La figure 6.2 illustre un exemple d'acquisition pour les deux types d'images.

Un dispositif électronique assure le fonctionnement du système d'éclairage : si la lumière visible s'allume, la lumière proche infrarouge s'éteindra automatiquement et inversement, ce qui permet au système d'acquisition de fonctionner en mode hybride; visible et proche infrarouge.

En plus de sa flexibilité, la technique proposée offre, entre autres, deux avantages intéressants :

- l'image visible obtenue est une image à niveaux de gris qui illustre la surface de l'échantillon. Celle-ci assure un traitement surfacique de l'échantillon, mais elle n'offre pas d'information sur le contenu intérieur (invisible) de l'échantillon; et
- l'image proche infrarouge illustre à la fois la surface et l'intérieur de l'échantillon. Étant donné que l'échantillon de la viande est un milieu hétérogène, la lumière proche infrarouge se diffuse en conséquence. Par exemple, les particules de persillage à l'intérieur de l'échantillon absorbent et diffusent la lumière proche infrarouge différemment des fibres musculaires (figure 6.2-b). Ceci se traduit en imagerie par des régions moins claires (ombres) qui correspondent aux éléments plus réfléchissants et/ou absorbants de la lumière proche infrarouge dans l'échantillon. Dans notre cas, ce sont les particules et les masses de persillage. L'image proche infrarouge (2D) est donc une projection orthogonale de l'échantillon de viande (3D). Ainsi elle permet d'obtenir l'information en profondeur d'une manière non-destructive, ce qui est n'est pas accessible avec l'image visible.

Comme il est difficile d'identifier le persillage à différents niveaux de profondeur de l'échantillon par traitement d'image uniquement dans le domaine proche infrarouge, en raison du faible contraste du persillage par rapport au muscle et à l'ombre à travers la viande, il est intéressant de combiner les images visibles de deux surfaces de la viande et les deux images proches infrarouges pour ce processus. Ainsi, la technique proposée combine à la fois les avantages de la lumière visible et du proche infrarouge sans pour autant partager leurs inconvénients.

6.2 Isolation du persillage par segmentation d'image

L'isolation du persillage est une phase cruciale dans le processus d'évaluation de sa proportion à l'intérieur d'un échantillon de viande, car elle est entre autres, parmi les premières étapes sur laquelle se base le reste du processus. En conséquence, la performance globale de la méthode d'évaluation ne pourrait pas être garantie sans la performance de la phase de la segmentation. Donc une attention particulière doit être portée à cette étape.

La figure 6.2 illustre deux types d'images à segmenter qui sont obtenues par le système d'acquisition de la technique proposée (figure 6.1). Les deux types d'images sont à niveaux de gris : une est prise dans le spectre du visible et l'autre dans le spectre proche infrarouge à 940 nm. Pour les deux types d'images, l'objectif de la segmentation est d'identifier les régions de persillage à la surface pour l'image visible, et à la fois à la surface et en profondeur pour l'image proche infrarouge.

Contrairement à l'image visible où le persillage est segmenté en se basant sur son niveau de gris à la surface (niveau de gris de réflectance), dans le cas de l'image proche infrarouge, le persillage devrait être segmenté à partir de son ombre (niveau de gris de transmittance).

Comme le montre la figure 6.2 (cas des images proches infrarouges), le processus de la segmentation n'est pas aisé au vu de la complexité associée (ex : ombre et faible contraste de persillage). Plusieurs phénomènes sont à l'origine de cette complexité, parmi lesquels on trouve les variations douces de niveau de gris entre les éléments de l'image (ex : persillage et muscle). Ces phénomènes pourraient être dus à la variation de l'épaisseur de l'échantillon de la viande, qui est l'une des grandes problématiques rencontrées lors des expérimentations, et aussi aux phénomènes optiques associés à la transmittance de la lumière à travers l'échantillon de la viande.

Afin d'avoir des résultats de segmentation efficaces et satisfaisants aux besoins de ce projet, la méthode de segmentation proposée au chapitre 5 est utilisée pour identifier le persillage dans les deux types d'images. Nous rappelons que cette méthode est une généralisation de l'algorithme FCE, lequel est proposé également dans le cadre de cette thèse (chapitre 4). L'algorithme FCE est une méthode originale proposée pour l'identification des régions les plus (ou les moins) claires dans une image de niveaux de gris. Ceci cadre bien avec la nature des images à traiter. Les performances de ces deux méthodes ont été démontrées respectivement aux chapitres 4 et 5. Le résultat de

l'application de la méthode de segmentation pour segmenter les deux images visibles et proches infrarouges de la figure 6.2 est illustré à la figure 6.3.




Figure 6.2. Images visibles et proches infrarouges.
(a1) image visible de la face 1; (b1) image proche infrarouge de la face 1;
(a2) image visible de la face 2; (b2) image proche infrarouge de la face 2.




Figure 6.3. Détection du persillage à partir des images visibles et proches infrarouges. Persillage détecté dans l'image : (a1) visible de la face 1; (b1) visible de la face 2; (a2) proche infrarouge de la face 1; (b2) proche infrarouge de la face 2; (a3) visible (rouge) et proche infrarouge (rouge et blanc) de la face 1; (b3) visible (rouge) et proche infrarouge (rouge et blanc) de la face 2.

6.3 Mise en correspondance et reconnaissance de forme

La mise en correspondance consiste à faire correspondre une région du persillage située à un niveau de profondeur donné (ex : à la face 1, qui est la face du haut) à une autre région du persillage située à un autre niveau de profondeur (ex : à la face 2). Cette région pourrait être elle-même ou une partie d'elle-même. C'est en quelque sorte la continuité de cette région à travers les muscles. Le processus menant à la réalisation de cette tâche (la mise en correspondance) est un processus qui fait partie d'un domaine général qui est la reconnaissance d'objet (dans certaines littératures, ce processus est aussi désigné reconnaissance de forme ou en anglais, "*pattern recognition*") qui est un domaine de recherche de la vision artificielle et de traitement d'image [104]. Plusieurs travaux de recherches ont été effectués dans ce domaine [105]. L'idée commune dans ce champ de recherche est d'utiliser des caractéristiques (des primitives) descriptives de l'objet pour la représenter, comme la forme géométrique, la couleur, la luminance ou toute autre caractéristique afin d'en faire la reconnaissance. Ces caractéristiques sont souvent prises à partir d'objets modèles pour construire un modèle de référence.

D'une manière générale, les méthodes de reconnaissance pourraient être classées essentiellement en deux catégories soit : les méthodes basées sur les caractéristiques et les méthodes photométriques [105]:

1. les méthodes dites de caractéristiques sont des méthodes basées sur les caractéristiques géométriques de l'objet (en anglais, "*Feature-based methods*"). Ces méthodes impliquent des relations et arrangements spatiaux entre les différents éléments de l'objet, ex : les contours et les points de jonctions. Deux modèles de représentation sont populaires dans la littérature : soit le modèle basé sur les contours [106] et le modèle basé sur le squelette de l'objet [107]. Le principe de ce genre d'approches consiste à comparer l'objet analysé à des modèles d'objets archivés dans une base de données. Par une méthode de mesure de similarité, il sera possible d'évaluer la similitude entre chaque modèle et l'objet à analyser. Ce type d'approche se limite à des objets rigides, ayant souvent des formes géométriques simples. Par ailleurs, l'intérieur de l'objet n'est souvent pas représenté, par exemple, que l'objet soit avec des contours linéaires simplifiés. Dans le cas des objets ayant

des contours en courbures complexes, la performance de ce genre d'approche est difficile à garantir. Ainsi, pour une application de reconnaissance de formes complexes, l'efficacité de ce modèle de représentation semble réduite.

2. les méthodes photométriques sont des méthodes basées sur la luminance de l'objet (en anglais, "*Brightness-based methods*") lesquelles impliquent plus directement l'utilisation des niveaux de gris des pixels. Ce sont des méthodes basées sur l'apparence visuelle de l'objet en termes de luminance. De ce fait, elles offrent un aspect complémentaire aux méthodes de caractéristiques. Dans ce contexte, les méthodes proposées dans la littérature pourraient être classées en deux catégories : les méthodes qui trouvent explicitement la correspondance/alignement entre les objets en utilisant les valeurs selon divers niveaux de gris [108], et les méthodes sans qu'elles trouvent explicitement la correspondance. Ce sont des méthodes basées sur des algorithmes d'apprentissage ou des réseaux de neurones [73]. En conséquence, ces méthodes exigent souvent plusieurs exemples typiques de l'objet ou de la forme à modéliser pour acquérir suffisamment d'information sur l'objet à comparer.

La figure 6.4 montre deux représentations géométriques appliquées sur des régions du persillage.




Figure 6.4. Représentations géométriques des régions de persillage.
(a1 et a2) représentation par contours; et (b1 et b2) représentation par squelette.

La figure 6.4 illustre deux types de représentation géométrique des régions de persillage, à savoir la représentation par contours (figure 6.4-a1-a2) et la représentation par squelette (figure 6.4-b1-b2). Ces deux représentations démontrent qu'il y a des similitudes entre les régions de la face 1 (figure 6.4-a1-b1) versus la face 2 de l'échantillon (figure 6.4-a2-b2). Cependant, il est clair que ces similitudes sont faibles pour établir des relations efficaces de similarités entre les régions de deux faces. Par ailleurs, l'apparence en termes de niveaux de gris entre les régions opposées de deux faces, potentiellement en correspondance, est similaire. Par exemple, les deux régions en haut au milieu de deux images (figures 6.4-a1 et 6.4-a2, voir la marque X)) sont similaires en termes de niveaux de gris malgré la non

ressemblance entre leurs caractéristiques géométriques (contours et squelette). Ainsi, une mesure d'apparence basée sur le niveau de gris entre les régions pourrait être une bonne signature pour mesurer la similarité entre les régions. Dans ce contexte, plusieurs approches ont été proposées dans la littérature [108]. Mais la plupart d'entre elles sont des variantes sur la même idée de base : il s'agit d'une mesure de la distance entre les caractéristiques photométriques des objets à comparer. Parmi les méthodes les plus populaires notons les méthodes basées sur le calcul de la distance entre les histogrammes à savoir, la méthode d'intersection d'histogrammes proposée par Swain et Ballard [108]. C'est une méthode simple à appliquer et elle tient compte des variations de l'histogramme des régions (ex : des vallées locales).

6.4 Catégorisation des régions du persillage

Nous avons démontré au chapitre 2 ainsi que dans [96] que l'image proche infrarouge de l'échantillon de la viande est riche en information sur la composition intrinsèque de la viande comme l'eau, les protéines, le collagène et le persillage. De plus, comme le montrent les figures 6.2 et 6.3, l'information contenue dans l'image proche infrarouge, inclut aussi celle de l'image visible. Par exemple, le persillage observé à la surface dans l'image visible est aussi retrouvable dans l'image proche infrarouge. Toutefois, cette propriété n'est pas réciproque. L'image proche infrarouge pourrait être aussi vue comme une image traduisant la perméabilité de la viande vis-à-vis de la lumière proche infrarouge. Ainsi, les éléments plus réfléchissants et/ou absorbants de l'échantillon comme les particules de persillage contribuent d'avantage à la formation des régions moins claires (ombres). L'image proche infrarouge (2D) est donc une projection orthogonale de l'échantillon de la viande (3D), qui permet de ressortir de l'information en profondeur d'une manière non-destructive, ce qui est n'est pas faisable par l'image visible.

Par conséquent, l'étude du contenu de l'image proche infrarouge permet sans doute d'extraire de l'information détaillée sur la totalité du persillage présent sous la surface de la viande et d'établir une relation de connectivité entre les régions du persillage à différents niveaux de profondeurs de l'échantillon de la viande. Par exemple, l'isolation du persillage inter-couches, (qui est une estimation de la quantité du persillage à différentes

profondeurs), est une estimation locale permettant de reconstruire la “carte” de distribution du persillage à un certain niveau de profondeur. La première estimation qui vient à l’esprit est celle au niveau de la surface de l’échantillon, obtenue à partir de l’image visible (ex : celle de la face 1). Celle-ci représente le persillage à une profondeur égale à zéro (la surface). Le persillage obtenu à partir de l’image visible de la face opposée (la face 2) est le persillage à la profondeur maximale, soit correspond à l’épaisseur de l’échantillon de viande. L’image proche infrarouge pourrait ainsi interpréter la totalité du persillage présent dans la pièce de la viande; les régions foncées représentent l’ombre du persillage. L’image proche infrarouge représente donc la projection orthogonale 2D (*connue*) du persillage déposé à travers le volume musculaire 3D (*inconnue*). La problématique revient donc à faire une estimation volumétrique (3D) du persillage à partir d’une information 2D connue. Pour ce faire, nous allons d’abord estimer le persillage juste en dessous de la surface de l’échantillon puisque celui-ci est comparable à celui de la surface : du point de vue photométrique, les niveaux de gris des régions juste en dessous de la surface (inconnues) devraient être légèrement inférieurs à ceux des régions observées à la surface (connues). L’image de la figure 6.5 illustre deux types de courbes de distribution des pixels du persillage en fonction du niveau de gris: le persillage identifié à la surface à partir de l’image proche infrarouge et le persillage observé exclusivement à l’intérieur de l’échantillon (c’est-à-dire sans tenir compte de celui observé à la surface. Celui-ci est identifié par l’image visible).




