

THÈSE

pour obtenir le grade de

DOCTEUR DE L'UNIVERSITÉ DE LILLE 1

Discipline : Automatique et Informatique Industrielle

Présentée et soutenue publiquement

par

Alice POREBSKI

le 20 novembre 2009

***Sélection d'attributs de texture couleur pour la
classification d'images. Application à l'identification de
défauts sur les décors verriers imprimés par
sérigraphie.***

JURY :

Christophe Chaillou	Professeur à l'Université Lille 1, Président de Jury
Christine Fernandez-Maloigne	Professeur à l'Université de Poitiers, Rapporteur
Olivier Lézoray	Professeur à l'Université de Caen, Rapporteur
Pierre Courtellemont	Professeur à l'Université de La Rochelle, Examineur
Damien Muselet	Maître de Conférences à l'Université de Saint-Étienne, Examineur
Ludovic Macaire	Professeur à l'Université Lille 1, Directeur de Thèse
Nicolas Vandenbroucke	Enseignant-chercheur à l'EIPC, Encadrant de Thèse

*"Ce sont les épreuves qui nous révèlent.
Elles nous mettent au défi de nous dépasser
et de nous voir dans notre propre réalité."*

*À Mes Parents,
À Benoît.*

On ne peut rien apprendre aux gens. On peut seulement les aider à découvrir qu'ils possèdent déjà en eux tout ce qui est à apprendre.
Galilée.

Avant-propos

En parallèle de ma troisième année de cycle ingénieur au sein de l'EIPC (École d'Ingénieurs du Pas-de-Calais), j'ai eu l'opportunité de suivre un Master Recherche en Automatique, Génie Informatique et Image (AG2I). A l'issue de cet enseignement, j'ai effectué au sein l'équipe Vision et Image (VI) du laboratoire LAGIS (Laboratoire d'Automatique, Génie Informatique et Signal), un stage de recherche encadré par **Nicolas Vandebroucke**, enseignant-chercheur à l'EIPC, et **Ludovic Macaire**, professeur à l'Université Lille 1 - Sciences et Technologies. C'est dans la poursuite du thème abordé lors de ce stage, à savoir la sélection d'attributs de texture couleur pour la classification d'images, que s'inscrit le sujet de ma thèse de doctorat.

Pour avoir su parfaitement susciter la curiosité des élèves-ingénieurs lors de leur programme de "promotion" de la recherche à l'EIPC, je tiens à remercier en premier lieu Messieurs **Jack-Gérard Postaire**, **Ludovic Macaire** et **Nicolas Vandebroucke**.

Monsieur Postaire, alors responsable de l'équipe VI, a su par son dynamisme et sa jovialité nous transmettre instantanément sa passion de la recherche. La complicité qu'il a partagée avec Ludovic et Nicolas lors de cette intervention a fait ressortir la bonne humeur et la cohésion qui règnent au sein de l'équipe VI. Les anecdotes retraçant leurs déplacements en conférences n'ont fait qu'attiser notre désir de découvrir ce métier. C'est ainsi que le premier pas dans le monde de la recherche fût franchi...

Ensuite, après avoir encadré mon stage de recherche, Ludovic et Nicolas ont endossé le rôle de co-encadrants de thèse et cela a été pour moi une chance. **Ludovic Macaire** est un encadrant qui se soucie particulièrement de l'avenir professionnel de ses doctorants et je tiens à le remercier pour ses conseils, sa bonne humeur, ainsi que pour son soutien tout au long de ces trois années de thèse. Merci également pour avoir su me laisser la liberté nécessaire à l'accomplissement de mes travaux, tout en y gardant un oeil critique et avisé.

Je tiens d'autre part à exprimer ma plus grande reconnaissance envers **Nicolas Vandebroucke**, qui a été le premier à croire en mes "capacités de recherche". Merci pour m'avoir encouragée et soutenue chaque fois que le besoin s'en faisait sentir et pour avoir toujours montré de l'intérêt pour mes travaux. Les débats que nous avons partagés avec Ludovic ont sûrement été la clé de notre travail commun.

Je remercie également les dirigeants de l'EIPC et la région Nord-Pas-de-Calais qui, dans le cadre des actions du pôle de compétitivité MAUD (Matériaux à Usage Domestique), ont financé ces trois années de recherche.

De façon générale, je remercie l'ensemble du personnel de l'EIPC pour les bons moments passés avec eux, et particulièrement :

- mon "chef", **Patrick Debay**, pour la confiance qu'il me porte et pour son investissement important dans l'école.
- **André Styza**, pour les conseils qu'il m'a promulgués.
- **Sabine Rensy, Shahram Bahrami** et **Yann Ducrocq**, pour la complicité que nous partageons.
- **Laurent Busin**, pour son aide et sa bonne humeur.
- **Monsieur Huglo**, directeur de l'EIPC, pour me permettre de continuer l'aventure au sein de l'école.

Mes plus vifs remerciements vont également à l'ensemble de l'équipe VI pour leur sympathie, et en particulier, à **Mariam**, avec qui j'ai pu partager les moments de doute que peut avoir tout doctorant.

Je tiens bien entendu à remercier l'ensemble des membres du jury :

- **Christine Fernandez-Maloigne**, Professeur à l'Université de Poitiers, et **Olivier Lézoray**, Professeur à l'Université de Caen, pour avoir accepté d'être rapporteurs de cette thèse,
- **Pierre Courtellemont**, Professeur à l'Université de La Rochelle, et **Damien Muselet**, Maître de Conférences à l'Université de Saint-Étienne, pour en avoir été les examinateurs,
- **Christophe Chaillou**, Professeur à l'Université Lille 1, pour avoir assumé le rôle de président du jury.

Un grand merci tout particulièrement à **Christine Fernandez-Maloigne** pour sa gentillesse et pour l'échange d'idées constructif qui a permis d'améliorer mon manuscrit.

Enfin, je remercie chaleureusement **Benoît, Agathe** et **ma famille** qui m'ont beaucoup soutenue et qui m'ont aidée à relever le challenge que représente la thèse. Et merci aussi à **Matthieu**, pour m'avoir épaulée dans l'élaboration des nombreux tableaux de l'annexe E.

Je suis heureuse de pouvoir à mon tour promouvoir la recherche auprès des élèves-ingénieurs avec Ludovic et Nicolas...

Table des matières

Avant-propos	5
Abréviations et notations	13
Introduction	19
I.1 Approche proposée	20
I.2 Classification supervisée de textures couleur	21
I.2.1 Apprentissage	22
I.2.1.1 Acquisition d'images prototypes	22
I.2.1.2 Génération d'attributs	22
I.2.1.3 Réduction de l'espace d'attributs et construction des classes	23
I.2.2 Classification	23
I.3 Plan du mémoire	24
Chapitre 1. Attributs de texture couleur	27
1.1 Introduction	27
1.2 Notion de texture	28
1.3 Exploitation de la couleur pour l'analyse de texture	30
1.3.1 Représentation de la couleur	31
1.3.2 Contribution de la couleur à l'analyse de texture	32
1.4 Présentation des bases d'images de texture couleur de référence	35
1.4.1 Description de la base VisTex	35
1.4.2 Description de la base BarkTex	35
1.4.3 Description de la base OuTex	38
1.5 Caractérisation des textures couleur	40
1.6 Attributs géométriques	41
1.7 Attributs basés sur la modélisation spatiale des textures	42
1.7.1 Modèles autorégressifs multispectraux	42
1.7.2 Modèles de Markov multispectraux	42
1.7.3 Motifs locaux binaires couleur	44
1.8 Attributs spatio-fréquentiels	47
1.8.1 Transformation de Gabor	48
1.8.2 Transformée en ondelettes	49

1.9	Attributs statistiques	50
1.9.1	Attributs statistiques du premier ordre	50
1.9.1.1	Statistiques d'image	50
1.9.1.2	Histogrammes d'image	51
1.9.2	Attributs statistiques du second ordre	52
1.9.2.1	Matrices de co-occurrences chromatiques	52
1.9.2.2	Attributs d'Haralick extraits des matrices de co-occurrences	55
1.9.2.3	Paramètres liés à la définition des attributs d'Haralick	59
1.9.2.4	Histogrammes des sommes et des différences	62
1.9.2.5	Attributs extraits des histogrammes des sommes et des différences	65
1.9.3	Attributs statistiques d'ordre supérieur	67
1.9.3.1	Matrices de longueurs de plages	67
1.9.3.2	Attributs de texture extraits des matrices de longueurs de plages	69
1.10	Conclusion	70
Chapitre 2. Réduction de l'ensemble d'attributs		73
2.1	Introduction	73
2.1.1	Classification supervisée de textures couleur	73
2.1.2	Réduction de la dimension du vecteur d'attributs	74
2.2	Extraction des attributs	77
2.2.1	Analyse factorielle discriminante et analyse en composantes principales	77
2.2.2	Analyse en composantes indépendantes	78
2.2.3	Limites	78
2.3	Sélection des attributs	79
2.3.1	Algorithmes de classement	79
2.3.2	Recherche de sous-espaces	80
2.3.2.1	Génération complète	82
2.3.2.2	Génération aléatoire	85
2.3.2.3	Génération séquentielle	88
2.3.2.4	Synthèse	91
2.3.3	Fonction d'évaluation	93
2.3.3.1	Mesure du taux d'erreur de classification	94
2.3.3.2	Mesure de consistance	95
2.3.3.3	Mesure d'information	96
2.3.3.4	Mesure de dépendance entre attributs	97
2.3.3.5	Mesure de distance	98
2.3.3.6	Combinaison de l'approche "wrapper" et de l'approche "filter"	101
2.3.4	Critères d'arrêt	102
2.4	Validation	103
2.4.1	Réseaux de neurones	104

2.4.2	Machines à vecteurs supports	106
2.4.3	k plus proches voisins	110
2.4.4	Plus proche barycentre	112
2.4.5	Combinaison de plusieurs classifieurs	113
2.5	Conclusion	114
Chapitre 3. Sélection d'attributs de texture couleur pour la classification d'images		117
3.1	Introduction	117
3.2	Approche multi-espaces couleur	119
3.2.1	Choix de l'espace couleur	119
3.2.2	Les 28 espaces couleur considérés	123
3.2.3	Codage et quantification de la couleur	125
3.2.3.1	Codage de la couleur	125
3.2.3.2	Quantification des composantes couleur	126
3.2.4	Conclusion	127
3.3	Attributs de texture couleur retenus	127
3.3.1	Critères de choix des attributs de texture couleur	128
3.3.2	Attributs de texture utilisés pour des applications industrielles	128
3.3.2.1	Attributs de texture extraits de l'image de luminance et attributs statistiques caractérisant la distribution des couleurs	129
3.3.2.2	Attributs de texture couleur intra-composantes	130
3.3.2.3	Attributs de texture couleur intra et inter-composantes	131
3.3.2.4	Synthèse	131
3.3.3	Matrices de co-occurrences chromatiques isotropiques de taille réduite	133
3.3.3.1	Intérêt des matrices de co-occurrences chromatiques de taille réduite	133
3.3.3.2	Intérêt des matrices de co-occurrences chromatiques isotropiques	135
3.4	Procédure de sélection proposée	137
3.4.1	Construction des sous-espaces candidats	138
	Choix de la procédure de génération	138
	Choix de la fonction d'évaluation	139
3.4.2	Sélection du sous-espace d'attributs le plus discriminant	140
	Choix de la méthode de classification	141
	Choix de l'ensemble d'images test	141
3.5	Méthode de classification supervisée développée	144
3.5.1	Apprentissage	144
3.5.2	Classification	145
3.6	Conclusion	145

Chapitre 4. Résultats expérimentaux	147
4.1 Introduction	147
4.2 Ensembles d'images utilisés pour classer les textures couleur	148
4.2.1 Choix des ensembles d'images	148
4.2.2 Ensemble d'images OuTex	152
4.2.3 Ensemble d'images VisTex	153
4.2.4 Ensemble d'images BarkTex	155
4.3 Résultats expérimentaux obtenus avec la base de référence OuTex	156
4.3.1 Temps de calcul des attributs d'Haralick	156
4.3.2 Résultats et temps de traitement obtenus lors de la sélection	157
4.3.2.1 Construction des $d_{max} = 50$ sous-espaces candidats	157
4.3.2.2 Sélection du sous-espace d'attributs le plus discriminant	158
4.4 Tests sur les autres bases	160
4.5 Comparaison des résultats de classification avec les travaux antérieurs	162
4.6 Influence des paramètres de la méthode développée	168
4.6.1 Influence des paramètres de caractérisation des textures couleur	169
4.6.1.1 Influence du niveau N de quantification	169
4.6.1.2 Influence de la structure du voisinage	173
Influence de la structure du voisinage sur les résultats de classification	173
Influence de la structure du voisinage sur le temps calcul des attributs	175
4.6.1.3 Influence de la distance spatiale ν	176
4.6.2 Influence des paramètres de la sélection d'attributs	179
4.6.2.1 Influence de la procédure de génération	179
4.6.2.2 Influence du critère du pouvoir discriminant	180
4.6.3 Conclusion	182
4.7 Apports de la méthode de classification de textures couleur	183
4.7.1 Apport de l'approche multi-espaces couleur	183
4.7.2 Apport de la considération conjointe des relations intra et inter-composantes	187
4.7.3 Apport de la sélection	190
4.8 Conclusion	191
Chapitre 5. Application à l'identification de défauts sur les décors de verres	193
5.1 Introduction	193
5.2 Les défauts à détecter	193
5.3 Contrôle qualité des décors de verres présentant des couleurs homogènes	196
5.3.1 Présentation du poste d'acquisition	196
5.3.2 Contrôle qualité des décors de verres par segmentation d'images couleur	199
5.4 Contrôle qualité des décors de verres présentant des textures couleur	201

5.4.1	Construction des bases d'images de décors de verres par simulation de défauts	202
5.4.2	Résultats du contrôle qualité des décors "Fanta" et "Sprite"	204
5.4.2.1	Résultats obtenus pour le contrôle des décors "Fanta"	206
	Apprentissage hors-ligne des décors "Fanta"	206
	Classification en-ligne des décors réels "Fanta"	207
5.4.2.2	Résultats obtenus pour le contrôle des décors "Sprite"	207
	Apprentissage hors-ligne des décors "Sprite"	207
	Classification en-ligne des décors réels "Sprite"	208
5.4.3	Bénéfices d'une telle approche pour l'entreprise	210
5.5	Conclusion	210
Conclusion générale et perspectives		213
Annexe A. Les principaux systèmes de représentation de la couleur		219
A.1	Espaces de primaires	219
A.1.1	L'espace (R_C, G_C, B_C) de la CIE	219
A.1.2	L'espace (r_C, g_C, b_C)	220
A.1.3	L'espace (X, Y, Z) de la CIE	221
A.2	Espaces luminance-chrominance	222
A.2.1	Les espaces perceptuellement uniformes	222
A.2.2	Les espaces antagonistes	223
A.2.3	Les espaces de télévision	223
A.3	Espaces perceptuels	224
A.3.1	Les espaces de coordonnées polaires	224
A.3.2	Les espaces de coordonnées perceptuelles	224
A.4	Espaces d'axes indépendants	225
A.4.1	L'analyse en composantes principales	225
A.4.2	L'espace d'Ohta	226
Annexe B. Évaluation des sous-espaces d'attributs		227
B.1	Mesures de séparation des classes utilisées dans la définition des mesures de consistance	227
B.2	Mesures d'entropie utilisées dans la définition des mesures d'information	227
Annexe C. Synthèse des travaux portant sur la classification d'images de texture couleur		229
Annexe D. Codage des espaces couleur		253
D.1	Principe et notations	253
D.2	Codage séparé	253
D.3	Codage non séparé	254

Annexe E. Autres résultats expérimentaux	255
E.1 Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur	255
E.1.1 Résultats obtenus avec la méthodologie développée	255
E.1.2 Résultats obtenus avec le niveau de quantification $N = 256$	255
E.1.3 Résultats obtenus lorsque la moyenne et la variance des attributs d'Haralick sont considérées	255
E.1.4 Résultats obtenus lorsque les distances spatiales $\nu = 5$ et $\nu = 1, 2, 3, 4$ et 5 sont considérées	256
E.1.5 Résultats obtenus lorsque la procédure SFFS est considérée	256
E.1.6 Résultats obtenus lorsque le critère de la trace est considéré	256
E.2 Temps requis pour classer les images test	266
E.3 Résultats de classification obtenus	267
E.3.1 Résultats de classification obtenus en considérant des attributs statistiques	267
E.3.2 Résultats de classification obtenus en fonction de la structure du voisinage	268
E.3.3 Résultats de classification obtenus en fonction des distances spatiales .	269
E.3.4 Résultats de classification obtenus en fonction de la procédure de génération	272
E.3.5 Résultats de classification obtenus en fonction de la mesure de distance	273
 Bibliographie	 275
 Table des figures	 289
 Table des tableaux	 295
 Communications écrites par la candidate	 299

Abréviations et notations

Abréviations

CIE	Commission Internationale de l'Éclairage
NTSC	National Television System Committee
PAL	Phase Alternate Line
SECAM	SÉquentiel Couleur À Mémoire
LOG	Laplacian Of Gaussian
MSAR	Multispectral Simultaneous AutoRegressive
LBP	Local Binary Pattern
WSF	Wavelet Statistical Features
WCF	Wavelet Co-occurrence Features
BB	Branch and Bound
SFS	Sequential Forward Selection
SBS	Sequential Backward Selection
SFFS	Sequential Forward Floating Selection
SBFS	Sequential Backward Floating Selection
GSFS	Generalized Sequential Forward Selection
GSBS	Generalized Sequential Backward Selection
PTA	Plus m -Take Away n
GPTA	Generalized Plus m -Take Away n
AG	Algorithmes Génétiques
ACP	Analyse en Composantes Principales
AFD	Analyse Factorielle Discriminante
ACI	Analyse en Composantes Indépendantes
MLP	Multi-Layer Perceptron
RBF	Radial Basic Functions
ART	Adaptative Resonance Theory
k -PPV	k plus proches voisins
SVM	Support Vector Machines

Notations relatives à la mesure de la couleur (colorimétrie)

$[C]$	Stimulus de couleur correspondant à une couleur C
R_C	Composante trichromatique d'un stimulus de couleur correspondant à la primaire $[R_C]$
G_C	Composante trichromatique d'un stimulus de couleur correspondant à la primaire $[G_C]$
B_C	Composante trichromatique d'un stimulus de couleur correspondant à la primaire $[B_C]$
r_C	Coordonnée trichromatique d'un stimulus de couleur correspondant à la primaire $[r_C]$
g_C	Coordonnée trichromatique d'un stimulus de couleur correspondant à la primaire $[g_C]$
b_C	Coordonnée trichromatique d'un stimulus de couleur correspondant à la primaire $[b_C]$

