



HAL
open science

CLASSIFICATION MULTI VUES DE RÉGIONS COULEUR - APPLICATION A L'ÉVALUATION 3D DES PLAIES CHRONIQUES

Hazem Wannous

► **To cite this version:**

Hazem Wannous. CLASSIFICATION MULTI VUES DE RÉGIONS COULEUR - APPLICATION A L'ÉVALUATION 3D DES PLAIES CHRONIQUES. Interface homme-machine [cs.HC]. Université d'Orléans, 2008. Français. NNT : . tel-00408712

HAL Id: tel-00408712

<https://theses.hal.science/tel-00408712>

Submitted on 31 Jul 2009

HAL is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

ÉCOLE DOCTORALE SCIENCES ET TECHNOLOGIES
INSTITUT PRISME

THÈSE présentée par :

Hazem WANNOUS

soutenue le : **8 décembre 2008**

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

Discipline/ Spécialité : **Sciences et Technologies Industrielles**

**CLASSIFICATION MULTI VUES
DE RÉGIONS COULEUR
APPLICATION A L'ÉVALUATION 3D
DES PLAIES CHRONIQUES**

JURY :

RAPPORTEURS :

Mr Pierre JANNIN
Mr Ludovic MACAIRE

Chargé de Recherches – HDR, INSERM / INRIA / IRISA
Professeur des Universités, Université de Lille 1

EXAMINATEURS:

Mr Pierre GOUTON
Mr Pierre JANNIN
Mr Patrick LAMBERT
Mr Christophe LÉGER
Mr Yves LUCAS
Mr Ludovic MACAIRE
Mme Sylvie TREUILLET

Professeur des Universités, Université de Bourgogne
Chargé de Recherches – HDR, INSERM / INRIA / IRISA
Professeur des Universités, Université de Savoie
Professeur des Universités, Université d'Orléans
Maître de conférences, Université d'Orléans
Professeur des Universités, Université de Lille 1
Maître de conférences – HDR, Université d'Orléans

Remerciements

Ce mémoire présente l'ensemble des travaux de recherche que j'ai effectué au cours des trois années de ma thèse dans l'équipe Images et Signaux pour les Systèmes au sein de l'institut PRISME à l'Université d'Orléans. Ils ont été financés par les Fonds Sociaux Européens et le Conseil Régional du Centre.

Je voudrais remercier tout d'abord Monsieur le professeur Youssoufi Touré, directeur de l'institut PRISME, de m'avoir accueilli au sein de son institut pour préparer cette thèse et d'avoir accepté d'assurer la direction administrative de ma thèse.

Je tiens à exprimer ma profonde reconnaissance à Monsieur Yves Lucas et Madame Sylvie Treuillet qui ont encadré mon travail ; leurs conseils éclairés et leurs commentaires précieux m'ont permis de surmonter mes difficultés et de progresser dans mes études. Leur perfectionnisme, leur grande disponibilité et leur grande sympathie ont été pour moi un soutien immense et un exemple à suivre.

J'adresse mes plus vifs remerciements à Monsieur Ludovic Macaire, Professeur à l'Université de Lille 1, et à Monsieur Pierre Jannin, Chargé de Recherches à l'INRIA/IRISA, d'avoir accepté d'être les rapporteurs de ce mémoire, pour la pertinence de leurs remarques, et leur participation au jury de thèse.

J'exprime toute ma gratitude et mon respect aux autres membres du jury qui malgré un emploi du temps serré, m'ont tous fait l'honneur d'accepter de prendre part à ce jury et surtout de lire et d'expertiser mon travail : Monsieur Patrick Lambert Professeur à l'Université de Savoie, président du jury, Monsieur Pierre Gouton Professeur à l'Université de Bourgogne et Monsieur Christophe Léger Professeur à l'Université d'Orléans, examinateurs de la thèse.

Je tiens à adresser mes plus sincères remerciements à tous les personnels médicaux qui ont collaborer à ce projet : Dr J.C. Pichaud au Center de Virazeil, Dr J. Rajaonarivo, Dr Z. El Asfari, Dr S. Lombard and D. Lafage à l'hôpital de Bourges et Dr K. Berriri à l'hôpital d'Issoudun. Sans leur précieuse collaboration, ce projet n'aurait pu aboutir.

Je souhaite également remercier Monsieur le professeur Yvon Voisin, Monsieur Alamin Mansouri et Monsieur Sliwa Tadeusz du Laboratoire Lezi à l'UTUT d'Auxerre pour l'intérêt qu'ils ont porté à mon travail.

J'adresse mes remerciements à Monsieur Pierre Marché et Monsieur Joël Allain, l'ancien et l'actuel directeur de l'ENSI de Bourges, de m'avoir accueilli au sein de leur école tout au long de ma thèse, ainsi qu'au personnel de l'école.

Enfin, une pensée émue pour tous les amis avec qui j'ai partagé un bureau, une salle, un café, un repas ou une console d'ordinateur pendant ces trois années : Adel, Anant, Arnaud, Baptiste, Benjamin, Damien, Issam, Mehdi, Moussa, Mustapha, Pierre, Salim, Yannick.

Je témoigne ma reconnaissance à ma famille, mes amis et mes proches, sans votre soutien et votre confiance rien n'aurait pu être fait.

Table des Matières

Table des Matières	i
Liste des Figures	v
Liste des Tableaux	xi
Introduction générale	1
1 Les plaies chroniques - Des pratiques manuelles au suivi par imagerie	7
1.1 Problématique médicale de l'escarre	8
1.1.1 Formation de l'escarre	8
1.1.2 Facteurs de risque	9
1.1.2.1 Risques primaires	9
1.1.2.2 Risques secondaires	9
1.1.3 Localisation des escarres	10
1.1.4 Prévention	10
1.1.5 Epidémiologie et incidences économiques	11
1.1.6 Classification selon les degrés de sévérité	12
1.1.7 Evaluation de la cicatrisation	13
1.1.7.1 Classification "colorielle"	13
1.1.7.2 Mesure de surface	13
1.1.7.3 Mesure du volume	14
1.2 État de l'art des techniques de suivi par imagerie	15
1.2.1 Analyse colorimétrique	15
1.2.1.1 Évaluation globale de la cicatrisation	15
1.2.1.2 Segmentation tissulaire multi-classes	18
1.2.1.3 Segmentation/détermination de la zone lésée	21
1.2.2 Analyse 3D	24
1.3 Conclusion et enjeux du projet ESCALE	25
2 Prétraitements	27
2.1 Introduction	28
2.2 Constitution d'une base d'images	28

2.2.1	Labellisations manuelles par des experts	29
2.2.2	Répétabilité inter/intra opérateur	31
2.3	Correction colorimétrique	33
2.3.1	Perception colorée et notion de couleur	34
2.3.2	Codage de la couleur dans les APN	35
2.3.3	Méthode de correction adoptée	37
2.3.3.1	Choix et composition de la mire	38
2.3.3.2	Détection et lecture automatique de la mire	40
2.3.3.3	Adaptation à l'illuminant	40
2.3.3.4	Équilibrage chromatique des APN	42
2.3.4	Validation expérimentale	43
2.3.4.1	Tests en laboratoire	43
2.3.4.2	Évaluation en conditions cliniques	48
2.3.4.3	Vers une mire couleur spécifique aux plaies chroniques	49
2.4	Segmentation en régions de couleurs homogènes	52
2.4.1	Algorithme Color Structure Code (CSC)	53
2.4.2	Méthode à base de graphes (EGBIS)	54
2.4.3	Algorithme Mean Shift	55
2.4.3.1	Filtrage Mean Shift	56
2.4.3.2	Segmentation Mean Shift	57
2.4.4	Algorithme JSEG	57
2.4.4.1	Quantification couleur	57
2.4.4.2	Segmentation spatiale de l'image quantifiée	58
2.4.5	Comparaison des méthodes sur les images d'escarres	60
2.4.5.1	Réglage des paramètres	60
2.4.5.2	Critère d'évaluation	63
2.4.5.3	Résultats	64
2.5	Création de la base d'échantillons	66
2.6	Conclusion	66
3	Classification tissulaire mono-vue	67
3.1	Introduction	68
3.2	Caractérisation des régions	68
3.2.1	Descripteurs de couleur	69
3.2.1.1	Moyenne des composantes	69
3.2.1.2	Histogramme couleur	72
3.2.1.3	Couleurs dominantes	75
3.2.2	Descripteurs de texture	76
3.2.2.1	Matrice de co-occurrence (GLCM)	76
3.2.2.2	Filtre de Gabor	78
3.2.2.3	Local Binary Pattern (LBP)	79
3.2.3	Récapitulatif des caractéristiques	82
3.3	Extraction/sélection de caractéristiques	84
3.3.1	Analyse discriminante linéaire (ADL)	85
3.3.2	Analyse en composantes principales (ACP)	86

3.3.3	Analyse en composantes indépendantes (ACI)	88
3.4	Classification des régions	89
3.4.1	Mesures de performance du classifieur	90
3.4.2	Séparateurs à vaste marge	91
3.4.2.1	Apprentissage à base de noyaux	92
3.4.2.2	SVM multiclassés	93
3.4.2.3	Sélection du modèle SVM	93
3.4.3	Méthode des k plus proches voisins (k-ppv)	96
3.4.4	Méthode k-ppv floue (<i>Fuzzy k-ppv</i>)	97
3.4.5	Méthode des K-Means	98
3.5	Études expérimentales	99
3.5.1	Génération du vecteur de caractéristiques	99
3.5.2	Comparaison du SVM à d'autres classifieurs	100
3.5.3	Rééchantillonnage des données	101
3.5.4	Autres critères d'évaluation du système	103
3.5.4.1	Evaluation par les coefficients de Kappa	103
3.5.4.2	Evaluation par les scores de recouvrement	104
3.5.5	Quantification de certaines influences sur la classification	107
3.5.5.1	Influence de la correction colorimétrique des images	107
3.5.5.2	Influence de l'algorithme de segmentation	108
3.5.5.3	Influence du nombre de régions segmentées	109
3.6	Conclusion	111
4	Classification tissulaire multi-vues	113
4.1	Introduction	114
4.2	Génération du modèle 3D à partir de 2 vues	115
4.3	Labellisation multi-vues	117
4.3.1	Homogénéité des facettes	119
4.3.2	Angle solide issu de la caméra	120
4.3.2.1	Lissage du modèle 3D	121
4.3.3	Probabilité d'appartenance à une classe	122
4.3.4	Stratégie de fusion	123
4.4	Evaluation multi-vues	125
4.4.1	Stabilité des labellisations 3D	126
4.4.2	Stabilité de la classification	128
4.4.3	Comparaison des surfaces 2D / 3D	128
4.5	Apports de l'approche multi-vue	130
4.5.1	Convergence du processus de classification tissulaire	130
4.5.2	Précision métrologique des relevés tissulaires	132
4.5.2.1	Mesures de surface	132
4.5.2.2	Mesure de volume	133
4.5.3	Robustesse au changement de point de vue	133
4.5.3.1	Stabilité de la correction colorimétrique	133
4.5.3.2	Stabilité des descripteurs de régions	134
4.6	Conclusion	135

Conclusion générale	137
5 Annexes	141
Annexe A	143
5.1 Le système visuel humain	143
5.2 Espaces couleur	144
5.2.1 Espace <i>CIERGB</i>	144
5.2.2 Espace <i>CIEXYZ</i>	145
5.2.3 Espace couleur <i>sRGB</i>	148
5.2.4 Espaces couleur uniformes $L^*a^*b^*$ et $L^*u^*v^*$	148
5.3 Constance chromatique	150
5.3.1 Hypothèse de Von Kries	151
5.3.2 Méthode Retinex patch blanc	152
5.3.3 Algorithme du monde gris	153
Annexe B	155
5.4 Cas des données linéairement séparables	155
5.5 Cas des données linéairement non-séparables	157
5.6 Cas des données non séparables	159
Bibliographie	161
Bibliographie de l'auteur	173

Liste des Figures

1	Organigramme de la chaîne de traitements d'images.	5
1.1	Processus d'apparition d'une escarre par hypoxie	8
1.2	Principales zones à risque d'apparition des escarres (a) position assise, (b) position couchée (c) position couchée sur le côté.	11
1.3	Les différents stades désignés par NPUAP	12
1.4	Typologie des tissus des plaies chroniques (a) bourgeon (b) fibrine (c) nécrose (d) épithélialisation	13
1.5	Analyse d'ulcères par [Oduncu et al., 2004].	17
1.6	Acquisition d'image et extraction manuelle de la plaie [Belem, 2004].	17
1.7	Segmentation de la plaie (a) bourgeon (b) non-bourgeon [Belem, 2004].	17
1.8	Schéma CBR de la classification des échantillons [Zhang et al., 2000].	19
1.9	Segmentation de la zone de brûlure (a) sélection manuelle (b) seuillage [Acha et al., 2003].	21
1.10	Évaluation de la segmentation (a) image brute (b) contour détecté (noir) et tracé manuellement (blanc). Le taux d'erreur est de 3.43% de pixels mal classés. [Kolesnik & Fexa, 2004].	22
1.11	Segmentation de zones dépigmentées [Schmid, 1999].	23
1.12	Lissage de l'image d'une lésion (a) avec PGF (b) avec un filtre médian [Celebi et al., 2005].	23
1.13	(a) Système MAVIS I (b) Système MAVIS II [Jones et al., 2006].	24
1.14	(a) Système de Krouskop (b) système MEDPHOS.	25
1.15	Projet DERMA	25
2.1	Chaîne de prétraitement appliqués aux images de plaies.	28
2.2	Protocole de prise de vues : une prise de vue faciale suivi de quatre autres : avant, arrière, gauche et droite, après un recul de l'APN pour éviter les singularités de l'auto-calibrage lors de la reconstruction 3D.	30
2.3	Première version de l'interface graphique de labellisation : les régions sont tracées manuellement à la souris par les experts.	30
2.4	Seconde version de l'interface graphique de labellisation : coloriage de régions automatiquement pré-segmentées.	31

2.5	Construction des échantillons de référence par la fusion des différentes labellisations manuelles fournies par les experts : (a) image originale (b) vérité terrain obtenue avec un taux de confiance de 75% (c-d) échantillons de référence extraits pour l'apprentissage du classifieur (e-h) tracés manuels de 4 experts (i-l) tracés manuels des mêmes experts à un mois d'intervalle.	33
2.6	Organigramme de la correction colorimétrique adoptée.	37
2.7	Chaîne de production de la mire de référence.	38
2.8	Mire de référence adoptée.	39
2.9	Détection et lecture automatique des couleurs de la mire. (a) détection précise des coins (b) Estimation robuste de la transformation homographique (c) zones centrales des carreaux servant au calcul des valeurs RGB.	40
2.10	à gauche : Banc d'évaluation des sources de dispersion (IUT de Bourges), à droite : Spectrophotomètre utilisé pour déterminer les valeurs XYZ des carreaux de la mire (IUT d'Auxerre).	44
2.11	Série de photos prises par un APN Sony DSC-H5 sous différentes sources d'éclairage et différents angles de vue. (a) lumière naturelle à 0° (b) flash à 20° (c) soleil direct à 40° (d) halogène à 20° (e) tungstène à 30° (f) néon à 40°.	45
2.12	Sensibilité à l'illuminant des APN : moyenne et valeur maximale des erreurs ΔE_{ab} obtenues pour différents illuminants sur 120 mesures par APN (5 angles, 24 carreaux, mode manuel). Colonne de gauche : avant correction. Colonne de droite : après correction.	46
2.13	Sensibilité au point de vue : moyenne et valeur maximale des erreurs ΔE_{ab} obtenues pour différents angles sur 72 mesures (3 APN, 24 carreaux, mode manuel). Colonne de gauche : avant correction, Colonne de droite : après correction.	47
2.14	Variations globales selon les APN : moyenne et valeur maximale des erreurs ΔE_{ab} sur 720 mesures (6 éclairages, 5 angles, 24 carreaux, réglage manuel de la balance des blancs) (a) avant correction (b) après correction.	48
2.15	Erreurs ΔE_{ab} mesurées sur les 24 carreaux de la mire avant et après correction (a) écarts aux valeurs de référence moyennés sur les 52 images (b) écarts entre les deux vues stéréo de la même plaie moyennés sur 26 paires d'images.	49
2.16	Segmentations obtenues par l'algorithme JSEG avant (a et c) et après correction colorimétrique (b et d), avec le même réglage des paramètres.	49
2.17	Représentation des couleurs dans l'espace RGB (a) les 24 carreaux de la mire <i>Macbeth</i> , (b) les tonalités les plus fréquentes dans les plaies chroniques.	50
2.18	Quantification couleur obtenue par l'algorithme GLA dans l'espace Lu^*v^* (a) image originale de la plaie (b) quantification (c) teintes des échantillons retenus.	50

2.19	Conception d'une mire spécifique aux plaies chroniques (a) palette des 132 teintes retenues par la quantification sur les 52 images de plaies (b) palette finale des 24 teintes intégrées à la mire.	51
2.20	Représentation des teintes dans l'espace $L^*u^*v^*$ (a) les 132 teintes sélectionnées par GLA (b) les 24 carreaux de la mire spécifique (c) les 24 carreaux de la mire <i>Macbeth</i>	51
2.21	Structure hiérarchique hexagonale du CSC	54
2.22	Quantification par l'algorithme GLA (a) image originale (b) image quantifiée (c) palette de couleurs réduite.	58
2.23	Valeurs de J selon différentes répartitions des étiquettes dans l'image quantifiée (a) image composée de 3 régions homogènes (b) une seule région texturée, (c) 2 régions.	59
2.24	Segmentation JSEG. (a) image originale (b-d) résultats de segmentation à différentes étapes de la croissance de régions dans la J-image.	59
2.25	Segmentations obtenues par CSC dans l'espace couleur HSV avec différents réglages (a) image originale (b) $S_H = S_S = S_V = -4$ (c) $S_H = S_V = 0, S_S = -4$ (d) $S_H = S_S = 0$. Le nombre des régions est respectivement de 460, 375 et 130.	61
2.26	Segmentations obtenues par CSC dans l'espace couleur RGB avec différents réglages (a) image originale (b) $S_d = 15$ (c) $S_d = 25$ (d) $S_d = 35$. Le nombre de régions est respectivement de 861, 401 et 190.	62
2.27	Segmentations obtenues par EGBIS avec différents réglages (a) image originale (b) $\sigma = 0.2, k = 300$ et $min = 100$ (c) $\sigma = 0.5, k = 300$ et $min = 50$ (d) $\sigma = 0.5, k = 200$ et $min = 100$. Le nombre de régions est respectivement de 160, 104 et 69.	62
2.28	Segmentations obtenues par Mean Shift avec différents réglages (a) image originale (b) $r = 4, h = 6.5$ et $Reg = 50$ (c) $r = 8, h = 6.5$ et $Reg = 100$ (d) $r = 8, h = 10$ et $Reg = 100$. Le nombre de régions est respectivement de 418, 264 et 144.	63
2.29	Segmentations obtenues par JSEG avec différents réglages (a) image originale (b) $m = 0.2, q = 50$, (c) $m = 0.2$ et $q = 300$ (b) $m = 0.8$ et $q = 300$. Le nombre de régions est respectivement de 122, 80 et 31.	64
2.30	Comparaison des algorithmes de segmentation. (1 ^{ère} ligne) image originale et vérité terrain, (2 ^{ème} ligne) segmentations par des algorithmes (3 ^{ème} ligne) labellisations correspondantes.	65
3.1	Représentation tridimensionnelle de couleur des tissus dans l'espace $L^*a^*b^*$. (1 ^{ère} ligne) deux images de plaies et leurs étiquetages manuels des classes de tissus par experts (2 ^{ème} ligne) représentation des images dans l'espace $L^*a^*b^*$ (3 ^{ème} et 4 ^{ème} lignes) représentation des différentes classes de tissus.	70
3.2	Représentation tridimensionnelle de couleur des tissus dans l'espace RGB. (1 ^{ère} ligne) représentation des images dans l'espace RGB (2 ^{ème} et 3 ^{ème} lignes) représentation des différentes classes de tissus.	71

3.3	Quantification systématique dans l'espace RGB. $255^3 = 16$ millions de couleurs quantifiées en 3^3 cellules (d) et 10^3 cellules. (a) image brute (b) image quantifiée sur 27 cellules (c) image quantifiée sur 1000 cellules (d-e) représentation correspondants dans le cube RGB.	73
3.4	Histogramme couleur RGB de différents types de tissus dans deux exemples pour trois types de tissus. Respectivement, de haut en bas, bourgeon, fibrine et nécrose, avec les histogrammes couleur R, G et B correspondants.	74
3.5	Représentation des régions pré-segmentées par leur 1 ^{ère} couleur dominante, issue d'une quantification respectivement (c) par l'algorithme Mean Shift (d) par l'algorithme GLA.	76
3.6	Calcul du LBP d'un pixel donné. $LBP = 1 + 16 + 32 + 64 + 128 = 241$.	79
3.7	Construction et uniformité d'un motif LBP. Le motif construit ici est uniforme (par exemple le motif 00101010 n'est pas uniforme).	80
3.8	Méthode LBP. Les histogrammes LBP des 4 régions pré-segmentées (version 256 motifs).	81
3.9	Projection linéaire par ADL et ACP. (a) représentation des 2 premiers attributs parmi 23 attributs représentant 653 échantillons étiquetés en 4 classes (b) projection par ADL (c) projection par ACP (deux premières composantes principales).	87
3.10	Matrice de confusion.	90
3.11	Séparation simplifiée dans un l'espace de représentation avec des dimensions plus élevées. L'idée d'utiliser les noyaux par SVM est de transformer un problème de séparation non-linéaire dans un problème de séparation linéaire dans l'espace re-description de grandes dimensions.	92
3.12	Courbe ROC : 4 courbes correspondant à 4 tests de classification par des noyaux différents.	94
3.13	Réglage des hyper-paramètres (C et gamma) du SVM avec un noyau gaussien RBF : cas du meilleur taux de classification de 71% obtenu sur la base d'apprentissage pour $C = 32$ et $\alpha = 0.031$	96
3.14	1 ^{er} exemple de classification automatique, comparée à la vérité terrain. (a) image originale (b) classification automatique (c) vérité terrain. . . .	106
3.15	2 ^{ème} exemple de classification automatique, comparée à la vérité terrain. (a) image originale (b) classification automatique (c) vérité terrain. . . .	106
3.16	3 ^{ème} exemple de classification automatique, comparée à la vérité terrain. (a) image originale (b) classification automatique (c) vérité terrain. . . .	107
3.17	Effet de la correction sur le résultats de classification (a-b) image sans correction avec la classification correspondante (c-d) l'image corrigée avec la classification correspondante.	108
3.18	Labellisations manuelles des régions segmentations, élaborées en se basant sur la vérité terrain fournie par des experts. Ici, on affecte à chaque région l'étiquette majoritairement représentée dans la labellisation. . . .	110

3.19	Influence de la sur-segmentation sur les résultats de classification : évaluation par les mesures de Sensibilité (Se), Spécificité (Sp) et Précision globale (P)	111
4.1	Chaîne de traitement d'images pour l'évaluation 2D / 3D des escarres.	114
4.2	(a) Chaîne de reconstruction 3D.	116
4.3	Evaluation de la reconstruction 3D (a) cartographie des erreurs (en mm) après recalage des données 3D sur la surface de référence délivrée par un scanner industriel (b) données statistiques du contrôle dimensionnel sur une série de 10 reconstructions en mode normal puis en mode macro.	116
4.4	Projection du maillage 3D sur la classification de deux vues. (a) modèle 3D reconstruit à partir de deux images (b-c) modèle projeté sur la classification des deux images (d) deux zones homologues sélectionnées illustrant la correspondance entre triangles homologues issus d'une même facette du modèle.	118
4.5	Découpage des facettes en deux sous-facettes. (a-b) projection des facettes du modèle sur la classification des deux vues (c-d) découpage des triangles homologues labellisés par plusieurs classes dans les deux vues. Le découpage illustré ici est obtenu en deux itérations du processus.	119
4.6	Projections d'une facette triangulaire du modèle 3D dans deux plans image. Les deux APN sont représentés par leur centres optiques O1 et O2.	120
4.7	Lissage du modèle 3D par un filtre Laplacien avec un facteur de relaxation de 0.01 en 20 itérations. (a-b) deux vues d'une même plaie (c-d) maillage du modèle reconstruit de cette plaie, respectivement avant et après filtrage (e-f) triangulation de Delaunay correspondante avant et après filtrage.	122
4.8	Stratégie de fusion des labellisations sur le modèle 3D.	124
4.9	Distribution des labellisations multi-vues dans l'algorithme de fusion.	125
4.10	Reconstruction 3D à partir de 2 prises de vue (1 ^{ère} ligne) trois images de la plaie prises de points de vue différents formant trois paires stéréoscopiques (2 ^{ème} ligne) trois modèles 3D reconstruits respectivement à partir des paires 1-2, 2-3 et 3-1.	126
4.11	Stabilité de labellisation multi-vues sur 5 reconstructions différentes. (1 ^{ère} ligne) deux images de la plaie prises de points de vue différents (2 ^{ème} et 3 ^{ème} lignes) fusion des labellisations manuelles reportée sur 5 reconstructions successives du modèle 3D d'une plaie.	127
4.12	Stabilité de labellisation sur différentes paires d'image de la même plaie. (1 ^{ère} ligne) trois images de la plaie prises de points de vue différents formant trois paires stéréoscopique (2 ^{ème} ligne) labellisations manuelles en 2D faites par des experts (3 ^{ème} ligne) fusion des labellisations des paires d'images, respectivement 1-2, 2-3 et 3-1.	128

4.13	Stabilité de la classification sur différentes paires d'image de la même plaie. (1 ^{ère} ligne) trois images de la plaie prises de points de vue différents formant trois paires stéréoscopique (2 ^{ème} ligne) classification automatique en 2D (3 ^{ème} ligne) fusion des classification des paires respectivement 1-2, 2-3 et 3-1 selon les trois modèles 3D calculés.	129
4.14	Labellisation mono-vue du modèle. (a-b) paire d'images (c-d) modèle 3D reconstruit respectivement selon la 1 ^{ère} et la 2 ^{ème} vue (e-f) projection du modèle sur les deux vues.	130
4.15	Exemple de classification multi-vues d'une escarre.	132
4.16	Calcul du volume exact de la plaie avec la labellisation multi-vues.	134
5.1	Fonctions d'absorption relative des cônes et des bâtonnets (a) coupe de la rétine (b) sensibilités spectrales des cônes et des bâtonnets.	143
5.2	Cube de couleur RGB.	145
5.3	Courbes des réponses spectrale X, Y et Z	146
5.4	Diagramme de chromaticité xy.	147
5.5	Mire couleur IT8.7/2	154
5.6	Principe des SVM dans le cas de deux ensembles de données. (a) cas linéairement séparable par un hyperplan H de marge maximale. Les vecteur de support, indiqués dans la figure, désignent les échantillons les plus proches de H . (b) cas linéairement non séparable.	158

Liste des tableaux

2.1	Scores de recouvrement intra expert à un mois d'intervalle.	32
2.2	Scores de recouvrement entre chaque expert et la vérité terrain.	32
2.3	Regressions polynomiales de différents ordres.	43
2.4	Protocole expérimental	44
2.5	Espaces colorimétriques et réglages adoptés pour les 4 méthodes de segmentation non supervisées sur la base d'images d'escarres.	64
2.6	Scores de recouvrement obtenus pour chaque algorithme.	65
3.1	Mesures d'intersection des histogrammes de différentes régions (B : bourgeon, F : fibrine, N : nécrose).	80
3.2	Mesures d'intersection des histogrammes moyennées sur plus de 300 échantillons.	81
3.3	Récapitulatif de l'ensemble des descripteurs de couleur et de texture extraits de notre base d'échantillons de tissus.	84
3.4	Evaluation du classifieur SVM avec différents noyaux.	94
3.5	Evaluation de la pertinence des descripteurs de couleur et de texture.	99
3.6	Comparaison des résultats des différentes méthodes de classification.	101
3.7	Comparaison de différentes méthodes d'analyse de données, combinées avec une étape de classification supervisée.	103
3.8	Matrice de confusion : classification automatique / expert.	104
3.9	Valeurs de Kappa et degrés d'accord correspondants.	104
3.10	Scores de recouvrement obtenus pour chaque type de tissu (52 images), comparés aux différentes mesures d'évaluation	105
3.11	Comparaison des taux de recouvrement obtenus par un expert donné et l'algorithme face à la vérité terrain élaborée par fusion des labellisations manuelles.	106
3.12	Comparaison des taux de recouvrement obtenus sans correction puis avec correction colorimétrique des images.	108
3.13	Comparaison des taux de recouvrement des 4 algorithmes de segmentation testés.	109
4.1	Nombre de triangles labellisés pour chaque étape de l'algorithme de fusion.	125

4.2	Stabilité de la reconstruction. Les surfaces des tissus sont obtenues sur 5 reconstructions sur chaque paire d'images.	127
4.3	Stabilité de la classification. Les surfaces des tissu sont obtenues sur 5 reconstructions issues des différentes paires d'images.	128
4.4	Erreurs de surface obtenues par retroprojection du plan image (d'une seul vue) sur le modèle 3D, pour une escarre relativement grande (54 cm^2).	129
4.5	Fusion des classifications : scores de recouvrement moyens sur 5 reconstructions du modèle pour chaque paire d'image	131
4.6	Evaluation de l'invariance de descripteurs grâce à l'approche multi-vues.	135

Introduction générale

La diffusion d'outils de vision artificielle pour le suivi thérapeutique des plaies chroniques est relativement récente. Alors que des systèmes d'imagerie sophistiqués ont été conçus pour l'exploration fonctionnelle interne (tomographie X, résonance magnétique nucléaire, ultrasons ...), l'observation externe s'est longtemps limitée à un simple examen visuel. La photographie était déjà utilisée pour archiver les images des lésions, mais c'est la photographie numérique et la puissance de traitement maintenant disponible sur un simple PC qui ont donné un véritable essor au traitement couleur et haute résolution de ces images médicales.

Un obstacle important à la diffusion de cette technique vient du fait que le suivi des plaies est de la responsabilité des infirmières, peu impliquées dans les activités de recherche, mais soucieuses de disposer d'outils pratiques, simples et conviviaux pour la surveillance des patients. L'examen d'une plaie ne devrait prendre que quelques instants, comme une prise de température ou de tension. Aussi les pratiques de mesure se sont limitées à apprécier visuellement les pourcentages de tissu sur la plaie (code couleur Rouge/Jaune/Noir) et plus rarement à mesurer la plaie, à la règle, par recopie sur calque ou exceptionnellement par moulage ou injection de sérum sous film. Différents types de plaies sont concernés : les plaies chroniques bien sûr, escarres et ulcères, mais aussi les brûlures et enfin les plaies traumatiques et de façon plus large les lésions superficielles étudiées en dermatologie comme les mélanomes et carcinomes et autres pathologies affectant la pigmentation.

Un outil d'évaluation des plaies par traitement d'images devrait combiner le relevé anatomique, c'est-à-dire la mesure géométrique de l'étendue spatiale de la plaie jusqu'à la description locale de son relief, et l'analyse tissulaire, c'est-à-dire la mesure colorimétrique des tissus jusqu'à la classification de ses régions. Les équipes ayant travaillé dans ce domaine ont très longtemps abordé le problème sous un seul angle, soit celui de la classification des tissus, soit celui de la mesure dimensionnelle. Ce n'est que récemment que sont apparus quelques systèmes dédiés à l'évaluation complète d'une plaie. Examinons maintenant les différents éléments composant une chaîne de traitement d'images de plaies, afin de mieux cerner les difficultés rencontrées et les progrès opérés pendant les deux dernières décennies, avant de présenter

ensuite de façon détaillée les travaux les plus significatifs du domaine.

La première difficulté est parfois négligée mais on s'en rend compte assez vite : l'acquisition des images reste une étape déterminante pour la suite des traitements. La photographie des plaies est techniquement difficile : la chambre du patient n'est pas un studio de photographe ... l'éclairage n'est pas maîtrisé, excepté par l'utilisation d'un flash, idéalement annulaire, ce que nous avons adopté, mais souvent réduit au flash incorporé dans l'appareil. Les ombres, les reflets sur les tissus humides ou gras, la couleur des draps, l'éclairage ambiant très variable, les artéfacts tels que des poils ou débris cutanés compliquent la prise de vues et la rendent peu reproductible. A cela s'ajoutent les problèmes de profondeur de champ limitée en mode macro et les risques de " bougé " associés à ce mode. Pour finir, le patient est rarement très coopératif et souvent incapable d'adopter une position inconfortable le temps d'une photo.

La correction colorimétrique des images s'impose pour assurer une bonne stabilité des couleurs et donc celle de la classification ultérieure des tissus. Des pastilles pour relever le blanc de référence, voire des mires calibrées standard ou mieux spécifiques, ont donc été utilisées pour s'affranchir au moins partiellement des changements d'éclairage et d'appareil photo numérique. Un objet de taille connue permettant de relever le facteur d'échelle est aussi utile dans le champ de vision si on souhaite faire des mesures dimensionnelles.

L'étape suivante est la constitution d'une base d'images représentative de toutes les plaies qui se différencient par leur stade de gravité, leur localisation corporelle, la chronologie dans le processus de cicatrisation, la présence d'infection ou d'exsudats... Ce processus d'archivage est long et dépend beaucoup de la bonne volonté des équipes cliniques car la plaie n'est observable que pendant l'examen clinique après nettoyage et avant changement de pansement.

La zone d'intérêt de la plaie doit ensuite être identifiée afin de la séparer des régions saines et plus généralement de l'arrière-plan. Ce détourage de la plaie a d'abord été traité manuellement, puis a été assisté par un détourage grossier à la souris suivi d'un détourage fin, par exemple par des techniques de contour actif. Nous proposerons une autre voie : l'identification des régions de peau saine, qui permet de ne conserver que les zones lésées. La caractérisation des différents tissus nécessite de disposer d'échantillons représentatifs de chaque type. On se heurte alors à la spécificité des images de plaies : les frontières entre les différents tissus ne sont jamais bien marquées, à tel point que des classes mixtes ont parfois été considérées. L'hybridation des tissus est même tridimensionnelle puisque dans le processus de cicatrisation, les bourgeons se forment sous la couche superficielle de fibrine et apparaissent ensuite progressivement avec des effets de transparence avant de déboucher à la surface. On comprend alors pourquoi les avis des experts sont partagés lorsqu'il s'agit de labelliser une plaie par différents types de tissus. Les frontières étant indéfinies, le consensus n'est jamais total, hormis sur les zones bien homogènes de la

plaie. L'extraction d'échantillons tissulaires caractéristiques de chaque type de tissu est donc très délicate.

La fragilité du consensus entre les experts a pour conséquence que la vérité terrain constituée sur la base d'images sera tributaire du nombre d'experts consultés, de leur niveau d'expertise, et de la rigueur du protocole adopté pour la labellisation des images, en particulier le réglage des écrans vidéo, les conditions d'éclairage et la non connaissance des patients photographiés. Peu de détails sont donnés dans les travaux sur cette étape pourtant importante qui fournit la référence au moment d'évaluer la classification automatique. Nous avons choisi de fusionner les avis d'experts et de ne considérer pour l'apprentissage que des régions recueillant un consensus suffisant de la part des experts.

Notons ici que dans de nombreux travaux, les performances de classification sont évaluées sur des échantillons extraits manuellement de l'image, dans des régions assez homogènes, ce qui ne préjuge en rien de l'efficacité réelle sur une image brute où aucune connaissance sur la répartition des différents tissus n'est fournie ... Dans l'approche que nous développerons, l'image sera segmentée automatiquement et les régions obtenues devront être classifiées dans un deuxième temps. Voilà pourquoi nous accorderons une grande attention au processus de segmentation non supervisé, puisque sa capacité à séparer les différents types de tissus conditionnera les performances finales du classifieur.

La caractérisation des différents tissus est l'étape suivante de la chaîne de traitement d'images. Elle commence par le choix de l'espace couleur dans lequel l'information colorimétrique va être exprimée. Les espaces perceptuels présentent ici l'intérêt de reproduire plus fidèlement les variations perçues par un observateur humain, par rapport aux espaces utilisés dans l'industrie. Malheureusement, les composantes chromatiques se révèlent insuffisantes à caractériser directement les différents tissus de façon robuste par de simples seuillages et la classification pixellaire sera vite abandonnée au profit d'outils statistiques.

L'histogramme dans sa version de base puis multi dimensionnelle, permet déjà de recueillir une information très riche sur la distribution colorimétrique. Nous l'avons complété par des mesures locales permettant d'incorporer des informations texturales. La nature statistique des descripteurs utilisés conduit à des vecteurs de caractéristiques imposants dont on mesure mal les pouvoirs discriminants respectifs et l'interdépendance. Une étape d'analyse de données est de plus en plus pratiquée pour réduire la dimension de l'espace des données et les conditionner. Nous avons donc inclus une étape d'analyse de données en amont de notre classifieur.

On peut ensuite aborder la phase de classification. Les classifieurs supervisés se sont rapidement imposés car, lors de l'évaluation, on se confronte à la vérité terrain établie par les experts. L'apprentissage du classifieur est donc le moyen d'incorporer une partie de cette expertise dans ce même classifieur. Actuellement les séparateurs

à vaste marge que nous avons également adoptés, ont supplanté les réseaux de neurones, de par leur capacité de généralisation et leur efficacité sur des classes non linéairement séparables, à condition de choisir judicieusement leur noyau. Nous avons adopté cette technique sur nos images de plaies.

La comparaison des performances des différents travaux n'est jamais aisée. Les équipes disposent chacune de leur propre base d'images, non partagée avec le reste de la communauté. De plus, les objectifs de classification ne sont pas identiques : identification du stade de gravité d'une escarre, séparation simple de la plaie et de la peau saine, classement des tissus parmi un nombre différent de classes avec parfois hybridation de celles-ci, degré d'une brûlure ...

Il est plus aisé de comparer les travaux lorsqu'on aborde le second volet de l'évaluation des plaies, c'est-à-dire le relevé anatomique. De nombreux prototypes ont été développés dans des laboratoires, basés sur des systèmes de vision active ou stéréoscopique. Ils sont intéressants pour des études ciblées sur quelques patients, lors de la mise au point de nouveaux traitements par exemple, mais leur coût, leur encombrement et leur complexité interdisent totalement leur diffusion massive dans les équipes de soin. Voilà pourquoi nous nous sommes attachés à n'utiliser qu'un simple appareil photo numérique du commerce, pour capturer à main levée la géométrie tridimensionnelle d'une plaie par un protocole multi vues facile à mettre en oeuvre.

Pour terminer cette introduction, une observation majeure doit être faite : aucun des systèmes rencontrés ne règle simultanément les deux problèmes dans l'évaluation d'une plaie : analyse colorimétrique tissulaire et mesure géométrique. Là se situe en grande partie l'originalité de ce travail et le bénéfice applicatif unique qui résulte aussi de l'intégration des deux dans notre chaîne de traitement d'images. Le modèle 3D de la plaie va contribuer à améliorer la classification des tissus et à la mesure exacte des surfaces tissulaires. Réciproquement, la classification des tissus va permettre l'extraction précise du modèle 3D grâce à l'élimination des régions saines périphériques.

L'organigramme de la Figure 1 illustre toutes les étapes de la chaîne de traitement appliquée.

Organisation du mémoire

- Le chapitre 1 présente le contexte médical lié à l'évaluation des plaies chroniques, la définition de l'escarre, ses localisations, son épidémiologie et les mesures de prévention. Une seconde partie du chapitre fait l'état de l'art des techniques d'analyse d'images appliquées à l'évaluation des plaies chroniques.
- Le chapitre 2 est consacré aux pré-traitements des images de plaies et comprend trois parties. La première étape est la constitution d'une base d'images

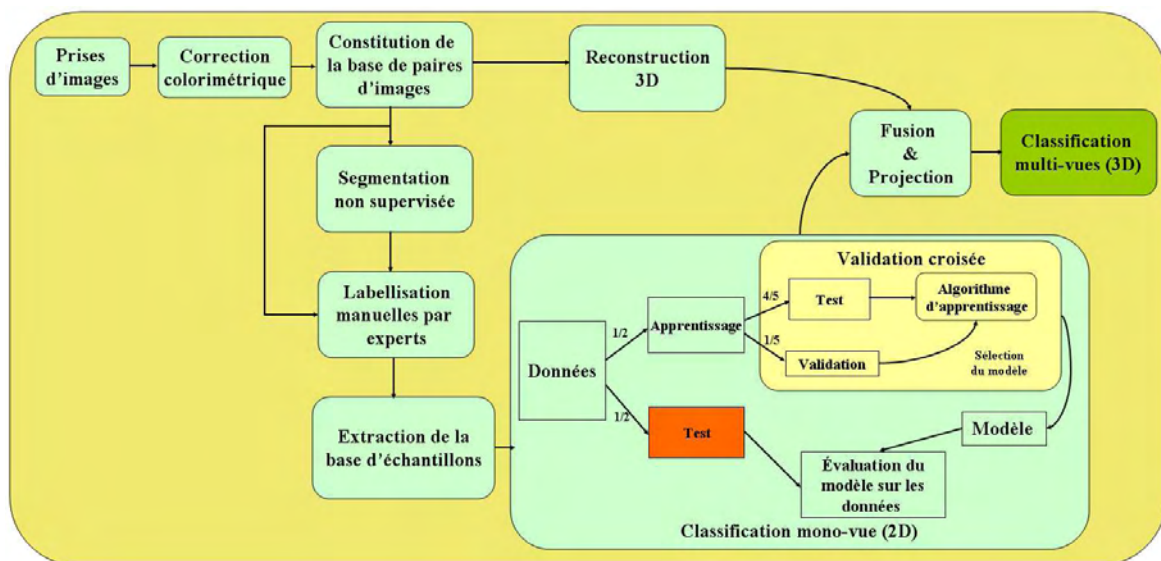


Figure 1 – Organigramme de la chaîne de traitements d'images.

photographiques acquises en milieu hospitalier et labellisées par plusieurs experts cliniciens. Cette base servira à la création d'échantillons de référence pour l'extraction des caractéristiques et l'évaluation des méthodes. Ensuite, une méthode de correction colorimétrique des images est proposée permettant de s'affranchir des différentes sources de perturbation sur le rendu des couleurs. Enfin la dernière partie concerne la segmentation automatique des images en régions de texture homogène.

- Le chapitre 3 se focalise sur la classification mono-vue des tissus, étape au coeur de notre système d'évaluation des plaies. Il introduit la représentation des échantillons de différents types de tissus par des descripteurs de couleur et de texture, puis aborde l'analyse discriminante des données. L'implémentation d'un classifieur de type séparateur à vaste marge (SVM) est détaillé et enfin des tests expérimentaux sont réalisés pour évaluer cette approche et la comparer avec des méthodes classiques.
- Le chapitre 4 présente l'approche multi-vues intégrant l'analyse géométrique et colorimétrique dans à seul outil pour l'évaluation tissulaire. Il explique notamment la stratégie de fusion adoptée pour arriver à une labellisation unique cohérente et robuste. Enfin des résultats expérimentaux valident les apports de notre approche multi-vues.

En conclusion, nous récapitulons les principales contributions de ce travail de thèse avant d'exposer les perspectives envisagées.

Les plaies chroniques - Des pratiques manuelles au suivi par imagerie

Ce chapitre présente le contexte médical des travaux de recherche sur l'évaluation des plaies chroniques. La première partie donne une description physiologique de l'escarre, évoque ses facteurs de risque, ses localisations, son épidémiologie, ses mesures de prévention, ses traitements à la fois locaux et généraux mais aussi ses complications. Nous présentons ensuite dans la deuxième partie un état de l'art des techniques de traitement d'image et de vision assistée par ordinateur appliquées au suivi thérapeutique des escarres, en soulignant leurs avantages et leurs inconvénients. Nous proposons enfin une approche adaptée à la pratique des soins dans le cadre du projet ESCALE.

Sommaire

1.1	Problématique médicale de l'escarre	8
1.1.1	Formation de l'escarre	8
1.1.2	Facteurs de risque	9
1.1.3	Localisation des escarres	10
1.1.4	Prévention	10
1.1.5	Epidémiologie et incidences économiques	11
1.1.6	Classification selon les degrés de sévérité	12
1.1.7	Evaluation de la cicatrisation	13
1.2	État de l'art des techniques de suivi par imagerie	15
1.2.1	Analyse colorimétrique	15
1.2.2	Analyse 3D	24
1.3	Conclusion et enjeux du projet ESCALE	25

1.1 Problématique médicale de l'escarre

1.1.1 Formation de l'escarre

L'escarre est une pathologie connue depuis longtemps ; elle doit son nom au mot grec "eskara" qui signifie "croûte noire". La définition établie par le National Pressure Ulcer Advisory Panel (NPUAP) décrit une escarre comme une lésion cutanée d'origine ischémique liée à une compression des tissus mous entre les saillies osseuses et le plan dur du support sur lequel repose le malade.

Assis ou allongé, le patient appuie sur le support avec une force proportionnelle à son poids. A son tour, la surface d'appui exerce une contre-pression sur la région cutanée avec laquelle elle est en contact. Logiquement, cette contre-pression dépend considérablement de la dureté du support. Par conséquent, une réduction de l'afflux sanguin se produit, de par à la pression excessive qui écrase les vaisseaux sanguins. Mais elle est aussi favorisée par :

- des vaisseaux sanguins en mauvais état, notamment à cause d'un diabète, d'une hypertension artérielle, ou de tabagisme, ...
- un manque d'oxygène (hypoxie).

Le rôle de la pression et de la perte de mobilité est prédominant. En effet, le développement pathologique d'une escarre repose sur la restriction ou même le blocage total du flux sanguin. Tout commence en profondeur, une fois les vaisseaux sanguins écrasés, la rougeur puis la plaie n'apparaissent qu'après un certain délai (Figure 1.1), [escarre.fr].




Figure 1.1 – Processus d'apparition d'une escarre par hypoxie

L'ANAES (Agence Nationale d'Accréditation et d'Évaluation en Santé) dans les recommandations issues de la conférence de consensus de novembre 2001 à Paris [ANAES, 2001], décrit trois types d'escarres :

- l'escarre accidentelle, liée à un trouble temporaire de la mobilité et/ou de la conscience
- l'escarre neurologique, conséquence d'une pathologie chronique, motrice et/ou sensitive, avec une indication chirurgicale assez fréquente en fonction de la surface, de la profondeur de l'escarre et de l'âge physiologique
- l'escarre plurifactorielle du sujet confiné au lit et/ou au fauteuil, où prédominent les facteurs intrinsèques, où les localisations peuvent être multiples et où l'indication chirurgicale est rare et le traitement essentiellement médical.

Les mesures de prévention des escarres ne peuvent être efficaces que lorsqu'elles prennent en considération tous les facteurs de risques propres à chaque patient.

1.1.2 Facteurs de risque

Les facteurs de risque qui concourent à la création de l'escarre peuvent être séparés en facteurs de risque primaires et facteurs de risque secondaires.

1.1.2.1 Risques primaires

Puisque la durée d'exposition à la pression est la principale cause dans la formation d'une escarre, le danger augmente avec le degré d'immobilité du patient :

immobilité complète : dès lors que les mouvements spontanés ne sont plus possibles, par exemple en cas de perte de connaissance, d'anesthésie ou de paralysie complète, le patient est en danger. L'âge n'a ici aucune importance.

immobilité relative : Le risque est potentiellement élevé, car les mouvements spontanés sont plus ou moins restreints. La sédation, les fractures, les fortes douleurs, une sclérose en plaques, une hémiplégie, une perte de sensibilité, etc. sont à prendre en compte. Puisque les soins jouent sur l'immobilité, ce facteur de risque est par nécessité sujet à des variations quotidiennes.

1.1.2.2 Risques secondaires

- Les états pathologiques affectent le fonctionnement et la résistance de la peau. La peau devient alors plus vulnérable à la pression qui, même si elle n'agit que brièvement, peut se traduire par l'apparition d'une lésion. Parmi ces facteurs de risque on distingue :

- La vascularisation insuffisante de la peau : Lorsque la vascularisation sanguine diminue, l'apport en oxygène devient inadéquat, et le métabolisme est perturbé. La peau devient moins tolérante à la pression. Une tension artérielle basse, une insuffisance cardiaque, un diabète, une artériosclérose, etc. peuvent être la source du problème.

- La fièvre : En réponse à la fièvre, le métabolisme des cellules cutanées s'accélère, le besoin en oxygène augmente. La vascularisation est donc déjà insuffisante, même si l'intensité de la pression reste en dessous du seuil de développement d'une escarre. Du reste, l'état fébrile aggrave l'immobilité du patient âgé. La fièvre est donc considérée comme le facteur de risque secondaire le plus sérieux.

- Mauvais état général : De nombreuses affections limitent considérablement la mobilité du patient et perturbent le métabolisme cutané, augmentant le risque d'escarre. Des études ont clairement démontré que le déficit protéique et l'apport énergétique insuffisant favorisent la genèse d'escarres. La carence en protéines provoque une accumulation d'eau dans les tissus qui limite fortement la vascularisation sanguine et le métabolisme de la peau. Une lésion tissulaire peut alors apparaître très rapidement sous l'action de la pression.
- Vieillesse physiologique de la peau : Indépendamment du danger posé par certaines maladies, la perte de cellules et de fibres de collagène provoquée par le vieillissement, rend la peau plus fine et le tissu conjonctif cutané moins élastique. Si le seuil de tolérance de la peau aux actions mécaniques est abaissé, une exposition à la pression, même de courte durée, peut évoluer vers une escarre.

Il est important de connaître les localisations possibles des escarres en fonction de la position des patients au lit ou au fauteuil, afin de ne pas négliger l'examen de ces zones lors des soins.

1.1.3 Localisation des escarres

Toute région exposée à une pression suffisante peut être le site d'une escarre. Néanmoins, le risque est maximum lorsque la force agit perpendiculairement sur une région cutanée qui couvre des structures osseuses convexes, donc saillantes avec peu de tissus élastiques (musculaires et adipeux sous-cutané) aptes à répartir la pression. Par conséquent, les régions du sacrum, de l'ischion, du grand trochanter, du talon et des malléoles externes sont des sites classiques (Figure 1.2)¹. La région sacrée est plus fréquemment atteinte par les escarres, étant donné une microcirculation réduite à ce niveau, associée à des pressions élevées. Les escarres trochantériennes et ischiatiques pourraient être plus fréquentes dans les services de long séjour. D'autres sites sont assez communément observés, tels le coude, la région malléolaire et le bord externe du pied. Les escarres occipitales s'observent essentiellement en cas de troubles sévères de la conscience.

En position assise, le risque d'escarres est plus grand qu'en position couchée où le poids du corps est réparti sur une superficie plus grande engendrant une pression moins importante.

1.1.4 Prévention

La prévention des escarres commence par la réduction de la pression par des changements de position et l'utilisation de supports adaptés (matelas, coussins de siège...). L'idéal est bien sûr de retrouver une bonne mobilité. Il est aussi important de conserver une bonne hygiène de la peau et une bonne nutrition. Il est essentiel

¹<http://www.ms-centrum.be/fr/zorgaspecten/doorligwonden.html>




Figure 1.2 – Principales zones à risque d'apparition des escarres (a) position assise, (b) position couchée (c) position couchée sur le côté.

d'examiner régulièrement les zones cutanées à risque. Il faut particulièrement observer les points d'appui du patient, zones où les pressions sont les plus fortes et les plus longues (talon, sacrum...). Ces parties du corps doivent également faire l'objet d'effleurage régulier, technique qui consiste à masser sans appuyer sur la peau. Cette pratique permet de favoriser la microvascularisation cutanée et ainsi d'éviter l'hypoxie des tissus en favorisant l'apport d'oxygène.

La prévention passe également par le choix du support. L'une des solutions préconisées est d'utiliser un matelas ou un surmatelas, permettant de mieux répartir les points d'appui et de réduire ainsi les pressions au niveau du sacrum, des talons ou des trochanters, en position allongée.

1.1.5 Epidémiologie et incidences économiques

Malgré les mesures de préventions mises en place au sein de comités anti-escarre dans les centres de soins, les escarres constituent une pathologie fréquente aux conséquences individuelles et collectives lourdes. Selon les études, la prévalence des escarres varie considérablement selon les contextes cliniques : entre 17% et 50% des patients entrant dans les services de soins prolongés, 5 à 7% des patients adressés en court séjour, 8% des opérés lorsque l'intervention dure plus de 3 heures, et 34 à 46% des blessés médullaires dans les deux ans suivant l'accident [ANAES, 2001]. L'étude de [Barbut et al., 2006] menée dans un centre hospitalier universitaire parisien, montre que 80% des escarres ont été acquises au cours du séjour à l'hôpital.

Les escarres entraînent une gêne douloureuse et une souffrance morale et physique, une limitation des capacités fonctionnelles (marche ou station assise impossible) avec comme conséquences une limitation de l'autonomie, des sorties et donc une diminution de la liberté. L'escarre a également pour conséquences une altération de l'image de soi et de la relation à autrui liée à l'aspect dégradant de la plaie, aux éventuels écoulements et odeurs de celle-ci. En outre, les escarres représentent un problème majeur de santé publique sur le plan économique. Les soins dispensés pour les escarres sont estimés en Europe à 8 milliards d'euros par an et les spécialistes prévoient qu'avec la vieillissement de la population leur nombre augmentera de 25% dans les dix prochaines années. La durée des soins peut atteindre plusieurs mois et les frais d'hospitalisation 60 keuro pour un seul patient. Au delà de cet aspect purement

économique, il est essentiel de tout mettre en oeuvre pour éviter l'apparition d'escarres. La prise en charge des escarres se fait donc à deux niveaux dans les hôpitaux, d'abord par la prévention puis par la thérapie.

1.1.6 Classification selon les degrés de sévérité

La description et l'évaluation initiales sont essentielles au choix d'une stratégie de traitement des escarres. Elles constituent une référence pour les évaluations ultérieures au cours du suivi. Plusieurs classifications différentes existent et classent le degré de gravité en quatre stades ou plus, depuis l'absence de lésion cutanée jusqu'au stade très avancé de l'atteinte osseuse voire articulaire. La classification la plus fréquemment utilisée est américaine [NPUAP, 2007]. Les plaies y sont classées par degré d'envahissement tissulaire en 4 stades :

- stade I : La peau intacte présente un érythème qui ne blanchit pas sous la pression du doigt. La lésion peut aussi se manifester par une décoloration de la peau ou de la chaleur.
- stade II : arrachement cutané touchant l'épiderme et éventuellement le derme. L'escarre se présente comme une ulcération.
- Stade III : Atteinte complète de la peau touchant le tissu sous-cutané. L'escarre se présente comme une ulcération profonde avec plaque de nécrose recouvrant en général des tissus sous-jacents dévitalisés.
- stade IV : Toute l'épaisseur de la peau est touchée avec destruction et nécrose importante atteignant les muscles, les os, les tendons ou les articulations. Ce stade est le plus souvent résultant d'une escarre de stade III après élimination des tissus nécrotiques. La Figure 1.3 montre les différents stades des escarres.




Figure 1.3 – Les différents stades désignés par NPUAP

Cette classification est reconnue comme élément de référence pour évaluer les escarres, les comparer et mesurer l'efficacité des actions préventives et curatives. Par contre, cette classification anatomoclinique qui fait surtout état de la profondeur de l'escarre et des couches tissulaires atteintes et ne permet pas une évaluation de l'ensemble des caractéristiques de l'escarre. Elle ne mentionne ni la surface, ni le volume de la plaie et ne peut donc être utilisée pour l'évaluation quantitative de la plaie.

Les deux derniers stades d'évolution d'escarre sont les plus douloureux. Lorsque leur apparition n'a pu être évitée, un suivi de cicatrisation doit être mis en place durant toute la période de soin.

1.1.7 Evaluation de la cicatrisation

L'évaluation de la cicatrisation est utile à la continuité des soins, à la cohérence et à la pertinence des décisions de traitement ainsi qu'à leur réajustement. Cette évaluation s'effectue par le relevé régulier de certains indicateurs de couleur, surfaciques et volumétriques [Koeffler, 2004].

1.1.7.1 Classification "colorielle"

Ce terme de classification "colorielle" est adopté par le personnel soignant pour désigner une évaluation basée sur une cartographie des couleurs des tissus. Elle consiste en une appréciation visuelle du pourcentage approximatif des tissus selon trois ou quatre couleurs : tissu noir (nécrose), jaune (fibrine) et rouge (bourgeon) (Figure 1.4). Cette classification créée en Angleterre [Cuzzell, 1988], a l'avantage d'être très facile d'emploi et de permettre un suivi aisé d'une plaie : le passage du noir au rouge traduit une amélioration, celui du rouge au noir une aggravation. Une variante de cette classification utilise comme couleur supplémentaire le rose pour l'épithélialisation, permettant une meilleure analyse de la plaie. Par les proportions des couleurs disposées dans un rectangle, cette technique permet de suivre l'aspect évolutif d'une plaie par sa composante dominante. C'est une méthode très subjective car le pourcentage accordé à chaque couleur est déterminé visuellement par le personnel soignant.

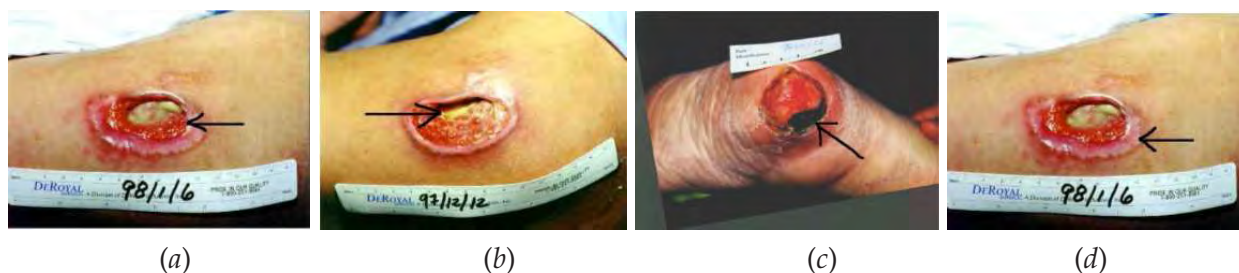


Figure 1.4 – Typologie des tissus des plaies chroniques (a) bourgeon (b) fibrine (c) nécrose (d) épithélialisation

1.1.7.2 Mesure de surface

Plusieurs méthodes sont proposées pour évaluer la surface de l'escarre :

- mesure directe de la longueur et de la largeur à l'aide d'une simple réglette millimétrée. Cette technique simple à utiliser et de coût très bas ne permet qu'un calcul imprécis de la surface de la plaie et n'est adaptée que pour les plaies plates et de forme régulière.
- recopie du pourtour de la plaie sur des calques transparents, éventuellement millimétrés, puis estimation de la surface par comptage manuel ou automatique après numérisation de l'image. Cette méthode peut entraîner un risque d'infection et le comptage du nombre de carreaux est fastidieux.

- utilisation d'images prises par un appareil photo. Cette technique ne nécessite que quelques minutes pour sa réalisation et c'est sans aucun doute la plus précise. De

plus, elle permet d'éviter le contact avec la peau. Cette technique fera l'objet de notre proposition pour l'évaluation des escarres et sera détaillée par la suite.

1.1.7.3 Mesure du volume

Parmi les méthodes existantes, on peut citer :

– le moulage de la plaie. L'empreinte du volume de la plaie se fait à l'aide d'un caoutchouc siliconé ou d'une pâte dentaire directement injectée dans la cavité de l'escarre. Cette méthode est précise, mais son temps de réalisation est long et elle est douloureuse pour le patient.

– technique de Berg consistant à recouvrir l'escarre d'un film bien ajusté et à injecter dans cette cavité désormais fermée, du sérum physiologique jusqu'à ce que la perte de substance soit totalement comblée. Le volume de sérum physiologique nécessaire est théoriquement représentatif du volume de la plaie. Cette méthode a pour avantage d'avoir une réalisation assez rapide. Par contre, il faut installer le patient dans une position confortable et adaptée au remplissage de la plaie. De plus il existe une absorption du sérum physiologique par la plaie et elle est donc peu précise.