Figure 6.5. Variation de la distribution des pixels du persillage à la surface et exclusivement sous la surface observée par les images proches infrarouges. (a) face 1; (b) face 2; (1) variation du niveau de gris des pixels du persillage à la surface; (2) variation du niveau de gris des pixels du persillage exclusivement sous la surface (persillage de l'image proche infrarouge sans tenir compte des pixels observés à la surface).

La figure 6.5 montre les courbes de variation des intensités de pixels des régions du persillage observées sur les images proches infrarouges de deux faces : les courbes (1) sont relatives au persillage qui pourrait être observé à la surface; les courbes (2) sont relatives au persillage sous la surface excluant celui observé à la surface. L'examen visuel de ces courbes montre que celles-ci ont plusieurs ondulations sous forme de modes. L'allure de ces ondulations est typiquement gaussienne. Ainsi, chaque ondulation pourrait traduire (fournir de l'information sur) une catégorie de régions de persillage. Par ailleurs, on pourra remarquer que la courbe relative au persillage de la surface, courbe-(1), possède moins d'ondulations que celle du persillage observé exclusivement sous la surface (courbe-(2)). Cette différence s'explique par le fait que la courbe relative au persillage de la surface est plus uniforme (même niveau de surface) alors que celle du persillage en dessous de la surface représente le persillage de plusieurs surfaces à différents niveaux de profondeurs dans l'échantillon de la viande.

Étant donné qu'on dispose de la courbe du persillage de la surface (même niveau de profondeur), celle-ci pourra servir pour estimer les régions du persillage juste en dessous de

la surface. Ainsi, le processus de catégorisation de ce type de régions (régions juste en dessous de la surface de l'échantillon) pourrait se faire en deux étapes :

1. à partir de la courbe de distribution de pixels relative au persillage exclusivement en dessous de la surface on cherche la vallée la plus proche du maximum de la courbe du persillage de la surface (cercle noir "o" à la figure 6.5-a-b). Cette vallée devrait correspondre au seuil d'une catégorie de régions de persillage qui viennent, raisonnablement, après celles de la surface, donc ces régions sont juste proches de la surface; et
2. les régions du persillage dont la valeur de la moyenne de pixels est inférieure au seuil trouvé pourraient être classées comme des régions proches (juste en dessous) de la surface.

La figure 6.6 illustre le résultat de ce processus de catégorisation appliqué aux deux images proches infrarouges de la figure 6.2.




Figure 6.6. Détection du persillage proche de la surface.
(persillage à la surface (rouge); persillage proche de la surface (vert);
et persillage en dessous de la surface (blanc).

La figure 6.6 montre les régions de persillage observées à la surface (rouge) et celles proches de la surface (vert) obtenues par le processus de catégorisation décrit ci-haut. Elle

démontre également la continuité géométrique entre le persillage de la surface et celui identifié juste en dessous de la surface, ce qui démontre le prolongement du persillage de la surface en dessous de la surface.

Cette méthode permet de faire une estimation locale du persillage proche de la surface étant donné qu'on dispose du persillage de la surface. Toutefois, ce processus de catégorisation ne pourrait pas être généralisé sur le même fondement pour faire une estimation locale du persillage à des profondeurs subséquentes entre les deux faces de la viande (ceci compte tenu de la diversité non linéaire des niveaux de gris des régions du persillage à travers l'échantillon de viande). Cependant, nous allons utiliser les résultats de cette méthode de catégorisation pour faire la mise en correspondance entre les régions du persillage en continuité entre les deux faces de l'échantillon.

6.5 Méthode proposée

Au cours de notre recherche bibliographique sur la description des formes géométriques possibles du persillage, aucune littérature décrivant la forme du dépôt du persillage n'a été trouvée. Aussi, selon plusieurs recherches aucune réponse précise à cette question n'a été formulée. Plus précisément, aucune étude ou article ne précise si les dépôts de gras ont suivi une forme géométrique particulière, ex : conique, cylindrique ou autre. Cependant, ce qui est connu est que:

1. le gras intramusculaire est le dépôt adipeux qui se met en place le plus tardivement parmi toutes les fractions adipeuses présentes au niveau des carcasses;
2. le persillage suit des directions parallèles au muscle, dans une coupe ou observation transversale ceci a un sens oblique. La figure C.1 (voir annexe C) illustre cette interprétation.
3. « Au sein du muscle squelettique, les triglycérides (acides gras) sont à la fois présents à l'intérieur des fibres musculaires sous forme de gouttelettes lipidiques et à l'extérieur des fibres dans des adipocytes intramusculaires [28]. Ces cellules sont soit isolées entre les fibres musculaires soit regroupées sous forme de tissu le long des faisceaux de fibres à proximité des vaisseaux sanguins » [28]. Dans [111], une

illustration de la coupe transversale de muscle est présentée. Dans cette publication et à l'annexe C, figure C.2 [111], plusieurs adipocytes regroupés pour former le tissu adipeux intramusculaire entre les faisceaux de fibres et à proximité des vaisseaux sanguins sont observés. Ceci montre qu'il n'y a pas de forme précise du persillage, ce dernier prend tout simplement la place laissée entre les faisceaux de fibres (plutôt ellipsoïde), un peu à la manière des racines de végétaux dans le sol;

4. les quantités de tissu adipeux intramusculaire varient en fonction de facteurs génétiques (espèces) et de facteurs non génétiques : selon le muscle, l'âge à l'abattage, le sexe, des caractéristiques de l'animal à la naissance, de l'alimentation, et des facteurs environnementaux (système d'élevage) [28].

Étant donné les complexités rencontrées pour modéliser les formes géométriques que pourraient prendre les régions du persillage, il est évident que quelque soit le modèle adopté implicitement pour modéliser la forme géométrique du volume de persillage, celui-ci ne sera pas parfait. Dans ce contexte, il est prudent que la solution passe d'abord par une méthode de mise en correspondance entre les régions de persillage observées sur les deux faces de l'échantillon. Étant donné que les formes géométriques des régions du persillage sont à la fois complexes, déformables et aléatoires, une mise en correspondance basée sur la forme géométrique aura ses limites. Cependant, compte tenu de la stabilité, relative, photométrique de la technique proposée pour faire l'acquisition de l'image (figure 6.1), il est possible d'établir une méthode de reconnaissance plutôt basée sur des mesures photométriques qui trouvent explicitement la correspondance entre les régions du persillage en utilisant de l'information de type niveau de gris. Par ailleurs, dans notre étude présentée à la section 6.3, nous avons démontré qu'une méthode photométrique, pour faire la mise en correspondance entre les régions du persillage observées sur les deux faces de l'échantillon, est un choix pertinent. De plus, la présence opposée des régions du persillage de part et d'autre de chaque face de la viande ainsi que la pose et la taille de la surface occupée par chaque région du persillage permettent de fournir de l'information spatiale afin de définir si une telle région se prolonge, en partie ou en totalité, sur toute l'épaisseur du morceau de viande où si elle s'interrompt.

6.5.1 Mise en correspondance et mesure de similarité

Si on considère une région de persillage sur l'une des deux faces de l'échantillon de la viande, cette région pourrait être une partie d'une même région de persillage observée à la face opposée, c'est-à-dire qu'elle s'agit probablement de la même région qui passe d'un bout à l'autre (d'une face à l'autre) de l'échantillon, comme elle pourrait être une région isolée déconnectée de toutes autres régions du persillage. Pour mettre la lumière sur cette ambiguïté, une méthode de mise en correspondance basée sur une mesure de similarité photométrique entre deux régions du persillage est proposée.

Étant donné une région $R1$ du persillage observée à la face 1 (la face 1 est prise à titre de référence), $R2$ est une région de persillage candidate observée à la face 2. C'est-à-dire qu'elle est en test de similarité avec la région $R1$. Chacune de ces deux régions se caractérisent par une probabilité de distribution de pixels de niveaux de gris respectives P_{R1} et P_{R2} . La figure 6.7 en illustre un exemple.




Figure 6.7. Exemple de probabilité de distribution de pixels de deux régions du persillage. (à droite en rouge région R1; à gauche région R2 en vert; et en bas les courbes des probabilités de distribution de pixels pour les deux régions).

La figure 6.7 illustre les courbes de variation de probabilité de distribution de pixels de deux régions $R1$ et $R2$ du persillage. Comme le montre la figure 6.7, les deux courbes se chevauchent dans une région (zone) commune de niveaux de gris. Dans cette zone, les deux régions $R1$ et $R2$ sont similaires en termes de niveau de gris (elles ont un même niveau de gris i).

En modélisation photométrique, le niveau de gris i pourrait s'exprimer par un modèle simple qui suppose que l'objet est composé d'éléments de surfaces planes, Lambertiennes et perpendiculaires à l'axe optique de la caméra. Le niveau de gris i d'un pixel p s'exprime par l'équation suivante [66]:

$$i = \int_{\lambda_{\min}}^{\lambda_{\max}} E(\lambda)Q(\lambda)S(\lambda)d\lambda \quad (1)$$

où :

- $E(\lambda)$ qui caractérise la distribution spectrale de puissance de l'illuminant;
- $Q(\lambda)$ qui définit la réflectance spectrale de l'élément de surface de l'objet projetant sur le pixel p ;
- $S(\lambda)$ qui caractérise la sensibilité spectrale du capteur de la caméra;
- λ_{\min} et λ_{\max} définissent la largeur de la bande spectrale définissant la sensibilité du capteur (ex : 380 et 780 nm pour le visible).

L'équation 1 est un modèle précis dans un processus de formation d'image pour une surface Lambertienne [66] (surface mate, surface qui réfléchit la lumière incidente dans toutes les directions, et indépendamment de la direction de la lumière incidente). Cette équation met en évidence la dépendance de l'intensité i du capteur et des conditions d'acquisitions ($E(\lambda)$, $Q(\lambda)$ et $S(\lambda)$). Ainsi, l'intensité i ne pourra pas être correctement considérée uniquement comme une propriété intrinsèque de l'objet en acquisition.

Par ailleurs, en spectroscopie, dans une acquisition en mode de transmission telle que réalisée par l'approche proposée dans cette thèse (figure 6.1), l'intensité de la lumière incidente dépend de la transmittance du milieu. Elle pourrait s'exprimer par la relation suivante [20]:

$$I = T_{\lambda} \cdot I_0 \quad (2)$$

où :

- I est l'intensité de la lumière sortante et I_0 est l'intensité de la lumière incidente;
- T_{λ} est la transmittance de la matière à une longueur d'onde λ (sans unité).

Selon la loi de Beer-Lambert, l'absorbance et la transmittance sont reliées par l'équation suivante [20]:

$$A_{\lambda} = -\log_{10}(T_{\lambda}) \quad (3)$$

où :

- A_{λ} est l'absorbance à une longueur d'onde λ (sans unité).

Par ailleurs, les équations 2 et 3 sont symétriques, c'est-à-dire que la permutation de la lumière incidente par rapport à la matière (ex : face 1 ou face 2), préserve la même réponse en termes d'absorbance et de transmittance. Ainsi, en se basant sur les équations 1, 2 et 3, et dans une acquisition en transmission telle que réalisée par l'approche proposée (figure 6.1), la réponse spectrale du capteur devrait être relativement similaire en cas d'une région homogène du persillage ou de muscle qui s'étend entre les deux faces de l'échantillon. Cependant, cette réponse ne pourra pas être préservée, entre les deux faces, car une telle région est affectée par la réflexion et la diffusion de la lumière qui proviennent des autres régions voisines (voir figure 6.1-b). Toutefois, cette similarité pourrait être suffisante pour en faire une caractéristique spectrale descriptive des régions du persillage en correspondance entre les deux faces de l'échantillon (région qui s'étend d'une face à l'autre). Nous avons par ailleurs démontré expérimentalement, au chapitre 2 (paragraphe 2.3.4), une similarité relative entre les régions du persillage "seul" et de muscle "seul".

Ainsi, dans l'exemple de la figure 6.7, plus les deux régions se chevauchent, plus elles sont similaires. On parle alors d'un recouvrement (chevauchement) photométrique de la région $R1$ versus la région $R2$ ou inversement. La largeur de la bande de recouvrement indique le

niveau de similarité entre les deux régions. Nous proposons le modèle suivant (équation 4) pour décrire ce recouvrement :

$$R_{R1R2} = N - \sum_{i=1}^N K(P_{R1}(i).P_{R2}(i)) \quad (4)$$

où :

- N est l'intensité maximale i de niveau de gris de pixels ($N= 256$ dans notre cas);
- P_{R1} et P_{R2} sont les probabilités de distribution des pixels des régions $R1$ et $R2$ respectivement; K est la fonction de recouvrement définie comme suit :

$$K(x) = \begin{cases} 1 & \text{si } x = 0 \\ \text{autrement} & \\ 0 & \end{cases} \quad (5)$$

L'équation 4 est composée de deux termes : le premier terme est fixe et égale à N qui est la plage de variation des intensités. Dans notre cas, $N = 256$. Le deuxième terme est la somme de la fonction K des produits des probabilités de distribution des pixels des régions $R1$ et $R2$. Ainsi, plus ce produit est non nul, moins la somme en question est importante, ce qui revient à un recouvrement (ou un chevauchement) plus important. Le recouvrement R_{R1R2} est positif. Il est nul lorsque les deux régions sont disjointes, c'est-à-dire que l'intersection des deux probabilités P_{R1} et P_{R2} est nulle aussi.