Notations relatives aux espaces couleur

N_E	Nombre d'espaces couleur considérés
(R, G, B)	Espace de primaires d'une caméra couleur
(R_C, G_C, B_C)	Espace de primaires définies par la CIE
(r, g, b)	Espace de primaires normalisées rouge, vert et bleu
(X, Y, Z)	Espace de référence colorimétrique de la CIE
(x, y, z)	Espace de référence colorimétrique normalisé de la CIE
(L, Chr_1, Chr_2)	Espace luminance-chrominance quelconque
(L^*, a^*, b^*)	Espace perceptuellement uniforme CIELAB
(L^*, u^*, v^*)	Espace perceptuellement uniforme CIELUV
(Y', I', Q')	Espace de télévision répondant à la norme NTSC
(Y', U', V')	Espace de télévision répondant à la norme PAL
(Y, Ch_1, Ch_2)	Espace luminance-chrominance défini par Carron
(Y, x, y)	Espace luminance-chrominance défini à partir de l'espace (x, y, z)
$(I1, r, g)$	Espace luminance-chrominance défini à partir de l'espace (r_C, g_C, b_C)
(A, C_1, C_2)	Espace antagoniste défini par Faugeras
(bw, rg, by)	Espace antagoniste défini par Ballard
(L, C, H)	Espace de coordonnées polaires quelconques (Luminance - Chroma - Teinte (H pour hue en anglais))
(A, C_{C1C2}, h_{C1C2})	Espace de coordonnées polaires défini à partir de l'espace (A, C_1, C_2)
$(bw, C'_{rgby}, h'_{rgby})$	Espace de coordonnées polaires défini à partir de l'espace (bw, rg, by)
(Y', C'_{IQ}, h'_{IQ})	Espace de coordonnées polaires défini à partir de l'espace (Y', I', Q')
(Y', C'_{UV}, h'_{UV})	Espace de coordonnées polaires défini à partir de l'espace (Y', U', V')
(L^*, C^*_{ab}, h_{ab})	Espace de coordonnées polaires défini à partir de l'espace (L^*, a^*, b^*)
(L^*, C^*_{uv}, h_{uv})	Espace de coordonnées polaires défini à partir de l'espace (L^*, u^*, v^*)
$(L, C_{Ch1Ch2}, h_{Ch1Ch2})$	Espace de coordonnées polaires défini à partir de l'espace (Y, Ch_1, Ch_2)
$(I1, C_{I2I3}, h_{I2I3})$	Espace de coordonnées polaires défini à partir de l'espace $(I1, I2, I3)$
(I, S, T)	Espace de perception humaine de la couleur (Intensité - Saturation - Teinte)
(L^*, S^*_{uv}, h_{uv})	Espace de coordonnées perceptuelles défini à partir de l'espace couleur (L^*, u^*, v^*)
$(I1, S1, H3)$	Espace de coordonnées perceptuelles défini par Liang
$(I5, S4, H2)$	Espace de coordonnées perceptuelles défini à partir du modèle de cône hexagonal double
$(I4, S3, H2)$	Espace de coordonnées perceptuelles défini à partir du modèle de cône hexagonal
$(I1, S2, H1)$	Espace de coordonnées perceptuelles défini à partir du modèle de triangle
$(I1, S1, H1)$	Espace de coordonnées perceptuelles défini à partir du modèle de triangle avec minimum
$(I1, I2, I3)$	Espace d'axes indépendants d'Ohta
(C_1, C_2, C_3)	Espace de représentation de la couleur quelconque
$C(P)$	Couleur du pixel P
$C_k(P)$	Valeur de la composante couleur C_k du pixel P
N	Niveau de quantification

Notations relatives aux données de l'image

\mathbf{I}	Image couleur numérique
N_p	Nombre de pixels dans l'image
\mathbf{I}^{C_k}	Image-composante de l'image couleur \mathbf{I} où les pixels sont caractérisés par la composante couleur C_k
\mathbf{I}^L	Image de luminance correspondant à l'image couleur \mathbf{I}

Notations relatives à la classification

N_C	Nombre de classes
C^j	Classe d'indice j ($j = 1, \dots, N_C$)
ξ	Ensemble des images
N_ξ	Nombre d'images appartenant à l'ensemble ξ
Ω	Ensemble des prototypes
N_ω^j	Nombre de prototypes caractérisant la classe C^j
$\omega^{i,j}$	$i^{\text{ème}}$ prototype de la classe C^j ($i = 1, \dots, N_\omega^j$ et $j = 1, \dots, N_C$)
τ	Ensemble d'images test

Notations relatives aux attributs de texture

N_A	Nombre d'attributs considérés
$LBP[P]^{C_k, C_{k'}}$	Attribut LBP couleur caractérisant les interactions spatiales entre les composantes couleur C_k et $C_{k'}$ des pixels situés dans le voisinage du pixel P
$LBP[\mathbf{I}]$	Histogramme LBP couleur caractérisant les interactions spatiales intra et inter-composantes des pixels de l'image \mathbf{I}
C	Mesure de contraste associée aux LBP
θ	Direction considérée lors du calcul de certains attributs de texture
ν	Distance entre le pixel à analyser et ses voisins
V	Nombre de pixels appartenant au voisinage du pixel à analyser
$M^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$	Matrice de co-occurrences chromatique qui mesure l'interaction spatiale entre les composantes couleur C_k et $C_{k'}$ des pixels de l'image \mathbf{I} pris deux à deux et distants de ν selon la direction θ
$m^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$	Matrice de co-occurrences chromatique normalisée qui mesure l'interaction spatiale entre les composantes couleur C_k et $C_{k'}$ des pixels de l'image \mathbf{I} pris deux à deux et distants de ν selon la direction θ
$f_i^{C_k, C_{k'}}(\nu, \theta)$	$i^{\text{ème}}$ attribut extrait de la matrice de co-occurrences chromatique normalisée $m^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$
$H_S^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$	Histogramme des sommes qui mesure l'interaction spatiale entre les composantes couleur C_k et $C_{k'}$ des pixels de l'image \mathbf{I} pris deux à deux et distants de ν selon la direction θ
$H_D^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$	Histogramme des différences qui mesure l'interaction spatiale entre les composantes couleur C_k et $C_{k'}$ des pixels de l'image \mathbf{I} pris deux à deux et distants de ν selon la direction θ
$h_S^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$	Histogramme des sommes normalisé qui mesure l'interaction spatiale entre les composantes couleur C_k et $C_{k'}$ des pixels de l'image \mathbf{I} pris deux à deux et distants de ν selon la direction θ
$h_D^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$	Histogramme des différences normalisé qui mesure l'interaction spatiale entre les composantes couleur C_k et $C_{k'}$ des pixels de l'image \mathbf{I} pris deux à deux et distants de ν selon la direction θ
$g_i^{C_k, C_{k'}}(\nu, \theta)$	$i^{\text{ème}}$ attribut extrait des histogrammes des sommes et des différences normalisés
$\mathcal{P}^{C_k}[\mathbf{I}](\theta)$	Matrice de longueurs de plages qui mesure l'interaction spatiale pour la composante couleur C_k des pixels de l'image \mathbf{I} analysés selon l'orientation θ
$h_i^{C_k}(\theta)$	$i^{\text{ème}}$ attribut extrait de la matrice de longueurs de plages $\mathcal{P}^{C_k}[\mathbf{I}](\theta)$

Notations relatives à la description des images

D	Dimension initiale de l'espace des attributs
d	Dimension réduite de l'espace des attributs
E	Espace initial d'attributs
X_l	Dénomination de l'attribut d'indice l appartenant à E ($l = 1, \dots, D$)
$\mathbf{X}_l = [\mathbf{X}_l^{1,1}, \dots, \mathbf{X}_l^{N_\omega^1,1}, \mathbf{X}_l^{1,2}, \dots, \mathbf{X}_l^{N_\omega^{N_C}, N_C}]$	Vecteur des prototypes de l'attribut d'indice l appartenant à E ($l = 1, \dots, D$)
$\mathbf{X}^{i,j} = [\mathbf{X}_1^{i,j}, \dots, \mathbf{X}_l^{i,j}, \dots, \mathbf{X}_D^{i,j}]^T$	Vecteur d'attributs dans E d'un des N_ω^j prototypes $\omega^{i,j}$ ($i = 1, \dots, N_\omega^j$) appartenant à la classe C^j ($j = 1, \dots, N_C$)
$\mathbf{X}_l^{i,j}$	Valeur du $l^{\text{ème}}$ attribut du prototype $\omega^{i,j}$
E_d	Sous-espace de d attributs évalué
Y_k	Dénomination de l'attribut d'indice k appartenant à E_d ($k = 1, \dots, d$)
$\mathbf{Y}_k = [\mathbf{Y}_k^{1,1}, \dots, \mathbf{Y}_k^{N_\omega^1,1}, \mathbf{Y}_k^{1,2}, \dots, \mathbf{Y}_k^{N_\omega^{N_C}, N_C}]$	Vecteur des prototypes de l'attribut d'indice k appartenant à E_d ($k = 1, \dots, d$)
$\mathbf{Y}^{i,j} = [\mathbf{Y}_1^{i,j}, \dots, \mathbf{Y}_k^{i,j}, \dots, \mathbf{Y}_d^{i,j}]^T$	Vecteur d'attributs dans E_d d'un des N_ω^j prototypes $\omega^{i,j}$ ($i = 1, \dots, N_\omega^j$) appartenant à la classe C^j ($j = 1, \dots, N_C$)
$\mathbf{Y}_k^{i,j}$	Valeur du $k^{\text{ème}}$ attribut du prototype $\omega^{i,j}$
d_{max}	Nombre de sous-espaces d'attributs pré-sélectionnés
\hat{d}	Dimension du sous-espace d'attributs discriminant sélectionné
$E_{\hat{d}}$	Sous-espace des \hat{d} attributs sélectionnés
\hat{Y}_k	Nom de l'attribut sélectionné d'indice k appartenant à $E_{\hat{d}}$ ($k = 1, \dots, \hat{d}$)
$\hat{\mathbf{Y}}^{i,j} = [\hat{\mathbf{Y}}_1^{i,j}, \dots, \hat{\mathbf{Y}}_k^{i,j}, \dots, \hat{\mathbf{Y}}_{\hat{d}}^{i,j}]^T$	Vecteur d'attributs sélectionnés de $E_{\hat{d}}$ d'un des N_ω^j prototypes $\omega^{i,j}$ ($i = 1, \dots, N_\omega^j$) appartenant à la classe C^j ($j = 1, \dots, N_C$)

Notations relatives à la sélection

J	Fonction d'évaluation
r	Rang d'itération de la procédure de sélection
N_{PI}	Nombre de chromosomes constituant la population initiale lors d'une procédure de génération aléatoire
X_+	Dénomination de l'attribut ajouté au sous-espace d'attributs lors de la procédure de sélection de type "Forward"
X_-	Dénomination de l'attribut retiré au sous-espace d'attributs lors de la procédure de sélection de type "Backward"
$P(C^j)$	Probabilité <i>a priori</i> de la classe C^j
$D^{jj'}(E_d)$	Mesure de séparation entre les classes C^j et $C^{j'}$, considérant le sous-espace d'attributs E_d
$P(\mathbf{Y}^{i,j} C^j)$	Probabilité d'occurrence de $\mathbf{Y}^{i,j}$ pour les prototypes de la classe C^j
$P(C^j \mathbf{Y}^{i,j})$	Probabilité <i>a posteriori</i> d'appartenir à la classe C^j étant donné le vecteur d'attributs $\mathbf{Y}^{i,j}$
$P(\mathbf{Y}^{i,j})$	Probabilité d'occurrence de $\mathbf{Y}^{i,j}$
$H(\mathbf{Y}^{i,j})$	Mesure d'entropie obtenue en considérant le vecteur d'attributs $\mathbf{Y}^{i,j}$
$P(\mathbf{Y}_k, \mathbf{Y}_{k'})$	Probabilité jointe entre les attributs Y_k et $Y_{k'}$
$P(\mathbf{Y}_k)$	Probabilité d'occurrence de \mathbf{Y}_k
Σ_W	Matrice de covariance intra-classe
Σ_B	Matrice de covariance inter-classe
Σ_T	Matrice de covariance totale
J_1	Mesure de consistance
J_2	Mesure d'information
J_3	Mesure de corrélation de Pearson
J_4	Mesure d'information mutuelle
J_5	Mesure de dépendance fondée sur l'entropie de Shannon
J_6	Mesure de dépendance fondée sur la distance de Bhattacharyya
J_7	Mesure de dépendance fondée sur la distance de Kullback-Liebler
J_8	Mesure de dépendance fondée sur la distance de Kolmogorov
J_9	Critère de Wilks
J_{10}	Critère de la trace
J_{11}	Critère de Hotelling
$\mathbf{W} = [\mathbf{W}_1, \dots, \mathbf{W}_d]^T$	Vecteur des poids

Notations relatives aux résultats expérimentaux

T_e	Temps moyen pour calculer un attribut à partir d'une image
T	Taux d'images test bien classées
T_c	Temps de classification

Introduction

Le sujet de recherche abordé lors de ma thèse de doctorat s'inscrit dans un contexte industriel, où la vision par ordinateur est utilisée pour le contrôle d'aspect de produits manufacturés. En effet, le champ applicatif de mes travaux de recherche est de répondre à la problématique de l'entreprise Arc International, qui souhaite automatiser le contrôle qualité des décors imprimés par sérigraphie sur les verres qu'elle produit.

Actuellement, le contrôle d'aspect des décors des verres est réalisé par vision humaine, ce qui est fastidieux, peu robuste et surtout très fatigant pour l'opérateur, d'où la nécessité d'automatiser ce contrôle.

Cependant, effectuer automatiquement un contrôle de ces produits à l'aide d'un système de vision industrielle s'avère délicat pour les différentes raisons suivantes :

- la surface à inspecter est de géométrie cylindrique,
- les décors imprimés présentent des textures colorées,
- la cadence de production est relativement élevée car elle atteint un verre par seconde,
- les défauts sont parfois difficiles à détecter visuellement.

Afin de pallier ces difficultés, des premiers travaux de recherche ont été initiés en 2003 dans le cadre de la thèse de doctorat de Laurent Busin [Bus06]. Ce dernier a développé un dispositif destiné à acquérir les images des décors à contrôler, afin de les traiter. L'image de la figure I.2 représente le décor du verre de la figure I.1 où sont présentes une zone de couleurs homogènes et une zone de texture couleur : les couleurs des pixels présents dans le cadre cyan sont homogènes alors que celles des pixels présents dans le cadre orange forment une texture.

Laurent Busin propose alors une approche de **segmentation**¹ d'images couleur par classification de pixels afin de détecter les défauts d'aspect localisés sur l'image du verre à contrôler. L'originalité de son approche porte sur la sélection des espaces couleur qui permettent de discriminer au mieux les classes de pixels en présence. Comme cette approche **multi-espaces couleur** ne tient compte que des distributions des couleurs présentes dans les images, d'excellents résultats ont été obtenus pour le contrôle des verres dont le décor présente des zones de couleurs homogènes.

Cependant, la répartition spatiale des couleurs n'est pas prise en compte par l'approche développée par Laurent Busin et cette dernière s'est avérée être mal adaptée aux décors présentant

1. La segmentation est un traitement qui consiste à créer une partition de l'image en régions disjointes.



Figure I.1 : Verre décoré par sérigraphie.



Figure I.2 : Image du décor du verre de la figure I.1 : le cadre cyan montre une zone d'analyse de couleur homogène, tandis que le cadre orange, une zone de texture couleur.

des zones de textures couleur. Par ailleurs, cette approche se limite à la détection des défauts et ne permet donc pas leur identification.

Les résultats prometteurs obtenus par Laurent Busin ont motivé l'entreprise Arc International et la Région Nord Pas-de-Calais, dans le cadre des actions du pôle de compétitivité MAUD, à étendre ces travaux au contrôle des décors de verres présentant des textures.

Dans le paragraphe I.1, l'approche que nous proposons est introduite. Cette approche est basée sur une méthode de classification supervisée d'images de texture couleur qui sera présentée dans le paragraphe I.2. Enfin, le plan du mémoire sera annoncé dans le paragraphe I.3.

I.1 Approche proposée

L'approche à mettre en place doit permettre de détecter automatiquement les défauts d'aspect se situant dans des zones présentant des textures couleur. Pour cela, nous proposons d'effectuer une **classification supervisée** des images de décors, en construisant différentes classes de manière à ce que chacune d'entre elles soit suffisamment représentative des défauts à détecter, ces derniers se caractérisant par des modifications de la texture des motifs imprimés.

La **classification d'images** consiste à partitionner un ensemble d'images en groupes ou classes, grâce à l'exploitation de leur similarité [JDM00]. Dans une approche supervisée, la

caractérisation des différentes classes est entièrement basée sur des **prototypes**, qui sont des échantillons de classe connue.

Le développement d'une procédure de classification supervisée va permettre non seulement de détecter les défauts présents sur les décors des verres, mais également de les identifier. Cela est intéressant pour l'entreprise car des statistiques sur la présence des défauts vont pouvoir être effectuées afin de cibler les actions correctives.

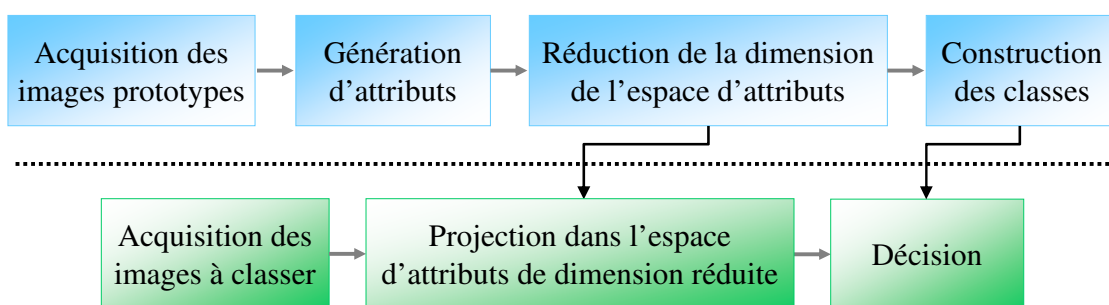
Au delà de l'application au contrôle automatique du décor des produits verriers, l'objectif de cette thèse est de proposer une méthodologie de classification d'images de texture couleur destinée aux diverses applications industrielles de contrôle d'aspect. L'approche que nous présentons dans ce manuscrit vise donc également à respecter les contraintes de temps de traitement et de qualité des résultats que peut imposer toute application industrielle.

Le paragraphe suivant présente les différentes étapes qui constituent la méthode de classification supervisée de textures couleur que nous avons adoptée.

I.2 Classification supervisée de textures couleur

Le schéma présenté sur la figure I.3 illustre de manière générale la méthode de classification supervisée d'images.

Apprentissage (hors-ligne)



Classification (en-ligne)

Figure I.3 : La classification supervisée.

Cette méthode est divisée en deux phases successives [JDM00] :

- l'**apprentissage**, effectué hors-ligne, a pour but de construire des classes à partir de l'ensemble des prototypes (également appelé **ensemble d'apprentissage**) [JMF99]. Pour cela, les textures présentes dans les images prototypes sont décrites par un ensemble d'**attributs**. Chaque texture est alors représentée par un **vecteur d'attributs** dans un es-

pace d'attributs. Un **classifieur**² est ensuite élaboré afin de déterminer la classe d'appartenance d'une image en fonction de ses caractéristiques.

- la **classification**, effectuée en-ligne, consiste à appliquer les règles de classification déterminées lors de l'apprentissage afin de classer l'image de la texture à contrôler.

Les paragraphes suivants détaillent ces deux phases en introduisant les notations nécessaires pour la suite du manuscrit.

I.2.1 Apprentissage

Pour effectuer une classification supervisée d'images, un apprentissage hors-ligne des différentes classes en présence est tout d'abord effectué. Cette phase peut être divisée en quatre parties :

- l'acquisition des images prototypes des différentes classes,
- la génération d'attributs,
- la réduction de la dimension de l'espace d'attributs,
- la construction des classes.

I.2.1.1 Acquisition d'images prototypes

Pour caractériser et discriminer N_C classes d'images C^j ($j = 1, \dots, N_C$), il est nécessaire de constituer une base d'images prototypes suffisamment représentatives des classes, que ce soit en termes de qualité et de quantité. Chaque classe C^j est alors représentée par N_ω^j images prototypes notés $\omega^{i,j}$ ($i = 1, \dots, N_\omega^j$, $j = 1, \dots, N_C$).

Une fois l'ensemble d'apprentissage construit, il est nécessaire de caractériser les différentes classes d'images en présence afin de les discriminer. Pour cela, des attributs sont générés à partir des différents prototypes.

I.2.1.2 Génération d'attributs

La description du contenu des images se fait par le biais d'attributs qui doivent permettre de discriminer les classes en présence. Dans le cas d'images de textures couleur, il est nécessaire d'utiliser des attributs qui soient non seulement capables de caractériser la distribution des couleurs, mais qui tiennent compte également de l'arrangement spatial de ces couleurs dans l'image. Les **attributs de texture couleur** répondent à ce double enjeu.

Un vecteur d'attributs $\mathbf{X}^{i,j} = [\mathbf{X}_1^{i,j}, \dots, \mathbf{X}_l^{i,j}, \dots, \mathbf{X}_D^{i,j}]^T$ de dimension D est alors construit pour chaque image prototype $\omega^{i,j}$ afin de caractériser la texture couleur qui y est présente. $\mathbf{X}_l^{i,j}$ représente la valeur du $l^{\text{ème}}$ attribut X_l calculée à partir du $i^{\text{ème}}$ prototype de la classe C^j .