– l'utilisation de techniques de relevé tridimensionnel sans contact avec des systèmes d'imagerie active ou de stéréovision). Il s'agit d'une méthode très précise de mesure des escarres sans aucun contact avec le patient. Cette technique a fait l'objet d'une première thèse préparée au sein de notre équipe [Albouy, 2006].

Jusqu'à présent, les pratiques cliniques d'évaluation des plaies sont visuelles ou manuelles, parfois douloureuses pour le patient, peu fiables et offrent une faible répétabilité. En ce qui concerne la proportion des tissus, elle est souvent estimée après un simple examen visuel avec un diagramme couleur rouge - jaune - noir. Afin de remédier au manque des données quantitatives qui affecte la coordination des soins entre les équipes et handicape les études cliniques sur la cicatrisation, des méthodes de quantification et de suivi de l'évolution des escarres ont été proposées par des équipes de recherche. Ces méthodes, basées sur le traitement d'images assisté par ordinateur, apportent une mesure qui est objective, fiable et reproductible. De plus, elles ont l'avantage de ne nécessiter aucun contact entre la plaie et le système de mesure.

1.2 État de l'art des techniques de suivi par imagerie

Ce paragraphe se propose d'analyser les principales méthodes d'imagerie appliquées au suivi de la cicatrisation des plaies, afin de mettre en avant leurs avantages et inconvénients et de tirer les leçons de celles qui peuvent être intéressantes pour concevoir notre système. Dès les années 90, beaucoup de travaux ont traité le problème de l'analyse et du suivi de l'évolution des plaies par imagerie. Mais rares sont les travaux ayant abouti au développement d'un outil de mesure pour la quantification complète de la cicatrisation, associant l'analyse colorimétrique, surfacique et volumétrique.

Les principales différences entre les travaux réalisés concernent les types de plaies étudiées (escarre, lésion, ulcère, ...), et surtout l'objectif visé. Pour certains, il s'agit d'extraire une indication globale de cicatrisation pour la détection de la zone lésée par une mesure de surface, d'autres vont rechercher une présence de l'infection, etc.

Une évaluation complète de la plaie devrait combiner le relevé anatomique (la mesure géométrique de l'étendue spatiale de la plaie jusqu'à la description locale de son relief) et l'analyse tissulaire, c'est-à-dire la mesure colorimétrique des tissus jusqu'à la classification des régions issus de la segmentation. Les équipes ayant travaillé dans ce domaine ont très longtemps abordé le problème sous un seul angle, soit celui de la classification des tissus, soit celui de la mesure dimensionnelle. Ce n'est que récemment que sont apparus quelques systèmes dédiés à l'évaluation complète d'une plaie. Nous présentons dans la suite les principaux travaux menés dans ce domaine, regroupés selon leurs objectifs.

1.2.1 Analyse colorimétrique

Les travaux réalisés dans ce sens sont les plus nombreux et leur point commun étant que les analyses de la plaie se limitent au plan 2D de l'image. Le principal objectif est la mesure de la surface occupée par la plaie ou par chacun des tissus de la plaie par une analyse couleur des régions constituant la plaie. Différents espaces de représentation de couleur peuvent être utilisés : RGB, HSV, $L^*a^*b^*$, $L^*u^*v^*$, Le lecteur trouvera une présentation de ces espaces en annexe A (5).

1.2.1.1 Évaluation globale de la cicatrisation

L'équipe du département de biostatistique et d'informatique médicale à l'université de Paris V a été l'un des parmi les premiers à proposer une méthode d'analyse des images couleur d'escarres prises par une caméra CCD, [Herbin et al., 1990] et [Herbin et al., 1993]. Leur analyse est basée sur l'évaluation d'un indice couleur (niveau de rougeur) sur des plaies créées de manière artificielle sur l'avant-bras de 8 personnes volontaires. L'extraction de cet indice est faite après un seuillage dans les espaces couleur sRGB et HSV, permettant de distinguer l'escarre de la peau saine et de calculer sa surface.

Un disque blanc de $2mm$ de diamètre est placé dans le champ de vue pour servir de référence colorimétrique (blanc de référence), et métrique (surface). Cette méthode s'avère insuffisamment robuste pour analyser des plaies naturelles, les tissus présentant une grande variabilité de couleur. En effet, il y a plusieurs teintes de rouge dans le bourgeon et la fibrine peut varier du noir au marron rougeâtre ou jaunâtre. De plus, les escarres n'ont pas une couleur uniforme comme sur les plaies artificielles créées par les auteurs. Enfin, la correction colorimétrique réalisée ne prend en compte que le blanc de référence. Une autre expérience d'analyse des plaies menée sur l'animal (porc) et montre que la distribution de couleur peut aider à différencier les tissus de la plaie et de la peau saine dans l'espace couleur HSV [Hansen et al., 1997].

Une approche différente propose, dans le cas d'une analyse d'ulcères de jambe, le choix du canal le plus pertinent dans les espaces de couleur RGB et HSV pour distinguer l'ulcère de la peau saine [Perez et al., 2001]. Une analyse tissulaire des ulcères est faite par les auteurs pour distinguer le bourgeon et la fibrine. Elle consiste à calculer différents paramètres caractérisant les tissus dans l'espace couleur RGB. Les paramètres, calculés sur des échantillons extraits manuellement, sont : la moyenne de l'histogramme, le pic le plus grand dans l'histogramme, la moyenne des pics les plus petits à gauche et à droite dans l'histogramme. La méthode de Perez ne prévoit que deux types de tissus (bourgeon et fibrine) dans la zone ulcéreuse, alors que la présence de la nécrose dans l'image change complètement le résultat d'analyse. Une telle analyse basée sur des informations extraites de l'histogramme couleur s'est révélée inefficace sur nos images (Chapitre cf. 3).

Une étude plus complète décrit une méthode semi-automatique basée sur une technique adaptative de spline pour détourner l'ulcère dans l'espace HSV [Oduncu et al., 2004]. La quantité de fibrine dans la zone de l'ulcère est ensuite déterminée par un seuillage dans le plan de la teinte H et comparée à une échelle de nuances basée sur l'inspection visuelle des experts humains. La méthode a été validée sur 50 images d'ulcères, afin de quantifier la présence de la fibrine dans l'image en cinq stades. Les résultats fournis par les auteurs affichent un excellent accord calculé par le coefficient Kappa² lors de la comparaison de la méthode avec une analyse des images par des experts. Le problème du recalage couleur a été abordé avec une règle colorée placée à côté de l'escarre (Figure 1.5).

Un point intéressant à souligner dans ce travail est que la quantification de la quantité de fibrine dans la zone de l'escarre peut être, selon certains experts, un facteur important d'évaluation de l'état de cicatrisation de la plaie. Notons que, la surface des tissus n'a pas été prise en compte dans l'évaluation alors quelle est un facteur très important pour l'évaluation clinique.

Dans une thèse réalisée à l'université de Glamorgan - UK [Belem, 2004], l'étude s'est focalisée sur la relation entre la couleur des plaies et la présence d'inflammation. L'auteur a traité le problème de l'acquisition d'images sous des conditions d'éclairage

²Un coefficient de Kappa égal à 1 indique un accord total entre deux opérateurs, alors qu'un coefficient de Kappa égal à zéro signifie un désaccord total entre opérateurs.



Figure 1.5 – Analyse d'ulcères par [Oduncu et al., 2004].

contrôlées et avec un calibrage couleur à l'aide d'une mire. Des zones d'intérêt de la plaie ont été sélectionnées manuellement et segmentées automatiquement (Figure 1.6). Ensuite, les informations statistiques caractérisant chaque zone ont été extraites pour préparer l'étape de classification. Ces informations sont principalement basées sur le calcul des moyennes, écart-types, skewness et kurtosis des différentes composantes dans les espaces couleur RGB, $L^*u^*v^*$ et $L^*c^*h^*$.



Figure 1.6 – Acquisition d'image et extraction manuelle de la plaie [Belem, 2004].

La segmentation automatique est achevée dans l'espace couleur $L^*c^*h^*$ par un seuillage dans le plan de la teinte. Cela permet l'extraction des parties de bourgeonnement, significatives de l'inflammation, car le but ici n'est pas de segmenter les différents types de tissu mais plutôt d'isoler les tissus de type bourgeon (Figure 1.7).



Figure 1.7 – Segmentation de la plaie (a) bourgeon (b) non-bourgeon [Belem, 2004].

Trois méthodes de classification (régression linéaire, réseau de neurones et séparateur à vaste marge) ont été testées sur des régions d'intérêt. Leur comparaison avec des classifications manuelles des médecins montre un coefficient de Kappa en faveur du SVM.

Dans les travaux précédents, les informations extraites pour l'analyse de la plaie sont des indices basés, soit sur des caractéristiques globales, soit sur la présence d'un seul tissu dans la zone lésée. Elles ont en fait une valeur clinique limitée et ne peuvent être en aucun cas suffisantes pour une quantification précise et complète des tissus.

1.2.1.2 Segmentation tissulaire multi-classes

Les travaux suivants se sont intéressés à l'identification de tous les tissus constitutifs d'une plaie, en allant jusqu'à la labellisation locale de toute la surface de la plaie. Dès l'année 1988, certains travaux préconisent de passer par un apprentissage sur des échantillons de référence pour améliorer la classification des différents tissus de l'escarre [Arnqvist et al., 1988]. Cet article propose une classification supervisée semi-automatique nécessitant un tracé manuel de zones d'intérêt et la sélection de l'apprentissage le mieux adapté à chaque cas. A l'aide de centaines d'images de différentes escarres prises sous différentes conditions d'éclairage, seize classifieurs bayésiens ont été créés afin de segmenter l'ulcère en trois classes de tissu (bourgeon, fibrine et nécrose). En plus de ces trois classes, l'auteur en définit une quatrième pour les zones de réflexions spéculaires, car les images ont été prises par une caméra CCD munie d'un flash. L'auteur attribue la difficulté de la classification des tissus à la mauvaise qualité des images prises par les cliniciens, mais ne donne aucun chiffre sur les résultats obtenus par cette méthode.

Jones et Plassmann ont mis au point un système appelé MAVIS (Measurement of Area and Volume Instrument System) pour mesurer les dimensions d'escarre [Jones & Plassmann, 1995] et [Plassmann & Jones, 1998]. La prise de deux images de l'escarre est réalisée avec une caméra CCD sous un éclairage contrôlé (ampoule halogène 250w) et la présence d'une zone de blanc de référence (oxyde de magnésium). Ils utilisent la couleur pour segmenter l'image de l'escarre en trois types de tissus (peau saine, escarre, et tissu épithélial). Les intensités des plans R, G, et B sont examinées séparément, puis un seuillage sur chaque plan est appliqué. Les auteurs concluent qu'un simple seuillage direct sur ces plans n'aboutit pas à une bonne segmentation séparant l'escarre et la peau saine et que la segmentation est partiellement atteinte en utilisant la projection d'histogrammes 1D ou 2D.

Ce dernier résultat a été confirmé dans les travaux de [Mekkes & Westerhof, 1995] et [Berriss & Sangwine, 1997]. Ils exposent une méthode de "clustering" 3D d'histogrammes couleur dans l'espace couleur *RGB*. Les clusters d'un tissu donné forment un nuage 3D irrégulier lié à la distribution complexe des couleurs. La teinte rouge du bourgeon varie en intensité du rouge foncé au rouge clair avec des nuances pourront aller jusqu'au marron, violet ou à l'orange. On comprend donc qu'un simple seuillage

selon les axes R , G et B ne permet pas d'obtenir une segmentation pertinente des trois tissus. Pour cette raison, de grands tableaux de couleurs présentés dans chaque type de tissu ont été créés à l'aide des cliniciens, comme base d'apprentissage permettant la classification de l'image en différents types de tissus. Encore une fois, la classification ne parvient pas totalement à distinguer les tissus de bourgeonnement de la peau saine.

Appliquant une méthodologie similaire, [Zhang et al., 2000] utilisent ces trois histogrammes R , G , et B comme trois signaux 2D d'entrée pour la classification de régions d'intérêt tissulaires. Une approche CBR (Case-Based Retrieval) a été implémentée en utilisant un classifieur par les k -plus proche voisins (k -ppv) avec une distance euclidienne. Ils calculent des taux de classification mixtes (bourgeon et fibrine, bourgeon et nécrose, bourgeon et tissu épithélial, fibrine et tissu épithélial), et multi-classes Figure 1.8.

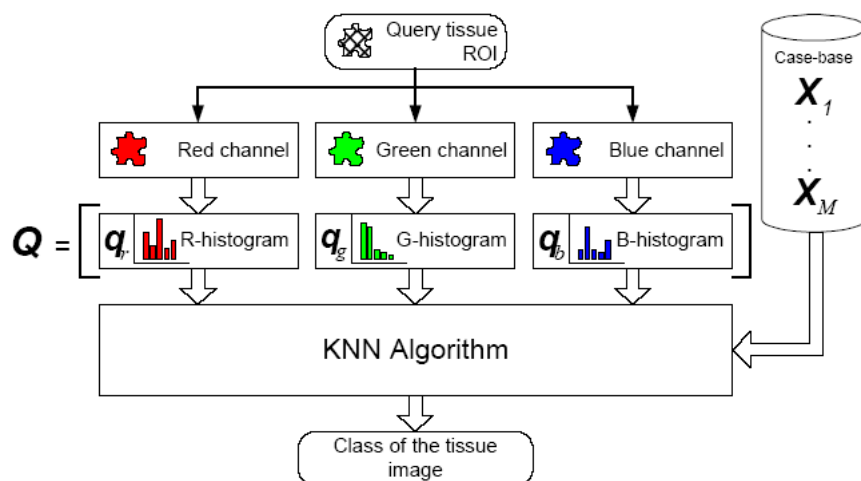


Figure 1.8 – Schéma CBR de la classification des échantillons [Zhang et al., 2000].

Des taux de classification moyens de 86.2% à 99.45% sont obtenus pour la classification binaire et de 88.7% pour la classification multi-classes. Il faut souligner, que les descripteurs des régions d'intérêt, basés uniquement sur la couleur, sont extraits de l'histogramme RGB sans aucune correction colorimétrique. En plus, il faut noter que ces résultats évaluent les capacités de classification sur des échantillons extraits manuellement, mais qu'aucun résultat de classification sur des images entières n'a été donné.

Une étude plus récente apporte des améliorations aux descripteurs des régions d'intérêt [Galushka et al., 2005]. Après avoir constitué une base de régions d'intérêt rectangulaires (10×10 pixels), extraits manuellement dans des zones de tissus bien homogènes, ils complètent par des descripteurs de texture les descripteurs de couleur issus des histogrammes RGB . Les trois mesures de texture utilisées sont le second moment angulaire décrivant l'homogénéité, le contraste et la corrélation. Ces mesures sont dérivées de la matrice de co-occurrence introduite dans [Haralick & K., 1973]. La

moyenne et l'écart-type des trois mesures de texture sont calculés sur chaque canal dans l'espace RGB. L'ensemble des 36 descripteurs est ensuite injecté à l'entrée d'un classifieur k-plus proches voisins avec k égal à 10. Les taux de classification annoncés se situent globalement entre 86% et 90% avec un apprentissage effectué sur le tiers des régions, en considérant respectivement une équi-représentation de 3 ou 6 classes de tissus. Cette fois encore, la capacité de classification est évaluée uniquement sur des régions d'intérêt rectangulaires sans aucune illustration des résultats de classification sur une image brute. Ceci s'explique par le fait de ne pas pré-segmenter l'image.

On peut noter que l'utilisation de l'histogramme couleur RGB est assez répandue dans ces applications, alors qu'elle s'avère insuffisante pour une parfaite classification des tissus. Une autre équipe a expérimenté la classification des ulcères en utilisant l'histogramme couleur dans l'espace HSV [D.I. & Tzeveleku, 2007]. Les descripteurs couleur extraits de l'histogramme de chaque région de la plaie et de la peau saine sont comparés avec une distance de Bhattacharyya puis combinés avec les paramètres des ondelettes de Gabor, calculés dans différentes orientations et échelles. L'ensemble des paramètres calculés (couleur et texture) caractérise les régions pré-segmentées par une méthode basée sur la théorie de *graph-cut*. Ces paramètres alimentent un SVM à noyau gaussien qui classe les tissus en six classes. Sur 85 images d'ulcères, environ 100 échantillons par classe ont été utilisés pour l'apprentissage et le taux de classification est de 83%. Cette nouvelle approche de classification semble plus robuste car elle utilise des descripteurs de couleur et de texture après une étape de segmentation. La classification utilisée n'est pas tout à fait cohérente : les quatre premières classes sont les stades définis par l'EPUAP décrivant la gravité de la plaie (état anatomoclinique) et les deux autres décrivent son état "coloriel". Il reste à signaler que la méthode n'est pas totalement automatique, car la région d'intérêt qui contient l'ulcère est extraite manuellement, ainsi que la référence de peau saine servant à calculer la distance de *Bhattacharyya*. Cette dernière est sensée se substituer à une correction colorimétrique.

Une approche de classification basée sur l'apprentissage supervisé des réseaux de neurones a été également appliquée aux brûlures [Acha et al., 2003] et [Serrano et al., 2005]. Le but est de séparer la zone brûlée de la peau saine pour identifier trois degrés de brûlures. Dans un premier temps, la segmentation de la zone de brûlure est réalisée de manière semi-automatique à partir d'un point sélectionné manuellement dans cette zone par un seuillage dans l'espace $L^*u^*v^*$ (Figure 1.9). Dans un second temps, un ensemble de paramètres (moyenne, écart-type, *kurtosis* et *skewness*) sont calculés dans les espaces $L^*u^*v^*$ et $L^*c^*h^*$, afin de former les entrées d'un réseau de neurones *fuzzy-artmap*. Les taux de classification obtenus sur 35 images de brûlures sont de 82 à 88%.

Cette méthode semi-automatique par seuillage n'est capable de classifier qu'un seul degré de brûlure à la fois. Il faut souligner aussi que la couleur d'une brûlure semble assez homogène par rapport à un tissu d'escarre, ce qui rend la méthode inapplicable dans notre cas.



Figure 1.9 – Segmentation de la zone de brûlure (a) sélection manuelle (b) seuillage [Acha et al., 2003].

Il ressort de cette étude bibliographique que la plupart des travaux sont basés sur des méthodes de classification directe des pixels pour séparer les différents types des tissus, en ne prenant pas en considération la continuité spatiale dans l'image. De plus, les résultats proviennent de zones sélectionnées manuellement. Le fait d'obtenir un bon taux de classification sur des échantillons sélectionnés manuellement n'est pas suffisant pour valider une bonne classification, car l'algorithme doit être appliqué sur toute la zone lésée et illustré sur l'image entière pour évaluer complètement la robustesse de la méthode.

1.2.1.3 Segmentation/détermination de la zone lésée

La définition du bord de la plaie fait souvent appel à un tracé manuel [Sanada et al., 2004], donnant ainsi aisément accès à des mesures surfaciques qui peuvent être calculées grâce à une échelle métrique présente près de la plaie au moment de la prise de vue. Cependant cette définition reste délicate et subjective.

A l'instar d'autres applications en dermatologie, comme la détection de mélanome [Colot et al., 1998] et [Zhang et al., 2000], plusieurs travaux ont visé une réelle fiabilité et reproductibilité de la détermination de la zone lésée par des traitements d'images couleur. Des détections semi-automatiques du bord de la plaie ont été proposées par l'utilisation de *spline* [Oduncu et al., 2004] ou de contour actif, [Jones, 1999] et [Plassmann & Jones, 2003] Comparés aux données manuelles, les biais des mesures de surface obtenue par l'algorithme de contour actif sont limités à 5%. Le contour actif a été aussi employé pour détecter des zones cancéreuses sur la peau comme les mélanome [Chung & Sapiro, 2000].

Une autre approche reposée sur l'apprentissage d'un SVM [Kolesnik & Fexa, 2004]. Plusieurs descripteurs couleur sont exploités : l'intensité du plan B, l'intensité du plan G, l'histogramme standard et enfin un échantillonnage de l'histogramme RGB en quatre catégories contenant chacune 25% des pixels. Ils sont combinés à des descripteurs de texture dérivés de la matrice symétrique de covariance, calculée dans le plan B par la convolution de l'image avec une gaussienne après un filtrage médian. La

performance de la segmentation ainsi obtenue est évaluée par comparaison à un tracé manuel fait par des experts cliniques. Malgré le nombre important des paramètres d'apprentissage et la complexité calculatoire des descripteurs, surtout de texture, la méthode est incapable de segmenter correctement une image servant à la fois pour l'apprentissage et le test (Figure 1.10).




Figure 1.10 – Évaluation de la segmentation (a) image brute (b) contour détecté (noir) et tracé manuellement (blanc). Le taux d'erreur est de 3.43% de pixels mal classés. [Kolesnik & Fexa, 2004].

Dans une version plus récente de leurs travaux [Kolesnik & Fexa, 2005], les auteurs renoncent à la combinaison des descripteurs de couleur et de texture et se contentent de l'échantillonnage des histogrammes. Cette fois-ci leur échantillonnage est multidimensionnel et toujours dans l'espace couleur RGB. Le calcul assez complexe de l'histogramme 3D fournit les entrées d'un classifieur binaire SVM. Malgré la sélection de plusieurs milliers d'échantillons de référence dans chaque classe, les auteurs avouent une grande difficulté à obtenir un détournage correct de l'escarre sur des images arbitraires non incluses dans l'ensemble d'apprentissage. Dans la dernière version de leurs travaux, ils préconisent une étape supplémentaire pour ajuster un contour actif sur une pyramide d'images multi résolution [Kolesnik & Fexa, 2006].

Plusieurs méthodes ont aussi été développées dans des applications similaires, comme celles en dermatologiques ayant pour objectif la détection des zones dépigmentées. Une technique de regroupement en clusters couleur issus d'un histogramme 2D des deux principales composantes de l'espace couleur $L^*u^*v^*$ est utilisée dans [Schmid, 1999]. Après lissage, les pics d'histogramme permettent d'estimer les centres ainsi que le nombre des clusters à l'aide d'un perceptron. Enfin, les images d'ulcère ont été segmentées par une version modifiée de l'algorithme fuzzy c-mean. On remarque que l'auteur complique le problème de la détection des ulcères par deux étapes de classification afin d'obtenir la segmentation (Figure 1.11). Cependant, l'évaluation des résultats par les experts demeure très qualitative et subjective car elle s'est faite visuellement.

Dans [Celebi et al., 2005], l'extraction des bords de la plaie a été achevée par algorithme de segmentation JSEG modifié. Deux modifications ont été apportées par les auteurs sur l'algorithme initial. La première concerne l'étape de prétraitement, initialement réalisée par un filtre non linéaire PGF (*Peer Group Filtering*) et remplacé par un filtre médian. La deuxième concerne la quantification couleur. Ils utilisent




Figure 1.11 – Segmentation de zones dépigmentées [Schmid, 1999].

une méthode basée sur la variance des couleurs [Wan et al., 1990] à la place de GLA (*Generalized Lloyd Algorithm*) utilisé dans JSEG. Les arguments donnés par les auteurs sur ces modifications ne sont pas convaincants, du fait que le réglage des paramètres de JSEG permet de passer d'une segmentation très fine à une segmentation grossière, ce qui règle leur problème de sur-segmentation. La réduction des artefacts, comme les poils sur la peau, que l'on peut obtenir par l'application d'un filtre médian, peut complètement affecter le résultat par la suppression des détails de la texture (Figure 1.12). Là aussi, l'évaluation de la performance a été faite visuellement par des experts.




Figure 1.12 – Lissage de l'image d'une lésion (a) avec PGF (b) avec un filtre médian [Celebi et al., 2005].

L'extraction de la plaie par détection des bords a été abordée dans la plupart des travaux comme un problème de segmentation. Cependant, ce problème peut être examiné de façon plus large, en considérant une classification étendue des différents types de tissus cutanés incluant la peau saine comme classe supplémentaire ; la frontière pouvant être ensuite implicitement déduite de la cartographie. Cette approche a de fortes chances d'être plus robuste car les tissus présents dans une plaie sont très inhomogènes. Elle est d'autant plus justifiée que l'indétermination la plus problématique du tracé est souvent l'inclusion ou non des tissus d'épidermisation en bordure de la zone lésée. Les chapitres suivants développent notre approche de classification des régions segmentées pour dresser la cartographie tissulaire complète.

1.2.2 Analyse 3D

Certaines équipes de recherche proposent une analyse dimensionnelle des plaies par des mesures de volume. Les travaux les plus anciens sont ceux de Jones et Plassmann dans le projet MAVIS [Plassmann & Jones, 1998]. Leur système est basé sur la technique de triangulation par projection de lumière structurée, composée de codes couleurs (Figure 1.13). L'analyse des déformations des franges couleurs observées par un capteur CCD permet de reconstruire la surface de la plaie en trois dimensions. Ce système permet d'estimer le volume avec une précision de l'ordre de 5%, satisfaisant ainsi les exigences de l'application.

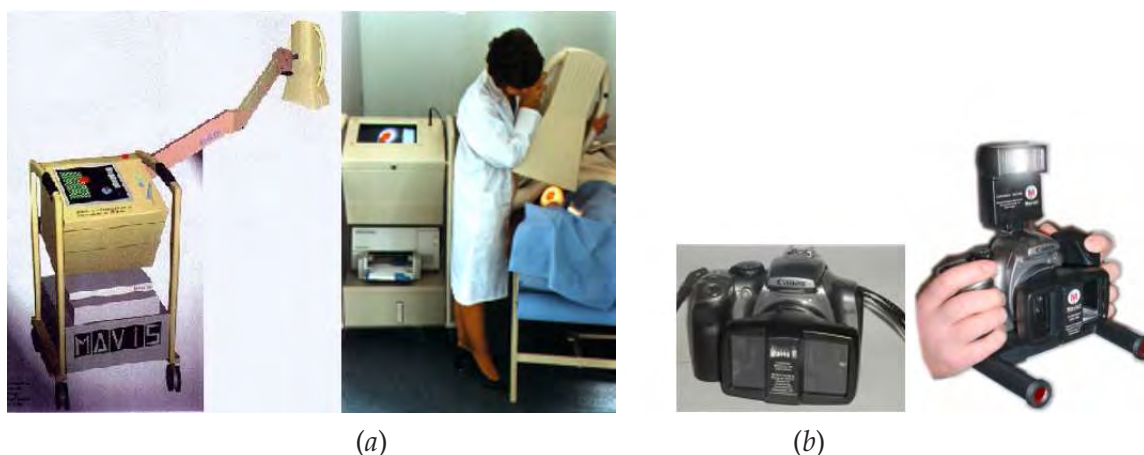


Figure 1.13 – (a) Système MAVIS I (b) Système MAVIS II [Jones et al., 2006].

Plus récemment, pour pallier le problème de maniabilité de leur système, l'équipe a mis au point une seconde version MAVIS-II réduite à un objectif spécial monté sur un appareil photo numérique réflex. Cet objectif assure la prise simultanée de deux demi-images pour la reconstruction d'un modèle 3D de la plaie.

Un système similaire au MAVIS-I a été développé en 2002 [Krouskop et al., 2002] (Figure 1.14-a). Il garantit une précision légèrement supérieure de l'ordre de 3%. Cependant, les performances de ces systèmes se voient fortement dégradées pour les escarres de petite taille, la résolution spatiale des éclairages structurés étant limitée. Pour remédier à ce problème, Malian a mis au point un système trinoculaire équipé d'un projecteur de texture nommé MEDPHOS (Figure 1.14) [Malian et al., 2002] [Malian et al., 2004]. Cet appareil utilise les relations géométriques entre les trois caméras pour mettre en correspondance les pixels des trois images. A partir de ces correspondances et de la position connue des trois caméras, la reconstruction 3D de la blessure est obtenue par une simple triangulation. La méthode permet d'atteindre une précision de l'ordre du millimètre sur la position des points 3D.

L'emploi de scanners industriels a été également testé dans le cadre du suivi thérapeutique de plaies dans le projet "DERMA" (Figure 1.15)[Romanelli et al., 2002] et [Callieri et al., 2003].

Un scanner laser de marque *Minolta* est utilisé pour acquérir la géométrie de l'escarre et capturer l'image des textures couleurs correspondantes. Le système DERMA propose différentes mesures comme le périmètre, la surface et le volume de



Figure 1.14 – (a) Système de Krouskop (b) système MEDPHOS.



Figure 1.15 – Projet DERMA

la plaie. La segmentation des tissus est possible après une sélection manuelle du bord de la plaie. Cette méthode est basée sur un algorithme de regroupement de régions appliqué dans l'espace HSV. Les contours peuvent aussi être définis par une méthode basée sur les *snakes* à l'aide des données de forme et de couleur provenant du modèle 3D. La précision métrologique du système annoncée par les auteurs est de 3% pour les mesures volumétriques et de 8% pour les surfaces tissulaires.

Généralement, les précisions obtenues par ces prototypes sont jugées suffisantes par les médecins pour ce genre d'application. Mais la plupart des systèmes d'acquisition dédiés sont des systèmes calibrés qui nécessitent des recalibrages fréquents pour assurer la stabilité des mesures. En outre, le fait qu'ils soient encombrants, lourds, onéreux et délicats à mettre en oeuvre, les rendent totalement inadaptés à une utilisation routinière dans les services de soins. D'autres systèmes, comme MAVIS-II, sont ergonomiques mais leur prix trop reste élevé pour une diffusion massive dans les centres de soins. C'est le cas du MAVIS II où de plus, le faible écartement entre les deux vues stéréo limite la précision de triangulation.

1.3 Conclusion et enjeux du projet ESCALE

Pour remédier aux problèmes des différentes techniques de suivi par imagerie et contourner leurs défauts et leurs limitations, nous proposons dans le cadre du projet ESCALE un nouvel outil de mesures sans contact avec le patient. Cet ou-

til offre une solution aux difficultés rencontrées, avec l'avantage d'allier la simplicité d'utilisation au faible coût, tout en garantissant l'efficacité et la précision des mesures.

Pratiquement, nous proposons d'utiliser un simple APN standard du commerce pour acquérir des images de plaies à main levée. Cette simplicité de mise en oeuvre devait faciliter la diffusion massive de cet outil dans les centres de soins. La contre partie est le développement d'algorithmes avancés permettant d'associer mesures volumétriques 3D avec des analyses couleur afin de quantifier l'état tissulaire de la plaie.

En ce qui concerne l'aspect 3D, le modèle géométrique est obtenu par stéréovision à partir de deux vues non calibrées, conduisant à un relevé volumétrique [Albouy, 2006] élaboré dans le cadre du projet ESCALE.

Cette thèse se concentre sur les analyses de couleur et de texture afin de dresser une cartographie tissulaire de la plaie dans chaque vue disponible. Ces informations vont par la suite être fusionnées sur le modèle 3D pour produire une classification multi-vues robuste et unique. La projection des zones tissulaires sur le relief 3D de la plaie va permettre un calcul exact des surfaces occupées en s'affranchissant des biais introduits par la projection perspective. Ainsi, en intégrant relevé 3D et analyse couleur dans une seule chaîne de traitement d'images, on optimise les performances de ces deux traitements : le modèle 3D contribue à améliorer la classification des tissus par une analyse multi-vues et les mesures exactes des surfaces tissulaires. Réciproquement, la classification des tissus va permettre une extraction plus précise du modèle 3D grâce à l'élimination des régions saines périphériques. Les chapitres qui suivent présentent l'approche adoptée : pré-traitement des images (Chapitre 2), classification mono-vue (Chapitre 3) et enfin classification multi-vues (Chapitre 4).

Prétraitements

Ce chapitre présente les étapes préalables à la classification tissulaire. Dans la première étape il constitue une base d'images cliniques de bonne qualité, dont on pourra extraire un ensemble d'échantillons de référence validés par des experts médicaux. La seconde étape réalise un découpage automatique des images en régions de texture couleur homogène, pour faciliter l'extraction de caractéristiques robustes lors de l'étape ultérieure de classification. Afin de limiter la dispersion dû aux variations d'éclairage et de rendu couleur des différents APN, une étape de correction colorimétrique a été intégrée en amont la chaîne de traitements.

Sommaire

2.1	Introduction	28
2.2	Constitution d'une base d'images	28
2.2.1	Labellisations manuelles par des experts	29
2.2.2	Répétabilité inter/intra opérateur	31
2.3	Correction colorimétrique	33
2.3.1	Perception colorée et notion de couleur	34
2.3.2	Codage de la couleur dans les APN	35
2.3.3	Méthode de correction adoptée	37
2.3.4	Validation expérimentale	43
2.4	Segmentation en régions de couleurs homogènes	52
2.4.1	Algorithme Color Structure Code (CSC)	53
2.4.2	Méthode à base de graphes (EGBIS)	54
2.4.3	Algorithme Mean Shift	55
2.4.4	Algorithme JSEG	57
2.4.5	Comparaison des méthodes sur les images d'escarres	60
2.5	Création de la base d'échantillons	66
2.6	Conclusion	66

2.1 Introduction

Afin d'appréhender toute la diversité des cas d'escarres, la première tâche consiste à collecter une base d'images sur plusieurs sites hospitaliers. La caractérisation tissulaire doit s'appuyer sur l'expertise médicale des spécialistes pour extraire des échantillons tissulaires avant d'élaborer des descripteurs colorimétriques pertinents de la classification automatique. La première partie de ce chapitre présente donc la constitution d'une base d'images d'escarres ainsi que la création d'échantillons de référence par une labellisation manuelle effectuée par des experts médicaux. Concernant les conditions de prises de vues, nous avons choisi l'option la moins contraignante pour les experts : les images ont été acquises sur plusieurs sites hospitaliers avec divers APN sans autre éclairage que le flash intégré. Cette liberté de prise de vues a imposé d'analyser et de corriger les variations colorimétriques observées lors des prises de vues. La seconde partie du chapitre aborde la correction colorimétrique des images. Enfin la dernière partie est consacrée à la segmentation automatique et non supervisée des images en régions de texture homogène. La Figure 2.1 montre l'ensemble de la chaîne de prétraitement appliqués aux images.

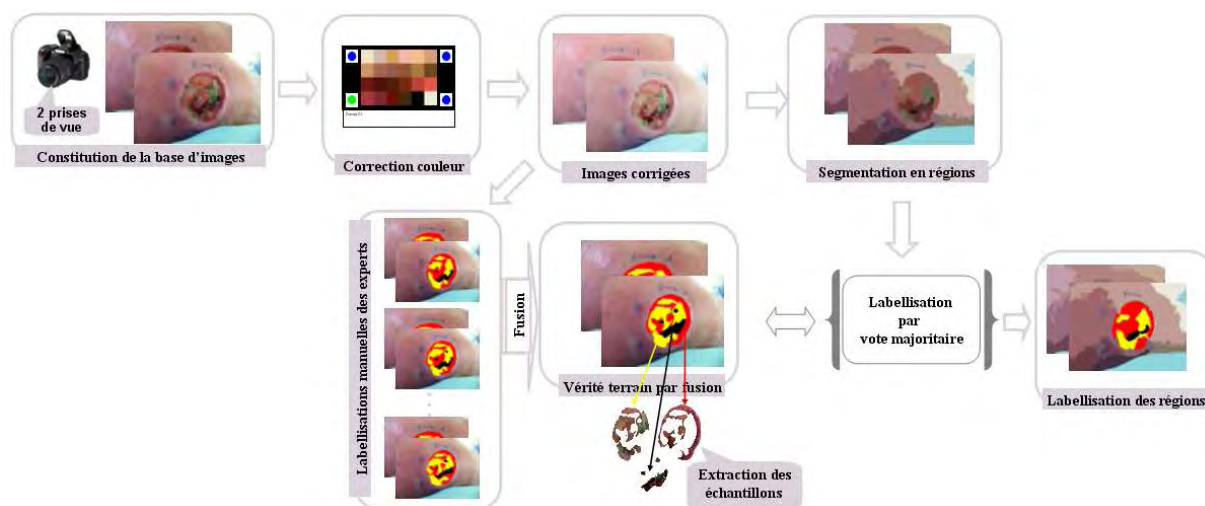


Figure 2.1 – Chaîne de prétraitement appliqués aux images de plaies.

2.2 Constitution d'une base d'images

Un partenariat a été établi avec quatre équipes cliniques des hôpitaux¹ de la région Centre. L'objectif est de collecter un nombre suffisant d'images de différents types de lésions présentant les trois classes de tissus (bourgeon, fibrine et nécrose), afin de permettre la généralisation des algorithmes et la conception d'un classifieur optimal des tissus.

¹Centre de rééducation ADAPT de Virazeil, Centre Hospitalier de Bourges, Centre Hospitalier d'Issoudun, Centre Hospitalier Régional d'Orléans

Plusieurs centaines de photos couleur (24 bits) avec une résolution minimale de 3 millions de pixels ont été prises avec différents modèles d'APN et stockées sous un format compressé (JPEG) de très bonne qualité. Chaque plaie a été photographiée selon plusieurs points de vue en respectant le protocole de prise de vues spécifié par la méthode de reconstruction du modèle 3D ([Albouy, 2006]). Après avoir placé la mire au plus près de l'escarre, une première vue faciale permet de cadrer la plaie en plein champ et de choisir la focale de la zoom le mieux adaptée. Typiquement, cette vue peut-être prise perpendiculairement au plan de l'escarre à seulement 20 cm pour une petite plaie, 30 cm pour une plaie étendue. Pour la seconde vue, on recule l'appareil de 10% à 20% environ et on pivote de 20° à 25°, sans changer le facteur de zoom fixé à la première image. La mire a trois fonctions : permettre le recalage colorimétrique de la photo, indispensable pour la classification des tissus, fournir un facteur d'échelle pour calculer les dimensions de l'escarre et enfin identifier le patient.

Afin d'enrichir la base pour en prenant en compte la diversité des points de vue, trois autres vues ont été ajoutées aux deux initiales afin de disposer de quatre vues cardinales pour chaque plaie. En effet, l'aspect tissulaire est plus sensible aux variations de points de vue que la détection de points singuliers utilisée dans la reconstruction 3D. Les autres prises de vues sont ainsi régulièrement réparties autour de la plaie comme le montre la Figure (2.2). La priorité étant la netteté des photos, l'utilisation du flash est conseillée chaque fois que des conditions d'éclairage insuffisantes entraînent un risque de bougé.

La reconstruction 3D peut être faite à partir de 2 vues seulement, la vue centrale et l'une des 4 vues cardinales. La multiplicité des points de vues permet de s'affranchir d'éventuels reflets ou occultations.

2.2.1 Labellisations manuelles par des experts

L'obtention d'une vérité terrain nous a semblé impérative pour évaluer la justesse de la segmentation tissulaire et la performance d'un classifieur. La base d'images d'escarres précédente a été fournie à un groupe d'experts médicaux, afin de la labelliser suivant le code couleur classique (bourgeon/fibrine/nécrose). Deux interfaces graphiques ont été développées pour la labellisation manuelle. La première version permet à l'expert médical de colorer des régions dans l'image d'escarre, en lui laissant une liberté totale pour le tracé des contours effectué à la souris (Figure 2.3).

Ces labellisations ont servi à l'évaluation des algorithmes de segmentation (§2.4.5). La seconde version de l'interface graphique permet de labelliser directement des régions automatiquement pré-découpées par l'algorithme de segmentation (Figure 2.4). Ces labellisations permettent d'obtenir des échantillons plus homogènes pour l'extraction des descripteurs. Elles serviront à l'évaluation de la classification automatique présentée au chapitre 3.

Des précautions ont été prises sur les conditions d'éclairage et le réglage des écrans graphiques, lors des séances de labellisation. Les patients correspondant aux




Figure 2.2 – Protocole de prise de vues : une prise de vue faciale suivi de quatre autres : avant, arrière, gauche et droite, après un recul de l'APN pour éviter les singularités de l'auto-calibrage lors de la reconstruction 3D.




Figure 2.3 – Première version de l'interface graphique de labellisation : les régions sont tracées manuellement à la souris par les experts.

escarres photographiées n'ont pas été visités par les experts médicaux qui participent à la labellisation pour éliminer toute influence extérieure.




Figure 2.4 – Seconde version de l’interface graphique de labellisation : coloriage de régions automatiquement pré-segmentées.

L’évaluation clinique de la cicatrisation d’une plaie chronique comporte d’une part des mesures volumétriques et d’autre part une classification couleur des tissus. En ce qui concerne les mesures volumétriques, les praticiens ont donné dans leur cahier des charges une précision de l’ordre de 5%. Pour ce qui est de l’analyse couleur, la précision n’a pas été spécifiée par les experts, concernant les pourcentages de tissus la performance des tracés exigée. L’analyse des tracés manuels réalisés par les experts sur des images d’escarres va permettre de quantifier celle-ci, par l’observation des répétabilités inter et intra expert.

2.2.2 Répétabilité inter/intra opérateur

L’analyse des tracés manuels des experts est pour évaluer les répétabilités inter et intra expert et établir une référence statistique pour l’évaluation ultérieure de la segmentation et de la classification automatiques des tissus. Une expérience de labellisations manuelles, exécutée par quatre experts indépendants et renouvelée à un mois d’intervalle, a permis d’évaluer leurs répétabilités par le calcul d’un score de recouvrement.

Le score de recouvrement donne l’accord entre deux labellisations différentes d’une même image j :

$$C(T_{1i}^j, T_{2i}^j) = \frac{\text{card}[T_{1i}^j \cap T_{2i}^j]}{\text{card}[T_{1i}^j \cup T_{2i}^j]} \quad (2.1)$$

où T_{1i}^j et T_{2i}^j désignent les ensembles des pixels labélisés comme appartenant au type de tissu ($i = 1, 2, 3$) respectivement dans chacune des labellisations et $\text{card}[\]$ le nombre de pixels. Ce score est ensuite moyenné sur N images en tenant compte de la fréquence d’apparition des tissus pour obtenir une valeur normalisée ($0 < \bar{C} < 1$) :

$$\bar{C}(T_{1i}, T_{2i}) = \frac{\sum_{j=1}^N C(T_{1i}^j, T_{2i}^j) * \bar{S}_i^j}{\bar{S}_i} \quad (2.2)$$

où \bar{S}_i^j représente la moyenne de la surface occupée par le tissu i sur les deux labellisations de l'image j et $\bar{S}_i = \sum_{j=1}^N \bar{S}_i^j$.

Afin d'obtenir une vérité terrain unique et fiable, les labellisations manuelles des différents experts ont été fusionnées. Pour chaque tissu, nous avons retenu les pixels qui représentent un taux de confiance supérieur ou égal à 75% soit au moins six labellisations concordantes sur huit (Figure 2.5). Un critère de vote majoritaire a été appliqué pour étiqueter les pixels de l'image conformément à une classe de tissu donnée. Les scores obtenus pour les labellisations faites à un mois d'intervalle par le même expert sont donnés dans le Tableau 2.1 ; ceux obtenus entre chaque expert et la vérité terrain, déduite de la fusion de leurs tracés, dans le Tableau 2.2.

Classe de tissu	Intra-expert				Moyenne tissu
	1	2	3	4	
Bourgeon	73.9 %	65.0 %	55.9 %	66.7 %	65.4 %
Fibrine	77.4 %	73.8 %	55.3 %	71.4 %	69.5 %
Nécrose	81.4 %	91.4 %	59.5 %	81.9 %	78.6 %
Moyenne expert	77.6 %	76.7 %	56.9 %	73.3 %	

Tableau 2.1 – Scores de recouvrement intra expert à un mois d'intervalle.

Classe de tissu	Expert / vérité terrain				Moyenne tissu
	1	2	3	4	
Bourgeon	73.2%	72.7%	39.3%	71.0%	64.1 %
Fibrine	58.9%	76.0%	42.8%	70.8%	62.1 %
Nécrose	79.3%	77.1%	82.6%	85.6%	81.2 %
Moyenne expert	70.5 %	75.3 %	54.9 %	75.8 %	

Tableau 2.2 – Scores de recouvrement entre chaque expert et la vérité terrain.

La comparaison des labellisations effectuées par les experts, établit clairement que cette tâche est subjective avec un score de recouvrement inter experts se situant entre 40% et 86%, et une répétabilité intra expert légèrement supérieure de 55% à 82%. Les experts ne réalisent pas deux labellisations identiques après un délai d'un mois. Ceux qui fournissent les labellisations les plus stables, obtiennent logiquement les meilleurs scores de recouvrement avec la vérité terrain. Les scores obtenus pour la fibrine sont les plus faibles car ce type de tissu est souvent mélangé avec le tissu nécrosé et les bourgeons poussent sous une couche de fibrine.

Ces résultats démontrent que l'identification des tissus est une tâche difficile même pour un expert humain, et soulignent l'intérêt de mettre au point une mesure quantitative non subjective par une segmentation automatique. Enfin les scores de recouvrement inter et intra experts donnent un ordre de grandeur pour juger de la performance de la classification automatique souhaitée.

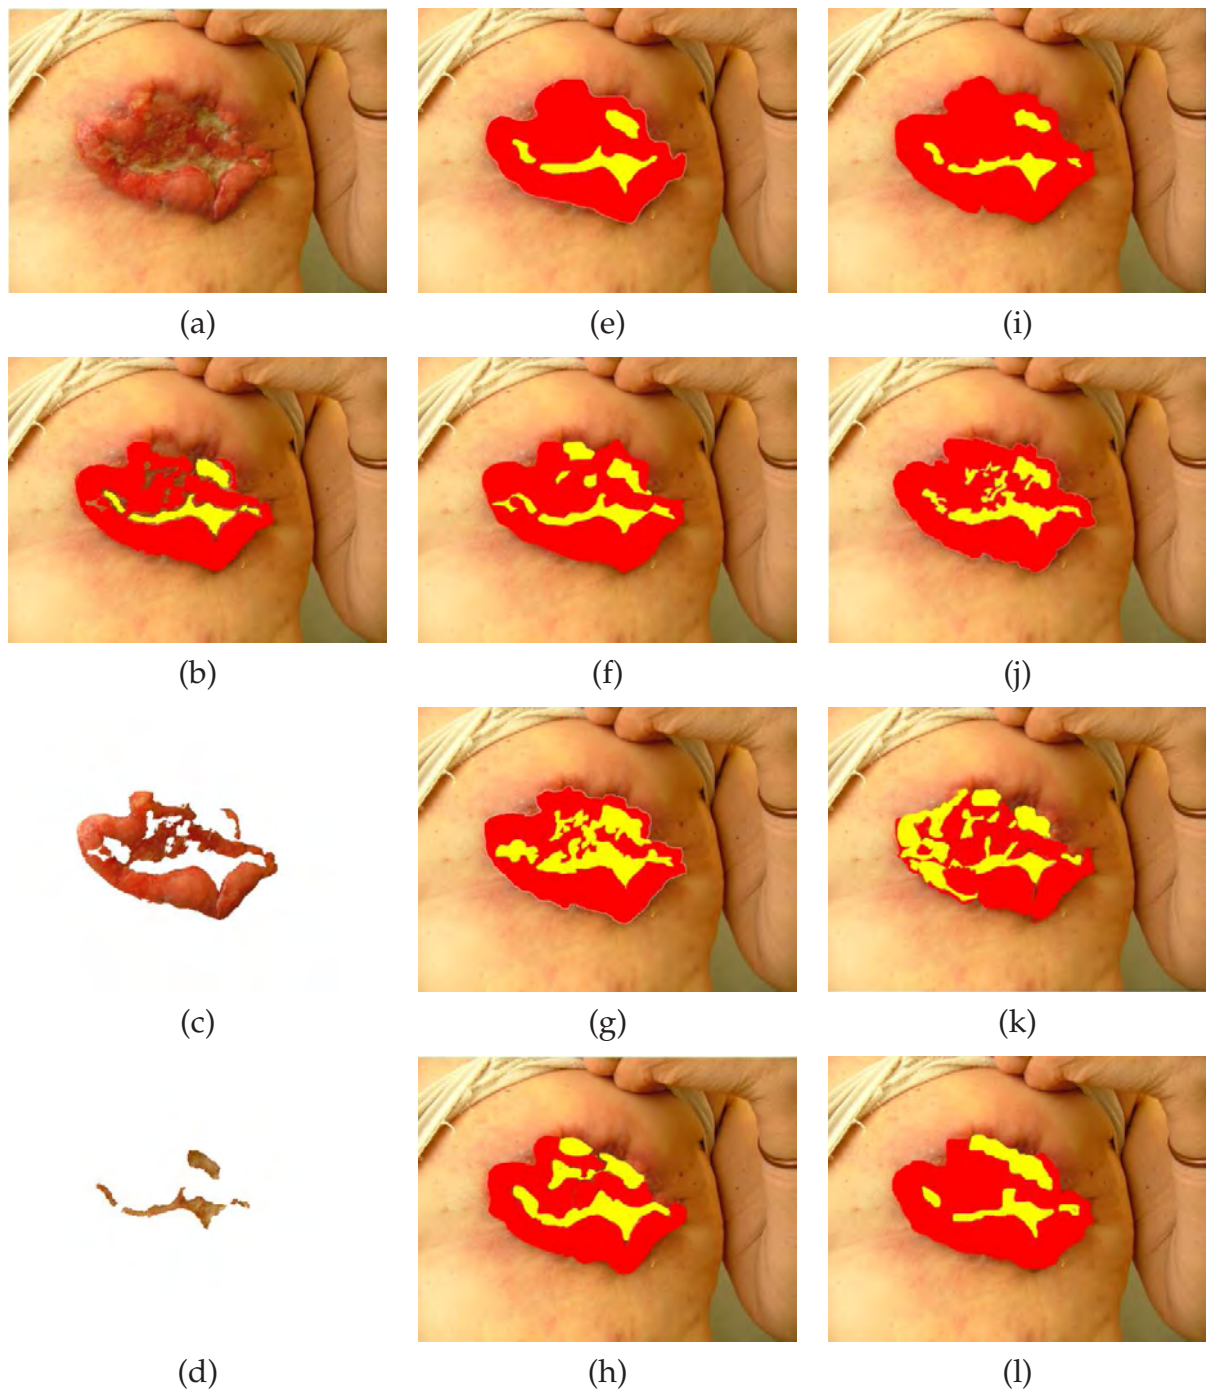


Figure 2.5 – Construction des échantillons de référence par la fusion des différentes labellisations manuelles fournies par les experts : (a) image originale (b) vérité terrain obtenue avec un taux de confiance de 75% (c-d) échantillons de référence extraits pour l'apprentissage du classifieur (e-h) tracés manuels de 4 experts (i-l) tracés manuels des mêmes experts à un mois d'inter valle.

2.3 Correction colorimétrique

La classification automatique des tissus repose sur une analyse des textures couleur dans l'image numérique. La reproductibilité des résultats est limitée par la

stabilité du processus d'acquisition des images, en particulier le rendu de la couleur qui s'avère être un attribut discriminant incontournable pour la classification et l'identification des tissus. En effet, les conditions d'éclairage, la réflectivité des tissus de la peau, la position des prises de vue et le modèle de l'APN sont des facteurs qui affectent les couleurs de l'image et par conséquent l'obtention de mesures stables.

L'APN, comme tout système d'imagerie numérique, dispose d'un codage interne des couleurs dépendant de l'appareil. Chaque APN a son propre espace de couleurs RGB, en fonction, entre autres, de la sensibilité spectrale de son capteur CCD, de l'optique et des réglages effectués lors de la prise de vue (sensibilité, balance des blancs, etc). Ces différences nuisent à l'obtention d'un ensemble d'images à peu près homogènes. D'autre part, les conditions d'éclairage dans la chambre du patient peuvent varier fortement d'un jour à l'autre et ce manque de reproductibilité s'avère très pénalisant dans le cas d'un suivi au cours du temps. Même en utilisant un flash, on ne s'affranchit pas totalement de l'influence de l'éclairage ambiant. Ceci impose d'appliquer une correction colorimétrique aux images afin d'obtenir une base d'apprentissage plus homogène.

Avant de présenter le codage de la couleur dans les APN, le paragraphe suivant introduit la notion de couleur, initialement liée à la perception humaine.

2.3.1 Perception colorée et notion de couleur

D'un point de vue physique, la lumière est une onde électromagnétique, dont une partie seulement du spectre est perçue par la rétine de l'œil humain (entre 380 et 780 nm). Dans l'œil, les cônes sont les cellules photoréceptrices de la rétine responsables de la perception colorée. Il en existe environ 6 millions sur rétine humaine, répartis en 3 familles, chacune étant préférentiellement sensible à une partie du spectre visible : les cônes *L* pour les grandes longueurs d'onde (rouge), les cônes *M* pour les moyennes (vert) et les cônes *S* pour les courtes longueurs d'onde (bleu). C'est par l'interprétation de ces stimuli trichromatiques que le cerveau construit sa perception de la couleur. La couleur, telle qu'elle est perçue par l'ensemble œil-cerveau est une sensation qui dépend des interactions complexes entre la source d'éclairage et les propriétés de surface de l'objet, mais aussi de l'apprentissage cognitif. Autrement dit, la couleur n'existe pas de façon intrinsèque sans une interprétation de notre cerveau.

On peut observer, dans des conditions expérimentales contrôlées, une relation entre la longueur d'onde dominante d'un stimulus² visuel et la couleur perçue. Mais cette relation est loin d'être suffisante dans l'expérience quotidienne. La stimulation lumineuse qui atteint la rétine peut venir directement d'une source de lumière (telle que le soleil, une lampe ou un projecteur), mais elle peut aussi émaner de la lumière réfléchiée par des objets ou des surfaces. Il suffit de regarder autour de soi pour

²On appelle stimulus le spectre qui atteint l'œil ou tout autre capteur : $S(\lambda) = I(\lambda) * R(\lambda)$, produit du spectre de l'illuminant $I(\lambda)$ avec le facteur spectral de réflexion de l'objet $R(\lambda)$ [Trémeau, 1993].

constater que l'expérience chromatique vient le plus souvent de surfaces éclairées, et rarement des sources elles mêmes[Delorme & Flückiger, 2003].

De plus, notre perception de la couleur peut en partie s'affranchir des changements d'éclairage : la couleur d'un vêtement porté, par exemple, ne semble pas changer de couleur lors d'un passage de l'extérieur à l'intérieur. Cette faculté humaine de voir des objets avec une couleur constante, indépendamment des changements d'éclairage, introduite par Piaget³ est la *constance perceptuelle*, qui joue un rôle important dans le développement cognitif. Les systèmes d'acquisition d'images numériques n'ont pas cette aptitude remarquable et le rendu des couleurs se trouve modifié de façon significative par un changement d'illumination de l'objet. Ces appareils n'interprètent pas les couleurs, ils se contentent d'en fournir une représentation numérique.

La colorimétrie est une science récente qui a pour objet de définir les grandeurs et les normes pour caractériser et échanger des données concernant l'apparence visuelle. La Commission Internationale de l'Éclairage (CIE) a joué un rôle fondateur dans ce domaine en introduisant le premier observateur colorimétrique de référence [CIE, 1931]. Ses recommandations font autorité en la matière et la CIE est reconnue par l'ISO (International Standard Organisation) comme un organisme international de normalisation pour tous les systèmes d'éclairage ou de reproduction d'images [CIE, 1995]. Depuis bientôt un siècle, de nombreux systèmes de représentations des couleurs ont vu le jour. Le lecteur pourra trouver plus de détails sur le système visuel humain, la colorimétrie et les différents espaces tridimensionnels de représentation des couleurs en Annexe

2.3.2 Codage de la couleur dans les APN

Qu'ils soient de technologie CCD⁴ ou CMOS⁵, les capteurs numériques d'image présents dans les APN utilisent une matrice composée de photosites sensibles à la lumière, encore appelé pixels. Chaque pixel a la capacité de collecter une charge électrique proportionnelle à la quantité de lumière reçue. En sortie, la luminance est codée par un convertisseur analogique/numérique⁶.

L'information de couleur est fournie par des filtres colorés qui recouvrent les photosites. On peut distinguer deux types de caméras couleur : mono-CCD et tri-CCD. Dans le mono-CCD, la couleur est obtenue en plaçant une mosaïque de filtres colorés, de telle sorte que chaque cellule du capteur ne perçoit qu'une des trois composantes RGB. Différentes mosaïques sont disponibles, le filtre colonne, le filtre de Rockwell, le filtre de Bayer et d'autres. La plupart des APN utilisent un filtre de Bayer, constitué d'une séquence vert-rouge-vert-bleu, en quinconce d'une ligne

³Jean Piaget, un psychologue suisse, a défini des stades du développement cognitif qui sont largement reconnus par les autres spécialistes travaillant dans ce domaine.

⁴Coupled Charge Device

⁵Complementary Metal Oxide Semiconductor

⁶Un CAN de 8 bits offre généralement une dynamique inférieure à 60 dB, un CAN de 10 bits entre 60 et 70 dB et un CAN de 12 bits au-delà de 70 dB [Trémeau et al., 2004].

à l'autre. Puisque nos yeux sont particulièrement sensibles au vert, il y a deux fois plus de pixels verts que de pixels bleus ou rouges. Chaque pixel ne code donc qu'un seul canal, les deux autres pouvant être interpolés à partir des valeurs des pixels adjacents par dématricage. Les caméras tri-CCD sont équipées d'un séparateur à base de prisme pour projeter le faisceau lumineux incident sur 3 capteurs CCD différents, un pour chacune de canaux R, V et B. Ainsi, à chaque point de l'image correspondent 3 cellules CCD et la résolution de l'image couleur n'est pas dégradée par mosaïquage⁷.

La sortie du capteur fournit les valeurs de luminance de chaque pixel de la matrice, appelées données brutes, enregistrées dans un fichier numérique au format brute (RAW en anglais). Le fichier RAW enregistre également les caractéristiques du filtre, afin qu'à la relecture, chaque pixel soit affecté au canal correspondant R, V ou B (ou à toute autre couleur de filtre). Outre le dématricage, la reconstruction de l'image à partir du fichier RAW tient compte de plusieurs paramètres de contrôle :

- la balance des blancs, qui permet d'adapter la réponse de l'APN à la température de couleur de la source lumineuse utilisée. Les APN offrent parfois le choix entre plusieurs illuminants normalisés⁸ et sont généralement équipés de deux modes : réglage automatique ou manuel. En mode automatique, des algorithmes internes permettent à l'APN de choisir automatiquement le blanc de référence le plus adapté. Le réglage manuel consiste à mémoriser les valeurs trichromatiques d'un blanc de référence en plaçant une feuille blanche devant l'APN. L'APN ajuste ensuite les gains des canaux RGB pour qu'ils délivrent des signaux de même amplitude.
- l'interprétation colorimétrique : puisque l'APN utilise différents jeux de filtres, le convertisseur de fichiers RAW doit donc assigner une couleur précise aux pixels RGB, généralement en faisant appel à un espace colorimétrique bien défini, tel que CIE XYZ.
- La répartition des tonalités : le convertisseur de fichiers RAW redistribue les tonalités d'une manière plus conforme à la façon dont notre œil perçoit les ombres et les lumières.
- la réduction du bruit, le lissage et la netteté : lorsque les détails d'une image arrivent à une taille très petite, l'acquisition sur un seul photosite ne délivre qu'une information partielle de la couleur (un seul canal R, V ou B), et peut causer des artéfacts. Les convertisseurs de fichiers RAW associent certains traitements de détection des contours et d'anticrénelage, afin d'éviter de réduire le bruit et d'améliorer la netteté.

Les convertisseurs de fichiers RAW utilisent des algorithmes propres à chaque APN, sans qu'il soit toujours possible d'y avoir accès. Les fabricants des APN ont chacun leur format constructeur pour encoder ces données brutes. Ils appliquent dans

⁷<http://www710.univ-lyon1.fr/~fdenis/club-EEA/cours/couleur2.html>

⁸les capteurs sont généralement calibrés pour les illuminants standards introduits par la CIE, comme par exemple la lumière du jour (illuminant D65) ou un éclairage incandescent ou halogène (illuminant A).

certains cas des algorithmes de compression voire même de cryptage des données. Ce qui fait qu'un fichier RAW⁹ n'a pas un format standard unique. La lecture de ce format nécessite donc la plupart du temps un logiciel ad-hoc fourni par le fabricant d'APN.