Pour mesurer la similarité de la région $R2$ par rapport à la région $R1$, nous proposons l'approche qui consiste à calculer la probabilité d'avoir un meilleur recouvrement de deux régions $R1$ et $R2$ par rapport à la région $R1$. Ainsi, la similarité de la région $R2$ par rapport à la région $R1$ pourrait s'exprimer par l'équation suivante :

$$S_{R1R2} = \frac{N - \sum_{i=1}^N K(P_{R1}(i) \cdot P_{R2}(i))}{N - \sum_{i=1}^N K(P_{R1}(i))} \quad (6)$$

La valeur de S_{R1R2} varie entre 0 et 1; plus la valeur de S_{R1R2} est proche de 1, plus $R2$ est similaire à $R1$. La similarité entre les deux régions $R1$ et $R2$ se calcule par la mesure de la similarité de la région $R1$ versus la région $R2$ et de la similarité de la région $R2$ versus la région $R1$. Ainsi, plus les deux régions ont des niveaux de gris en commun non nuls plus elles sont similaires. Mathématiquement, la mesure de similarité (ou l'indice de similarité) entre les deux régions $R1$ et $R2$ pourrait s'exprimer par l'équation suivante :

$$S(R1, R2) = 0.5 * \left(\frac{N - \sum_1^N K(P_{R1} \cdot P_{R2})}{N - \sum_1^N K(P_{R1})} + \frac{N - \sum_1^N K(P_{R1} \cdot P_{R2})}{N - \sum_1^N K(P_{R2})} \right) \quad (7)$$

L'équation (7) montre que la valeur de la similarité entre la région $R1$ et la région $R2$ varie entre 0 et 1. Dans le cas particulier où $P_{R1} = P_{R2}$; $S(R1, R2) = 1$ et dans le cas où $P_{R1} \cap P_{R2} = 0$; $S(R1, R2) = 0$. Ainsi, une valeur de S proche de 1 indique que les deux régions $R1$ et $R2$ sont très similaires. Par conséquence elles pourraient appartenir à la même région de persillage qui s'étend entre les deux faces de l'échantillon. Inversement, une valeur de S proche de 0 indique que les deux régions ne font pas partie de la même région de persillage. Donc un seuil entre 0 et 1 pourrait être attribué pour la mise en correspondance entre les régions. L'équation (7) est invariante à la taille, à la géométrie, à la rotation et à la translation des régions, ce qui cadre bien avec notre application étant donné que les régions de persillage n'ont pas de formes rigides ou précises.

Le processus de reconnaissance proposé consiste à identifier les régions en correspondance entre les deux faces de l'échantillon. Ces régions devraient traverser la totalité de l'échantillon. Donc, elles sont observables simultanément pour les deux types d'images :

visibles et proches infrarouges. Pour ce faire, nous allons utiliser les images proches infrarouges pour faire la recherche de correspondance entre les régions, mais le calcul de similarité se fera en utilisant uniquement les régions observées à la surface, qui sont identifiables par les images visibles. Ces régions sont souvent en parti incluses dans les régions proches infrarouges.

L'étape de calcul de la similarité entre les régions de persillage est précédée par une phase de recherche de la région à faire comparaître avec la région de départ. Ainsi, une région d'intérêt "ROI" de la région de départ est définie (la ROI est le rectangle dans lequel la région de persillage observé par l'image proche infrarouge existe, la figure 6.8 en montre un exemple). L'éventuelle existence d'une région de persillage, correspondante à la région de départ, à la face opposée devrait être dans une zone proche de celle de la région de départ. Ceci s'explique puisque que le persillage s'étend obliquement entre les muscles tel que démontré dans notre étude présentée au début du paragraphe 6.5 (voir aussi la figure C.1 à l'annexe C). La ROI de la région de départ est alors projetée "projection orthogonale" sur la face opposée. Un processus de recherche des éventuelles régions du persillage est ainsi amorcé. Ce processus stipule que toute région de la face 2 qui fait une intersection avec la ROI projetée est potentiellement en lien avec la région de départ de la face 1. Ainsi, pour chaque nouvelle région trouvée trois similarités sont calculées :

1. la similarité $S(R1, r2)$ entre la région $R1$ de départ et la région $r2$ qui fait une intersection avec la ROI projetée sur la face opposée, il s'agit donc d'une région de persillage complète ou partielle;
2. la similarité $S(R1, R2)$ entre la région de départ et toute la région objet d'intersection avec la ROI projetée; et finalement,
3. la similarité $S(R2, r1)$ entre la région trouvée dans 2) et la partie de la région (ou la région) de départ correspondant à la projection inverse (c'est-à-dire la projection de la ROI de la région $R2$ sur la face 1.

La figure 6.8 illustre deux exemples de mise en correspondance entre deux régions de persillage.




Figure 6.8. Mise en correspondance entre les régions.
(a) face 1; (b) face 2.

La figure 6.8 montre deux exemples de mise en correspondance entre les régions des deux faces. Ainsi, pour chaque région de la face 1 et de la face 2, les trois similarités $S(R1, r2)$, $S(R1, R2)$ et $S(R2, r1)$ sont calculées. La valeur maximale parmi les trois similarités calculées permet d'identifier les deux régions ou la région et la partie de région de la face de départ et de la face opposée les plus similaires. La valeur retenue pourrait être enregistrée dans un premier tableau des similarités des régions de la face 1 versus les régions de la face 2. Le même processus s'applique pour toutes les régions de la face 1 versus les régions de la face 2. Inversement, un deuxième tableau est dressé pour calculer les similarités des régions de la face 2 versus les régions de la face 1. Ainsi, un troisième et dernier tableau est dressé à partir des deux tableaux précédents. Celui-ci contient les similarités maximales entre les valeurs trouvées par les deux tableaux précédents. Ce

dernier tableau est le tableau de similarités de toutes les régions de la face 1 versus la face 2 et inversement. Finalement, à partir du tableau de similarités, si l'indice de similarité de deux régions est supérieur à un certain seuil, on considère qu'elles font partie de la même portion de persillage. Le résultat de l'application de ce processus (avec un seuil de similarité de 0,85) sur l'échantillon de la viande de la figure 6.2 est illustré à la figure suivante.




Figure 6.9. Mise en correspondance des régions de persillage.
(a) face 1; (b) face 2.

Selon la figure 6.9 on observe que les positions des régions détectées vis-à-vis chaque face montrent que les unes sont perceptuellement (pour un observateur) une continuité des autres. On ne dispose pas d'une vérité-terrain pour confirmer ces interprétations. Mais en se basant sur des observations qualitatives effectuées sur plusieurs échantillons, les résultats obtenus montrent que l'approche proposée pour calculer les similarités entre les régions est raisonnablement acceptable, et que celle-ci pourrait être utilisée comme une approche intermédiaire dans la méthode globale pour l'évaluation volumétrique du persillage dans la viande de bœuf.

6.5.2 Estimation volumétrique du persillage

Après l'étape de mise en correspondance, les régions de persillage observées sur les images proche infrarouge sont classées en trois catégories :

1. régions en correspondance entre les deux faces de l'échantillon, c'est-à-dire qu'il s'agit de la même section de persillage qui s'étend d'une face à l'autre. Ce sont les régions identifiées par le processus de mesure de similarité (paragraphe 6.5.1) ;
2. régions isolées et placées aléatoirement à travers l'échantillon de la viande, mais elles sont proches de l'une des deux faces de l'échantillon, elles sont alors de faible profondeur. Ce sont, les régions observables partiellement ou totalement par l'image visible uniquement sur une seule face ; et
3. régions isolées et placées aléatoirement à travers l'échantillon de la viande, mais qui sont à l'intérieur de l'échantillon. Ce sont les régions observables uniquement par l'imagerie proche infrarouge, comme les particules du persillage qui sont à l'intérieur de l'échantillon.

Dans les prochaines sections, nous allons modéliser ces trois catégories de régions afin d'estimer le volume du persillage contenu dans l'échantillon de viande.

6.5.2.1 Estimation volumétrique des régions mises en correspondance

L'étude de la forme volumétrique (ou de l'architecture) de dépôt du persillage à travers les muscles est un problème complexe. D'ailleurs au meilleur de notre connaissance, aucun rapport publié ou étude scientifique décrivant la forme géométrique ou un motif de dépôts du gras n'a été trouvé dans la littérature. Plus précisément, il n'existe pas de littérature scientifique décrivant si le dépôt de graisse suit une forme géométrique particulière, à savoir: conique, cylindrique ou autre. En se basant sur nos observations expérimentales et sur des recherches expérimentales sur ce sujet [28], nous concluons que les particules du persillage ont des formes aléatoires: sphérique, conique, ellipsoïde ou tout autre forme complexe. Cependant, d'après nos observations on pourra approximer les régions de persillage mises en correspondance entre les deux faces comme suit :

- une région de persillage observée en 2D pourrait être modélisée par une forme ellipsoïdale ayant une surface équivalente à celle de la région de persillage;
- si deux régions sont mises en correspondance entre la face 1 et la face 2 de l'échantillon, le persillage équivalent pourrait être modélisé par une forme d'un cône tronqué (cône à deux bases). La surface de chaque base correspond à la surface de la région du persillage en question.

Les figures 6.10 et 6.11 montrent respectivement une illustration 3D des deux faces de l'échantillon de viande (cas de la figure 6.2) et une illustration 3D du modèle géométrique 3D proposé pour deux régions mises en correspondance.




Figure 6.10. Illustration 3D des deux faces de l'échantillon de la viande.




Figure 6.11. Modèle de deux régions mises en correspondance.

La figure 6.11 illustre un exemple de mise en correspondance entre deux régions de persillage de deux faces. Il s'agit d'une région de la face de départ (ex : face du haut comme référence) qui est mise en correspondance avec une autre région ou avec une partie d'une autre région de la face opposée. Il s'agit donc de la même région observée sur les deux bouts de l'échantillon de viande. Ainsi, le modèle géométrique adapté pour ce genre de correspondance pourrait être celui d'un cône tronqué (figure 6.11-c). Toutefois, si les surfaces de deux régions sont disproportionnées, nous modélisons la correspondance tout simplement (d'une manière simplifiée) par une forme cylindrique (figure 6.11-b). C'est-à-dire, si l'une des surfaces de deux régions est beaucoup plus large que l'autre (ex : 2 fois). Dans ce cas, le modèle proposé est cylindrique ayant une surface de base égale à la surface de la petite région.

Le volume du persillage pour les deux modèles des deux régions mises en correspondance se calcule comme suit :

$$Vrc_n = \begin{cases} \frac{(Srf1 + Srf2) * \sqrt{E^2 + r_1^2}}{2} & \text{si } \frac{\max(Srf1, Srf2)}{\min(Srf1, Srf2)} < 2 \\ \text{Sinon} & \\ \min(Srf1, Srf2) * \sqrt{E^2 + r_2^2} & \end{cases} \quad (8)$$

où :

- $Srf1$ est la surface de la région appartenant à la face 1; $Srf2$ est la surface de la région appartenant à la face 2; E est l'épaisseur de l'échantillon de la viande testé; $r1$ le rayon du modèle associé à la grande région; et $r2$ le rayon du modèle associé à la petite région.

Le volume total de persillage dans tout l'échantillon de viande pour cette catégorie de région est égal à la somme des volumes de toutes les régions mises en correspondance. Ce volume pourrait s'exprimer par l'équation suivante.

$$Vrc = \sum_{n=1}^{Nrc} Vrc_n \quad (9)$$

où :

- Nrc est le nombre des régions mises en correspondance entre les deux faces.

Étant donné que l'échantillon de viande est composé d'un nombre important de petites régions de persillage (souvent des régions minuscules de quelques pixels), la mise en correspondance de ce type de régions est difficile, en particulier à cause de leur dispersion spatiale et de leur grand nombre. Pour alléger le processus d'estimation volumétrique de persillage, nous avons modélisé ces régions par une forme cylindrique à l'instar de l'exemple de la figure 6.11-c. Ainsi, le volume de ces régions pourrait être calculé comme suit :

1. calculer la surface totale occupée par toutes les régions pour chaque face;
2. chercher le centre de masse globale de ces régions sur chaque face;
3. calculer le volume de ces régions à l'instar de l'exemple de la figure 6.11-b.

Le processus proposé pour estimer le volume des régions de persillage de l'ensemble des régions mises en correspondance entre les deux faces de l'échantillon de viande se résume comme suit : le volume de persillage pour chaque couple de régions mis en correspondance se calcule selon le modèle proposé par l'équation 9, et le volume du persillage obtenu pour toutes les régions mises en correspondance se calcule selon l'équation 10. Le volume total de persillage obtenu pour toutes les régions mises en correspondance se calcule alors selon l'équation suivante :

$$V1 = Vrc + Vr \quad (10)$$

où :

- Vr est le volume estimé des petites régions.