2. Nous appelons classifieur une méthode de classification associée à un paramétrage donné

Pour obtenir des taux de classification répondant aux objectifs d'une application industrielle, nous verrons qu'il est intéressant de calculer les attributs de texture à partir d'images codées dans différents espaces couleur. Il s'agit de la stratégie multi-espaces couleur.

Dans un premier temps, nous considérerons de nombreux attributs, ce qui peut pénaliser la qualité de la discrimination et imposer un temps de classification en-ligne trop important pour être compatible avec les contraintes d'une application industrielle [JDM00]. Il sera donc nécessaire de procéder à une réduction de l'espace d'attributs afin de ne conserver que les plus pertinents.

I.2.1.3 Réduction de l'espace d'attributs et construction des classes

Pour obtenir des performances de classification satisfaisant aux contraintes industrielles, il est nécessaire de réduire la dimension de l'espace initial $E = \{X_1, \dots, X_D\}$ des attributs X_l ($l = 1, \dots, D$) afin de ne considérer que les plus pertinents pour l'application considérée. La classification opère alors dans le sous-espace $E_{\hat{d}} = \{Y_1, \dots, Y_{\hat{d}}\}$ d'attributs pertinents Y_k ($k = 1, \dots, \hat{d}$, $\hat{d} < D$) résultant de cette réduction.

Nous développerons une procédure de sélection séquentielle pour réduire le nombre d'attributs de texture couleur.

Une fois le sous-espace d'attributs pertinents $E_{\hat{d}}$ sélectionné pour discriminer les classes en présence, les règles de décision sont déterminées afin d'être appliquées lors de la phase de classification en-ligne.

I.2.2 Classification

L'apprentissage supervisé étant effectué, la classification des textures couleur peut opérer en-ligne sur les images des décors de verres. Pour cela, les \hat{d} attributs pertinents déterminés lors de l'apprentissage sont extraits de l'image du verre à contrôler puis comparés aux coordonnées des images prototypes dans le sous-espace d'attributs discriminant sélectionné, afin d'assigner l'image à une classe.

La sélection d'attributs de texture, calculés à partir d'images codées dans différents espaces couleur et qui tiennent compte de la répartition spatiale des couleurs aussi bien au sein de chaque composante d'un même espace (relations intra-composantes), qu'entre les composantes couleur de chaque espace (relations inter-composantes), constitue l'originalité principale de notre méthodologie.

I.3 Plan du mémoire

Notre contribution porte principalement sur les attributs de texture couleur et leur sélection. C'est pourquoi, les deux premiers chapitres de ce mémoire s'intéressent respectivement à ces deux thèmes. La méthodologie originale de classification d'images de texture couleur (parfois appelée plus simplement classification de textures couleur) et les résultats expérimentaux qui en découlent seront présentés dans les chapitres suivants.

Le chapitre 1 présente l'état de l'art des principaux attributs de texture couleur utilisés dans le cadre de la classification d'images. La majorité de ces attributs a tout d'abord été définie pour décrire les textures présentes dans les images en niveaux de gris, et ce, en caractérisant au mieux les différentes propriétés de texture recensées dans le paragraphe 1.2. Cependant, plusieurs auteurs ont montré que l'exploitation de la couleur permet d'améliorer les résultats en termes de classification de textures, comparativement à une simple analyse des propriétés de la luminance (cf. § 1.3). Ces conclusions résultent notamment de l'application de méthodes de classification sur différentes bases d'images de référence, qui sont décrites au paragraphe 1.4. Les principaux attributs caractérisant à la fois la texture et la couleur sont alors présentés dans les paragraphes 1.5 à 1.9.

Atteindre une discrimination aussi performante que possible des classes d'images en présence amène cependant à considérer un ensemble important d'attributs de texture couleur. Par ailleurs, la détermination *a priori* des attributs qui permettent de discriminer au mieux les classes considérées est difficile. C'est pourquoi, nous proposons d'utiliser une méthode de sélection automatique des attributs, opérant lors de l'apprentissage supervisé. Le chapitre 2 présente les principales méthodes de réduction de la dimension de l'espace d'attributs. Ces méthodes peuvent être divisées en deux catégories : l'extraction d'attributs et la sélection d'attributs. Le nombre de méthodes de réduction étant très important, nous avons choisi de nous restreindre à une brève vue d'ensemble des principales méthodes d'extraction (cf. § 2.2), pour mener une analyse plus détaillée des méthodes de sélection (cf. § 2.3) qui seront exploitées dans nos travaux. Ce chapitre présentera également les différentes méthodes de validation destinées à mesurer la qualité de l'espace d'attributs sélectionné lors de l'apprentissage et la pertinence des règles de décision utilisées pour la phase de classification (cf. § 2.4).

Dans le chapitre 3, la démarche qui nous a amené à considérer plusieurs espaces couleur pour caractériser les classes d'images en présence sera présentée (cf. § 3.2). Puis, nous justifions le choix d'utiliser les attributs d'Haralick pour caractériser les textures couleur (cf. § 3.3). Enfin, nous détaillerons la méthode originale de sélection séquentielle que nous avons développée pour réduire la dimension de l'espace initial d'attributs (cf. § 3.4). Chacun des choix retenus dans ce chapitre sera motivé par les contraintes de performances qu'exigent les applications industrielles en termes de résultats et de temps d'exécution. La méthode de classification de textures couleur résultant de ces différents choix sera finalement présentée dans le para-

graphe 3.5.

Le chapitre 4 présentera alors les résultats expérimentaux obtenus en appliquant la méthodologie développée à trois ensembles d'images extraits de bases de référence et décrits au paragraphe 4.2. Les résultats de classification et les temps de traitement obtenus avec ces bases seront alors détaillés dans les paragraphes 4.3 et 4.4. Une comparaison de ces résultats avec ceux obtenus dans les travaux parus dans la littérature et portant sur la classification de textures couleur sera ensuite menée dans le paragraphe 4.5. Cette comparaison permettra de mettre en évidence la pertinence de la méthodologie développée. D'autre part, afin d'étudier la robustesse de la méthode vis-à-vis des principaux paramètres qui la définissent, nous analyserons dans le paragraphe 4.6 l'influence de ces paramètres sur les performances de classification. Enfin, nous évaluerons dans le paragraphe 4.7 la pertinence des choix qui ont été arrêtés dans le chapitre précédent en mesurant l'apport de l'approche multi-espaces couleur pour caractériser les textures, le bénéfice que présente la considération conjointe des relations spatiales intra et inter-composantes, et enfin l'apport de la procédure de sélection.

Enfin, nous appliquerons dans le chapitre 5 la méthodologie développée au contrôle qualité des décors de verres produits par l'entreprise Arc International, afin de montrer la pertinence de l'approche proposée vis à vis d'une application en milieu industriel. Le processus de sérigraphie ainsi que les défauts d'aspect qui peuvent être générés durant la fabrication des verres seront tout d'abord présentés (cf. § 5.2). Puis, le paragraphe 5.3 décrira brièvement les premiers travaux de recherche initiés par Laurent Busin sur le contrôle qualité des décors de verres et montrera leurs limites. Le paragraphe 5.4 présentera alors les résultats obtenus par notre approche en termes d'identification de défauts présents sur des décors texturés. Ce paragraphe mettra ainsi en évidence l'apport de la méthode originale développée durant ces travaux de doctorat.

Chapitre 1

Attributs de texture couleur

1.1 Introduction

Dans le cadre de la classification d'images contenant chacune une texture (appelées **images de texture**), il est essentiel d'exploiter des attributs qui caractérisent et discriminent au mieux les différentes classes d'images de texture en présence. Ces **attributs de texture** peuvent être regroupés en quatre grandes familles [PVM09] :

- les attributs géométriques,
- les attributs basés sur la modélisation spatiale des textures,
- les attributs spatio-fréquentiels,
- les attributs statistiques.

La majorité de ces attributs a tout d'abord été définie pour décrire les textures présentes dans les **images en niveaux de gris**. Nous considérons que les **attributs de texture en niveaux de gris** sont des attributs qui tiennent uniquement compte de l'information de **luminance** (la luminance est ici définie comme étant l'attribut d'une sensation visuelle selon laquelle une surface paraît émettre plus ou moins de luminosité). Ces attributs de texture en niveaux de gris ont pour but de caractériser au mieux les différentes propriétés de texture, que nous avons recensées dans le paragraphe 1.2.


Cependant, dans le cadre de la classification d'images de texture couleur, l'exploitation de la seule information de luminance est parfois insuffisante pour discriminer les textures. Par ailleurs, plusieurs auteurs ont montré que l'exploitation de la couleur permet d'améliorer les résultats en termes de classification de textures, comparativement à une simple analyse en niveaux de gris [Pal04, BR04, HCG⁺05] (cf. § 1.3). Ces conclusions résultent de l'application de méthodes de classification sur différentes bases d'images de référence, présentées dans le paragraphe 1.4. Dans les paragraphes 1.5 à 1.9, nous nous attacherons donc à décrire les principaux attributs de texture couleur, utilisés dans le cadre de la classification d'images. Enfin, une synthèse de cette étude sera présentée dans le paragraphe 1.10.

1.2 Notion de texture

Il n'existe pas de définition universelle de la notion de **texture**. Dans le cadre de l'analyse d'images, différentes définitions sont proposées [TJ98] :

- certains auteurs vont s'attacher plus particulièrement à l'aspect visuel, comme Tamura, qui définit la texture de la façon suivante : "We may regard texture as what constitutes a macroscopic region. Its structure is simply attributed to the repetitive patterns in which elements or primitives are arranged according to a placement rule." [TMY78].
- D'autres auteurs définissent la texture selon leur propre application. La définition de Sklansky illustre ce propos : "A region in an image has a constant texture if a set of local statistics or other local properties of the picture function are constant, slowly varying, or approximately periodic." [Skl78].

Les images de la figure 1.1, issues de la base de données image VisTex (une description approfondie de cette base d'images de référence est fournie au paragraphe 1.4), représentent respectivement la texture d'une brique, celle d'un tissu et celle de l'eau. Les textures présentes dans ces images se manifestent non seulement comme un agencement spatial plus ou moins régulier d'éléments qui constituent un ensemble, mais aussi par des informations visuelles qui permettent de les décrire qualitativement à l'aide d'adjectifs tels que contrastées, grossières, fines, lisses, tachetées, granuleuses, marbrées, régulières ou irrégulières...



(a) Texture d'une brique.

(b) Texture d'un tissu.

(c) Texture de l'eau.


Figure 1.1 : Exemples de textures.

Bien qu'il soit aisé de décrire une texture visuellement, il reste difficile d'en donner une définition précise. D'un point de vue formel, il est généralement admis que la texture est fonction des variations spatiales de niveaux de gris des pixels de l'image, et dans la pratique, il existe deux approches pour la définir [CP95] :


- la première correspond à une observation du type **macroscopique** et fait appel à la notion de **texton** définie par Julesz [Jul81]. Dans ce contexte, la texture est considérée comme la répartition spatiale répétitive ou périodique d'un motif élémentaire, également appelé **primitive** (une primitive est un ensemble connexe de pixels qui partagent des propriétés similaires [Her99]). C'est le cas de l'image de la figure 1.2(a) issue de la base OuTex

(cf. § 1.4.3) où la primitive considérée correspond à un pavé. La texture peut alors être définie selon une approche **déterministe** (ou **structurelle**) dans la mesure où les motifs de base se répartissent de manière régulière et ordonnée dans l'image en suivant des règles précises de direction et de placement.

- la seconde approche considère que l'observation doit se faire à un niveau **microscopique** où les pixels obéissent localement aux règles d'une distribution à déterminer. Ce propos est illustré par l'image de la figure 1.2(b) où la primitive de la texture est cette fois-ci considérée au niveau d'un voisinage de chaque pixel. Elle peut alors être définie selon un approche **probabiliste** (ou **aléatoire**) dans la mesure où la distribution des niveaux de gris des pixels apparaît irrégulière et désordonnée dans l'image.



(a) Observation macroscopique d'une texture (image de taille 746×538 extraite de la base OuTex).



(b) Observation microscopique d'une texture (image de taille 746×538 extraite de la base OuTex).

Figure 1.2 : Illustration des approches microscopique et macroscopique de la texture.

Dans beaucoup de cas, la texture n'est ni totalement structurelle, ni totalement aléatoire. Par exemple, elle peut se caractériser essentiellement selon certaines directions dominantes, sans qu'il y ait vraiment de répartition régulière ou complètement aléatoire d'un motif de base [Mav01, Han02]. Dans ce cas, elle est définie comme étant une **texture orientée** (ou **texture directionnelle**) [Cos01]. L'image de la figure 1.2 issue de la base BarkTex (cf. § 1.4.2) illustre ce type de texture.

La distinction aisément faite par l'oeil humain entre plusieurs textures est une tâche difficile à réaliser en vision par ordinateur, dans la mesure où il existe un nombre infini de textures et où chacune possède ses propres caractéristiques. Il n'existe d'ailleurs pas de méthodes capables de classer toutes les textures aussi bien que le ferait un observateur humain. Cependant, Tuceryan recense un certain nombre de propriétés intuitives généralement attribuées à la texture, qui peuvent être exploitées pour l'analyse d'images en niveaux de gris [TJ98]. Ces propriétés définissent les impressions visuelles de l'observateur humain et permettent par conséquent de reproduire au mieux la classification de textures effectuée par ce dernier :



Figure 1.3 : Illustration d'une texture orientée (image de taille 256×384 extraite de la base BarkTex).

- La définition d'une texture doit impliquer un voisinage spatial. La taille de ce voisinage dépend du type de texture ou de la surface occupée par le motif définissant cette dernière.
- Une région est considérée comme texturée si elle présente un nombre suffisant de motifs la définissant.
- La texture est un arrangement spatial des niveaux de gris des pixels.
- Elle peut être perçue à différents niveaux d'**échelle** (l'échelle correspond ici au champ de vision : c'est la taille en millimètre des côtés de la surface observée) et à différents niveaux de **résolution spatiale** (la résolution spatiale correspond au nombre de pixels par unité de longueur).

Ces propriétés texturales ont permis de définir un grand nombre d'attributs caractérisant les textures présentes dans des images en niveaux de gris.

Certains de ces attributs ont ensuite été étendus à la couleur. Leur définition tient alors compte des composantes définissant le système de représentation de la couleur considéré, comme par exemple les composantes rouge, verte et bleue du système (R, G, B) (cf. annexe A).

Le paragraphe suivant montre comment la couleur peut être exploitée pour améliorer l'analyse de texture couleur.

1.3 Exploitation de la couleur pour l'analyse de texture

Avant de mesurer la contribution de la couleur à l'analyse de texture, une brève explication de la représentation de la couleur d'une image numérique est tout d'abord nécessaire.

1.3.1 Représentation de la couleur

Lors de l'acquisition d'une image par une caméra couleur, la scène observée est numérisée afin d'extraire des valeurs numériques manipulables par l'ordinateur. Il s'agit de l'échantillonnage et de la **quantification** de l'information couleur. Chaque image couleur numérique \mathbf{I} est une matrice de pixels P dont la couleur $C(P)$ est définie par trois composantes rouge, verte et bleue notées respectivement $C_R(P)$, $C_G(P)$ et $C_B(P)$. La couleur peut non seulement être représentée en utilisant ces trois composantes, mais également en utilisant d'autres systèmes de représentation de la couleur [Van00]. Une étude approfondie de ces différents systèmes de représentation est présentée en annexe A.

Dans le cas général, la couleur d'un pixel est représentée par trois composantes notées C_1 , C_2 et C_3 . A ces trois composantes, correspondent respectivement trois vecteurs directeurs normés \vec{C}_1 , \vec{C}_2 et \vec{C}_3 qui forment le repère d'un espace vectoriel d'origine O appelé **espace couleur** et noté (C_1, C_2, C_3) . Dans cet espace, la couleur d'un pixel donne naissance à un point C , qui définit le vecteur couleur \vec{OC} et dont les coordonnées sont les niveaux des composantes C_1 , C_2 et C_3 . La figure 1.4 illustre ce propos.




Figure 1.4 : Le pixel encadré en blanc dont les composantes couleur sont C_1 , C_2 et C_3 donne naissance à un point C dans l'espace (C_1, C_2, C_3) .

Par extension de ce principe à l'ensemble des pixels d'une image, les couleurs des pixels d'une image donnent donc naissance à des nuages de points dans l'espace couleur (C_1, C_2, C_3) considéré (cf. figure 1.5).

A partir de l'image couleur \mathbf{I} codée dans l'espace (C_1, C_2, C_3) , on peut extraire trois **images-composantes** notées \mathbf{I}^{C_k} , où chaque pixel est caractérisé par une des composantes couleur C_k ($k \in (1, 2, 3)$). Nous appellerons d'autre part \mathbf{I}^L , l'image de luminance correspondant à l'image couleur \mathbf{I} , dont la définition est donnée en annexe A.

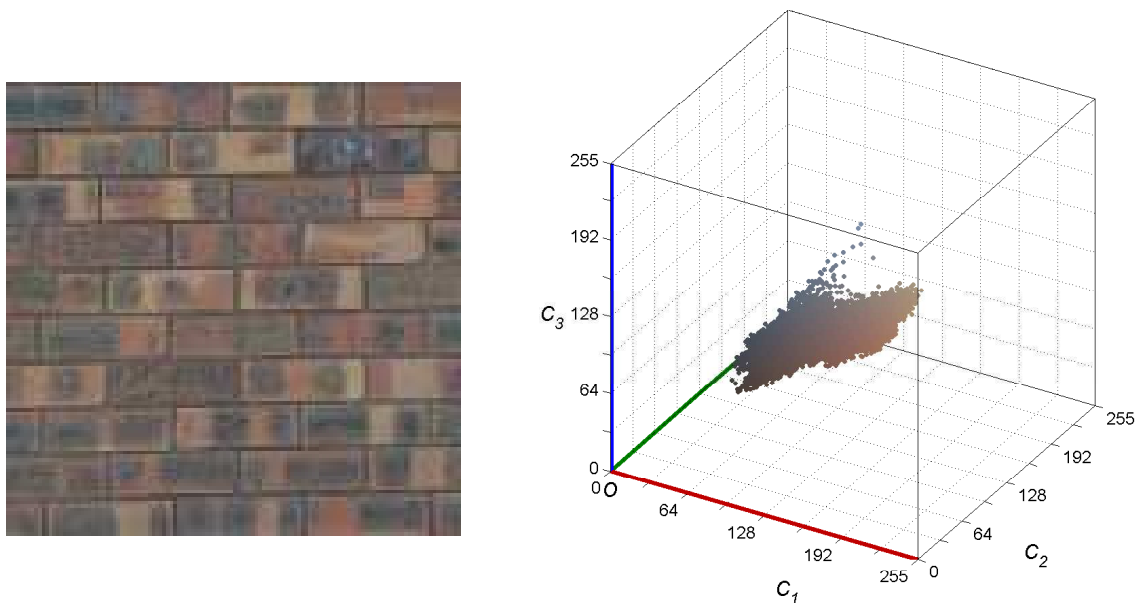


Figure 1.5 : Les couleurs des pixels de l'image donnent naissance à des nuages de points dans l'espace (C_1, C_2, C_3) .

1.3.2 Contribution de la couleur à l'analyse de texture

Différents auteurs se sont penchés sur l'apport de la couleur à la classification d'images de texture :

- Palm mesure le contenu informationnel de différents attributs de texture extraits d'images de la base Vistex, dont les couleurs des pixels sont codées dans un espace couleur luminance-chrominance [Pal04]. Il effectue cette mesure à l'aide de la distance de Kolmogorov et évalue le contenu informationnel d'attributs de texture qui, d'une part ne considèrent que l'information de luminance et qui, d'autre part ne prennent en compte que le caractère chromatique de la couleur. Il montre ainsi que la considération du caractère chromatique de la couleur permet d'enrichir l'information fournie par la seule prise en compte de la luminance.
- De même, Van den Broek, ainsi que Hernandez montrent que l'exploitation de la couleur permet d'améliorer les résultats de classification de textures [BR04, HCG⁺05]. Pour cela, ils comparent les taux de bonne classification obtenus en caractérisant les images de texture couleur par des attributs calculés d'une part, uniquement à partir de la luminance, et d'autre part, avec des composantes couleur.