Une étape de correction colorimétrique doit chercher à s'affranchir, d'une part, de l'influence de l'éclairage et, d'autre part, des dérives et variations entre les différents modèles d'APN. La correction colorimétrique idéale exigerait l'accès aux données brutes du capteur, en photographiant en mode RAW. Mais, du fait que nos images sont prises par le personnel soignant qui maîtrise mal les fonctionnalités avancées de leur appareil, et sachant que les APN ne disposent pas tous du mode d'enregistrement RAW, il a semblé plus judicieux de travailler sur les données RGB, en enregistrant les images au format standard JPEG.

2.3.3 Méthode de correction adoptée

Le contexte de notre application impose plusieurs facteurs non contrôlés comme l'éclairage de la scène, la position des prises des vues ou le type d'APN utilisé. Dans ces conditions, les méthodes classiques de correction sont insuffisantes. Nous proposons d'utiliser une procédure d'adaptation chromatique fondée sur l'hypothèse de Von Kries en introduisant une mire de référence dans le champ de prise de vue. Notre méthode consiste à estimer l'illuminant par l'algorithme de "Retinex patch blanc" avant d'appliquer un équilibrage chromatique des couleurs (Annexe A).

L'approche de correction adoptée peut être décomposée en plusieurs étapes (Figure 2.6) :

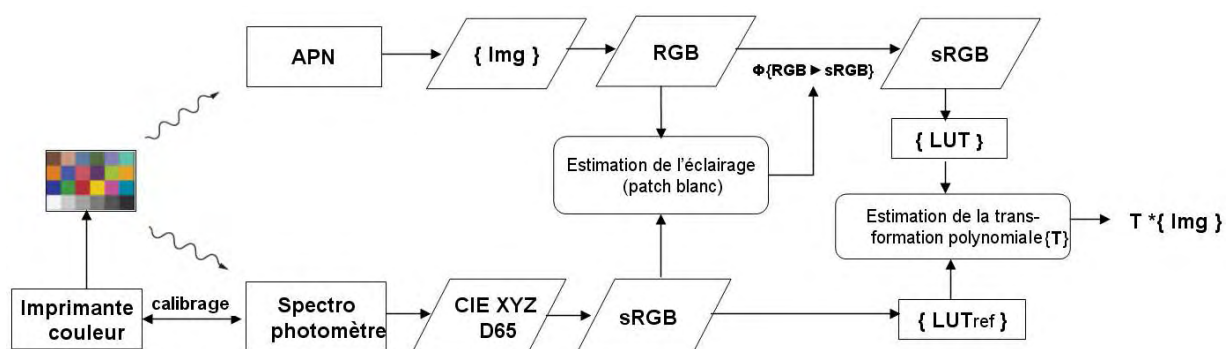


Figure 2.6 – Organigramme de la correction colorimétrique adoptée.

⁹Il s'agit en fait d'un terme générique regroupant les différents formats de fichiers des fabricants (CRW et CR2 de Canon, MRW de Minolta, NEF de Nikon, ORF d'Olympus, etc)



Figure 2.7 – Chaîne de production de la mire de référence.

2.3.3.1 Choix et composition de la mire

L'objet de référence introduit dans le champ de vue contient une mire standard *Macbeth* de petite taille, des marqueurs et une zone de texte (Figure 2.8). Il remplit plusieurs fonctions :

- contourner le problème de la détection d'une zone de réflectance maximale dans la scène, par l'utilisation d'un blanc de référence (carreau n°19) ;
- déterminer la table de correspondance entre les données couleurs à l'étape de caractérisation de l'APN ;
- fournir une référence métrique pour la mise à l'échelle d'un relevé de mesures 2D/3D ;
- identifier le patient et la date de prise de vue (zone de texte).

Il faut souligner ici que l'insertion d'une petite mire dans le champ de vue n'est pas gênante pour l'équipe de soin. La méthode a d'ailleurs été inspirée de la pratique clinique d'une règlette de trois ou quatre couleurs utilisée pour faciliter la classification "colorielle" [Cuzzell, 1988]. La mire a été conçue de façon à rendre possible sa détection automatique dans l'image quelle que soit sa position.

Pour éviter les risques d'infection, les mires doivent être jetables et fabriquées en assez grand nombre pour être distribuées sur les divers sites hospitaliers partenaires. Nous avons donc eu recours à un ensemble d'équipements (PC, imprimante couleur¹⁰, colorimètre¹¹ et spectrophotomètre¹²) pour maîtriser le processus de fabrication (Figure 2.7).

L'utilisation de mires étalonnées du commerce n'a pas été retenue pour plusieurs raisons :

¹⁰HP Photosmart 2610

¹¹Sonde ColorVision Spyder2TM Colorimeter

¹²Minolta CS-1000 mis à notre disposition par le laboratoire Lezi à l'TUT d'Auxerre




Figure 2.8 – Mire de référence adoptée.

- impossibilité de disposer de mires étalonnées de dimensions optimales pour notre application
- coût élevé incompatible avec notre objectif de système bas coût utilisable dans tous les services hospitaliers
- problème de stérilisation de la mire placée au bord de l’escarre sujette à des infections.

Le modèle de la mire conçue sur PC contient les 24 carreaux de la mire standard *Macbeth* (18 couleurs et 6 nuances de gris, dont un blanc de référence). La chaîne d’impression a été calibrée grâce au logiciel *PrintFixPro*. Le spectrophotomètre a permis de vérifier les valeurs XYZ des carreaux sur un échantillon de mires, en utilisant l’illuminant normalisé CIE D65 et l’observateur CIE¹³. Ces valeurs sont ensuite transformées dans l’espace $sRGB$ par l’équation 5.6 donnée en Annexe A. Les 24 carreaux de la mire permettent de construire une matrice de dimension 3×24 de valeurs de référence $sRGB$.

$$\begin{pmatrix} \langle R_{m,i} \rangle \\ \langle G_{m,i} \rangle \\ \langle B_{m,i} \rangle \end{pmatrix} = \Phi_{XYZ \rightarrow sRGB} \begin{pmatrix} \langle X_{m,i} \rangle \\ \langle Y_{m,i} \rangle \\ \langle Z_{m,i} \rangle \end{pmatrix} \quad (2.3)$$

où $(X_{m,i}, Y_{m,i}, Z_{m,i})$ désignent les mesures délivrées par le spectrophotomètre pour le patch i et $(R_{m,i}, G_{m,i}, B_{m,i})$ les valeurs transformées.

L’espace $sRGB$ est choisi comme espace de correction pour plusieurs raisons : pour la compacité de stockage et le chargement rapide des fichiers image, et parce que c’est l’espace naturel d’affichage. Aucune transformation n’est nécessaire contrairement aux espaces $CIEXYZ$ et $CIELAB$. En contrepartie, le calcul d’une distance perceptuelle comme ΔE_{ab} ou ΔE_{2000} imposera une transformation. Un des inconvénients de cet espace est son gamut¹⁴ de couleur restreint, mais on verra au paragraphe

¹³L’observateur de référence de la CIE 1931 définit le comportement moyen de l’œil sous un angle de 2° .

¹⁴Le gamut est le sous-ensemble de couleurs qu’un de matériel donné permet de reproduire.

2.3.4.3 qu'il reste suffisant pour représenter la gamme réduite des couleurs caractéristiques des plaies chroniques.

2.3.3.2 Détection et lecture automatique de la mire

La détection automatique de la mire dans les images s'appuie sur l'estimation robuste d'une transformation homographique et peut être décrite en 4 étapes (figure 2.9) :

- détection des 4 cibles rondes placées aux coins de la mire (3 bleues et une verte) pour repérer le quadrilatère englobant les 24 carreaux couleur. Les positions des sommets du quadrilatère sont ensuite affinées en appliquant le détecteur d'Harris et Stephen [Harris & Stephens, 1998] au voisinage des 4 coins de la mire (points verts dans la Figure 2.9-a) ;
- estimation des 31 coins des carreaux de couleur à l'intérieur de la mire par le détecteur Harris et Stephen (points rouges dans la Figure 2.9-a) ;
- calcul de l'homographie qui annule l'effet de perspective et transforme l'image pour redonner à la mire sa forme réelle au facteur d'échelle près (Figure 2.9-b) ;
- extraction des 24 valeurs *RGB* par moyennage sur les carreaux de la mire.




Figure 2.9 – Détection et lecture automatique des couleurs de la mire. (a) détection précise des coins (b) Estimation robuste de la transformation homographique (c) zones centrales des carreaux servant au calcul des valeurs *RGB*.

2.3.3.3 Adaptation à l'illuminant

Le système visuel humain est capable de s'adapter à une variation d'intensité comme à une variation globale de couleur de la source d'éclairage. L'adaptation chromatique est le mécanisme dynamique qui permet au système visuel humain d'ajuster sa réponse aux changements d'illuminant, afin de préserver la couleur naturelle des objets [Fernandez-Maloigne, 2005].

C'est le contrôle de la balance des blancs qui remplit cette fonction dans les APN. En l'absence d'un éclairage contrôlé et d'un réglage stable et unique sur les

divers APN, une adaptation à l'illuminant s'avère nécessaire a posteriori sur les images. Elle est possible à partir du patch blanc présent sur la mire. Les méthodes d'adaptation chromatique de la littérature adoptent généralement l'hypothèse de Von Kries [MacAdam, 1993]. Elle stipule que l'adaptation du système visuel à différents illuminants est réalisée en ajustant trois coefficients de gain associés aux trois canaux de couleur *LMS* (voir les détails en Annexe A).

Les algorithmes d'adaptation chromatique sur les systèmes numériques mettent donc en oeuvre une transformation des coordonnées trichromatiques d'une couleur (X_S, Y_S, Z_S) vers (X_D, Y_D, Z_D) , par une matrice de dimension 3×3 :

$$\begin{pmatrix} X_D \\ Y_D \\ Z_D \end{pmatrix} = M^{-1} \begin{pmatrix} R_{WD}/R_{WS} & 0 & 0 \\ 0 & V_{WD}/G_{WS} & 0 \\ 0 & 0 & B_{WD}/B_{WS} \end{pmatrix} M \begin{pmatrix} X_S \\ Y_S \\ Z_S \end{pmatrix} \quad (2.4)$$

avec

$$[M] = [M_A] \begin{bmatrix} \rho_D/\rho_S & 0 & 0 \\ 0 & \gamma_D/\gamma_S & 0 \\ 0 & 0 & \beta_D/\beta_S \end{bmatrix} [M_A]^{-1} \quad (2.5)$$

$$[\rho_S \ \gamma_S \ \beta_S] = [X_{WS} \ Y_{WS} \ Z_{WS}] [M_A] \quad (2.6)$$

$$[\rho_D \ \gamma_D \ \beta_D] = [X_{WD} \ Y_{WD} \ Z_{WD}] [M_A] \quad (2.7)$$

où (X_{WS}, Y_{WS}, Z_{WS}) et (X_{WD}, Y_{WD}, Z_{WD}) sont respectivement les coordonnées trichromatiques du blanc de référence d'origine et de destination dans l'espace XYZ, cependant (R_{WS}, G_{WS}, B_{WS}) et (R_{WD}, G_{WD}, B_{WD}) sont les coordonnées trichromatiques du blanc de référence d'origine et de destination dans l'espace RGB.

Le principe de ces algorithmes peut être résumé en trois étapes :

1. Transformer les valeurs primaires (X_S, Y_S, Z_S) dans le domaine des réponses des cônes *LMS*, pour obtenir les réponses (R_S, G_S, B_S) sous l'illuminant d'origine ;
2. Mettre à l'échelle les composantes couleur obtenues (R_S, G_S, B_S) par un facteur dépendant à la fois du blanc de référence des couleurs d'origine et de destination, pour obtenir ainsi la réponse adaptée (R_D, G_D, B_D) .
3. Revenir dans l'espace XYZ par la transformation inverse M^{-1} .

Les différences entre les méthodes proposées dans la littérature résident essentiellement dans la définition des réponses dans le domaine des cônes [Nayatani et al., 1981] [Fairchild, 1998] [Graham et al., 2000] [E308-01, 2001] [Ward & Eydberg-Vileshin, 2002]. Cette définition est liée à la prédiction des coefficients de la matrice M_A .

Plusieurs travaux, ont montré qu'une transformation linéaire diagonale est un bon modèle pour la constance chromatique à condition de pouvoir estimer le blanc de

référence ou l'illuminant de la scène [Finlayson et al., 1993], [Finlayson et al., 1994]. Dans notre cas, nous utilisons le patch blanc de la mire couleur comme réflecteur parfait pour déterminer l'illuminant. L'adaptation chromatique est faite en appliquant l'algorithme *Retinex patch blanc* [Land, 1977] dans l'espace couleur *sRGB*.

Les valeurs corrigées R_c, V_c, B_c sont obtenues par :

$$\begin{bmatrix} R_c \\ G_c \\ B_c \end{bmatrix} = \begin{bmatrix} K_R & 0 & 0 \\ 0 & K_G & 0 \\ 0 & 0 & K_B \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (2.8)$$

où $K_R = R_{m,19}/R_W$, $K_G = G_{m,19}/G_W$, $K_B = R_{m,19}/B_W$, et où $R_{m,19}, G_{m,19}$ et $B_{m,19}$ sont les valeurs trichromatiques du patch blanc $n^\circ 19$ mesurées sur notre mire à l'aide du spectrophotomètre.

Cette étape corrige l'image pour rendre les coordonnées trichromatiques indépendantes du changement d'illuminant mais elles restent dépendantes du type d'APN, ce qui implique une étape supplémentaire d'équilibrage chromatique.

2.3.3.4 Équilibrage chromatique des APN

Une même scène photographiée par deux APN donne lieu à des rendus couleur différents. Pour faire face à cette variabilité, on met en place un équilibrage chromatique (ou étalonnage). Cet étalonnage définit la relation entre l'espace couleur RGB propre à l'appareil et un espace couleur indépendant (comme *sRGB* ou *CIEXYZ*). Cette relation $\Phi_{RGB \rightarrow sRGB,m}$ peut être estimée au sens des moindres carrés par une régression polynomiale sur l'ensemble des couleurs de référence présentes sur la mire [Haeghen et al., 2000] :

$$\begin{pmatrix} R_c \\ G_c \\ B_c \end{pmatrix} = \Phi_{RGB \rightarrow sRGB} \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (2.9)$$

$$= \begin{pmatrix} a_1 & \cdots & a_m \\ b_1 & \cdots & b_m \\ c_1 & \cdots & c_m \end{pmatrix} \left[\Theta_m \begin{pmatrix} R \\ G \\ B \end{pmatrix} \right] \quad (2.10)$$

Le Tableau 2.3 présente plusieurs modèles de transformations polynômiales d'ordre croissant [Kang, 1997]

Dans le cas d'une transformation d'ordre 9 (Θ_9) par exemple, la correction de l'image s'effectue ensuite dans chaque canal [Jones et al., 2006] :

$$\begin{aligned} R_c &= a_1R + a_2G + a_3B + a_4RG + a_5RB + a_6GB + a_7R^2 + a_8G^2 + a_9B^2 \\ G_c &= b_1R + b_2G + b_3B + b_4RG + b_5RB + b_6GB + b_7R^2 + b_8G^2 + b_9B^2 \\ B_c &= c_1R + c_2G + c_3B + c_4RG + c_5RB + c_6GB + c_7R^2 + c_8G^2 + c_9B^2 \end{aligned} \quad (2.11)$$

Ordre (m)	Transformation (Θ_m)
3	$(R \ G \ B)^t$
6	$(R \ G \ B \ RG \ GB \ BR)^t$
8	$(1 \ R \ G \ B \ RG \ GB \ BR \ RGB)^t$
9	$(R \ G \ B \ RG \ GB \ BR \ R^2 \ G^2 \ B^2)^t$

Tableau 2.3 – Regressions polynomiales de différents ordres.

Il est évident que le nombre et la répartition des couleurs de référence utilisées auront une forte incidence sur la précision de la transformation estimée, et par conséquent, de l'équilibrage chromatique réalisé. Cependant, le grand nombre des couleurs d'une mire normalisée comme la mire IT8.7/2 (présentée en Figure 5.5 de l'Annexe A), induit une procédure d'étalonnage fastidieuse. La mire *Macbeth* avec ses 24 patches semble idéale de ce point de vue. Il faut noter ici que les carreaux de la mire qui présentent une saturation trop élevée ne sont pas pris en compte dans le calcul. Nous avons testé la méthode de regression avec plusieurs ordres (3, 6 et 9). Nous avons retenu un modèle de régression d'ordre 3 qui donne des résultats comparables à ceux des ordres supérieurs.

2.3.4 Validation expérimentale

Avant de lancer une campagne d'acquisition d'images d'escarres dans les centres hospitaliers, la méthode de correction colorimétrique a été testée dans des conditions maîtrisées en laboratoire. Les principaux objectifs de cette manipulation sont :

- évaluer les variations observées selon les différentes sources d'éclairage et points de vues
- évaluer les variations chromatiques induites par les différents APN
- quantifier l'apport de la procédure de correction adoptée

2.3.4.1 Tests en laboratoire

Pour évaluer les différents facteurs de dispersion colorimétrique, la mire a été photographiés sous différentes sources d'éclairage et selon différents points de vue avec plusieurs APN. Cette expérimentation a été réalisée au département Mesures Physiques de l'IUT de Bourges à l'aide des équipements suivants (Figure 2.10) :

- un banc optique muni d'un porte-échantillon et d'un rail orientable selon différents angles
- une mire couleur placée sur fond noir
- trois APN commerciaux¹⁵ placés à courte distance de la mire (30-40 cm)
- trois sources d'éclairage artificiel (halogène, tungstène, néon).

¹⁵un compact Leica D-Lux3, un bridge Sony DSC-H5 et un reflex Canon Eos 350D




Figure 2.10 – à gauche : Banc d'évaluation des sources de dispersion (IUT de Bourges), à droite : Spectrophotomètre utilisé pour déterminer les valeurs XYZ des carreaux de la mire (IUT d'Auxerre).

Les modalités du protocole expérimental sont présentées dans le Tableau 2.4. L'inclinaison des éclairages artificiels permet de limiter les reflets sur la mire. En ce qui concerne le réglage de balance des blancs des APN, deux séries de test sont effectuées, en mode automatique puis en mode manuel personnalisé. Ce dernier mode consiste à placer une feuille blanche sous l'éclairage testé pour mémoriser le blanc de référence. Seul le mode automatique a été utilisé avec le flash. Nous obtenons ainsi un total de 55 photos par APN. Quelques exemples de prises de vues sont illustrés en Figure 2.11.

Facteurs	Modalités
3 APN	Leica D-Lux3, Sony DSC-H5, Canon Eos 350D
6 sources d'éclairage	Halogène, Tungstène, Néon, Lumière naturelle, Soleil direct, Flash
5 angles de vue	0, 10, 20, 30, 40
2 modes de balance des blancs	automatique, manuel

Tableau 2.4 – Protocole expérimental

Cette expérimentation permet d'évaluer les influences du changement de point de vue ou d'éclairage par le calcul de l'erreur ΔE_{ab} , avant et après correction sur les 24 carreaux de la mire.




Figure 2.11 – Série de photos prises par un APN Sony DSC-H5 sous différentes sources d'éclairage et différents angles de vue. (a) lumière naturelle à 0° (b) flash à 20° (c) soleil direct à 40° (d) halogène à 20° (e) tungstène à 30° (f) néon à 40° .

Sensibilité à l'illuminant

Pour chaque illuminant et chaque APN, on a moyenné les mesures obtenues pour les 5 angles différents dans les deux modes de balance des blancs (Figure 2.12). Plusieurs remarques peuvent être faites au regard de ces résultats. Avant correction, les erreurs obtenues sous différents illuminants varient entre 8 et 28 en moyenne et entre 15 et 45 en valeur maximale. Les différents APN présentent des disparités dans la qualité de leur images sous différents type d'éclairage. Le bridge SONY donne le meilleur rendu des couleurs alors que le compact LEICA donne un rendu particulièrement mauvais lors de l'utilisation du flash, par exemple. Soulignons enfin que, pour les trois APN, les erreurs constatées en mode manuel de réglage du blanc sont légèrement inférieures à celles obtenues avec le mode automatique. Dans tous les cas, la procédure de correction réduit de façon significative les variations moyennes (d'un facteur 2 à 3 selon les cas), offrant ainsi une meilleure stabilité du processus de prise d'images.

Sensibilité au point de vue

Pour chaque angle et chaque illuminant, on a moyenné les mesures obtenues par les trois APN en mode manuel (Figure 2.13). Ces résultats montrent que le point de vue a peu d'incidence sur les mesures avec des variations modérées selon l'éclairage utilisé. Ceci conforte l'utilisation d'une mire pouvant être photographiée sous différents angles de vues pour la reconstruction 3D.

Les erreurs globales obtenues avec chaque APN sont présentées dans la Figure 2.14. Avant correction, les erreurs obtenues varient entre 11 et 17 en moyenne et entre

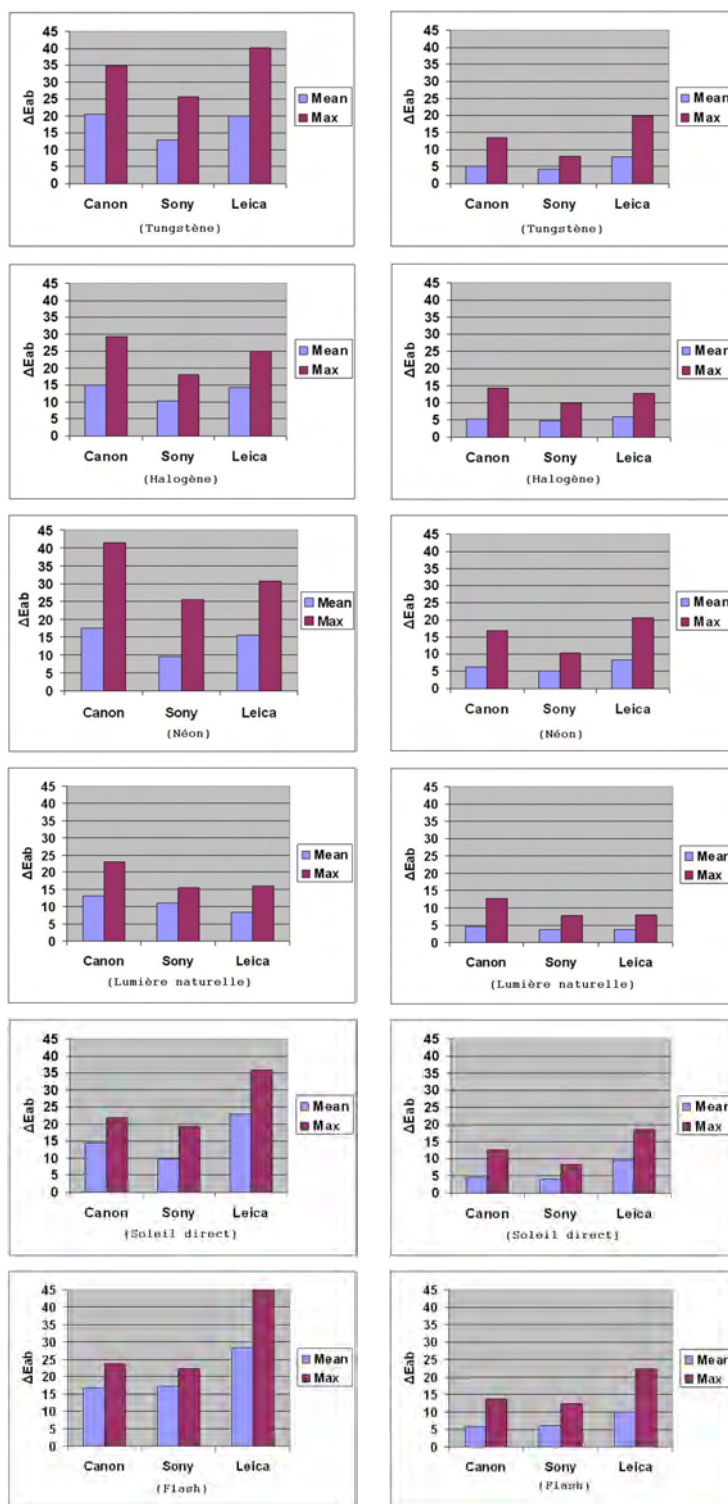


Figure 2.12 – Sensibilité à l’illuminant des APN : moyenne et valeur maximale des erreurs ΔE_{ab} obtenues pour différents illuminants sur 120 mesures par APN (5 angles, 24 carreaux, mode manuel). Colonne de gauche : avant correction. Colonne de droite : après correction.




Figure 2.13 – Sensibilité au point de vue : moyenne et valeur maximale des erreurs ΔE_{ab} obtenues pour différents angles sur 72 mesures (3 APN, 24 carreaux, mode manuel). Colonne de gauche : avant correction, Colonne de droite : après correction.

16 et 31 en valeur maximale.

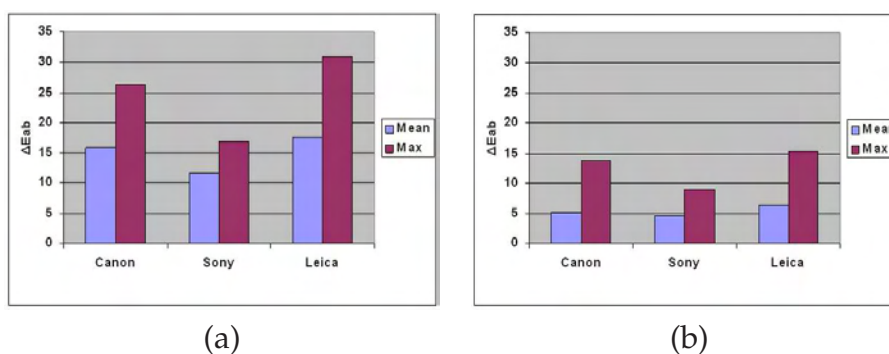


Figure 2.14 – Variations globales selon les APN : moyenne et valeur maximale des erreurs ΔE_{ab} sur 720 mesures (6 éclairages, 5 angles, 24 carreaux, réglage manuel de la balance des blancs) (a) avant correction (b) après correction.

Cette variation n'est pas identique pour les trois APN. Un changement d'APN induit donc un changement du rendu couleur préjudiciable pour le suivi thérapeutique. Mais on peut remarquer que la procédure de correction réduit de façon significative les variations (d'un facteur 3 environ), offrant ainsi un équilibrage colorimétrique acceptable.

2.3.4.2 Evaluation en conditions cliniques

Les résultats obtenus lors des tests expérimentaux en laboratoire ont permis de valider cette méthode de correction, et les mires ont été diffusées aux partenaires médicaux pour réaliser des prises de vues sur des plaies. Dès l'arrivée d'une première série d'images, nous avons voulu évaluer la performance de notre méthode sur ces images prises en conditions cliniques (conditions d'éclairage inconnues, différents APN). La Figure 2.15 montre les résultats obtenus sur 26 plaies. Deux vues stéréoscopiques ont été prises pour chaque plaie, soit une base de 52 images.

La correction permet de réduire les écarts colorimétriques moyens $\overline{\Delta E_{ab}}$ de 20.5 ± 7.1 à 4.55 ± 1.14 sur l'ensemble des images. Notons aussi que les écarts dus aux changements de points de vue entre les deux images stéréo de la même plaie sont ramenés de 8.14 ± 0.85 à 3.55 ± 0.69 . La correction colorimétrique favorise donc aussi la mise en correspondance entre les vues stéréoscopiques.

Le bénéfice de la correction sur les résultats d'une segmentation en régions est visible sur la Figure 2.16. Le Chapitre 3 en donnera une évaluation quantitative en sortie de la chaîne de traitements d'après les résultats de classification des régions.

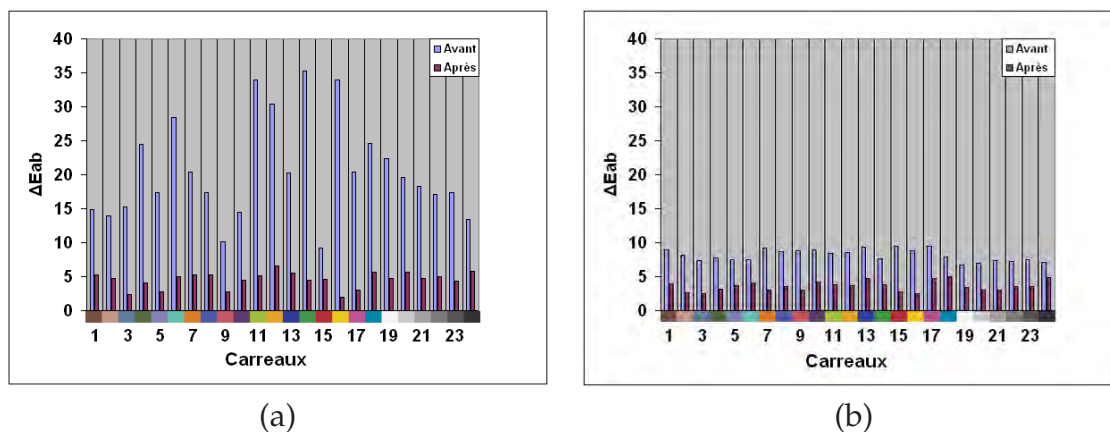


Figure 2.15 – Erreurs $\overline{\Delta E_{ab}}$ mesurées sur les 24 carreaux de la mire avant et après correction (a) écarts aux valeurs de référence moyennés sur les 52 images (b) écarts entre les deux vues stéréo de la même plaie moyennés sur 26 paires d’images.




Figure 2.16 – Segmentations obtenues par l’algorithme JSEG avant (a et c) et après correction colorimétrique (b et d), avec le même réglage des paramètres.

2.3.4.3 Vers une mire couleur spécifique aux plaies chroniques

La mire couleur *Macbeth* utilisée est une mire générique destinée aux scènes où toutes les couleurs naturelles peuvent être présentes. Cependant une plaie chronique ne présente qu’un sous-ensemble assez réduit de teintes, dont les nuances ne sont pas

proposées dans cette mire (Figure 2.17); d'où l'idée de construire une mire couleur spécifique à notre application.




Figure 2.17 – Représentation des couleurs dans l'espace RGB (a) les 24 carreaux de la mire Macbeth, (b) les tonalités les plus fréquentes dans les plaies chroniques.

- Pour constituer une mire dédiée aux plaies, la stratégie suivante a été adoptée :
- après correction colorimétrique des 26 paires d'images assez représentatives des plaies chroniques (escarres, ulcères, etc.), les zones lésées ont été extraites sur chaque image par un tracé manuel
 - puis, une quantification couleur a été appliquée sur toutes les zones sélectionnées pour caractériser les couleurs dominantes.

Cette étape de quantification a été réalisée par l'Algorithme Lloyd Généralisé (GLA) dans l'espace $L^*u^*v^*$. Ce choix s'explique par le fait que c'est le prétraitement utilisé dans la méthode de segmentation adoptée plus loin (§2.4.5). Un exemple de quantification est illustré sur la Figure 2.18.




Figure 2.18 – Quantification couleur obtenue par l'algorithme GLA dans l'espace Lu^*v^* (a) image originale de la plaie (b) quantification (c) teintes des échantillons retenus.

Sur les 132 teintes extraites par GLA, 24 ont été finalement retenues en observant deux mesures : la fréquence de représentation et l'étendue du recouvrement des plaies initiales. Cette dernière mesure s'effectue par maximisation de ΔE_{uv} sur l'ensemble des échantillons. Au final, nous avons établi la nouvelle mire couleur,

constituée de 24 teintes caractéristiques des plaies chroniques. Cette sélection permet de conserver une mire de taille compacte tout en offrant une palette étendue des tonalités présentes dans les plaies chroniques (Figure 2.19).

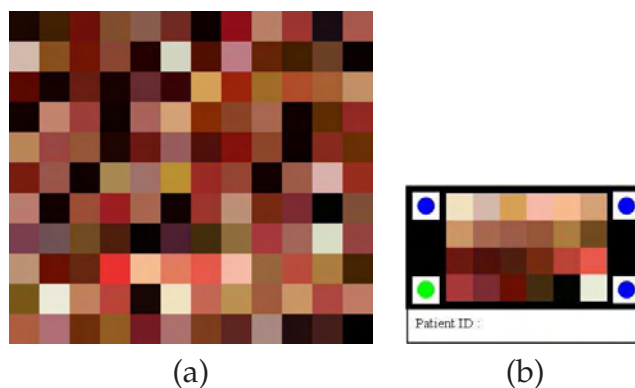


Figure 2.19 – Conception d'une mire spécifique aux plaies chroniques (a) palette des 132 teintes retenues par la quantification sur les 52 images de plaies (b) palette finale des 24 teintes intégrées à la mire.

Afin de valider la représentation des teintes sélectionnées dans l'espace uniforme $L^*u^*v^*$, on compare en Figure 2.20 la répartition dans cet espace couleur des carreaux de la mire spécifique à ceux de la mire *Macbeth*. Dans cette représentation tridimensionnelle, le cube de couleurs RGB ainsi que l'observateur standard CIE₃₁ (en ligne blanche) sont toujours présents sur le graphe. Quelques exemplaires de cette mire spécifique sont en cours d'évaluation dans les centres cliniques.

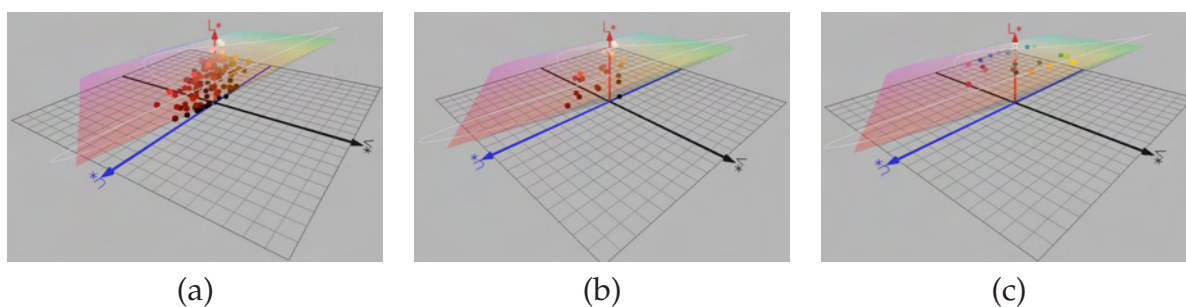


Figure 2.20 – Représentation des teintes dans l'espace $L^*u^*v^*$ (a) les 132 teintes sélectionnées par GLA (b) les 24 carreaux de la mire spécifique (c) les 24 carreaux de la mire Macbeth.

L'étape de correction colorimétrique s'est révélée indispensable pour s'affranchir des variations d'éclairage et de points de vue, et des disparités de rendu couleur entre les APN. Cette procédure est nécessaire pour garantir la robustesse du reste de la chaîne de traitements incluant la segmentation puis la classification des régions couleur.

2.4 Segmentation en régions de couleurs homogènes

La segmentation couleur consiste à partitionner une image en régions, c'est-à-dire en ensembles de pixels à la fois connexes et ressemblants au sens colorimétrique. Elle est souvent réalisée avant les étapes d'interprétation de l'image et de prise de décision, telle que la reconnaissance des objets ou la classification. Les nombreuses techniques de segmentation existantes se différencient par les critères d'homogénéité utilisés. Elles sont couramment regroupées en trois principales catégories [Skarbek & Koschan, 1994] :

- segmentation basée pixels
- segmentation basée régions
- segmentation basée contours

Dans la première catégorie, seules les informations des pixels (comme la couleur, le niveau de gris) sont considérées de façon isolée sans notion de connexité ou de voisinage. On trouve dans cette catégorie, les méthodes de seuillage, de clustering d'histogrammes (K-means, fuzzy C-means, etc.) [Pappas, 1992],[Malik et al., 2001]. Ces méthodes reposent sur l'hypothèse selon laquelle les pixels d'une même région forment soit un nuage de points dans un espace colorimétrique, soit un mode dans un histogramme couleur. Les classes de couleurs constituées sont ensuite reportées sur l'image. La segmentation est alors implicite puisqu'on suppose que chaque classe correspond à une région dans l'image sans vérifier les propriétés d'adjacence des pixels.

La segmentation par régions assigne un label ou une étiquette à un ensemble de pixels connexes présentant des caractéristiques homogènes proches. Nous retrouvons dans cette catégorie la segmentation basée sur la croissance de régions et les méthodes par *division-fusion*. La croissance de régions débute à partir de germes dans l'image que l'on propage aux pixels voisins de teintes ressemblantes. On agglomère ainsi les pixels de proche en proche, jusqu'à ce qu'aucun regroupement ne soit plus possible. Les méthodes dites de *division* partent de l'image entière que l'on va découper récursivement en plus petites régions tant que ces régions ne sont pas suffisamment homogènes. Une approche duale de *fusion* part d'un ensemble de petites régions homogènes qui sont récursivement regroupées sous des conditions de proximité spatiale (adjacence) et d'homogénéité. Les méthodes dites de *division-fusion* sont un mélange de ces deux approches.

La troisième catégorie correspond à une approche duale qui cherche à détecter une transition (ou contour) entre deux régions connexes. Les détecteurs de contours peuvent être simples, comme les opérateurs de Sobel ou de Roberts, ou plus complexes tel que l'opérateur de Canny. La segmentation par approche contour peut être faite à partir de l'image de gradient, du laplacien par détection des contours ou par application d'un contour déformable initialisé automatiquement ou manuellement, [Chesnaud et al., 1999], [Fan et al., 2001].

Dans le contexte de ces travaux de thèse, notre choix est d'appliquer une méthode de segmentation non supervisée en régions de couleur homogène pour simplifier le processus ultérieur de classification des tissus.

Étant donné que l'escarre est un mélange non uniforme de trois types de tissus et que la distinction entre tissus est souvent très délicate, l'approche de segmentation basée sur le contour a déjà été écartée. Notons qu'une approche par contours actifs a été appliquée pour l'extraction de la zone lésée dans l'image plutôt que de segmenter en différents types de tissus [Plassmann & Jones, 2003]. Si la segmentation basée sur les pixels permet bien l'extraction de plusieurs classes par multiseuillage, elle néglige totalement la connexité des pixels. Ces algorithmes ont l'avantage d'être simples mais leur application aux images d'escarres a montré des capacités très limitées pour partitionner les classes de tissus correctement ([Mekkes & Westerhof, 1995], [Kolesnik & Fexa, 2004]). Il semble en effet plus judicieux d'établir la classification sur des régions plutôt que sur les pixels car les régions homogènes permettent le calcul de descripteurs à la fois plus discriminants et plus robustes, en s'affranchissant du bruit et de la disparité colorimétrique rencontrés au niveau des pixels.

Nous avons d'abord sélectionné quatre méthodes de segmentation non supervisées connues pour leur efficacité sur des images couleur texturées : l'approche basée sur la théorie des graphes EGBIS (Efficient Graph-Based Image Segmentation) [Felzenszwalb & Huttenlocher, 2004], l'algorithme Mean Shift [Comaniciu & Meer, 2002], l'algorithme Color Structure Code (CSC) [Priese & Rehrmann, 1998] et l'algorithme JSEG [Deng & Manjunath., 2001]. Avant de comparer leurs performances sur nos images d'escarres, nous introduisons brièvement ces algorithmes en décrivant leur principe de fonctionnement.

2.4.1 Algorithme Color Structure Code (CSC)

Il s'agit d'un algorithme de type *merge and split*, particulièrement efficace et robuste. L'une des propriétés de cet algorithme est d'être complètement parallélisable et de ne pas dépendre du sens de balayage de l'image.

L'algorithme CSC [Priese & Rehrmann, 1993], repose sur une topologie hiérarchique hexagonale de l'image. La structure hiérarchique est constituée d'îlots hexagonaux disposés à différents niveaux. Un ensemble de 7 pixels forme un îlot de niveau 0, 7 îlots de niveau 0 forment un îlot de niveau 1, etc. De façon recursive, un îlot de niveau $n + 1$ est constitué de 7 îlots de niveau n disposés hexagonalement jusqu'à ce qu'un îlot recouvre toute l'image (Figure 2.21).

Dans la phase d'initialisation, un simple algorithme de croissance de régions est appliqué localement et en parallèle dans chaque îlot de niveau 0, constituant des *éléments*. Ensuite, les éléments de niveau n sont regroupés en éléments de niveau $n + 1$ de manière recursive selon un critère de distance efficace. Cependant, une étape de découpage a lieu simultanément à l'étape de fusion, afin de vérifier que l'on n'agglo-




Figure 2.21 – Structure hiérarchique hexagonale du CSC

mère pas des îlots de couleurs localement proches mais variant de façon importante à plus grande échelle (comme un dégradé par exemple). L'analyse au niveau n est une analyse globale des propriétés colorimétriques des éléments de niveau $n - 1$. Grâce à ce traitement, des régions de couleurs différentes ne seront pas connectées lorsqu'une longue chaîne de pixels relie la première région à deuxième.

Pour améliorer les performances de la segmentation, l'algorithme CSC utilise un filtre *SNN* (*Symmetric Nearest Neighbor*), qui atténue le bruit [Pietikainen & Harwood, 1986]. Le fonctionnement du filtre *SNN* est simple : chaque pixel est examiné dans son voisinage hexagonal, en calculant la valeur moyenne des trois paires de pixels symétriques autour du pixel central dans l'îlot. Pour chacune des trois paires de voisins, on conserve la valeur la plus proche du pixel central et on moyenne ensuite les 4 valeurs. Pour nos tests, nous avons utilisé une version développée par Patrick Sturm de la méthode proposée dans [Priese & Rehrmann, 1998], permettant de choisir l'espace couleur (RGB ou HSV)¹⁶.

2.4.2 Méthode à base de graphes (EGBIS)

Les images segmentées peuvent être décrites par un graphe d'adjacence entre régions, les noeuds représentent les régions et les arcs les relations entre régions. L'algorithme EGBIS est une méthode de partitionnement de graphes [Felzenszwalb & Huttenlocher, 2004].

Soit $G = \{V, E\}$, où V désigne la liste des noeuds et E la liste des arêtes du graphe, un graphe non orienté de l'image, les éléments de V sont les pixels dans l'image. Chaque arête $e \in E$ connecte une paire de pixels voisins, pondérée par un poids $w(e)$ mesurant la similarité entre deux sommets adjacents. Le but de l'algorithme est de fournir une partition $S = C_1, C_2, \dots, C_k$ de G , où chaque composante $C_i = 1, \dots, k$ est un Arbre de Poids Minimum Recouvrant (APMR) un ensemble de pixels connexes sur l'image. Chaque composante est donc représentée par sa variation interne $Int(C_i)$, c'est-à-dire par le poids $w(e)$ le plus grand de C_i dans l'arbre des

¹⁶http://www.uni-koblenz.de/~lb/lb_research/research.csc.html

composantes :

$$Int(C_i) = \sum_{e \in APMR(C_i, E)} w(e) \quad (2.12)$$

Deux composantes se comparent par leur variation externe $Ext(C_i, C_j)$, correspondant au poids minimum des arêtes reliant C_i et C_j . La partition voulue est obtenue sur la base de l'algorithme de Kruskal [Cormen et al., 1990], en construisant un arbre recouvrant de poids minimum du graphe. Au départ $S = C_1, C_2, \dots, C_{|V|}$, car aucun sommet n'est connecté. On ajoute ensuite les arêtes par ordre de poids croissant, en évitant les cycles. Un critère d'arrêt $D(C_i, C_j)$ permet de limiter la croissance des régions :

$$D(C_i, C_j) = \begin{cases} 1 & \text{si } Ext(C_i, C_j) > \min(Int(C_i) + \tau_i, Int(C_j) + \tau_j) \\ 0 & \text{sinon} \end{cases} \quad (2.13)$$

Le seuil τ_i sert à pénaliser le regroupement des grandes régions. Sa valeur diminue avec la taille de la région i car il est défini par : $\tau_i = k/|C_i|$, où k est une constante et $|C_i|$ le nombre d'éléments de C_i .

Le critère d'homogénéité utilisé dans l'algorithme EGBIS est le suivant : Soient a_1, a_2 les arêtes de poids maximaux v_1, v_2 dans deux régions C_1, C_2 candidates à la fusion $a_{1,2}$ l'arête connectant les régions C_1 et C_2 et $v_{1,2}$ son poids :

$$P(C_1, C_2) = \begin{cases} \text{vrai} & \text{si } (v_{1,2} < v_1 + \frac{k}{|C_1|}) \text{ et } (v_{1,2} < v_2 + \frac{k}{|C_2|}) \\ \text{faux} & \text{sinon} \end{cases} \quad (2.14)$$

La constante positive k permet de régler la finesse de la segmentation, les auteurs conseillant d'utiliser la valeur $k = 300$. Ce prédicat est appliqué sur les arêtes dans l'ordre de poids croissant. La principale propriété de cet algorithme est de respecter un critère de bonne segmentation grâce au prédicat 2.14, en évitant qu'elle ne soit ni trop fine ou ni trop grossière. L'algorithme présente l'avantage d'être générique et d'être indépendant de la structure de graphe utilisée. L'algorithme EGBIS a été développé dans l'espace couleur RGB après un filtrage gaussien de l'image [Felzenszwalb & Huttenlocher, 2004].

2.4.3 Algorithme Mean Shift

La méthode Mean Shift est un estimateur du gradient de densité non paramétrique [Fukunaga & Hostetler, 1975] exploité récemment pour le traitement d'image [Comaniciu & Meer, 2002]. Ce cadre est intéressant car il prend simultanément en compte des informations spatiales (position des pixels) et d'amplitude (niveau de gris, couleur ou information spectrale). L'algorithme a l'avantage de ne reposer sur aucun a priori de la distribution des intensités des pixels. Introduisons d'abord le concept du filtrage Mean Shift avant de présenter la segmentation associée.

2.4.3.1 Filtrage Mean Shift

Soit un échantillon de n points $\{x_1, x_2, \dots, x_n\}$ dans un espace euclidien \mathbb{R}^d de dimension d . Ces n points sont répartis dans l'espace suivant une certaine distribution de probabilité. En tout point $x \in \mathbb{R}^d$, la densité de la distribution des échantillons est estimée par la fonction :

$$\hat{f}_k(x) = \frac{1}{nh^d} \sum_{i=1}^n K\left(\frac{x - x_i}{h}\right) \quad (2.15)$$

avec h le rayon constant et K une fonction scalaire. En pratique, on utilise souvent le noyau d'Epanechnikov défini par :

$$K_E(x) = \begin{cases} \frac{1}{2}c_d^{-1}(d+2)(1 - \|x\|^2) & \text{si } \|x\|^2 < 1 \\ 0 & \text{sinon} \end{cases} \quad (2.16)$$

où c_d désigne le volume de la sphère unité dans \mathbb{R}^d .

La procédure Mean Shift consiste à rechercher les zones de forte densité dans l'espace. Pour ce faire, on calcule le gradient de l'estimation de densité :

$$\nabla \hat{f}_{Kg}(x) = \frac{n_x}{nh^d c_d} \frac{d+2}{h^2} \left[\frac{1}{n_x} \sum_{x_i \in S_h(x)} (x - x_i) \right] \quad (2.17)$$

où $S_h(x)$ désigne l'hypersphère de dimension d , de rayon h , de volume $h^d c_d$, contenant n_x points et centrée en x . $S_h(x)$ est appelé *noyau uniforme*. Si l'on utilise les notations suivantes :

$$M_h(x) = \left[\frac{1}{n_x} \sum_{x_i \in S_h(x)} x_i \right] - x \quad (2.18)$$

$$f_u(x) = \frac{n_x}{nh^d c_d} \quad (2.19)$$

on a :

$$M_h(x) = \frac{h^2}{d+2} \frac{\nabla \hat{f}_E(x)}{f_U(x)} \quad (2.20)$$

La quantité $M_h(x)$ est appelée vecteur Mean Shift et la quantité $f_u(x)$ définit l'estimation de densité avec le noyau uniforme de rayon h . On peut ainsi remarquer que l'estimation du gradient de la densité au point x peut être calculée à partir de l'échantillon Mean Shift utilisant un noyau uniforme centré en x . Le vecteur Mean Shift $M_h(x)$ a la direction du gradient de l'estimation de la densité en x , lorsque cette estimation utilise le noyau d'Epanechnikov. Ainsi, en translatant de façon itérative un point x de l'espace de la quantité $M_h(x)$, le point x définit un chemin convergent vers une densité maximum.

A partir de cette propriété, on en déduit la procédure Mean Shift comprenant les étapes suivantes :

- i) sélection aléatoire de n points $\{y_1, y_2, \dots, y_n\}$ dans l'espace R^d
- ii) calcul du vecteur Mean Shift $M_h(y_i)$ pour chaque point $y_i, i = 1, \dots, n$
- iii) translation de chaque point y_i par la quantité $M_h(y_i)$
- iv) retour au point ii)

On obtient une procédure itérative simple qui converge obligatoirement vers les points de plus forte densité.

2.4.3.2 Segmentation Mean Shift

Dans le cas de la segmentation, l'image est considérée comme un treillis bi-dimensionnel de pixels. Chaque point x_i est décrit par cinq coordonnées spatio-chromatiques : deux coordonnées spatiales et trois valeurs chromatiques dans les plans RGB de l'image. Les régions sont constituées en regroupant les données filtrées (points de convergence) dont la distance euclidienne n'excède pas un seuil fixé. Pour séparer correctement les différentes régions et ainsi améliorer la segmentation, le filtrage Mean Shift peut être itéré de manière à accentuer son effet avant cette étape de fusion. A chaque itération, une image est construite en affectant à chaque pixel les composantes d'amplitude des points de convergence.

La version testée sur notre base d'images est une adaptation à l'espace $L^*a^*b^*$ développé par Georgescu and Christoudias pour le système EDISON (Edge Detection and Image SegmentatiON)¹⁷.

2.4.4 Algorithme JSEG

La méthode de segmentation JSEG a été développée par [Deng & Manjunath., 2001]. L'idée de base est de séparer le processus de segmentation en deux étapes : une quantification couleur suivie d'une segmentation spatiale.

2.4.4.1 Quantification couleur

Cette étape consiste à limiter le nombre de couleurs présentes dans l'image. En effet, une image codée sur 24 bits peut contenir des milliers de couleurs, difficiles à gérer lors de l'étape de segmentation. La quantification permet de réduire ce nombre à quelques tonalités dominantes pour conserver une bonne représentation des images naturelles. La quantification ne tient pas compte de la répartition spatiale des couleurs.

¹⁷<http://www.caip.rutgers.edu/riul/research/code/EDISON/index.html>.

Dans un premier temps, un filtrage par un algorithme non linéaire nommé PGF (*Peer Group Filtering*) est appliqué pour lisser l'image et réduire le bruit [Deng et al., 1999]. L'algorithme remplace chaque pixel dans l'image par la somme pondérée de ses voisins en privilégiant ceux qui sont de couleur proche. Les paramètres statistiques locaux sont employés comme des poids : les zones texturées sont affectées de poids plus faibles et les zones lisses de poids plus grands.

Un Algorithme de Lloyd Généralisé (GLA), similaire à celui des K-Means, est utilisé pour quantifier les couleurs dans l'espace perceptuel *CIELUV*. Les couleurs similaires, c'est à dire, d'écart colorimétrique inférieur à un seuil, sont regroupées et représentées par une seule et même couleur, ce qui réduit le nombre total d'étiquettes. L'image quantifiée est formée en assignant à chaque pixel l'étiquette qui correspond à sa couleur initiale.




Figure 2.22 – Quantification par l'algorithme GLA (a) image originale (b) image quantifiée (c) palette de couleurs réduite.

2.4.4.2 Segmentation spatiale de l'image quantifiée

La segmentation spatiale est effectuée sur l'image quantifiée en considérant la répartition des étiquettes. L'algorithme JSEG utilise un critère d'homogénéité s'inspirant du discriminant de Fisher [Duda & Hart, 1970] :

soient P l'image quantifiée en C classes P_i avec $i = 1, \dots, C$, $p = (x, y) \in P$ un pixel donné, g le centre de gravité des pixels de P , et g_i les centres de gravité des pixels de chaque classe P_i . Le critère de segmentation est défini par l'expression suivante :

$$J = \frac{S_T - S_W}{S_W} = \frac{S_B}{S_W} \quad (2.21)$$

où S_T et S_W sont définis par :

$$S_T = \sum_{p \in P} \|p - g\|^2 \quad (2.22)$$

$$S_W = \sum_{i=1}^C \sum_{p \in P_i} \|p - g_i\|^2 \quad (2.23)$$

S_W mesure les dispersions spatiales des pixels qui portent la même étiquette. J confronte les dispersions inter et intra classes. Dans le cas d'une image composée de plusieurs régions de couleur homogène, la valeur de J est élevée, alors que si les classes sont uniformément distribuées dans l'image, elle tend à être faible, (Figure 2.23).

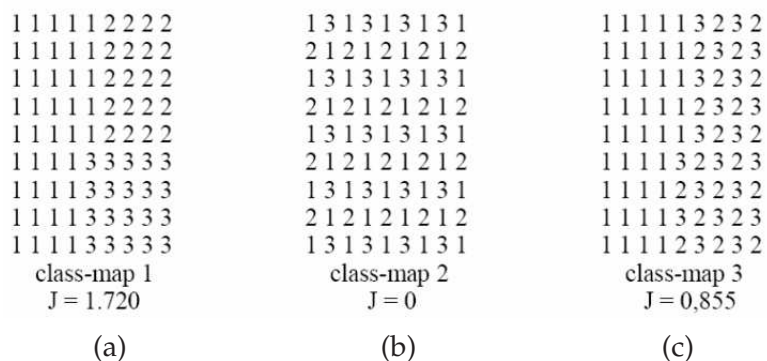


Figure 2.23 – Valeurs de J selon différentes répartitions des étiquettes dans l'image quantifiée (a) image composée de 3 régions homogènes (b) une seule région texturée, (c) 2 régions.

Ce critère J est calculé dans un voisinage restreint autour de chaque pixel pour générer une J -image : une valeur J est affectée à chaque pixel. Ainsi, une valeur J est attribuée à chaque pixel. Les valeurs les plus faibles sont au centre des régions homogènes, alors que les plus élevées dessinent les frontières des régions. Une méthode de croissance de régions appliquée à la J -image permet d'obtenir la segmentation de l'image originale. (Figure 2.24).




Figure 2.24 – Segmentation JSEG. (a) image originale (b-d) résultats de segmentation à différentes étapes de la croissance de régions dans la J -image.

Une étape de fusion est ensuite appliquée pour éviter une sur-segmentation.

Les régions adjacentes sont fusionnées en fonction de leur similitude de couleur déterminée par le calcul d'une distance dans l'espace couleur uniforme *CIELUV*. Le processus se poursuit jusqu'à ce qu'un seuil maximal de distance couleur soit atteint entre deux régions adjacentes.

La paragraphe suivant présente une comparaison des performances de ces quatre méthodes de segmentation sur notre base d'images d'escarres.

2.4.5 Comparaison des méthodes sur les images d'escarres

Elle a pour l'objectif de sélectionner la méthode préparant au mieux l'étape de classification. Après la première étape de réglage des paramètres, on discutera du critère d'évaluation utilisé pour comparer les résultats de segmentation automatique aux labellisations des experts (§2.2.2).

2.4.5.1 Réglage des paramètres

Ce réglage a été réalisé de manière empirique pour optimiser globalement les résultats de segmentation sur une base d'images. L'objectif est d'adopter un seul et même réglage sur toute la base d'images pour chaque algorithme. L'ajustement des paramètres a été fait par simple comparaison visuelle, en veillant à éviter une sous-segmentation qui conduisait à des erreurs de classification sur des régions incluant plusieurs classes tissulaires. Cependant, un trop grand nombre de régions alourdit les traitements ultérieurs et pose des problèmes de classification liés à la taille critique des régions de petite taille. Il faut donc trouver un bon compromis : éviter une sous-segmentation de l'image et conserver un nombre raisonnable de régions segmentées.

Algorithme CSC

Le nombre de paramètres à régler dans l'algorithme CSC dépend de l'espace couleur utilisé. Dans l'espace *RGB*, le seul paramètre à régler est le seuil S_d de la distance euclidienne minimale qui détermine la similarité entre deux couleurs. Plus cette distance est petite, plus l'image sera sur-segmentée. Dans l'espace *HSV*, l'algorithme CSC nécessite le réglage de trois seuils, S_H , S_S et S_V , un par plan. Chacun de ces seuils est choisi parmi 9 valeurs différentes dans la plage $[-4 + 4]$, et un bon réglage doit optimiser le jeu des trois paramètres. Plus les valeurs de seuil sont élevées, moins les nuances de couleurs sont discriminées et plus la segmentation est grossière. Idéalement pour disposer d'une segmentation d'image ignorant les variations dues à l'éclairage ou à la saturation, il suffit de régler le seuil de la teinte S_H pour des valeurs fixes de S_S et S_V (nulles en général).

Nous avons testé l'algorithme CSC sur notre base d'images avec les deux espaces couleur *RGB* et *HSV*. Malgré l'interprétation intuitive de l'espace *HSV*, les résultats de segmentation sont nettement moins bons que ceux obtenus avec l'espace *RGB* sur l'ensemble de la base, à quelques exceptions près. Des résultats de segmentation

obtenus avec plusieurs jeu de paramètres sont présentés dans la Figure 2.25 pour l'espace HSV et dans la Figure 2.26 pour l'espace RGB . Au vu des résultats observés, nous avons choisi l'espace RGB et le seuil S_d a été réglé à 25.




Figure 2.25 – Segmentations obtenues par CSC dans l'espace couleur HSV avec différents réglages (a) image originale (b) $S_H = S_S = S_V = -4$ (c) $S_H = S_V = 0, S_S = -4$ (d) $S_H = S_S = 0$. Le nombre des régions est respectivement de 460, 375 et 130.

Algorithme EGBIS

L'algorithme EGBIS nécessite le réglage de trois paramètres : σ , k et min . Le paramètre σ est l'écart type du filtre gaussien utilisé avant la segmentation. Le paramètre k est impliqué dans les seuils adaptatifs (équation 2.14). Le paramètre min est la taille minimale des régions. Si la région candidate à la fusion a une taille inférieure à min , elle sera fusionnée avec une région voisine candidate à la fusion. La Figure 2.27 illustre trois segmentations de la même image avec trois réglages différents des paramètres. Un bon compromis entre le niveau de sur-segmentation et la taille minimum des régions segmentées a été observé pour $\sigma = 0.5$, $k = 200$, $min = 100$.

Algorithme Mean Shift

Le système EDISON nécessite le réglage de trois paramètres. Les deux premiers r et h caractérisent le noyau K : r est la taille de la fenêtre de recherche dans l'image pour le calcul du vecteur Mean Shift et h le rayon utilisé lors du calcul du gradient de densité. Le paramètre r est d'ordre spatial alors que h est d'ordre chromatique. Le troisième paramètre Reg fixe le nombre minimum de pixels dans une région lors de




Figure 2.26 – Segmentations obtenues par CSC dans l'espace couleur RGB avec différents réglages (a) image originale (b) $S_d = 15$ (c) $S_d = 25$ (d) $S_d = 35$. Le nombre de régions est respectivement de 861, 401 et 190.

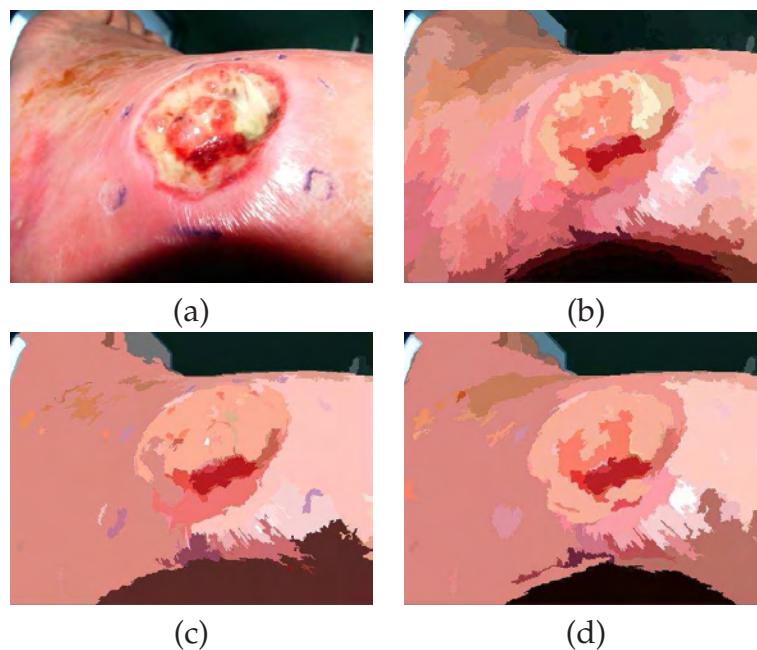


Figure 2.27 – Segmentations obtenues par EGBIS avec différents réglages (a) image originale (b) $\sigma = 0.2, k = 300$ et $min = 100$ (c) $\sigma = 0.5, k = 300$ et $min = 50$ (d) $\sigma = 0.5, k = 200$ et $min = 100$. Le nombre de régions est respectivement de 160, 104 et 69.

l'étape de fusion (Figure 2.28).