La proportion volumétrique, exprimée en pourcentage du persillage de cette catégorie de régions est égale au rapport du volume de ces régions multiplié par 100 et divisé par le volume de l'échantillon de viande, qui se calcule selon l'équation suivante.

$$Pv1 = 100 \frac{V1}{X * Y * E} \quad (11)$$

où :

- X , Y et E , sont respectivement la longueur, la largeur et l'épaisseur de l'échantillon.

6.5.2.2 Estimation volumétrique des régions isolées

Rappelons que les particules ou les régions isolées du persillage dispersées à travers les muscles n'ont pas de forme géométrique ou volumétrique particulière. Ces régions prennent tout simplement la place laissée entre les faisceaux de fibres musculaires [28]. Les régions qui parcourent toute l'épaisseur de l'échantillon de la viande (régions en correspondance) ont donc déjà été identifiées par le processus de mises en correspondance proposé au paragraphe 6.5.1; les régions résiduelles sont donc les deux autres catégories (deux et trois) selon la classification présentée au paragraphe 6.5.2. Rappelons que la deuxième catégorie correspond à des régions isolées proches de la surface, ces régions de faibles profondeurs sont les régions observables partiellement ou totalement par l'image visible, uniquement sur une seule face. La troisième catégorie inclut les régions qui sont à l'intérieur de l'échantillon et qui ne sont donc pas observables par l'image visible. Ce type de régions pourrait avoir la forme d'une masse volumique de persillage à l'intérieur de l'échantillon, ce sont souvent des régions de petites tailles comme les particules du persillage. Par ailleurs, l'illustration de la forme 2D de ce type de régions, observées par l'image proche infrarouge, en particulier pour les régions de petites tailles, montre que celle-ci a l'allure de forme circulaire ou ellipsoïdale. Ainsi, cette catégorie de régions pourrait être modélisée par une forme sphéroïdale. La figure 6.13 montre le modèle proposé pour évaluer le volume du persillage des régions isolées.




Figure 6.12. Modèle d'une région isolée du persillage.
 (a) forme réelle de la région en 2D; (b) forme du modèle en 2D;
 (c) modélisation finale.

Le processus d'estimation du volume du persillage de ce type de régions pourrait être effectué selon le modèle géométrique de la figure 6.13. Ce processus pourrait être décrit comme suit :

1. calculer la surface, l'axe majeur (principal) et l'axe mineur (secondaire) de la région de persillage (figure 6.13-a);
2. déterminer l'ellipsoïde équivalent (figure 6.13-b); et finalement,
3. déterminer (à partir de 2) le modèle volumétrique final de la région, qui est un sphéroïde (figure 6.13-c).

Ainsi, le volume de la région transformée en modèle sphéroïdale est donné par l'équation 12.

$$V_s = \frac{4}{3} \pi a b^2 \quad (12)$$

où :

- a est la demi longueur de l'axe majeur du sphéroïde; et b est la demi-longueur de l'axe mineur.

Comme nous avons classifié les régions résiduelles (isolées) en deux catégories (régions proches de la surface de faibles profondeurs et régions d'intérieur de l'échantillon), alors les deux estimations du volume de persillage sont calculées : les régions de persillage classées proches de la surface sont estimées en moitié de leur volume en considérant que

celles-ci sont approximativement l'équivalent à un demi sphéroïde (en estimant que la moitié du volume sphéroïdal (Figure 6.12) a été coupé à la surface (équation 13)), alors que les régions qui sont classées à l'intérieur de l'échantillon sont estimées en un volume d'un sphéroïde au complet (équation 14).

$$V2 = \frac{1}{2} \sum_{n=1}^{Nps} V_{S_n} \quad (13)$$

$$V3 = \sum_{n=1}^{Nin} V_{S_n} \quad (14)$$

où :

- Nps est le nombre des régions juste proches des deux surfaces;
- Nin est le nombre des régions à l'intérieur de l'échantillon de la viande.

Les proportions volumétriques, en termes de pourcentage, du persillage de ces deux catégories de régions s'expriment par les équations 15 et 16.

$$Pv2 = 100 \frac{V2}{X * Y * E} \quad (15)$$

$$Pv3 = 100 \frac{V3}{X * Y * E} \quad (16)$$

où :

- X, Y et E , respectivement sont la longueur, la largeur et l'épaisseur de l'échantillon.

6.5.2.3 Estimation de la proportion du persillage

Dans le paragraphe 6.3, une méthode de catégorisation des régions de persillage en deux catégories (persillage de surface et persillage de profondeur) a été proposée. En se basant sur l'information spatiale et photométrique contenue dans les images visibles et proches infrarouges de deux faces de l'échantillon, les régions de persillage ont été finalement

classées en trois catégories : 1) régions en correspondances qui sont visibles de part et d'autre de deux côtés de l'échantillon; 2) régions qui sont proches de l'une des deux surfaces de l'échantillon; et 3) régions qui sont à l'intérieur de l'échantillon. Ainsi, pour chaque catégorie de régions, une modélisation géométrique a été proposée (paragraphe 6.5.2.1 et 6.5.2.2). À chaque modèle, une équation mathématique a été associée afin d'estimer le volume de persillage de chaque région. La proportion volumétrique totale du persillage dans l'échantillon de la viande est la somme des proportions des trois catégories de régions de persillage (équations 11; 15 et 16) tel que exprimé par l'équation 17.

$$P_v = P_{v1} + P_{v2} + P_{v3} \quad (17)$$

La méthode proposée pour l'évaluation de la proportion volumétrique du persillage contenu dans un échantillon de viande de bœuf se résume comme suit :

1. segmenter les images visibles et proches infrarouges afin d'isoler le persillage des muscles;
2. identifier les régions de persillage proches de la surface à partir de l'image proche infrarouge. Ainsi, deux catégories de régions de persillage sont obtenues (régions de surface et régions de profondeur) ;
3. identifier les petites régions de surface et de tailles minuscules (un seuil définissant la taille maximale d'une région pourrait être utilisé pour identifier ces régions. Ce seuil pourrait dépendre de la résolution de l'image);
4. identifier les régions en correspondance à partir des régions de surface obtenues à l'étape 2. Ainsi, trois catégories de régions de persillage sont obtenues (régions en correspondance entre les deux faces de l'échantillon, régions proches de la surface isolées localement et régions de profondeur qui sont à l'intérieur de l'échantillon);
5. calculer la proportion volumétrique du persillage pour les trois catégories de régions selon les modèles volumétriques proposés pour chaque catégorie de régions (équations 11; 15 et 16);
6. calculer la proportion totale du volume du persillage contenu dans la totalité de l'échantillon de la viande (équation 17).

6.6 Résultats et discussion

Nous avons appliqué la méthode proposée (paragraphe précédent) sur plusieurs échantillons de viande de bœuf. Les échantillons expérimentés auraient des épaisseurs et des densités de persillage variables. On dénombre plus de 50 échantillons dans notre base de données. Afin de réaliser une étude plus judicieuse de la méthode proposée, indépendamment de la phase de la segmentation, nous avons vérifié visuellement les résultats de la segmentation des images visibles et proches infrarouges. Ainsi nous avons corrigé manuellement les éventuelles images sur et/ou sous-segmentées.

Le tableau 6.1 illustre les résultats des proportions de persillage estimé sur quelques échantillons représentatifs de même catégorie (grade) AAA du muscle *Longissimus dorsi* de bœuf Angus pris dans notre base de données.

Tableau 6.1. Estimation des proportions volumétrique du persillage dans des échantillons de viande de bœuf de même grade.

Échantillon	1	2	3	4	5	6	7	8	9	10	m	e
Pv (%)	17,6	14,5	22,8	17	17,5	12,6	20,3	20,3	18,0	17,1	17,3	0,35

* Pv : % en volume selon l'équation 17; m = moyenne; et e = écart type.

Ces résultats démontrent que les proportions du persillage obtenues sont élevées ce qui reflète la nature d'une viande classée AAA. Cependant ces résultats ne sont pas uniformes, ils sont plutôt variables et aléatoires malgré le fait que les échantillons prennent tous du même grade. De plus, il est clair qu'il n'y a pas de lien ou de rapport évident entre les proportions de persillage des échantillons. À titre d'exemple, une faible proportion de persillage observée sur l'échantillon numéro x (ex : x = 1) ne signifie pas non plus une faible proportion observée sur l'échantillon numéro x+1 (ex : x+1 = 2), ce qui appuie ce qu'on a démontré dans notre revue de littérature (paragraphe 6.5) : la distribution de persillage est aléatoire à travers le muscle de la viande.

6.7 Méthode chimique

La méthode chimique est la méthode de référence utilisée pour évaluer le niveau de gras intramusculaire (persillage) dans toute sorte de viande incluant celle de bœuf. Cette méthode est fastidieuse, elle prend beaucoup de temps à réaliser (souvent plusieurs heures), elle est coûteuse, destructive et n'offre aucune information sur la distribution du persillage dans la viande. Le processus d'évaluation de ce genre de méthode est semblable d'un laboratoire à un autre. Brièvement, il s'agit de sécher l'échantillon par lyophilisation afin d'évaporer l'eau, peser l'échantillon (gras+muscle), et finalement extraire le gras seul et le muscle seul par un processus chimique (ex : utiliser l'éther comme solvant pour dissoudre le gras puis évaporer l'éther pour garder le gras seul) [97]. La proportion de persillage par rapport au muscle se calcule alors en termes de poids.

Pour valider la méthode numérique proposée dans cette thèse, nous avons utilisé la méthode chimique officielle accréditée par *L'Association of Official Agricultural Chemists* (AOAC) pour ce genre d'application (AOAC 991.36) [97]. Cette méthode, qui est la « *gold standard* » pour la méthode proposée, a été effectuée par Mme Nancy Bolduc technicienne en travaux d'enseignement et de recherche au Département des sciences animales de l'Université Laval sur 22 échantillons de viande de bœuf. Les mêmes échantillons ont été analysés numériquement par la méthode proposée afin d'estimer la proportion de persillage dans chaque échantillon avant d'être envoyé pour analyse chimique (voir Annexe B pour plus d'information sur le protocole expérimental). Ainsi, les résultats de l'estimation de la proportion de persillage contenu dans ces échantillons, résultats obtenus par la méthode proposée, sont comparés et validés par rapport aux résultats obtenus par la méthode chimique.

6.8 Évaluation quantitative de la méthode proposée

La méthode proposée a été expérimentée sur un grand nombre d'échantillons de viande de bœuf. Par la suite, nous avons comparé et évalué la méthode proposée par rapport à la méthode chimique (paragraphe 6.7) sur 22 échantillons. Ces échantillons ont permis d'obtenir 88 images (22*4 images) à traiter dans notre base de données. Ces échantillons,

sont diversifiés : faux filet, filet mignon, du steak et du muscle *Longissimus dorsi* de bœuf Angus. Les échantillons sont de grades variables avec des épaisseurs allant de 5 à 7 mm. Ces échantillons ont été obtenus sur une période de deux mois à partir des tablettes des magasins spécialisés en boucherie. On peut supposer que leur approvisionnement pourrait provenir de plusieurs fermes bovines de différentes régions géographiques et qui n'ont pas nécessairement le même système d'élevage. Ces facteurs d'élevage agissent sur la qualité de persillage déposé entre les muscles [28]. Pour chaque échantillon, les images visibles et proches infrarouges des deux côtés de l'échantillon ont été obtenues dans les mêmes conditions expérimentales (ex : même intensité d'éclairage). Les deux images visibles ont été acquises en mode réflexion en utilisant un éclairage fluorescent et les deux images proches infrarouges ont été acquises en mode transmission en utilisant un projecteur proche infrarouge d'une longueur d'onde de 940 nm. L'ajustement du montage expérimental a été parfois variable mais dans la plupart des cas il a été comme suit : la lentille de la caméra est égale à 12 mm, la distance CCD-échantillon est égale à 41 cm, la distance de la lumière proche infrarouge à l'échantillon est égale à 30 cm, et la distance entre le diffuseur de la lumière et l'échantillon est égale à 9 cm (voir dispositif de la figure 6.1).

Les résultats de l'estimation de la proportion volumétrique du persillage obtenus par la méthode proposée (analyse visible/NIR du persillage humide) ont été évalués par rapport aux résultats obtenus par la méthode chimique (gras intramusculaire sur une base sèche). Le tableau 6.2 illustre les résultats de proportions du volume du persillage obtenus par les deux méthodes (voir Tableau B.1 en annexe B pour consulter tous les valeurs).

Tableau 1.2. Proportions du volume de persillage obtenu par la méthode proposée et par la méthode chimique.

Échantillon	% gras Visible /NIR	% gras chimique	Écart
1	11,61	9,55	2,06
2	12,4	12,80	0,4
3	18,06	13,13	4,93
4	16,13	13,51	0,34
5	16,13	13,51	2,62
6	19,75	15,65	4,1
7	14,52	16,92	2,4
...
22	25,01	30,60	5,59
Moyenne	18,31	20,07	3,82
Écart type	9,47	14,88	2,49

Il ressort de ce tableau, que les valeurs obtenues par les deux méthodes ont une tendance raisonnablement régulière (variations synchronisées) : par exemple, une proportion élevée du persillage dans l'échantillon selon la méthode chimique est aussi observée selon la méthode proposée et inversement. La figure 6.12 illustre les tendances graphiques des résultats obtenus par les deux méthodes.