L'exploitation de la couleur permettant d'améliorer les résultats en termes de classification d'images de texture couleur, notre choix se portera donc plus particulièrement sur des attributs qui caractérisent à la fois la texture et la couleur.

Notons que pour effectuer cette double caractérisation, différentes approches existent [FGDT04, PFJ06, ADBB04]. Cependant, trois d'entre elles sont couramment considérées :

1. Certains auteurs proposent simplement d'associer des attributs de texture extraits de

l'image de luminance avec des attributs caractérisant la distribution des couleurs au sein d'un espace de représentation [VCBFM02, MVP03, PFJ06, LVPF08]. La figure 1.6 illustre cette approche.

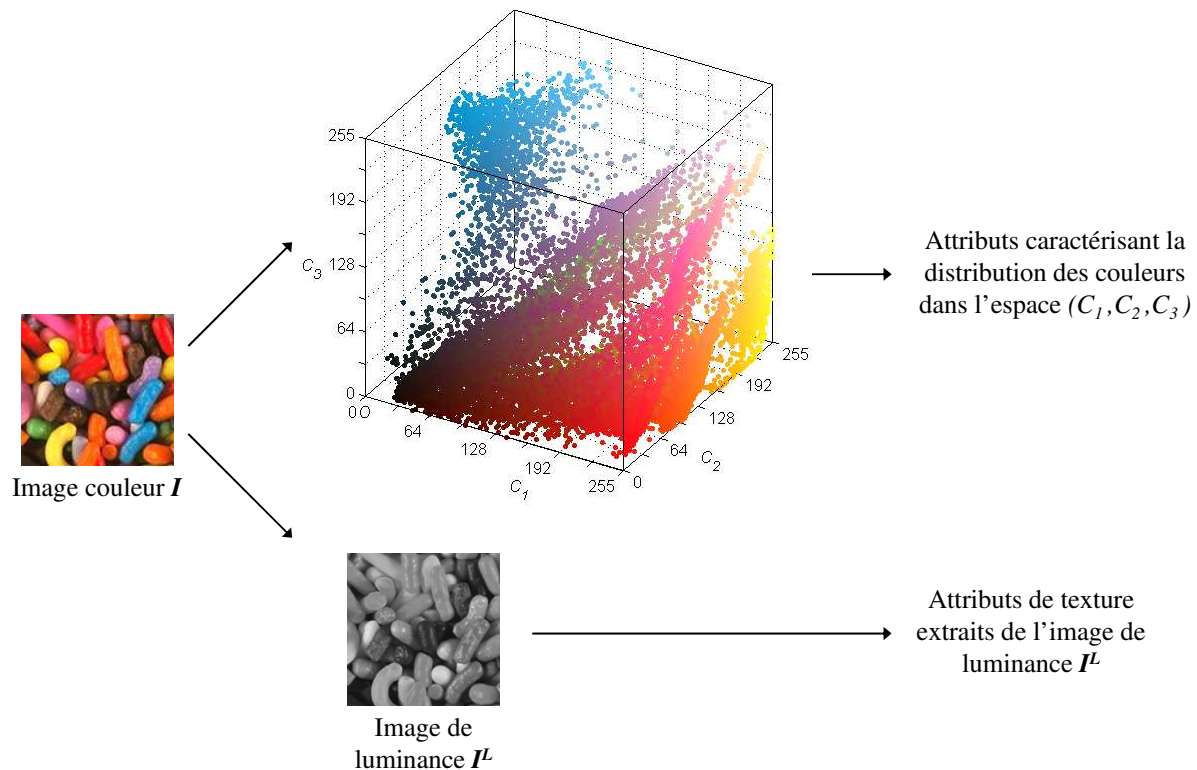


Figure 1.6 : Caractérisation de la texture couleur par des attributs de texture extraits de l'image de luminance et des attributs caractérisant la distribution des couleurs dans l'espace (C_1, C_2, C_3).

2. D'autres auteurs préfèrent considérer des attributs de texture couleur qui ne tiennent compte que des **relations intra-composantes** (les relations intra-composantes caractérisent les interactions spatiales entre les différents niveaux au sein d'une même composante) [ADBB04, MALDTB05, AML08]. La figure 1.7 illustre cette approche.
3. Enfin, pour caractériser la texture couleur, certains auteurs proposent de considérer des attributs de texture couleur qui tiennent compte à la fois des relations intra et inter-composantes (les **relations inter-composantes** caractérisent les relations entre les différents niveaux de deux composantes couleur différentes) [ADBB04, PS04, XM07]. La figure 1.8 illustre cette approche de caractérisation de textures couleur.

Arvis montre que la considération d'attributs intra ou inter-composantes permet d'obtenir de meilleurs résultats de classification par rapport à l'utilisation d'attributs de texture extraits de l'image de luminance associés à des attributs caractérisant la distribution des couleurs [ADBB04]. C'est pourquoi nous proposons de concentrer notre étude sur les attributs de texture couleur.




Figure 1.7 : Caractérisation de la texture couleur par des attributs de texture couleur qui ne tiennent compte que des relations intra-composantes dans l'espace (C_1, C_2, C_3) .

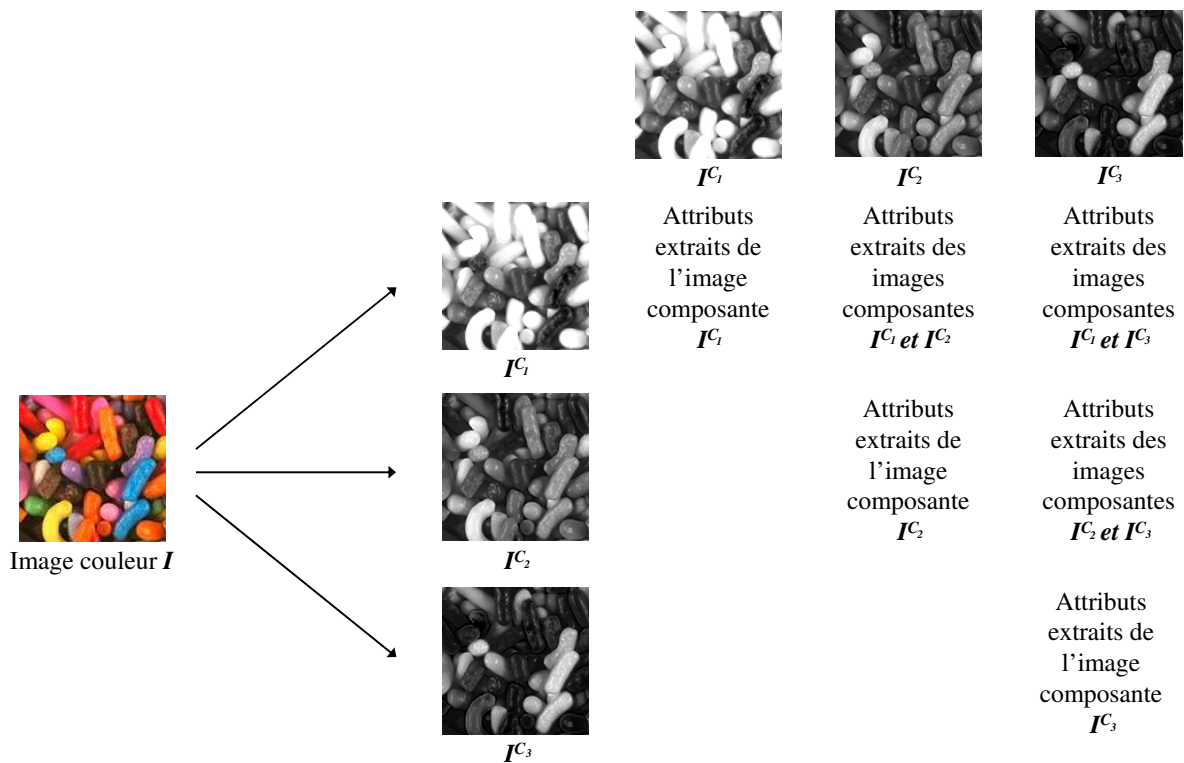


Figure 1.8 : Caractérisation de la texture couleur par des attributs de texture couleur qui tiennent compte à la fois des relations intra et inter-composantes dans l'espace (C_1, C_2, C_3) .

Avant de décrire plus précisément ces attributs, nous présentons dans le paragraphe suivant différentes bases d'images de texture couleur couramment utilisées dans le cadre de la classification de textures.

1.4 Présentation des bases d'images de texture couleur de référence

Les bases d'images de texture couleur VisTex, BarkTex et OuTex sont considérées comme des bases de référence car elles sont fréquemment employées dans la littérature afin de comparer expérimentalement les résultats de classification de textures couleur obtenus par différentes méthodes [PGM⁺, Lak, OMP⁺02]. Les paragraphes suivants décrivent ces bases d'images car elles seront utilisées pour présenter et comparer les résultats de mes travaux.

1.4.1 Description de la base VisTex

La base VisTex est une collection d'images de texture couleur extraites de scènes naturelles [PGM⁺]. Cette base de référence est constituée de 168 images acquises dans des conditions non contrôlées et réparties en 19 catégories de textures couleur. Ces images sont disponibles en différentes tailles : 128×128 , 128×192 , 192×128 , 512×512 , 512×768 et 768×512 pixels, ce qui correspond à différentes résolutions spatiales. Cependant, le nombre d'échantillons pour chaque catégorie de textures est faible. En effet, il varie entre 2 et 20 selon la catégorie considérée. C'est pourquoi, la plupart des auteurs qui utilisent cette base d'images sont amenés à diviser les images en "imasettes" afin d'augmenter le nombre d'échantillons [Pal04, HCG⁺05, KH06, MP04, PMV02, DW01].

L'image de la figure 1.9 représente quelques textures couleur de taille 128×128 pixels issues de la base VisTex. Cette figure illustre cinq classes d'images et chaque ligne contient quatre images propres à chaque classe. On trouve de haut en bas :

- la classe **Bark**, représentant des écorces d'arbres,
- la classe **Fabric**, où se trouvent divers textiles,
- la classe **Food**, où sont présents différents types d'aliments,
- la classe **Metal**, représentant la texture de différents métaux,
- et enfin la classe **Water**, où diverses images d'eau sont présentes.

1.4.2 Description de la base BarkTex

La base BarkTex comporte 6 classes d'images de texture couleur orientées verticalement correspondant à des écorces d'arbres, avec 68 images pour chacune d'entre elles, ce qui représente 408 images au total, disponibles en deux tailles : 128×192 et 256×384 pixels correspondant à deux résolutions spatiales différentes [Lak].



Figure 1.9 : Exemple d'images de taille 128×128 extraites de la base VisTex.

Les différentes classes sont les suivantes : la classe **Betula pendula**, la classe **Fagus silvatica**, la classe **Picea abies**, la classe **Pinus silvestris**, la classe **Quercus robur** et enfin la classe **Robinia pseudacacia**. Ces dénominations désignent différents types d'arbres. L'image de la figure 1.10 illustre quelques unes des textures couleur de taille 128×192 présentes dans la base BarkTex.

La taille de la base BarkTex est plus importante que celle de la base VisTex. Les résultats obtenus sont donc plus significatifs et plus représentatifs de la qualité de la méthode de classification considérée.

D'autre part, la discrimination des textures de cette base est beaucoup plus complexe que celle de la base VisTex. En effet, toutes les images de texture couleur de cette base représentent un seul et même type d'objet, à savoir des écorces d'arbres. La discrimination visuelle entre les différentes classes d'écorce est donc parfois difficile, comme le montre la figure 1.11, où sont




Figure 1.10 : Exemple d'images de taille 128×192 extraites de la base BarkTex.

représentées deux images, qui semblent appartenir à la même classe mais qui sont en fait issues de deux classes différentes.

De plus, contrairement à la base VisTex où les textures à étudier sont présentes sur l'ensemble de l'image, les images de la base BarkTex représentent non seulement la texture des différents types d'écorces mais aussi le fond de l'image, comme le montre la figure 1.12.

Seule la texture des écorces doit être prise en compte pour la classification. C'est pourquoi il est important de délimiter pour chaque image une zone d'étude, centrée sur l'écorce, qui permet de ne pas considérer le fond de l'image [MVK⁺02].

Enfin, comme pour la majorité des images représentant des scènes naturelles, les conditions d'éclairage lors de l'acquisition des images de la base BarkTex ne sont pas contrôlées, comme le montre la figure 1.13 où sont représentées deux images appartenant à la classe *Betula pendula*, mais acquises selon des conditions d'éclairage différentes.




Figure 1.11 : Exemples d'images de la base BarkTex appartenant à deux classes différentes mais qui semblent visuellement très proches.

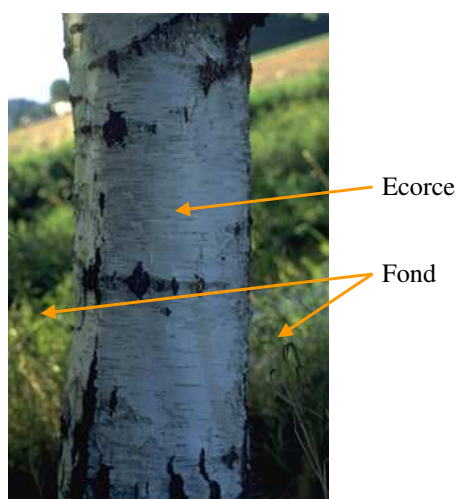


Figure 1.12 : Exemple d'une image de la base BarkTex où sont représentées deux textures (fond et écorce).

1.4.3 Description de la base OuTex

La base d'images de texture couleur OuTex a été créée dans le but de fournir un large panel de textures pour les applications de traitement d'images [OMP⁺02]. Tout comme la base VisTex, la base OuTex contient un grand nombre d'objets différents, à savoir 29 catégories d'images de texture couleur. Le nombre d'images par catégorie varie entre 1 et 47 selon la catégorie considérée. C'est pourquoi, comme pour la base VisTex, la plupart des auteurs qui utilisent les images OuTex sont amenés à les diviser en "imassettes" afin d'augmenter le nombre d'échantillons [ADBB04, MP04, PMV02, XYD05, IMK05].




Figure 1.13 : Exemple d'images de la base BarkTex acquises avec des conditions d'éclairage différentes.

Une des particularités de la base OuTex est qu'elle offre aux utilisateurs des images acquises dans des conditions diverses et contrôlées. Les images de taille 746×538 pixels sont acquises par une caméra 3CCD de modèle Sony DXC-755P, avec trois sources lumineuses différentes :

- un éclairage du type "soleil à l'horizon", dont la température de couleur proximale est égale à 2300 K,
- une lampe à incandescence (2856 K),
- une lampe fluorescente (4000 K).

La **température de couleur proximale** d'une source de lumière, mesurée en Kelvin (K), est la température à laquelle il faudrait porter un corps noir pour obtenir l'impression visuelle la plus proche de celle produite par cette source de lumière [VM05].

D'autre part, grâce à cette base, les textures peuvent être étudiées selon six résolutions spatiales différentes (100, 120, 300, 360, 500 and 600 dpi¹) et avec une direction d'observation spécifique parmi neuf possibles (0°, 5°, 10°, 15°, 30°, 45°, 60°, 75° et 90°).

Les images de la figure 1.15 illustrent la texture de la figure 1.14 acquise avec :

- différentes conditions d'éclairage (images 1.15(a) et 1.15(b)),
- différentes résolutions (images 1.15(c) et 1.15(d)),
- différents angles de rotation de la texture autour de l'axe optique de la caméra (images 1.15(e) et 1.15(f)).

Les trois bases de référence étant présentées, nous proposons d'introduire dans le paragraphe suivant les attributs classiquement utilisés pour classer les images de texture couleur.

1. La résolution spatiale est ici exprimée en **dpi** (Dots Per Inch) ce qui équivaut en français au nombre de pixels par pouce.



Figure 1.14 : Image de taille 746×538 contenant la texture d'un plastique acquise avec un éclairage du type "soleil à l'horizon", une résolution de 100 dpi et un angle de rotation de 0° .

1.5 Caractérisation des textures couleur

Les attributs pouvant caractériser les différentes textures en présence peuvent être regroupés en plusieurs grandes catégories, détaillées dans les paragraphes suivants [TJ98] :

- les attributs géométriques,
- les attributs basés sur la modélisation spatiale des textures,
- les attributs spatio-fréquentiels,
- les attributs statistiques.

La répartition des attributs dans ces différentes catégories n'est pas stricte et un attribut peut appartenir à plusieurs d'entre elles.

Le type de texture à analyser conditionne souvent le choix des attributs à utiliser. En effet, une texture régulière sera mieux décrite par des attributs géométriques, tandis qu'une texture irrégulière sera mieux caractérisée par des attributs statistiques.

Un autre critère important dans le choix des attributs de texture est leur invariance aux transformations engendrées par la modification des conditions d'observation, telles que la rotation, la translation, l'homothétie, le changement des conditions d'éclairage ou encore le changement de résolution spatiale.

Nous proposons dans les paragraphes suivants de décrire les attributs appartenant à chacune des quatre catégories citées ci-dessus.

Comme de très nombreux travaux portent sur l'analyse des textures couleur, nous avons choisi de limiter notre étude bibliographique en se restreignant aux travaux de classification de textures couleur utilisant des attributs qui tiennent compte soit des relations intra-composantes seules, soit des relations intra et inter-composantes.



(a) Texture de la figure 1.14 acquise avec une lampe à incandescence.



(b) Texture de la figure 1.14 acquise avec une lampe fluorescente.




(c) Texture de la figure 1.14 acquise avec une résolution de 300 dpi.



(d) Texture de la figure 1.14 acquise avec une résolution de 500 dpi.



(e) Texture 1.14 de la figure 1.14 acquise avec un angle de rotation de 45° .



(f) Texture 1.14 de la figure 1.14 acquise avec un angle de rotation de 90° .

Figure 1.15 : Images représentant la même texture que la figure 1.14 acquise avec différentes conditions d'éclairage, différentes résolutions et différents angles de rotation de la texture autour de l'axe optique de la caméra.

1.6 Attributs géométriques

La description dite géométrique d'une texture tient compte de l'information structurelle et contextuelle de l'image. Elle est particulièrement bien adaptée à la description des textures lorsque celles-ci sont observées à un niveau macroscopique. En effet, la description de la texture est faite par :

- une extraction explicite des primitives (régions, contours, motifs élémentaires, ...) lors d'un prétraitement,
- des règles de placement de ces primitives.

Cette description se fait par le biais d'attributs appelés attributs géométriques. Par exemple, Zheng a récemment proposé une méthode géométrique de classification d'images de texture couleur particulièrement bien adaptée à l'analyse des textures de viande [ZSZ07].

Cependant, comme ces attributs sont sensibles à la régularité des motifs texturés présents dans l'image, ils ne permettent pas de caractériser des textures irrégulières comme celles présentes dans la majorité des images naturelles. Nous ne nous attarderons donc pas sur les attributs issus de ces méthodes, mais privilégierons plutôt les attributs permettant la caractérisation des textures sans hypothèses *a priori* sur leur géométrie.

1.7 Attributs basés sur la modélisation spatiale des textures

Ces attributs sont issus de différentes modélisations de la répartition spatiale des couleurs dans l'image. Les principaux modèles utilisés dans le cadre de la classification d'images couleur sont :

- les modèles autorégressifs multispectraux,
- les modèles de Markov multispectraux,
- les motifs locaux binaires.

1.7.1 Modèles autorégressifs multispectraux

Les modèles autorégressifs multispectraux sont l'extension au domaine de la couleur des modèles autorégressifs définis en niveaux de gris. Ils considèrent que la couleur d'un pixel dépend de son voisinage et que les niveaux des composantes couleur de ce pixel sont des combinaisons linéaires des niveaux des composantes couleur des pixels voisins, ajouté d'un bruit blanc.

Les attributs de texture couleur sont obtenus par estimation des paramètres du modèle linéaire considéré pour caractériser les différentes textures.

Le modèle le plus connu et le plus utilisé dans le cadre de la classification de textures couleur est le modèle MSAR (Multispectral Simultaneous AutoRegressive model) [HK04, BK98].