Figure 2.28 – Segmentations obtenues par Mean Shift avec différents réglages (a) image originale (b) $r = 4, h = 6.5$ et $Reg = 50$ (c) $r = 8, h = 6.5$ et $Reg = 100$ (d) $r = 8, h = 10$ et $Reg = 100$. Le nombre de régions est respectivement de 418, 264 et 144.

Algorithme JSEG

L'algorithme JSEG est piloté par deux paramètres. Le premier est le seuil d'homogénéité m de fusion entre deux régions adjacentes ($0.0 \leq m \leq 1.0$). Le second est le seuil de quantification q ($0 \leq q \leq 600$) précise le nombre maximal de classes de couleurs. On peut éventuellement préciser le nombre l d'échelles de segmentation pour une meilleure extraction de la texture, mais en réglant le seuil d'homogénéité m à zéro, l'algorithme ne modifiera rien et les régions obtenues seront sur-segmentées. En réglant ce seuil à sa valeur maximum, les regroupements de régions seront rares, et cela conduit à une image sous-segmentée. Concernant le seuil de quantification q , plus sa valeur est grande, moins il reste de couleurs à l'issue de cette phase. Les résultats de segmentation d'une même image avec trois paramétrages différents sont donnés dans la Figure 2.29. Le meilleur compromis a été obtenu pour un seuil d'homogénéité à 0.2 et un seuil de quantification de 300.

Le tableau 2.5 récapitule les réglages adoptés pour les 4 algorithmes.

2.4.5.2 Critère d'évaluation

Il est impératif de s'assurer de la pertinence du découpage des régions obtenu par la segmentation non supervisée vis-à-vis des contours tissulaires identifiés par les experts. Pour cela, il suffit de confronter les régions extraites à la vérité terrain, en affectant à chaque région la classe de tissu majoritairement représentée dans la zone équivalente de la vérité terrain. Ensuite, l'accord entre cette labellisation semi automatique et la vérité terrain est évalué par le score de recouvrement, présenté




Figure 2.29 – Segmentations obtenues par JSEG avec différents réglages (a) image originale (b) $m = 0.2$, $q = 50$, (c) $m = 0.2$ et $q = 300$ (d) $m = 0.8$ et $q = 300$. Le nombre de régions est respectivement de 122, 80 et 31.

Méthodes	Espaces	Paramètres
CSC	RGB	$S_d = 25$
EGBIS	RGB	$\sigma = 0.5, k = 200, \min = 100$
Mean Shift	CIE $L^*a^*b^*$	$r=8, h=6.5, \text{Reg}=100$
JSEG	CIE $L^*u^*v^*$	$m=0.2, q=300$

Tableau 2.5 – Espaces colorimétriques et réglages adoptés pour les 4 méthodes de segmentation non supervisées sur la base d'images d'escarres.

dans les équations 2.1 et 2.2 du § 2.2.1. Ce score permet de calculer un pourcentage de similarité entre deux labellisations pour chaque tissu.

Notons que ces résultats dépendent du paramétrage des algorithmes, maintenu fixe sur toute la base d'images. En effet, de par le principe du vote majoritaire appliqué, la sur-segmentation favorise l'obtention de bons scores de recouvrement. Cependant, il est important de conserver des régions de taille suffisante pour un calcul statistiquement fiable et robuste des descripteurs.

2.4.5.3 Résultats

En se basant sur ce critère, les résultats de segmentation obtenus par les quatre algorithmes ont été comparés sur une base d'une cinquantaine images d'escarres de pathologies diverses, après correction colorimétrique. La Figure 2.30 montre des

exemples de segmentation réalisées par les quatre algorithmes sur une image d'es-carre typique, en comparant les résultats de labellisation semi automatique à la vérité terrain. Les scores de recouvrement sont présentés dans le Tableau 2.6.

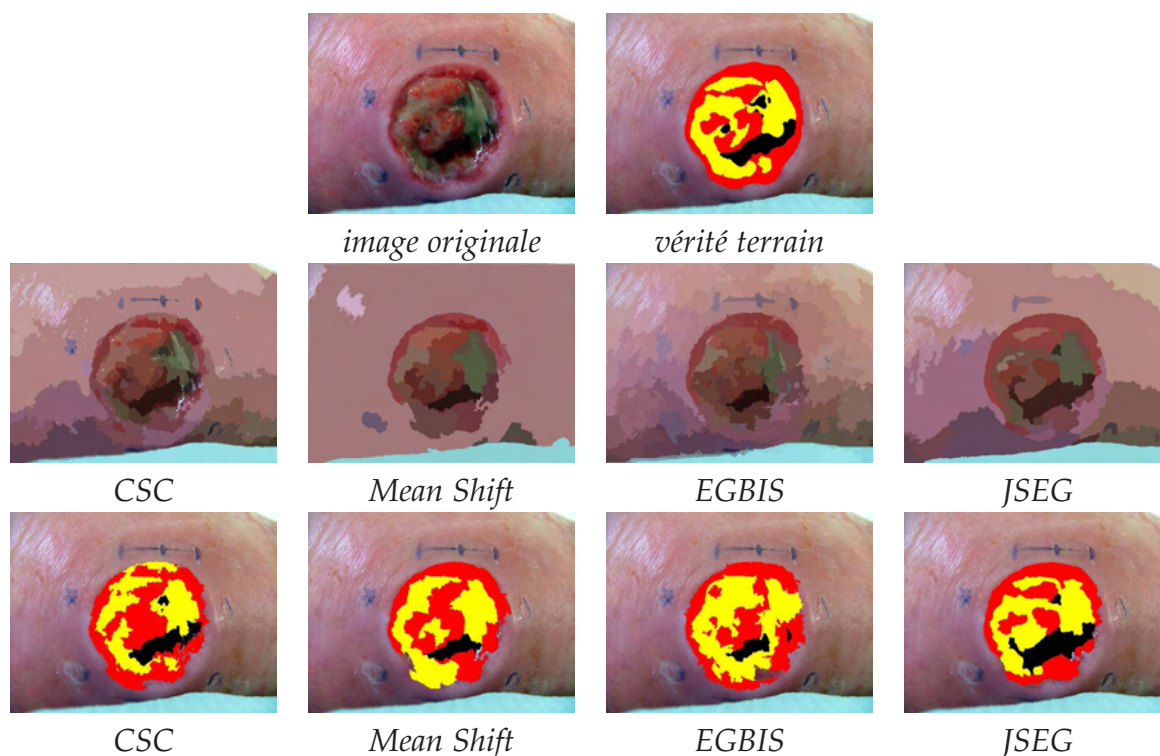


Figure 2.30 – Comparaison des algorithmes de segmentation. (1^{ère} ligne) image originale et verité terrain, (2^{ème} ligne) segmentations par des algorithmes (3^{ème} ligne) labellisations correspondantes.

Classe de tissu	Algorithme de segmentation			
	CSC	EGBIS	Mean Shift	JSEG
Bourgeon	72.4 %	60.2 %	79.2 %	80.2 %
Fibrine	56.4 %	61.6 %	67.8 %	68.1 %
Nécrose	64.9 %	62.1 %	70.7 %	71.1 %
Moyenne	64.6 %	61.3 %	72.6 %	73.1 %

Tableau 2.6 – Scores de recouvrement obtenus pour chaque algorithme.

Les scores élevés confirment qu’une étape de segmentation automatique est un pré-traitement opportun avant classification des régions. On constate que la segmentation JSEG garantit le meilleur taux de recouvrement (73.1% moyenné sur les trois types de tissu), suivi de Mean Shift. Cette évaluation a permis de sélectionner l’algorithme de segmentation le mieux adapté à notre application. Une validation supplémentaire de cette étape pourra se faire après la classification automatique.

2.5 Création de la base d'échantillons

La constitution d'une base d'échantillons d'apprentissage doit s'appuyer sur l'expertise clinique. La première méthode de labellisation manuelle proposait aux experts de dessiner sur écran à la souris les frontières des régions tissulaires sur une série d'images numériques d'escarres. Cependant, le caractère très fastidieux de cette méthode et les écarts sensibles constatés entre les experts nous ont orienté vers une seconde approche basée sur une segmentation automatique non supervisée. Dans cette nouvelle version, les experts disposent maintenant d'images, dans lesquelles les régions de couleur homogène sont pré-segmentées (Figure 2.4). Il ne leur reste plus qu'à désigner pour chacune d'elle la classe de tissu par un simple clic de souris. Un des avantages de la segmentation automatique est de respecter au mieux les propriétés chromatiques de l'image numérique dans la recherche des frontières, ce qui facilite l'extraction de descripteurs robustes et discriminants à l'intérieur des régions homogènes. Les échantillons extraits de cette façon serviront de base d'apprentissage et de test pour le classifieur.

2.6 Conclusion

Dans ce chapitre, nous avons présenté les différentes étapes de notre chaîne de pré-traitements appliqués à l'image avant la classification. Tout d'abord, une base d'images d'escarres a été constituée sur plusieurs sites hospitaliers. Par des labellisations manuelles d'experts, nous avons pu constituer une vérité terrain et évaluer la répétabilité intra et inter experts, qui donnent des indicateurs de référence pour évaluer la classification automatique. Ensuite, nous avons proposé une méthode de correction colorimétrique pour s'affranchir des variations d'éclairage et des écarts chromatiques entre les divers modèles d'APN. Les tests ont permis de vérifier que cette correction réussit à diminuer de façon significative les écarts de couleur. Finalement, quatre méthodes de segmentation en régions couleur ont été testées. La méthode JSEG est celle qui présente le meilleur score de recouvrement avec les labellisations des experts. Les résultats obtenus valident l'approche retenue d'une classification pilotée par la segmentation : les régions automatiquement segmentées présentent bien des frontières tissulaires proches de la vérité terrain issue des tracés experts. Ces régions vont servir directement de base d'apprentissage pour la classification qui fait l'objet du chapitre suivant.

Classification tissulaire mono-vue

Un processus de classification tissulaire se déroule en trois étapes : une étape de caractérisation des régions, une seconde étape de conditionnement des données extraites pour finir par une étape de labellisation par types de tissus. L'étape de caractérisation a pour but de créer un vecteur de descripteurs décrivant les régions pré-segmentées. La deuxième étape consiste à effectuer une analyse discriminante permettant de mieux préparer les données afin d'éviter leur redondance et de réduire leur dimensionalité. La troisième étape permet de séparer les différents groupes de vecteurs et d'associer chaque région à un type de tissu.

Sommaire

3.1	Introduction	68
3.2	Caractérisation des régions	68
3.2.1	Descripteurs de couleur	69
3.2.2	Descripteurs de texture	76
3.2.3	Récapitulatif des caractéristiques	82
3.3	Extraction/sélection de caractéristiques	84
3.3.1	Analyse discriminante linéaire (ADL)	85
3.3.2	Analyse en composantes principales (ACP)	86
3.3.3	Analyse en composantes indépendantes (ACI)	88
3.4	Classification des régions	89
3.4.1	Mesures de performance du classifieur	90
3.4.2	Séparateurs à vaste marge	91
3.4.3	Méthode des k plus proches voisins (k-ppv)	96
3.4.4	Méthode k-ppv floue (<i>Fuzzy k-ppv</i>)	97
3.4.5	Méthode des K-Means	98
3.5	Études expérimentales	99
3.5.1	Génération du vecteur de caractéristiques	99
3.5.2	Comparaison du SVM à d'autres classifieurs	100
3.5.3	Rééchantillonnage des données	101
3.5.4	Autres critères d'évaluation du système	103

3.5.5	Quantification de certaines influences sur la classification . . .	107
3.6	Conclusion	111

3.1 Introduction

Dans ce chapitre, nous présentons les différentes étapes du processus de classification appliqué sur les régions obtenues par segmentation dans le chapitre précédent. Afin de permettre une bonne représentation de ces régions, différents types de descripteurs de couleur et de texture vont être calculés sur la base d'échantillons étiquetés par quatre types de tissus grâce à une référence faite par des experts. La comparaison de ces descripteurs va permettre de sélectionner les meilleurs descripteurs de couleur et de texture, formant la combinaison finale de vecteurs de caractéristiques des régions.

Dans un dernier temps, nous abordons la phase de classification, où un classifieur SVM va être conçu pour labelliser les régions avec quatre types de tissus (bourgeon, fibrine, nécrose et peau saine). Avant cette étape, une analyse discriminante des données est mise en oeuvre dans le but est de conditionner les vecteurs de caractéristiques et de rendre la classification plus robuste. Nous avons appliqué trois approches d'analyse discriminante sur les vecteurs d'attributs afin d'extraire un sous-espace optimal améliorant l'apprentissage. Leurs effets ont été quantifiés à la sortie du classifieur SVM. Enfin, nous comparons notre approche de classification supervisée avec d'autres méthodes supervisées et non supervisées et nous réalisons une série d'évaluations des résultats obtenus sur notre base d'images d'escarres selon différents critères.

3.2 Caractérisation des régions

Les données extraites d'une image peuvent être de type et de nature différents et dépendent de l'application et du but recherché. Dans le cas de l'évaluation des plaies, les informations recherchées peuvent être divisées en deux types :

- des informations visuelles sur les couleurs spécifiques aux tissus (descripteurs de couleur)
- des informations sur les variations locales des couleurs des tissus (descripteurs de texture).

Les informations décrivant la forme de la zone tissulaire, sa taille, sa position ou toute information structurelle sur les plaies ne sont pas pertinentes à ce niveau, même si elles contribuent ensuite à la qualité du diagnostic final. Le calcul des surfaces tissulaires sera effectué à cet effet.

Notre problème de classification des régions pré-segmentées n'est pas très éloigné de celui de l'indexation. L'article [Smeulders et al., 2000] offre un aperçu des familles de descripteurs proposés. Pour identifier quelques descripteurs de couleur et

de texture pertinents dont certains ont été appliqués aux images de plaies chroniques, nous nous sommes intéressés à tester leurs performances sur notre application.

3.2.1 Descripteurs de couleur

Avant de coder le contenu visuel de l'image par des descripteurs de couleur, il convient de s'interroger sur le choix de la représentation préférable de l'image dans un des espaces couleur. Des nombreuses études dans le domaine du traitement de l'image numérique se sont spécialisés sur la présentation du contenu visuel dans un espace de couleur idéal [CIE, 1931], [Judd, 1930]. Ces espaces couleur ont pour objectif d'accentuer les caractéristiques visuelles des images, de souligner les ressemblances visuelles entre images, et de pallier certains défauts liés à l'acquisition des données, à la prise de vue, à l'éclairage, etc.

L'espace couleur est souvent choisi en fonction de l'application visée ([Vandenbroucke, 2000] [Busin et al., 2004] : le modèle YUV est utilisé dans les standards de diffusion télévisuelle PAL, NTSC, et SECAM; le modèle YCbCr s'intègre dans les domaines de la compression vidéo avec les standards MPEG-2 et MPEG-4; le modèle LUV est lié au monde de l'impression [Vandenbroucke & Macaire, 2000]. Dans le domaine de l'indexation d'images naturelles, les descripteurs de couleur sont souvent exprimés dans les espaces RGB, LUV et HSV, pour des facilités de calcul de la similarité visuelle. Les Figures 3.1 et 3.2 donnent des représentations des tissus cutanés des plaies dans les espaces couleur $L^*a^*b^*$ et RGB.

Les exemples précédents exprimés dans deux espaces couleur différents montrent, d'une part le mélange très important entre les trois classes de tissus (bourgeon, fibrine et nécrose) et d'autre part la diversité colorimétrique à l'intérieur d'une même classe dans deux images différentes. Cette inhomogénéité et cette diversité intra classe complique la tâche d'identification et de séparation des classes de tissus. En ce qui concerne l'espace de représentation des données, tous les analyses faites sur la représentation colorimétrique de tissus sont en faveur des espaces perceptuellement uniformes come $L^*a^*b^*$ ou $L^*u^*v^*$. Ces espaces présentent l'intérêt de reproduire plus fidèlement les variations perçues par un observateur humain.

Enfin, l'analyse de la couleur, contrairement à la texture, est fortement dépendante de l'espace de représentation des données. C'est pourquoi, dans notre chaîne de traitement, nous avons procédé à une phase de correction colorimétrique avant de caractériser le contenu tissulaire des images de plaies chroniques. Nous présentons ci-dessous les différents descripteurs qui ont été utilisés pour décrire les régions de tissus cutanés.

3.2.1.1 Moyenne des composantes

Le descripteur *Mean Color Descriptor* (MCD) représente la caractérisation la plus simple de la couleur, puisqu'il correspond aux valeurs moyennes de tous les pixels

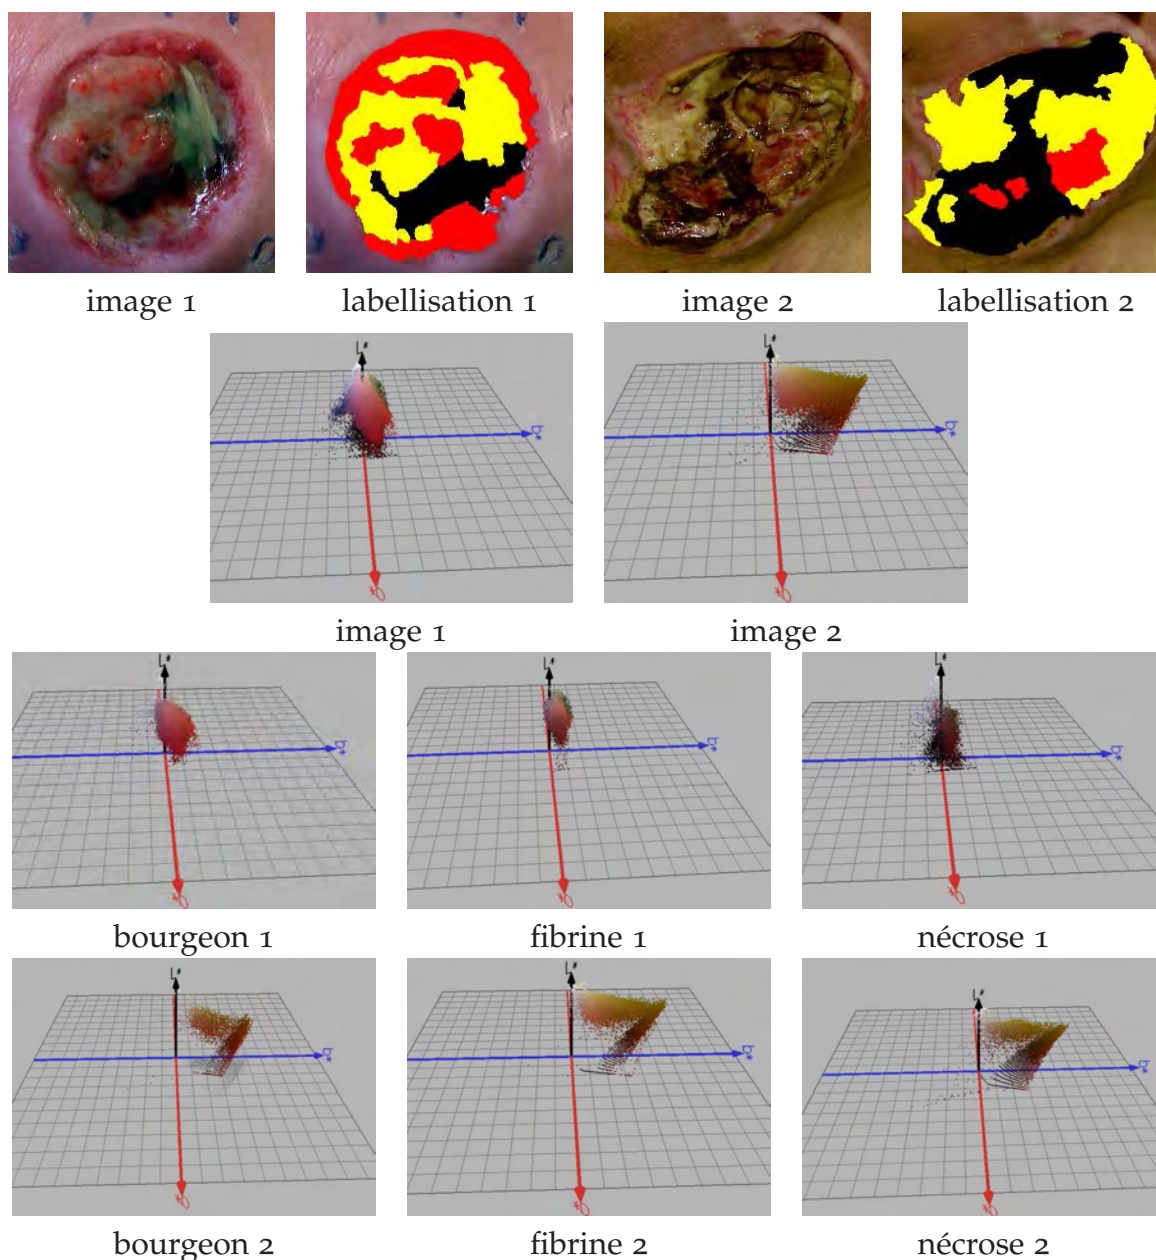


Figure 3.1 – Représentation tridimensionnelle de couleur des tissus dans l'espace $L^*a^*b^*$. (1^{ère} ligne) deux images de plaies et leurs étiquetages manuels des classes de tissus par experts (2^{ème} ligne) représentation des images dans l'espace $L^*a^*b^*$ (3^{ème} et 4^{ème} lignes) représentation des différentes classes de tissus.

dans une région dans chaque canal de l'espace de représentation de l'image. Dans [Huang et al., 1996], le MCD est calculé dans l'espace HSV et combiné avec d'autres descripteurs de couleur (histogramme classique HSV), des descripteurs de texture et de forme pour décrire les régions pré-segmentées par un algorithme de clustering *K-means*. L'espace couleur LUV a été utilisé dans SIMPLicity [Wang, 2000] et le MCD est calculé pour chaque région. Les moyennes des pixels de chaque région dans l'espace HSV ont aussi été exploité par FRIP [Ko et al., 2000]. Enfin, le MCD a été

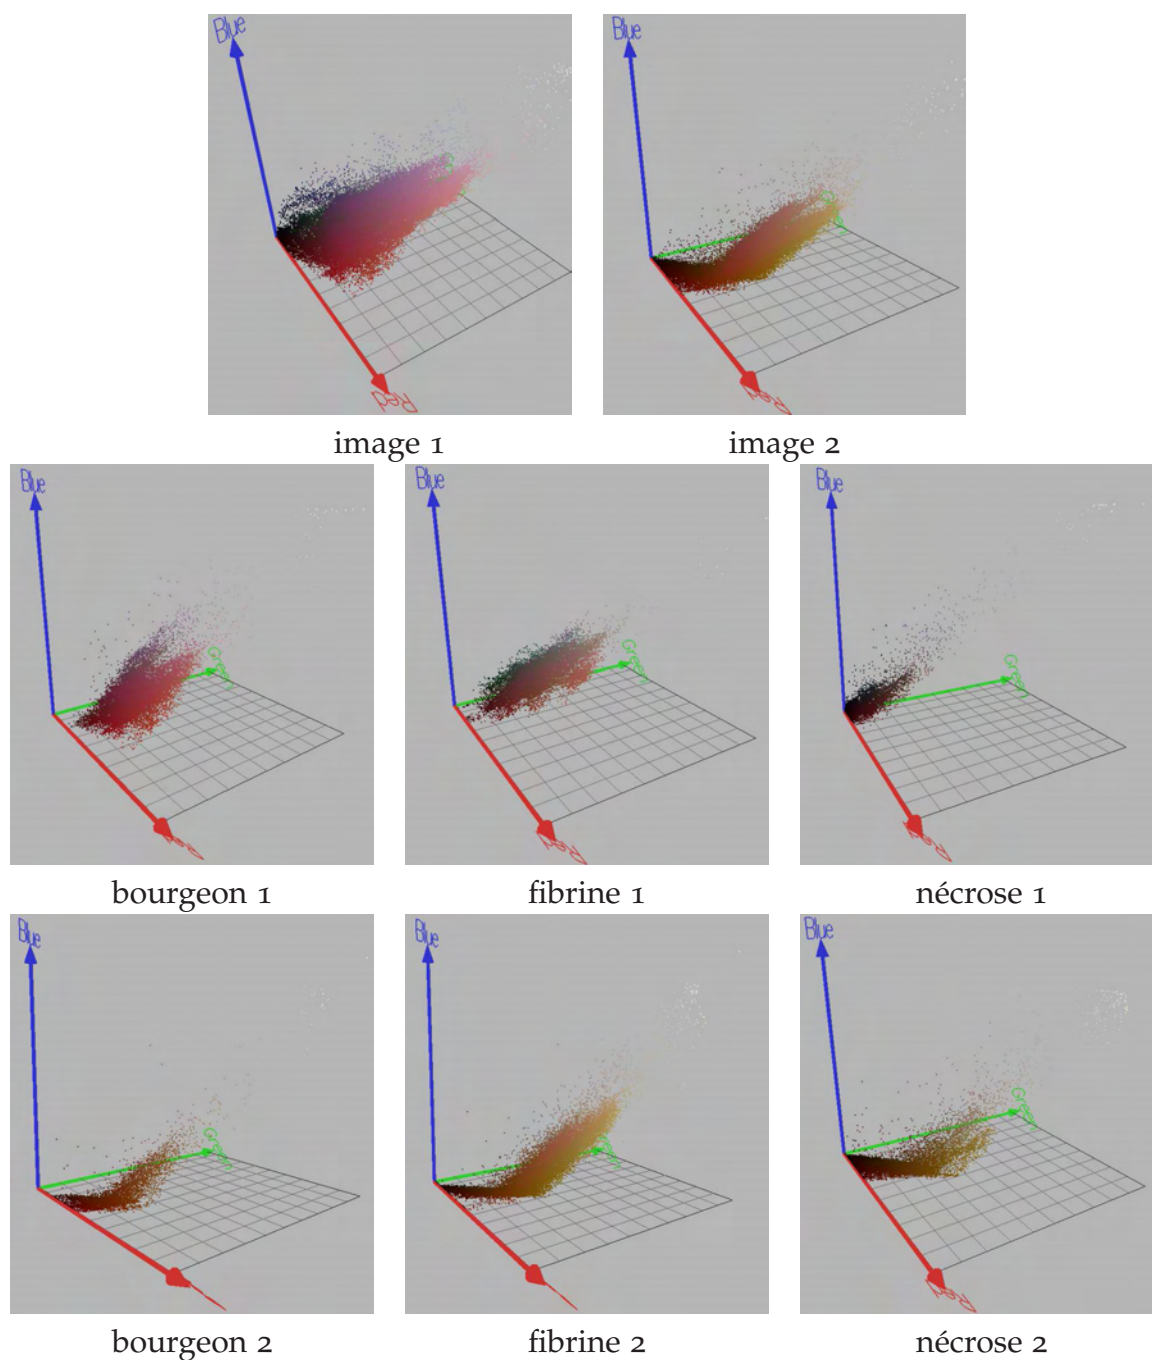


Figure 3.2 – Représentation tridimensionnelle de couleur des tissus dans l'espace RGB. (1^{ère} ligne) représentation des images dans l'espace RGB (2^{ème} et 3^{ème} lignes) représentation des différentes classes de tissus.

employée dans l'espace $L^*a^*b^*$ par [Kompatsiaris et al., 2001] et [Carson et al., 2002] pour décrire des régions pré-segmentées automatiquement.

Le MCD a été employé pour l'analyse d'images de plaies : dans les espaces RGB-normalisé et HSV [Herbin et al., 1990] [Herbin et al., 1993] dans les espaces

RGB et HSV pour quantifier les tissus de bourgeon et de fibrine dans l'image [Perez et al., 2001]. Le MCD des trois espaces couleur RGB, Lu^*v^* et Lc^*h^* a aussi été calculé dans des zones sélectionnées manuellement pour quantifier la présence d'inflammation de zones ulcéreuses [Belem, 2004]. Enfin, dans [Acha et al., 2003] et [Serrano et al., 2005] le MCD a aussi été employé dans les espaces Lu^*v^* et Lc^*h^* dans le but d'identifier les degrés des brûlures.

La caractérisation des régions par leur MCD peut se justifier sur des régions homogènes en couleur. Des régions de petite taille (cas d'une sur-segmentation) peuvent garantir cette homogénéité, mais pour des régions plus grandes, le MCD devra être combiné avec d'autres descripteurs.

3.2.1.2 Histogramme couleur

L'histogramme couleur reste la référence des descripteurs couleur utilisés aujourd'hui grâce à sa quantification systématique de l'information couleur. L'histogramme de l'image couleur fait référence à la probabilité conjointe des trois canaux de couleur. Il est défini par :

$$h_{A,B,C}(a, b, c) = N.Prob(A = a, B = b, C = c) \quad (3.1)$$

où A, B et C représentent les trois canaux couleur (R, G et B ou H, S et V, ...) et N est le nombre de pixels dans l'image.

Les descripteurs de régions les plus évolués reposent toujours sur ce type d'histogramme. Les premiers travaux en recherche d'images par le contenu basés sur l'histogramme couleur ont été présentés en 1991 par [Swain & Ballard, 1991]. La description des régions par l'histogramme RGB a été largement utilisée pour ses bonnes performances, soit dans sa version classique ou avec une quantification selon les trois composantes (Figure 3.3). Le principe de la quantification des histogrammes a inspiré de nombreux descripteurs : l'autocorrélogramme [Huang et al., 1997] qui représente le nombre d'occurrences de paires de pixels ayant des couleurs (quantifiées) données et à distance donnée ou le *color structure descriptor* [Messing et al., 2001] qui compte pour chaque couleur quantifiée le nombre d'éléments structurants dans un voisinage donné (8×8) contenant un pixel de cette couleur. Ce dernier descripteur, calculé dans l'espace couleur HMMD¹, a été incorporé dans la norme MPEG7.

Dans l'histogramme pondéré [Boujemaa & Vertan, 2000], on pondère la présence de chaque pixel dans la cellule couleur correspondante par une mesure caractéristique du voisinage du pixel. On peut citer aussi l'histogramme flou [Vertan & Boujemaa, 2000] comme une variante intéressante de l'histogramme couleur, dans lequel chaque pixel participe à toutes les cellules de l'histogramme classique avec une pondération correspondant à la similarité entre la couleur du pixel et celle

¹L'espace HMMD a été proposé par [Manjunath et al., 2001] H est la 1^{ère} composante de l'espace HSV, les MM font référence aux maxima et minima des valeurs R, G et B dans l'espace RGB et enfin D exprime la différence entre ces maxima et minima.

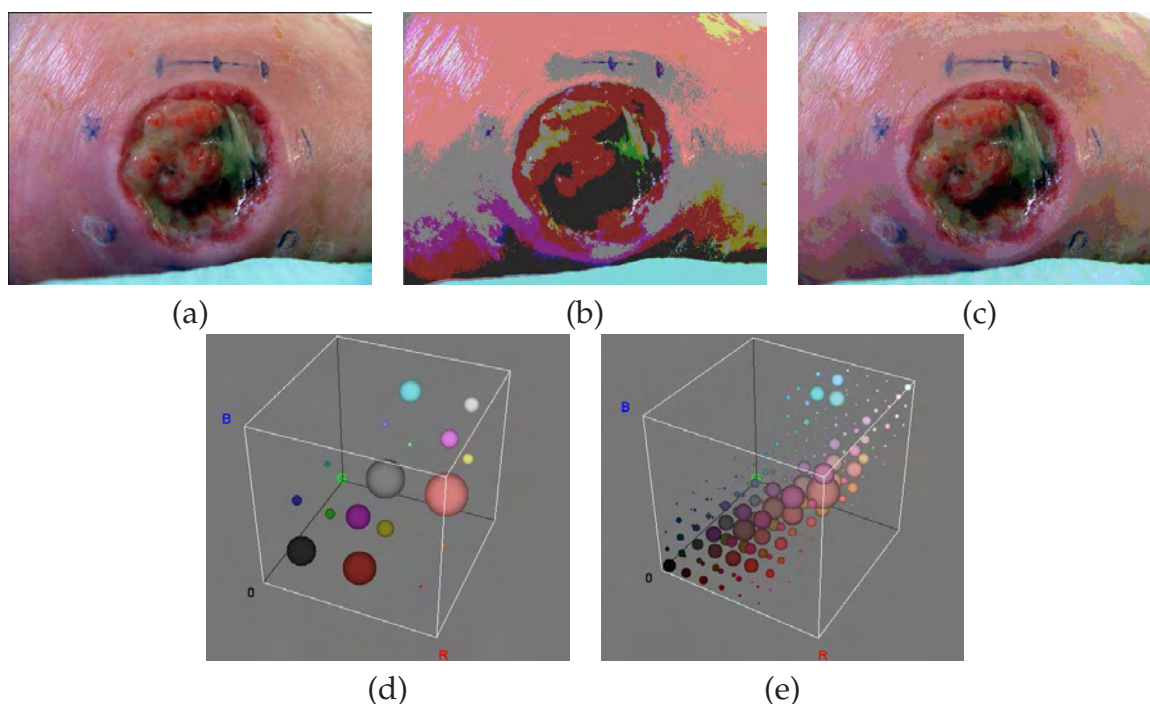


Figure 3.3 – Quantification systématique dans l'espace RGB. $255^3 = 16$ millions de couleurs quantifiées en 3^3 cellules (d) et 10^3 cellules. (a) image brute (b) image quantifiée sur 27 cellules (c) image quantifiée sur 1000 cellules (d-e) représentation correspondants dans le cube RGB.

de chaque cellule. On peut souligner que toutes ces variantes exploitent la distribution spatiale des pixels pour chaque couleur quantifiée de l'histogramme pour mieux décrire la région d'intérêt.

Le pouvoir de discrimination couleur de l'histogramme dépend du type d'histogramme et du mode de quantification, mais aussi de l'espace couleur de représentation. [Zhao & Grosky, 2000] démontrent que la représentation des régions par un histogramme HSV bidimensionnel 10×10 sur les composantes H et S améliore leur technique de recherche d'image sémantique. Un autre descripteur, dit *scalable color*, basé sur l'histogramme HSV multidimensionnel quantifié en 256 cellules (16 pour H, 4 pour S et 4 pour V) a été adopté dans la norme MPEG7. Ce descripteur n'est qu'un histogramme HSV encodé par la transformée de Haar avec une représentation binaire évolutive, en terme de nombre de cellules et du taux de représentation des cellules. Utilisé dans [Smith & Chang, 1996], le système VisualSeek caractérise les régions par un vecteur appelé *binary color set* qui peut être assimilable à un histogramme. Ce vecteur est en fait une quantification de l'histogramme 3-D HSV en 8 cellules soit 2 modalités pour chacune des composantes H, S et V). Dans [Kim & Han, 2000], les régions sont décrites par deux paramètres représentant la densité de couleur et la probabilité de co-occurrence d'une couleur. Ces deux paramètres sont dérivés d'un histogramme multidimensionnel 3D-RGB quantifié en 216 cellules ($6 \times 6 \times 6$). Dans le système Blobworld [Carson et al., 2002], les régions sont décrites par des histogrammes

concaténés avec une quantification systématique des espaces couleur considérés (166 cellules dans HSV et 218 dans La*b*^a).

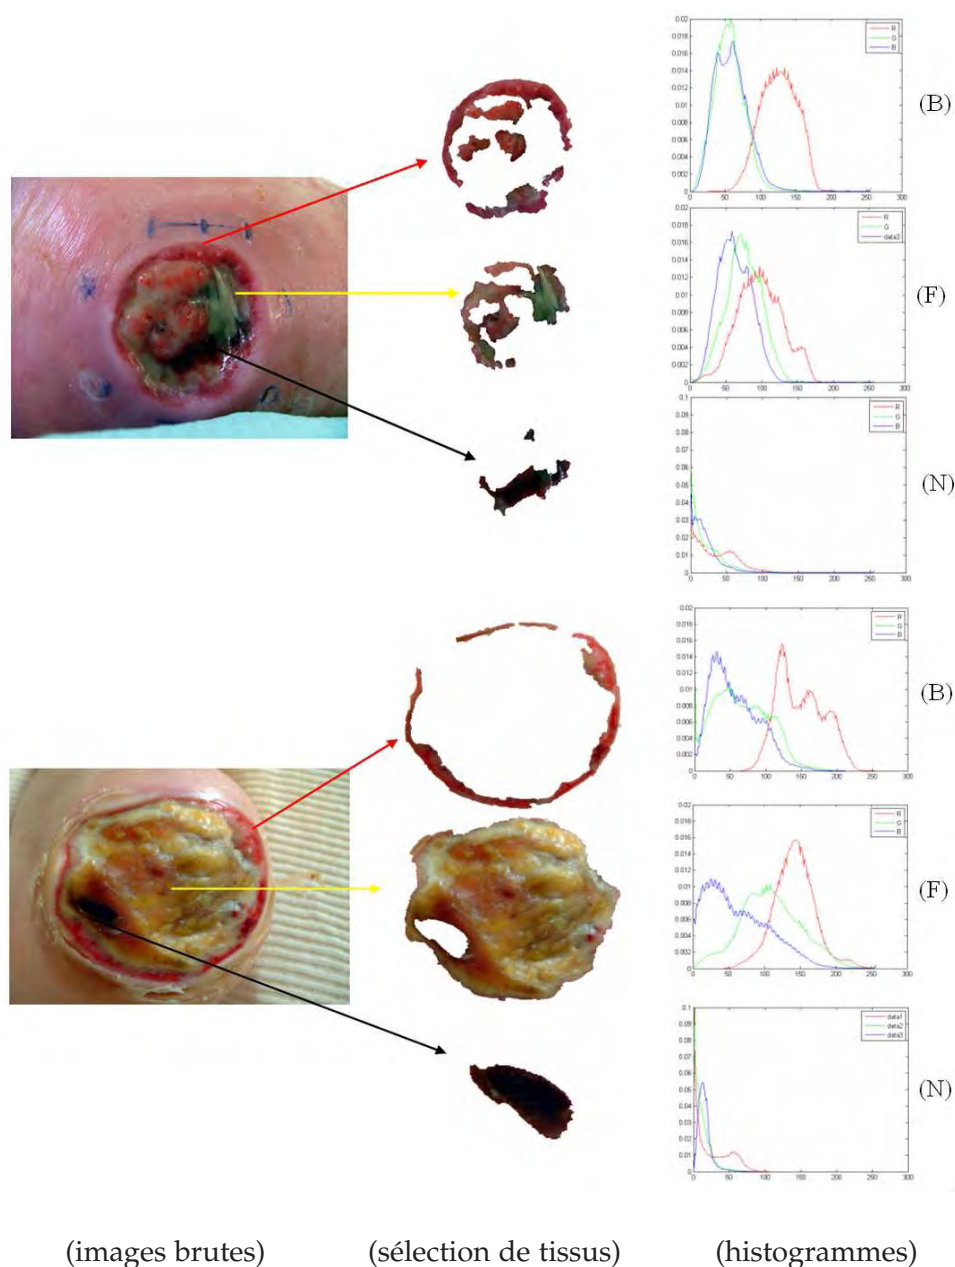


Figure 3.4 – Histogramme couleur RGB de différents types de tissus dans deux exemples pour trois types de tissus. Respectivement, de haut en bas, bourgeon, fibrine et nécrose, avec les histogrammes couleur R, G et B correspondants.

Malgré la difficulté de différencier des tissus cutanés par leurs histogrammes (Figure 3.4), la caractérisation couleur basée sur l’histogramme est la plus utilisée sur les images de plaies chroniques. Certains utilisent une représentation de l’image par un histogramme multidimensionnel 3D-RGB, afin de former des clusters pour segmenter les différents tissus [Mekkes & Westerhof, 1995] et [Berriss & Sangwine, 1997]. D’autres emploient les cellules de l’histogramme 3D-RGB quantifié de l’image en-

tière comme entrée du classifieur SVM pour séparer l'escarre de la peau saine [Kolesnik & Fexa, 2004] [Kolesnik & Fexa, 2005]. L'histogramme classique dans l'espace RGB a été aussi utilisé par [Zhang et al., 2000] et [Galushka et al., 2005] comme descripteur de couleur des zones sélectionnés manuellement, en entrée d'un classifieur k-plus proche voisins.

3.2.1.3 Couleurs dominantes

La notion de couleurs dominantes ou DCD (*Dominant Color Descriptor*) correspond à la sélection d'un sous-ensemble de couleurs représentatives d'une région par une quantification imprécise de l'espace couleur. Afin de calculer ce descripteur, les couleurs présentes dans une image donnée sont d'abord regroupées dans des *clusters*. Il en résulte un petit nombre de couleurs dont les pourcentages sont aussi calculés. Parfois, les variations des couleurs sélectionnées comme dominantes peuvent aussi être calculées. Ce descripteur peut être représenté par :

$$f_c = \{(c_i, p_i); i = 1, \dots, N, p_i \in [0, 1]\} \quad (3.2)$$

où c_i est la $i^{\text{ème}}$ couleur dominante avec un pourcentage p_i et N le nombre total de couleurs dominantes. Différentes méthodes de clustering peuvent être utilisées pour le calcul de la couleur dominante dans une région (Figure 3.5), comme les algorithmes GLA (*Generalized Lloyd Algorithm*) [Deng & Manjunath, 1999] et *Mean Shift* [Comaniciu & Meer, 2002], présentés au Chapitre 2.

Deux couleurs dominantes au maximum sont extraites dans [Hirata et al., 2002]. Dans [Deng et al., 1999], le nombre de couleurs dominantes, choisies parmi une palette de 256 couleurs établie pour une base d'images donnée, est de 3.5 par région en moyenne. La norme MPEG7 introduit un descripteur DCD, dont le nombre maximal de couleurs dominantes est fixé à 8. Les couleurs dominantes présentent l'avantage de constituer un descripteur plus compact que l'histogramme couleur classique, où seules quelques couleurs pertinentes sont considérées, mais toujours sélectionnées parmi une palette fixe de couleurs.

D'autres descripteurs couleur peuvent encore être cités : dans [Grecu & Lambert, 2001], les régions sont obtenues par classification non-supervisée des chrominances a et b des pixels de l'image dans l'espace $L^*a^*b^*$.

Ils reste à souligner que des descripteurs de couleur dits invariants sont très utilisés dans le domaine de la reconnaissance de formes et de la classification sous éclairage non contrôlé, comme la matrice de co-occurrence chromatique [Muselet & Macaire, 2007], l'histogramme couleur invariant [Finlayson & Schaefer, 2001] [Hordley et al., 2002] ou encore l'histogramme couleur invariant adapté [Muselet et al., 2004]. Bien que ces descripteurs soient assez robuste aux changements d'éclairage, nous avons jugé plus pertinent pour notre application d'appliquer une correction colorimétrique sur nos images plutôt que de caractériser les zones tissulaires dans les image brutes par des invariants. La raison vient du fait que les sources de perturbation colorimétriques qui peuvent affecter nos images




Figure 3.5 – Représentation des régions pré-segmentées par leur 1^{ère} couleur dominante, issue d'une quantification respectivement (c) par l'algorithme Mean Shift (d) par l'algorithme GLA.

ne proviennent pas seulement de l'éclairage mais aussi des APN. Ces descripteurs invariants pourraient nous dispenser d'une correction colorimétrique en acceptant de prendre toute les photos avec le même APN.

3.2.2 Descripteurs de texture

Il existe un très grand nombre de méthodes pour analyser la texture des images. Elles peuvent être classées globalement en quatre catégories [Mihran. & Anil, 1998]. Les méthodes statistiques sont basées sur les occurrences de niveaux de gris de l'image. Parmi ces méthodes, la méthode des matrices de co-occurrences GLCM (*Gray Level Co-occurrence Matrix*) est sans doute la plus connue. Dans les approches structurelles, une grammaire peut être définie pour décrire le motif de la texture. Enfin, dans les méthodes de filtrage spatio-fréquentiel, telles que le filtre de Gabor, l'analyse de texture décrit le rendu visuel de la texture par une somme de signaux de fréquences, d'amplitudes et de directions différentes.

Dans la majorité des cas, ces outils sont appliqués à la classification d'images naturelles ou de régions fortement texturées. Nous avons testé différentes approches sur nos régions d'images pré-segmentées. Nous présentons ci-dessous le principe de base de ces méthodes avant de les tester sur notre application.

3.2.2.1 Matrice de co-occurrence (GLCM)

Haralick propose un ensemble de 14 attributs statistiques, calculés à partir de la GLCM [Haralick & K., 1973] et dont les éléments représentent l'estimation de la pro-

babilité de transition d'un niveau de gris à un autre selon une direction donnée à une distance donnée. Le principe de cette matrice est le suivant : pour une image donnée à n niveaux de gris, il est possible de calculer la distribution de probabilité $P_{d,\theta}(i, j)$ (la fréquence d'apparition) des paires de niveaux de gris i et j dans une direction donnée θ à une distance d du pixel courant. P est une matrice carrée d'ordre n dont les indices sont les niveaux de gris considéré. Il est généralement admis que toute l'information texturale dérivable des matrices de cooccurrence est contenue dans les distributions $P_{d,0^\circ}, P_{d,45^\circ}, P_{d,90^\circ}$ et $P_{d,135^\circ}$ avec une distance inter-pixels d adaptée.

Les choix du vecteur de déplacement et de la taille de la fenêtre locale où calculer la mesure sont essentiels pour la réussite de la méthode. La difficulté à surmonter lors de l'application de cette technique réside précisément dans le choix de ces paramètres qui varient selon le type d'images et de textures. En règle générale, plus les éléments diagonaux de la matrice de cooccurrence sont grands et plus la texture est homogène dans la région considérée.

Étant donné que les textures de tissus cutanés sont isotropes, nous prenons arbitrairement un déplacement vers la droite, pour une distance d'un pixel ($d = 1$) dans une fenêtre 5×5 , en faisant l'hypothèse que l'information est la même dans les autres directions [Muzzolini, 1996]. Dans chaque région pré-segmentée de notre base d'images, nous avons calculé cinq indices de texture dérivés de la GLCM : l'énergie (ENR), l'entropie ou second moment angulaire (ENT), le contraste (CNT), l'homogénéité (HMG) et la corrélation (COR), dont les expressions sont données par :

$$\left\{ \begin{array}{l} ENR = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} P_d^2(i, j) \\ ENT = - \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} P_d(i, j) \log_2 P_d(i, j) \\ CNT = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i - j)^2 P_d(i, j) \\ HMG = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \frac{1}{1+(i-j)^2} P_d(i, j) \\ COR = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} \frac{(i-\mu_i)(j-\mu_j)}{\sigma_i \sigma_j} P_d(i, j) \\ \text{où } \mu_i = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} i P_d(i, j) \text{ et } \sigma_i = \sum_{i=0}^{n-1} \sum_{j=0}^{n-1} (i - \mu_i) P_d(i, j) \end{array} \right. \quad (3.3)$$

La caractérisation de régions texturées par la GLCM est largement utilisée en traitement d'images [Muzzolini, 1996]. Elle présente une grande simplicité de mise en oeuvre et donne généralement de bons résultats.

Concernant le traitement d'images des plaies, la GLCM a aussi été utilisée dans [Galushka et al., 2005] comme descripteur de texture pour caractériser des régions en entrée d'un classifieur k-ppv. Les auteurs ont employé trois mesures d'indices de texture issues de la GLCM : l'énergie, le contraste et la corrélation. Les moyennes et

l'écart-types de ces trois mesures ont été calculés dans chacune des trois composantes de l'espace RGB, totalisant 18 indices de texture calculés pour quatre angles différents ($0^\circ, 45^\circ, 90^\circ, 135^\circ$). Nos tests sur les images d'escarres ont confirmé que les tissus cutanés des plaies sont isotropes et que le recours à quatre orientations n'apportera donc aucune information. Bien que les taux de classification obtenus avec les descripteurs de texture seuls soient nettement inférieurs à ceux obtenus avec les descripteurs de couleur, la combinaison des deux améliore le processus de classification.

3.2.2.2 Filtre de Gabor

Le filtre de Gabor permet de filtrer l'image dans une direction et à une fréquence données. Il constitue un excellent compromis espace-fréquence pour la représentation du contenu des images. Ce filtre a une base sinusoidale modulée par une gaussienne. C'est donc un filtre passe bande de gabarit gaussien. Il est très répandu par sa propriété de résolution optimale conjointe en fréquence et en temps. La fonction du filtre de Gabor est donnée par :

$$G(u, v) = A \left(\exp\left\{-\frac{1}{2}\left[\frac{(u - u_0)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2}\right]\right\} + \exp\left\{-\frac{1}{2}\left[\frac{(u + u_0)^2}{\sigma_u^2} + \frac{v^2}{\sigma_v^2}\right]\right\} \right) \quad (3.4)$$

avec $\sigma_u = 1/2\pi\sigma_x$, $\sigma_v = 1/2\pi\sigma_y$ et $A = 2\pi\sigma_x\sigma_y$, où σ_x et σ_y sont les déviations standard le long des axes x et y et u_0 est la longueur d'onde de la sinusoïde le long de la direction x à 0° d'orientation.

Le filtre de Gabor fait partie d'une famille de techniques d'analyse et de caractérisation de texture qui décrivent le rendu visuel par un mélange de signaux de fréquence, d'amplitude et de direction différentes. Il permet l'extraction directe de caractéristiques de texture localisées en fréquence et en orientation, en utilisant le principe des fenêtres gaussiennes, qui glissent sur l'image en capturant ses propriétés locales. Il s'appuie sur un banc de filtres très sélectifs en fréquence et en orientation.

Généralement, ces bancs analysent 6 directions polaires (pas de 30°) et 5 échelles (1, 2, 4, 8, 16) [Dunn & Higgins, 1995] [Poursaberi & Araabi, 2006]. Il est commun d'utiliser un banc de filtres de Gabor pour caractériser plus précisément l'information fréquentielle des régions de l'image selon des directions ou des distances particulières. Si les méthodes issues des transformées de Fourier sont adaptées pour caractériser les textures régulières et uniformes. La texture de tissus cutanés n'étant ni régulière ni uniforme, des fréquences directionnelles ne peuvent pas caractériser nos régions tissulaires.

Dans le cadre de notre application sur les plaies chroniques, les descripteurs de Gabor ont été calculés sur les trois plans R, G et B de l'image filtrée par filtre de Gabor avec une fenêtre glissante de taille (7*7) pixels et pour 5 échelles. La caractéristique extraite des régions de l'image filtrée est l'énergie moyenne données par l'équation 3.3. Nous obtenons au total un vecteur de 15 caractéristiques de texture par régions, qui sera ensuite testé et comparé avec d'autres vecteurs.

3.2.2.3 Local Binary Pattern (LBP)

La méthode LBP, introduite par Ojala [Ojala et al., 1996] se définit comme une mesure de texture invariante, dérivée de la définition générale d'une texture dans un voisinage local. Le concept du LBP est simple : un code binaire décrivant la texture locale d'une région est calculé par seuillage d'un voisinage avec le niveau de gris du pixel central. Tous les voisins prendront alors une valeur 1 si leur valeur est supérieure ou égale au pixel courant et 0 sinon (Figure 3.6). On va alors multiplier cette matrice composée de 0 et 1 par les poids LBP (Figure 3.6) et sommer tous ses éléments pour obtenir la valeur LBP du pixel courant. On obtiendra donc des pixels dont l'intensité se situe entre 0 et 255 comme dans une image 8 bits ordinaire. Plutôt que de décrire l'image par la séquence des motifs LBP, on peut choisir pour descripteur de texture un histogramme de dimension 255.

6	5	2	1	0	0	1	2	4			
7	6	1	1		0	128		8		241	
13	28	11	1	1	1	64	32	16			
image brute			image seuillée			poids			LBP		

Figure 3.6 – Calcul du LBP d'un pixel donné. $LBP = 1 + 16 + 32 + 64 + 128 = 241$

Pour calculer un LBP dans un voisinage de P pixels, dans un rayon R , on compte simplement les occurrences de niveaux de gris g_p plus grands que la valeur centrale.

$$LBP_{P,R} = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p \quad (3.5)$$

où $s()$ est la fonction *signe* :

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3.6)$$

et où g_p et g_c sont respectivement les niveaux de gris d'un pixel voisin et du pixel central.

Deux variantes de la méthode LBP ont été présentées dans [Ojala et al., 2002] ; la première définit des LBP pour des voisinages de différentes tailles, ce qui permet de traiter la texture à différentes échelles, la seconde définit ce que l'on appelle les LBP uniformes. On définit un motif uniforme comme étant un motif possédant exactement 0 ou 2 transitions (01 ou 10) dans un parcours circulaire comme dans l'exemple de la Figure 3.7 (par exemple 10000001 ou 00011000 est un motif uniforme, mais pas 00101010).

La notion d'uniformité dans la méthode LBP est importante pour représenter les informations de primitives structurelles comme les coins et les contours. Ojala a




Figure 3.7 – Construction et uniformité d'un motif LBP. Le motif construit ici est uniforme (par exemple le motif 00101010 n'est pas uniforme).

constaté que seuls 58 des 256 motifs LBP sont uniformes mais expérimentalement on constate dans [Ahonen et al., 2006] que 90% des motifs rencontrés dans des images sont uniformes. Dans ce cas, la dimension de l'histogramme LBP peut être réduite de manière importante avec un histogramme de dimension 59. Chacune des 58 premières catégories contiendra le nombre d'occurrences de l'un des motifs uniformes. La dernière contiendra le nombre d'occurrences de tous les motifs non uniformes, ce regroupement permettant de réduire la dimension sans perdre trop d'information. La méthode LBP s'est révélée très efficace pour la classification d'images texturées comme dans les applications de reconnaissance de visage [Ahonen et al., 2006] [Tan & Triggs, 2007]. Elle a aussi été appliquée à la segmentation d'images d'escarres [Kolesnik & Fexa, 2005]. Un histogramme LBP quantifié en 18 cellules construit sur l'image entière sert de descripteur à l'entrée d'un classifieur SVM chargé de segmenter l'image en deux zones (escarre et peau saine).

Dans le cadre de l'évaluation des plaies chroniques, nous avons construit pour chaque région pré-segmentée deux versions de l'histogramme LBP (58 et 256 motifs) afin de choisir la plus performante sur les régions tissulaires. Même si ça n'est pas souvent le cas sur l'ensemble des images de notre base, l'histogramme LBP de l'exemple de la Figure 3.8 semble assez discriminant entre les trois types de tissus et révèle une similarité élevée entre deux tissus de même type (bourgeon dans l'exemple).

La discrimination a pu être vérifiée par le calcul de la mesure de l'intersection des histogrammes H_1 et H_2 par la formule :

$$Inter_{12} = H_1 \cap H_2 = \sum_i \frac{\min\{H_1(i), H_2(i)\}}{\max\{H_1(i), H_2(i)\}} \quad (3.7)$$

De grandes valeurs de l'intersection correspondent à des similarités élevées. Le tableau 3.1 donne les résultats d'intersection des histogrammes des régions présentées dans la Figure 3.8 et on constate bien expérimentalement qu'il est maximisé lorsque les deux échantillons sont du même type.

Intersection des histogrammes	$Inter_{B1F1}$	$Inter_{B1N1}$	$Inter_{F1N1}$	$Inter_{B1B2}$
Résultats d'intersection	0.36	0.56	0.46	0.81

Tableau 3.1 – Mesures d'intersection des histogrammes de différentes régions (B : bourgeon, F : fibrine, N : nécrose).

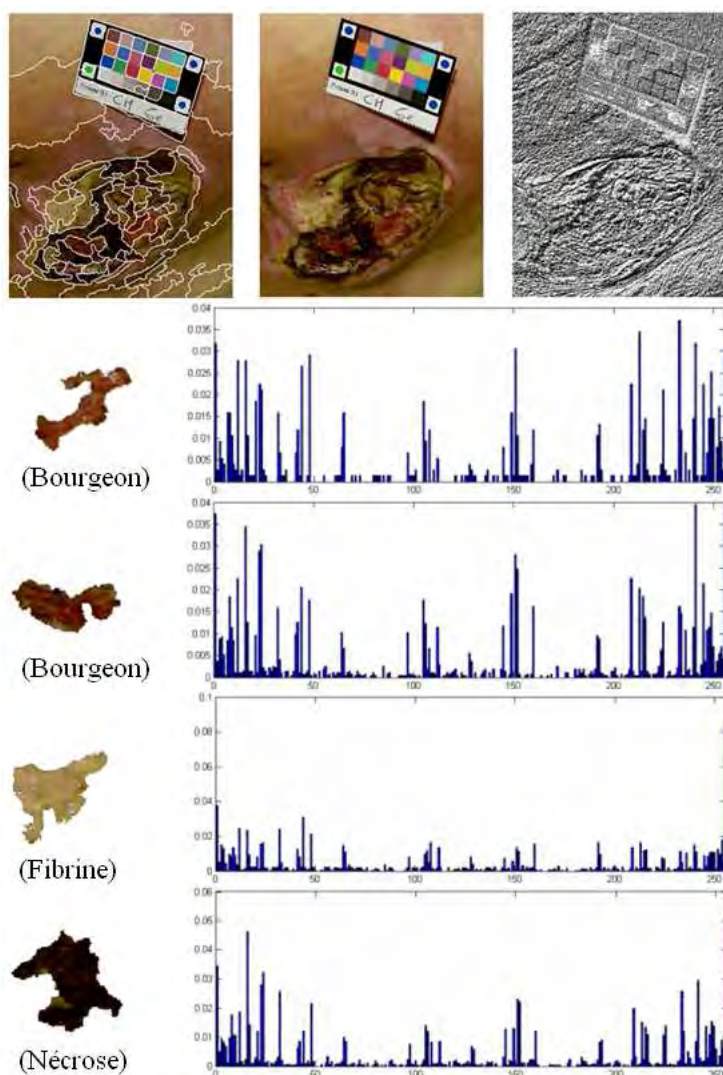


Figure 3.8 – Méthode LBP. Les histogrammes LBP des 4 régions pré-segmentées (version 256 motifs).

Le pouvoir de discrimination du descripteur LBP est efficace dans cet exemple, mais ce n'est pas le cas en général sur nos images où les résultats révèlent son inefficacité sur certains types de tissus. Nous avons testé ce descripteur sur plus de 300 échantillons prélevés sur les quatre types de tissus, en calculant l'intersection entre les régions du même type et les résultats obtenus sont donnés dans le Tableau 3.2 :

Intersection des histogrammes	$Inter_{BB}$	$Inter_{FF}$	$Inter_{NN}$	$Inter_{SS}$
Résultats d'intersection	0.3	0.6	0.1	0.8

Tableau 3.2 – Mesures d'intersection des histogrammes moyennées sur plus de 300 échantillons.

Avec une mesure d'intersection entre les histogrammes qui varie entre 0.1 pour le nécrose et 0.8 pour la peau saine, nous constatons que le LBP est instable pour les différents types. Il est beaucoup plus efficace sur les zones de peau saine que sur les tissus lésés.