Figure 6.13. Illustration graphique de la proportion de persillage obtenue par la méthode proposée versus la méthode chimique.

La figure 6.12 montre une illustration graphique des résultats obtenus par la méthode proposée versus la méthode chimique. À l'exception du résultat obtenu pour l'échantillon numéro 14 qui présente un pic remarquable, les deux courbes démontrent une tendance raisonnablement synchronisée entre les résultats obtenues par les deux méthodes. La différence remarquable observée pour l'échantillon numéro 14 pourrait être due à diverses raisons, par exemple : la distribution du gras, sa densité, etc. fait en sorte qu'il est plus difficile à évaluer par la méthode proposée; ou tout simplement, peut y avoir une erreur dans les résultats de part et d'autre dans la méthode chimique ou dans la méthode proposée. Advenant qu'il n'y a pas d'erreur d'estimation sur un échantillon au niveau de la méthode chimique, la différence de résultat pourrait être attribuée à une erreur expérimentale. Par exemple, l'échantillon estimé par la méthode proposée n'est pas exactement celui estimé par la méthode chimique (ex. : mal coupé, voir annexe B).

6.8.1 Calibrage des résultats et évaluation quantitative

Afin d'évaluer quantitativement les résultats obtenus par la méthode proposée (proportion volumétrique du persillage) par rapport aux résultats obtenus par la méthode chimique (%)

gras sur base sèche), nous allons d'abord calibrer les résultats obtenus par la méthode proposée par rapport aux résultats obtenus par la méthode chimique. Ce processus consiste à transférer, par un modèle mathématique, les résultats obtenus par la méthode proposée en des résultats équivalents à ceux obtenus par la méthode chimique. Pour ce faire, nous allons modéliser, par une régression linéaire, la proportion du persillage obtenu par les deux méthodes sur quelques échantillons représentatifs de l'ensemble des échantillons à évaluer. Ainsi, nous avons partagé les données (les résultats) en deux ensembles : un pour la modélisation et l'autre pour l'évaluation des résultats. Par ailleurs, les valeurs observées à la figure 6.13, indiquent que les résultats obtenus par les deux méthodes pourraient être liés par une modélisation linéaire (tendance graphique linéaire).

La régression linéaire du premier ordre entre les deux méthodes obtenue avec la moitié des échantillons (1, 3, 5, ..., 19 et 21) est donnée par l'équation suivante :

$$y_{pc} = 0,9x_p + 2,28 \quad (18)$$

où :

- x_p est valeur obtenue par la méthode proposée;
- y_{pc} est la valeur calibrée.

Ainsi, l'étude comparative entre les résultats obtenus par la méthode proposée versus la méthode chimique pourrait être effectuée par une analyse de la corrélation entre les deux méthodes, à savoir le calcul du coefficient de corrélation de Pearson [112]. Dans ce travail de doctorat, nous allons utiliser le coefficient de Pearson pour mesurer la force d'association entre les valeurs estimées par la méthode proposée et celles mesurées par la méthode chimique. Mathématiquement, la valeur du coefficient de corrélation de Pearson varie entre -1 et 1. D'une façon générale, une valeur proche de 1 (ex : entre 0,8 et 1) indique que les deux méthodes sont fortement corrélées, entre 0,5 et 0,8 celle-ci indique une corrélation modérée et une valeur inférieure à 0,5 indique une corrélation faible. Inversement, une valeur de corrélation de signe négatif traduit une corrélation négative. La figure 6.14 illustre la distribution conjointe de la proportion du gras intramusculaire estimé par la méthode proposée (valeurs calibrées) versus la méthode chimique.




Figure 6.14. Distribution conjointe de la proportion du gras intramusculaire estimé par la méthode proposée versus la méthode chimique.

La figure 6.13 illustre la régression linéaire calculée entre la méthode proposée et la méthode chimique. Tel qu'illustré graphiquement, l'écart entre les deux résultats est relativement rapproché, ceci à tous les niveaux des proportions du persillage dans les échantillons. Ceci démontre une similitude viable entre les deux méthodes.

Le coefficient de corrélation de Pearson r observé ici est égal à 0,71, ce qui démontre une corrélation relativement modérée à élevée entre les deux méthodes.

La précision de la méthode proposée par rapport à la méthode chimique (« *gold standard* ») pourrait être exprimée par l'Erreur standard de prédiction (ESP) [112]. Elle se calcule comme suit :

$$ESP = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_p - X_r)^2} \quad (19)$$

où :

- X_p est la valeur prédite; X_r est la valeur de référence et N est le nombre des valeurs observées.

L'application de l'équation 19 sur les données obtenues donne une ESP de 3,68. La signification de cette valeur dépend de la précision qu'on cherche. Toutefois, dans cette première étude académique, nous considérons que cette ESP est raisonnable étant donné que celle-ci est comparable à l'écart type moyen (2,49) entre les résultats obtenus la méthode proposée versus ceux de la méthode de référence.

Afin de confirmer que la corrélation entre les deux méthodes (test de la régression linéaire précédente) se tient et que le risque est faible (ou non critique) d'avoir des valeurs obtenues, par le hasard, par la méthode proposée, nous allons utiliser le test statistique de l'hypothèse nulle, notée H_0 [112]. Ce test consiste à évaluer la vraisemblance entre les deux méthodes. Le risque de rejeter à tort l'hypothèse nulle H_0 alors qu'elle est vraie est consenti à l'avance. Il est fixé par un seuil qui s'appelle le seuil de signification du test, connu en probabilité par la notation P_{value} . Le P_{value} se calcule selon la loi de probabilité utilisée en calcul statistique [112]. Le P_{value} correspond à la probabilité de rejeter H_0 sachant que H_0 est vraie. En statistique, le choix de la valeur de P_{value} dépend des conséquences de rejeter à tort l'hypothèse H_0 . La plus utilisée est de 0,05 (ou 5% du hasard).

Selon les résultats statistiques des proportions de persillage obtenues par la méthode proposée, l'analyse de la variance ou ANOVA donne un $P_{\text{value}} = 0,6$. Ceci démontre que les valeurs obtenues par la méthode proposée et la méthode chimique ne présentent pas de différences significatives.

Dans cette section la méthode proposée a été évaluée par rapport à la méthode chimique (paragraphe 6.7). Les résultats statistiques issus de cette étude démontrent que les deux méthodes utilisées présentent une corrélation relativement bonne ($r = 0,71$) et des résultats comparables pour l'évaluation de la proportion de persillage (ANOVA, $P_{\text{value}} = 0,6$). Ceci démontre la validité de la méthode proposée.

6.9 Conclusion

Dans ce chapitre une nouvelle méthode non-destructive d'évaluation de la proportion de persillage dans la viande de bœuf est proposée. Selon notre recherche bibliographique et au meilleure de notre connaissance, aucune méthode semblable n'a été élaborée. Ainsi, l'approche de vision artificielle proposée dans le cadre de cette thèse permet d'évaluer non seulement la quantité du persillage à la surface mais aussi en totalité de l'échantillon. L'étude menée dans ce chapitre a démontré qu'en utilisant un système de vision hybride (visible et proche infrarouge), il est possible d'analyser la distribution de persillage à la surface tout comme en profondeur de l'échantillon et d'estimer de manière non-destructive la proportion de persillage dans la totalité de celui-ci. De plus, contrairement aux méthodes chimiques, qui est la méthode officielle, la méthode développée dans cette thèse est non-destructive, rapide et peu coûteuse.

L'évaluation de la méthode proposée a été effectuée par rapport aux résultats obtenus par une analyse chimique entant que « gold standard ». L'analyse statistique de la corrélation entre les deux méthodes démontre la viabilité de la méthode proposée comme méthode non-destructive d'estimation de la proportion de persillage dans la viande de bœuf.

Chapitre 7

Conclusion

Le persillage (gras intramusculaire) dans la viande de bœuf est l'un des critères les plus importants pour évaluer la qualité, notamment la "jutosité", dans les systèmes de classification de la viande. L'analyse chimique, méthode destructive, est le moyen officiellement utilisé dans les laboratoires de recherche et de contrôle de la qualité pour évaluer la proportion de persillage dans un échantillon de viande. C'est une méthode destructive, complexe et qui n'offre aucune information sur la distribution de persillage dans la viande.

Au cours de ces travaux de doctorat, une méthode non-destructive destinée à l'évaluation volumétrique du persillage dans la viande de bœuf est proposée. Cette nouvelle méthode, qui pourrait être intégrée industriellement, à long terme, dans un système de vision (*machine vision*), serait une première dans ce domaine. En effet, au meilleur de notre connaissance, aucune méthode semblable n'a été élaborée bien qu'il existe d'autres études et méthodes qui ont été proposés tel que cité au chapitre 6. Contrairement à la méthode chimique, la méthode proposée est non-destructive, rapide et aucun produit chimique n'est utilisé pour la réaliser. De plus, au-delà de l'évaluation quantitative du persillage, la méthode proposée permet d'extraire plusieurs informations supplémentaires, indispensables à l'étude de la qualité de la viande, telles que la distribution et l'architecture du persillage dispersé à travers l'échantillon de viande.

La motivation derrière ce projet de recherche vient d'une part de l'originalité de sa problématique et d'autre part, des défis à relever pour surmonter les difficultés affrontées au cours du développement d'une telle méthode. Quant aux difficultés rencontrées pour la mise en œuvre de la méthode proposée, nous pouvons citer la segmentation d'images, la reconnaissance du persillage à travers les muscles et l'estimation de la proportion

volumétrique du persillage dans la viande. Pour résoudre le problème de la segmentation, nous avons proposé une méthode originale basée sur un modèle mathématique permettant d'évaluer l'homogénéité des régions en termes de niveaux de gris. Cette nouvelle méthode, qui est relativement générale, permet d'extraire les régions les moins (ou les plus) claires dans une image à niveaux de gris. L'implémentation de cette méthode a été effectuée avec succès dans un algorithme appelé FCE "*First Class Extraction*". Parmi les avantages de cet algorithme, il y a sa robustesse face au bruit et sa sensibilité face au changement de contraste entre les régions et l'ombre dans l'image, ce qui convient bien à notre application. La généralisation de cet algorithme pour une segmentation appliquée aux images visibles et proches infrarouges au niveau de notre approche a démontré des résultats satisfaisants pour les objectifs attendus. Quant au problème de l'estimation de la proportion volumétrique du persillage dans l'échantillon de la viande, il a été résolu en deux étapes. La première consiste en une catégorisation des régions de persillage en se basant sur une mesure de similarité et en fonction de leurs positions spatiales en profondeur par rapport à la surface de l'échantillon. Ainsi trois catégories sont issues de ce classement : régions en correspondance entre les deux faces de l'échantillon, régions proches de la surface, et régions intérieures de l'échantillon. La deuxième étape consiste en une modélisation géométrique des régions du persillage en fonction de leurs catégories. Ceci permet d'estimer la proportion volumétrique du persillage dans la totalité de l'échantillon de la viande.

❖ Contributions

De ces travaux de doctorat, quatre contributions scientifiques notables sont identifiées soit: la technique proposée, deux méthodes de segmentation d'images et une méthode non-destructive pour estimer la proportion volumétrique du persillage, en plus de l'intégration de toutes ces contributions dans une même méthode. Ainsi, plusieurs publications scientifiques découlent de ces contributions, entre des articles des journaux, de conférence et des posters pour des conférences. Certaines de ces publications sont déjà réalisées :

- a. A. Ziadi, X. Maldague, L. Saucier, "Near-Infrared Light Transmission in Beef Meat and Qualitative Marbling Evaluation Using Image Analysis",

ICGST International Journal on Graphics, Vision and Image Processing, GVIP, Vol. 9, No: 6, pp: 7-12, 2009.

- b. A. Ziadi, X. Maldague, L. Saucier, “Image analysis in computer vision: A high level means for Non-Destructive evaluation of marbling in beef meat”, *Proceedings of the 10th edition of the Quantitative Infrared Thermography (QIRT), International conference, Vol.1. No.1, pp: 541-548, 2010.*
- c. A. Ziadi, L. Saucier, X. Maldague, “Extraction of homogeneous gray-level regions using the “First Class Extraction” algorithm”, *Journal of Machine Vision and Applications, (accepté) 2011.*
- d. A. Ziadi, X. Maldague, L. Saucier, “Visible and Near-Infrared Light Transmission: A hybrid Imaging Method for Intramuscular Fat Evaluation”, *Canadian Meat Science Association, Technical Symposium of Halifax, 2011 (postère).*
- e. A. Ziadi, X. Maldague, L. Saucier, “A new Technique for Non-Destructive Measurement of Marbling in Beef Meat Using Visible and Near-Infrared Imaging”, *57th International Congress of Meat Science and Technology (ICoMST), 2011.*

Les originalités qui découlent de cette thèse se manifestent au niveau de la technique proposée ainsi que des fondements scientifiques adoptés pour solutionner ce problème. En effet, nous avons démontré au deuxième chapitre ainsi qu’aux articles [a-b], que l’emploi de la lumière proche infrarouge en mode transmission permet de détecter le persillage non seulement à la surface comme dans le cas traditionnel d’une image visible, mais aussi en profondeur de l’échantillon de viande. De plus, l’emploi d’une seule caméra à la fois dans le spectre visible pour l’image de la surface et dans le spectre proche infrarouge pour l’image de profondeur du persillage permet d’offrir un système de vision artificielle hybride (visible et proche infrarouge). L’intégration industrielle de cette approche pour le contrôle de la qualité de la viande constituera sans doute une avancée majeure dans la façon d’effectuer une estimation non-destructive du persillage contenu dans un échantillon de viande.