Khotanzad et Hernandez utilisent le modèle MSAR couleur, qui caractérise les relations intra et inter-composantes, pour classer les textures couleur de la base VisTex [HCG⁺05, KH06].

Qazi propose quant à lui de caractériser les textures couleur de cette base en utilisant une extension des modèles autorégressifs basée sur la séparation des informations de luminance et de chrominance [QABFM09].

1.7.2 Modèles de Markov multispectraux

Les modèles markoviens, comme les champs de Markov ou les champs de Gibbs, sont des cas particuliers des modèles autorégressifs. En effet, ces outils probabilistes de modélisation

spatiale des textures ont également pour intérêt de pouvoir caractériser les interactions locales entre les pixels de façon simple. Le plus souvent utilisée dans un cadre bayésien (c'est-à-dire que l'on estime les paramètres du modèle et leur intervalle de confiance), cette approche consiste également à faire l'hypothèse que la valeur des composantes couleur d'un pixel ne dépend que de celles d'un voisinage réduit de ce pixel [BK98].

Ce qui distingue les modèles de Markov multispectraux des modèles autorégressifs est la définition du voisinage utilisé. En effet, pour analyser les textures dans le cadre des modèles Markoviens, la dépendance entre la couleur d'un pixel et celles de ses voisins n'est mesurée que s'ils appartiennent à une **clique**. Une clique est un ensemble de pixels qui sont voisins deux à deux selon le voisinage considéré. La figure 1.16 montre l'exemple du 8-voisinage et des cliques qui lui sont associées.




Figure 1.16 : Le 8-voisinage et les cliques associées.

Sur cette figure, on distingue une clique constituée d'un pixel (singleton), 4 cliques constituées de deux pixels voisins (doubletons), chacune étant orientée dans une des directions classiques (0° , 45° , 90° et 135°) mais également 4 cliques constituées de trois pixels voisins et une clique à quatre pixels où chacun des pixels appartient bien au voisinage des autres, au sens du 8-voisinage.

A chaque clique est associée une fonction paramétrique appelée **fonction potentiel**, dont la valeur dépend des relations qui existent entre les niveaux des composantes couleur des pixels de la clique. Cette fonction tient non seulement compte des relations intra-composantes mais également des relations inter-composantes. Les paramètres de la fonction potentiel sont ensuite estimés. Khotanzad utilise par exemple la méthode des moindres carrés pour effectuer cette estimation [KH06]. Ce sont ces paramètres estimés qui constituent les attributs décrivant la texture observée.

Hernandez utilise ces attributs pour montrer que l'exploitation de la couleur permet d'améliorer les résultats en termes de classification de textures par rapport à l'exploitation de la seule information de luminance [HCG⁺05, KH06]. Les modèles utilisés par l'auteur pour analyser les textures de la base VisTex sont les champs de Markov multispectraux et les pseudo champs de Markov, ces derniers étant une variante des champs de Markov multispectraux (estimation différente du bruit blanc).

Chindaro a également exploité les champs de Markov pour définir une nouvelle méthode de classification de textures basée sur la fusion d'informations provenant de différents espaces couleur [CSD05, CSF06].

La modélisation par les champs de Markov ou les champs de Gibbs s'adapte particulièrement bien à la description des textures lorsque celles-ci sont observées à un niveau microscopique. Cependant, l'estimation des paramètres de la fonction potentiel nécessite l'examen d'un nombre élevé de pixels. Pour pallier cette contrainte, Suen propose, pour classer les images de texture couleur de la base VisTex, une extension des champs de Markov qui ne nécessite qu'un nombre réduit de pixels [SH99].

1.7.3 Motifs locaux binaires couleur

Les motifs locaux binaires (LBP : Local Binary Pattern) ont initialement été proposés pour décrire les textures présentes dans des images en niveaux de gris [OPH96]. Leur extension à la couleur a ensuite été plusieurs fois utilisée par Mäenpää et Pietikäinen dans le cadre de leur étude sur l'utilisation conjointe de la texture et de la couleur, pour la classification d'images de texture couleur [MP04, PMV02].

Les LBP consistent à attribuer, à chaque pixel P de l'image \mathbf{I} à analyser, des valeurs caractérisant le motif local autour de ce pixel. Ces valeurs sont calculées en comparant les niveaux des composantes couleur du pixel central P aux niveaux des composantes des pixels voisins. Le résultat de la comparaison effectuée pour chaque pixel voisin est codé grâce à un masque de poids. On note $LBP[P]^{C_k, C_{k'}}$, l'attribut LBP couleur caractérisant les interactions spatiales entre les composantes couleur C_k et $C_{k'}$ des pixels situés dans le voisinage du pixel P . La figure 1.17 illustre le calcul de $LBP[P]^{C_1, C_1}$, $LBP[P]^{C_1, C_2}$ et $LBP[P]^{C_2, C_1}$ pour un pixel P dont la couleur est codée dans un espace (C_1, C_2, C_3) avec $N = 8$ niveaux de quantification (la couleur des pixels

est représentée par la cellule $\begin{pmatrix} C_1 \\ C_2 \\ C_3 \end{pmatrix}$). Dans cet exemple le voisinage 3×3 est utilisé.

Pour le calcul de $LBP[P]^{C_1, C_1}$ du pixel P à analyser (pixel central), les composantes C_1 des pixels appartenant à son voisinage 3×3 sont comparées à la valeur $C_1(P) = 5$ du pixel P analysé. Pour tout pixel du voisinage dont la composante C_1 est inférieure à $C_1(P)$, on attribue le label 0 et pour tout pixel du voisinage dont la composante C_1 est supérieure ou égale

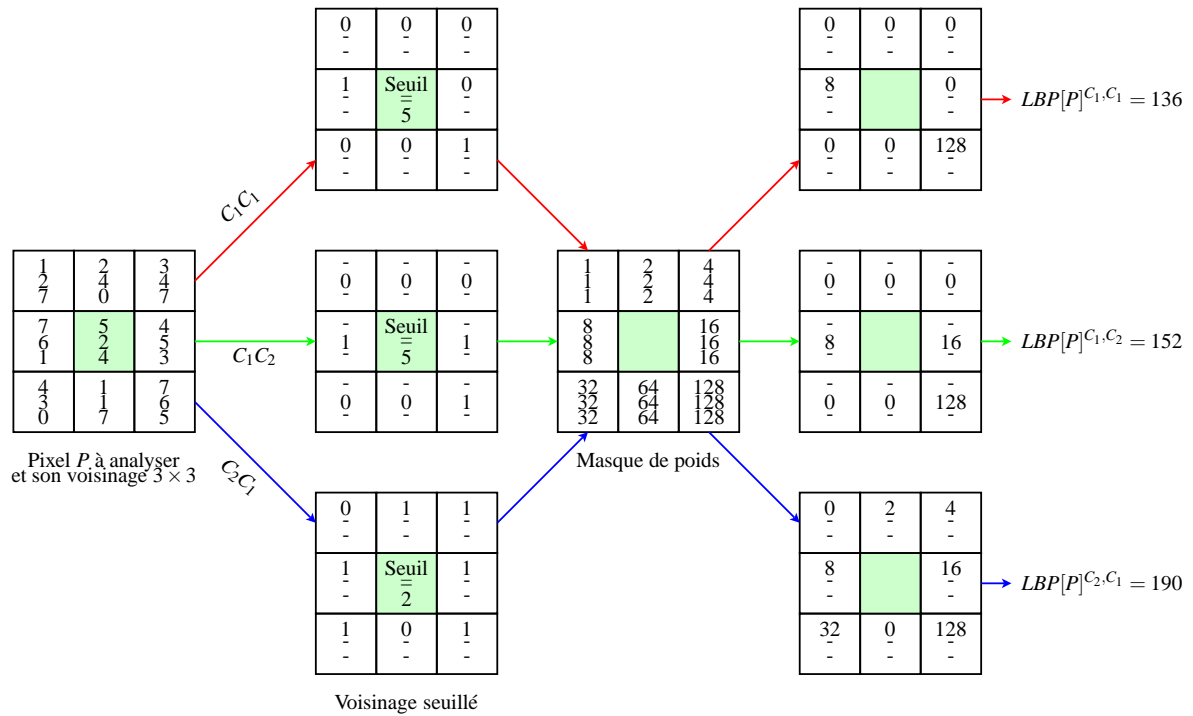


Figure 1.17 : Illustration du calcul de $LBP[P]^{C_1, C_1}$, $LBP[P]^{C_1, C_2}$ et $LBP[P]^{C_2, C_1}$ pour un pixel couleur P codé dans l'espace (C_1, C_2, C_3) avec $N = 8$.

à $C_1(P)$, le label 1 est attribué. Un masque de poids, permettant de coder le voisinage par les biais de pondérations plus ou moins importantes, est ensuite appliqué aux labels obtenus et les valeurs résultantes sont enfin sommées pour obtenir la valeur de $LBP[P]^{C_1, C_1}$ du pixel analysé (ici, $LBP[P]^{C_1, C_1} = 8 + 128 = 136$).

Pour le calcul de $LBP[P]^{C_1, C_2}$, ce sont cette fois-ci les composantes C_2 des pixels appartenant au voisinage 3×3 du pixel central qui sont comparées à la composante $C_1(P) = 5$.

Enfin pour le calcul de $LBP[P]^{C_2, C_1}$, le seuil de comparaison correspond à la composante $C_2(P) = 2$ du pixel P analysé et ce sont les composantes C_1 des pixels appartenant au voisinage 3×3 qui sont seuillées.

Pour caractériser chaque pixel P d'une image couleur \mathbf{I} , 9 LBP sont donc nécessaires :

– 3 LBP caractérisant les relations intra-composantes :

$$LBP[P]^{C_1, C_1}, LBP[P]^{C_2, C_2}, LBP[P]^{C_3, C_3},$$

– 6 LBP caractérisant les relations inter-composantes :

$$LBP[P]^{C_1, C_2}, LBP[P]^{C_2, C_1}, LBP[P]^{C_1, C_3}, LBP[P]^{C_3, C_1}, LBP[P]^{C_2, C_3} \text{ et } LBP[P]^{C_3, C_2}.$$

Enfin, pour caractériser la texture complète à analyser, les LBP de chaque pixel de l'image \mathbf{I} sont calculés et les distributions correspondant aux 9 LBP sont présentées dans 9 histogrammes différents. Ces derniers sont ensuite concaténés en un unique histogramme noté $LBP[\mathbf{I}]$ de taille $9 \times N$, où N est le niveau de quantification considéré [PMV02]. Pour la classification des tex-




Figure 1.18 : Exemples de voisinages utilisés pour le calcul des LBP.

tures couleur, Mäenpää suggère la méthode du maximum de vraisemblance pour comparer ces histogrammes [MP04].

Les LBP peuvent être étudiés en considérant un voisinage autre que le voisinage 3×3 pour caractériser les interactions spatiales entre le pixel P et ses voisins [PMV02, MP04]. Deux paramètres sont alors introduits :

- V , le nombre de voisins du pixel à analyser,
- R , le rayon du cercle sur lequel ces voisins se situent.

La figure 1.18 illustre deux voisinages, avec différentes valeurs de V et R .

Le masque de poids utilisé pour calculer les LBP est alors lui aussi circulaire et les poids prennent des valeurs comprises entre 2^0 et 2^{V-1} .

Une autre extension des LBP permet quant à elle de considérer des attributs invariants à la rotation. Pour calculer ces attributs, V rotations du masque de poids sont effectuées et les V $LBP[P]^{C_k, C_{k'}}$ correspondants sont calculés ($C_k, C_{k'} \in (C_1, C_2, C_3)$). Parmi ces V attributs, celui qui caractérisera au final les interactions spatiales entre les composantes couleur C_k et $C_{k'}$ sera le $LBP[P]^{C_k, C_{k'}}$ qui a la valeur minimale.

Enfin, Jiji propose récemment une approche floue des LBP qu'il utilise pour mesurer la pertinence de différents espaces couleur [JG07]. Il en conclut que parmi les espaces (R, G, B) , (H, S, V) et (H, S, I) , l'espace (R, G, B) est le mieux adapté pour l'analyse de textures couleur.

Les motifs locaux binaires font partie, tout comme les modèles autorégressifs et les modèles de Markov multispectraux, des principaux descripteurs de texture basés sur la modélisation spatiale utilisés dans le cadre de la classification d'images couleur. D'autres descripteurs sont utilisés pour caractériser les textures couleur. On retrouve entre autre les attributs spatio-fréquentiels, présentés dans le paragraphe suivant.

1.8 Attributs spatio-fréquentiels

L'ensemble des attributs spatio-fréquentiels peut être décomposé en trois catégories :

– **Domaine spatial :**

Les attributs privilégiant le domaine spatial caractérisent la texture par le nombre de transitions par unité de surface [TJ98]. Les textures fines tendent en effet à avoir une forte densité de transitions par unité de surface, contrairement aux textures plus grossières. Les transitions couleur peuvent par exemple être détectées par la méthode de Di Zenzo [Zen86].

Cependant, ce type d'attributs, utilisé dans les problématiques de segmentation d'images par exemple, n'a à notre connaissance encore jamais été appliqué à la classification d'images de texture couleur.

– **Domaine fréquentiel :**

La transformée de Fourier et la transformée en cosinus discrète fournissent quant à elles une représentation de la texture exclusivement dans le domaine des fréquences. Pour caractériser les textures couleur, une **batterie de filtres** est utilisée (une batterie de filtres est un ensemble de filtres, chacun étant sensible à une fréquence particulière). Pour déterminer les attributs de texture qui caractérisent les relations intra-composantes, tous les filtres sont appliqués séparément sur les images-composantes² de l'image couleur analysée. Un ou plusieurs attributs statistiques (comme l'énergie, la variance, ...) sont ensuite calculés à partir des images filtrées. En ce qui concerne le calcul des attributs qui caractérisent les relations entre deux composantes couleur différentes, il faut considérer la différence des images-composantes filtrées, prises deux à deux, puis extraire un ou plusieurs attributs statistiques de l'image résultante [MP04]. On obtient alors un ensemble d'attributs pour chaque filtre [DW01].

La transformée de Fourier et la transformée en cosinus discrète sont particulièrement bien adaptés au cas des images contenant des textures grossières, qui présentent de grandes continuités entre les valeurs de chaque composante couleur des pixels. En effet, les hautes fréquences étant réservées à des changements locaux des composantes couleur des pixels, on parvient dans ce cas à représenter l'intégralité de l'information présente dans l'image sur très peu de coefficients, correspondant aux basses fréquences. Drimbarean utilise la transformée en cosinus discrète en niveaux de gris et son extension à la couleur pour caractériser les textures de la base d'images VisTex [DW01]. Il compare ainsi les résultats de classification obtenus en considérant d'une part des attributs de texture définis en niveaux de gris et d'autre part leur extension à la couleur. Dans ses travaux, il effectue également la comparaison de différents attributs de texture (attributs extraits de la transformation de Gabor couleur (cf. § 1.8.1), attributs d'Haralick extraits des matrices de co-occurrences chromatiques (cf. § 1.9.2.2) et attributs extraits de la

2. Les pixels d'une image-composante ne sont caractérisés que par une unique composante couleur.

transformée en cosinus discrète couleur). Il en conclut que l'analyse des attributs extraits de la transformée en cosinus discrète permet d'obtenir les meilleurs taux de classification d'images de texture couleur, que ce soit avec une caractérisation en niveaux de gris ou avec des attributs de texture couleur. D'autre part, il constate que ce descripteur est le moins coûteux en temps de calcul.

– **Domaine spatio-fréquentiel :**

Enfin, il existe d'autres attributs très intéressants de part le fait qu'ils associent les deux représentations présentées ci-dessus : les attributs spatio-fréquentiels. Parmi les attributs les plus utilisés en classification de textures couleur, on retrouve entre autre les attributs extraits de :

- la transformation de Gabor,
- la transformée en ondelettes.

Ces attributs sont présentés dans les paragraphes suivants.

1.8.1 Transformation de Gabor

La transformation de Fourier d'une image va permettre de mettre en évidence les régularités de la texture en examinant le domaine fréquentiel. Le problème posé par cette opération, qui agit globalement sur l'image, est qu'elle ne tient pas compte de la localisation spatiale.

Une solution est d'utiliser une transformation alternative appelée transformation de Fourier à fenêtre glissante, où le principe est d'appliquer la transformation de Fourier dans une fenêtre d'observation qui se déplace dans l'image. Le choix de la taille de la fenêtre et du pas de déplacement dépend des caractéristiques spatiales des textures à analyser.

Il existe différentes fenêtres d'observation : la fenêtre triangulaire, la fenêtre de Hamming, la fenêtre Hanning et la fenêtre de Gauss [Cou98]. Lorsque cette dernière est appliquée, on parle de transformation de Gabor.

Pour caractériser la texture couleur, les filtres sont appliqués à chacune des fenêtres balayant les images-composantes de l'image couleur à classer. Les coefficients de Gabor, dont l'expression est disponible dans la publication de Palm [PL02], sont ensuite calculés pour chaque fenêtre et chaque filtre. Pour un filtre donné, l'attribut caractérisant la totalité de l'image est alors obtenu en calculant l'énergie, l'entropie ou la variance des coefficients obtenus pour chaque fenêtre [PL02].

Tout comme Drimbarean, Palm s'est penché sur l'association des filtres de Gabor à la couleur. Il montre également que la considération d'attributs de texture couleur permet d'améliorer les résultats de classification des images de la base VisTex par rapport à l'utilisation d'attributs définis en niveaux de gris [PL02, PKLS00].

Les attributs extraits de la transformation de Gabor font partie des attributs les plus utilisés

dans le domaine de la classification d'images de texture couleur car ils sont performants pour décrire les textures que celles-ci soient observées à un niveau macroscopique ou microscopique. D'autre part, des études physiologiques montrent qu'il est possible d'assimiler le fonctionnement de certains neurones du cortex visuel à ce type de filtres [San05].

L'inconvénient principal de cette méthode est le réglage des paramètres des filtres. De plus, pour caractériser certaines textures, il est nécessaire d'avoir une fenêtre d'analyse assez grande, ce qui peut impliquer un temps de calcul assez élevé.

1.8.2 Transformée en ondelettes

La représentation de Gabor se base sur une fenêtre d'observation de longueur fixe, ce qui peut être un handicap car certaines textures peuvent être caractérisées selon différentes échelles. Pour pallier cette limite, la transformée en ondelettes se base sur une analyse multi-échelles de l'image, dans le sens où des fenêtres d'analyse de différentes tailles sont utilisées [CRFM01].

De nombreux attributs statistiques ou de co-occurrences (Wavelet Statistical Features et Wavelet Co-occurrence Features (WSF et WCF)) peuvent être extraits des transformées en ondelettes couleur d'une image [AGA05, dWSLD99, KIM⁺03]. Arivazhagan utilise ces attributs pour classer les textures couleur de la base VisTex [AGA05].

Les énergies calculées pour les différents filtres sont également utilisés pour caractériser les textures. Sengur utilise ces énergies pour classer les textures de la base VisTex et met ainsi en évidence que l'apport de la couleur améliore la classification des images de texture couleur [Sen08].

D'autres auteurs, comme Van de Wouwer, Xu et Hiremath ont également travaillé sur la classification de textures couleur par le biais de la transformée en ondelettes [dWSLD99, XYD05, HSP06]. L'avantage de cette transformée est qu'elle permet une caractérisation multi-échelles de la texture en considérant à la fois les informations globales et locales contenues dans l'image. De plus, comme pour les autres attributs spatio-fréquentiels décrits précédemment, les attributs extraits des ondelettes se rapprochent du processus de la vision humaine qui opère une décomposition fréquentielle systématique des images lorsque celles-ci parviennent sur la rétine [RM05].

Cependant, les conclusions quant à la pertinence des attributs extraits des ondelettes diffèrent selon les auteurs. Les travaux de Iakovidis suggèrent que ces attributs ne sont pas toujours les plus adéquats pour caractériser les textures [IMK05]. Il montre pour cela que les LBP couleur permettent d'obtenir de meilleurs résultats de classification pour les bases VisTex et OuTex, que ceux obtenus par l'analyse d'attributs issus de la transformée en ondelettes. Au contraire, Van de Wouwer montre à plusieurs reprises l'intérêt de ces attributs pour la classification d'images de texture couleur, lorsque ceux-ci sont judicieusement exploités

[dWLS97, dWLS99].