Pour finir avec les descripteurs de texture, deux autres mesures de texture intéressantes méritent d'être testées. Proposées par [Carson et al., 1997], elles ont été extraites sur nos régions afin de les comparer avec les autres descripteurs. Ces mesures sont le contraste moyen normalisé (c) et l'anisotropie (a), définies par :

$$\begin{cases} c = 2\sqrt{\lambda_1 + \lambda_2} \\ a = 1 - \lambda_2/\lambda_1 \end{cases} \quad (3.8)$$

Les mesures de contraste et d'anisotropie se calculent avec la matrice M_σ des moments d'ordre 2, elle aussi dérivée du gradient de la luminance L de l'image (noté ∇I), dans l'espace couleur La^*b^* . L'expression de M_σ pour un pixel (x,y) peut être calculée après un lissage de l'image par un filtre gaussien de largeur de bande σ . M_σ est alors donnée par :

$$M_\sigma(x, y) = G_\sigma(x, y) * (\nabla I)(\nabla I)^T \quad (3.9)$$

3.2.3 Récapitulatif des caractéristiques

Nous avons dans un premier temps calculé séparément les différents descripteurs (couleur et texture) que l'on vient de présenter, afin de former les vecteurs de caractéristiques pour l'étape d'apprentissage ultérieure. Ces descripteurs ont été calculés sur un ensemble d'échantillons extraits des images labellisées par des experts en quatre classes (bourgeon, fibrine, nécrose et peau saine). Ce sont :

I- Descripteurs de couleur :

- un histogramme 3D dans l'espace couleur RGB quantifié systématiquement en $(4 \times 4 \times 4)$ cellules noté $(h - RGB)$, formant 64 attributs pour chaque région
- un histogramme 3D dans l'espace perceptuellement uniforme CIELAB, quantifié systématiquement en $(5 \times 10 \times 10)$, formant 500 cellules. Sachant que 282 cellules de cet histogramme sont souvent vides, seulement 218 cellules correspondant à la gamme $0 < R, G, B < 1$ sont prises en compte [Carson et al., 1997]. On obtient au final un vecteur de 218 attributs par région noté par la suite $h - LAB$
- un histogramme 2D dans l'espace HSV, quantifié systématiquement en 16×16 cellules pour chacune des composantes H et S. Il constitue un vecteur de 256 attributs par région noté $h - HS$
- un histogramme 2D dans l'espace RGB-normalisé, quantifié systématiquement en (16×16) cellules pour les composantes r et g représentant la *chromaticité* $(R, G, B)^2$. ce descripteur est noté $h - rg$
- la couleur moyenne MCD des trois composantes dans l'espace CIELAB combiné avec la couleur dominante DCD dans l'espace RGB. Cette dernière est obtenue avec une quantification par la procédure *Mean Shift*, appliquée dans

²Cet espace est souvent représenté par seulement deux composantes, $r = \frac{R}{R+G+B}$ et $g = \frac{G}{R+G+B}$, car la troisième se déduit directement des deux autres ($b = 1 - r - g$)

chaque région pour former 8 attributs représentant les trois composantes R, G et B des deux premières couleurs dominantes³ avec leurs pourcentages. Ce groupe de descripteurs constitue au final un vecteur de 11 attributs couleur par région, que nous noterons MCD-DCD.

II- Descripteurs de texture :

- un histogramme des motifs LBP de 256 cellules formant un vecteur de 256 attributs de texture par région, noté ($h - LBP$)
- un vecteur des motifs LBP de 59 cellules ($m - LBP$)
- un ensemble de 5 attributs de texture issus de la matrice de co-occurrence calculée dans les trois plans de l'espace couleur RGB. Ces attributs sont les valeurs moyennes de l'énergie, l'entropie, le contraste, l'homogénéité et la corrélation. Au total, ce groupe de descripteurs forme un vecteur de 15 attributs de texture par région, et sera appelé GLCM
- un vecteur de 15 indices de texture issus de l'application du filtre de Gabor dans les trois plans de l'espace RGB. Ces indices représentent l'énergie moyenne calculée sur l'image filtrée à 5 échelles différentes, notés par la suite GAB
- deux mesures de texture présentées dans [Carson et al., 2002], mesurant le contraste normalisé et l'anisotropie dans chaque région. Ces mesures sont issues de la matrice des moments du second ordre, dérivées du gradient de l'image d'intensité L dans l'espace $L^*a^*b^*$. Ce vecteur à deux attributs de texture sera appelé par la suite AC.

Il reste à souligner deux points importants lors du calcul des descripteurs de texture : premièrement, l'analyse de texture est effectuée dans les trois plans R, G et B de l'image, car ils se sont révélés plus appropriés lors des comparaisons avec d'autres plans, comme le plan d'intensité L de l'espace $L^*a^*b^*$. Deuxièmement, toutes les images ont été mises à la même échelle, grâce à une référence métrologique dans l'image (mire couleur).

Le tableau 3.3 récapitule l'ensemble des vecteurs de caractéristiques générées à partir de plus de 600 échantillons (régions pré-segmentées) issus de la phase de segmentation sur une base de 50 images labellisées par des experts. Dans ce tableau, la taille du vecteur de caractéristique est donnée ainsi que le temps moyen de calcul, avec un PC Pentium 4 CPU 3.4 GHz, de chaque vecteur sur une image de taille 512×384 pixels, sachant que ce temps dépend du nombre de régions et de la taille de la plaie dans l'image.

Dépendant de la taille de l'image (ou la zone de la plaie) et du nombre de régions pré-segmentées, ce temps a été moyenné afin de donner un ordre de grandeur sur le temps de traitement à additionner à celui des autres étapes de la chaîne. Notons

³ dans certains cas où la taille de la région est très petite et que cette dernière représente une forte homogénéité, la première couleur dominante est répétée deux fois au lieu de représenter la région par une deuxième couleur très peu présente.

Descripteurs	Taille de vecteur	Temps de calcul (sec)	
Couleur	<i>h-RGB</i>	64	13
	<i>h-LAB</i>	218	20
	<i>h-HSV</i>	256	25
	<i>h-rg</i>	256	20
	<i>MCD-DCD</i>	8	5
Texture	<i>h-LBP</i>	256	6
	<i>m-LBP</i>	59	6
	<i>GLCM</i>	15	15
	<i>GAB</i>	15	6
	<i>AC</i>	2	17

Tableau 3.3 – Récapitulatif de l'ensemble des descripteurs de couleur et de texture extraits de notre base d'échantillons de tissus.

que le pouvoir de discrimination et la variabilité des descripteurs ne seront pas discutés avant la présentation du classifieur, car on convient de les évaluer seulement en sortie de la chaîne de traitement. Le fait d'évaluer les performances des descripteurs après classification, donnera plus de pertinence à l'évaluation et plus d'efficacité au processus, car l'évaluation est souvent relative aux critères utilisés et liée à leurs mesures de similarité.

Lorsque l'étape de calcul est terminée, les caractéristiques peuvent être bruitées et leur nombre important. On convient donc de faire une sélection parmi celles-ci et/ou d'en extraire de nouvelles plus pertinentes, par combinaison ou par projection dans un sous-espace. C'est le rôle de la phase d'extraction/sélection de caractéristiques exposée dans le paragraphe suivant.

3.3 Extraction/sélection de caractéristiques

L'extraction/sélection des caractéristiques permet d'éviter la redondance des données et de réduire leur dimensionnalité en conservant le maximum d'information possible dans un espace de dimension inférieure. On peut faire la distinction entre les méthodes d'extraction qui créent de nouvelles variables à partir des anciennes et les méthodes de sélection qui cherchent seulement un sous-ensemble d'attributs optimal suivant un critère donné. Parmi les méthodes d'extraction bien établies, nous en avons retenu trois :

- L'Analyse Factorielle Discriminante (AFD) : cette technique d'analyse linéaire, cherche le sous-espace vectoriel pour lequel l'inertie intra-classe est minimale (classes compactes) et l'inertie inter-classes est maximale (classes séparées). Cette méthode est supervisée car elle suppose la connaissance de la classe d'appartenance pour un certain nombre d'échantillons.
- L'Analyse en Composantes Principales (ACP) : elle est basée sur l'hypothèse

que l'information est principalement portée par les axes de grande variance. On aboutit à définir un sous-espace de dimension p' ($p' < p$) engendré par les vecteurs propres de la matrice de covariance correspondant aux p' plus grandes valeurs propres.

- L'Analyse en Composantes Indépendantes (ACI) : l'objectif de cette technique statistique est de décomposer les données en combinaisons linéaires de nouvelles variables qui soient indépendantes.

On introduit dans les paragraphes suivants les principes de base de ces méthodes. Nous les appliquons ensuite sur nos données avant d'aborder la phase d'apprentissage du classifieur.

3.3.1 Analyse discriminante linéaire (ADL)

L'ADL est une technique introduite par Fisher [Fisher, 1936]. Elle part de la connaissance de la partition en classes des individus d'une population et cherche les combinaisons linéaires des variables décrivant les individus qui réalise la meilleure discrimination entre les classes. Dans cet objectif, l'ADL cherche un sous-espace dans lequel les moyennes des attributs des classes (centroïdes des nuages d'échantillons des classes) sont dispersées alors que la covariance interne de chaque classe (tailles des nuages) est minimisée.

L'idée de base est de trouver une projection des échantillons sur une droite qui sépare le mieux possible les deux classes. Le critère de séparation est exprimé par la maximisation du rapport des variances inter-classes et intra-classe dans cette projection. Dans le cas binaire, où x_1, x_2, \dots, x_n désigne un ensemble d'échantillons parmi lesquels n_1 appartiennent à la classe W_1 et n_2 appartiennent à W_2 , leurs projections sur une droite d'orientation W (vecteur unitaire) s'écrivent $y_i = W^t x_i$.

Soit μ_i les centres de gravité de chaque classe (pour $i = 1, 2$) et y_i leurs projections :

$$\mu_i = \frac{1}{n_i} \sum_{X \in W_i} X = \frac{1}{n_i} \sum_{y \in W_i} y = \frac{1}{n_i} \sum_{X \in W_i} W^t X = W^t \mu_i \quad (3.10)$$

Il s'agit de maximiser leur distance, soit

$$(\mu_1 - \mu_2)^2 = W^t (\mu_1 - \mu_2) (\mu_1 - \mu_2)^t W = W^t S_B W \quad (3.11)$$

où $S_B = (\mu_1 - \mu_2)(\mu_1 - \mu_2)^t$ est appelée matrice de dispersion inter-classe. La dispersion de chaque classe (pour $i = 1, 2$) est définie par :

$$s_i^2 = \sum_{X \in W_i} W^t (X - \mu_i) (X - \mu_i)^t W = W^t S_i W \quad (3.12)$$

La dispersion intra-classe totale est donc $s_1^2 + s_2^2 = W^t (S_1 + S_2) W = W^t S_W W$ où S_W est la matrice de dispersion intra-classe, égale à la somme des matrices de

dispersion des deux classes. La discrimination linéaire de Fisher consiste à choisir la transformation linéaire $W^t X$ qui maximise le critère :

$$J(W) = \frac{(\mu_1 - \mu_2)^2}{s_1^2 + s_2^2} = \frac{W^t S_B W}{W^t S_W W} \quad (3.13)$$

Ce critère peut être ramené à une recherche des valeurs propres de $S_W^{-1} S_B$ qui vérifient par définition :

$$S_W^{-1} S_B W = \lambda W \quad (3.14)$$

Etant donné que $S_B W$ se trouve dans la direction de $\mu_1 - \mu_2$, la solution peut s'écrire :

$$W = S_W^{-1} (\mu_1 - \mu_2) \quad (3.15)$$

le vecteur propre W désignant la droite qui sépare le mieux les deux classes.

3.3.2 Analyse en composantes principales (ACP)

L'analyse en composante principale est une technique mathématique qui réduit la dimensionnalité d'un système complexe de corrélations à un nombre réduit de dimensions, conservant néanmoins l'essentiel de la variance totale des données. Soit un ensemble de données x_1, x_2, \dots, x_n que l'on cherche à représenter dans un sous-espace par combinaison des données originales de l'espace initial. Ce sous-espace doit expliquer les corrélations éventuelles entre les données par de nouvelles variables, appelées composantes principales. Cette représentation par les composantes principales (de dimension 1 dans le cas le plus simple) consiste à projeter les points sur une droite d'équation $x = N + ae$ d'orientation e (vecteur unitaire) passant par le centre de gravité μ :

$$\mu = \frac{1}{n} \sum_k X_k \quad (3.16)$$

Les scalaires a_1, a_2, \dots, a_n qui minimisent le critère des moindres carrés

$$J_1(a_1, a_2, \dots, a_n, e) = \sum_k \|(\mu + a_k e) - X_k\|^2 \quad (3.17)$$

sont les $a_k = e^t (X_k - \mu)$.

Ils correspondent à la projection orthogonale de X_k sur la droite d'orientation e passant par N . En développant J_1 et en annulant les dérivées par rapport à a_k , on obtient :

$$\mu = \frac{\partial J_1(a_1, a_2, \dots, a_n, e)}{\partial a_k} = 2a_k - 2e^t (X_k - \mu) = 0 \quad (3.18)$$

soit $a_k = e^t (X_k - \mu)$. Afin de choisir la meilleure droite, il faut trouver la direction e qui minimise J_1 . On montre que

$$J_1(e) = -e^t S e + \sum_k \|X_k - \mu\|^2 \quad (3.19)$$

et que le vecteur e cherché correspond au vecteur propre de la plus grande valeur propre de la matrice de dispersion⁴ S .

L'analyse en composantes principales se généralise à une dimension quelconque $d' < d$:

$$\begin{cases} X = \mu + \sum_{i=1}^{d'} a_i e_i \\ J^{d'}(a_1, a_2, \dots, a_n, e) = \sum_k \|(\mu + \sum_{i=1}^{d'} a_{ki} e_i) - X_k\|^2 \end{cases} \quad (3.20)$$

où $J^{d'}$ est minimisé pour les vecteurs propres $e_1, \dots, e_{d'}$ correspondants aux d' plus grandes valeurs propres de la matrice de dispersion.

L'analyse en composantes principales est utile pour analyser des données corrélées et bruitées, ou appartenant à un espace de dimension élevée, en cherchant des projections qui étalent les points d'une classe. Par contre, elle ne garantit pas forcément une bonne discrimination entre les classes (Figure 3.9), car une telle projection peut réduire le pouvoir discriminant. Dans cette figure, les deux techniques d'analyse par ADL et ACP ont été appliquées sur un ensemble de 23 caractéristiques étiquetées avec 4 classes de tissus, afin de les représenter dans un sous-espace à 8 dimensions. Ce vecteur de caractéristiques est une combinaison des attributs de couleur et de texture issus des descripteurs MCD-DCD et GLCM.

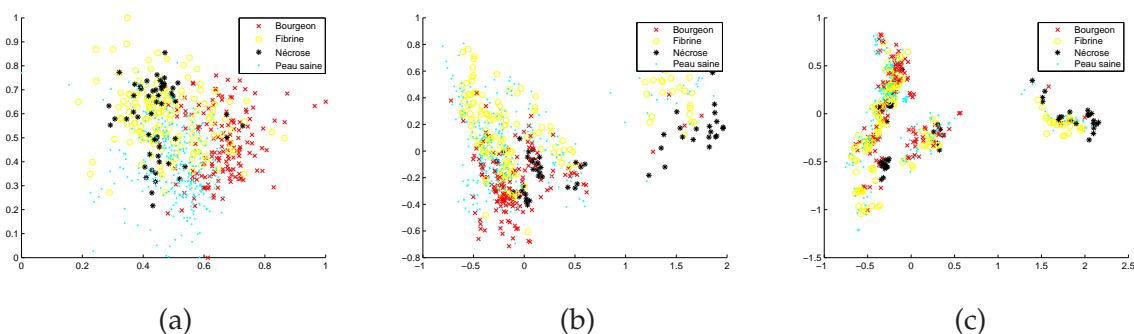


Figure 3.9 – Projection linéaire par ADL et ACP. (a) représentation des 2 premiers attributs parmi 23 attributs représentant 653 échantillons étiquetés en 4 classes (b) projection par ADL (c) projection par ACP (deux premières composantes principales).

Dans la Figure (3.9-a), on peut constater clairement le mélange et le bruitage très importants des données, justifiant de les qualifier comme non-séparables. La tâche de séparation s'annonce impossible avec une simple analyse ADL.

⁴La matrice de dispersion d'un ensemble de données x_1, x_2, \dots, x_n est définie comme étant $S = \sum_k (X_k - m)(X_k - m)^t$. Cela correspond à la matrice de covariance, à un facteur multiplicatif près (de valeur $n - 1$).

3.3.3 Analyse en composantes indépendantes (ACI)

L'ACI est une extension utile de l'ACP, développée dans le contexte de la séparation aveugle des mélanges linéaires de sources indépendantes. Ces techniques de séparation aveugle ont été conçues pour l'utilisation dans le cas d'applications de séparation des signaux sonores au de traitement de signaux médicaux [Hyvarinen & Oja, 2000] et [Comon, 1994]. En résumé, plutôt que d'exiger simplement que les variables d'un vecteur de données soient décorrélatées comme dans l'ACP, ces coefficients doivent ici être indépendants les uns des autres (ou aussi peu dépendants que possible). Des statistiques d'ordre supérieur sont nécessaires pour déterminer l'expansion de l'ACI.

L'analyse en composantes indépendantes d'un vecteur aléatoire $x = (x_1, x_2, \dots, x_p)$ consiste à trouver une transformation représentant le mélange de n sources indépendantes par ce vecteur aléatoire. Cela revient à identifier le modèle sous la forme multiplicative suivante :

$$X = As \tag{3.21}$$

où les composantes s_i du vecteur $s = (s_1, s_2, \dots, s_n)$ sont mutuellement indépendantes et où A désigne la matrice de mélange. La recherche de composantes linéaires qui soient aussi peu dépendantes que possible se traduit formellement par la minimisation de $I(A^{-1}X)$, où $I(Y)$ est une mesure de la dépendance des coordonnées d'un vecteur aléatoire Y . Les nouvelles variables contenues dans S sont appelées composantes indépendantes. L'estimation des composantes indépendantes avec des combinaisons linéaires des variables d'observation x_1, x_2, \dots, x_n s'obtient en inversant la matrice de mélange :

$$s = A^{-1}X = WX \tag{3.22}$$

L'analyse en composantes indépendantes peut être abordée par la recherche de distributions les plus éloignées possibles de la distribution normale (gaussienne). La justification essentielle de ce point de vue est le théorème central limite qui stipule que la distribution d'une somme de variables aléatoires indépendantes, sous certaines conditions, tend vers une distribution gaussienne. Ainsi, une somme de deux variables aléatoires indépendantes a généralement une distribution plus proche d'une gaussienne que les deux variables aléatoires d'origine. Dans le cadre d'un modèle linéaire $X = As$, il existe un lien très significatif entre la dépendance, la corrélation et la non-gaussianité. Dans la recherche de composantes linéaires par l'approche adoptée dans [Hyvarinen & Oja, 2000], minimiser la dépendance $I(Y)$ revient à minimiser la corrélation tout en maximisant la non gaussianité de chaque composante (non-gaussianités marginales). Une des méthodes employées pour mesurer la non-gaussianité et estimer les sources indépendantes de façon rapide, est la méthode itérative du point fixe [Hyvarinen, 1999]. L'algorithme FastICA [Hurri, 2005] basé sur cette méthode du point fixe a permis de tester la méthode ACI sur nos données.

L'intérêt des méthodes d'analyse présentées ici en amont d'un classifieur vient du fait que la précision de ce dernier dépend de la présence de bruit ou de caractéristiques non pertinentes dans la base d'apprentissage. Une étape de sélection

ou de ré-échantillonnage des exemples d'apprentissage améliore sensiblement les performances. Les calculs de l'information mutuelle ou de la corrélation entre les exemples permettent de conserver les données les plus représentatives des catégories étudiées. Un changement d'espace de représentation des données par ACP ou ADL est également utile pour mieux caractériser certains concepts. Enfin une analyse ACI des données par la recherche d'une indépendance des variables, afin de maximiser leur séparation en fonction de leur indépendance statistique mesurée par l'information mutuelle, peut aussi accroître les performances du classifieur.

Cette étape de pré-traitement des données décrivant différentes classes d'échantillons nous a permis de tirer quelques conclusions. D'abord, les données extraites des tissus cutanés sont très bruitées, mal conditionnées, et linéairement non-séparables. Les analyses de discrimination linéaire ou par composantes principales ne semblent pas suffisantes pour séparer les données des différentes classes. L'analyse par ces méthodes est sensible à la distribution et à la nature des données (gaussienne, non-gaussienne, ...) que l'on ignore. Enfin, ces méthodes d'analyse peuvent être rentables en couplant leur efficacité de conditionnement et de décorrélation des données, ainsi leur capacité de réduction de dimensionalité sans perte d'information, avec le pouvoir de séparation d'un classifieur SVM. La mise en oeuvre de ce classifieur fait l'objet du paragraphe suivant.

3.4 Classification des régions

On distingue en général deux modes d'apprentissage :

- la classification supervisée, qui s'opère à partir d'un ensemble d'apprentissage où chaque observation a préalablement été classée. À partir de cet ensemble d'apprentissage, on construit une règle de décision qui permettra d'affecter une catégorie à une observation inédite. La règle de décision se fait par la recherche des fonctions discriminantes comme dans le cas des Séparateurs à Vaste Marge (SVM), où l'on recherche les frontières de décision en maximisant la marge séparatrice entre les différentes classes.
- l'apprentissage non supervisé, où on ne dispose pas de la classe associée aux observations. L'algorithme de reconnaissance doit alors lui-même trouver les catégories à partir des régularités statistiques des observations. Dans ce cas, la recherche d'une partition des données revient à regrouper celles-ci selon une certaine mesure de similarité ou de dissimilarité. La métrique employée peut être de nature géométrique (*K-Means*) ou probabiliste (*Bayes*).

Dans notre application, nous disposons pour chaque image de la base d'une labellisation manuelle de la plaie considérée, selon les différents types de tissus. Nous disposons donc d'un ensemble d'apprentissage où les observations sont annotées par des experts. Nous nous sommes donc orientés logiquement vers un apprentissage

supervisé. Nous présentons d'abord les critères d'évaluation du classifieur qui permettent la bonne évaluation du système, car ces critères vont conditionner nos choix de modèle de classification et de descripteurs de régions.

3.4.1 Mesures de performance du classifieur

En classification de données, une approche souvent utilisée consiste à faire des calculs de sensibilité et de spécificité de détection. On va par la suite utiliser ces mesures pour évaluer le paramétrage du modèle et l'utilisation de différents noyaux pour notre classifieur. Elles seront aussi employées lors des comparaisons de différents descripteurs, ainsi que pour tester l'efficacité de notre approche face aux autres méthodes. L'analyse des réponses des observateurs va se faire en triant les réponses négatives et positives. On distingue 4 situations :

- **Vrai Positif** : instance positive, classifiée positive.
- **Faux Positif** : instance négative, classifiée positive.
- **Vrai Négatif** : instance négative, classifiée négative.
- **Faux Négatif** : instance positive, classifiée négative.

On résume les résultats d'un classifieur sur des données de test pour chaque classe dans une matrice dite de confusion comme en figure 3.10.

		Réponse de l'expert	
		p	n
Réponse du classifieur	Y	Vrai Positif	Faux Positif
	N	Faux Négatif	Vrai Négatif

Figure 3.10 – Matrice de confusion.

Quatre mesures d'évaluation sont dérivées de cette matrice pour chaque classe de tissu :

- la sensibilité (Se) est considérée comme le ratio des régions simultanément labellisées par cette classe, par la classifieur et l'expert. C'est la capacité du classifieur de détecter les VP
- la spécificité (Sp) désigne le ratio des régions non labellisées avec cette classe par le classifieur et l'expert. C'est la capacité du classifieur à éviter les FP
- le taux de réussite (T) est la moyenne de la sensibilité et la spécificité
- la précision globale (P) est la proportion des régions classées correctement.

$$\left\{ \begin{array}{l} Se = \frac{VP}{VP+FN} \\ Sp = \frac{VN}{VN+FP} \\ T = \frac{Se+Sp}{2} \\ P = \frac{VP+VN}{TP+FN+FP+TN} \end{array} \right. \quad (3.23)$$

La sensibilité et la spécificité sont très couramment utilisées par les cliniciens comme mesures fiables d'estimation de la performance dans les tâches de diagnostic [Alberg et al., 2004], [Shapiro, 1999]. L'idéal pour un classifieur serait d'obtenir une sensibilité et une spécificité égales à 1, ce qui n'est généralement pas possible. Pour cela, il faut tenter d'obtenir les plus fortes valeurs pour ces deux paramètres, sachant qu'ils varient en sens inverse. On peut s'appuyer pour ce choix sur un outil graphique appelé courbe ROC (Receiver Operating Characteristics), qui trace l'évolution de la sensibilité Se en fonction de $1-Sp$.

Désormais, toute évaluation de notre classifieur va être basée sur ces quatre mesures, calculées pour chaque type de tissu ou moyennées sur les quatre types. Le fait d'utiliser dans certains tests les moyennes de ces mesures sans considérer leur valeur pour un tissu donné, est lié au fait que l'on ne souhaite pas accorder de préférence à un tissu. Lors de la validation clinique, on verra qu'il est important de présenter des résultats d'évaluation pour chaque tissu.

3.4.2 Séparateurs à vaste marge

Les séparateurs à vaste marge (SVM) sont des classifieurs basés sur des techniques d'apprentissage supervisé ayant des hyperplans optimaux dans un espace de données multidimensionnel. Ce sont des outils mathématiques très performants issus de la théorie d'apprentissage statistique élaborée par V.N Vapnick [Vapnik, 1999] appliqués essentiellement à la reconnaissance des formes, l'identification et l'analyse statistique. Depuis, cette technique d'apprentissage a connu un développement considérable et sa motivation principale est la recherche des limites probabilistes qui permettent de réduire au maximum les erreurs de classification et les "risques empiriques" en maximisant les marges de séparation.

Les SVM linéaires fournissent des solutions à marge maximale entre l'hyperplan séparateur et les échantillons de l'ensemble d'apprentissage. Dans le cas où les données sont linéairement séparables, la notion de marge maximale est intuitivement pertinente et ceci nous permettra de définir la notion de Support Vector. Nous présentons dans l'annexe B le cas des données linéairement séparables, les données linéairement non-séparables et enfin les SVM non-linéaires, comme illustration parfaite du rôle que peuvent jouer les noyaux. Les principales sources de SVM utili-

sées ici sont [Burges, 1998], [Joachims, 1999], [Joachims, 2000], [Chang & Lin, 2001] et [Guermeur, 2007].

3.4.2.1 Apprentissage à base de noyaux

Les algorithmes d'apprentissage à base de noyaux exploitent l'idée suivante : simplifier la séparation des données en transposant le problème initial d'un espace de représentation de faible dimension dans un espace de plus grande dimension. La fonction de transformation Φ est non-linéaire (Figure 3.11). Pour un problème donné de classification, on considère donc son expression dans H au lieu de R^n : $\{\Phi(x_1, y_1), (\Phi(x_2, y_2), \dots, (\Phi(x_n, y_n))\} \in H \times \{-1, +1\}$, où les y_i sont les étiquettes des classes. Si le noyau est judicieusement choisi, le problème de classification devient alors plus facile à résoudre, typiquement linéairement séparable.




Figure 3.11 – Séparation simplifiée dans un l'espace de représentation avec des dimensions plus élevées. L'idée d'utiliser les noyaux par SVM est de transformer un problème de séparation non-linéaire dans un problème de séparation linéaire dans l'espace re-description de grandes dimensions.

On appelle en fait "noyau" toute application $K : R^n \times R^n \rightarrow R$ qui a la forme $K(x, y) = \langle \Phi(x), \Phi(y) \rangle_H$ où Φ est une fonction de transformation de l'espace de représentation initial R^n vers l'espace transformé H .

Pour pouvoir représenter le produit scalaire $\langle \Phi(x), \Phi(y) \rangle$, la fonction K doit nécessairement :

- être symétrique : $K(x, y) = \langle \Phi(x), \Phi(y) \rangle = \langle \Phi(y), \Phi(x) \rangle = K(y, x)$
- satisfaire aux conditions de Cauchy-Schwarz :

$$K^2(x, y) = \langle \Phi(x), \Phi(y) \rangle^2 \leq \|\Phi(x)\|^2 \cdot \|\Phi(y)\|^2 = K(x, x) \cdot K(y, y)$$

Enfin, pour garantir l'existence d'un espace intermédiaire H , la fonction $K(x, y)$ doit respecter la condition de Mercer⁵ [Mercer, 1909]

- Différents noyaux $K(x, y)$ sont utilisés en pratique, les plus fréquemment étant :
- le noyau linéaire : $x * y$
 - le noyau polynômial : $(x * y + \theta)^d, d \in \mathbb{N}, \theta \in R$
 - le noyau gaussien RBF (*Radial Basis Function*) : $\exp(-\alpha \|x - y\|^2), \alpha \in R$
 - le noyau sigmoïdal : $\tanh(x * y + \theta), \theta \in R$

⁵Pour toute fonction $g(x)$ telle que $\int g(x)^2 dx$ est fini, il faut que $\int \int K(x, y) g(x) g(y) dx dy \geq 0$.

Enfin, on peut citer le noyau perceptron simplifié (*simplified perceptron kernel*) moins utilisé avec les SVM que les quatre derniers noyaux. Ce noyau a été présenté dans [Lin & Li., 2005] et [Lin & Li, 2008] comme concurrent du noyau gaussien RBF, alors qu'il bénéficie d'un modèle de sélection de paramètres plus rapide, comme on le montrera plus loin dans ce chapitre. Le noyau de perceptron simplifié s'écrit : $K(x, y) = -\|x - y\|_2$, avec la distance ℓ_2 -norme $= (\sum_{i=1}^n |x_i - y_i|^2)^{1/2}$.

Dans certains cas, surtout avec des données provenant d'attributs discrets, on utilise des noyaux plus appropriés. Une difficulté importante dans un problème de classification nouveau provient du fait que l'on ignore la cartographie des données dans leur espace : il n'est pas évident de dire a priori quel noyau va fournir le meilleur résultat.

3.4.2.2 SVM multiclass

Les SVM ont été conçus à l'origine pour les problèmes de classification binaires. Cependant, plusieurs approches permettent d'étendre cet algorithme aux cas à plusieurs classes [Hsu & Lin, 2002]. On peut citer les deux approches les plus connues :

- la première consiste à se ramener au problème binaire : on cherche à décomposer le problème initial en un ensemble de sous problèmes à deux classes, puis on affecte un SVM standard à chacun de ces sous problèmes. Pour cela, on classe les points d'une classe contre tous les points de toutes les autres classes. Ainsi, pour N classes, on obtient N frontières de séparation. Pour prédire la classe d'un nouveau point, on utilise les fonctions de décision obtenues par classification binaire. Cette approche est appelée "un contre les autres" [Bottou et al., 1994].
- la seconde consiste à considérer toutes les paires possibles de classes et à construire un hyperplan pour chaque paire de classes. Ainsi, on finit par obtenir $N(N - 1)/2$ hyperplans séparateurs. Quand on traite un nouveau point x , chaque hyperplan vote pour sa classe préférée, et la classe affectée à ce point est celle majoritaire après le vote [Friedman, 1996]. Cette approche est appelée "un contre un". Selon [Hsu & Lin, 2002], les deux approches offrent des performances similaires.

3.4.2.3 Sélection du modèle SVM

Lors de la conception d'un classifieur SVM, on doit résoudre un problème d'optimisation dans un espace de dimension conséquente. La performance finale de ce système dépend étroitement de la sélection de fonctions noyaux adaptées et du réglage de leurs paramètres.

I Choix du noyau

Il peut largement modifier l'efficacité du classifieur SVM. Il n'existe pas de noyau universel pour toutes les applications. Plusieurs noyaux ont été testés sur notre base d'échantillons afin de sélectionner celui qui réalise la meilleure projection des données pour simplifier la séparation entre les classes de tissus. Pour chaque noyau, nous avons testé différents paramètres afin de déterminer de façon empirique, en fonction des taux de précision obtenus, le noyau le mieux adapté à notre application. Le tableau 3.4 ci-dessous présente la sensibilité (Se), la spécificité (Sp), le taux de réussite (T) et le taux de précision global (p) moyen obtenus par le classifieur SVM pour plusieurs noyaux. Le courbe ROC correspondante est représentée dans la Figure 3.12 :

<i>Noyau</i>	Se (%)	Sp (%)	T (%)	P (%)
<i>Linéaire</i>	66	88	77	83
<i>Polynomial</i>	61	87	74	82
<i>RBF</i>	68	88	78	83
<i>Perceptron</i>	72	90	81	85

Tableau 3.4 – Evaluation du classifieur SVM avec différents noyaux.




Figure 3.12 – Courbe ROC : 4 courbes correspondant à 4 tests de classification par des noyaux différents.

On interprète ce graph en recherchant la courbe qui s'approche le plus du coin supérieur gauche, soit $Se = Sp = 1$. Il correspond à une bonne détection du tissu présent avec un bon rejet des autres classes. Le noyau perceptron semble le plus adapté à nos données, suivi par RBF. Par contre, le noyau linéaire est beaucoup moins approprié.

Lors de l'étape de sélection de noyaux, deux paramètres doivent être soigneusement choisis : un paramètre relatif au noyau utilisé et le paramètre de régularisation C , qui contrôle la pénalité de l'erreur de classification.

II Réglage des hyper-paramètres

Le réglage des hyper-paramètres d'un classifieur SVM est une étape cruciale afin d'établir un système de classification efficace. La méthode la plus utilisée pour optimiser les hyper-paramètres est la validation croisée.

Nous avons choisi comme classifieur l'algorithme SVM à marge douce (C-SVM) avec différents noyaux : linéaire, polynomial, RBF et perceptron. Par conséquent, nous avons dû optimiser un paramètre (C) dans les cas des noyaux linéaire ou perceptron et deux paramètres respectivement (C, α) dans le cas des noyaux RBF, (C, θ) et polynomial⁶. Pour l'optimisation des valeurs de ces paramètres nous avons utilisé la méthode line search (ou parallel grid search), combinée avec une validation croisée.

La procédure LOO (Leave One Out) est une validation croisée adaptée pour des données en faible nombre. Elle consiste à diviser l'ensemble des n données en deux bases : une base d'apprentissage de $n - 1$ exemples et une base de test ne contenant qu'un seul exemple, réitérant n apprentissages où l'exemple de test est un exemple différent. Il est connu que la procédure LOO donne une estimation presque non biaisée de l'espérance de l'erreur de généralisation [Chapelle et al., 2001]. Cependant, la procédure est coûteuse en calculs, car nécessitant n apprentissages, mais elle peut être allégée par une procédure simple d'estimation de l'erreur de généralisation (ou du taux de précision) dite de validation croisée k -fold [Duan et al., 2003] [Chapelle et al., 2001]. Elle consiste à diviser l'ensemble des données en k sous-ensembles mutuellement exclusifs de taille approximativement égale. L'apprentissage de la machine est effectué en utilisant $k-1$ sous-ensembles et le test est effectué sur le sous-ensemble restant. Cette procédure est répétée k fois et chaque sous-ensemble est utilisé une fois pour le test. L'erreur de généralisation est obtenue par la moyenne des k taux d'erreur. La LOO peut être vue comme le cas extrême de la validation croisée k -fold, où $k = n$.

En ce qui concerne le choix de k , une grande valeur de k abaisse le nombre d'échantillons de test mais la variance de test augmente ainsi que le temps de calcul. Si la valeur de k est petite, la base de test s'agrandit et le biais de test augmente. Par conséquent, le temps de calcul diminue ainsi que la variance de l'estimateur. Dans la pratique, le choix de k dépend de la taille de la base de données utilisée. Pour une base très grande, une valeur de $k = 3$ peut être raisonnable, pour une petite base on doit utiliser une valeur plus grande ($k = 10$) afin de permettre à l'estimateur d'apprendre un plus grand nombre d'échantillons.

Le processus d'optimisation des paramètres du classifieur SVM pour notre base d'échantillons a été effectué de la façon suivante :

- le coefficient de pénalisation C a été optimisé dans l'intervalle $[2^{-5}, 2^{15}]$

⁶Le degré polynomial a été fixé à 3 pour restreindre la recherche à deux hyper-paramètres.

- la largeur de bande α a été optimisée dans l'intervalle $[2^{-15}, 2^3]$
- la valeur de θ a été optimisée dans l'intervalle $[2^{-15}, 2^3]$
- une validation croisée de type *5-folds* a été exécutée sur les données.

La Figure 3.13 illustre le réglage des hyper-paramètres C et α du classifieur C-SVM avec un noyau gaussien RBF par la technique *parallel grid search*. Les données d'apprentissage du classifieur ont été obtenues par une combinaison de descripteurs de couleur et de texture calculés sur une base d'échantillons (>600) représentant les quatre types de tissu. Cette combinaison est représentée par un vecteur de 23 caractéristiques détaillé plus loin.

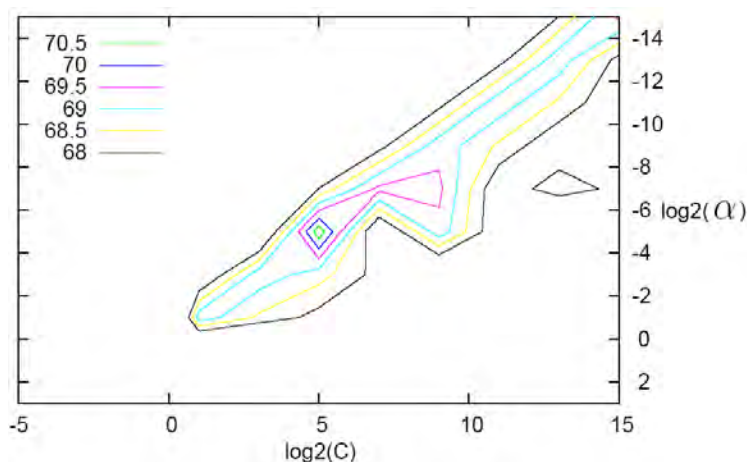


Figure 3.13 – Réglage des hyper-paramètres (C et γ) du SVM avec un noyau gaussien RBF : cas du meilleur taux de classification de 71% obtenu sur la base d'apprentissage pour $C = 32$ et $\alpha = 0.031$.

Notons que les hyper-paramètres ont été réglé uniquement sur cette dernière combinaison de descripteurs.

Les SVM sont des méthodes de classification qui offrent de bonnes performances dans la résolution de problèmes variés, en traitement d'image, pour la catégorisation de textes ou le diagnostic médical, grâce à leur capacité de généralisation. Nous avons donc adopté les SVM comme technique de classification dans notre application. Ils seront mis en oeuvre sur les vecteurs de caractéristiques calculés sur nos échantillons tissulaires expertisés par des médecins. Pour vérifier la suprématie de cette technique sur notre base d'images, nous la comparons ici à d'autres méthodes moins avancées, supervisées (k-ppv et Fuzzy k-ppv) et non supervisées (K-Means) présentées ci-dessous.

3.4.3 Méthode des k plus proches voisins (k-ppv)

C'est la méthode de classification supervisée non paramétrique⁷ la plus simple, dont le principe est le suivant : l'ensemble des données d'apprentissage inspire directement la construction du modèle des différentes classes. Pour classer une donnée

⁷On peut distinguer les méthodes paramétriques qui modélisent les données par un ensemble de paramètres à estimer, des méthodes non paramétriques qui ne font pas d'hypothèse sur la nature de la distribution de ces données.

de test, il suffit de calculer la distance entre cette donnée et l'ensemble des données d'apprentissage, puis d'effectuer un vote majoritaire parmi les k données les plus proches, chacune des données votant pour la classe à laquelle elle appartient. Le seul paramètre qu'il est nécessaire de fixer est donc le nombre k de voisins à considérer pour prendre la décision. Dans la plupart des cas, plus la valeur de k est grande, plus l'influence du bruit des données d'apprentissage est réduite. Une validation croisée⁸ lors des expérimentations peut être utilisée pour déterminer la valeur de k .

La distance la plus couramment utilisée est la distance euclidienne mais il est possible d'en utiliser d'autres comme celle de Hamming ou de Mahalanobis [Chou, 1995]. L'avantage de ce classifieur est qu'il ne nécessite pas de phase d'apprentissage puisque chaque fois qu'un nouvel échantillon on calcule les distances entre ses éléments et le nouveau point. L'algorithme k -ppv est très simple à mettre en place mais il est relativement lent, puisqu'il doit calculer toutes les distances entre chaque point de la base et les éléments à classer. Les performances de la méthode k -ppv peuvent être sensiblement améliorées avec sa variante floue.

3.4.4 Méthode k -ppv floue (*Fuzzy k-ppv*)

La notion centrale dans la théorie de la logique floue est celle de coefficient d'appartenance d'un élément (vecteur) à un ensemble (classe). Ce coefficient peut prendre toute valeur entre 0 et 1, à condition que la somme des coefficients d'appartenance à toutes les classes vaille 1, alors que dans la logique classique l'appartenance à une certaine classe est binaire. Cette manière, beaucoup moins contraignante, de définir l'appartenance est mieux adaptée à la réalité physique, car le passage d'une forme à l'autre est souvent continu. La méthode de k -ppv flou de Keller [Keller et al., 1985] propose de calculer pour chaque point un degré d'appartenance du point inconnu, fonction des distances de X à chaque prototype X_j , selon la formule :

$$f_{C_i} = \frac{\sum_j u_{ij} d(X, X_j)^{\left(\frac{2}{1-m}\right)}}{\sum_{ij} u_{ij} d(X, X_j)} \quad (3.24)$$

où u_{ij} est le degré d'appartenance flou du point X_j à la classe C_i associé à chaque prototype, qui dépend d'un avis d'expertise, ou du voisinage appris du prototype. Dans le cas de k -ppv classique, u_{ij} vaut 1 ou 0 selon que le point appris X_j appartient ou non à la classe C_i . Le paramètre m dans l'équation précédente règle l'influence de la distance entre X et X_j . Lors du réglage de m , on peut différencier les cas suivants :

- $m < 1$: plus la valeur de m est petite, plus l'influence de la distance des échantillons sur la classification est grande. Pour $m \rightarrow 1$, l'influence augmente de façon exponentielle.

⁸Le protocole consiste à répéter n fois la même expérience avec des données d'apprentissage différentes pour différentes valeurs de k et à choisir la valeur de k correspondant à la meilleure configuration en moyenne.

- $m > 1$: plus la valeur de m est grande, plus l'influence de la distance des échantillons sur la classification est petite. Pour $m \rightarrow 3$, l'influence diminue de façon exponentielle.
- si $m \rightarrow \infty$, on tend vers le k-ppv classique.

Il faut souligner ici que l'algorithme k-ppv flou possède des avantages par rapport à l'algorithme k-ppv, du fait qu'il est capable de prendre en considération la nature ambiguë des voisins d'un échantillon test, afin de déterminer son appartenance, de telle sorte que ces voisins ambigus ne jouent pas un rôle crucial dans la décision. En outre, le k-ppv flou assigne pour chaque région une valeur ou un coefficient d'appartenance à chaque classe, plutôt qu'une décision binaire. Par exemple, pour une région avec un coefficient d'appartenance de 0.9 à la classe "bourgeon" et 0.05 pour les deux autres classes (fibrine et nécrose), celle-ci peut être attribuée à la classe bourgeon avec un degré de confiance élevé. Si les coefficients sont respectivement 0.5, 0.45 et 0.05 pour les classes bourgeon, fibrine et nécrose, il est incertain que la région candidate appartienne à la classe de bourgeon.

Enfin, l'inconvénient majeur de cette famille de classifieurs réside dans la multiplicité des calculs pour comparer un élément à toutes les instances d'exemples. Le choix initial du nombre k et d'une mesure de distance constitue également une difficulté. Nous avons testé ces deux méthodes sur nos images afin de classifier les zones tissulaires dans l'image en quatre classes. La distance euclidienne a été utilisée et la valeur de k a été définie par un test de validation croisée (meilleur réglage pour $k = 5$).

3.4.5 Méthode des K-Means

La méthode des K-means est une des techniques de classification non supervisée dites de *clustering*, les plus utilisées notamment en reconnaissance de formes. En considérant le nombre K d'ensembles connus a priori, elle permet de générer itérativement une partition de l'espace de données qui est définie par la position des centres des différents ensembles. Ces positions sont obtenues en minimisant les variances moyennes de tous les points appartenant aux K ensembles. L'algorithme K-Means requiert donc comme paramètres d'entrée, le nombre de classes et le nombre d'itérations. La grande popularité de K-means vient de sa simplicité conceptuelle, de sa rapidité et de ses faibles exigences en taille mémoire. K-means est une technique objective, ce qui veut dire qu'elle minimise la valeur d'un certain critère numérique lorsqu'elle ne peut plus le faire baisser. Cependant, il est tout à fait possible qu'une autre configuration des prototypes conduise à des valeurs encore plus faibles du critère.

Nous avons testé l'algorithme K-means, avec la distance euclidienne comme critère, pour classifier l'ensemble des vecteurs de caractéristiques de tissus en quatre classes. L'intérêt de cet algorithme est d'observer le comportement d'une approche non supervisée sur des données supposées être très bruitées, afin de justifier le choix d'un apprentissage supervisé.

3.5 Études expérimentales

Nous avons présenté au cours des paragraphes précédents différents types de descripteurs qui ont été calculés sur nos régions pré-segmentées automatiquement. L'approche supervisée adoptée pour l'étape de classification a aussi été présentée. Nous allons présenter dans cette partie les différents tests effectués lors de la mise en oeuvre du classifieur.

3.5.1 Génération du vecteur de caractéristiques

Pour chaque groupe de descripteurs calculés (voir §3.2.3), nous avons divisé les données en deux ensembles égaux (apprentissage et test) pour juger de leur pertinence en vue de la classification en différents types de tissu par un classifieur C-SVM avec un noyau perceptron. Notre processus expérimental a consisté à diviser aléatoirement la base d'échantillons en deux ensembles (apprentissage et test), puis à itérer l'opération 10 fois et à moyenner les résultats afin d'évaluer globalement la pertinence des descripteurs. Le Tableau 3.5 présente l'évaluation des descripteurs considérés. Cette évaluation contient la valeur moyenne de Se, Sp, T et de P, le nombre de vecteurs de support (SV) obtenu et le temps d'apprentissage (TA).

Descripteurs	Se (%)	Sp (%)	T (%)	P (%)	SV	TA (sec)	
Couleur	<i>h-RGB</i>	58	87	72	80	290	0.6
	<i>h-LAB</i>	66	87	76	82	295	1.56
	<i>h-HSV</i>	62	87	75	81	288	1.99
	<i>h-rgb</i>	57	86	72	80	287	1.60
	MCD-DCD	67	89	78	84	256	0.41
Texture	<i>h-LBP</i>	30	78	54	66	319	5.3
	<i>m-LBP</i>	29	77	53	66	323	1.5
	GLCM	54	82	68	72	285	0.48
	<i>GAB</i>	47	81	64	71	275	1.6
	<i>AC</i>	32	79	55	68	250	0.23

Tableau 3.5 – Evaluation de la pertinence des descripteurs de couleur et de texture.

Plusieurs remarques peuvent être faites sur ces derniers résultats :

- les descripteurs de couleur sont généralement plus pertinents que ceux de texture pour identifier le type de tissus d'escarre. Une raison pour cela est que l'apprentissage du classifieur SVM a été réalisé à l'aide des labellisations des experts, plus sensibles à la couleur des tissus pour établir leur diagnostic qu'à la texture elle-même.
- malgré un nombre très faible d'attributs, le MCD-DCD fournit la meilleure classification des régions parmi tous les descripteurs de couleur. L'augmentation du nombre de caractéristiques n'améliore pas systématiquement la qualité

de l'apprentissage ce qui témoigne de corrélation entre les descripteurs. Cette augmentation risque donc d'accentuer la redondance et d'augmenter par la suite le temps de calcul comme dans le cas des histogrammes 256-HSV et 256-LAB.

- du fait que les images de notre base ont été corrigées chromatiquement, l'espace RGB-normalisé, réputé stable avec des changements d'éclairage, ne s'est pas révélé plus performant que le RGB standard.
- en ce qui concerne les descripteurs de texture, les meilleurs résultats sont obtenus avec la GLCM. Cela peut être expliqué par le fait que la texture des tissus n'a pas de caractère périodique ni directionnel. Aussi une simple évaluation quantitative de la distribution des niveaux de gris dans les trois plans R, G et B, par le calcul des attributs issus de la GLCM, suffit à décrire la texture des tissus.
- en ce qui concerne le nombre de vecteurs de support (SV) obtenus lors de l'étape d'apprentissage, le nombre de SV moyen obtenu avec les descripteurs de texture est légèrement supérieur à celui obtenu lors de l'apprentissage avec les attributs de couleur à l'exception du cas de AC, où le vecteur de caractéristiques contient seulement deux attributs.
- puisque le nombre de données, ainsi que la dimension du vecteur de caractéristiques sont relativement faibles, nous avons un temps d'apprentissage qui varie de 0.23 pour AC avec une dimension de 2 à 5.3 sec pour $h - LBP$ de dimension 256, ce qui semble cohérent.

Suite aux derniers tests d'évaluation des différents descripteurs, nous pouvons faire une sélection qui combine des descripteurs de couleur et de texture avec les meilleurs résultats. La combinaison de MCD-DCD avec la GLCM n'est pas forcément la plus discriminante par suite de corrélation, nous avons testé toutes les combinaisons possibles. Au final, notre système d'identification des régions de tissu pré-segmentées peut se résumer à :

- un modèle de classifieur : C-SVM avec un paramètre de pénalisation $C=100$ et un noyau perceptron
- un vecteur de descripteurs : 23 attributs de couleur et de texture issus de MCD-DCD et GLCM.

Il rest à comparer notre classifieur avec d'autres méthodes de classification afin de prouver sa supériorité.

3.5.2 Comparaison du SVM à d'autres classifieurs

Les résultats obtenus avec notre classifieur ont été comparés aux méthodes classiques présentées plus haut dans le chapitre : le k-ppv et k-ppv flou (méthodes supervisées) et k-means (méthode non supervisée). Le test de comparaison a été réalisé en parallèle pour les trois méthodes (k-ppv, k-ppv flou et SVM) dans les mêmes conditions, du fait que la base globale de caractéristiques est divisée de manière aléatoire

en deux ensembles (apprentissage et test) pour programmer les trois classifieurs⁹. On rappelle que ce test a été répété 10 fois, afin d’obtenir des résultats moyennés. En ce qui concerne le K-means, puisque ce classifieur ne nécessite pas d’étape d’apprentissage, il a été exécuté en parallèle avec les autres mais seulement sur la base de test, la base d’apprentissage étant ignorée.

<i>Algorithme</i>	<i>Se (%)</i>	<i>Sp (%)</i>	<i>T (%)</i>	<i>P (%)</i>
<i>k-ppv</i>	63	86	75	80
<i>k-ppv flou</i>	66	87	77	81
<i>k-means</i>	39	77	58	68
<i>SVM</i>	72	90	81	85

Tableau 3.6 – Comparaison des résultats des différentes méthodes de classification.

A partir de ces derniers résultats, on peut faire plusieurs observations. Premièrement, on constate l’inefficacité d’un apprentissage non-supervisé pour classifier les zones tissulaires d’escarre en quatre classes différentes. Même si une autre méthode non-supervisée plus évoluée pourrait donner des résultats supérieurs, on reste convaincu que l’approche supervisée est le choix judicieux pour ce genre de problème. Deuxièmement, le classifieur k-ppv flou fonctionne mieux sur notre base d’échantillons avec une sensibilité moyenne de 66% contre 63% pour le k-ppv. Enfin, le pouvoir discriminant du SVM révèle remarquable, grâce à sa capacité de généralisation par rapport aux autres méthodes.

3.5.3 Rééchantillonnage des données

Au paragraphe §3.3, plusieurs algorithmes de sélection/extraction des caractéristiques ont été présentés, en laissant de côté la mise en oeuvre et les discussions potentielles. Nous présentons maintenant ces aspects avec le traitement de nos données afin de déterminer leur impact sur la classification. Étant donné que le processus d’apprentissage devient plus lourd quand les données sont bruitées ou mal conditionnées, nous avons jugé pertinent de combiner la puissance d’une méthode de classification comme SVM à une étape préliminaire d’analyse de données. Le processus est le suivant : d’abord, il faut générer un vecteur de $p = 23$ attributs de couleur et de texture par échantillon pour l’ensemble de $n = 600$ échantillons, ranger tous les vecteurs dans une matrice de données de taille $n \times p$ et enfin normaliser les données. Les données de la base initiale vont être analysées afin d’être ré-échantillonnées, pour former une nouvelle base. Nous avons expérimenté plusieurs techniques d’analyse (ADL, ACP, ACI) sur nos données et évalué leur impact respectif sur les performances du classifieur.

Lors de l’application de l’ACP, une fois la matrice de covariance générée sur les données brutes, il suffit d’en rechercher les vecteurs propres associés aux valeurs

⁹En fait, les classifieurs k-ppv et k-ppv flou ne comportent pas vraiment de phase d’apprentissage mais juste une base d’exemples. Dans ce test, la base d’apprentissage du SVM s’identifie à la base d’exemples du k-ppv et k-ppv flou.

propres de plus fort module pour déterminer les composantes principales du modèle optimal. La première composante représente en fait l'axe de rotation autour duquel le nuage de points a la plus faible inertie, donc celui qui explique le mieux la dispersion des échantillons. En étendant le raisonnement au sous espace orthogonal, on obtient la seconde composante etc. Au final, après la projection des données brutes, p' composantes principales sont obtenues en ordonnant les vecteurs propres selon l'ordre décroissant des valeurs propres. Le nombre p' a été fixé à 8 composantes¹⁰.

De façon similaire, nous avons appliqué l'analyse ADL afin de trouver l'hyperplan optimal des variables par des combinaisons linéaires des variables initiales. La seule différence vient du fait que l'analyse ADL est une analyse supervisée qui suppose la connaissance de la classe d'appartenance, impliquant de fournir les étiquettes des échantillons de la base d'apprentissage.

En ce qui concerne l'ACI, nous avons utilisé la fonction de contraste *pow3* proposé dans l'algorithme FastICA [Hurri, 2005] pour estimer les composantes indépendantes, en maximisant la non-gaussianité des données initiales. En fait, contrairement à l'ACP, où les composantes principales sont ordonnées en fonction du module de la variance, l'ACI ne fournit pas de rang aux composantes indépendantes à extraire. Ce qui veut dire que les composantes indépendantes produites ne sont pas ordonnées par leur pouvoir explicatif. Par conséquent, pour avoir une réduction de dimensionalité lors de l'analyse par l'ACI, il faut la coupler avec l'ACP.

Les variables discriminantes du nouvel espace de projection linéaire obtenu par ADL, les composantes principales issues de l'analyse par ACP et les composantes indépendantes résultant de l'étape d'ACI vont structurer la nouvelle base d'apprentissage du SVM. En effet, le SVM va rechercher une frontière de décision linéaire entre deux classes mais on améliore ses performances en augmentant la séparabilité des échantillons. Nous pouvons alors effectuer l'apprentissage dans ce nouvel espace, dessinant une frontière de décision non linéaire dans l'espace initial. Nous avons donc implémenté quatre méthodes hybrides (ADL, ACP, ACI et ACP/ACI) sur le même vecteur de caractéristiques, afin de mesurer leur effet des ces méthodes sur l'efficacité du classifieur. On rappelle que le vecteur de caractéristiques utilisé dans ces tests est celui obtenu par la meilleure combinaison de 23 attributs de couleur et de texture (MCD-DCD + GLCM) avec le même protocole de test que précédemment. Les mesures de performance de chaque méthode sont données dans le Tableau 3.7.

Plusieurs remarques peuvent être faites sur les résultats obtenus :

- plutôt que de simplifier la tâche de séparation du SVM, l'étape ADL semble la compliquer. Cette inefficacité est surtout liée au mélange très important des classes de données non-linéairement séparables. L'utilisation de cette mé-

¹⁰Le nombre de composantes principales est choisi comme égal aux p' vecteurs propres tel que le rapport d'énergie $\sum_{i=1}^{p'} \lambda_i / \sum_{i=1}^p \lambda_i$ soit proche de 1, où λ_i désigne une valeur propre et p le nombre de variables initiales.

<i>Approche</i>	<i>Réduction de dimension</i>	<i>Se(%)</i>	<i>Sp(%)</i>	<i>T(%)</i>	<i>P(%)</i>
<i>sans conditionnement</i>	Non	72	89	81	85
<i>ADL</i>	Oui (à 8)	70	89	79	85
<i>ACP</i>	Oui (à 8)	73	90	82	86
<i>ACI</i>	Non	75	91	83	87
<i>ACP/ACI</i>	Oui (à 8)	77	92	84	88

Tableau 3.7 – Comparaison de différentes méthodes d'analyse de données, combinées avec une étape de classification supervisée.

thode d'analyse est surtout fiable dans des applications où il n'y a pas un mélange important entre les classes, Or, pour des applications telle que l'évaluation des tissus cutanés, cette approche n'est pas complètement valide car certains nuages de points sont partiellement mélangés. La Figure 3.9 donne un exemple où l'analyse discriminante non-linéaire serait plus appropriée.

- des améliorations ont été apportées aux résultats de classification SVM par ACP et ACI avec une supériorité en faveur de l'ACI, ce qui peut s'expliquer par le fait que nos données ont plutôt une distribution non-gaussienne. La réussite d'une méthode dans un problème donné est liée à la nature des données, car pour des données gaussiennes, l'analyse ACI serait peu pertinente.
- un couplage des méthodes dans une approche hybride combine l'efficacité de séparation des composantes par ACI couplée avec la capacité de réduction de dimensionalité de ACP sans perte d'information. Cette approche se révèle efficace, obtenant meilleures mesures de performance.
- en ce qui concerne le temps d'analyse rajouté à l'apprentissage SVM, il est relativement faible (4 secondes pour ACI) et quasiment nul pour ACP et ADL.

3.5.4 Autres critères d'évaluation du système

3.5.4.1 Evaluation par les coefficients de Kappa

Afin de valider notre approche de classification des tissus de plaies chroniques, nous devons évaluer les résultats obtenus avec des méthodes reconnues en milieu clinique. Disposant d'une référence (vérité terrain), il est courant d'évaluer la qualité d'une méthode de diagnostic au moyen des sensibilité, spécificité et des valeurs prédictives comme nous l'avons déjà présenté. D'autres outils d'évaluation sont aussi répandus dans le domaine médical et biologique : les coefficients de Kappa [Cohen, 1960], [Laplanche et al., 1987], [Reed, 2000].

Par définition, le coefficient de Kappa K est un indice statistique variant entre 0 et 1, utilisé notamment pour évaluer le degré d'accord constaté entre deux juges, évaluateurs ou observateurs, quant à la manière de classer un ensemble d'individus ou d'objets dans un certain nombre de catégories définissant les modalités d'une variable nominale. Le coefficient Kappa se calcule en appliquant la formule suivante (avec P_o la proportion d'accord et P_e la proportion de cas où, selon la théorie des probabilités,

on peut parvenir à un accord avec des réponses aléatoires) :

$$K = \frac{P_o - P_e}{1 - P_e} \quad (3.25)$$

Pour mieux comprendre l'évaluation par le coefficient Kappa, nous l'avons appliqué à la matrice de confusion résultant de la classification d'un ensemble de 327 régions pré-segmentées selon l'approche (ACP/ACI/SVM). Les résultats sont donnés ci-dessous :

Classification automatique	Labellisation experts					
	Classe de tissus	<i>Bourgeon</i>	<i>Fibrine</i>	<i>Nécrose</i>	<i>Peau saine</i>	Total
	<i>Bourgeon</i>	62	4	01	14	81
	<i>Fibrine</i>	4	44	3	17	68
	<i>Nécrose</i>	0	2	28	1	31
	<i>Peau saine</i>	10	14	4	119	147
	Total	76	64	36	151	327

Tableau 3.8 – Matrice de confusion : classification automatique / expert.

A partir des deux étiquetages pour chaque échantillon de tissu, on a :

$$\begin{cases} P_o = (1/327) * (62 + 44 + 28 + 119) = 0.7737 \\ P_e = (1/327^2) * (81 * 76 + 68 * 64 + 31 * 36 + 147 * 151) = 0.3163 \\ K = 0.7737 - 0.3163 / (1 - 0.3163) = 0.6690 \end{cases}$$

Suivant le classement de Landis et Koch [Landis & Koch, 1977] fréquemment utilisé en biologie, le Kappa de notre méthode de classification est considéré comme bon (Tableau 3.9).