La technique proposée nous permet d’avoir deux types d’images : une image visible de la surface de la viande et une image proche infrarouge de la surface et du dessous de la

surface de l'échantillon. Celle-ci est la projection orthogonale de l'échantillon de viande (3D) en une image d'ombre (2D). L'étude réalisée au deuxième chapitre a révélé la nature des images à traiter pour la détection du persillage à travers les muscles de la viande. Pour les deux types d'images visibles et proches infrarouges, les régions du persillage sont de tailles (surfaces) variables allant de régions minuscules (quelques pixels par région) à des régions de tailles plus importantes. Cette variation est semblable au point de vue épaisseur (ou volume) des régions. En conséquence, le contraste en niveaux de gris entre les régions de persillage et les muscles pourrait être : considérable dans le cas des grandes régions de persillage, souvent faible dans le cas des petites régions et aussi pour les régions ayant de petites épaisseurs.

Dans le cas des images proches infrarouges, les images sont affectées par l'ombre, des régions qui occultent d'autres régions, ce qui pourrait causer une ambiguïté entre les régions de persillage et les zones de muscle affectées par l'ombre. L'ensemble de ces facteurs nous met face à des défis à relever pour segmenter les images en régions afin de détecter le persillage. La revue de littérature sur les méthodes de segmentation d'image présentée au troisième chapitre nous a conduits à privilégier le développement d'une méthode de segmentation d'images en régions qui s'adapte le mieux possible à notre application. Pour ce faire et compte tenu de la complexité de l'analyse d'images qui est due entre autres, à la variation de l'ombre et du faible contraste entre les régions de persillage et du muscle, nous avons développé, au quatrième chapitre, une méthode efficace de segmentation qui s'adapte le mieux possible avec notre application. Cette méthode, qui est relativement générale, permet d'identifier les régions homogènes les plus (ou les moins) claires dans une image en niveaux de gris. Elle est basée sur un modèle mathématique permettant d'évaluer l'homogénéité des régions en termes de niveaux de gris. Ce modèle a aussi été introduit dans cette thèse. L'implémentation de cette méthode par un algorithme appelé "*First Class Extraction*" (FCE) a démontré que la simplicité conceptuelle de la méthode proposée la rend efficace pour segmenter les régions homogènes les plus (ou les moins) claires dans une image à niveaux de gris. Les expériences réalisées sur différentes catégories d'images démontrent la qualité des résultats obtenus et confirment les propriétés attendues de cet algorithme.

La généralisation de cette méthode, au chapitre 5, pour la segmentation en régions des images visibles et proches infrarouges de la viande de bœuf, a démontré des résultats satisfaisants face aux objectifs attendus.

Puisque la forme volumétrique d'une section de persillage est aléatoire et que celle-ci dépend de la façon dont le persillage se dépose entre les fibres musculaires, ce qui est imprévisible, même en anatomie animale au meilleure de notre connaissance, nous avons combiné les résultats de la segmentation de deux types d'images de deux faces de l'échantillon de viande pour estimer la proportion du persillage contenu dans celui-ci. L'intégration des travaux précédents nous a permis, finalement, de développer une nouvelle méthode non-destructive pour estimer la proportion volumétrique du persillage dans la viande de bœuf. Ainsi, dans un premier lieu, dans une étude préliminaire que nous avons publiée dans l'article [b], nous avons proposé une méthode permettant d'estimer la proportion minimale et maximale de persillage dans un échantillon de viande et finalement, au chapitre six, nous avons proposé avec succès une méthode non-destructive permettant d'estimer avec une précision acceptable la proportion de persillage contenue dans un échantillon de viande. Selon notre recherche bibliographique, aucune méthode semblable n'a été développée. Cette méthode a été développée principalement en deux étapes :

1. une catégorisation des régions de persillage segmentées en se basant sur une mesure de similarité et en fonction des positions spatiales en profondeur et par rapport à la surface de l'échantillon. Une technique de mesure de similarité entre les régions de chaque face, également proposée aux chapitre six, a permis d'identifier les régions en correspondance avec les deux faces. Ainsi, trois catégories de persillage sont issues de ce classement soit : les régions en correspondance entre les deux faces de l'échantillon ; les régions proches de la surface, et les régions intérieures de l'échantillon.
2. une modélisation géométrique des régions de persillage en fonction de leurs catégories, ce qui permet d'estimer la proportion volumétrique du persillage dans la totalité de l'échantillon de viande.

Ainsi, l'efficacité de la méthode proposée pour l'estimation du persillage est basée non seulement sur la méthode elle-même, mais aussi sur les approches utilisées comme étapes intermédiaires pour développer la méthode au complet à savoir : la technique d'acquisition d'images, l'algorithme FCE et la méthode de segmentation et de reconnaissance du persillage.

Les résultats obtenus par la méthode proposée (non-destructive) dans cette thèse pour l'estimation de la proportion volumétrique du persillage dans la viande de bœuf ont été comparés aux résultats obtenus par l'analyse chimique (destructive) comme méthode officielle (« gold standard »). L'analyse statistique de la corrélation entre les résultats obtenus par les deux méthodes démontre la viabilité de la méthode proposée comme méthode non-destructive d'estimation de la proportion du persillage dans la viande de bœuf.

❖ Perspectives de recherches futures

Cette thèse a menée à la production de plusieurs contributions scientifiques d'intérêt. La méthode proposée pour l'estimation non-destructive de la proportion du persillage dans la viande de bœuf pourrait être considérée comme un premier pas vers le développement d'un système de vision artificielle (*machine vision*) destiné au contrôle de qualité de la viande sur la ligne d'abattage. Les approches proposées dans ces travaux de doctorat sont raisonnablement suffisantes pour la mise en œuvre pratique d'une méthode d'estimation du persillage. Toutefois, certains aspects techniques et méthodiques pourraient être revus :

- le système d'acquisition d'images : nous avons réalisé nos expérimentations avec une caméra dont la réponse spectrale est bonne dans le visible, mais moyenne dans le proche infrarouge. Le choix de la caméra est indispensable, donc il serait intéressant d'avoir accès à une caméra plus performante;
- le système d'éclairage visible et proche infrarouge : l'uniformité de l'éclairage est très importante dans un système de vision. Nous avons utilisé un système

d'éclairage d'uniformité relativement modeste, il serait préférable d'intégrer au système global un système d'éclairage de bonne uniformité et d'intensité variable;

- le temps de calcul : la notion de *temps réel* n'est pas un facteur critique dans la méthode proposée. Toutefois, du point de vue pratique, il serait intéressant de revoir la structure des algorithmes afin d'optimiser le temps de calcul.
- Les réalisations expérimentales ont été accompagnées de quelques difficultés pratiques, tels que la facilité d'obtention des échantillons avec des coupes uniformes et la disponibilité d'un laboratoire pour ce genre d'expériences. Comme l'approche d'acquisition d'images (chapitre 2) ainsi que les méthodes d'analyses d'image (chapitres 4, 5 et 6) sont, relativement, générales, il est pertinent de refaire un plus grand nombre d'échantillon homogènes sur différents muscles et différentes espèces (ex. : porc, gibier) couplé à une analyse chimique complète en duplicata pour améliorer et généraliser la méthode proposée à d'autres types de viande.

D'autres pistes de recherches futures pourraient être explorées :

- La méthode proposée dans cette thèse incorpore un système d'éclairage proche infrarouge d'une longueur d'onde de 940 nm. Toutefois, un éclairage multi-longueur d'ondes permettrait l'accès à d'autres techniques d'analyse d'image qui pourraient améliorer la performance de la méthode d'estimation du volume du persillage;
- L'approche d'acquisition d'images proposée dans cette thèse est basée sur une acquisition de type matricielle "*area scan*". Cependant, l'étude d'un nouveau système d'acquisition linéaire, "*line scan*", est une approche qui est potentiellement intéressante. Étant donné que l'éclairage se fait localement (ligne par ligne), ceci pourrait révéler des informations pertinentes sur l'architecture tridimensionnelle du persillage avec précision à l'intérieur de la viande.

Bibliographie

- [1] T. Pun, G. Gerig, O. Ratib, "Image analysis and computer vision in medicine", *Computerized Medical Imaging and Graphics*, Vol. 18, No. 2, pp. 85-96, 1994.
- [2] A. El Maadi, X. Maldague, "Outdoor Infrared Video Surveillance : A novel dynamic technique for the subtraction of a changing background of IR images", *Infrared Physics & Technology*. Vol. 49, pp: 261-265, January 2007.
- [3] G.A. Ruz and P.A. Estévez, "Image segmentation using fuzzy min-max neural networks for wood defect detection", *Intelligent Production Machines and Systems*, D.T. Pham, E.E. Eldukhri and A.J. Soroka (Eds), 2005, pp:183-188.
- [4] K. Chen, Ch. Qin, "Segmentation of beef marbling based on vision threshold", *Computers and Electronics in Agriculture*. Vol. 62, pp:223-230, 2008.
- [5] Faucitano L., Huff P., Teuscher F., Gariépy C., Wegner J., "Application of computer image analysis to measure pork marbling characteristics", *Meat Science*, No: 69, pp.537-543, 2005.
- [6] <http://www.cbef.com/beefquality.htm>, (consulté en juillet 2010).
- [7] Yoshikawa F., Toraichi K., Wada K., Ostu N., Nakai H., Mitsumoto M., K. Katagishi, "On a grading system for beef marbling", *Pattern Recognition Letters*, Vo. 21, pp.1037-1050, 2000.
- [8] Lu J., Tan J., Shatadal P., Gerrard D.E., "Evaluation of pork color by using computer vision", *Meat Science*, Vol. 56, pp. 57-60, 2000.
- [9] N. Otsu, "A threshold selection method from gray-level histograms", *IEEE Transactions on systems, Man, and Cyber.*, Vol. 9, No.1, p. 62-66, 1979.
- [10] Shiranita K., Miyajima T., Takiyama R., "Detrmination of meat quality by texture analysis", *Pattern Recognition Letters*, Vo. 19, pp.1319-1324, 1998.
- [11] Tan J., "Meat quality evaluation by computer vision", *Journal of Food Engineering*, Vol. 61, pp.27-35, 2004.
- [12] Toraichi K., Kwan P.W.H., Katagishi K., Sugiyama T., Wada K., Mitsumoto M., Nakai H., Yoshikawa F., "On a Fluency Image Coding System for Beef Marbling Evaluation", *Pattern Recognition Letters*, Vol. 23, pp.1277-1291, 2002.
- [13] Naganathan G..K, Grimes L. M., Subbiah J., Calkins C. R., "Predicting Beef Tenderness using Hyperspectral Imaging", *An ASABE Meeting Presentation*, Paper Number: 063036, July 2006.
- [14] Qiao J., Ngadi M. O., Wang N., Gariépy C., Prasher S. O., "Pork quality and marbling level assessment using a Hyperspectral imaging system", *Journal of Food Engineering*, Vol. 83, pp.10 -16, 2007.
- [15] Rust S. R., Price D.M., Subbiah J., Kranzler G., Hilton G. G., Vanoverbeke D. L., Morgan J. B., "Predicting beef tenderness using near-infrared spectroscopy", *Journal of animal science*, No: 86, pp.211-219, 2008.
- [16] X. P. Maldague, 2001, *Theory and Practice of Infrared Technology for Nondestructive Testing*, John Wiley & Sons, N. Y.
- [17] Brian G. Osborne, "Near-infrared Spectroscopy in Food Analysis", *Encyclopedia of Analytical Chemistry*, John Wiley & Sons Ltd, Chichester. ISBN 0471 97670 9.
- [18] R. Gosselin, D. Rodrigue, C. Duchesne, "On-Line Prediction Of Crystallinity Spatial Distribution Across Polymer Films Using NIR Spectral Imaging And