Il existe une autre grande famille d'attributs permettant de caractériser les différentes classes d'images de texture couleur : il s'agit de la famille des attributs statistiques.

1.9 Attributs statistiques

Comme les attributs spatio-fréquentiels, les attributs statistiques permettent de caractériser tout type de textures, même les textures fines et sans régularité apparente. Pour ce type d'attributs, la texture est définie en termes de variation de couleur et ce sont également les relations entre les pixels et leur voisins qui sont étudiées.

De nombreux descripteurs statistiques sont utilisés dans le cadre de la classification de textures couleur. On retrouve entre autre :

- les statistiques d'image,
- les histogrammes d'image,
- les matrices de co-occurrences chromatiques,
- les histogrammes des sommes et des différences,
- les matrices de longueurs de plages.

Ces descripteurs peuvent être divisés en plusieurs catégories selon leur **ordre**, l'ordre du descripteur dépendant du type d'interaction spatiale entre les pixels considérés. Pour les histogrammes d'image, on ne s'intéresse qu'au pixel lui-même, ce descripteur appartient donc à la catégorie des descripteurs statistiques du premier ordre. Les matrices de co-occurrences sont quant-à-elles des descripteurs d'ordre 2, car leur calcul considère des couples de pixels.

1.9.1 Attributs statistiques du premier ordre

1.9.1.1 Statistiques d'image

De nombreuses statistiques peuvent directement être extraites d'une image afin de caractériser la texture couleur qu'elle contient [CP95]. Les statistiques les plus courantes sont [Van00] :

- la **moyenne** des composantes couleur,
- la **variance** ou l'écart-type, qui constitue une estimation du degré de dispersion des composantes couleur autour de leur moyenne,
- la **dissymétrie**³, qui mesure le degré d'assymétrie des valeurs des composantes couleur par rapport à leur moyenne,
- l'**aplatissement**⁴, qui estime le degré de concavité ou convexité des composantes couleur par rapport à leur moyenne.

3. *skewness* en anglais.

4. *kurtosis* en anglais.

Cependant, ces statistiques n'exploitent que l'information de couleur des pixels et négligent les relations spatiales entre ces derniers. La caractérisation des textures couleur à partir de ces attributs est donc peu performante.

1.9.1.2 Histogrammes d'image

Les histogrammes font également partie des descripteurs statistiques du premier ordre. Ils décrivent la distribution des niveaux des composantes couleur de l'image à analyser. Cette description peut être effectuée de différentes façons :

- L'histogramme peut être implanté selon une structure tridimensionnelle (3D) composée de cellules caractérisant chaque couleur. Si les composantes couleur sont codées sur 8 bits, l'histogramme de l'image contiendra alors 256^3 cellules. Chacune de ces cellules contient en fait le nombre de pixels de l'image caractérisés par la couleur considérée.
- Une autre description consiste quant à elle à considérer indépendamment les trois composantes couleur par le biais des histogrammes mono-dimensionnels (1D) des images-composantes [Bus06].

Ces deux descripteurs ont tous deux été utilisés par Mäenpää et Pietikäinen pour classer les textures des bases VisTex et OuTex à l'aide de la méthode d'intersection d'histogrammes [MP04, PMV02].

Cependant, ces histogrammes sont rarement exploités directement pour la classification des textures couleur. Des attributs sont souvent extraits de ces histogrammes pour discriminer les différentes classes [Van00], comme :

- la **médiane**, qui partitionne l'histogramme en deux parties d'égales populations,
- le **mode**, qui correspond au maximum de l'histogramme,
- l'**intervalle inter-quartile**, qui est une caractéristique de dispersion autour de la médiane.

Une autre façon d'exploiter les histogrammes d'images a été proposée par Paschos en 2003 pour classer les images de la base VisTex [PP03]. Il s'agit des ratios d'histogrammes. Le calcul de ces attributs consiste tout d'abord à concaténer les histogrammes des images-composantes. Les cellules de l'histogramme résultant sont alors combinées deux à deux et les ratios correspondant sont calculés.

Tout comme pour les statistiques d'image, l'inconvénient majeur des histogrammes est qu'ils n'exploitent que l'information de couleur et négligent les relations spatiales entre les pixels. Il est donc nécessaire de considérer des attributs statistiques d'ordre supérieur pour une analyse de texture plus efficace.

1.9.2 Attributs statistiques du second ordre

1.9.2.1 Matrices de co-occurrences chromatiques

Les matrices de co-occurrences, introduites par Haralick en 1973, ont tout d'abord été implémentées en niveaux de gris [HSD73]. L'exploitation de la couleur permettant d'améliorer les résultats en termes de classification de textures, Palm propose d'étendre le concept de matrices de co-occurrences aux images couleur en définissant les matrices de co-occurrences chromatiques [Pal04]. Cet outil statistique est intéressant de part le fait qu'il mesure la distribution des composantes couleur dans l'image, tout en prenant en compte les interactions spatiales entre les pixels.

Expliquons le calcul de ces matrices pour une image \mathbf{I} dont la couleur est codée dans un espace couleur (C_1, C_2, C_3) . Considérons :

- $C_k, C_{k'} \in (C_1, C_2, C_3)$, deux des trois composantes couleur,
- θ , la direction particulière selon laquelle les relations entre les pixels vont être analysées ($0^\circ, 45^\circ, 90^\circ$ et 135°). La figure 1.19 illustre les différentes directions considérées.
- ν , la distance spatiale de Manhattan (en nombre de pixels) séparant le pixel à analyser de ses voisins (cf. figure 1.20),
- et $M^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$, la matrice de co-occurrences chromatique qui mesure l'interaction spatiale entre les composantes C_k et $C_{k'}$ des pixels de l'image \mathbf{I} se trouvant à une distance spatiale ν l'un de l'autre, selon la direction θ .




Figure 1.19 : Les 4 directions considérées.

Le contenu de la cellule $M^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta, (i, j))$ de cette matrice indique le nombre de fois qu'un pixel P de l'image \mathbf{I} , dont le niveau de composante couleur $C_k(P)$ est égal à i possède, dans son voisinage suivant la direction θ , un pixel P' , se trouvant à une distance ν de P et dont le niveau de composante $C_{k'}(P')$ est égal à j . La figure 1.21 illustre le calcul de $M^{C_1, C_2}[\mathbf{I}](1, 0^\circ)$, $M^{C_1, C_2}[\mathbf{I}](1, 45^\circ)$, $M^{C_1, C_2}[\mathbf{I}](1, 90^\circ)$ et $M^{C_1, C_2}[\mathbf{I}](1, 135^\circ)$ pour une image \mathbf{I} dont la couleur des pixels est codée dans un espace (C_1, C_2, C_3) avec $N = 4$ niveaux de quantification (la couleur

des pixels est représentée par la cellule $\begin{pmatrix} C_1 \\ C_2 \\ C_3 \end{pmatrix}$).




Figure 1.20 : Illustration de la distance v .

Par exemple, pour déterminer le contenu de la cellule située sur la troisième ligne et la première colonne de la matrice $M^{C_1, C_2}[\mathbf{I}](1, 0^\circ)$ de la figure 1.21 (c'est-à-dire le contenu de la cellule $M^{C_1, C_2}[\mathbf{I}](1, 0^\circ, (0, 2))$), on examine le voisinage "horizontal" des pixels de l'image où $C_1 = 0$ (encadrés en rouge) et on compte le nombre de fois où l'on trouve, dans ce voisinage, des pixels se trouvant à une distance $v = 1$ et dont la composante couleur C_2 est égale à 2 (entourés en rouges). Le premier pixel où $C_1 = 0$ (en haut à gauche) possède un pixel voisin dont la composante C_2 est égale à 2, sur la droite, et le deuxième pixel où $C_1 = 0$ (en haut à droite) possède également un pixel voisin dont la composante C_2 est égale à 2, sur la gauche, ce qui représente 2 occurrences.

Pour déterminer le contenu de la cellule $M^{C_1, C_2}[\mathbf{I}](1, 45^\circ, (0, 2))$ de la figure 1.21, on examine le voisinage constitué des pixels présents sur la première diagonale et on compte le nombre de fois où l'on trouve, dans ce voisinage, des pixels se trouvant à une distance $v = 1$ et dont les composantes C_1 et C_2 sont respectivement égales à 0 et 2. Les deux pixels où $C_1 = 0$ n'ont aucun pixel voisin dont la composante C_2 est égale à 2. Le contenu de la cellule $M^{C_1, C_2}[\mathbf{I}](1, 45^\circ, (0, 2))$ est donc 0. Il en est de même pour la cellule $M^{C_1, C_2}[\mathbf{I}](1, 135^\circ, (0, 2))$.

Par contre, pour la cellule $M^{C_1, C_2}[\mathbf{I}](1, 90^\circ, (0, 2))$, un pixel dont la composante C_2 est égale à 2 est voisin "verticalement" et séparé d'une distance $v = 1$ du premier pixel dont la composante C_1 est nulle. Le contenu de la cellule $M^{C_1, C_2}[\mathbf{I}](1, 90^\circ, (0, 2))$ est donc égal à 1.

Les matrices $M^{C_2, C_1}[\mathbf{I}]$, $M^{C_3, C_1}[\mathbf{I}]$ et $M^{C_3, C_2}[\mathbf{I}]$ ne sont pas prises en compte car elles peuvent être déduites respectivement des matrices $M^{C_1, C_2}[\mathbf{I}]$, $M^{C_1, C_3}[\mathbf{I}]$ et $M^{C_2, C_3}[\mathbf{I}]$ par symétrie.

Ces matrices de co-occurrences sont insensibles aux translations des objets dans les images. Comme elles mesurent les interactions locales entre les pixels, elles dépendent de la taille de l'image et sont sensibles à la résolution spatiale. Pour les rendre indépendantes de la taille de l'image, il est nécessaire de normaliser ces matrices par le nombre total de co-occurrences dans

0 1 0	3 2 1	0 0 0
1 2 1	2 0 1	1 1 3
2 0 0	1 0 0	3 2 3

Image couleur représentée dans l'espace (C_1, C_2, C_3)

$C_2 \backslash C_1$	0	1	2	3
0	0	3	1	2
1	0	0	1	1
2	2	1	1	0
3	0	0	0	0

Matrice $M^{C_1, C_2}[\mathbf{I}](1, 0^\circ)$ associée

$C_2 \backslash C_1$	0	1	2	3
0	1	1	3	1
1	0	1	0	0
2	0	1	1	0
3	0	0	0	0

Matrice $M^{C_1, C_2}[\mathbf{I}](1, 45^\circ)$ associée

$C_2 \backslash C_1$	0	1	2	3
0	0	3	1	1
1	1	1	0	1
2	1	1	1	0
3	0	0	0	0

Matrice $M^{C_1, C_2}[\mathbf{I}](1, 90^\circ)$ associée

$C_2 \backslash C_1$	0	1	2	3
0	1	1	0	0
1	0	0	1	1
2	0	2	1	1
3	0	0	0	0

Matrice $M^{C_1, C_2}[\mathbf{I}](1, 135^\circ)$ associée**Figure 1.21** : Image couleur \mathbf{I} et ses matrices de co-occurrences associées ($N = 4$).

la matrice considérée $\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} M^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))$:

$$m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (a, b)) = \frac{M^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (a, b))}{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} M^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))} \quad \forall (a, b) \in [0, \dots, (N-1)] \quad (1.1)$$

où N est le niveau de quantification des composantes couleur.

Pour une distance v donnée, chaque image couleur \mathbf{I} est donc caractérisée par 24 matrices

de co-occurrences chromatiques normalisées :

$$\begin{array}{cccc}
- m^{C_1, C_1}[\mathbf{I}](v, 0^\circ) & - m^{C_1, C_1}[\mathbf{I}](v, 45^\circ) & - m^{C_1, C_1}[\mathbf{I}](v, 90^\circ) & - m^{C_1, C_1}[\mathbf{I}](v, 135^\circ) \\
- m^{C_2, C_2}[\mathbf{I}](v, 0^\circ) & - m^{C_2, C_2}[\mathbf{I}](v, 45^\circ) & - m^{C_2, C_2}[\mathbf{I}](v, 90^\circ) & - m^{C_2, C_2}[\mathbf{I}](v, 135^\circ) \\
- m^{C_3, C_3}[\mathbf{I}](v, 0^\circ) & - m^{C_3, C_3}[\mathbf{I}](v, 45^\circ) & - m^{C_3, C_3}[\mathbf{I}](v, 90^\circ) & - m^{C_3, C_3}[\mathbf{I}](v, 135^\circ) \\
- m^{C_1, C_2}[\mathbf{I}](v, 0^\circ) & - m^{C_1, C_2}[\mathbf{I}](v, 45^\circ) & - m^{C_1, C_2}[\mathbf{I}](v, 90^\circ) & - m^{C_1, C_2}[\mathbf{I}](v, 135^\circ) \\
- m^{C_1, C_3}[\mathbf{I}](v, 0^\circ) & - m^{C_1, C_3}[\mathbf{I}](v, 45^\circ) & - m^{C_1, C_3}[\mathbf{I}](v, 90^\circ) & - m^{C_1, C_3}[\mathbf{I}](v, 135^\circ) \\
- m^{C_2, C_3}[\mathbf{I}](v, 0^\circ) & - m^{C_2, C_3}[\mathbf{I}](v, 45^\circ) & - m^{C_2, C_3}[\mathbf{I}](v, 90^\circ) & - m^{C_2, C_3}[\mathbf{I}](v, 135^\circ).
\end{array}$$

Klein propose une extension des matrices de co-occurrences invariante aux changements d'éclairage, pour le suivi d'objets dans des séquences d'images [Kle08]. Il s'agit des matrices de co-occurrences pondérées. Cependant ces descripteurs de texture couleur s'appliquent uniquement lorsque les couleurs de l'image à traiter sont connues *a priori*.

De nombreux auteurs n'utilisent pas directement les matrices de co-occurrences chromatiques pour caractériser les textures couleur car elles sont très consommatrices en espace mémoire. Les utilisateurs préfèrent donc extraire de ces matrices des attributs afin de réduire la quantité d'informations à manipuler, tout en conservant la pertinence de ces descripteurs. Nous notons $f_i^{C_k, C_{k'}}(v, \theta)$, l'attribut d'indice i extrait de la matrice de co-occurrences chromatique normalisée $m^{C_k, C_{k'}}[\mathbf{I}](v, \theta)$.

1.9.2.2 Attributs d'Haralick extraits des matrices de co-occurrences

Haralick propose quatorze attributs de texture extraits des matrices de co-occurrences [HSD73] :

1. Second moment angulaire (ou énergie) :

$$f_1^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \{m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))\}^2 \quad (1.2)$$

2. Contraste :

$$f_2^{C_k, C_{k'}, v, \theta} = \sum_{n=0}^{N-1} n^2 \left\{ \sum_{i=0}^{N-1} \sum_{\substack{j=0 \\ |i-j|=n}}^{N-1} m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j)) \right\} \quad (1.3)$$

3. Corrélation :

$$f_3^{C_k, C_{k'}, v, \theta} = \frac{\sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - \mu_x)(j - \mu_y) m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))}{\sigma_x \sigma_y} \quad (1.4)$$

où μ_x , μ_y , σ_x et σ_y sont respectivement les centres de gravité et les écarts type de $m_x^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i))$ et $m_y^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (j))$, avec

$$m_x^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i)) = \sum_{j=0}^{N-1} m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))$$

et

$$m_y^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (j)) = \sum_{i=0}^{N-1} m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))$$

4. Variance (ou inertie) :

$$f_4^{C_k, C_{k'}, v, \theta} = \frac{1}{N^2} \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i - \mu)^2 m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j)) \quad (1.5)$$

où μ est le centre de gravité des coefficients de la matrice $m^{C_k, C_{k'}}[\mathbf{I}]$.

5. Moment différentiel inverse (ou homogénéité) :

$$f_5^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{1}{1 + (i - j)^2} m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j)) \quad (1.6)$$

6. Moyenne des sommes :

$$f_6^{C_k, C_{k'}, v, \theta} = \sum_{l=0}^{2(N-1)} l \cdot m_{x+y}^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (l)) \quad (1.7)$$

où

$$m_{x+y}^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (l)) = \sum_{i=0}^{N-1} \sum_{\substack{j=0 \\ i+j=l}}^{N-1} m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j)), \quad l = 0, 1, \dots, 2(N-1)$$

7. Variance des sommes :

$$f_7^{C_k, C_{k'}, v, \theta} = \sum_{l=0}^{2(N-1)} (l - f_6^{C_k, C_{k'}, v, \theta})^2 m_{x+y}^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (l)) \quad (1.8)$$

8. Entropie des sommes :

$$f_8^{C_k, C_{k'}, v, \theta} = - \sum_{l=0}^{2(N-1)} m_{x+y}^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (l))] \log \{m_{x+y}^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (l))]\} \quad (1.9)$$

9. Entropie :

$$f_9^{C_k, C_{k'}, v, \theta} = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (i, j))] \log \{m^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (i, j))]\} \quad (1.10)$$

10. Variance des différences :

$$f_{10}^{C_k, C_{k'}, v, \theta} = \sum_{l=0}^{N-1} (l - \mu_{x-y})^2 m_{x-y}^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (l))] \quad (1.11)$$

où

$$m_{x-y}^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (l))] = \sum_{i=0}^{N-1} \sum_{\substack{j=0 \\ |i-j|=l}}^{N-1} m^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (i, j))], \quad l = 0, 1, \dots, (N-1)$$

et

$$\mu_{x-y} = \sum_{l=0}^{N-1} l \cdot m_{x-y}^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (l))]$$

11. Entropie des différences :

$$f_{11}^{C_k, C_{k'}, v, \theta} = - \sum_{l=0}^{N-1} m_{x-y}^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (l))] \log \{m_{x-y}^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (l))]\} \quad (1.12)$$

12. Information sur la corrélation :

$$f_{12}^{C_k, C_{k'}, v, \theta} = \frac{f_9^{C_k, C_{k'}, v, \theta} - HXY1}{\max \{HX, HY\}} \quad (1.13)$$

où

$$HXY1 = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (i, j))] \log \{m_x^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (i))] \times m_y^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (j))]\}$$

$$HX = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m_x^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (i))] \log \{m_x^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (i))]\}$$

$$HY = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m_y^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (j))] \log \{m_y^{C_k, C_{k'}} [\mathbf{I}((v, \theta), (j))]\}$$

13. Information sur la corrélation :

$$f_{13}^{C_k, C_{k'}, v, \theta} = (1 - \exp[-2.0(HXY2 - f_9^{C_k, C_{k'}, v, \theta})])^{\frac{1}{2}} \quad (1.14)$$

où

$$HXY2 = - \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} m_x^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (i))] \times m_y^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \\ \log \{ m_x^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (i))] \times m_y^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \}$$

14. Coefficient de corrélation maximal :

$$f_{14}^{C_k, C_{k'}, v, \theta} = (\text{Plus grande valeur propre de } Q)^{\frac{1}{2}} \quad (1.15)$$

où

$$Q((v, \theta), (i, j)) = \sum_{l=0}^{N-1} \frac{m_x^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (i, l))] \times m_y^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j, l))]}{m_x^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (i))] \times m_y^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (l))]}$$

Notons qu'Haralick a proposé ces 14 attributs de texture sans vraiment donner de précision sur leur signification. Cependant, les attributs les plus utilisés dans la littérature, comme l'énergie, le contraste, la corrélation, la variance, l'homogénéité et l'entropie, ont fait l'objet d'analyses intuitives en ce qui concerne leur apport pour la caractérisation des textures :

- l'énergie mesure l'homogénéité globale de l'image [Sha01].
- le contraste mesure les variations locales des couleurs présentes dans l'image à analyser [SS01]. Une valeur faible de cet attribut caractérise une texture plutôt uniforme.
- la corrélation permet de mesurer les dépendances linéaires entre les niveaux des composantes couleur dans l'image [HSD73, Paq03].
- la variance mesure la répartition d'une composante couleur autour de la valeur moyenne. Plus cet attribut est élevé et plus importants sont les écarts entre les valeurs prises par la composante couleur et la moyenne.
- l'homogénéité traduit l'homogénéité locale au sein de la texture [Paq03].
- l'entropie donne une information quant au désordre que peut présenter la texture [Sha01].