Kappa (K)	Accord
≥ 0.81	Excellent
0.61 - 0.80	Bon
0.21 - 0.60	Modéré
0 - 0.20	Mauvais
< 0	Très mauvais

Tableau 3.9 – Valeurs de Kappa et degrés d'accord correspondants.

3.5.4.2 Evaluation par les scores de recouvrement

Tous les tests d'évaluation précédents basés sur des mesures de sensibilité, spécificité, taux de réussite et taux global, traitent le problème d'un point de vue statistique, sans pondération suivant la surface ou la confiance dans la réponse du classifieur. Au final, la classification incorrecte d'une petite zone aura le même impact que celle d'une zone étendue, ce qui n'est judicieux d'une évaluation clinique. Dans

cette optique, nous avons proposé dans le deuxième chapitre un critère d'évaluation à l'aide d'une labellisation manuelle, que l'on a appelé "score de recouvrement", prenant en compte la surface des régions pour chaque type de tissu. Ce critère a été utilisé à deux reprises : une première fois pour calculer les répétabilités intra/inter experts et une deuxième fois pour évaluer notre méthode de segmentation, en comparant les scores de quatre algorithmes différents.

Nous avons appliqué ce critère au calcul des scores de recouvrement obtenus par le processus de classification automatique comparé à la vérité terrain des experts, sur une base d'un cinquantaine d'images d'escarres et pour chaque type de tissu. Le Tableau 3.10 présente les scores de recouvrement (SCR), comparés de nouveau aux dernières mesures d'évaluation, mais cette fois, pour chaque type de tissu.

<i>Classe de tissu</i>	<i>Se (%)</i>	<i>Sp (%)</i>	<i>T (%)</i>	<i>P (%)</i>	<i>SCR (%)</i>
<i>Bourgeon</i>	81	92	86	89	85
<i>Fibrine</i>	67	92	79	87	70
<i>Nécrose</i>	82	98	90	92	83
<i>Peau saine</i>	80	84	82	83	92
<i>Moyenne</i>	77	92	84	88	83

Tableau 3.10 – Scores de recouvrement obtenus pour chaque type de tissu (52 images), comparés aux différentes mesures d'évaluation

La comparaison entre les scores de recouvrement et les mesures de performance pour chaque type de tissu peut refléter la distribution des tailles de régions pré-segmentées et son effet sur le résultat final de classification. Une meilleure sensibilité (82%) est obtenue pour la nécrose. Cependant, le meilleur taux de recouvrement (92%) est obtenu pour la peau saine. Puisque le calcul du taux de recouvrement prend en compte la surface des tissus classifiés, cela s'explique par le fait que les régions de nécrose mal classifiées sont relativement grandes comparées à celles de peau saine. En ce qui concerne la fibrine, c'est le tissu avec les plus faibles sensibilités et taux de recouvrement. Les résultats des mesures de performance et de recouvrement sont proportionnels également pour le bourgeon.

D'un point de vue clinique, nous comparons les résultats de taux de recouvrement obtenus pour chaque type de tissu par notre approche automatique, avec ceux obtenus par les experts, déduits de la fusion de plusieurs labellisations manuelles (paragraphe §2.2.2). Les résultats montrent que l'algorithme atteint de meilleures performances qu'un expert donné du fait que les experts n'ont pas forcément un consensus très net sur la labellisation de la plaie (voir le Tableau 3.11).

Notons que le score de recouvrement pour le tissu "peau saine" ne figure pas dans le Tableau 3.11, car les experts n'ont pas établi de diagnostic sur les zones de peau saine lors de cette expérience. Cela a forcément influencé le résultat de taux moyen en faveur de l'algorithme du fait que la peau saine présente le taux de recou-

Classe de tissu	Experts	Algorithme
Bourgeon	64.1 %	85 %
Fibrine	62.1 %	70 %
Nécrose	81.1 %	83 %
Peau saine	–	92 %
Moyenne	69.1 %	83 %

Tableau 3.11 – Comparaison des taux de recouvrement obtenus par un expert donné et l'algorithme face à la vérité terrain élaborée par fusion des labellisations manuelles.

vrement le plus élevé. Les Figures 3.14 à 3.16 montrent des résultats de classification obtenus sur un exemple de plaie chronique typique.




Figure 3.14 – 1^{er} exemple de classification automatique, comparée à la vérité terrain. (a) image originale (b) classification automatique (c) vérité terrain.




Figure 3.15 – 2^{ème} exemple de classification automatique, comparée à la vérité terrain. (a) image originale (b) classification automatique (c) vérité terrain.

Plusieurs constatations peuvent être faites sur les résultats de classification dans les trois dernières figures : premièrement, la capacité de séparation des classes de tissus est stable sur les différents cas cliniques (escarre de sacrum, ulcère de jambe, escarre de malléole). Cette capacité n'a pas été affectée par la diversité de couleur de




Figure 3.16 – 3^{ème} exemple de classification automatique, comparée à la vérité terrain. (a) image originale (b) classification automatique (c) vérité terrain.

peau des patients. Notons que malgré les reflets présents sur la partie bourgeon dans la Figure 3.15, notre algorithme montre une bonne indépendance face aux variations d'éclairage. En fait, la présence de pixels trop saturés dans cette zone n'a pas empêché l'algorithme de la classer comme bourgeon. Enfin, l'efficacité remarquable de notre approche telle qu'illustrée les images des exemples précédents permet de la qualifier de robuste.

3.5.5 Quantification de certaines influences sur la classification

Après l'évaluation de l'impact des descripteurs sur les performances du classifieur, l'optimisation complète de notre système doit prendre en compte l'influence des autres étapes de la chaîne de traitement, c'est à dire celles de la méthode de correction couleur, de l'algorithme de segmentation et de sa paramétrisation (effet de la sur-segmentation).

3.5.5.1 Influence de la correction colorimétrique des images

Lorsque notre méthode de correction colorimétrique a été présentée au Chapitre 2, l'évaluation s'est basée sur le calcul de la distance $CIE\Delta E_{ab}$ dans l'espace uniforme CIELAB sur les carreaux de la mire présente dans l'image, entre celles de référence et les valeurs mesurées. Nous avons démontré une bonne stabilité colorimétrique sur nos images avec cette correction, sans mesurer son influence sur les résultats finaux de classification. Nous avons donc exécuté toute la chaîne de traitement d'images (segmentation + apprentissage + classification) sur notre base d'images, sans correction puis avec correction. Les résultats obtenus sont présentés dans le Tableau 3.12.

L'apport de la correction colorimétrique est très important et son effet est particulièrement remarquable dans le tableau 3.12 sur les résultats de classification des tissus de fibrine et de nécrose, les deux tissus les plus sensibles aux dérives colorimétriques. La Figure 3.17 illustre cet effet sur un exemple de classification.

On constate l'effet de l'absence de correction de l'éclairage sur la réaction du classifieur : des zones Bourgeon classifiées comme Fibrine et des zones Fibrine au

Classe de tissu	Sans correction	Avec correction
Bourgeon	85 %	85 %
Fibrine	52 %	70 %
Nécrose	50 %	83 %
Peau saine	84 %	92 %
Moyenne	67 %	83 %

Tableau 3.12 – Comparaison des taux de recouvrement obtenus sans correction puis avec correction colorimétrique des images.




Figure 3.17 – Effet de la correction sur le résultats de classification (a-b) image sans correction avec la classification correspondante (c-d) l'image corrigée avec la classification correspondante.

milieu de la zone lésé n'ont pas été identifiées par le classifieur en tant que zone lésée. L'étape de correction a rendu toutes ces zones identifiables.

3.5.5.2 Influence de l'algorithme de segmentation

Dans le Chapitre 2, nous avons présenté quatre méthodes de segmentation en régions, comparé qualitativement leurs résultats sur nos images puis évalué leur performance par le calcul du taux de recouvrement pour chaque type de tissu afin de sélectionner la plus adaptée. Le taux de recouvrement a été calculé avant classification après une labellisation des régions segmentées, avec le tissu majoritairement présent dans la vérité terrain. On a pu ainsi évaluer le taux de classification maximal que l'on

obtiendrait en classant correctement des régions plus au moins bien délimitées par la pré-segmentation. Après avoir implémenté notre classifieur, nous avons pu quantifier leur impact sur la qualité de la segmentation et quantifier leurs influences sur la classification en mesurant les taux de recouvrement obtenus avec les quatre algorithmes et pour chaque type de tissu. Afin de réaliser cette évaluation, nous avons recomposé toute la chaîne de traitement séparément pour chaque algorithme de segmentation. Nous entendons par chaîne de traitement, la segmentation des régions, la labellisation manuelle, l'extraction des descripteurs et enfin la classification des régions par SVM. Les résultats d'évaluation obtenus par les quatre algorithmes confirment notre évaluation préliminaire, en favorisant l'algorithme JSEG, comme le montre le Tableau 3.13.

<i>Classe de tissu</i>	<i>JSEG</i>	<i>Mean Shift</i>	<i>CSC</i>	<i>EGBIS</i>
<i>Bourgeon</i>	85 %	77 %	61%	26%
<i>Fibrine</i>	70 %	75 %	69%	59%
<i>Nécrose</i>	83 %	72 %	24%	34%
<i>Peau saine</i>	92 %	86 %	70%	66%
<i>Moyenne</i>	83 %	77 %	60.0%	46.1%

Tableau 3.13 – Comparaison des taux de recouvrement des 4 algorithmes de segmentation testés.

Les résultats obtenus montrent la supériorité de l'algorithme JSEG, suivi par Mean Shift. En les comparant, on constate que ce ne sont pas les mêmes classe de tissu qui sont les mieux identifiées (Bourgeon et Nécrose pour JSEG, Bourgeon et Fibrine pour Mean Shift). Bien que le choix des descripteurs et le réglage du modèle de classification jouent un rôle important pour l'efficacité du classifieur, le taux de réussite de la classification est contraint avant tout par la pertinence de la segmentation.

3.5.5.3 Influence du nombre de régions segmentées

L'effet important de la taille des régions¹¹ a déjà été évoqué lors de la comparaison des taux de recouvrement avec les mesures de performance. Nous avons donc décidé de quantifier cette influence. Nous avons effectué une série de 5 tests de segmentation avec l'algorithme JSEG, correspondant respectivement à une sous-segmentation, une sur-segmentation et trois segmentations intermédiaires. Les différents résultats de segmentation ont été obtenus par le réglage progressif des deux principaux paramètres de l'algorithme JSEG, le seuil d'homogénéité m et le seuil de quantification q présentés dans le Chapitre 2.

Là encore, il faut réactiver toute la chaîne de traitement d'images pour chacune des 5 segmentations. Le seul problème a été de fournir une labellisation manuelle par des experts pour chaque segmentation afin de fournir une vérité terrain correspondant à chaque segmentation, qui sert ensuite pour l'extraction d'échantillons de

¹¹Les tailles des régions segmentées et le nombre des ces régions sont généralement liés et ce sont des indices d'une sur/sous-segmentation

tissus. Notons que cela représente une tâche très fastidieuse pour les experts, surtout pour les images sur-segmentées, ce qui n'était finalement pas possible. Nous avons contourné ce problème par une labellisation des régions des 5 nouvelles segmentations en attribuant à chaque région l'étiquette majoritairement représentée dans la labellisation fournie par les experts à partir de tracés libres sur ordinateur, élaborant ainsi une vérité terrain pour chaque nouvelle segmentation (Figure 3.18).




Figure 3.18 – Labellisations manuelles des régions segmentations, élaborées en se basant sur la vérité terrain fournie par des experts. Ici, on affecte à chaque région l'étiquette majoritairement représentée dans la labellisation.

Le nombre de régions segmentées obtenues pour chaque réglage est respectivement de 351, 533, 670, 1009 et 1500. Nous avons dans chaque cas recalculé les vecteurs de caractéristiques, divisé la base en deux ensembles égaux pour l'apprentissage et le test et utilisé notre classifieur. Les différentes mesures de performance obtenues pour les 5 tests sont présentées dans l'histogramme de la Figure 3.19.

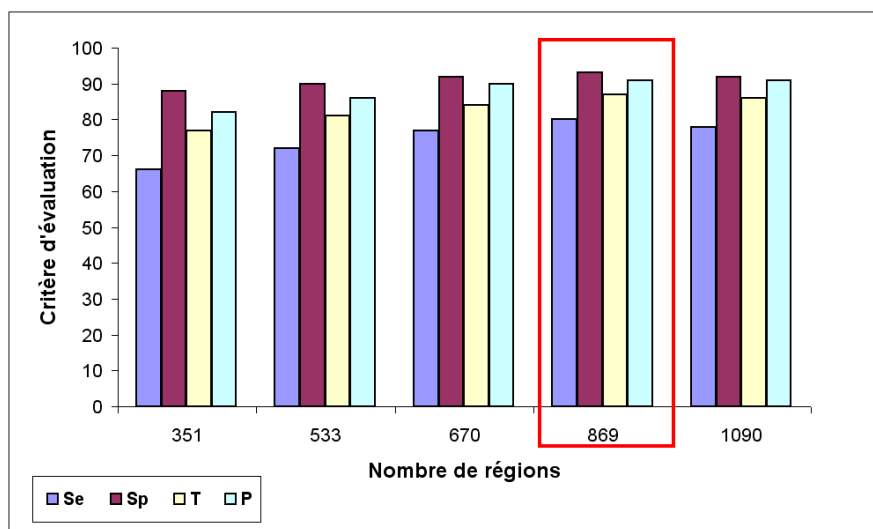


Figure 3.19 – Influence de la sur-segmentation sur les résultats de classification : évaluation par les mesures de Sensibilité (Se), Spécificité (Sp) et Précision globale (P)

On remarque que l'efficacité du système augmente avec le nombre des régions segmentées, mais à un certain niveau de sur-segmentation, quand la taille des régions devient très petite, cette efficacité régresse. Donc, il s'avère judicieux de viser une légère sur-segmentation plutôt que d'avoir une sous-segmentation. Cela reste valable jusqu'à un certain niveau où la taille minimale d'une région interdit toute mesure statistique pertinente. Le seuil de sur-segmentation de notre algorithme a été réglé de façon empirique sur notre base d'images. Expérimentalement, un seuil de sur-segmentation de régions de 50 pixels (échantillons $\geq 1cm^2$) fournit un bon compromis.

3.6 Conclusion

Dans ce chapitre, nous avons présenté un processus de classification tissulaire appliqué à l'évaluation de l'état cutané des plaies chroniques. Ce processus a été décomposé en trois étapes : extraction des données caractérisant les zones tissulaires, analyse et ré-échantillonnage de données et identification des zones par étiquetage avec quatre classes de tissus. Pour l'extraction des données caractérisant les échantillons, nous avons testé plusieurs descripteurs de couleur et de texture afin de sélectionner la combinaison optimale. Ensuite, l'analyse des données et la réduction de leur dimension ont été effectuées par des méthodes de discrimination. Enfin, la phase de classification a été abordée et un classifieur SVM a été conçu après le réglage des paramètres pour le classifieur du noyau le plus adapté à nos données.

Lors de la phase d'expérimentation, nous avons mis en compétition les différents descripteurs de couleur puis de texture et la combinaison optimale a été choisie pour décrire nos régions pré-segmentées. Nous avons aussi comparé la performance de notre approche à celle d'autres méthodes supervisées et non supervisées. Plusieurs types d'évaluation vérifiées par les labellisations des experts, ont confirmé l'efficacité et la robustesse de notre classifieur.

Classification tissulaire multi-vues

Ce chapitre aborde l’approche multi-vues intégrant la reconstruction 3D et la classification colorimétrique des tissus. Nous introduisons dans la première partie la technique de reconstruction tridimensionnelle non calibrée, qui permet de générer un modèle 3D de la plaie à partir de deux vues prises à main levée avec un APN. Nous présentons ensuite la méthodologie de labellisation multi-vues employée, la stratégie de fusion des labellisations et les différents tests d’évaluation, en mettant l’accent sur les apports qualitatifs et quantitatifs de cette approche pour le processus de suivi des plaies, par rapport au cas mono-vue, avant de conclure.

Sommaire

4.1	Introduction	114
4.2	Génération du modèle 3D à partir de 2 vues	115
4.3	Labellisation multi-vues	117
4.3.1	Homogénéité des facettes	119
4.3.2	Angle solide issu de la caméra	120
4.3.3	Probabilité d’appartenance à une classe	122
4.3.4	Stratégie de fusion	123
4.4	Evaluation multi-vues	125
4.4.1	Stabilité des labellisations 3D	126
4.4.2	Stabilité de la classification	128
4.4.3	Comparaison des surfaces 2D / 3D	128
4.5	Apports de l’approche multi-vue	130
4.5.1	Convergence du processus de classification tissulaire	130
4.5.2	Précision métrologique des relevés tissulaires	132
4.5.3	Robustesse au changement de point de vue	133
4.6	Conclusion	135

4.1 Introduction

Nous avons jusqu'à présent discuté de la classification tissulaire comme faisant partie d'un système automatique, ce qui représente déjà un réel progrès par rapport à un simple examen visuel, mais qui doit fournir des résultats reproductibles, indépendamment de la position et de l'orientation de l'APN. Or, un calcul des surfaces vraies n'est pas possible avec une seule image car les parties de l'escarre qui ne sont pas normales au plan de l'APN y paraissent plus petites. Des évaluations citées dans la littérature ont même montré qu'une déviation de seulement 20° par rapport à une vue frontale de la plaie entraîne un biais d'environ 10% sur la surface mesurée. Enfin dans les différents travaux, la segmentation/classification est généralement réalisée à partir d'une seule vue. Or un léger déplacement de point de vue provoque des déformations perspective et des variations d'éclairage qui suffisent à induire des biais non négligeables dans les résultats de classification.

A l'instar du clinicien, qui dispose d'une grande variété de points d'observation pour établir un diagnostic fiable, une technique multi vues doit permettre d'arriver à un résultat plus robuste. En s'appuyant sur la reconstruction 3D de la scène, l'idée est, à terme, de faire coopérer les informations couleur des régions, le calcul des points de vue et le relief dans la prise de décision pour d'une part obtenir une labellisation plus robuste et d'autre part accéder aux surfaces réelles.

Nous disposons déjà d'un modèle 3D de la plaie élaboré au sein du projet ESCALE. Par l'intégration des modes d'évaluation "coloriel" et 3D de l'état d'une escarre, il s'agit maintenant d'unifier la chaîne complète de traitement d'images des plaies chroniques, résumée par l'organigramme donné en Figure 4.1.

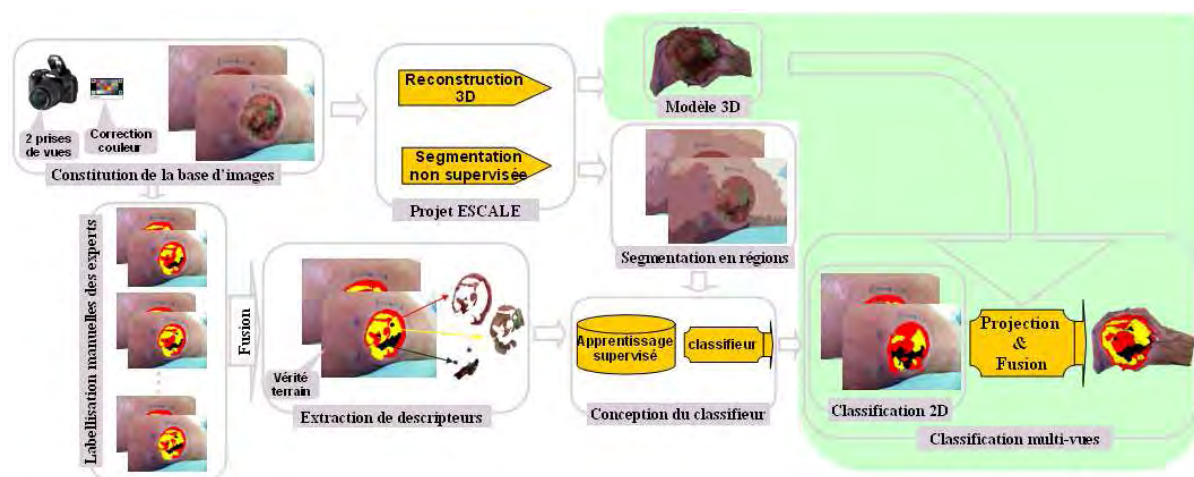


Figure 4.1 – Chaîne de traitement d'images pour l'évaluation 2D / 3D des escarres.

4.2 Génération du modèle 3D à partir de 2 vues

La reconstruction tridimensionnelle d'escarres a fait l'objet des travaux de la thèse de Benjamin Albouy ([Albouy, 2006]). Nous introduisons ici les grandes lignes de la chaîne de reconstruction d'un modèle 3D d'une plaie à partir de deux vues, pour mieux comprendre par la suite son utilisation dans la classification multi-vues.

Nous utilisons la stéréovision non calibrée comme technique de reconstruction : à partir de deux vues et sans autre information, il est possible de reconstruire un modèle de plusieurs milliers de points 3D de la plaie. Cette triangulation nécessite la mise en correspondance d'un grand nombre de points dans les deux images. L'extraction des points est réalisée en appliquant le détecteur de Harris et Stephen adapté à la couleur [Gouet, 2000]. Afin d'assurer une mise en correspondance 3D assez précise, les deux points de vue sont séparés par un angle relativement important (10° à 20°). Cet éloignement des points de vue nécessite par contre une mise en correspondance robuste et particulièrement performante pour générer un grand nombre de points appariés.

La mise en correspondance s'effectue en plusieurs étapes : une initialisation robuste sur une vingtaine des régions d'intérêt par le descripteur SIFT permet d'initialiser la matrice fondamentale. L'estimation de la matrice fondamentale repose sur des algorithmes sophistiqués RANSAC permettant de détecter les faux appariements ne respectant pas la contrainte épipolaire. Elle est suivie d'une étape de rectification qui facilite la mise en correspondance d'un grand nombre de points par application de la contrainte épipolaire ; enfin une dernière étape de multiplication des appariements est appliquée après des transformations locales dans les images.

Une fois la matrice fondamentale estimée, une étape d'auto-calibrage permet d'obtenir les paramètres intrinsèques de la caméra grâce aux équations de Krupa. Enfin, le calcul de la position des caméras permet le calcul des points 3D à partir de chaque appariement par triangulation.

Le modèle 3D ainsi généré est composé de 2500 à 3000 points triangulés sur une plaie à partir de deux images de taille 1024×768 pixels. Il est obtenu en moins de 2 minutes sur un PC standard (Pentium IV 3 GHz).

Une étude comparative a montré que cette technique de stéréovision non calibrée atteint des résolutions inférieures (facteur 10) aux scanners industriels mais avec un système de prise de vues très simple et assez rapide [Albouy et al., 2007]. Elle offre une précision de reconstruction à peine deux fois moins grande, avec une erreur résiduelle moyenne de 0.4 mm , soit environ 2.5% de la profondeur typique d'une escarre. Les tests ont démontré que les prises de vue en mode macro donnent des résultats plus stables et cohérents, en fournissant un plus grand nombre de points avec une meilleure stabilité de l'estimation de la matrice fondamentale et des erreurs résiduelles inférieures à 1 mm dans 95% des cas (Figure 4.2). Cela correspond

à un écart relatif sur la profondeur de 3.5% environ, une précision suffisante pour l'application visée.

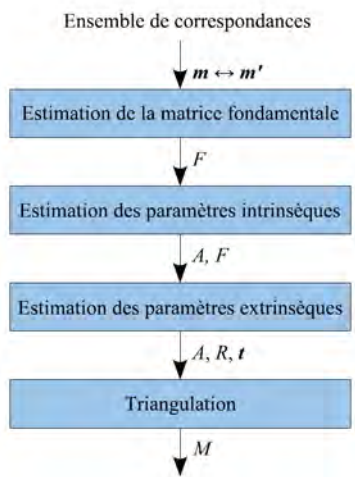


Figure 4.2 – (a) Chaîne de reconstruction 3D.

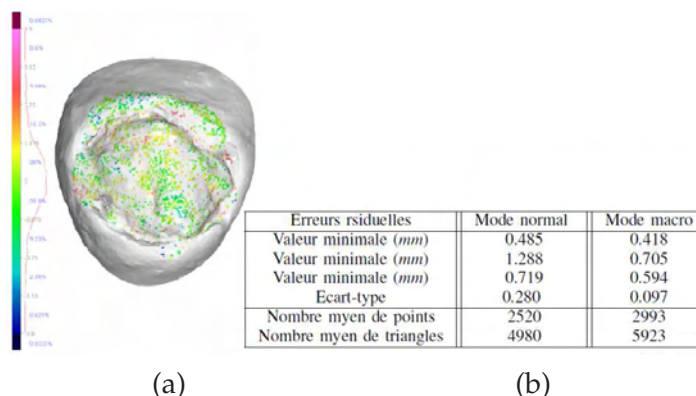


Figure 4.3 – Evaluation de la reconstruction 3D (a) cartographie des erreurs (en mm) après recalage des données 3D sur la surface de référence délivrée par un scanner industriel (b) données statistiques du contrôle dimensionnel sur une série de 10 reconstructions en mode normal puis en mode macro.

Ces résultats remarquables sont obtenus grâce à un protocole peu contraignant : une première vue frontale combinée à une seconde vue avec un angle de vergence de 10° à 30° et un recul d'environ 10% de la distance objet-caméra enfin d'éviter les singularités de l'auto-calibrage.

Après cette introduction sur la technique de reconstruction tridimensionnelle, nous allons présenter dans la suite du chapitre notre méthodologie de labellisation multi-vues. Elle tire profit de la correspondance géométrique des zones de l'escarre dans deux vues différentes, fournie par le modèle 3D, pour réaliser une classification tissulaire plus robuste, dite multi-vues.

4.3 Labellisation multi-vues

L'idée principale dans cette approche multi-vues est de fusionner sur le modèle 3D les classifications de tissus provenant de plusieurs vues pour parvenir à un résultat plus robuste. En effet, la géométrie épipolaire permet de mettre en relation dans les images les voisinages correspondant à une même facette du modèle 3D discret. Dans les travaux antérieurs, on se limitait à une analyse mono-vue (normale au plan moyen de bouchage de la plaie) puisqu'un relevé anatomique 3D n'était pas disponible.

Les résultats de classification obtenus pour chacune de deux images de la plaie prises à main levée de points de vue différents vont être fusionnés en s'appuyant sur le modèle 3D obtenu à partir de ces deux vues. Ce modèle étant constitué d'un maillage de facettes¹, chaque triangle homologue recouvre la même partie de l'escarre des deux images après projection dans le plan des images. En fait, lors de la fusion des labellisations des deux vues, on se trouve néanmoins face à des conflits de classification liés aux différences éventuelles entre les triangles homologues dans les deux images. Dans la Figure 4.4, nous avons projeté les facettes du modèle 3D sur la labellisation 2D des deux images afin de mieux illustrer les différents cas de correspondance entre triangles homologues. Lors de la comparaison des triangles dans les deux vues, on peut rencontrer plusieurs situations :

- les deux triangles sont labellisés par une seule et même classe dans les deux vues
- les deux triangles sont labellisés par une seule classe dans chaque vue mais différente pour chaque vue
- les deux triangles sont labellisés par une seule classe dans une vue et par plusieurs classes dans la deuxième vue
- les deux triangles sont labellisés par plusieurs classes dans chaque vue.

Dans le premier cas, le résultat de fusion immédiat est une facette labellisée avec la même classe, mais dans les trois autres cas, différents facteurs doivent être pris en compte pour opérer la fusion : la surface de la facette, l'angle de vue de la facette par rapport à la caméra (angle solide) et la probabilité d'appartenance du triangle à la classe attribuée lors de la classification mono-vue. Des tests liés à un ou à plusieurs de ces trois facteurs vont conduire la prise de la décision sur l'appartenance de la facette à une classe ou à plusieurs classes selon une stratégie de fusion présentée ci-dessus. Nous introduisons dans le paragraphe suivant les différents facteurs pris en compte lors de la fusion des labellisations sur le modèle 3D avant de détailler la stratégie de fusion regroupant tous ces facteurs.

¹On appellera par la suite "facette" un triangle du maillage 3D et "triangle" la projection de cette facette dans chaque plan image.

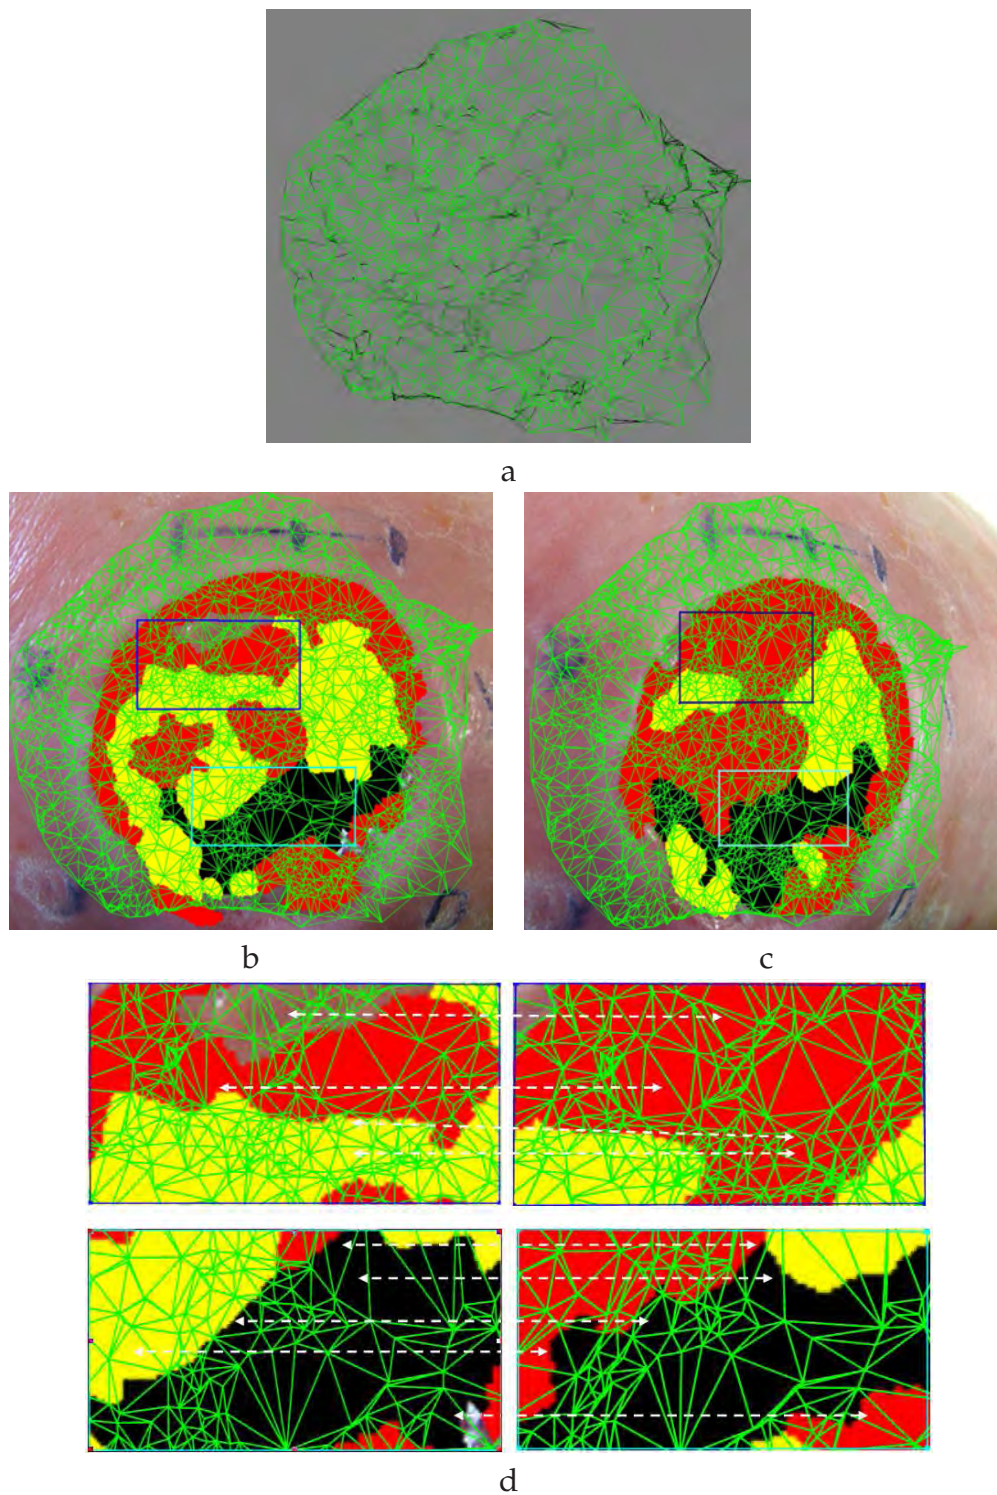


Figure 4.4 – Projection du maillage 3D sur la classification de deux vues. (a) modèle 3D reconstruit à partir de deux images (b-c) modèle projeté sur la classification des deux images (d) deux zones homologues sélectionnées illustrant la correspondance entre triangles homologues issus d'une même facette du modèle.

4.3.1 Homogénéité des facettes

Elle est obtenue par le découpage d'une facette dans la triangulation de Delaunay et revient à insérer un nouveau point de maillage à l'intérieur de la facette à découper. L'ajout d'un nouveau point dans le modèle 3D va rajouter simultanément un point dans chaque image. Deux modes de découpage ont été testés : le premier consiste à ajouter un point au centre de gravité de la facette pour générer trois sous-facettes. Le deuxième considère la droite qui relie le milieu de la plus grande arête au sommet opposé, découpant la facette en deux sous-facettes (Figure 4.5). Lors du découpage suivant le deuxième mode (que nous avons sélectionné), un nouveau point se rajoute aux points du modèle 3D et il faut donc projeter ce point dans les deux images pour former deux nouveaux sous-triangles. Afin de réaliser ces projections, nous utilisons les deux matrices de projection estimées pendant la phase de reconstruction 3D des prises de vues.




Figure 4.5 – Découpage des facettes en deux sous-facettes. (a-b) projection des facettes du modèle sur la classification des deux vues (c-d) découpage des triangles homologues labellisés par plusieurs classes dans les deux vues. Le découpage illustré ici est obtenu en deux itérations du processus.

L'objectif du découpage² est de rendre assez petites les facettes du maillage labellisées différemment dans les deux vues pour que deux triangles homologues d'une facette (ou sous-facette) dans ce maillage soient labellisés entièrement ou au moins majoritairement par une seule classe dans chaque vue. Le critère de découpage prend en considération la surface de la facette, appréciée relativement au parallélépipède englobant le nuage de points 3D du modèle. Si la surface de la facette en question est relativement grande, on peut se permettre de la découper et de calculer les pro-

²Cette technique de découpage évite d'avoir des sous-triangles de plus en plus pointus comme dans le cas du découpage en trois sous-triangles par le centre de gravité de la facette.

jections des nouveaux sommets de chacun des sous-triangles dans chaque vue. Après quelques itérations, on obtient dans chaque vue des triangles labellisés entièrement ou majoritairement par une seule classe. Notons que le problème de fusion ne sera résolu que partiellement par un découpage, puisque il existera toujours des triangles homologues labellisés différemment dans les deux vues. Il faut donc envisager d'autres critères de fusion pour ces triangles.

4.3.2 Angle solide issu de la caméra

L'analyse des couleurs et de la texture est très sensible à l'orientation de la facette et de plus, l'escarre n'étant pas une surface plane, l'appréciation visuelle est très dépendante de l'angle de vue. Partant de cette observation, lorsque deux nouveaux triangles homologues résultant du découpage sont labellisés différemment par la classification dans les deux vues, il est pertinent de donner la priorité au triangle vu sous le plus grand angle solide. Il convient donc de rappeler la notion d'angle solide et comment on calcule cet angle pour deux triangles homologues issus de la projection d'une facette du modèle 3D sur les deux plans image (Figure 4.6) : pour calculer l'angle solide sous lequel un APN observe une facette 3D de surface S , on projette la facette sur une sphère de rayon R centrée au centre optique (O).




Figure 4.6 – Projections d'une facette triangulaire du modèle 3D dans deux plans image. Les deux APN sont représentés par leur centres optiques O_1 et O_2 .

Pour une facette élémentaire de surface dS et dont la normale fait un angle α

avec la direction de l'observation \overrightarrow{OG} où G est le centre de gravité de la facette 3D, on a :

$$d\Omega = \frac{dS \cos(\alpha)}{R^2} \text{ avec } R = \|\overrightarrow{OG}\| \quad (4.1)$$

Pour comparer les angles solides issus des centres optiques O_1 et O_2 il suffit de mesurer les rayons $\|\overrightarrow{O_1G}\|$ et $\|\overrightarrow{O_2G}\|$ et de calculer les deux angles formés par ces deux vecteurs avec la normale³ \vec{N} de la facette. Donc, pour chaque facette en question, nous devons calculer :

$$d\Omega_i = \frac{dS \cos(\overrightarrow{O_i m_i}, \vec{N})}{\|\overrightarrow{O_i G}\|^2} = \frac{\overrightarrow{O_i m_i} \cdot \vec{N}}{\|\overrightarrow{O_i m_i}\| \cdot \|\vec{N}\|} \cdot \frac{1}{\|\overrightarrow{O_i G}\|^2} \text{ pour } i = 1, 2 \quad (4.2)$$

Pour calculer les deux angles solides associés à la visibilité d'une facette, il faut connaître la position des centres optiques des deux prises de vues. Or, ces paramètres sont obtenus directement lors de la reconstruction du modèle 3D. Si la différence entre les deux angles solides pour une facette donnée est très importante, cela signifie que l'appréciation visuelle d'un triangle dans l'une des vues est beaucoup plus fiable que dans l'autre et la décision de labellisation se fera en faveur du premier.

L'angle solide est un facteur important, fiable lorsque le modèle de reconstruction 3D est assez dense et peu bruité. A l'analyse de certains cas de reconstruction, nous nous sommes rendus compte que l'angle solide est sensible aux erreurs de localisation des points 3D qui perturbent l'orientation des petites facettes. Ceci impose une étape préalable d'ajustement du modèle par un filtrage.

4.3.2.1 Lissage du modèle 3D

Le lissage du modèle s'effectue par un filtrage passe-bas qui atténue les irrégularités ponctuelles dûes aux erreurs de reconstruction en lissant le modèle par un filtre laplacien. L'action de ce filtrage est une relaxation du maillage qui répartit plus régulièrement les sommets du maillage.

L'algorithme de filtrage est le suivant : pour chaque sommet S du modèle, une analyse topologique et géométrique est réalisée afin de déterminer les sommets voisins, et les facettes connectées à S . Ensuite, une matrice de connectivité contenant les listes des sommets voisins de chaque sommet est construite pour chaque sommet. Un processus itératif déplace les sommets, de sorte que les coordonnées de chaque sommet S soient modifiées selon la moyenne des sommets connectés. Un facteur de relaxation permet de contrôler l'amplitude du déplacement des sommets. La stabilité du processus est sensible à ce paramètre. En général, un filtrage avec un petit facteur de relaxation et un grand nombre d'itérations est plus stable que dans le cas inverse. Nous avons réglé empiriquement le processus de filtrage de notre modèle sur un nombre important de modèles pour limiter la perte d'information lors du filtrage.

³La normale d'un triangle ABC est donnée par l'expression : $\vec{N} = \frac{\overrightarrow{AB} \times \overrightarrow{AC}}{\|\overrightarrow{AB} \times \overrightarrow{AC}\|}$, où \times désigne le produit vectoriel. Lors du calcul de l'angle solide, seule l'orientation de la normale est utile.

Notons que le risque de perte d'information par filtrage est plus grand sur les zones peu maillées du modèle que sur les zones denses. La Figure 4.7 montre l'effet du lissage sur un modèle 3D d'une plaie reconstruite à partir de deux prises de vue.




Figure 4.7 – Lissage du modèle 3D par un filtre Laplacien avec un facteur de relaxation de 0.01 en 20 itérations. (a-b) deux vues d'une même plaie (c-d) maillage du modèle reconstruit de cette plaie, respectivement avant et après filtrage (e-f) triangulation de Delaunay correspondante avant et après filtrage.

4.3.3 Probabilité d'appartenance à une classe

Quand la différence entre les deux angles solides d'une facette n'est pas significative, le critère de l'angle solide n'est pas pris en compte et le score du classifieur sur les régions contenant les triangles dans les deux vues est alors considéré. Dans la plupart des classifieurs SVM multiclassés, on applique une règle de discrimination (*un contre un* ou *un contre tous*) la décision d'appartenance étant obtenue par un vote. La décision finale est exprimée seulement par l'étiquette d'appartenance à une des classes. Pendant la phase de classification mono-vue des tissus, nous avons utilisé un classifieur multiclassés SVM de type *un contre tous* basé sur les codes correcteurs d'erreurs définis dans un cadre probabiliste [Wu & Lin, 2004]. Cette approche consiste

à entraîner un classifieur correcteur à séparer chaque paire de classes $\{w_i, w_j\}$ sans considérer les autres classes pour estimer les probabilité $P_i(x \in w_i)$ et $P_j(x \in w_j)$. Nous estimons dans notre cas pour chaque échantillon de test, la probabilité d'appartenance de cet échantillon à chacune des quatre classes de tissu pour calculer un indice de confiance du classifieur. Lors de l'étape de classification d'une région test, la sortie du classifieur ne contient plus seulement l'étiquette de la classe de plus grande probabilité d'appartenance, mais plutôt quatre valeurs représentant ses probabilités d'appartenance à chacune des classes. Le triangle sera labellisé par l'étiquette de la région classifiée avec la probabilité la plus élevée.

4.3.4 Stratégie de fusion

Après avoir présenté tous à tous trois facteurs pour opérer la fusion des labellisations des deux vues, nous pouvons introduire la stratégie de fusion adoptée :

pour chaque facette du modèle 3D, la proportion de chaque type de tissu est calculée dans chacun des triangles homologues. Dans le cas où les deux triangles homologues ne contiennent qu'un seul et même type de tissu pour les deux images, la facette du modèle 3D est étiquetée par ce tissu. Dans le cas contraire, la facette est découpée par la médiane de son plus grand côté en deux sous-triangles. Le processus de découpage est récursif avec un critère d'arrêt lié à une surface minimale de la facette (seuil de découpage).

Notons que, la répartition des points 3D constituant le maillage triangulaire à la surface de la plaie n'est pas homogène. Résultant d'un processus d'appariement entre les points d'intérêt détectés dans l'image, ces points 3D sont fortement concentrés dans les régions texturées et épars dans les régions homogènes. En conséquence, la taille typique des triangles est variable sur le modèle 3D. A cette étape, si le découpage de la facette ne se traduit pas par des sous-triangles homologues homogènes, trois possibilités doivent être testées :

la première est d'appliquer le critère de classe dominante et d'attribuer cette classe dominante à la facette du modèle 3D, lorsqu'elle est commune dans les deux triangles homologues.

Dans le cas contraire, c'est à dire lorsque les classes dominantes sont différentes dans les deux images, nous nous basons sur le calcul des deux angles solides portés par la facette et issus du centre optique de l'APN dans chaque vue. Si la différence entre les deux angles est significative, c'est que la facette est vue de biais dans une des vues et de façon plus frontale. Dans l'autre cas, la facette du modèle sera labellisée entièrement par la classe qui correspond au plus grand angle solide.

Dans le dernier cas où cette différence n'est pas importante, un indice de confiance peut être pris en compte. Il est basé sur la probabilité d'appartenance à une classe donnée des deux régions contenant les triangles homologues après chaque

classification mono-vue. Le triangle sera labellisé par l'étiquette de la région classifiée avec la plus grande probabilité.

Concernant les facteurs d'angle solide et de probabilité d'appartenance, la priorité est donnée à l'angle solide dans le cas d'un écart angulaire important, car il est clair qu'une facette a plus de chances d'être bien classifiée de face que de profil. Cette stratégie de fusion a été implémentée selon l'organigramme de la Figure 4.8.

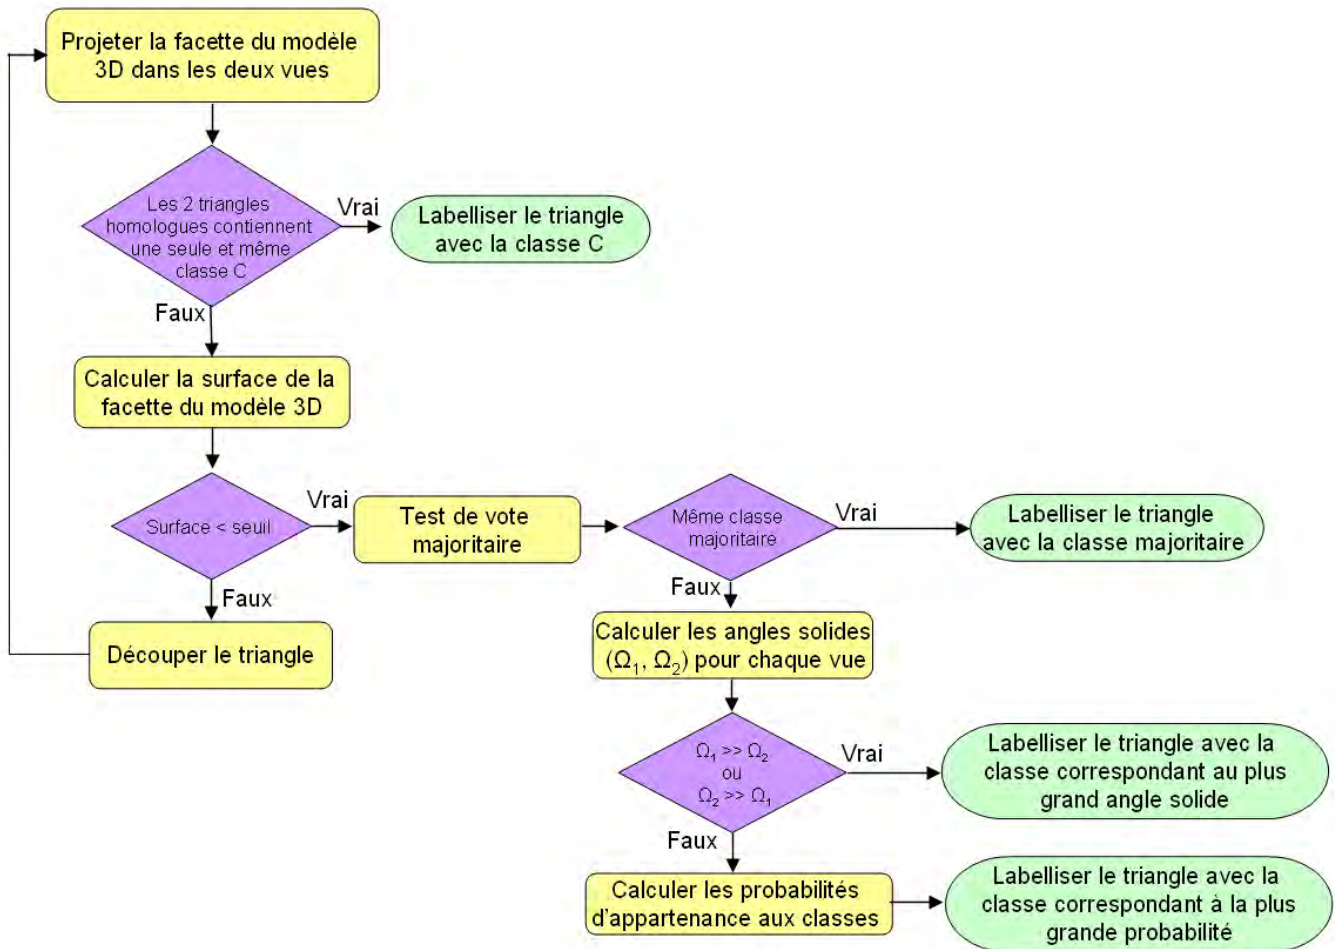


Figure 4.8 – Stratégie de fusion des labellisations sur le modèle 3D.

Pour analyser ce processus de fusion et observer comment l'étiquetage des facettes dans le modèle 3D est accompli par notre algorithme, nous avons exécuté ce processus sur des paires d'images labellisées à la fois par les experts et par le classifieur. Le Tableau 4.1 donne le nombre de triangles labellisés à chaque étape sur un exemple de paires d'images.

L'histogramme de la Figure 4.9 indique la surface totale des triangles labellisés au cours des différentes étapes, moyennée sur une dizaine de modèles de reconstruction 3D. Il apparaît clairement que seulement 45% de la surface totale a été labellisée avec la même classe dans les deux vues. Nous mettons ainsi en évidence et de façon

	Classe commune	Découpage	Classe dominante	Angle solide	Probabilité d'appartenance
Nbr de triangles	1280	77	540	700	561
Pourcentage	40.5 %	2.4 %	17.0 %	22.2 %	17.9 %

Tableau 4.1 – Nombre de triangles labellisés pour chaque étape de l'algorithme de fusion.

qualitative, la dépendance de la classification mono-vue au point de vue et la nécessité de combiner plusieurs vues pour garantir une classification performante. L'étape de découpage des facettes résoud le problème pour un nombre limité de triangles, représentant 2.5% de la surface totale. Cependant, environ 20% de la surface du modèle est labellisée par le critère de classe dominante, correspondant aux triangles labellisés par plus d'un type de tissu, mais majoritairement par une et même classe dominante dans les deux vues. Enfin, pour environ 30% de la surface de la plaie, les deux critères d'angle solide et de probabilité d'appartenance doivent être calculés.

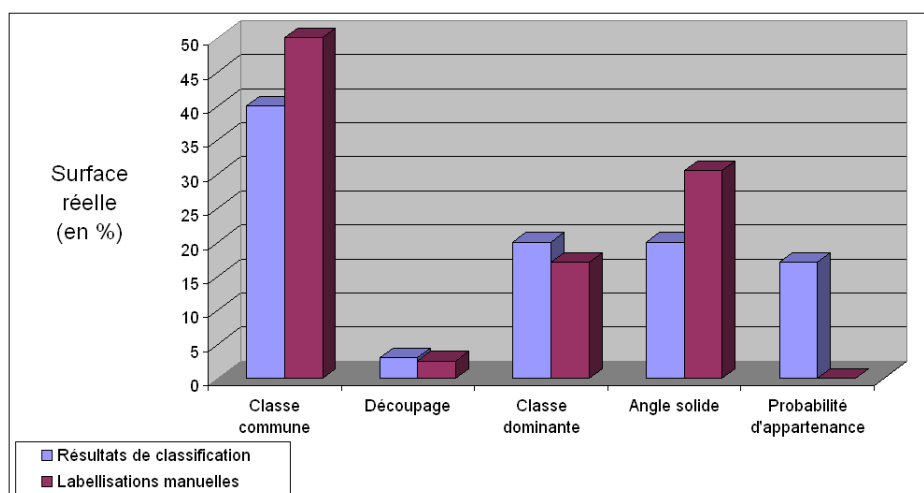


Figure 4.9 – Distribution des labellisations multi-vues dans l'algorithme de fusion.

Notons enfin que pour la labellisation manuelle, le pourcentage de la surface des tissus labellisé par le critère de probabilité est nul car le degré de confiance des experts dans la labellisation effectuée, de même que le degré d'expertise propre à chaque expert n'ont pas été considérés.

4.4 Evaluation multi-vues

Grâce à la fusion, il est désormais possible de procéder à des évaluations multi-vues des plaies. Dans cette optique, trois prises de vue différentes de la même plaie ont été faites, constituant trois paires stéréoscopiques (vues 1-2, vues 1-3 et vues 2-3). Après avoir labellisé chaque image manuellement (experts) et automatiquement (algorithmes), un modèle 3D a été reconstruit pour chaque paire d'images (Figure 4.10).




Figure 4.10 – Reconstruction 3D à partir de 2 prises de vue (1^{ère} ligne) trois images de la plaie prises de points de vue différents formant trois paires stéréoscopiques (2^{ème} ligne) trois modèles 3D reconstruits respectivement à partir des paires 1-2, 2-3 et 3-1.

Plusieurs expérimentations ont été menées pour évaluer la dispersion des résultats liées au calcul du modèle 3D et les progrès réalisés par rapport au traitement mono-vue. Tout d’abord, nous avons testé la stabilité de la labellisation 3D sur différentes reconstructions, puis celle de la classification d’une même plaie sur plusieurs reconstructions. Enfin nous avons comparé les surfaces tissulaires obtenues en classification mono-vue et multi-vues.

4.4.1 Stabilité des labellisations 3D

Cette expérimentation n’a pas pour but d’évaluer la qualité du modèle 3D reconstruit, mais plutôt la stabilité de cette reconstruction sur différentes paires d’images de la même plaie. Dans ce test, nous n’utilisons que les labellisations manuelles des trois vues réalisées par les experts, afin d’analyser les apports du multi-vue en s’affranchissant des erreurs de classification automatique.

Étant donné que la mise en correspondance de points dans les images utilise des algorithmes stochastiques (de type RANSAC), nous n’obtenons jamais deux modèles identiques lors l’exécutions successives de l’algorithme. Pour cette raison, la reconstruction a été exécutée cinq fois sur chaque paire d’images, constituant 15 modèles 3D différents d’une même plaie (Figure 4.11).

Ensuite, les labellisations manuelles de chaque paire stéréoscopique ont été fusionnées et projetées sur le modèle 3D correspondant en utilisant la stratégie de fusion détaillée dans l’organigramme de la Figure 4.8 avec un seul changement : le test de probabilité d’appartenance à une classe est écarté car, seules les labellisations manuelles des experts sont utilisées dans cette expérience. La Figure 4.12 montre une escarre selon trois vues différentes, sa labellisation manuelle et la fusion des labellisations sur les trois modèles reconstruits à partir des trois paires d’images.

Cette expérimentation a été menée sur plusieurs plaies et les surfaces (moyennes




Figure 4.11 – Stabilité de labellisation multi-vues sur 5 reconstructions différentes. (1^{ère} ligne) deux images de la plaie prises de points de vue différents (2^{ème} et 3^{ème} lignes) fusion des labellisations manuelles reportée sur 5 reconstructions successives du modèle 3D d’une plaie.

et écart-types) associées aux fusions des classifications ont été calculées à chaque fois. Le tableau 4.2 présente les pourcentages obtenus par type de tissu pour chaque paire d’images sur un exemple de plaie.

Classe de tissu	Paire d’images			
	en %	1-2	2-3	1-3
Bourgeon		17.4±1.8	17.6±0.5	23.8±0.7
Fibrine		67.0±1.4	67.6±0.5	53.0±0.8
Nécrose		15.6±0.3	14.6±0.5	23.2±0.4

Tableau 4.2 – Stabilité de la reconstruction. Les surfaces des tissus sont obtenues sur 5 reconstructions sur chaque paire d’images.

Ces résultats attestent de la bonne stabilité des labellisations multi-vues, malgré les variations liées à la reconstruction du modèle 3D. Il faut enfin souligner que la paire 1-3 donne des pourcentages tissulaire assez éloignés des paires 1-2 et 2-3, tout simplement parce que le modèle 3D obtenu est dépendant du point de vue (occultations, reflets, etc.)

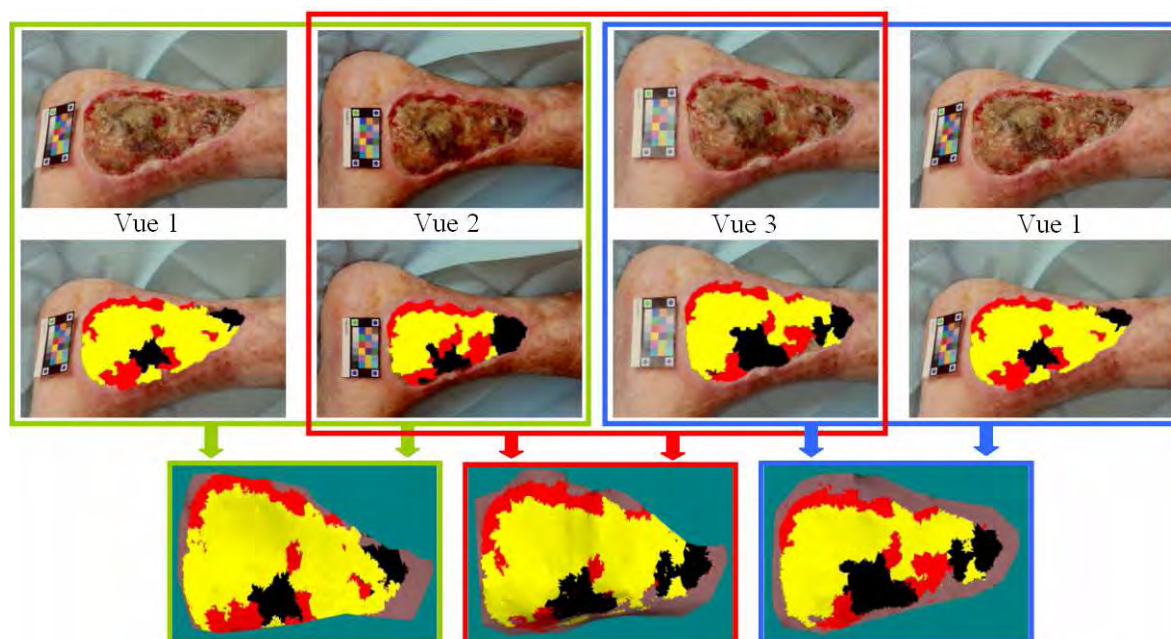


Figure 4.12 – Stabilité de labellisation sur différentes paires d'image de la même plaie. (1^{ère} ligne) trois images de la plaie prises de points de vue différents formant trois paires stéréoscopique (2^{ème} ligne) labellisations manuelles en 2D faites par des experts (3^{ème} ligne) fusion des labellisations des paires d'images, respectivement 1-2, 2-3 et 3-1.

4.4.2 Stabilité de la classification

Nous avons reconduit la dernière expérimentation de test dans les mêmes conditions, mais en substituant les classifications automatiques obtenues aux labellisations manuelles (Figure 4.13). Le tableau 4.3 présente les pourcentages par type de tissu et pour chaque paire d'images.

Classe de tissu en %	Paire d'images		
	1-2	2-3	1-3
Bourgeon	16.5±1.7	21.6±0.7	21.6±0.5
Fibrine	70.9±1.8	62.0±0.7	55.8±0.5
Nécrose	12.6±0.3	16.4±0.3	22.6±0.4

Tableau 4.3 – Stabilité de la classification. Les surfaces des tissu sont obtenues sur 5 reconstructions issues des différentes paires d'images.

Suite à ces deux expériences, nous pouvons considérer que le processus de fusion multi-vues est peu sensible aux variations de reconstructions 3D.