- Chemometrics Methods”, *The Canadian Journal of Chemical Engineering*, Vol.86, No: 5, pp:869-878, 2008.
- [19] R. Gosselin, D. Rodrigue, R. Gonzalez, C. Duchesne, “Potential of Hyperspectral Imaging for Quality Control of Polymer Blend Films”, *Industrial & Engineering Chemical Research*, Vol.48, No: 6, pp: 3033-3042, 2009.
- [20] J. Workman, Jr. L. Weyer. “Practical Guide to Interpretive Near-Infrared Spectroscopy”, *CRC Press, Taylor & Francis Group*, ISBN 1-57444-784-X, 2007.
- [21] http://fr.wikipedia.org/wiki/Loi_de_Beer-Lambert (consulté en septembre 2010).
- [22] Y. Liu, B. G. Lyon, W. R. Windham, C.E. Realini, T. Dean D. Pringle, S. Duckett, “Prediction of color, texture, and sensory characteristics of beef steaks by visible and near infrared reflectance spectroscopy. A feasibility study ” *Meat Science*, Vol. 65, pp: 1107–1115, 2003.
- [23] R. Rùdbotten, B.N. Nilsen, K.I. Hildrum, “Prediction of beef quality attributes from early post mortem near infrared reflectance spectra”, *Food Chemistry*. Vol.69, No.4, pp: 427-436, 2000.
- [24] R.M. García-Rey, J. García-Olmo, E. De Pedro, R. Quiles-Zafra, M.D. Luque de Castro, “Prediction of texture and colour of dry-cured ham by visible and near infrared spectroscopy using a fiber optic probe”, *Meat Science*, Vol.70, No.2, pp: 357–363, 2005.
- [25] R.L.P. van Veen and H.J.C.M. Sterenborg, A. Pifferi, A. Torricelli and R. Cubeddu, “Determination of VIS- NIR absorption coefficients of mammalian fat, with time-and spatially resolved diffuse reflectance and transmission spectroscopy”, *Proc. Biomedical Topical Meetings, on CD-ROM, Paper SF5, Optical Society of America*, Washington, DC, 2004.
- [26] R. Rùdbotten, B.N. Nilsen, K.I. Hildrum, “Prediction of beef quality attributes from early post mortem near-infrared reflectance spectra”, *Food Chemistry*, Vol. 69, pp: 427-436, 2000.
- [27] S. Andre’, I. Murray, E.A. Navajas, A.V. Fisher, N.R. Lambe, L. Bunger, “Prediction of sensory characteristics of lamb meat samples by near infrared reflectance spectroscopy”, *Meat Science*, Vol. 76, pp: 509–516, 2007.
- [28] B. Leuret, L. Lefaucheur, J. Mourot, “La qualité de la viande de porc Influence des facteurs d’élevage non génétiques sur les caractéristiques du tissu musculaire”, *INRA Prod. Anim.*, Vol. 12, No.1, pp :11-28, 1999.
- [29] <http://www.nirtech.net> (consulté en septembre 2010).
- [30] Deshmukh K.S, Shinde G.N, “An Adaptive Color Image Segmentation”, *ELCVIA : Electronic Letters on Computer Vision and Image Analysis*, 2005, Vol. 5, No. 4, pp: 12-23, 2005.
- [31] J.H Chang, K.C Fan, Y.L Chang, “Multi-modal gray-level histogram modeling and decomposition”, *Image and Vision Computing*, Vol. 20, pp:203-216, 2002.
- [32] J. Silverman, S. R. Rotman, C. E. Cafer, “Segmentation of multi-dimensional infrared imagery from histograms”, *Infrared Physics & Technology*, Vol 45, pp:191-200, 2004.
- [33] D.C. Tseng, Y. F. Li, and C. T. Tung, “Circular histogram thresholding for color image segmentation”, *Proceeding of the Third International Conference of Document Analysis and Recognition*, Montreal, Canada, Vol. 2, pp: 673-676, 1995.

- [34] F. Kurugollu, B. Sankur, A.E. Harmanci, "Color image segmentation using histogram multithresholding and fusion", *Image and Vision Computing*, Vol. 19, No : 13, pp:915-928, 2001.
- [35] Z. Yang, Z. Pu, Z. Qi, "Relative entropy multilevel thresholding method based on genetic optimization", *Int. Conf. Neural Networks & Signal Processing*, Vol 1, pp: 583-586, 2003.
- [36] Thrasyvoulos N. Pappas, "An Adaptive Clustering Algorithm for Image Segmentation", *Transactions on signal processing*, Vol 40, No. 4, 1992.
- [37] C. W. Chen, J. Luo, K. J. Parker, "Image segmentation via Adaptive K-Mean Clustering and Knowledge-Based Morphological Operations with Biomedical Applications", *Transactions on Image Processing*, Vol. 7, No. 12, 1998.
- [38] J. B. MacQueen "Some Methods for classification and Analysis of Multivariate Observations, Proceedings of 5-th Berkeley Symposium on Mathematical Statistics and Probability", *Berkeley, University of California Press*, 1:281-297, 1967.
- [39] Bezdek, J.C, "Pattern Recognition with Fuzzy Objective Function Algorithms". *Plenum Press*, New York, 1981.
- [40] R. Krishnapuram, J. M. Keller, "A Possibilistic Approach to Clustering", *Transaction on Fuzzy Systems* Vol. 1, No. 2, 1993.
- [41] M. Fleury, L. Hayat, A.F. Clark, "Parallel entropic auto-thresholding", *Image and Vision Computing*, Vol. 14, pp: 247-263, 1996.
- [42] N.R. Pal, S.K. Pal, "Object-background segmentation using new definitions of entropy", *Computers and Digital Techniques*, IEE Proceedings, Vol. 136, pp: 284-295, 1989.
- [43] M. Poyes de Albuquerque, I.A. Esquef, A.R. Gesualdi Mello, M. Portes de Albuquerque, "Image thresholding using Tsallis entropy", *ELSEVIER*, 1059-1065, 2004.
- [44] A. Plastino, A.R. Plastino, "Tsallis Entropy and Jaynes' Information Theory Formalism", *Brazilian Journal of Physics*, Vol, 29, pp: 50-60, 1999.
- [45] C.H. Li, C.K. Lee, "Segmentation of die patterns using minimum cross entropy", *Digital Object Identifier*, Vol. 2, pp: 721-724, 1992.
- [46] C.H. Li, P.K.S. Tam, "An iterative algorithm for minimum cross entropy thresholding", *Pttern Recognition Letters*, Vol. 19, pp: 771-776, 1998.
- [47] C. A. Murthy, Sankar K. Pal, "Histogram thresholding by minimizing graylevel fuzziness", *Information Sciences*, Vol. 60, p: 107-135, 1992.
- [48] Mark L.G. Althouse, C.I. Chang, "Image Segmentation by Local Entropy Methods", *Proceedings, International Conference on Image Processing*, Vol. 3, pp:61-64, 1995.
- [49] G.Z. Li, C.W. An, J. Pang, M. Tan, X.Y. Tu, "Color Image Adaptive Clustering Segmentation", *Proceeding technique for color image segmentation*. pp:104-107, 2004.
- [50] M.T. Hagan, H.B. Demuth, M. Beale, "Neural Network Design", *PWS Publishing Compagny*, 1995.
- [51] R.P. Lippmann, "An Introduction to Computing with Neural Nets", *IEEE ASSP Magazine*, pp. 4-22, avril 1987.
- [52] T. Kohonen, "Self-Organization and Associative Memory", 2nd Edition, Berlin: *Springer-Verlag* (1987).
- [53] S. Ji, H.W. Park, "Image Segmentation of Color Image Based on Region Coherency", *IEEE, International Conference on Image Processing*, pp: 80-83, 1998.

- [54] R. Adams, L. Bischof, "Seeded region growing", *IEEE Transaction on Pattern Analysis and Machine Intelligence*, 16: 641-647, 1994.
- [55] G.M. Espindola, G. Camara, I. A. Reis, L. S. Biens, A. M. Monteiro, "Parameter selection for region-growing image segmentation algorithms using spatial autocorrelation", *International Journal of Remote Sensing*, Vol. 27, No. 14, pp: 3035-3040, 2006.
- [56] A. Tremeau, N. Borel, "A region growing and merging algorithm to color segmentation", *Pattern Recognition*, Vol 30, pp: 1191-1203, 1997.
- [57] Y.N Deng, B.S. Manjunath, "Unsupervised Segmentation of Color-Texture Regions in Images and Video", *IEEE Transaction on pattern analysis and machine intelligence*, Vol. 23, No.8, 2001.
- [58] B. Cramarius, M. Gabbouj, and J. Astola, "Clustering Based Region Growing Algorithm for Color Image Segmentation", *13th International Conference on Digital Signal Processing Proceedings*, DSP 97, Vol 2, pp. 875-860, 1997.
- [59] J. Canny, "A Computational Approach to Edge Detection", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 8, No. 6, Nov. 1986.
- [60] J. Xu, P.F. Shi, "Natural color image segmentation", *ICIP*, p. 973-976, 2003.
- [61] J.P Fan, David. K. Y. Yau, "Automatic Image Segmentation by Integrating Color-Edge Extraction and Seeded Region Growing", *IEEE, Item: 1057-7149/01*, 2001.
- [62] S.Chabrier, B.Emile, H. Laurent, C. Rosenberger and P. Marché, "Unsupervised Evaluation of Image Segmentation, Application to Multi-spectral Images", *Proceedings of the 17th International Conference on Pattern Recognition*, Vol. 1, pp: 576-579, 2004.
- [63] M. Borsotti, P. Campadelli, R. Schettini, "Quantitative evaluation of color image segmentation results", *Pattern Recognition Letters*, Vol 19, pp: 741-747, 1998.
- [64] Z. Kato, T. Pong, "A Markov random field image segmentation model for color textured images", *Image and Vision Computing*, Vol. 24, pp:1103-1114, 2006.
- [65] Y.Wu, X. Yang, K. Luk Chan, "Unsupervised Color Image Segmentation Based on Gaussian Mixture Model", *Proceedings of the 2003 Joint Conference of the Fourth International Conference on Information, Communication and Signal Processing and Fourth Pacific-Rim Conference on Multimedia (ICICS-PCM 2003)*, pp: 541-544, 2003.
- [66] R. C. Gonzalez, R. E.Woods, S. L. Eddins, "Digital image processing using MATLAB", *Pearson Prentice Hall*, ISBN 0-13-008519-7, 2004.
- [67] J.S Cardoso, L. Corte-Real, "Toward a Generic Evaluation on Image Segmentation", *IEEE Transactions on image processing*, Vol. 14, No. 11, pp:1773-1782, 2005.
- [68] Y. J. Zhang, "A survey on evaluation methods for image segmentation", *Pattern Recognition*, Vol. 29, No. 8, pp:1335-1346, 1996.
- [69] S. Chabrier, B. Emile, C. Rosenberger, H. Laurent, "Unsupervised Performance Evaluation of Image Segmentation", *EURASIP Journal on Applied Signal Processing*, Vol. 2006, pp:1-12, 2006.
- [70] J. Liu, Y.H. Yang, "Multiresolution color image segmentation", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1994, 16(7). 689-700.
- [71] M. Daoudi A. Lachkar, R. Benslimane. "Extraction de motifs de zellige arabomoresque par une nouvelle méthode de segmentation non-supervisée d'images couleurs", *conférence CORESA 04*, 2004.

- [72] J.W. Funck, Y. Zhong, D.A. Butler, C.C. Brunner, J.B. Forrer, "Image segmentation algorithms applied to wood defect detection", *Computers and Electronics in Agriculture*, Vol. 41, 2003, pp:157-179.
- [73] A. Ziadi, F. Ntawiniga, X. Maldague, "Neural Networks for color image segmentation: application to sapwood assessment", *IEEE, Canadian Conference on Electrical and Computer Engineering*, 2007, pp:417-420.
- [74] C. A. Murthy, S.K. Pal, "Histogram thresholding by minimizing gray-level fuzziness", *Information Sciences*, Vol. 60, 1992, p: 107-135.
- [75] L. Macaire, N. Vandenbroucke, J.G Postaire, "Color image segmentation by analysis of subset connectedness and color homogeneity properties", *Computer Vision and Image Understanding*, Vol. 102, pp: 105–116, 2006.
- [76] O. Losson, C. Botte-Lecocq, L. Macaire, "FuzzyMode Enhancement and Detection for Color Image Segmentation", *Hindawi Publishing Corporation EURASIP Journal on Image and Video Processing*. Vol. 2008 pp:1-19, 2008.
- [77] E. Akbas and N. Ahuja, "From ramp discontinuities to segmentation tree", *9th Asian Conference on Computer Vision (ACCV)*, Xi'an, China, September 2009.
- [78] C.H. Li, C.K. Lee, "Segmentation of die patterns using minimum cross entropy", *Digital Object Identifier*, Vol. 2, 1992, pp: 721-724.
- [79] C.H. Li, P.K.S. Tam, "An iterative algorithm for minimum cross entropy thresholding", *Pattern Recognition Letters*, Vol. 19, 1998, pp: 771-776.
- [80] F. Y. Shih, S. Cheng, "Automatic seeded region growing for color image segmentation", *Image and Vision computing*, Vol. 23, pp:877-886, 2005.
- [81] J. Chen, T. N. Pappas, A. Mojsilovic and B. E. Rogowitz, "Adaptive Perceptual Color-Texture Image Segmentation", *IEEE transactions on image processing*, Vol. 14, No. 10, 2005, pp:1524-1536.
- [82] A. Dupuis, P. Vasseur, "Image segmentation by cue selection and integration", *Image and Vision Computing*, Vol.24, 2006, pp:1053-1064.
- [83] H. An-xiang, C. Gang, Li. Jun-li, C. Zhe-ru, Z. Dan, "A flower image retrieval method based on ROI feature", *Journal of Zhejiang University Science*. Vol 7. 2004, pp: 764-772.
- [84] J. Liu, Y.H. Yang, "Multiresolution color image segmentation", *IEEE Trans. on Pattern Analysis and Machine Intelligence*, 1994, 16(7). 689–700.
- [85] S.Chabrier, B.Emile, H. Laurent, C. Rosenberger and P. Marché, "Unsupervised Evaluation of Image Segmentation, Application to Multi-spectral Images", *Proceedings of the 17th International Conference on Pattern Recognition*, 2004, Vol. 1, pp: 576-579.
- [86] R. Krishnapuram, J. M. Keller, "A Possibilistic Approach to Clustering", *Transaction on Fuzzy Systems* Vol. 1, No. 2, 1993, pp: 98-110.
- [87] Y. Deng, B.S. Manjunath, "Unsupervised Segmentation of Color-Texture Regions in Images and Video", *IEEE Transactions on pattern analysis and machine intelligence*, Vol. 23, No. 8, 2001, pp:800-810.
- [88] <http://vision.ece.ucsb.edu/segmentation/jseg/software>, consulted in November 2009.
- [89] R. Nock and F. Nielsen, "Statistical Region Merging", *IEEE Transactions on pattern analysis and machine intelligence*, Vol. 26, No. 11, 2004, pp:1452-1458.
- [90] P F. Felzenszwalb, D. P.Huttenlocher, "Efficient Graph-Based Image Segmentation", *International Journal of Computer Vision*. Vol. 59, No. 2, pp: 167–181, 2004.