Cependant, il est difficile d'interpréter ce que représentent les autres attributs, même de manière intuitive. Une étude complète serait nécessaire pour décrire ces attributs et mesurer la corrélation entre ces derniers, comme le précise Haralick [HSD73].

A la suite d'Haralick, plusieurs auteurs comme Anys ont proposé d'autres attributs de co-occurrences dont les plus exploités sont présentés ci-dessous [AH95]. Certains de ces attributs ont été utilisés par Van Den Broek pour la classification d'images de texture couleur [BR04].

- **Moment diagonal** : $f_{15}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \left(\frac{1}{2} |i-j| m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j)) \right)^{1/2}$
- **Moyenne** : $f_{16}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} i \times m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))$
- **Cluster shade** : $f_{17}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i+j-2f_{16}^{C_k, C_{k'}, v, \theta})^3 \times m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))$
- **Cluster prominence** : $f_{18}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i+j-2f_{16}^{C_k, C_{k'}, v, \theta})^4 \times m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))$
- **Différence inverse** : $f_{19}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \frac{m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))}{1+|i-j|}$
- **Dissimilarité** : $f_{20}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} |i-j| \times m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))$
- **Covariance** : $f_{21}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} (i-\mu_x)(j-\mu_y) \times m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j))$
- **Probabilité maximale** : $f_{22}^{C_k, C_{k'}, v, \theta} = \max_{0 \leq i, j \leq N-1} \{ m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j)) \}$
- **Troisième moment angulaire** : $f_{23}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} \left(m^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i, j)) \right)^3$

La plupart de ces attributs ont une signification semblable à celle des attributs d'Haralick. Cependant, certains d'entre eux sont intéressants de part le fait qu'ils permettent de caractériser des aspects différents de la texture. Les clusters shade et prominence vont par exemple mesurer, tout comme la variance, la distribution des niveaux de composantes couleur autour de la moyenne, mais avec une plus grande capacité de discrimination [ATR03].

Les matrices de co-occurrences dont sont extraits les attributs présentés ci-dessus dépendent des paramètres θ et v qui définissent le voisinage considéré lors du calcul de ces matrices. Le paragraphe suivant s'intéresse à ces paramètres et présente les principaux voisinages utilisés dans le cadre de la classification de textures couleur.

1.9.2.3 Paramètres liés à la définition des attributs d'Haralick

Afin de rendre la caractérisation invariante à la direction de la texture, Haralick propose de ne pas considérer directement les attributs $f_i^{C_k, C_{k'}, v, \theta}$ ($i = 1, 2, \dots, 14$) extraits des matrices de co-occurrences, mais d'utiliser la moyenne et la variance des attributs $f_i^{C_k, C_{k'}, v, \theta}$ selon les directions θ ($\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$) :

$$f_i^{C_k, C_{k'}, v, moy} = \frac{f_i^{C_k, C_{k'}, v, 0^\circ} + f_i^{C_k, C_{k'}, v, 45^\circ} + f_i^{C_k, C_{k'}, v, 90^\circ} + f_i^{C_k, C_{k'}, v, 135^\circ}}{4} \quad (1.16)$$

$$f_i^{C_k, C_{k'}, v, var} = \frac{1}{4} \left\{ (f_i^{C_k, C_{k'}, v, 0^\circ} - f_i^{C_k, C_{k'}, v, moy})^2 + (f_i^{C_k, C_{k'}, v, 45^\circ} - f_i^{C_k, C_{k'}, v, moy})^2 + (f_i^{C_k, C_{k'}, v, 90^\circ} - f_i^{C_k, C_{k'}, v, moy})^2 + (f_i^{C_k, C_{k'}, v, 135^\circ} - f_i^{C_k, C_{k'}, v, moy})^2 \right\} \quad (1.17)$$

Palm utilise ce type d'attributs, étendus à la couleur, pour caractériser les textures des bases de référence VisTex et BarkTex [Pal04].

Cependant, la majorité des auteurs utilisant les attributs d'Haralick ne respectent pas la définition initiale proposée par ce dernier. En effet, plutôt que de considérer la moyenne et la variance des attributs d'Haralick extraits de matrices de co-occurrences chromatiques caractérisant chaque direction θ (0° , 45° , 90° et 135°), de nombreux auteurs préfèrent considérer directement les attributs d'Haralick en les extrayant de matrices de co-occurrences chromatiques calculées avec un voisinage particulier. Les différentes formes de voisinages considérées sont les suivantes [BSP00, BR04, ADBB04, DW01, Rik04, AML08, PVM08b] :

- le "2-voisinage 0° ", qui caractérise les interactions spatiales entre les pixels selon la direction horizontale ($\theta = 0^\circ$),
- le "2-voisinage 45° ", qui caractérise les interactions spatiales entre les pixels selon la première diagonale ($\theta = 45^\circ$),
- le "2-voisinage 90° ", qui caractérise les interactions spatiales entre les pixels selon la direction verticale ($\theta = 90^\circ$),
- le "2-voisinage 135° ", qui caractérise les interactions spatiales entre les pixels selon la deuxième diagonale ($\theta = 135^\circ$),
- le "4-voisinage 1", qui caractérise les interactions spatiales entre les pixels selon les directions $\theta = 0^\circ$ et $\theta = 90^\circ$,
- le "4-voisinage 2", qui caractérise les interactions spatiales entre les pixels selon les directions $\theta = 45^\circ$ et $\theta = 135^\circ$,
- le "8-voisinage", qui caractérise les interactions spatiales entre les pixels selon toutes les directions ($\theta = 0^\circ$, $\theta = 45^\circ$, $\theta = 90^\circ$ et $\theta = 135^\circ$).

La figure 1.22 illustre ces différents voisinages, pour une distance de Manhattan $\nu = 1$.

Certains auteurs utilisent les attributs d'Haralick extraits de matrices de co-occurrences caractérisant uniquement les interactions spatiales selon la direction $\theta = 0^\circ$ [PBL06, PVM08b]. C'est une étude préliminaire qui a incité ce choix en fonction d'une orientation particulière dans les textures analysées.

Cependant la plupart des auteurs ayant travaillé sur la classification de textures couleur discriminent les différentes classes à l'aide des attributs d'Haralick extraits des matrices de co-occurrences chromatiques calculées avec un "8-voisinage" et une distance de Manhattan ν fixée à 1 [BSP00, BR04, ADBB04, DW01, Rik04, AML08]. Ces matrices sont appelées **matrices de co-occurrences isotropiques** [AML08].

Les attributs d'Haralick sont utilisés par Pydipati afin de détecter les citronniers malades grâce à la classification des feuillages selon leur couleur et leur texture [PBL06]. Il extrait ces attributs à partir de matrices de co-occurrences chromatiques ne tenant uniquement compte des relations intra-composantes et calculées avec le "2-voisinage 0° " et une distance ν fixée à 1.

Drimbarean, Van Den Broek et Van Rikxoort utilisent également les attributs d'Haralick extraits des matrices de co-occurrences intra-composantes pour caractériser les textures couleur

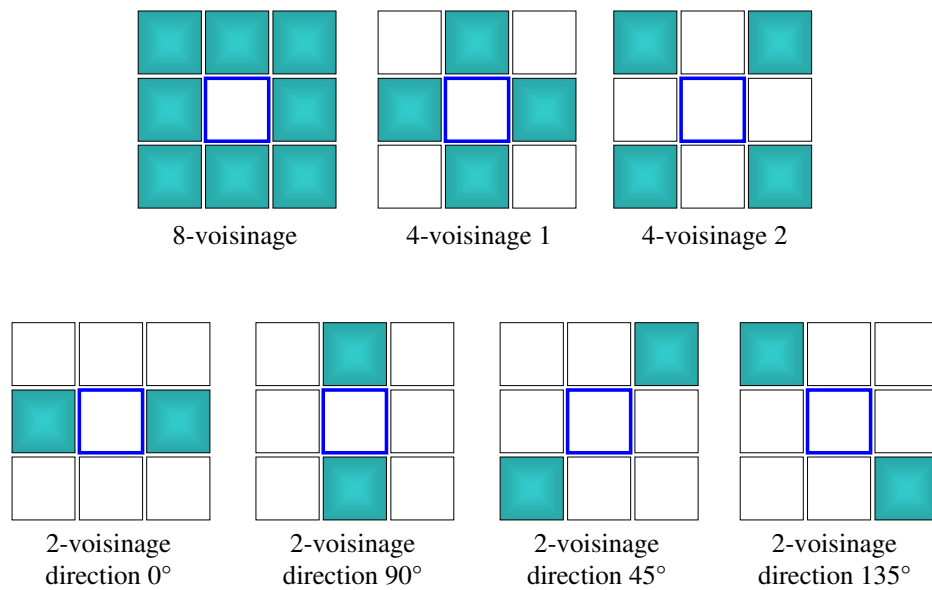


Figure 1.22 : Illustration pour une distance $\nu = 1$ des différents voisinages considérés lors du calcul des matrices de co-occurrences.

de la base Vistex, en considérant la forme "isotropique" de ces matrices [DW01, BR04, Rik04].

Palm et Tessier proposent quant à eux d'utiliser les attributs d'Haralick extraits de matrices de co-occurrences chromatiques qui tiennent compte à la fois des relations intra et inter-composantes [Pal04, Tes04]. En comparant leur résultats avec ceux obtenus en considérant des attributs extraits des matrices de co-occurrences définies avec la luminance, ils montrent que l'apport de la couleur permet d'améliorer les résultats de classification. D'autre part, Palm, qui a comparé les résultats de classification des bases VisTex et BarkTex obtenus en considérant différentes valeurs de ν ($\nu = 1, 5, 10, 15, 20$), montre que le choix de la distance dépend de la base d'images utilisée [Pal04].

Arvis compare quant à lui les résultats de classification obtenus par :

- des attributs d'Haralick extraits de matrices de co-occurrences chromatiques qui ne tiennent uniquement compte que des relations intra-composantes,
- des attributs d'Haralick extraits de matrices de co-occurrences chromatiques qui ne tiennent exclusivement compte que des relations inter-composantes,
- des attributs d'Haralick extraits de matrices de co-occurrences chromatiques qui tiennent compte à la fois des relations intra et inter-composantes.

Il effectue cette comparaison à partir des résultats de classification obtenus avec les images de texture couleur des bases VisTex et OuTex, et montre que les attributs qui tiennent compte à la fois des relations intra et inter-composantes donnent les meilleurs résultats de classification [ADBB04]. D'autre part, il montre que ces attributs peuvent être appliqués aux problèmes de classification en temps réel, à condition d'avoir effectué une sous-quantification préalable de la couleur de l'image analysée (cf. paragraphe 3.2.3.2).

D'autres descripteurs statistiques permettent de caractériser les textures couleur. C'est le cas notamment des histogrammes des sommes et des différences qui s'apparentent aux matrices de co-occurrences chromatiques dans le sens où ils se basent également sur l'analyse des composantes couleur des paires de pixels, selon une direction et une distance spécifiques.

1.9.2.4 Histogrammes des sommes et des différences

Les histogrammes des sommes et des différences ont initialement été proposés par Unser pour décrire les textures présentes dans des images en niveaux de gris [Uns86]. Münzenmayer a ensuite étendu ces descripteurs statistiques à la couleur en définissant les histogrammes des sommes et des différences intra et inter-composantes [MVK⁺02].

Utilisés conjointement, ces histogrammes possèdent une capacité de discrimination presque identique à la matrice de co-occurrences chromatique, avec l'avantage de calculs beaucoup moins exigeants en espace mémoire [MVK⁺02, MALDTB05].

Pour expliquer le calcul de ces histogrammes pour une image \mathbf{I} codée dans un espace couleur (C_1, C_2, C_3) , considérons :

- $C_k, C_{k'} \in (C_1, C_2, C_3)$, deux des trois composantes quantifiées sur N niveaux,
- θ , la direction particulière selon laquelle les relations entre les pixels vont être analysées ($0^\circ, 45^\circ, 90^\circ$ et 135°),
- ν , la distance de Manhattan séparant le pixel analysé de ses voisins (en nombre de pixels),
- $H_S^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$, l'histogramme des sommes qui mesure l'interaction spatiale entre les composantes C_k et $C_{k'}$ des pixels de l'image \mathbf{I} se trouvant à la distance ν l'un de l'autre, selon la direction θ ,
- et $H_D^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta)$, l'histogramme des différences qui mesure également l'interaction spatiale entre les composantes C_k et $C_{k'}$ des pixels de l'image \mathbf{I} se trouvant à la distance ν l'un de l'autre, selon la direction θ .

Le contenu de la cellule $H_S^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta, (i))$ indique le nombre de fois où la somme des niveaux des composantes couleur $C_k(P)$ et $C_{k'}(P')$ de deux pixels P et P' de l'image \mathbf{I} , se trouvant à une distance ν l'un de l'autre selon la direction θ , est égale à i ($i \in [0, 2 \times (N - 1)]$).

De même, le contenu de la cellule $H_D^{C_k, C_{k'}}[\mathbf{I}](\nu, \theta, (j))$ indique le nombre de fois où la différence des niveaux des composantes couleur $C_k(P)$ et $C_{k'}(P')$ de deux pixels P et P' de l'image \mathbf{I} , se trouvant à une distance ν l'un de l'autre selon la direction θ , est égale à j ($j \in [-(N - 1), N - 1]$).

La figure 1.23 (où la couleur de chaque pixel de l'image est représentée par la cellule


C_1
C_2
C_3

 et où les composantes couleur sont codées avec $N = 4$ niveaux de quantification) illustre le calcul de ces histogrammes.


Par exemple, pour déterminer le contenu de la cellule $H_S^{C_1, C_2}[\mathbf{I}](1, 0^\circ, (3))$ de l'histogramme-

0	3	0
1	2	0
0	1	0
1	2	1
2	0	1
1	1	3
2	1	3
0	0	2
0	0	3


Image couleur représentée dans l'espace (C_1, C_2, C_3)




(a) $H_S^{C_1, C_2}[\mathbf{I}](1, 0^\circ)$




(b) $H_S^{C_1, C_2}[\mathbf{I}](1, 90^\circ)$




(c) $H_S^{C_1, C_2}[\mathbf{I}](1, 45^\circ)$




(d) $H_S^{C_1, C_2}[\mathbf{I}](1, 135^\circ)$




(e) $H_D^{C_1, C_2}[\mathbf{I}](1, 0^\circ)$



(f) $H_D^{C_1, C_2}[\mathbf{I}](1, 90^\circ)$



(g) $H_D^{C_1, C_2}[\mathbf{I}](1, 45^\circ)$



(h) $H_D^{C_1, C_2}[\mathbf{I}](1, 135^\circ)$

Figure 1.23 : Image couleur \mathbf{I} et les histogrammes des sommes et des différences associés ($N = 4$).

me des sommes $H_S^{C_1, C_2}[\mathbf{I}](1, 0^\circ)$ associé à l'image couleur \mathbf{I} de la figure 1.23, on compte le nombre de fois où la somme des niveaux des composantes couleur $C_1(P)$ et $C_2(P')$ de deux pixels P et P' de l'image \mathbf{I} , se trouvant à une distance $v = 1$ l'un de l'autre selon la direction 0° , est égale à 3. Dans cet exemple, le contenu de la cellule $H_S^{C_1, C_2}[\mathbf{I}]((1, 0^\circ)(3))$ est égal à 4 (cf. interactions spatiales entre les pixels entourés de bleu).

En ce qui concerne le contenu de la cellule $H_D^{C_1, C_2}[\mathbf{I}]((1, 45^\circ)(-1))$ de l'histogramme des différences $H_D^{C_1, C_2}[\mathbf{I}](1, 45^\circ)$ associé à l'image couleur \mathbf{I} de la figure 1.23, on compte le nombre de fois où la différence des niveaux des composantes couleur $C_1(P)$ et $C_2(P')$ de deux pixels P et P' de l'image \mathbf{I} , se trouvant à une distance $v = 1$ l'un de l'autre selon la direction 45° , est égale à -1 . Dans cet exemple, $H_D^{C_1, C_2}[\mathbf{I}]((1, 45^\circ)(-1)) = 1$ (cf. interactions spatiales entre les pixels entourés de rouge).

Les histogrammes $H_S^{C_2, C_1}[\mathbf{I}](v, \theta)$, $H_S^{C_3, C_1}[\mathbf{I}](v, \theta)$ et $H_S^{C_3, C_2}[\mathbf{I}](v, \theta)$ ne sont pas pris en compte car ils n'apportent pas plus d'informations par rapport à la prise en compte des seuls histogrammes $H_S^{C_1, C_2}[\mathbf{I}](v, \theta)$, $H_S^{C_1, C_3}[\mathbf{I}](v, \theta)$ et $H_S^{C_2, C_3}[\mathbf{I}](v, \theta)$, grâce à la propriété d'associativité des opérations d'addition et de soustraction. Il en est de même pour les histogrammes des différences $H_D^{C_2, C_1}[\mathbf{I}](v, \theta)$, $H_D^{C_3, C_1}[\mathbf{I}](v, \theta)$ et $H_D^{C_3, C_2}[\mathbf{I}](v, \theta)$.

Afin d'être invariants à la taille de l'image, les histogrammes des sommes et des différences sont normalisés :

$$\text{pour } i \in [0, 2 \times (N - 1)], \quad h_S^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i)) = \frac{H_S^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i))}{N_P}, \quad (1.18)$$

$$\text{pour } j \in [-(N - 1), N - 1], \quad h_D^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (j)) = \frac{H_D^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (j))}{N_P}. \quad (1.19)$$

où N_P est le nombre de pixels de l'image. Ces histogrammes normalisés des sommes et des différences sont préférentiellement utilisés car ils peuvent être interprétés comme étant des densités de probabilité. On dispose alors d'une caractérisation probabiliste de l'organisation spatiale des pixels de l'image, basée sur une analyse de voisinage.

Une image de texture couleur sera donc caractérisée par une collection d'histogrammes des sommes et des différences intra et inter-composantes estimés pour différentes distances v et différentes directions θ . Il est intéressant de noter que pour les histogrammes intra-composantes, la distance $v = 0$ amène à considérer un histogramme d'image classique, tandis que pour les histogrammes inter-composantes, la distance $v = 0$ permet d'exprimer la corrélation entre les différentes composantes couleur au sein des pixels eux-mêmes [MVK⁺02].

Cependant, cette collection d'histogrammes n'est pas exploitée directement pour classer les images de texture couleur. Les utilisateurs préfèrent en effet extraire de ces histogrammes des

attributs de texture, afin de réduire le nombre d'informations. Nous notons $g_i^{C_k, C_{k'}}(v, \theta)$, l'attribut d'indice i extrait des histogrammes des sommes et des différences normalisées $h_S^{C_k, C_{k'}}[\mathbf{I}](v, \theta)$ et $h_D^{C_k, C_{k'}}[\mathbf{I}](v, \theta)$.

1.9.2.5 Attributs extraits des histogrammes des sommes et des différences

Unser propose seize attributs de texture extraits des histogrammes des sommes et des différences pour décrire les textures présentes dans des images en niveaux de gris [Uns86]. Les dix premiers attributs ont été choisis par l'auteur car ce sont les attributs les plus couramment utilisés pour décrire de manière globale les histogrammes, tandis que les six autres attributs ont été proposés dans le but de faire une analogie avec les indices d'Haralick extraits des matrices de co-occurrences.