4.4.3 Comparaison des surfaces 2D / 3D

Par simple rétroprojection de la cartographie 2D tissulaire sur le modèle 3D on peut plaquer les résultats de classification mono-vue sur le maillage triangulaire. La Figure 4.14 montre sur un exemple les variations observées sur le placage des

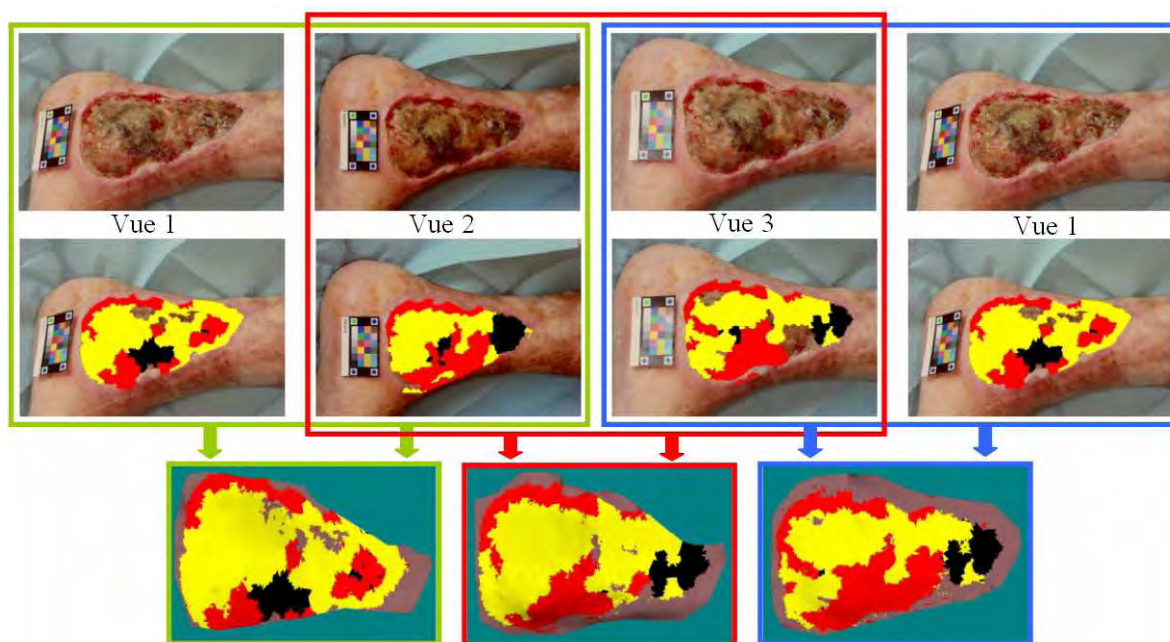


Figure 4.13 – Stabilité de la classification sur différentes paires d’image de la même plaie. (1^{ère} ligne) trois images de la plaie prises de points de vue différents formant trois paires stéréoscopique (2^{ème} ligne) classification automatique en 2D (3^{ème} ligne) fusion des classification des paires respectivement 1-2, 2-3 et 3-1 selon les trois modèles 3D calculés.

cartographies selon les points de vue. Le modèle 3D permet une comparaison exacte des classifications mono-vue puisque les écarts exprimés en cm^2 et non plus en pixel.

Le tableau 4.4 présente les erreurs de calcul des surfaces en cm^2 pour chaque type de tissu, lorsqu’on fait la retroprojection d’un plan image sur le modèle 3D.

Classe de tissu (en cm^2)	Images		
	1	2	3
Bourgeon	0.5	5.5	1.1
Fibrine	1.3	2.0	1.7
Nécrose	0.4	3.0	3.2

Tableau 4.4 – Erreurs de surface obtenues par retroprojection du plan image (d’une seule vue) sur le modèle 3D, pour une escarre relativement grande ($54 cm^2$).

Les erreurs obtenues, différentes d’une image à l’autre, reflètent l’effet de la projection perspective dans l’image et les reliefs cutanés de l’escarre. Cette expérimentation confirme les limitations de la labellisation mono-vue et la nécessité de prendre en compte l’aspect 3D.




Figure 4.14 – Labellisation mono-vue du modèle. (a-b) paire d'images (c-d) modèle 3D reconstruit respectivement selon la 1^{ère} et la 2^{ème} vue (e-f) projection du modèle sur les deux vues.

4.5 Apports de l'approche multi-vue

L'intérêt de l'approche multi-vues est évident dans la mesure où l'on enrichit la connaissance disponible en mono-vue, mais il reste à démontrer quantitativement son bénéfice final sur la performance de la classification tissulaire. Plus généralement, nous évoquons plus loin les perspectives ouvertes par cette approche multi-vues pour la mesure des surfaces et de volumes et discutons de son intérêt pour l'analyse de la dépendance au point de vue de différents éléments.

4.5.1 Convergence du processus de classification tissulaire

Pour quantifier l'intérêt de la fusion des résultats de classification 2D, nous avons calculé les scores de recouvrement obtenus⁴ en mono-vue (2D) et en multi-vues (3D). Cependant, le calcul des scores de recouvrement nécessite la référence à une "vérité terrain". Or, si nous disposons d'une labellisation manuelle 2D réalisée par des experts sur chacune des vues, nous n'avons pas de référence en 3D. A partir d'une vérité terrain en 2D pour une paire d'images et d'un modèle 3D reconstruit à

⁴Le score de recouvrement est présenté dans le Chapitre 2, page 31

partir de ces dernières, nous avons constitué pour chaque paire d'images une "vérité terrain multi-vue" en fusionnant les deux vérités terrains 2D. Le processus de création de cette dernière s'appuie sur la même stratégie de fusion présentée précédemment dans l'organigramme de la Figure 4.8, mais sans tenir compte du critère de probabilité d'appartenance aux classes puisque les vérités terrain 2D sont des labellisations manuelles.

NB : on pourrait néanmoins donner aux experts la possibilité d'exprimer leur indécision par des labellisations "floues" plutôt bourgeon, plutôt fibrine, très certainement bourgeon, etc... ou de classer les experts en catégories telles que Spécialiste, Généraliste, ...).

Après la création de la vérité terrain multi-vues, le calcul des scores de recouvrement devient possible pour chaque paire d'images. Les résultats obtenus par type de tissu sont donnés dans le Tableau 4.5. On constate que les résultats de classification sont plus proches de la vérité terrain 3D que ceux de la classification mono-vue avec la vérité terrain 2D, ce que nous qualifions de processus convergence de la classification, avec le nombre de vues considérées.

Classe de tissu	Paire d'images					
	1-2		1-3		2-3	
en %	2D	3D	2D	3D	2D	3D
Bourgeon	72.4	73.2	66.4	73.0	60.9	71.0
Fibrine	87.8	93.7	89.6	94.3	97.6	86.4
Nécrose	72.8	88.4	52.2	72.3	44.1	51.9
Moyenne	77.5	85.2	69.4	79.9	67.6	69.8

Tableau 4.5 – Fusion des classifications : scores de recouvrement moyens sur 5 reconstructions du modèle pour chaque paire d'image

Notons que même si la vérité terrain multi-vues est issue des vérités terrain 2D et si la classification multi-vues est aussi issue des classifications 2D, les deux étiquetages des tissus étant par ailleurs obtenus avec une stratégie de fusion presque identique⁵, les scores de recouvrement multi-vues ne reflètent pas forcément les scores en 2D. Dans le cas multi-vues, les effets des déformations perspective et des variations d'éclairage sont pris en compte par la fusion du modèle 3D, ce qui n'est pas le cas en 2D, même pour les experts puisque les labellisations manuelles sont réalisées sur écran sans autre connaissance du patient.

Nous constatons que les scores de recouvrement sont globalement améliorés en multi-vues (3D) par rapport aux scores en mono-vue (2D). L'amélioration des résultats de classification par fusion est visible dans la Figure 4.15, où certaines zones de l'escarre ont été mal étiquetées dans une des deux vues et ensuite corrigées par la fusion multi-vues. On assiste donc à une convergence des classifications en passant

⁵La seule différence est de considérer ou pas le test de probabilité d'appartenance à une classe dans le cas de fusion des classification 2D.

du mono-vue au multi-vues, ce qui se traduit par un meilleur accord entre les labellisations manuelles et la classification automatique.

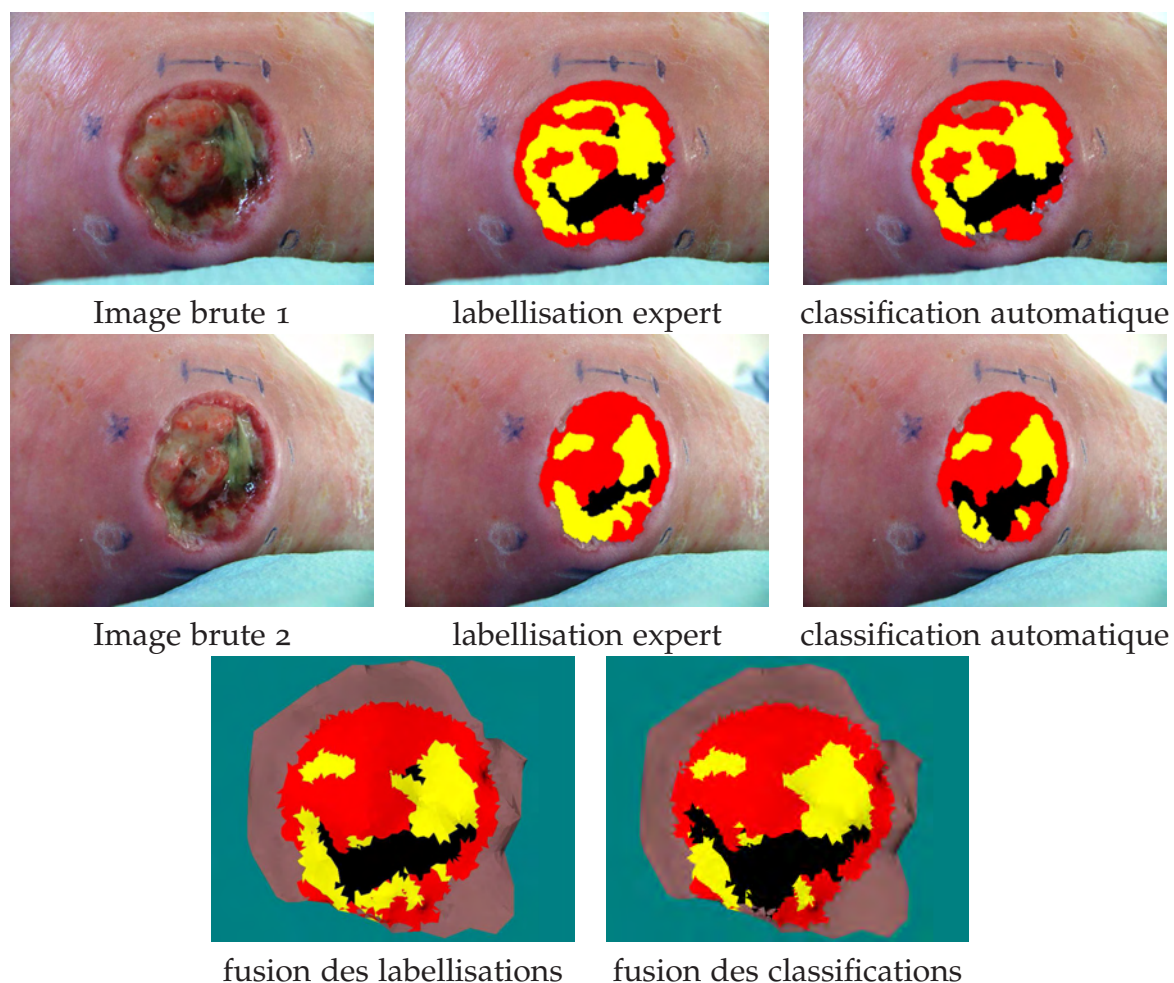


Figure 4.15 – Exemple de classification multi-vues d'une escarre.

4.5.2 Précision métrologique des relevés tissulaires

4.5.2.1 Mesures de surface

La mesure par photographie numérique est actuellement pratiquée par les médecins pour le suivi thérapeutique d'escarres car elle évite les risques liés au contact avec la plaie et permet l'archivage des données patients mais l'image de la plaie ne donne pas accès à la mesure des surfaces réelles. En effet, les déformations dues à la projection perspective dans l'image et au relief cutané ne peuvent pas être prises en compte en mono-vue. Des évaluations ([Plassmann & Jones, 2003], ont montré qu'une inclinaison de seulement 20° par rapport au plan frontal de la plaie entraîne un biais sur mesure de la surface d'environ 10%. L'approche multi vues permet non seulement par fusion des labellisations d'appliquer la labellisation de chaque type de tissu sur le maillage triangulaire, mais aussi de profiter du relevé 3D de la plaie pour

accéder aux mesures réelles de surfaces.

Le modèle 3D étant mis à l'échelle grâce à une mire de dimension connue placée dans le champ de l'image, il suffit d'additionner les surfaces des triangles élémentaires pour obtenir les surfaces totales en mm^2 pour chaque classe de tissu. Il s'agit bien des vraies surfaces, calculées directement sur le modèle 3D et non plus d'une simple addition de pixels dans le plan de l'image.

4.5.2.2 Mesure de volume

Dans le cas du suivi thérapeutique d'escarres, le volume d'intérêt est la cavité creusée par la plaie et limité par le bord naturel de peau saine. Le calcul de ce volume avec un modèle 3D requiert en principe une surface fermée par un plan de bouchage virtuel. On peut estimer le volume de la plaie en intégrant les volumes élémentaires des prismes définis entre les facettes du maillage triangulaire et ce plan de bouchage moyen calculé à partir du contour externe de la plaie.

Après la classification multi-vues du modèle 3D de la plaie en quatre classes, les triangles internes labélisés comme peau saine doivent être exclus dans un premier temps du modèle 3D afin de ne conserver que les tissus de la plaie constituant une seule composante connexe (pas de régions de peau saine à l'intérieur d'une escarre qui cicatrise toujours depuis sa périphérie). L'ensemble des triangles de la plaie jointif avec peau saine définit implicitement le contour de la plaie. Dans un deuxième temps, le plan de bouchage sera ajusté sur le maillage grâce à ce contour. Enfin le volume peut être délimité par la surface de l'escarre reconstruite et ce plan de bouchage virtuel (4.16).

4.5.3 Robustesse au changement de point de vue

Nous venons de montrer que l'approche multi-vues offre de nouvelles possibilités pour des mesures précises des surfaces tissulaires et du volume d'une plaie. On voit immédiatement qu'en sortant du contexte applicatif du projet ESCALE, de nombreuses perspectives sont ouvertes pour des études de traitement d'images multi-vues comme l'évaluation de la stabilité colorimétrique ou l'analyse de la robustesse d'un descripteur face au changement de point de vue. Dans un deuxième temps, ces études pourront être étendues à l'intégration des conditions liées aux changements de point de vue dans l'étape de extraction des caractéristiques des régions pour renforcer le processus de classification 2D.

4.5.3.1 Stabilité de la correction colorimétrique

Lorsque la méthode de correction colorimétrique a été présentée dans le deuxième chapitre, nous avons évalué son efficacité en entrée de la chaîne de traitement grâce à la mire couleur *Machbeth* présente dans le champ de l'image, ne disposant pas encore de l'évaluation en bout de chaîne effectuée en sortie du classifieur mono-vue. Lors de l'évaluation par la distance $CIE\Delta E_{ab}$, nous avons constaté

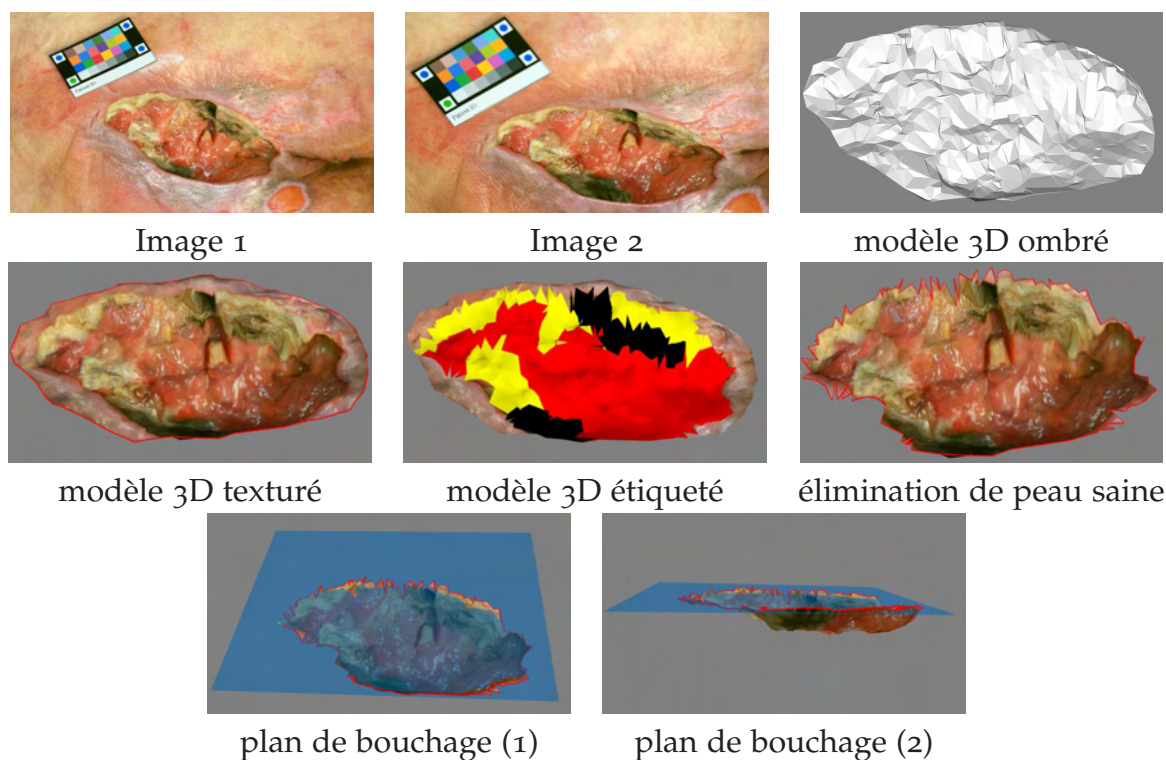


Figure 4.16 – Calcul du volume exact de la plaie avec la labellisation multi-vues.

des écarts colorimétriques importante entre les image brutes de la même plaie, nettement réduite après correction. Notons que la distance a été calculée seulement sur les carreaux de la mire, car ce sont les seules zones appariées dans les deux images. Disposant maintenant d'un système d'analyse d'images multi-vues, il est possible de calculer la distance colorimétrique entre tous les triangles homologues du modèle 3D dans les deux images. A titre d'exemple, la distance $CIE\Delta E_{ab}$ moyenne entre les deux images de la plaie présentée dans la Figure 4.16 a été réduite de 8 ± 0.7 à 3.9 ± 0.5 sur l'ensemble des triangles du modèle.

Une application directe concerne la correction colorimétrique, mais cette fois-ci pour évaluer la mire couleur spécifique que nous avons créée spécialement pour les images de plaies chroniques, présentée dans le Chapitre 2. Pour quantifier les performances de cette mire face à la mire *Macbeth*, nous devons évaluer l'effet de correction sur des zones d'escarre en calculant les écarts colorimétriques entre les triangles des deux vues où les deux mires sont simultanément présentes. Une fois de plus, l'approche multi-vues offre des possibilités d'analyse d'influence du point de vue dans les images, grâce à la mise en correspondance des triangulaires élémentaires homologues.

4.5.3.2 Stabilité des descripteurs de régions

L'exploitation des informations géométriques issues du modèle 3D ouvre une voie intéressante pour l'analyse de descripteurs multi-vues pertinents et invariants

au changement de point de vue. Lorsque nous disposons d'une base d'escarres multi-vues plus étendue, il sera possible de programmer notre classifieur en intégrant pour chaque échantillon de tissu les informations colorimétriques de plusieurs points de vue. A titre d'exemple, nous avons réalisé des tests de stabilité de quelques descripteurs face au changement de point de vue. Les descripteurs testés sont des histogrammes quantifiés dans deux ou trois dimensions : 3D-RGB ($16 \times 16 \times 16$ cellules), 2D-HS (32×30 cellules), 2D- a^*b^* (32×30 cellules). Ces descripteurs ont été calculés dans toutes les zones triangulaires homologues mises en correspondance entre les deux vues grâce au modèle 3D reconstruit. Afin de comparer deux histogrammes calculés dans deux zones homologues, nous avons calculé trois types de distance : la corrélation, l'intersection et la distance de Battacharyya. Le tableau 4.6 présente les distances obtenues sur la paire d'images de la Figure 4.15, moyennées sur l'ensemble des triangles du modèle.

	Correl.		Inters.		Battach.	
	Moyenne	Ecart-type	Moyenne	Ecart-type	Moyenne	Ecart-type
3D-RGB	0.4	0.12	0.35	0.1	0.7	0.09
2D-HS	0.6	0.22	0.4	0.1	0.8	0.12
2D- a^*b^*	0.83	0.1	0.69	0.13	0.55	0.16

Tableau 4.6 – Evaluation de l'invariance de descripteurs grâce à l'approche multi-vues.

On peut remarquer dans cet exemple, que l'histogramme bi-dimensionnel dans l'espace $L^*a^*b^*$ présente une forte corrélation moyenne (Correl. = 0.83) entre les deux vues et que l'histogramme bi-dimensionnel dans l'espace HSV présente aussi une bonne mesure de similarité (Battach. = 0.8) contre une très faible mesure d'intersection dans l'espace RGB (Inters. = 0.35). En moyenne, l'espace $L^*a^*b^*$ assure la meilleure stabilité des trois mesures de similarité.

4.6 Conclusion

Nous avons développé dans ce chapitre une nouvelle approche multi-vues en intégrant le modèle 3D dans le processus de classification tissulaire, optimisant ainsi la classification ainsi le détournement de ce modèle. Cette méthode permet de fusionner les résultats provenant de plusieurs prises de vue pour obtenir une labellisation multi-vues unique et plus robuste. Diverses expérimentations ont été présentées dans le but d'évaluer la stabilité et l'efficacité de cette méthode dans une chaîne complète de traitement d'image d'escarres. Les tests établissent clairement que notre algorithme de fusion améliore la stabilité des résultats.

Nous avons constaté que la classification tissulaire est un processus très dépendant des conditions d'éclairage et du changement de point de vue. De plus, en fonction du point de vue, les surfaces calculées dans l'image ne sont pas les mêmes,

par simple effet de la projection perspective du relief cutané dans le plan de l'image. Ce problème a été contourné par l'approche multi-vues, en s'affranchissant d'une source de cette dispersion importante des mesures. En reportant directement sur le modèle 3D le résultat de la fusion de classifications effectuées sur des images de la même escarre, acquises depuis des points de vue différents, la classification est considérablement améliorée et la quantification de tissus n'est plus simplement relative (pourcentage de chaque type dans le plan de l'image) mais absolue (superficie des tissus en cm^2).

Pour donner à ce système d'évaluation quantitative multi-vues une plus grande robustesse, il est nécessaire d'accumuler un grand nombre d'images d'escarres pour enrichir la base existante et prendre en compte la grande diversité des cas réels. A partir d'un grand nombre de paires d'images d'escarres, nous pourrions nous appuyer sur la labellisation multi-vue manuelle pour concevoir des descripteurs qui rendent le classifieur plus robuste.

Conclusion générale

Dans cette thèse, nous nous sommes intéressés au problème de la classification tissulaire de plaies chroniques à partir d'images couleur. Ces travaux contribuent à la mise au point d'un outil d'évaluation destiné au suivi thérapeutique des plaies. Notre approche se distingue des précédentes par l'utilisation de plusieurs vues permettant de combiner le relevé tridimensionnel de la plaie et l'analyse colorielle des tissus en un seul et même outil.

Les protocoles expérimentaux mis en place ont démontré la pertinence de nos contributions au regard des approches classiques, et ont permis d'identifier l'influence des différentes étapes, comme la correction colorimétrique, le choix des descripteurs de couleur et de texture de régions ou de la méthode de segmentation sur les performances du classifieur final. Nous résumons ici les principaux résultats et contributions exposés dans ce manuscrit.

Originalité du travail :

L'originalité de ce travail réside dans le développement d'un outil complet d'évaluation des plaies combinant un relevé anatomique 3D avec la classification couleur des tissus. La technique proposée est particulièrement conviviale puisque la capture des images s'effectue à main levée avec un simple APN. Cette solution bas coût et simple d'emploi devrait favoriser sa diffusion dans les centres de soins et son usage à domicile pour la télémédecine.

Le protocole multi-vues adopté permet :

- de fusionner les classifications mono-vues sur le modèle 3D
- d'accéder à une mesure exacte des surfaces tissulaires
- d'obtenir un détournage de la plaie sur le modèle 3D

L'intégration des deux modules (analyse couleur et relevé 3D), traités jusqu'à présent de façon indépendante, permet d'en retirer des bénéfices mutuels. À l'instar du clinicien, qui dispose d'une variété de points d'observation pour établir son diagnostic, l'analyse multi-vues renforce la cohérence et la stabilité des résultats de

classification et garantit la qualité de l'estimation des paramètres quantitatifs, indépendamment du relief de la scène et des déformations perspectives induites lors du déplacement de l'APN. Le modèle 3D permet de fusionner les différentes classifications en une cartographie unique en profitant de la géométrie épipolaire établie entre les vues. Réciproquement, la détection du bord de la plaie par classification des tissus permet de calculer des indicateurs cliniques importants sur modèle 3D, de nature dimensionnelle comme la surface, la profondeur et le volume de la cavité de la lésion.

Apports spécifiques :

Les travaux menés dans cette thèse ont contribué à à différents niveaux au domaine de l'évaluation tissulaire par imagerie numérique :

- mise en place d'une méthode de calibrage colorimétrique permettant de s'affranchir des perturbations liées aux changements d'APN, d'éclairage et de points de vues. Un point innovant a été la conception d'une mire couleur spécifique, adaptée aux tonalités caractéristiques des plaies chroniques.
- constitution d'une base d'images cliniques et extraction d'échantillons représentant les 4 classes de tissus : bourgeon, fibrine, nécrose et peau saine. Aucune base de ce type n'était disponible jusqu'à présent pour l'évaluation des plaies chroniques, d'autant plus qu'elle intègre un protocole de prise d'images multi-vues.
- mise en oeuvre de deux techniques de labellisation manuelle par des experts : la première permet de colorier des photos des plaies sur ordinateur avec l'avantage de fournir exactement la classification décidée par l'expert, lui laissant une totale liberté pour le tracé des contours effectué à la souris. La seconde permet de désigner une classe de tissu pour des régions pré-segmentées de l'image par un simple clic de souris. Les deux techniques ont été appliquées et les résultats de classification automatique suivant le modèle choisi ont été comparés. La labellisation manuelle sert de vérité terrain à la fois pour la constitution d'échantillons des classes de tissus, et pour l'évaluation de la chaîne complète de traitement, en particulier, des performances du classifieur.
- test de quatre algorithmes de segmentation couleur non supervisée et comparaison de leurs performances sur une base d'images de plaies. Un point important concerne l'influence du nombre et de la taille des régions pré-segmentées sur les résultats finaux de classification. Le niveau de sur-segmentation est contrôlé par le paramétrage des algorithmes : des régions de petite taille favorisent l'homogénéité tout en augmentant la discrimination de la base d'apprentissage, mais une taille minimum est requise pour un calcul statistiquement fiable des descripteurs. Une recherche de réglage optimal de ce paramétrage a été effectuée sur l'algorithme de segmentation sélectionné afin

d'adapter le degré de segmentation à notre base d'images.

- mise en oeuvre de différents descripteurs de couleur et de texture caractérisant le contenu des régions tissulaires et sélection des descripteurs les plus discriminants pour la classification tissulaire.
- analyse discriminante des données par différentes méthodes pour assurer un bon conditionnement et améliorer les performances du classifieur tout en réduisant la taille de la base d'apprentissage.
- mise au oeuvre d'un classifieur SVM où la sélection du modèle et d'un noyau adaptés à nos données a été effectuée par une technique de validation croisée. Malgré une base d'apprentissage réduite, le taux de classification obtenu par notre algorithme rivalise avec celui d'un expert, comparé à la vérité terrain constituée par la fusion des tracés de plusieurs experts.
- rétro projection et fusion des résultats de classification mono-vue sur le modèle 3D. Grâce à la géométrie épipolaire qui met en relation les zones triangulaires dans les images. Les classifications de tissus provenant de deux vues ont été fusionnées sur le modèle 3D pour parvenir à un résultat plus robuste. Après la classification multi-vues du modèle 3D de la plaie en quatre classes, le détournage du modèle représentant seulement les tissus de la lésion est obtenu et le plan de bouchage est ajusté sur le maillage.
- mise au point d'une stratégie de fusion multi-vues combinant la taille des facettes du modèle 3D, l'angle solide sous lequel sont observées ces facettes et leurs probabilités d'appartenance à une classe dans chacune des vues, pour obtenir une labellisation unique du modèle 3D de la plaie.

Perspectives :

Nous envisageons de nombreuses perspectives de ces travaux autour des différents aspects abordés durant cette thèse. D'un point de vue général, les deux axes du projet ESCALE ont été développés en parallèle, ce qui fait que les outils de reconstruction et de classification n'ont pas été implémentés sous la même interface logicielle : par conséquent, le lien entre les deux n'est pas complètement automatique. Le développement d'un logiciel intégré, complet et convivial est une priorité pour la validation clinique de ce nouvel outil d'évaluation des plaies dans les centres hospitaliers, à une plus grande échelle. D'autre part, il semble intéressant d'aborder le suivi thérapeutique et non plus seulement l'évaluation ponctuelle de la plaie, ce qui suppose le développement d'outils pour appréhender les évolutions de la plaie d'un point de vue géométrique (déformations du modèle 3D) et colorimétrique (changement d'état des tissus).

La première étape à franchir est l'extension de la base d'images. Les expérimen-

tations doivent se poursuivre sur un plus grand nombre d'images pour prendre en compte toute la diversité des cas réels et donner à la classification une plus grande robustesse. Une démarche a été initiée au sein du réseau national de l'association PERSE⁶ pour collecter des images sur de nombreux sites. Le nombre de classes pourra être élargi pour prendre en considération une typologie des tissus plus riche, considérant d'autres classes de tissus, comme l'épithélialisation, qui constitue une zone transitoire entre le bourgeon et la peau saine. L'extension de la base d'images permettra aussi d'élargir le champ d'application vers différents types de plaies comme les plaies traumatiques, les brûlures, etc.

Le test de nouveaux descripteurs, sur lesquels reposent la performance de la classification, pourrait profiter de travaux sur l'invariance couleur afin de s'affranchir de la mire dans l'image, sachant que la dépendance du rendu couleur des images aux APN reste un problème difficile à résoudre sans une étape d'équilibrage chromatique. Les descripteurs de couleur et de texture étant sensibles aux points de vue et aux éclairages, l'analyse de leur robustesse pourrait être abordé localement, grâce à la mise en correspondance des zones triangulaires par le modèle 3D, en intégrant un facteur lié aux changements d'échelle.

La prise en compte d'un nombre de vues plus grand permettra de développer des techniques de fusion plus riches et plus robustes. En effet, le modèle 3D de la plaie se reconstruit actuellement à partir de deux vues seulement et, par conséquent, la fusion des labellisations est limitée. Il est prévu à terme d'estimer le modèle 3D à partir de 3 à 5 vues de la même plaie, ce qui conduira à un modèle 3D plus précis et à une labellisation plus riche des tissus de la plaie, permettant de résoudre les problèmes d'occultations liés des zones trop profondes et de reflets pour certains points de vue.

Enfin, le développement d'une méthode de segmentation adaptative et multi-vues s'appuyant sur l'information de la couleur et de la texture des zones triangulaires mises en correspondance par le modèle 3D pourra renforcer la robustesse de la labellisation tissulaire. Les points de contour extraits dans les images par cette segmentation pourront définir à la mise en correspondance et enrichir ainsi le modèle 3D.

⁶PERSE (Prévention Education Recherche en Soins d'Escarres) est une association des professionnels de santé en France, créée en 1991.

Chapitre **V**

Annexes

ANNEXE A Colorimétrie et espaces couleur

5.1 Le système visuel humain

La lumière incidente sur une surface étant caractérisée par sa distribution de puissance spectrale $E(\lambda)$, un petit élément de la surface de l'objet réfléchit une fraction de l'illumination incidente dans l'œil. La fonction de réflectivité $R(\lambda)$ établit cette fraction comme une fonction de la longueur d'onde de la lumière incidente. Le spectre de la lumière qui atteint l'œil est appelé signal couleur et représenté mathématiquement par :

$$C(\lambda) = E(\lambda)R(\lambda) \quad (5.1)$$

L'information implicite dans $C(\lambda)$ est codée par la rétine, en utilisant ses trois classes de cônes photorécepteurs. La Figure 5.1 illustre la réponse spectrale donnée par ces cônes. L , M et S particulièrement sensibles respectivement au rouge, au vert et au bleu. Les cônes permettant la vision diurne sont remplacé la nuit par des bâtonnets photorécepteurs dit de classe R.

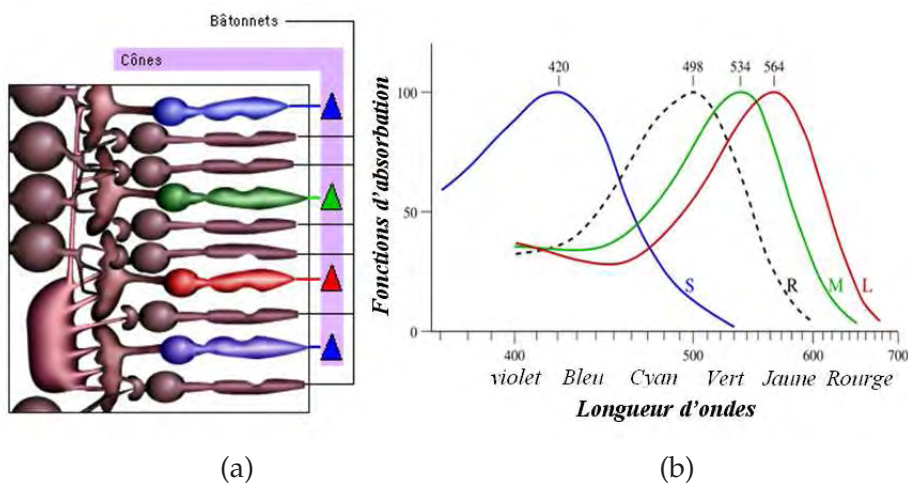


Figure 5.1 – Fonctions d'absorption relative des cônes et des bâtonnets (a) coupe de la rétine (b) sensibilités spectrales des cônes et des bâtonnets.

On peut constater sur cette figure que les sensibilités des cônes L , M et S ne sont pas exactement centrées sur les trois couleurs fondamentales.

Les réponses totales des cônes sont la somme de leurs réponses à toutes les longueurs d'onde de la lumière. Mathématiquement, nous pouvons décrire ces sommes par des intégrales et si on note la réponse des trois types de cônes par l , m et s , on trouve :

$$\begin{aligned} l &= \int_{\omega} C(\lambda)L(\lambda)d\lambda \\ m &= \int_{\omega} C(\lambda)M(\lambda)d\lambda \\ s &= \int_{\omega} C(\lambda)S(\lambda)d\lambda \end{aligned} \quad (5.2)$$

où $L(\lambda)$, $M(\lambda)$ et $S(\lambda)$ représentent les sensibilités relatives des trois types de cônes et ω est la gamme de longueurs d'onde pour laquelle ces cellules ont une réponse non-nulle. C'est ce triplet de réponses des cônes qui est à la base de tous les traitements visuels ultérieurs par le système visuel humain et d'où résulte finalement notre perception de la couleur.

5.2 Espaces couleur

Grâce aux lois fondamentales de l'appariement [Sève, 1996] [Ford & Roberts, 1998], qui résument les propriétés de la synthèse additive, les couleurs peuvent être représentées comme des vecteurs d'un espace à trois dimensions. Ceci permet par exemple d'effectuer des changements de base de manière simple.

Étant données les trois couleurs primaires C_i et une couleur test C , toutes connues par leur distribution d'énergie spectrale, $c_i(\lambda)$ et $c(\lambda)$ le signal couleur reçu par la rétine, les coordonnées C_i sont calculées par la relation suivante, qui fait le lien entre l'information colorimétrique et le signal couleur avec $\lambda_1 = 380nm$ et $\lambda_2 = 780nm$:

$$C_i = \int_{\lambda_1}^{\lambda_2} C(\lambda)c_i(\lambda)d\lambda \quad (5.3)$$

Il existe différentes familles d'espaces de représentation des couleurs : on peut citer les espaces primaires RGB et XYZ , les espaces perceptuellement uniformes comme les espace $CIE L^*a^*b^*$, $CIE Lu^*v^*$ et Lch , les espaces répondant à la perception humaine comme les TSL ou TSI . Nous allons introduire ici simplement les espaces primaires et les deux espaces uniformes $L^*a^*b^*$ et $L^*u^*v^*$, vu la dépendance de notre méthode de calibrage colorimétrique à ces espaces.

5.2.1 Espace $CIE RGB$

La plupart des dispositifs d'acquisition d'image, tels que les APN ou les scanners, manipulent des signaux du format RGB . C'est pourquoi l'espace RGB

est couramment employé dans les applications de traitement d'image. Comme vu précédemment, l'œil humain distingue les couleurs à travers trois types de cônes photorécepteurs, conduisant à caractériser naturellement toute couleur discernable par l'homme par un point dans un espace à trois dimensions. Plus précisément, réponses spectrales des trois types de cônes déterminent les intensités des 3 couleurs primaires rouge, vert et bleu, l'espace RGB étant défini à partir de ces trois couleurs primaires.

L'espace couleur RGB, mis au point en 1931 par la CIE [CIE, 1931], consiste à représenter les couleurs à partir de trois rayonnement monochromatiques de couleurs rouge, verte et bleue. Il est commode de représenter le triplet formé par les primaires comme un cube de couleur où chacune des primaires constitue l'un des axes de coordonnées. Le cube de couleur RGB est illustré dans la Figure 5.2, où chaque axe du cube représente les intensités de rouge, vert, bleu dans l'intervalle [0 255] pour un codage 8 bits.

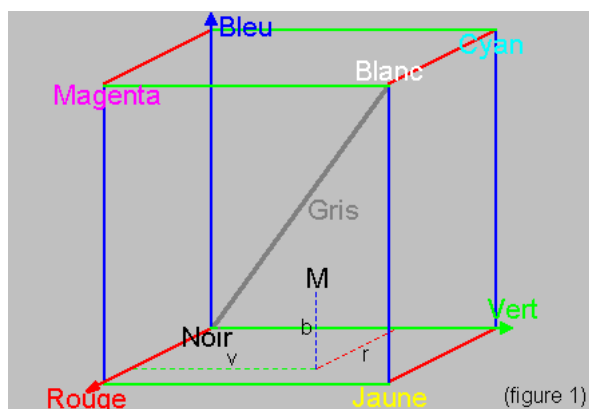


Figure 5.2 – Cube de couleur RGB.

La technologie des capteurs d'image, conduit à utiliser naturellement l'espace RGB. Cependant, la représentation RGB a quelques inconvénients qui diminuent les performances des systèmes. L'espace RGB n'est pas uniforme, c'est à dire que les distances relatives entre les couleurs ne reflètent pas les différences perceptuelles. De plus, ses composantes sont fortement corrélées.

Il faut souligner aussi l'existence d'une partie négative dans les spectres (Figure 5.2) et l'impossibilité de reproduire un certain nombre de couleurs par superposition des trois spectres dans cet espace. Ceci peut poser des problèmes dès que l'on désire travailler en synthèse additive. Afin de pallier ces inconvénients, la CIE a défini un espace de représentation de la couleur basée sur trois primaires non visibles X, Y et Z.

5.2.2 Espace CIEXYZ

Cet espace couleur est basé sur trois primaires XYZ (X pour le rouge, Y pour le vert et Z pour le bleu), dites virtuelles, pour contourner les problèmes posés par

l'espace *CIERGB* [Judd, 1930]. Dans cet espace, les triplets décrivant chaque couleur en fonction de ses composantes primaires ont tous des valeurs positives pour les spectres visibles. La fonction $Y(\lambda)$ représente approximativement la sensibilité visuelle de l'œil humain et par conséquent, la composante Y est usuellement considérée comme la composante de luminance du spectre incident. Enfin, tout spectre d'égal énergie est associé à un triplet dont toutes les composantes sont égales. L'espace *CIE XYZ 1931* est le modèle de référence qui décrit les couleurs perçues par l'homme et tous les modèles élaborés par la suite en dépendent d'une façon ou d'une autre.




Figure 5.3 – Courbes des réponses spectrale X, Y et Z

On passe du *CIERGB* au *CIE XYZ* par une simple transformation linéaire et la matrice de transformation peut être interprétée comme un changement de base :

$$\begin{pmatrix} X \\ Y \\ Z \end{pmatrix} = A * \begin{pmatrix} R \\ G \\ B \end{pmatrix} = \begin{pmatrix} X_r & X_g & X_b \\ Y_r & Y_g & Y_b \\ Z_r & Z_g & Z_b \end{pmatrix} * \begin{pmatrix} R \\ G \\ B \end{pmatrix} \quad (5.4)$$

Les coefficients de la matrice de transformation A sont directement liés au blanc de référence choisi. Ainsi, les valeurs des primaires X, Y et Z sont conditionnées par ce blanc de référence, en plus des primaires R, G et B . Par conséquent, il existe plusieurs matrices de passage [Trémeau, 1993]. Ainsi, pour pouvoir spécifier complètement la transformation *RGB* vers *XYZ*, il faut connaître les coordonnées des stimuli primaires et le blanc de référence de l'illuminant. Dans la plupart des situations, il faut formuler des hypothèses puisque ces informations ne sont pas accessibles.

Étant donné la difficulté à manipuler et à visualiser un ensemble de vecteurs 3D, il est devenu courant d'utiliser une projection des vecteurs 3D sur un plan unitaire où la somme des composantes est égale à 1. La somme des trois composantes ne représentant que l'intensité de la couleur et non la proportion de chacune des primaires, on obtient ainsi un diagramme dit de chromaticité. Les projections des vecteurs 3D

représentant les couleurs sont appelées coordonnées chromatiques.

Le diagramme de chromaticité le plus utilisé est le diagramme chromatique xy de la CIE (Figure 5.4). Afin de pouvoir représenter et analyser assez simplement, dans un repère géométrique à deux dimensions, les coordonnées X , Y et Z , on utilise en général les coordonnées normalisées x , y et z suivantes :

$$x = \frac{X}{X+Y+Z}, \quad y = \frac{Y}{X+Y+Z}, \quad z = \frac{Z}{X+Y+Z} \quad (5.5)$$

Étant donné que la somme des trois coordonnées vaut 1 (en effet $x + y + z = 1$), z se déduit directement des deux autres. C'est pourquoi cette dernière coordonnée n'est généralement pas utilisée.




Figure 5.4 – Diagramme de chromaticité xy .

La figure 5.4 montre le "fer à cheval" des couleurs, dit CIE 1931, produit par cette transformation. Cette représentation sert de base à beaucoup de calculs colorimétriques.

De cette façon, le paramètre y n'est plus directement proportionnel à la luminance et les coordonnées couleur restent toujours positives. On y retrouve le contour des couleurs spectrales et entre les points représentant les primaires rouge et bleue, la droite dite des pourpres. Le point E de coordonnées $(1/3, 1/3)$ y représente le blanc équiénergie ou blanc idéal. La couleur complémentaire de la couleur spectrale A est la couleur A' extrémité opposée sur l'axe EA . Cet espace chromatique fonde la base scientifique de la colorimétrie moderne, couramment utilisée aujourd'hui pour le repérage et la comparaison des couleurs, mais qui demeure un outil en évolution permanente.

5.2.3 Espace couleur sRGB

L'espace sRGB (pour standard RGB), est une variante du modèle RGB qui offre une gamme de teintes plus restreintes. La raison de son introduction vient de la volonté de réduire les différences chromatiques entre les documents affichés et leur équivalent imprimé. Les images RGB peuvent contenir beaucoup plus de couleurs qu'une imprimante ne peut en produire. En réduisant la palette RGB, il est possible d'obtenir des résultats plus harmonieux entre l'affichage écran et le papier. Le modèle sRGB permet aussi de calibrer les couleurs des images du web, pour que la qualité de leur affichage soit la même d'un moniteur à l'autre.

Les deux espaces couleur CIE XYZ et le sRGB sont reliés par une transformation linéaire. La première étape pour calculer les valeurs sRGB associées à des valeurs XYZ s'effectue par la transformation suivante (pour $X, Y, Z \in [0;1]$) :

$$\begin{pmatrix} R_{lin} \\ V_{lin} \\ B_{lin} \end{pmatrix} = \begin{pmatrix} 3.240479 & -1.537150 & -0.498535 \\ -0.969256 & 1.875992 & 0.041556 \\ 0.055648 & -0.204043 & 1.057311 \end{pmatrix} \begin{pmatrix} X \\ Y \\ Z \end{pmatrix} \quad (5.6)$$

Les valeurs obtenues par cette transformation ne sont pas les résultats finaux. Pour chaque composante R, G et B (notée C_{sRGB}), on a :

$$C_{sRGB} = \begin{cases} 12.92C_{lin} & \text{si } C_{lin} \leq 0.0031308 \\ (1 + 0.055)C_{lin}^{1/2.4} & \text{si } C_{lin} > 0.0031308 \end{cases} \quad (5.7)$$

5.2.4 Espaces couleur uniformes $L^*a^*b^*$ et $L^*u^*v^*$

Les espaces couleur classiques, tels que CIE RGB et CIE XYZ sont issus d'une approche purement physique, sans prise en compte des données psychophysiques. Dans le cas d'autres espaces couleur, tels que l'espace CIE $L^*a^*b^*$, l'approche physique est corrigée par des données relatives à la vision humaine. Certaines couleurs jugées proches par un observateur sont graphiquement distantes (dans le diagramme de chromaticité xy) et réciproquement, des couleurs jugées très différentes par un observateur sont graphiquement proches, à cause de la non-uniformité de l'espace CIE XYZ, [MacAdam, 1985]. Par contre, deux couleurs proches en distance dans l'espace CIE $L^*a^*b^*$ le sont aussi pour l'observateur humain grâce à son uniformité.

L'espace de représentation perceptuellement uniforme CIE $L^*a^*b^*$, mis au point par la CIE en 1976 pour répondre à cette exigence, a été établi par des relations non linéaires à partir du système XYZ. Le blanc de référence utilisé est caractérisé par les trois composantes trichromatiques (X_w, Y_w, Z_w) prises dans l'espace XYZ. Les composantes chromatiques de cet espace sont données par les équations suivantes :

$$L^* = \begin{cases} 116 \times \sqrt[3]{\frac{Y}{Y_w}} - 16 & \text{si } \frac{Y}{Y_w} > 0.008856 \\ 903.3 \times \frac{Y}{Y_w} & \text{si } \frac{Y}{Y_w} \leq 0.008856 \end{cases} \quad (5.8)$$

Les composantes chromatiques dans l'espace $L^*a^*b^*$ sont données par les équations suivantes :

$$a^* = 500 \times \left(f \left(\frac{X}{X_W} \right) - f \left(\frac{Y}{Y_W} \right) \right) \quad (5.9)$$

$$b^* = 200 \times \left(f \left(\frac{Y}{Y_W} \right) - f \left(\frac{Z}{Z_W} \right) \right) \quad (5.10)$$

avec

$$f(x) = \begin{cases} \sqrt[3]{x} & \text{si } \frac{Y}{Y_W} > 0.008856 \\ 7.787 \times \frac{16}{116} & \text{si } \frac{Y}{Y_W} \leq 0.008856 \end{cases} \quad (5.11)$$

L'information de luminance correspond ici à la clarté (L) qui représente la réponse de l'œil à un niveau de luminance et les composantes a^* et b^* représentent respectivement l'opposition de couleur vert-rouge et bleu-jaune.

La même année, la CIE a proposé un autre espace perceptuellement uniforme, l'espace $L^*u^*v^*$. Même si l'espace $L^*a^*b^*$ a connu une plus grande diffusion, ces deux espaces ont de grandes similitudes. L^* est calculée de la même façon que dans le modèle de $L^*a^*b^*$ et les composantes chromatiques de cet espace sont données par les équations suivantes :

$$u^* = 13L^*(u' - u'_0) \quad (5.12)$$

$$v^* = 13L^*(v' - v'_0) \quad (5.13)$$

avec

$$u' = \frac{4X}{(X + 15Y + 3Z)} \quad (5.14)$$

$$v' = \frac{9Y}{(X + 15Y + 3Z)} \quad (5.15)$$

$$u'_0 = \frac{4X_W}{(X_W + 15Y_W + 3Z_W)} \quad (5.16)$$

$$v'_0 = \frac{9Y_W}{(X_W + 15Y_W + 3Z_W)} \quad (5.17)$$

Du point de vue de leur uniformité perceptuelle, les deux espaces ($L^*a^*b^*$ et $L^*u^*v^*$) ne sont pas parfaitement perceptuellement uniformes et présentent des particularités utiles selon l'application.

Dans l'espace $L^*b^*b^*$, l'écart colorimétrique entre deux stimuli de couleur est calculé comme la distance euclidienne entre les points correspondants, $[L1, a1, b1]$ et

[L_2, a_2, b_2] :

$$\begin{aligned}\Delta E_{ab}^* &= \sqrt{(L_1 - L_2)^2 + (a_1 - a_2)^2 + (b_1 - b_2)^2} \\ &= \sqrt{(\Delta L^*)^2 + (\Delta a^*)^2 + (\Delta b^*)^2}\end{aligned}\quad (5.18)$$

et l'écart dans l'espace $L^*u^*v^*$ est donné par :

$$\Delta E_{uv}^* = \sqrt{(\Delta L^*)^2 + (\Delta u^*)^2 + (\Delta v^*)^2}\quad (5.19)$$

L'œil humain ne peut distinguer deux couleurs que si leur écart ΔE_{ab}^* est supérieur à 1, mais dans la pratique des écarts colorimétriques inférieur à 6 sont tolérés [Hardeberg, 1999], [Abrardo et al., 1996]. Cette tolérance peut être justifiée par le fait que l'espace $CIE L^*a^*b^*$ n'est pas un espace parfaitement uniforme, donc les valeurs de ΔE_{ab}^* qui rendent perceptible la différence des couleurs dépendent de la position dans le diagramme xy et de la direction entre les deux vecteurs couleurs.

Des études récentes en neurophysiologie de la vision ont permis d'évaluer la sensibilité des critères psychosensoriels de la vision des couleurs, ce qui a conduit à définir des facteurs psychométriques (coefficients de pondération) de chacun des critères de classification précédemment introduits. Ces études ont débouché sur de nouvelles formules d'écart colorimétrique, comme le CMC (Colour Measurement Committee) [Hayden & Oulton, 1994], le CIE 1994 [CIE, 1995] et CIE2000 [Luo et al., 2001], [Sharma & Wu, 2004].

5.3 Constance chromatique

Souvent, les images sont prises dans des conditions variables d'éclairage, entraînant une dominante couleur. Les méthodes de constance chromatique peuvent être utilisées pour supprimer cette dominante. Elles permettent de déterminer les propriétés de réflectance des surfaces des objets composant une scène, indépendamment de l'illuminant et des caractéristiques de l'observateur (ou capteur). Leur utilité ne se limite pas seulement aux applications de vision par ordinateur, mais s'étend à d'autres applications d'imagerie couleur.

La recherche de constance chromatique comporte généralement deux étapes : l'étape d'estimation et l'étape de correction. Lors de l'étape d'estimation, une hypothèse est faite sur la distribution de la couleur des pixels de l'image. Cette hypothèse est utilisée pour estimer les propriétés de l'illuminant de la scène. Lors de l'étape de correction, l'estimation de l'illuminant est utilisée pour la correction des couleurs de la scène, en changeant l'illuminant estimé en un illuminant canonique (l'illuminant canonique est celui pour lequel les capteurs ont été calibrés).

La constance chromatique est un problème sous déterminé ; par conséquent il n'est pas possible de le résoudre de manière générale. Il n'existe jusqu'à présent au-

cune méthode de constance chromatique universelle. Plusieurs stratégies sont disponibles dans la littérature pour obtenir des solutions approximatives. Les algorithmes les plus connus sont : le monde gris (*gray world*), le retinex patch blanc (*white patch retinex*) appelé également réflecteur parfait et le modèle d'adaptation chromatique fondé principalement sur l'hypothèse de Von Kries, [Cardei, 2000]. Malgré leur extrême simplicité, une étude menée par [Funt et al., 1998] a montré empiriquement que ces méthodes empiriques marchent aussi bien voire mieux que d'autres algorithmes plus complexes, quand la couleur est utilisée pour l'appariement d'objets dans une base d'images. D'autre part, ces algorithmes sont souvent utilisés comme composantes de systèmes plus complexes [Finlayson et al., 1990], [Funt & Cardei, 1999]. Un état de l'art complet des différentes méthodes de constance chromatique peut être trouvé dans [Barnard, 1999] et [Chambah et al., 2002].

5.3.1 Hypothèse de Von Kries

Chez l'être humain, le mécanisme visuel qui contrôle l'adaptation des photorécepteurs au type d'illumination courante pour préserver l'apparence d'un objet a été identifié par Johannes Von Kries au début du vingtième siècle. Il considérait que le mécanisme d'adaptation chromatique pouvait s'expliquer uniquement par le contrôle individuel du gain sur les cônes des photorécepteurs (L, M, S) de la rétine et que l'amplitude du gain était une fonction directe de l'illumination ambiante [MacAdam, 1993].

Au début du vingtième siècle, Johannes Von Kries a proposé un modèle d'adaptation qui est encore à la base de plusieurs algorithmes de constance chromatique [Cardei, 2000]. Sa règle d'adaptation stipule que les fonctions de sensibilité spectrale de l'œil sont invariantes et indépendantes, et que l'adaptation du système visuel à différents illuminants est réalisée en ajustant trois coefficients de gain associés aux trois canaux de couleur (L, M, S). Ces coefficients (notés k_L, k_M et k_S dans l'équation 5.20) sont ajustés tels qu'une surface blanche de référence ait une apparence constante. L', M' et S' représentent les stimuli après adaptation :

$$\begin{bmatrix} L' \\ M' \\ S' \end{bmatrix} = \begin{bmatrix} k_L & 0 & 0 \\ 0 & k_M & 0 \\ 0 & 0 & k_S \end{bmatrix} \cdot \begin{bmatrix} L \\ M \\ S \end{bmatrix} \quad (5.20)$$

Les coefficients sont ajustés de telle manière que les stimuli d'une surface blanche de référence (L_w, M_w et S_w) soient constants et égaux à 1 :

$$k_L = \frac{1}{L_w}, \quad k_M = \frac{1}{M_w}, \quad k_S = \frac{1}{S_w} \quad (5.21)$$

La couleur d'un patch blanc de référence peut être aussi interprétée comme étant la couleur de l'illuminant, cette méthode est connue sous le nom de patch blanc (*white patch WP*). En se basant sur ce modèle, plusieurs algorithmes de constance chromatique estiment les stimuli correspondant à une surface blanche dans une scène et utilisent ensuite la règle d'adaptation de Von Kries pour corriger l'image (voir

l'algorithme Retinex).

5.3.2 Méthode Retinex patch blanc

L'une des théories les plus connues de constance chromatique est celle de Retinex de Land, [Land, 1977]. Le terme " Retinex " s'inspire des mots "rétine" et "cortex", suggérant que l'œil et le cerveau sont impliqués dans le processus. Il décrit le mécanisme biologique qui convertit un flux lumineux en mesures de luminance. Cette théorie repose sur des expériences qui confirment que le système visuel convertit le flux lumineux (le signal couleur) en valeurs de luminance qui sont indépendantes du flux d'entrée.

L'ensemble d'algorithmes appelé Retinex [Ciurea & Funt, 2004], [Funt & Ciurea, 2004], proposé à la base par Edwin H. Land, prend en compte les relations locales d'illumination pour reproduire les mécanismes d'adaptation chromatique de la vision humaine [Land, 1977]. Ces mécanismes sont responsables du développement des techniques de constance chromatique et du perfectionnement de la gamme dynamique de tons sur l'image. Land a montré que ces mécanismes de la vision couleur ne sont pas des phénomènes ponctuels et bien localisés mais plutôt des phénomènes complexes qui considèrent l'interdépendance d'un voisinage de photorécepteurs. Autrement dit, la couleur perçue d'un seul point sur une image ne dépend pas de la lumière réfléchiée par ce même point et lui seul, mais résulte de la lumière réfléchiée par ses points voisins. Des illusions d'optiques bien connues témoignent de ce phénomène.

Land a développé plusieurs variantes d'algorithmes Retinex. Le but de tous ces algorithmes est d'obtenir l'information de luminance qui correspond aux réflectances des objets dans l'image pour chaque classe de Retinex. Ce traitement est effectué séparément, mais de la même manière, pour chaque classe de photorécepteur. Après le calcul de l'information de luminance, la deuxième étape de l'algorithme consiste à trouver la zone de réflectance maximale et à déterminer si elle correspond à un patch blanc.

La méthode du patch blanc ou du réflecteur parfait constitue la première version du Retinex, où l'illumination est supposée uniforme. L'hypothèse faite est que les valeurs maximales de chaque canal représentent la réflectance maximale possible de l'illuminant, comme celle causée par une réflexion spéculaire ou un objet naturellement blanc dans l'image, sensés générer des valeurs maximales de tristimulus couleur. Cela revient à diviser chaque canal par la valeur maximale trouvée dans l'image. L'équation donne les valeurs R_c, G_c, B_c :

$$\begin{bmatrix} R_c \\ G_c \\ B_c \end{bmatrix} = \begin{bmatrix} k_R & 0 & 0 \\ 0 & k_G & 0 \\ 0 & 0 & k_B \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (5.22)$$

où

$$\begin{aligned} k_R &= \frac{1}{\alpha} = \frac{S_r}{\rho_r} \\ k_G &= \frac{1}{\beta} = \frac{S_g}{\rho_g} \\ k_B &= \frac{1}{\gamma} = \frac{S_b}{\rho_b} \end{aligned} \quad (5.23)$$

avec

$$(\rho_r, \rho_g, \rho_b) = \max(R, G, B) \quad (5.24)$$

$$(S_r, S_g, S_b) = (255, 255, 255) \quad (5.25)$$

Les valeurs $\rho_r, \rho_g, \rho_b, S_r, S_g$ et S_b sont déterminées empiriquement ou basées sur des connaissances a priori.

Dans une version plus récente de l'algorithme Retinex [Land, 1986], les valeurs de la luminance sont calculées à partir des valeurs logarithmique des réponses des capteurs, indépendamment sur toutes les composantes chromatiques. Ainsi, l'algorithme utilise des différences de logarithmes au lieu des rapports de valeurs linéaires, où les valeurs de la luminance L_p sont calculées sur un point x_p influencé par un ensemble de N points x_i choisis aléatoirement dans son voisinage :

$$L_p = \frac{1}{N} \sum_{i=1}^N (\log(I(x_p)) - \log(I(x_i))) \quad (5.26)$$

Le fait d'utiliser LES valeurs logarithmiques des réponses des capteurs n'a pas amélioré la performance de l'algorithme [Brainard & Wandell, 1986]. L'une des faiblesses de l'algorithme Retinex est qu'il peut être difficile de déterminer la valeur maximale en présence de bruit due à la saturation des capteurs. L'autre faiblesse est que la réponse maximale d'un canal peut ne pas être caractéristique de la couleur de l'illuminant.

5.3.3 Algorithme du monde gris

Cet algorithme part de l'hypothèse que le monde est un mélange équilibré de toutes les couleurs et que sa teinte moyenne est donc grise. Il suffit donc pour neutraliser l'illuminant d'ajuster les réponses des capteurs, pour que la moyenne soit grise et obtenir ainsi une description des objets indépendante de la couleur des sources de lumière. En effet, selon l'hypothèse du monde gris, si une quantité suffisante de couleurs est présente dans une image, la couleur moyenne sur toute celle-ci devra être proche du gris. En fonction de cette valeur moyenne, il sera possible d'estimer les gains qui corrigeront chromatiquement l'image. Puisque la méthode du monde gris pose l'hypothèse que la moyenne de chacun des trois canaux sur toute l'image forme un rapport fixe sous l'illuminant canonique, La correction s'effectue comme dans l'équation 5.22 en choisissant les coefficient diagonaux comme :

$$(\rho_r, \rho_g, \rho_b) = (R_{moyenne}, G'_{moyenne}, B_{moyenne})$$

(5.27)

$$(S_r, S_g, S_b) = (v, v, v) \quad (5.28)$$

Les valeurs S_r, S_g, S_b sont déterminées ici d'une manière empirique ou basées sur une connaissance a priori de la distribution des couleurs dans les images à corriger.

Nous constatons expérimentalement que le monde gris corrige correctement les zones en demi-teinte et sombres de l'image, mais génère fréquemment dans les zones claires une dominante initiale de couleur complémentaire à la dominante de l'image.