- [91] A. Tremeau, N. Borel, "A region growing and merging algorithm to color segmentation", *Pattern Recognition*, Vol 30, pp: 1191-1203, 1997.
- [92] Bezdek, J.C, *Pattern Recognition with Fuzzy Objective Function Algorithms*. Plenum Press, New York, 1981.
- [93] S.Chabrier, B.Emile, H. Laurent, C. Rosenberger and P. Marché, "Unsupervised Evaluation of Image Segmentation, Application to Multi-spectral Images", *Proceedings of the 17th International Conference on Pattern Recognition*, Vol. 1, pp: 576-579, 2004.
- [94] S. Chabrier, B. Emile, C. Rosenberger, H. Laurent, "Unsupervised Performance Evaluation of Image Segmentation", *EURASIP Journal on Applied Signal Processing*, Vol. 2006, pp:1-12, 2006.
- [95] <http://www.beefgradingagency.ca>, (consulté en septembre 2010).
- [96] A. Ziadi, X. Maldague, L. Saucier. (2009) . "Near-Infrared Light Transmission in Beef Meat and Qualitative Marbling Evaluation Using Image Analysis", *ICGST International Journal on Graphics, Vision and Image Processing, GVIP*, Vol. 9, No: 6, pp: 7-12.
- [97] AOAC Official Method 991.36. (2006) . "Fat (Crude) in Meat and Meat Products, Solvent Extraction (Submersion) Method", *Journal of AOAC international*.
- [98] AOAC 960.39, "Fat (Crude) or Ether extract in Meat", *Journal of AOAC international*, 2006.
- [99] D. W. Newcom, T. J. Baas and J. F. Lampe, "Prediction of intramuscular fat percentage in live swine using real-time ultrasound", *J. Anim. Sci.*, Vol.80, pp: 3046-3052, 2002.
- [100] M.M. Ávila, M.L. Durán, T. Antequera, R. Palacios, and M. Luquero, "3D Reconstruction on MRI to Analyse Marbling and Fat Level in Iberian Loin", *Pattern Recognition and Image Analysis: Lecture Notes in Computer Science*, Vol. 4477, pp: 145-152, 2007.
- [101] S. Anderson, "Determination of Fat, Moisture, and Protein in Meat and Meat Products by Using the FOSS FoodScan™ Near-Infrared Spectrophotometer with FOSS Artificial Neural Network Calibration Model and Associated Database: Collaborative Study", *Journal of AOAC international*, Vol. 90, No. 4, pp: 1073-1083, 2007.
- [102] L.G. Garcia, T.E. Lawrence, T.H. Montgomery, D.B. Parker, M.S. Brown, "The Prediction of Fat Percentage in the Longissimus Dorsi Muscle in Fed Beef Using Nuclear Magnetic Resonance", *Journal of Muscle Foods*, Vol. 17, pp:375-380, 2006.
- [103] Chandraratne, M.R., Samarasinghe, S., Kulasiri, D., Isherwood, P., Bekhit, A.E.D. and Bickerstaffe, R., "Determination of Fat Content in Retail Ready Meat Samples using Image Analysis", *Lincoln University, Canterbury, NEW ZEALAND (Research Report 05/2003)*, ISSN 1174-6696, 2003.
- [104] C. M. Bishop, "Pattern Recognition and Machine Learning", *ISBN-10: 0-387-31073-8 Springer*, 2006.
- [105] S. Belongie, J. Malik and J. Puzicha, "Shape Matching and Object Recognition Using Shape Contexts", *IEEE Transaction on Pattern Analysis and machine intelligence*, Vol. 24, No: 24, pp:509-522, 2002.
- [106] L. Huang, M. Wang, "Efficient shape matching through model-based shape recognition", *Pattern Recognition*, Vol. 29, No. 2, pp:207-215, 1996.
- [107] H. Zaboli, M. Rahmati, A. Mirzaei, "Shape recognition by clustering and matching of skrlrtons", *Journal of computers*, Vol.3 No.5, pp:24-33, May 2008.

- [108] M. J. Swain, D. H. Ballard, “Color Indexing”, *International Journal of Computer Vision*, Vol. 7, No: 1, pp: 11-32, 1991.
- [109] G. Finlayson, S. Hordley, G. Schaefer, G. Y. Tian, “Illuminant and device invariant colour using histogram equalisation”, *Pattern Recognition*, Vol. 38, pp:179 – 190, 2005.
- [110] A. Ziadi, X. Maldague, L. Saucier, “Image analysis in computer vision: A high level means for Non-Destructive evaluation of marbling in beef meat”, *Proceedings of the 10th edition of the Quantitative Infrared Thermography (QIRT), International conference*, Vol.1. No.1, pp: 541-548, 2010.
- [111] X. J. Yang, E. Albrecht, K. Ender, R. Q. Zhao and J. Wegner, “Computer image analysis of intramuscular adipocytes and marbling in the longissimus muscle of cattle”, *J. Anim. Sci.* Vol.84, pp:3251-3258, 2006.
- [112] R.E. Walpole, R. H. Myers, S. L. Myers, “Probability and Statistics for Engineers and Scientists”, 8th, ed. *Prentice Hall*, ISBN 0-13-187711-9, 2006.

Annexe A : la viande de bœuf et ses caractéristiques

Canada Prime			Persillage en quantité égale ou supérieure à légèrement abondante
Canada AAA			Persillage en quantité égale ou supérieure à faible
Canada AA			Persillage en quantité allant de très faible à moins que faible
Canada A			Présence de traces de persillage allant jusqu'à une quantité moins que très faible

Figure A.1. Les quatre catégories de qualité de la viande. Canada A/AA/AAA/Prime sont les catégories de qualité les plus élevés au Canada, elles représentent 88% de toute la viande classée [6].

Tableau A.1 : Caractéristiques des grades de qualité de la viande bovine au Canada [6].

THE QUALITY GRADES						
Grade	Maturity (Age)	Muscling	Rib Eye Muscle	Marbling ^	Fat Colour and Texture	Fat Measure
CANADA PRIME	Youthful	Good to excellent with some deficiencies	Firm, bright red	Slightly abundant	Firm, white or amber	2 mm or more
CANADA A, AA, AAA	Youthful	Good to excellent with some deficiencies	Firm, bright red	A - trace AA - slight AAA - small	Firm, white or amber	2 mm or more
B1	Youthful	Good to excellent with some deficiencies	Firm, bright red	No requirement	Firm, white or amber	Less than 2 mm
B2	Youthful	Deficient to excellent	Bright red	No requirement	Yellow	No requirement
B3	Youthful	Deficient to good	Bright red	No requirement	White or amber	No requirement
B4	Youthful	Deficient to excellent	Dark red	No requirement	No requirement	No requirement
D1	Mature	Excellent	No requirement	No requirement	Firm, white or amber	Less than 15 mm
D2	Mature	Medium to excellent	No requirement	No requirement	White to yellow	Less than 15 mm
D3	Mature	Deficient	No requirement	No requirement	No requirement	Less than 15 mm
D4	Mature	Deficient to excellent	No requirement	No requirement	No requirement	15 mm or more
E	Youthful or mature	Pronounced masculinity				




Figure A.2. Spectre de réflectance d'une région de muscle et d'une région de gras d'un échantillon de viande de bœuf [13].




Figure A.3. Illustration d'un spectre d'absorbance du gras pur chez les mammifères [25]. Le maximum du signal est observé à 930 nm.




Figure A.4. Spectre d'absorbance d'une viande de bœuf [22].

Annexe B : procédure expérimentale et mise en registre des images




Figure B.1. Montage utilisé pour l'acquisition d'images.
(a) montage; (b) image synthétique d'un échantillon de viande; et (c) images proches infrarouges de la face de dessus et de dessous d'un réel échantillon de viande.




Figure B.2. Image visible d'un échantillon de viande.

La figure B.2 illustre une acquisition d'image (image visible) d'un échantillon de viande de bœuf prise par le montage d'acquisition de la figure B.1. Les quatre points de références (couleur noir) indiquent la région à traiter pour évaluer la proportion du persillage. Ainsi, c'est cette région qui est évaluée par la méthode chimique.

Les mêmes quatre points de référence servent aussi pour faire la mise en registre des images des deux faces : Il s'agit de mettre les pixels de deux faces dans un même système de coordonnées. C'est-à-dire que les pixels vis à vis, de la face de dessus et de la face de dessous, ont les mêmes coordonnées. Pour accomplir ce processus (mise en registre), nous avons pivoté les images (visible et proche infrarouge) de la face de dessus.




Figure B.3. Image proche infrarouge d'un échantillon de viande.
(échantillon de la figure B.2).

Tableau B.1. Proportions du volume de persillage obtenu par la méthode proposée et par la méthode chimique.

Échantillon	% gras Visible /NIR	% gras chimique	Écart
1	11,61	9,55	2,06
2	12,4	12,80	0,4
3	18,06	13,13	4,93
4	16,13	13,51	0,34
5	16,13	13,51	2,62
6	19,75	15,65	4,1
7	14,52	16,92	2,4
8	17,15	17,60	0,45
9	16,6	17,67	5,07
10	20,76	18,77	1,99
11	19,37	19,25	0,12
12	17,04	19,30	2,26
13	22,87	19,46	3,43
14	10,88	19,88	9
15	17,5	20,00	2,49
16	20,36	20,12	0,24
17	20,31	20,27	0,04
18	17,64	23,46	5,82
19	18,08	24,43	6,36
20	24,99	25,70	0,71
21	23,45	27,05	3,6
22	25,01	30,60	5,59
Moyenne	18,31	20,07	3,82
Écart type	9,47	14,88	2,49

Annexe C : diverses illustrations expérimentales




Figure 1. Example ultrasound image used for prediction of intramuscular fat percentage. ^aFat layers. ^bTrapezius muscle. ^cRegion of interest: 100 × 100 pixel area, 10 image parameters generated from this region. ^d10th rib.

Figure C.1. Illustration par imagerie d'ultrasons du dépôt du persillage chez les porcs [99].

Dans [99], une méthode par ultrasons pour la prédiction du pourcentage du gras intramusculaire dans la viande du porc est proposée. Dans cette méthode, l'évaluation du persillage se fait à partir des ROIs (100x100 pixels) des images ultrasons de la 10^{ème} et de la 11^{ème} côte de l'animal vivant. Un technicien spécialement formé analyse les images afin de déterminer la proportion du persillage.

Comme le montre la figure C.1, le persillage suit des directions parallèles au muscle, dans une coupe ou observation transversale, ceci a un sens oblique.




Figure 2. Macroscopic and microscopic image of stained marbling flecks. (A) Macroscopic image of large and small marbling flecks. Muscle fiber bundles are grayish; marbling flecks are dark; connective tissue is whitish; and blood vessels are indicated by the arrows. Scale bar = 6 mm. (B) Microscopic image of small marbling flecks; muscle fibers are grayish but well outlined; adipocytes are whitish; connective tissue is grayish; and blood vessels are indicated by the arrows. Scale bar = 100 μ m.

Figure C.2. Illustrations macroscopique et microscopique d'une coupe transversale d'un échantillon de viande [28].




Figure 1. Example of a black and white-rendered image of an LM cross-section with marbling flecks detected and grouped as follows: A, B = marbling flecks belonging to the dorsal marbling group; C, D = marbling flecks belonging to the ventral marbling group; A, D = marbling flecks belonging to the large marbling group; C = marbling fleck belonging to the middle marbling group; B = marbling fleck belonging to the small marbling group; and M = middle line.

Figure C.3. Illustration d'un exemple de différentes catégories de persillage [111].