Figure 5.5 – Mire couleur IT8.7/2

ANNEXE B Séparateurs à Vaste Marge

5.4 Cas des données linéairement séparables

Soit une base d'exemples $\{\vec{x}_i, y_i\}, i = 1, \dots, n$ constituant un ensemble de données linéairement séparables, où \vec{x}_i désigne le vecteur d'observation et y_i , label de la classe, appartient à $\{-1, 1\}$ pour un problème à deux classes. Le but d'un SVM est de trouver un hyperplan H séparant les points \vec{x}_i en deux populations, de telle manière que les points \vec{x}_i appartenant à la même classe se trouvent d'un même côté de l'hyperplan (cf. Figure 5.6). Un hyperplan est dit optimal (à marge maximale) s'il sépare sans erreur les exemples de la base d'apprentissage (\vec{x}_i, y_i) et s'il est situé à une distance maximale des vecteurs les plus proches de la base. Soit le couple de paramètres $\langle w, b \rangle$ caractérisant l'équation de cet hyperplan (w est le vecteur normal à l'hyperplan et b est le biais) donnée par :

$$w \cdot \vec{x} + b = 0 \quad (5.29)$$

On peut écrire pour chaque couple (x_i, y_i) de l'ensemble :

$$\begin{cases} \vec{w} \cdot \vec{x}_i + b > 0 & \text{pour les points de la classe 1} \\ \vec{w} \cdot \vec{x}_i + b < 0 & \text{pour les points de la classe 2} \end{cases} \iff \begin{cases} \vec{w} \cdot \vec{x}_i + b \geq +1 & \text{si } y_i = +1 \\ \vec{w} \cdot \vec{x}_i + b \leq -1 & \text{si } y_i = -1 \end{cases} \quad (5.30)$$

Ce qui peut se résumer par une description unifiée de l'ensemble des conditions :

$$y_i(\vec{w} \cdot \vec{x}_i + b) \geq +1, \quad \forall i \in \{1, \dots, n\} \quad (5.31)$$

Les points pour lesquels la partie haute de l'équation 5.31 est vérifiée sont situés sur l'hyperplan $H_1 : \vec{x}_i \cdot \vec{w} + b = 1$ avec une normale \vec{w} et une distance perpendiculaire à l'origine de $|1 - b|/||w||$. De même, les points pour lesquels la partie basse de l'équation 5.31 est vérifiée sont situés sur l'hyperplan $H_2 : \vec{x}_i \cdot \vec{w} + b = -1$ avec une normale \vec{w} et une distance perpendiculaire à l'origine de $|-1 - b|/||w||$. Par conséquent, $d_+ = d_- = 1/||\vec{w}||$ et la marge est simplement $2/||\vec{w}||$. Notons que H_1 et H_2 sont parallèles (même normale) et qu'aucun point des classes ne se trouve entre eux.

Pour construire cet hyperplan optimal, on doit maximiser la marge $2/||\vec{w}||$ ou

encore minimiser $\|\vec{w}\|^2/2$, ce que s'exprime par :

$$\min_{\vec{w}, b} \left(\frac{1}{2} \|\vec{w}\|^2 \right) \text{ sous la contrainte } y_i(\vec{w} \cdot \vec{x}_i + b) \geq 1, \forall i = 1, \dots, n. \quad (5.32)$$

Ce problème peut se résoudre en utilisant les multiplicateurs de Lagrange associés aux contraintes d'inégalité, appelés également variables duales et le dual lagrangien de ce problème. On est donc amené à rechercher un point selle w^*, b^*, α^* du lagrangien :

$$L(\vec{w}, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^n \alpha_i [y_i(\vec{w} \cdot \vec{x}_i + b) - 1] \quad (5.33)$$

où $\alpha_i, i = 1, \dots, n$ désignent les coefficients de Lagrange. Au point selle, la valeur de L est minimum pour $\vec{w} = \vec{w}^*$ et $b = b^*$ et maximum pour $\alpha = \alpha^*$. Minimiser le Lagrangien par rapport aux (w, b) , conduit à :

$$\begin{cases} \frac{dL}{d\vec{w}} = 0 \Rightarrow \vec{w}^* = \sum_{i=1}^n \alpha_i^* y_i \vec{x}_i \\ \frac{dL}{db} = 0 \Rightarrow \sum_{i=1}^n \alpha_i^* y_i = 0 \end{cases} \quad (5.34)$$

On peut ainsi transformer le problème initial en son dual, afin d'obtenir α^* en maximisant la forme suivante du lagrangien :

$$Ld(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j \quad (5.35)$$

sous les contraintes

$$\sum_{i=1}^n \alpha_i y_i = 0 \text{ et } \alpha_i \geq 0 \quad (5.36)$$

Il suffit alors de résoudre le problème d'optimisation quadratique 3.11 pour déterminer $\alpha_i, i = 1, \dots, n$, et calculer ensuite $w^* \cdot \vec{x} = \sum_{i=1}^n \alpha_i^* y_i$. De plus, la condition complémentaire de Karush Kuhn Tucker (KKT) donne :

$$\alpha_i^* [y_i(\vec{w}^* \cdot \vec{x}_i + b^*) - 1] = 0 \quad (5.37)$$

Celle-ci divise l'ensemble des points en deux parties : les \vec{x}_i dont les α_i correspondants sont nuls et les autres dont les α_i sont strictement positifs. Dans le premier cas la contrainte linéaire perd son effet, comme elle est automatiquement satisfaite dans l'optimisation du problème dual, elle est inactive. Dans le deuxième cas, les points \vec{x}_i pour lesquels $\alpha_i \neq 0$ (contraintes actives) sont appelés **vecteurs de support** et se trouvent sur les hyperplans H_1 et H_2 parallèles à H (cf. Figure 5.6). En d'autres termes, ce sont les seuls vecteurs utiles pour le calcul de l'hyperplan optimal. Finalement l'hyperplan de décision est :

$$f(\vec{x}) = \sum_{i=1}^n \alpha_i^* y_i \vec{x}_i \cdot \vec{x} + b^* \quad (5.38)$$

La classe d'un nouveau point \vec{x} est simplement donnée par le signe de $f(\vec{x})$.

5.5 Cas des données linéairement non-séparables

Dans la plupart des problèmes pratiques, les données ne sont pas séparables par un simple hyperplan. Il convient de modifier l'approche précédente afin de prendre en compte la possibilité d'observations mal classées. Une solution à ce problème consiste à reformater les conditions de l'équation 5.31 en incorporant des paramètres ξ_i permettant d'assouplir les contraintes :

$$\begin{cases} y_i(\vec{w} \cdot \vec{x}_i + b) \geq +1 - \xi_i & \forall i = 1, \dots, n \\ \xi_i \geq 0 \end{cases} \quad (5.39)$$

Une erreur est commise sur une observation \vec{x}_i par la structure de décision utilisée si $\xi_i > 1$. La fonction $\sum_{i=1}^n \xi_i$ constitue donc un coût caractérisant les erreurs commises sur les éléments de l'ensemble d'apprentissage. Le problème d'optimisation doit être reformulé de manière à minimiser l'erreur de classification de la structure de décision conjointement avec la maximisation de la marge. Ceci revient à minimiser l'expression :

$$\frac{1}{2} \|\vec{w}\|^2 + C \sum_{i=1}^n \xi_i \quad (5.40)$$

sous les contraintes de l'équation 5.39, où C est un paramètre choisi par l'utilisateur. Il permet de faire un compromis entre le nombre de points mal classés et le maximum de distance du point le plus proche de l'hyperplan séparateur. Plus C est choisi grand, plus les erreurs sont pénalisées. L'hyperplan est celui qui vérifie la minimisation des paramètres (équation 5.40) sous les contraintes 5.39. Le lagrangien du problème primal s'écrit maintenant :

$$L(\vec{w}, b, \alpha, \beta) = \frac{1}{2} \|\vec{w}\|^2 + C \sum_{i=1}^n \xi_i - \sum_{i=1}^n \alpha_i [y_i(\vec{w} \cdot \vec{x}_i + b) - 1 + \xi_i] - \sum_{i=1}^n \beta_i \xi_i \quad (5.41)$$

où $\alpha_i, \beta_i, i = 1, \dots, n$, désignent les coefficients de Lagrange. Au point selle, la valeur de L est minimum pour $\vec{w} = \vec{w}^*$, $b = b^*$ et $\xi_i = \xi_i^*$ et maximum pour $\alpha = \alpha^*$ et $\beta = \beta^*$. Minimiser le lagrangien par rapport aux (\vec{w}, b, ξ_i) , fournit les équations :

$$\begin{cases} \frac{dL}{d\vec{w}} = 0 \Rightarrow \vec{w}^* = \sum_{i=1}^n \alpha_i^* y_i \vec{x}_i \\ \frac{dL}{db} = 0 \Rightarrow \sum_{i=1}^n \alpha_i^* y_i = 0 \\ \frac{dL}{d\xi_i} = 0 \Rightarrow \alpha_i + \beta_i = C \end{cases} \quad (5.42)$$

La résolution du problème est ainsi ramenée à sa formulation duale, où on doit déterminer $\alpha_i, i = 1, \dots, n$, et calculer \vec{w}^* pour obtenir l'équation de l'hyperplan optimal en fonction des α_i , en maximisant :

$$Ld(\alpha) = \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i,j=1}^n \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j \quad (5.43)$$

sous les contraintes :

$$\sum_{i=1}^n \alpha_i y_i = 0 \text{ et } 0 \leq \alpha_i \leq C \quad (5.44)$$

Les conditions complémentaires KKT donnent :

$$\begin{aligned} \alpha_i^* [y_i(\vec{w}^* \cdot \vec{x}_i + b^*) - 1 + \xi_i] &= 0 \\ \beta_i \cdot \xi_i &= 0 \end{aligned} \quad (5.45)$$

Ici, les vecteurs de support correspondent aux observations les plus proches de l'hyperplan optimal et vérifient la condition $0 < \alpha_i < C$, comme dans le cas des données linéairement séparables. Cette méthode est connue sous le nom de SVM à marge douce (ou *soft margin SVM*).

Un des problèmes posés par cette approche est le choix du paramètre C . Il doit être choisi de manière empirique en fonction de la connaissance du bruit sur les données. Plus C est grand, plus on pénalise les erreurs ; plus les variables de relâchement ξ prennent de faibles valeurs, et plus la marge de tolérance aux erreurs est petite. Dans le cas où C tend vers $+\infty$, la solution converge vers la même solution que celle obtenue pour le problème de recherche de l'hyperplan séparateur sans terme de pénalisation, mais appliqué aux données non linéairement séparables. Ceci se justifie aussi par le fait que les α_i ne sont pas bornés dans le problème initial. Réciproquement, plus C est petit, plus la marge de tolérance aux erreurs est grande, et plus il y aura de vecteurs qui tombent dans la zone entre les deux hyperplans séparateurs. Dans le cas extrême où C tend vers 0, la marge devient si grande que tous les points tombent dans la zone de marge. Le modèle à marge douce perd alors de son sens et l'algorithme converge vers une solution triviale.

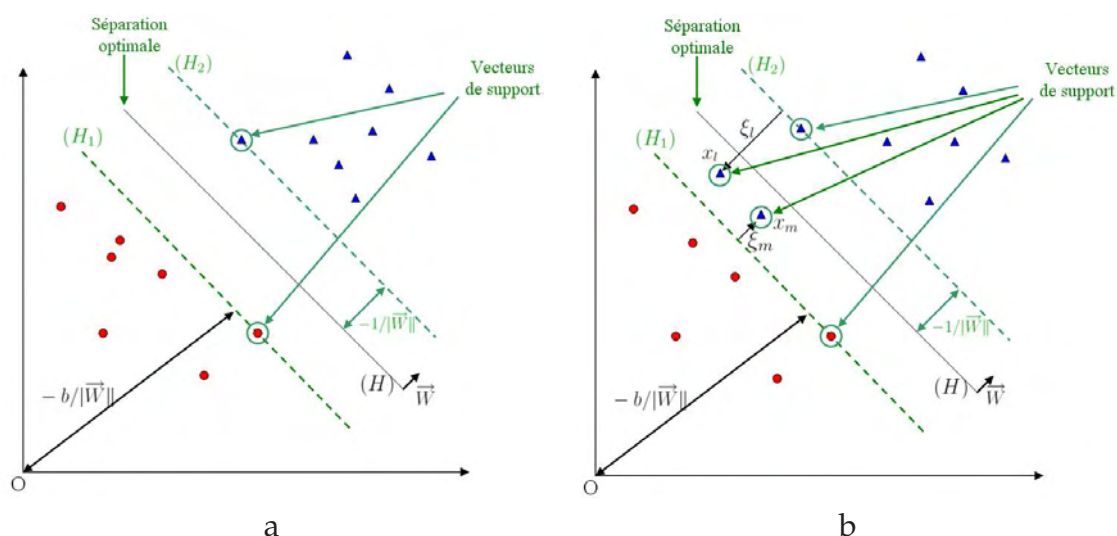


Figure 5.6 – Principe des SVM dans le cas de deux ensembles de données. (a) cas linéairement séparable par un hyperplan H de marge maximale. Les vecteur de support, indiqués dans la figure, désignent les échantillons les plus proches de H . (b) cas linéairement non séparable.

5.6 Cas des données non séparables

Des frontières de décision linéaires sont très limitées pour résoudre tous les problèmes de classification. Pour permettre aux SVM de répondre à des problèmes complexes de classification, l'algorithme initial présenté précédemment a été transformé pour élaborer des structures de détection non-linéaires. L'extension au cas non-linéaire peut être effectuée en transformant les observations à l'aide d'une fonction Φ puis en appliquant un détecteur linéaire. L'idée est donc de projeter les points d'apprentissage dans un espace H donné, grâce à la fonction $\Phi(x)$ et d'appliquer la même méthode d'optimisation de la marge dans l'espace H .

Dans la formulation précédente, les observations \vec{x}_i , interviennent seulement par les produits scalaires $\vec{x}_i \cdot \vec{x}_j$. L'idée consiste à remplacer le produit scalaire par une fonction $K(\vec{x}_i, \vec{x}_j)$ appelée fonction **noyau**. Cela nécessite une transformation de l'espace vectoriel initial en un espace euclidien (qui peut avoir une dimension infinie) appelé espace de Hilbert.

$$\begin{aligned} \Phi : R^n &\rightarrow H \\ (\vec{x}_i, \vec{x}_j) &\mapsto \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) = K(\vec{x}_i, \vec{x}_j) \end{aligned} \tag{5.46}$$

En présentant cette nouvelle fonction noyau $K(\vec{x}_i, \vec{x}_j)$ dans l'expression d'un SVM linéaire, on obtient la fonction de décision suivante non-linéaire :

$$f(x) = \sum_{i=1}^n \alpha_i^* y_i K(\vec{x}_i, \vec{x}) + b \tag{5.47}$$

Bibliographie

- [Abrardo et al., 1996] Abrardo, A., Cappellini, V., Cappellini, M., & Mecocci, A. (Scottsdale, Arizona. 1996). Art-works colour calibration using the vasari scanner. In *Proceedings of IST and SID's 4th Color Imaging Conference : Color Science, Systems and Applications*, (pp. 94–97). (Cité page 150.)
- [Acha et al., 2003] Acha, B., Serrano, C., I Acha, J., & Roa, M. L. (2003). Cad tool for burn diagnosis. *Inf. Process Med Imaging*, 18, 294–305. (Cité pages v, 20, 21 et 72.)
- [Ahonen et al., 2006] Ahonen, T., Hadid, A., & Pietikäinen, M. (2006). Face description with local binary patterns : application to face recognition. *IEEE Trans Pattern Anal Mach Intell*, 28(12), 2037–2041. (Cité page 80.)
- [Alberg et al., 2004] Alberg, A. J., Park, J. W., Hager, B. W., Brock, M. V., & Diener-West, M. (2004). The use of "overall accuracy" to evaluate the validity of screening or diagnostic tests. *Journal of General Internal Medicine*, 19, 460–465. (Cité page 91.)
- [Albouy et al., 2007] Albouy, A., Treuillet, S., & Lucas, Y. (2007). Finding two optimal positions of a hand-held camera for the best 3d reconstruction,. In *3DTV-Conference, Kos Island, Grèce* (pp. 1–4). (Cité page 115.)
- [Albouy, 2006] Albouy, B. (2006). *Relevé Volumétrique par Stéréovision à partir de Deux Vues non Calibrées - Application au Suivi Thérapeutique d'Escarres*. PhD thesis, Université d'Orléans. (Cité pages 14, 26, 29 et 115.)
- [ANAES, 2001] ANAES (2001). Conférence de consensus. prévention et traitement des escarres de l'adulte et du sujet âgé. In *ANAES : Agence Nationale d'Accréditation et d'Evaluation en Santé* Hôpital Européen Georges-Pompidou, Paris. (Cité pages 8 et 11.)
- [Arnqvist et al., 1988] Arnqvist, J., Hellgren, J., & Vincent, J. (1988). Semiautomatic classification of secondary healing ulcers in multispectral images. In *Proc. th International Conference on Pattern Recognition*, volume 1 (pp. 459–461). (Cité page 18.)
- [Barbut et al., 2006] Barbut, F., Paryzbut, B., Boëlle, P., Farid, D. N. R., Kosmann, M., & Luquel, L. (2006). Escarres dans un hôpital universitaire de court séjour. prévalence, facteurs de risque et modalités de prise en charge. *Presse Med*, 35(14), 769–778. (Cité page 11.)
- [Barnard, 1999] Barnard, K. (1999). *Practical color constancy*. PhD thesis, Simon Fraser University, School of Computing, Burnaby, B.C., Canada. (Cité page 151.)

- [Belem, 2004] Belem, B. (2004). *Non-Invasive Wound Assessment by Image Analysis*. PhD thesis, University of Glamorgan, Wales - UK. (Cité pages v, 16, 17 et 72.)
- [Berriss & Sangwine, 1997] Berriss, W. & Sangwine, S. (1997). A colour histogram clustering technique for tissue analysis of healing skin wounds. In *Proc. Sixth Int. Conf. on Image Processing and its Applications*, volume 2 (pp. 693–697). (Cité pages 18 et 74.)
- [Bottou et al., 1994] Bottou, L., Cortes, C., Denker, J., Drucker, H., Guyon, I., Jackel, L., Cun, Y. L., Müller, U., Säcker, E., Simard, P., & Vapnik, V. (1994). Comparison of classifier methods : A case study in handwritten digit recognition. In *Proceedings of the 13th International Conference on Pattern Recognition*. (Cité page 93.)
- [Boujemaa & Vertan, 2000] Boujemaa, N. & Vertan, C. (2000). Upgrading color distributions for image retrieval : can we do better ? In *Proc. of International Conference on Visual Information System (VISoo)* (pp. 178–188). (Cité page 72.)
- [Brainard & Wandell, 1986] Brainard, D. H. & Wandell, B. A. (October 1986). Analysis of the retinex theory of color vision. *J Opt Soc Am A*, 3, 1651–1661. (Cité page 153.)
- [Burges, 1998] Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data Mining and Knowledge Discovery*, 2, 121–167. (Cité page 92.)
- [Busin et al., 2004] Busin, L., Vandenbroucke, N., Macaire, L., & Postaire, J. (2004). Color space selection for unsupervised color image segmentation by analysis of connectedness properties. In *First Int. Conf. on Complex Systems Intelligence and Modern Technological Applications (SEE, ed.)*, (Cherbourg, France) (pp. 311–316). (Cité page 69.)
- [Callieri et al., 2003] Callieri, M., Cignoni, P., Coluccia, M., Gaggio, G., Pingi, P., Romanelli, M., & Scopigno, R. (2003). Derma : monitoring the evolution of skin lesions with a 3d system. In *8th Int. Workshop on Vision, Modeling and Visualization* (pp. 167–174). Munich, 2003. (Cité page 24.)
- [Cardei, 2000] Cardei, V. C. (2000). *A neural network approach to colour constancy*. PhD thesis, Simon Fraser University. (Cité page 151.)
- [Carson et al., 1997] Carson, C., Belongie, S., Greenspan, H., & Malik, J. (1997). Region-based image querying. In *Proc. IEEE Workshop on Content-Based Access of Image and Video Libraries* (pp. 42–49). (Cité page 82.)
- [Carson et al., 2002] Carson, C., Belongie, S., Greenspan, H., & Malik, J. (2002). Blobworld : image segmentation using expectation-maximization and its application to image querying. *IEEE Trans on Pattern Anal and Machine Intell.* (PAMI), 24(8), 1026–1038. (Cité pages 71, 73 et 83.)
- [Celebi et al., 2005] Celebi, M., Aslandogan, Y. A., & Bergstresser, P. (2005). Unsupervised border detection of skin lesion images. In *Proc. Int Conf on Information Technology : Coding and Computing ITCC05*, volume 2 (pp. 123–128). (Cité pages v, 22 et 23.)
- [Chambah et al., 2002] Chambah, M., Besserer, B., & Courtellemont, P. (2002). Recent progress in automatic digital restoration of color motion pictures. In *SPIE Electronic Imaging*, volume 4663 (pp. 98–109). San Jose, CA, USA. (Cité page 151.)

- [Chang & Lin, 2001] Chang, C.-C. & Lin, C.-J. (2001). LIBSVM : a library for support vector machines. In *software available at <http://www.csie.ntu.edu.tw/~cjlin/libsvm>*. (Cité page 92.)
- [Chapelle et al., 2001] Chapelle, O., Vapnik, V., Bousquet, O., & Mukherjee, S. (2001). Choosing kernel parameters for support vector machines. *Machine Learning*, (pp. 131–160). (Cité page 95.)
- [Chesnaud et al., 1999] Chesnaud, C., Refregier, P., & Boulet, V. (1999). Statistical region snake-based segmentation adapted to different physical noise models. *IEEE Trans on Pattern Anal and Machine Intell. (PAMI)*, 21(11), 1145–1157. (Cité page 52.)
- [Chou, 1995] Chou, K. C. (1995). A novel approach to predicting protein structural classes in a (20-1)-d amino acid composition space. *Proteins*, 21(4), 319–344. (Cité page 97.)
- [Chung & Sapiro, 2000] Chung, D. H. & Sapiro, G. (2000). Segmenting skin lesions with partial differential equations based image processing algorithms. In *Proc. Int.Conf. on Image Processing*, volume 3 (pp. 404–407). (Cité page 21.)
- [CIE, 1931] CIE (1931). *CIE. Compte rendu de la huitième session. Technical report*. Technical report, Cambridge University Press, Cambridge. (Cité pages 35, 69 et 145.)
- [CIE, 1995] CIE (1995). *CIE. Industrial colour-difference evaluation*. Technical report, Bureau Central CIE, Vienna, Rapport technique 116. (Cité pages 35 et 150.)
- [Ciurea & Funt, 2004] Ciurea, F. & Funt, B. (January 2004). Tuning retinex parameters. *Journal of Electronic Imaging*, 13, 58–64. (Cité page 152.)
- [Cohen, 1960] Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educ Psychol Meas*, 20, 27–46. (Cité page 103.)
- [Colot et al., 1998] Colot, O., Devinoy, R., Sombo, A., & De Brucq, D. (1998). A colour image processing method for melanoma detection. *Lecture Notes in Computer Science*, 1496, 562–569. (Cité page 21.)
- [Comaniciu & Meer, 2002] Comaniciu, D. & Meer, P. (2002). Mean shift : a robust approach toward feature space analysis. *IEEE Trans on Pattern Anal and Machine Intell. (PAMI)*, 24(5), 603–619. (Cité pages 53, 55 et 75.)
- [Comon, 1994] Comon, P. (1994). Independent component analysis, a new concept. *Signal Processing*, 36(3), 287–314. (Cité page 88.)
- [Cormen et al., 1990] Cormen, T. H., Leiserson, C. E., & Rivest., R. L. (1990.). *Introduction to Algorithms*. McGraw-Hill Book Company. (Cité page 55.)
- [Cuzzell, 1988] Cuzzell, J. Z. (1988). The new ryb color code. *American Journal of Nursing*, 88(10), 1342–1346. (Cité pages 13 et 38.)
- [Delorme & Flückiger, 2003] Delorme, A. & Flückiger, M. (2003). *Perception et réalité. Une introduction à la psychologie des perceptions*. De Boeck. (Cité page 35.)
- [Deng et al., 1999] Deng, Y., Kenney, S. and Moore, M., & Manjunath, B. S. (1999). Peer group filtering and perceptual color image quantization. In *Proc. IEEE Int. Symp. on Circuits and Systems VLSI (ISCAS'99)*, volume vol 4 (pp. pp.21–4). Orlando, FL. (Cité pages 58 et 75.)

- [Deng & Manjunath, 1999] Deng, Y. & Manjunath, B. S. (1999). An efficient low-dimensional color indexing scheme for region based image retrieval. In *Proc. IEEE Intl. Conf. on Acoustics, Speech and Signal Processing (ICASSP'99)* Phoenix, Arizona. (Cité page 75.)
- [Deng & Manjunath., 2001] Deng, Y. & Manjunath., B. S. (2001). Unsupervised segmentation of colour-texture regions in images and video. *IEEE Trans on Pattern Anal and Machine Intelli (PAMI)*, 23(8), 800– 810. (Cité pages 53 et 57.)
- [D.I. & Tzevelekou, 2007] D.I., K. & Tzevelekou, F. (2007). Automated pressure ulcer lesion diagnosis for telemedicine systems. 26(5), 18–22. (Cité page 20.)
- [Duan et al., 2003] Duan, K., Keerthi, S. S., & Poo, A. N. (2003). Evaluation of simple performance measures for tuning svm hyperparameters. *Jornal of Neurocomputing*, 51, 41–59. (Cité page 95.)
- [Duda & Hart, 1970] Duda, R. & Hart, P. (1970). *Pattern Classification and Scene Analysis*. New York, : John Wiley & Sons. (Cité page 58.)
- [Dunn & Higgins, 1995] Dunn, D. & Higgins, W. (1995). Optimal gabor filters for texture segmentation. *IEEE. Trans. on Image Processing*, 4, 947–964. (Cité page 78.)
- [E308-01, 2001] E308-01, A. (2001). *Standard practice for computing the colors of objects by using the CIE system*. Technical report, ASTM International, p. 769. (Cité page 41.)
- [Fairchild, 1998] Fairchild, M. D. (1998). *Color appearance models*. Addison Wesley. (Cité page 41.)
- [Fan et al., 2001] Fan, J., Yau, D. Y., Elmagarmid, A. K., & Aref, W. G. (2001). Automatic image segmentation by integrating color-edge extraction and seeded region growing. *IEEE Trans Image Process*, 10(10), 1454–1466. (Cité page 52.)
- [Felzenszwalb & Huttenlocher, 2004] Felzenszwalb, P. & Huttenlocher, D. (Septembre 2004). Efficient graph-based image segmentation. *International Journal of Computer Vision*, 59(2), 167–181. (Cité pages 53, 54 et 55.)
- [Fernandez-Maloigne, 2005] Fernandez-Maloigne, F. (2005). Les modèles d'apparence couleur. In *Université de Poitier, Laboratoire SIC - EHINC'05*. (Cité page 40.)
- [Finlayson et al., 1994] Finlayson, G., Drew, M., & B., F. (1994). Color constancy : generalized diagonal transforms suffice. *J. Opt. Soc. Am. A*, 11(11), 3011–3020. (Cité page 42.)
- [Finlayson et al., 1993] Finlayson, G., Drew, M. S., & Funt, B. (1993). Diagonal transforms suffice for color constancy. In *IEEE proceedings : International Conference on Computer Vision* (pp. 164–171). (Cité page 42.)
- [Finlayson & Schaefer, 2001] Finlayson, G. & Schaefer, G. (2001). Colour indexing across devices and viewing conditions. In *Proceedings of 2nd Int. Workshop on Content-based MultiMedia Indexing* (pp. 215–221). Brescia, Italy. (Cité page 75.)
- [Finlayson et al., 1990] Finlayson, G. D., B., S., & L., C. J. (1990). Comprehensive colour image normalization. In *European Conference on Computer Vision* (pp. 475–490). (Cité page 151.)

- [Fisher, 1936] Fisher, R. (1936). The use of multiple measurements in taxonomic problems. In *Annals of Eugenics*, volume 7 (pp. 179–188). (Cité page 85.)
- [Ford & Roberts, 1998] Ford, A. & Roberts, A. (1998). *Color space conversions*. Technical report, Technical report. (Cité page 144.)
- [Friedman, 1996] Friedman, J. (1996). *Another approach to polychotomous classification*. Technical report, Technical report, Department of Statistics, Stanford University. (Cité page 93.)
- [Fukunaga & Hostetler, 1975] Fukunaga, K. & Hostetler, L. (1975). The estimation of the gradient of a density function, with applications in pattern recognition. *IEEE Trans. on Information Theory*, 21(1), 32–40. (Cité page 55.)
- [Funt & Cardei, 1999] Funt, B. & Cardei, V. C. (1999). Bootstrapping color constancy. In *proceedings of SPIE Electronic imaging*, volume IV (pp. 36–44). (Cité page 151.)
- [Funt & Ciurea, 2004] Funt, B. & Ciurea, F. (January 2004). Retinex in matlabm. *Journal of Electronic Imaging*, 13, 48–57. (Cité page 152.)
- [Funt et al., 1998] Funt, B., K., B., & L., M. (June 1998). Is colour constancy good enough? In *in Proceedings of the 5th European Conference on Computer Vision*, volume volume 1, (pp. pages 445 – 459.). Freiburg, Germany. (Cité page 151.)
- [Galushka et al., 2005] Galushka, M., Zheng, H., Patterson, D., & L., B. (2005). Case-based tissue classification for monitoring leg ulcer healing. In *Proc. 18th IEEE Symposium on Computer-Based Medical Systems* (pp. 353–358). (Cité pages 19, 75 et 77.)
- [Gouet, 2000] Gouet, V. (2000). *Mise en correspondance d'images en couleurs, application à la synthèse de vues intermédiaires*. PhD thesis, Université Montpellier II Sciences et Techniques du Languedoc. (Cité page 115.)
- [Graham et al., 2000] Graham, D., Finlayson, & Süsstrunk :, S. (2000). Performance of a chromatic adaptation transform based on spectral sharpening. In *Color Imaging Conference* (pp. 49–55). Scottsdale, Arizona. (Cité page 41.)
- [Grecu & Lambert, 2001] Grecu, H. & Lambert, P. (2001). Image retrieval by partial queries. In *Proc. International Conference on Image Processing*, volume 1 (pp. 26–29). (Cité page 75.)
- [Guermeur, 2007] Guermeur, Y. (2007). *SVM Multiclass - Théorie et Applications*. PhD thesis, Habilitation à Diriger des Recherches de l'Université Nancy I. (Cité page 92.)
- [Haeghen et al., 2000] Haeghen, Y. V., Naeyaert, J. M., Lemahieu, I., & Philips, W. (2000). An imaging system with calibrated color image acquisition for use in dermatology. *IEEE Trans Med Imaging*, 19(7), 722–730. (Cité page 42.)
- [Hansen et al., 1997] Hansen, G., Sparrow, E., Kokate, J., K.J., L., & Iaizzo, P. (1997). Wound status evaluation using color image processing. 16(1), 78–86. (Cité page 16.)
- [Haralick & K., 1973] Haralick, R. M. & K., S. (1973). Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3(6), 610–621. (Cité pages 19 et 76.)
- [Hardeberg, 1999] Hardeberg, J. Y. (1999). *Acquisition and Reproduction of Color Images : Colorimetric and Multispectral Approaches*. PhD thesis, Ecole Nationale Supérieure des Télécommunications, Paris, France. (Cité page 150.)

- [Harris & Stephens, 1998] Harris, C. & Stephens, M. (1998). A combined corner and edge detector. In *Proceedings of The Fourth Alvey Vision Conference* (pp. 147–151). Manchester, Royaume-Uni. (Cité page 40.)
- [Hayden & Oulton, 1994] Hayden, S. L. & Oulton, D. P. (1994). The quantification of small visual colour differences. In *Journal of the Society of Dyers and Colourists JSDC*, volume 110. (Cité page 150.)
- [Herbin et al., 1993] Herbin, M., Bon, F., Venot, A., Jeanlouis, F., Dubertret, M., Dubertret, L., & Strauch, G. (1993). Assessment of healing kinetics through true color image processing. 12(1), 39–43. (Cité pages 15 et 71.)
- [Herbin et al., 1990] Herbin, M., Venot, A., Devaux, J., & Piette, C. (1990). Color quantitation through image processing in dermatology. 9(3), 262–269. (Cité pages 15 et 71.)
- [Hirata et al., 2002] Hirata, K., E., K., & Hara, Y. (2002). On image segmentation for object-based image retrieval. In *Proc. 16th International Conference on Pattern Recognition*, volume 3 (pp. 1031–1034). (Cité page 75.)
- [Hordley et al., 2002] Hordley, S., Finlayson, G., Schaefer, G., & et Tian, G. (2002). *Illuminant and Device Invariant Colour Using Histogram Equalisation*. Technical report, Technical report sys-co2-16, School of Information Systems, University of East Anglia, Norwich, United Kingdom. (Cité page 75.)
- [Hsu & Lin, 2002] Hsu, C.-W. & Lin, C. J. (2002). A comparison of methods for multi-class support vector machines. *IEEE Transactions on Neural Networks*, 13, 415–425. (Cité page 93.)
- [Huang et al., 1997] Huang, J., Kumar, S., Mitra, M., Zhu, W.-J., & Zabih, R. (1997). Image indexing using color correlograms. In *Proc. IEEE Computer Society Conference on Computer Vision and Pattern Recognition* (pp. 762–768). (Cité page 72.)
- [Huang et al., 1996] Huang, T., S., M., & Ramchandran, K. (1996). Multimedia analysis and retrieval system (mars) project. *Proceedings of the 33rd Annual Clinic on Library Application of Data Processing - Digital Image Access and Retrieval*. (Cité page 70.)
- [Hurri, 2005] Hurri, J. (2005). The fastica package for matlab v. 2.5. In [<http://www.cis.hut.fi/projects/ica/fastica/>]. (Cité pages 88 et 102.)
- [Hyvarinen, 1999] Hyvarinen, A. (1999). Fast and robust fixed-point algorithms for independent component analysis. *IEEE Trans on Neural Networks*, 10(3), 626–634. (Cité page 88.)
- [Hyvarinen & Oja, 2000] Hyvarinen, A. & Oja, E. (2000). Independent component analysis : Algorithms and applications. *Neural Networks*, 13(4), 411–430. (Cité page 88.)
- [Joachims, 1999] Joachims, T. (1999). SVMlight library for support vector machine. In *Software available at <http://svmlight.joachims.org/>*. (Cité page 92.)
- [Joachims, 2000] Joachims, T. (2000). Estimating the generalization performance of a svm efficiently. In *Proceedings of the International Conference on Machine Learning* Morgan Kaufman. (Cité page 92.)

- [Jones & Plassmann, 1995] Jones, B. F. & Plassmann, P. (1995). An instrument to measure the dimensions of skin wounds. *42(5)*, 464–470. (Cité page 18.)
- [Jones et al., 2006] Jones, C. D., Plassmann, P., Stevens, R. F., R., P. M., & McCarthy, M. B. (2006). *Good Practice Guide to the use of MAVIS II*. Technical report, Medical Imaging Research Unit Technical Report TR-07-06, University of Glamorgan. (Cité pages v, 24 et 42.)
- [Jones, 1999] Jones, T. (1999). *Improving the Precision of Leg Ulcer Area Measurement*. PhD thesis, University of Glamorgan, Wales-UK. (Cité page 21.)
- [Judd, 1930] Judd, D. B. (1930). *Reduction of data on mixture of color stimuli*. Technical Report 515-548, Bureau of Standards Journal Research, 4(163). (Cité pages 69 et 146.)
- [Kang, 1997] Kang, H. (1997). Color technology for electronic imaging devices. In *SPIE Optical Engineering Press*. (Cité page 42.)
- [Keller et al., 1985] Keller, J., Gray, M., & Givens, J. (1985). A fuzzy k-nearest neighbours algorithm. *IEEE Trans. Syst. Man Cybern*, 15, 580–585. (Cité page 97.)
- [Kim & Han, 2000] Kim, T. K. & Han, J. H. (2000). Partial image matching by measures from connected color regions. In *IEEE International Conference on Multimedia and Expo (ICME'00)*. (Cité page 73.)
- [Ko et al., 2000] Ko, B., Lee, H.-S., & Byun, H. (2000). Region-based image retrieval system using efficient feature description. In *Proc. 15th International Conference on Pattern Recognition*, volume 4 (pp. 283–286). (Cité page 70.)
- [Koeffler, 2004] Koeffler, M. J. (2004). *Actualisation de la prise en charge des escarres : application dans un hôpital gériatrique*. PhD thesis, Université Louis Pasteur de Strasbourg - France. (Cité page 13.)
- [Kolesnik & Fexa, 2004] Kolesnik, M. & Fexa, A. (2004). Segmentation of wounds in the combined color-texture feature space. *SPIE Medical Imaging*, 5370, 549–556. (Cité pages v, 21, 22, 53 et 75.)
- [Kolesnik & Fexa, 2005] Kolesnik, M. & Fexa, A. (2005). Multi-dimensional color histograms for segmentation of wounds in images. *Lecture Notes in Computer Science*, 3656, 1014–1022. (Cité pages 22, 75 et 80.)
- [Kolesnik & Fexa, 2006] Kolesnik, M. & Fexa, A. (2006). How robust is the svm wound segmentation? In *Proc. 7th Nordic Signal Processing Symposium NORSIG 2006* (pp. 50–53). (Cité page 22.)
- [Kompatsiaris et al., 2001] Kompatsiaris, I., E., T., & Strintzis, M. (2001). Region-based color image indexing and retrieval. In *Proc. International Conference on Image Processing*, volume 1 (pp. 658–661 vol.1). (Cité page 71.)
- [Krouskop et al., 2002] Krouskop, T. A., Baker, R., & Wilson, M. S. (2002). A noncontact wound measurement system. *J Rehabil Res Dev*, 39(3), 337–345. (Cité page 24.)
- [Land, 1977] Land, E. H. (1977). The retinex theory of color vision. *Scientific American*, (pp. pp. 108–128,). (Cité pages 42 et 152.)
- [Land, 1986] Land, E. H. (1986). Recent advances in retinex theory. *Vision Res*, 26(1), 7–21. (Cité page 153.)

- [Landis & Koch, 1977] Landis, J. & Koch, G. (1977). The measurement of observer agreement for categorical data. *Biometrics*, 33, 159–174. (Cité page 104.)
- [Laplanche et al., 1987] Laplanche, A., Com-Nougue, C., & Flamant, R. (1987). *Méthodes statistiques appliquées à la recherche clinique*. Technical report, Flammarion Médecine-Sciences ed, Paris. (Cité page 103.)
- [Lin & Li., 2005] Lin, H.-T. & Li, L. (2005). Infinite ensemble learning with support vector machines. *J. Gama et al., eds., Machine Learning : ECML '05, Lecture Notes in Artificial Intelligence*, 3720, 242–254, Springer-Verlag. (Cité page 93.)
- [Lin & Li, 2008] Lin, H.-T. & Li, L. (2008). Support vector machinery for infinite ensemble learning. *Journal of Machine Learning Research*, 9, 285–312. (Cité page 93.)
- [Luo et al., 2001] Luo, M. R., Cui, G., & Rigg, B. (Oct. 2001). The development of the cie 2000 color-difference formula : Ciade2000. *Color Res. Appl.*, 26, 340–350. (Cité page 150.)
- [MacAdam, 1985] MacAdam, D. L. (1985). Color measurement, theme and variation. *Optical Sciences Springer-Verlag*. (Cité page 148.)
- [MacAdam, 1993] MacAdam, D. L. (1993). Chromatic adaptation. in festschrift der albrecht-ludwigs-university at, 1902 [translation : J. von kries "colorimetry-fundamentals"]. *SPIE*, MS 77 of Milestone Series. (Cité pages 41 et 151.)
- [Malian et al., 2002] Malian, A., Heuvel van den, F., & Azizi, A. (2002). A robust photogrammetric system for wound measurement. In *International Archives of Photogrammetry and Remote Sensing*, volume 34 (pp. 264 –269). Corfu, Greece. (Cité page 24.)
- [Malian et al., 2004] Malian, M. A., Azizi, A., & van den, H. F. A. (2004). Medphos : A new photogrammetric system for medical measurement. *International Archives of Photogrammetry and Remote Sensing*, 35, 929–933. (Cité page 24.)
- [Malik et al., 2001] Malik, J., Belongie, S., Leung, T., & Shi, J. (2001). Contour and texture analysis for image segmentation. *International Journal of Computer Vision*, 43(1), 7–27. (Cité page 52.)
- [Manjunath et al., 2001] Manjunath, B., Ohm, J.-R., V., V. V., & Yamada, A. (2001). Color and texture descriptors. 11(6), 703–715. (Cité page 72.)
- [Mekkes & Westerhof, 1995] Mekkes, J. R. & Westerhof, W. (1995). Image processing in the study of wound healing. *Clin Dermatol*, 13(4), 401–407. (Cité pages 18, 53 et 74.)
- [Mercer, 1909] Mercer, J. (1909). Functions of positive and negative type and their connection with the theory of integral equations. *Philosophical Transactions of the Royal Society of London, Series A*, 209, 415–446. (Cité page 92.)
- [Messing et al., 2001] Messing, D., van Beek P., & Errico, J. (2001). The mpeg-7 colour structure descriptor : image description using colour and local spatial information. In *Proc. International Conference on Image Processing*, volume 1 (pp. 670–673). (Cité page 72.)
- [Mihran. & Anil, 1998] Mihran., T. & Anil, K. J. (1998). *Texture Analysis*. The Handbook of Patern Recognition and Computer Vision. (Cité page 76.)

- [Muselet & Macaire, 2007] Muselet, D. & Macaire, L. (2007). Combining color and spatial information for object recognition across illumination changes. *Pattern Recognition Letters*, 28, 1176–1185. (Cité page 75.)
- [Muselet et al., 2004] Muselet, D., Macaire, L., Bonnet, P., & Postaire, J. (2004). Reconnaissance d'objets sous éclairage non contrôlé par l'intersection entre histogrammes couleur spécifiques. *Traitement du Signal*, 21, 679–698. (Cité page 75.)
- [Muzzolini, 1996] Muzzolini, R. E. (1996). *A Volumetric Approach to segmentation and Texture Characterisation of Ultrasound Images*. PhD thesis, Ph.D. Thesis, département de computer sciences, university of Saskatchewan, CANADA. (Cité page 77.)
- [Nayatani et al., 1981] Nayatani, Y., Takahama, K., & Sobagaki, H. (1981). Formulation of a nonlinear model of chromatic adaptation. *Color Res. Appl.*, 6, 161–173. (Cité page 41.)
- [NPUAP, 2007] NPUAP (2007). Redéfinition les stades des escarres et actualités. In *Conférence de consensus NPUAP San Antonio*. (Cité page 12.)
- [Oduncu et al., 2004] Oduncu, H., Hoppe, A., Clark, M., Williams, R. J., & Harding, K. G. (2004). Analysis of skin wound images using digital color image processing : a preliminary communication. *Int J Low Extrem Wounds*, 3(3), 151–156. (Cité pages v, 16, 17 et 21.)
- [Ojala et al., 1996] Ojala, T., Pietikainen, M., & Harwood, D. (1996). A comparative study of texture measures with classification based on feature distributions. In *Pattern Recognition*, volume 29 (pp. 51–59). (Cité page 79.)
- [Ojala et al., 2002] Ojala, T., Pietikainen, M., & Maenpaa, T. (2002). Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. 24(7), 971–987. (Cité page 79.)
- [Pappas, 1992] Pappas, T. (1992). An adaptive clustering algorithm for image segmentation. *IEEE Transactions on Signal Processing*, 40(4), 901–914. (Cité page 52.)
- [Perez et al., 2001] Perez, A., Gonzaga, A., & Alves, J. (2001). Segmentation and analysis of leg ulcers color images. In *Proc. International Workshop on Medical Imaging and Augmented Reality* (pp. 262–266). (Cité pages 16 et 72.)
- [Pietikainen & Harwood, 1986] Pietikainen, M. & Harwood, D. (1986). Segmentation of color images using edge-preserving filters. In *V. Cappellini and R. Marconi, editors, Advances in Image Processing and Pattern Recognition, North-Holland* (pp. 94–99). (Cité page 54.)
- [Plassmann & Jones, 2003] Plassmann, P. & Jones, T. (April 2003). Improved active contour models with application to measurement of leg ulcers. *SPIE Journal of Electronic Imaging*, 12, 317–326. (Cité pages 21, 53 et 132.)
- [Plassmann & Jones, 1998] Plassmann, P. & Jones, T. D. (1998). Mavis : a non-invasive instrument to measure area and volume of wounds. *Medical Engineering and Physics*, 20, 332–338. (Cité pages 18 et 24.)
- [Poursaberi & Araabi, 2006] Poursaberi, A. & Araabi, B. N. (2006). Iris recognition for partially occluded images : Methodology and sensitivity analysis. *EURASIP Journal on Advances in Signal Processing*, 2007, 1687–6172. (Cité page 78.)

- [Priese & Rehrmann, 1993] Priese, L. & Rehrmann, V. (1993). A fast hybrid color segmentation method. *S. J. Poppl and H. Handels, editors, Mustererkennung and Springer Verlag*, (pp. 297-304.). (Cité page 53.)
- [Priese & Rehrmann, 1998] Priese, L. & Rehrmann, V. (1998). Fast and robust segmentation of natural color scenes. In *proceedings of Asian Conf. on Computer Vision* (pp. 598–606). Hong-kong. (Cité pages 53 et 54.)
- [Reed, 2000] Reed, J. F. (2000). Homogeneity of kappa statistics in multiple samples. *Comput Methods Programs Biomed*, 63(1), 43–46. (Cité page 103.)
- [Romanelli et al., 2002] Romanelli, M., Gaggio, G., Coluccia, M., Rizzello, F., & Piaggese, A. (2002). Technological advances in wound bed measurements. *WOUNDS*, 14, 58–66. (Cité page 24.)
- [Sanada et al., 2004] Sanada, H., Moriguchi, T., Miyachi, Y., Ohura, T., Nakajo, T., Tokunaga, K., Fukui, M., Sugama, J., & Kitagawa, A. (2004). Reliability and validity of design, a tool that classifies pressure ulcer severity and monitors healing. *J Wound Care*, 13(1), 13–18. (Cité page 21.)
- [Schmid, 1999] Schmid, P. (1999). Segmentation of digitized dermatoscopic images by two-dimensional color clustering. 18(2), 164–171. (Cité pages v, 22 et 23.)
- [Serrano et al., 2005] Serrano, C., Acha, B., Gómez-Cía, T., Acha, J. I., & Roa, L. M. (2005). A computer assisted diagnosis tool for the classification of burns by depth of injury. *Burns*, 31(3), 275–281. (Cité pages 20 et 72.)
- [Shapiro, 1999] Shapiro, D. E. (1999). The interpretation of diagnostic tests. *Statistical Methods in Medical Research*, 8(2), 113–134. (Cité page 91.)
- [Sharma & Wu, 2004] Sharma, G. & Wu, W. E. N. D. (2004). The ciede2000 color-difference formula : Implementation notes, supplementary test data, and mathematical observations. *Color Res. Appl.* (Cité page 150.)
- [Skarbek & Koschan, 1994] Skarbek, W. & Koschan, A. (1994). *Colour image segmentation - a survey*. Technical report, Institute for Technical Informatics, Technical University of Berlin. (Cité page 52.)
- [Smeulders et al., 2000] Smeulders, A., Worring, M., Santini, S., Gupta, A., & Jain, R. (2000). Content-based image retrieval at the end of the early years. 22(12), 1349–1380. (Cité page 68.)
- [Smith & Chang, 1996] Smith, J. R. & Chang, S. F. (1996). Tools and techniques for color image retrieval. In *IST/SPIE Proceedings* (pp. 426–437). (Cité page 73.)
- [Sève, 1996] Sève, R. (1996). *Physique de la couleur. De l'apparence colorée à la technique colorimétrique*. Masson. (Cité page 144.)
- [Swain & Ballard, 1991] Swain, M. & Ballard, D. (1991). Color indexin. *International Journal of Computer Vision (IJCV)*, 7(1), 11–32. (Cité page 72.)
- [Tan & Triggs, 2007] Tan, X. & Triggs, B. (2007). Enhanced local texture feature sets for face recognition under difficult lighting conditions. In *IEEE Conf. on AMFG* (pp. 168 –182). (Cité page 80.)

- [Trémeau, 1993] Trémeau, A. (octobre 1993). *Contribution des modèles de la perception visuelle à l'analyse d'images couleur*. PhD thesis, Thèse de doctorat, Université Jean Monnet de Saint-étienne. (Cité pages 34 et 146.)
- [Trémeau et al., 2004] Trémeau, A., Fernandez-Maloigne, C., Bonton, P., Colot, O., Gouton, P., Lafon, D., Lambert, P., Macaire, L., Montesinos, P., Philipp-Foliguet, S., Richard, N., & Vannoorenberghe, P. (2004). *Image numérique couleur : de l'acquisition au traitement*. Éditions Dunod, Paris. (Cité page 35.)
- [Vandenbroucke, 2000] Vandenbroucke, N. (2000). *Segmentation d'images couleur par classification de pixels dans des espaces d'attributs colorimétriques adaptés. Application à l'analyse d'images de football*. PhD thesis, Université de Lille 1. (Cité page 69.)
- [Vandenbroucke & Macaire, 2000] Vandenbroucke, N. & Macaire, L. (2000). Représentation de la couleur en analyse d'images. *Techniques de l'Ingénieur*. (Cité page 69.)
- [Vapnik, 1999] Vapnik, V. N. (1999). An overview of statistical learning theory. *IEEE Trans Neural Netw*, 10(5), 988–999. (Cité page 91.)
- [Vertan & Boujemaa, 2000] Vertan, C. & Boujemaa, N. (2000). Embedding fuzzy logic in content based image retrieval. In *Proc. NAFIPS Fuzzy Information Processing Society 19th International Conference of the North American* (pp. 85–89). (Cité page 72.)
- [Wan et al., 1990] Wan, S. J., Prusinkiewicz, P., & Wong, S. K. M. (1990). Variance-based color image quantization for frame buffer display. *Color Research and Application*, 15, 52–58. (Cité page 23.)
- [Wang, 2000] Wang, J. Z. (2000). Pathfinder : multiresolution region-based searching of pathology images using irm. *Proc AMIA Symp*, (pp. 883–887). (Cité page 70.)
- [Ward & Eydelberg-Vileshin, 2002] Ward, G. & Eydelberg-Vileshin, E. (2002). Picture perfect rgb rendering using spectral prefiltering and sharp color primaries. In *13th Eurographics Workshop Rendering Pisa, Italy*. (Cité page 41.)
- [Wu & Lin, 2004] Wu, T.-F. & Lin, C.-J. (2004). Probability estimates for multi-class classification by pairwise coupling. *Journal of Machine Learning Research*, 5, 975–1005. (Cité page 122.)
- [Zhang et al., 2000] Zhang, Z., Stoecker, W., & Moss, R. (2000). Border detection on digitized skin tumor images. 19(11), 1128–1143. (Cité pages v, 19, 21 et 75.)
- [Zhao & Grosky, 2000] Zhao, R. & Grosky, W. (2000). From features to semantics : some preliminary results. In *Proc. IEEE International Conference on Multimedia and Expo ICME 2000*, volume 2 (pp. 679–682). (Cité page 73.)

Bibliographie de l'auteur

Revue nationale

1. Y. Lucas, S. Treuillet, **H. Wannous**, B. Albouy & Dr J.C. Pichaud "Classification colorielle d'escarres par étiquetage de régions 3D" *L'Escarre - Revue officielle PERSE Prévention et Recherche en Soins d'Escarre* Techni Media Services n°36 Escarre et évaluations déc 2007 p.16-18.
2. Y. Lucas, S. Treuillet, B. Albouy, **H. Wannous** & Dr J.C. Pichaud "Evaluation d'escarres avec un simple appareil photo numérique - Un outil développé avec des praticiens hospitaliers" *L'Escarre - Revue officielle PERSE - Prévention et Recherche en Soins d'Escarres* Techni Media Services n°34 Escarre et évaluations juin 2007 p.24-27.
3. Dr J.C. Pichaud, Dr H. Barre, Y. Lucas, S. Treuillet, B. Albouy & **H. Wannous** "ESCALE : ESCarre Analyse Lisibilité Evaluation Imagerie 3D couleur par simple appareil photo numérique Fruit de l'expérience d'une collaboration médico-scientifique" *L'Escarre - Revue officielle PERSE - Prévention et Recherche en Soins d'Escarres* Techni Media Services n°30 Escarre et évaluations juin 2006 p.26-30.

Communications internationales avec comité de lecture

1. **H. Wannous**, Y. Lucas, S. Treuillet & B. Albouy "Fusion of multi view Tissue Classification Based on Wound 3D model" *Int. conf. on Advanced Concepts for Intelligent Vision Systems (ACIVS'08)*, Juan les Pins, France 20-24 October 2008.
2. **H. Wannous**, Y. Lucas & S. Treuillet, "A complete 3D wound assessment tool for accurate tissue classification and measurement" *IEEE Int. Conf. on Image Processing (ICIP'08)*, San Diego, California, USA 12-15 October 2008.
3. **H. Wannous**, Y. Lucas, S. Treuillet & B. Albouy "Classification mapping on 3D model : a solution for measuring real area covered by skin wound tissues" *IEEE Int. Conf. on information technologies : from theory to applications (ICTTA'08)*, Damascus, Syria 7-11 April 2008.
4. **H. Wannous**, Y. Lucas, & S. Treuillet, "Efficient SVMs classifier based on color and texture region features for wound tissue images" *SPIE Medical Imaging :*

Computer-Aided Diagnosis, SPIE Digital Library Proc. 6915, 69152T San Diego, USA, 17-21 February 2008.

5. **H. Wannous**, Y. Lucas & S. Treuillet, "Supervised Tissue Classification from Color Images for a Complete Wound Assessment Tool", *Int. conf. of IEEE engineering in medicine and biology society (EMBS'07)* Lyon, France, 23-26 August 2007.
6. Y. Lucas, S. Treuillet, B. Albouy, **H. Wannous** & Dr J.C.Pichaud "3D and color wound assessment using a simple digital camera" *9th EPUAP Open Meeting* Berlin Germany 30 August-2 September 2006.

Lecture Notes in Computer Science (LNCS)

1. **H. Wannous**, Y. Lucas, S. Treuillet & B. Albouy, "Fusion of multi-view tissue classification based on 3D model", *Lecture Notes in Computer Science*, Vol.5229, Springer Verlag, 2008, p.924-934.

Communications nationales avec comité de lecture

1. **H. Wannous**, Y. Lucas & S. Treuillet & B. Albouy, "ESCALE : outil complet de mesures 2D/3D pour le suivi thérapeutique d'escarres" *6ème Colloque Capteurs 2008*, Bourges, France 5 - 6 Mars 2008.
2. **H. Wannous**, Y. Lucas & S. Treuillet "Classification supervisée de régions couleur - Application au suivi thérapeutique des escarres" *21ème Conf. sur le traitement du signal et des images (GRETSI'07)*, Troyes France 11-15 September 2007.
3. **H. Wannous**, Y. Lucas & S. Treuillet" Classification tissulaire robuste appliquée au suivi thérapeutique d'escarres" *Onzième Congrès Francophone des Jeunes Chercheurs en Vision par Ordinateur (ORASIS'07)*, Obernai France 4-8 Juin 2007.

Communications nationales sans actes

1. **H. Wannous**, Y. Lucas & S. Treuillet, "Classification tissulaire dérivée par segmentation d'images couleur dédiée à un outil de suivi thérapeutique d'escarres" *Colloque Sciences en Sologne 2007*, Orléans, France 23 - 24 Mai 2007.
2. Y. Lucas, S. Treuillet, B. Albouy, H. Wannous, & Dr J.C. Pichaud "ESCALE : suivi thérapeutique d'escarres quantitatif avec un simple appareil photo" *Journée PERSE Prévention Recherche en Soins d'Escarre - Paris Tour Eiffel - 29 Mars 2007.*
3. **H. Wannous**, Y. Lucas & S. Treuillet, "Segmentation couleur multi-vues appliquée au suivi thérapeutique d'escarres" *Colloque Sciences en Sologne* Orléans, France 31 mai - 1er Juin 2006.

Séminaires - Réunions GDR

1. **H. Wannous**, Y. Lucas & S. Treuillet, "Classification tissulaire robuste appliquée au suivi thérapeutique d'escarres" *École d'hiver sur l'imagerie numérique couleur*, Campus du Futuroscope, Université de Poitiers 9-11 Janvier 2007.
2. Y. Lucas, **H. Wannous**, A. Domingues & S. Treuillet "Evaluation et réglage d'une chaîne de traitement d'images routières" *Journée bilan du groupe SCATI : chaîne et pilotage de traitements GdR ISIS - ENST Paris* 28 Septembre 2006.

Hazem WANNOUS

**CLASSIFICATION MULTI VUES DE RÉGIONS
COULEUR - APPLICATION A L'ÉVALUATION 3D DES
PLAIES CHRONIQUES**

Alors que l'exploration fonctionnelle repose sur des techniques d'imagerie médicale sophistiquées, le relevé anatomique de surface fait encore appel à des pratiques cliniques manuelles imprécises et coûteuses. A partir d'images couleur prises à main levée avec un appareil photo numérique, un outil innovant d'évaluation des plaies chroniques a été développé. Il combine les deux modes d'examen pratiqués, l'analyse colorimétrique et la mesure dimensionnelle des tissus lésés, dans un système convivial, pour une diffusion massive dans les équipes de soin. S'appuyant sur une vérité terrain établie par des cliniciens, une base d'échantillons cutanés a été constituée. Ils sont issus d'une segmentation non supervisée d'image couleur après correction colorimétrique assurant l'indépendance aux conditions d'éclairage, aux changements de point de vue et d'appareil. Ils sont ensuite caractérisés par des descripteurs de couleur et de texture, sélectionnés et re-conditionnés par des techniques d'analyse de données, pour faire l'apprentissage des quatre catégories de tissus par un séparateur à vaste marge à noyau perceptron. Les résultats de classification mono vue sont alors fusionnés grâce au modèle 3D de la plaie qui établit les correspondances spatiales d'une paire d'images stéréoscopiques. Il en résulte une nette amélioration de la robustesse de la classification, également stable sur plusieurs reconstructions. Les surfaces tissulaires exactes sont obtenues par simple rétro projection des régions tissulaires sur le modèle 3D. Ce modèle géométrique est également renforcé puisque le détourage automatique de la plaie utilise la détection de peau saine pour éliminer des triangles du maillage.

Mots clés : Classification, segmentation, modélisation 3D, correction couleur, plaies chroniques

**MULTI VIEW CLASSIFICATION OF COLOR REGIONS
APPLICATION TO THE 3D ASSESSMENT OF
CHRONIC WOUNDS**

Despite the advance of functional exploration based on sophisticated medical imaging techniques, the digitization of anatomical surfaces still rely on manual imprecise and expensive clinical practice. From color images acquired with a hand held digital camera, an innovative tool for assessing chronic wounds has been developed. It combines both types of assessment, namely color analysis and dimensional measurement of injured tissue, in a user-friendly system, to provide the largest spreading in care staffs. Based on a ground truth established by clinicians, a sample database of wound tissue images has been constructed. These samples come from unsupervised color image segmentation after color correction to ensure stability under lighting conditions, viewpoint and camera type changes. They are characterized by color and texture descriptors, selected and re-sampled with data analysis techniques, before the learning stage of four categories of tissues of a Support Vector Machine classifier with perceptron kernel. The results of single view classification are merged and directly mapped on the mesh surface of the 3D wound model captured using uncalibrated vision techniques applied on a stereoscopic image pair. The result is a significative improvement in the robustness of the classification, equally stable over several reconstructions. The exact tissue areas are simply obtained by retro projection of the tissue regions on the 3D model. This geometric model is also strengthened since the automatic delineation of the wound uses skin detection to remove extra triangles from the mesh.

Key words: Classification, segmentation, 3D modeling, color correction, chronic wounds



**Institut PRISME - Equipe ISS,
12, rue de Blois, B.P. 6744 45067 ORLEANS CEDEX 2**