L'ensemble de ces attributs a ensuite été étendu à la couleur, puis a été appliqué par Münzenmayer dans le cadre de la classification d'images de texture couleur [MVK⁺02]. Ces attributs sont les suivants :

1. Centre de gravité-somme :

$$g_1^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{2(N-1)} i \times h_S^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i)) = \mu_S \quad (1.20)$$

2. Variance-somme :

$$g_2^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{2(N-1)} (i - \mu_S)^2 h_S^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i)) \quad (1.21)$$

3. Cluster shade-somme :

$$g_3^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{2(N-1)} (i - \mu_S)^3 h_S^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i)) \quad (1.22)$$

4. Cluster prominence-somme :

$$g_4^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{2(N-1)} (i - \mu_S)^4 h_S^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i)) \quad (1.23)$$

5. Entropie-somme :

$$g_5^{C_k, C_{k'}, v, \theta} = - \sum_{i=0}^{2(N-1)} h_S^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i)) \log \{h_S^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (i))\} \quad (1.24)$$

6. Centre de gravité-différence :

$$g_6^{C_k, C_{k'}, v, \theta} = \sum_{j=-(N-1)}^{N-1} j \times h_D^{C_k, C_{k'}}[\mathbf{I}]((v, \theta), (j)) = \mu_D \quad (1.25)$$

7. Variance-différence :

$$g_7^{C_k, C_{k'}, v, \theta} = \sum_{j=-(N-1)}^{N-1} (j - \mu_D)^2 h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \quad (1.26)$$

8. Cluster shade-différence :

$$g_8^{C_k, C_{k'}, v, \theta} = \sum_{j=-(N-1)}^{N-1} (j - \mu_D)^3 h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \quad (1.27)$$

9. Cluster prominence-différence :

$$g_9^{C_k, C_{k'}, v, \theta} = \sum_{j=-(N-1)}^{N-1} (j - \mu_D)^3 h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \quad (1.28)$$

10. Entropie-différence :

$$g_{10}^{C_k, C_{k'}, v, \theta} = - \sum_{j=-(N-1)}^{N-1} h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \log \{h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))]\} \quad (1.29)$$

11. Second moment angulaire (ou énergie) :

$$g_{11}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{2(N-1)} \{h_S^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (i))]\}^2 \times \sum_{j=-(N-1)}^{N-1} \{h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))]\}^2 \quad (1.30)$$

12. Contraste :

$$g_{12}^{C_k, C_{k'}, v, \theta} = \sum_{j=-(N-1)}^{N-1} j^2 \times h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \quad (1.31)$$

13. Corrélation :

$$g_{13}^{C_k, C_{k'}, v, \theta} = \sum_{i=0}^{2(N-1)} (i - \mu_S)^2 h_S^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (i))] - j^2 \times h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \quad (1.32)$$

14. Variance :

$$g_{14}^{C_k, C_{k'}, v, \theta} = g_2^{C_k, C_{k'}, v, \theta} + g_{12}^{C_k, C_{k'}, v, \theta} \quad (1.33)$$

15. Moment différentiel inverse (ou homogénéité) :

$$g_{15}^{C_k, C_{k'}, v, \theta} = \sum_{j=-(N-1)}^{N-1} \frac{1}{1 + j^2} h_D^{C_k, C_{k'}}[\mathbf{I}((v, \theta), (j))] \quad (1.34)$$

16. Entropie :

$$g_{16}^{C_k, C_{k'}, v, \theta} = g_5^{C_k, C_{k'}, v, \theta} + g_{10}^{C_k, C_{k'}, v, \theta} \quad (1.35)$$

Martinez-Alajarin utilise une partie de ces attributs pour classer des textures de surfaces marbrées [MALDTB05]. Cependant, son analyse des textures couleur se restreint à l'utilisation des histogrammes intra-composantes.

Münzenmayer utilise quant à lui des attributs extraits des histogrammes intra et inter-composantes pour classer les images de texture couleur des bases de référence VisTex et Bark-Tex [MVK⁺02].

De plus, il a récemment proposé un nouvel ensemble d'attributs invariants aux changements d'éclairage [MWHW05]. Ces attributs, également extraits des histogrammes des sommes et des différences sont obtenus par une combinaison linéaire des attributs précédemment définis.

L'utilisation des attributs extraits des histogrammes des sommes et des différences permet d'obtenir une capacité de discrimination presque identique à celle des attributs extraits de la matrice de co-occurrences chromatique, avec l'avantage de nécessiter de calculs non seulement beaucoup moins exigeants en espace mémoire, mais également plus rapides, de part le fait qu'il y a moins de cellules à analyser [Uns86].

Des descripteurs statistiques d'ordre supérieur à deux, comme les matrices de longueurs de plages, permettent également de caractériser les textures.

1.9.3 Attributs statistiques d'ordre supérieur

1.9.3.1 Matrices de longueurs de plages

Alors que l'analyse de texture basée sur les matrices de co-occurrences chromatiques s'effectue en étudiant les niveaux des composantes couleur des pixels pris deux à deux, la méthode des matrices de longueurs de plages consiste à analyser les images en considérant des segments de pixels caractérisés par le même niveau de composante couleur, et ce, dans une direction donnée [ZSZ07]. Ainsi, une longueur de plage est une suite de pixels consécutifs et adjacents ayant tous le même niveau de composante.

Pour une image couleur \mathbf{I} codée dans un espace (C_1, C_2, C_3) et pour chaque composante $C_k \in (C_1, C_2, C_3)$, on peut calculer 4 matrices de longueurs de plages $\mathcal{P}^{C_k}[\mathbf{I}](0^\circ)$, $\mathcal{P}^{C_k}[\mathbf{I}](45^\circ)$, $\mathcal{P}^{C_k}[\mathbf{I}](90^\circ)$ et $\mathcal{P}^{C_k}[\mathbf{I}](135^\circ)$, chacune analysant les relations entre les pixels dans une direction donnée (0° , 45° , 90° et 135°). Ces matrices possèdent N lignes, où N représente le nombre de niveaux de quantification de la composante couleur C_k , et T colonnes, où T représente la taille maximale de l'image dans la direction choisie. Un élément de la matrice de longueurs de plages $\mathcal{P}^{C_k}[\mathbf{I}](\theta)$ s'écrit donc $\mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j))$, où i indique le niveau de la composante couleur C_k considérée, j la longueur de la plage et θ , la direction considérée. La cellule $\mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j))$ indique le nombre de fois où l'on a une suite de j pixels consécutifs et adjacents dans la direction θ et dont le niveau de composante C_k est égal à i .

La figure 1.24 (où la couleur de chaque pixel de l'image est représentée par la cellule C_1 , C_2 , C_3 et où les composantes couleur sont codées avec $N = 4$ niveaux de quantification) illustre ce propos.

0 0 0	0 1 3	0 3 3	1 1 2	2 3 3
1 3 3	1 3 3	1 3 3	1 3 3	1 3 3
3 3 3	0 3 3	0 0 3	2 0 3	2 3 3
1 3 3	1 0 2	1 0 2	2 2 2	2 2 2
2 3 3	3 3 0	1 3 0	1 3 0	2 3 0

Image couleur \mathbf{I} représentée dans l'espace (C_1, C_2, C_3)

	1	2	3	4	5
0	0	1	1	0	0
1	1	1	1	0	1
2	3	2	0	0	0
3	2	0	0	0	0

Matrice $\mathcal{P}^{C_1}[\mathbf{I}](0^\circ)$ associée

	1	2	3	4	5
0	5	0	0	0	0
1	9	1	0	0	0
2	5	1	0	0	0
3	2	0	0	0	0

Matrice $\mathcal{P}^{C_1}[\mathbf{I}](45^\circ)$ associée

Figure 1.24 : Image couleur \mathbf{I} et ses matrices de longueur de plages $\mathcal{P}^{C_1}[\mathbf{I}](0^\circ)$ et $\mathcal{P}^{C_1}[\mathbf{I}](45^\circ)$ associées ($N = 4$).

Par exemple, pour déterminer le contenu de la cellule située sur la troisième ligne et la deuxième colonne de la matrice $\mathcal{P}^{C_1}[\mathbf{I}](0^\circ)$ de la figure 1.24 (c'est-à-dire le contenu de la cellule $\mathcal{P}^{C_1}[\mathbf{I}](2, 2, 0^\circ)$ entourée en rouge), on examine les pixels de l'image où $C_1 = 2$ et on compte le nombre de fois où l'on a une suite de deux pixels consécutifs et adjacents dans la direction horizontale. Dans cet exemple, nous avons deux suites où deux et seulement deux pixels, qui ont leur composante $C_1 = 2$, sont contigus.

Pour déterminer le contenu de la cellule située sur la deuxième ligne et la deuxième colonne de la matrice $\mathcal{P}^{C_1}[\mathbf{I}](45^\circ)$ de la figure 1.24 (c'est-à-dire le contenu de la cellule $\mathcal{P}^{C_1}[\mathbf{I}](1, 2, 45^\circ)$ entourée en bleu), on examine les pixels de l'image où $C_1 = 1$ et on compte le nombre de fois où l'on a une suite de deux pixels consécutifs et adjacents dans la direction 45° . Ici, nous avons une suite où deux et seulement deux pixels, qui ont leur composante $C_1 = 1$, sont voisins selon la direction 45° .

Il est à noter qu'un niveau de composante couleur n'est compté qu'une seule fois dans la plage de plus grande longueur à laquelle il appartient.

Tout comme les matrices de co-occurrences, les matrices de longueurs de plages requièrent un coût important de stockage en mémoire. Afin de réduire le nombre d'informations, cinq attributs de texture extraits de ces matrices sont utilisés. Nous notons $h_i^{C_k}(\theta)$, l'attribut d'indice i extrait de la matrice de longueurs de plages $\mathcal{P}^{C_k}[\mathbf{I}](\theta)$.

1.9.3.2 Attributs de texture extraits des matrices de longueurs de plages

Galloway propose les cinq attributs suivants [Gal75] :

1. Accentuation des petites plages :

$$h_1^{C_k}(\theta) = \frac{\sum_{i=0}^{N-1} \sum_{j=1}^T \frac{\mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j))}{j^2}}{\sum_{i=0}^{N-1} \sum_{j=1}^T \mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j))} \quad (1.36)$$

Cet attribut caractérise la finesse de la texture. Plus $h_1^{C_k}(\theta)$ est grand, plus les zones ayant le même niveau de composante C_k sont petites.

2. Accentuation des grandes plages :

$$h_2^{C_k}(\theta) = \frac{\sum_{i=0}^{N-1} \sum_{j=1}^T j^2 \mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j))}{\sum_{i=0}^{N-1} \sum_{j=1}^T \mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j))} \quad (1.37)$$

Plus $h_2^{C_k}(\theta)$ est grand, plus il y a plus de zones étendues ayant le même niveau de composante C_k , et donc plus la texture est grossière.

3. Hétérogénéité des niveaux de composante couleur :

$$h_3^{C_k}(\theta) = \frac{\sum_{i=0}^{N-1} \left(\sum_{j=1}^T \mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j)) \right)^2}{\sum_{i=0}^{N-1} \sum_{j=1}^T \mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j))} \quad (1.38)$$

$h_3^{C_k}(\theta)$ mesure l'uniformité de la distribution des plages. Cet attribut est minimal lorsque les plages sont également distribuées entre les différents niveaux de la composante couleur C_k .

4. Hétérogénéité des longueurs de plages :

$$h_4^{C_k}(\theta) = \frac{\sum_{j=1}^T \left(\sum_{i=0}^{N-1} \mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j)) \right)^2}{\sum_{i=0}^{N-1} \sum_{j=1}^T \mathcal{P}^{C_k}[\mathbf{I}]((\theta), (i, j))} \quad (1.39)$$

Plus $h_4^{C_k}(\theta)$ est grand, plus le nombre de plages de même longueur est important.

5. Pourcentage de plages :

C'est le rapport entre le nombre total de plages et le nombre de pixels de l'image :

$$h_5^{C_k}(\theta) = \frac{\sum_{j=1}^T \sum_{i=0}^{N-1} \mathcal{P}^{C_k}[\mathbf{I}](\theta, (i, j))}{N_P} \quad (1.40)$$

Plus la texture est homogène et plus cet attribut a une valeur importante.

Les matrices de longueurs de plages ont récemment été utilisées par Zheng pour comparer les résultats de classification d'images de texture couleur obtenus d'une part, par des attributs statistiques et d'autre part, par des attributs géométriques [ZSZ07]. Étant donnée la régularité des motifs présents dans les textures de viande à analyser, les attributs géométriques se sont révélés être mieux adaptés que les matrices de longueurs de plages pour la caractérisation de ce type de textures.

Enfin, il est intéressant de noter que seules les relations intra-composantes sont prises en compte par les matrices de longueurs de plages.

1.10 Conclusion

Les principaux attributs de texture couleur utilisés dans le cadre de la classification d'images ont été présentés au cours de ce chapitre. D'autres attributs, moins courants, permettent également la caractérisation de la texture couleur, comme par exemple, la fonction d'autocorrélation couleur [Pas98], les moments chromatiques [Pas00], le modèle de covariance couleur [Lak02] ou encore les fractales [SH94]. Les quaternions, qui sont un outil de modélisation pour le codage des images couleur, offrent également une perspective intéressante pour caractériser les textures couleurs [VB00, DCFM07].

Les travaux dans lesquels des attributs de texture couleur ont été utilisés dans le cadre de la classification d'images sont recensés dans l'annexe C. De ces travaux, nous pouvons en conclure que les attributs privilégiant les interactions inter-composantes sont ceux qui permettent d'obtenir en général les meilleurs taux de classification.

L'influence de l'espace couleur retenu pour caractériser les couleurs sur la qualité de la discrimination des textures n'a pas été abordée dans ce chapitre. Cette problématique sera un des points approfondis au chapitre 3.

Le choix des attributs de texture couleur à considérer est un point délicat, car il dépend de différents facteurs :

- Tout d'abord, les textures à discriminer influence ce choix. Les attributs géométriques, par exemple, sont de part leur définition bien adaptés aux textures très régulières (cf. § 1.6). Au contraire, ils ne permettent pas de caractériser efficacement des textures irrég-

- gulières, comme celles présentes dans la majorité des images naturelles, dans la mesure où l'exploitation des primitives extraites deviendrait presque impossible.
- Le choix des attributs dépend également des contraintes liées à l'application :
 - Les contraintes liées au temps de classification en-ligne imposent de se tourner vers des descripteurs de texture couleur peu gourmands en temps de calcul, comme les LBP ou les attributs d'Haralick extraits des histogrammes des sommes et des différences ou des matrices de co-occurrences, lorsqu'une sous-quantification de la couleur de l'image analysée est effectuée [ADBB04].
 - Les conditions d'acquisition des images de texture influent également sur le choix des attributs. Par exemple, les travaux de Mäenpää montrent qu'il est préférable d'utiliser les motifs locaux binaires, pour classer les images de la base OuTex lorsque celles-ci sont acquises dans des conditions d'éclairage fixes. Par ailleurs, ils montrent que les attributs extraits de la transformée de Gabor sont mieux adaptés lorsque ces images sont acquises dans des conditions d'éclairage non contrôlées [MP04].
 - Certaines applications imposent de se tourner vers des descripteurs invariants aux transformations engendrées par la modification des conditions d'observation, telles que la rotation, la translation, l'homothétie ou encore le changement de résolution spatiale.

Les attributs sont donc à choisir avec soin car non seulement ils dépendent de l'application considérée comme nous venons de le voir, mais d'autre part, ils influent sur la qualité de la classification, et ce, de deux manières possibles :

- Tout d'abord, les attributs ne sont pas tous aussi informatifs les uns par rapport aux autres : ils peuvent correspondre à du bruit, être peu significatifs ou encore non pertinents pour la tâche à réaliser.
- D'autre part, le nombre d'attributs utilisés pour caractériser les textures influe également sur la qualité de la classification. En effet, un nombre trop faible d'attributs peut conduire à une caractérisation imparfaite des textures, et donc à des résultats de classification peu performants. De même, un nombre trop élevé peut détériorer la qualité de la discrimination entre les différentes classes. En effet, les attributs peuvent alors être corrélés, ce qui provoque des redondances d'information qui contribuent à détériorer la qualité de la discrimination.

Comme le choix *a priori* des attributs considérés se révèle être délicat pour discriminer les classes en présence, nous proposons de considérer un large ensemble d'attributs qui sera réduit automatiquement lors d'un apprentissage supervisé. Pour ce faire, il est nécessaire de constituer une base d'images d'apprentissage représentatives des différentes classes à discriminer. La réduction de l'ensemble d'attributs nécessite alors une sélection d'attributs ou une extraction d'attributs [Bla06].

Ces solutions permettent d'améliorer la qualité de la classification tout en réduisant les temps de calcul de la phase de classification en-ligne, ce qui est important pour le contrôle qualité de produits manufacturés. Nous allons donc nous intéresser dans le chapitre suivant à ces méthodes de réduction de l'ensemble d'attributs.

Chapitre 2

Réduction de l'ensemble d'attributs

2.1 Introduction

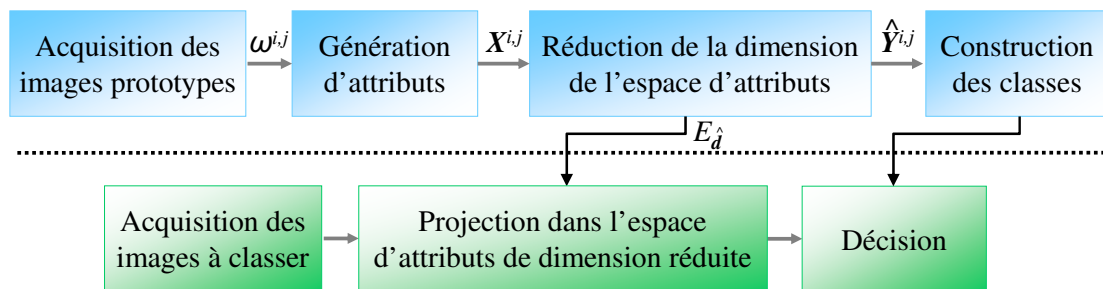
Dans le chapitre précédent, nous avons présenté les principaux attributs de texture couleur utilisés dans les problèmes de classification d'images pour caractériser et discriminer les différentes classes d'images. Le choix de ces attributs est délicat et atteindre une discrimination performante des classes en présence nous amène à considérer un ensemble important d'attributs qu'il est nécessaire de réduire lors d'un apprentissage supervisé.

Dans ce chapitre, nous présentons les méthodes permettant de réduire la dimension de l'ensemble d'attributs considéré pour discriminer les différentes classes en présence. Dans une première partie introductive, nous proposons au paragraphe 2.1.1 de situer cette étape de réduction dans le processus de classification supervisée de textures couleur. Ensuite, nous introduirons au paragraphe 2.1.2 la notion d'espace d'attributs afin d'illustrer les différents problèmes qui sont soulevés lorsqu'un ensemble d'attributs de dimension trop importante est considéré.

2.1.1 Classification supervisée de textures couleur

La classification supervisée de textures couleur est divisée en deux étapes, l'apprentissage hors-ligne et la classification en-ligne. L'apprentissage hors-ligne consiste à caractériser et discriminer les N_C classes en présence. Cet apprentissage aboutit à la définition de règles de décision qui permettront de déterminer la classe d'appartenance d'une image de texture couleur en fonction de ses caractéristiques, lors de la phase de classification en-ligne. La figure 2.1 reprend le schéma de la figure I.3 illustrant le principe de la classification supervisée.

Afin de caractériser les N_C classes d'images de texture couleur lors de la phase d'apprentissage, D attributs sont calculés à partir d'images prototypes lors de l'étape de génération d'attributs. Chaque classe C^j ($j = 1, \dots, N_C$) est représentée par N_ω^j prototypes. Le $i^{\text{ème}}$ prototype de la classe C^j est noté $\omega^{i,j}$ ($i = 1, \dots, N_\omega^j$ et $j = 1, \dots, N_C$).

Apprentissage (hors-ligne)Classification (en-ligne)**Figure 2.1** : La classification supervisée d'images.

A chaque image prototype $\omega^{i,j}$ est alors associé un vecteur d'attributs $\mathbf{X}^{i,j}$ de dimension D ($\mathbf{X}^{i,j} = [\mathbf{X}_1^{i,j}, \dots, \mathbf{X}_l^{i,j}, \dots, \mathbf{X}_D^{i,j}]^T$), caractérisant la texture couleur présente dans l'image.

Obtenir des résultats de classification satisfaisants nous amène généralement à décrire les textures de la manière la plus détaillée possible en utilisant un grand nombre d'attributs. Dans le cas de la classification d'images de texture couleur, l'utilisation d'attributs de texture couleur permet une meilleure caractérisation que celle basée sur des attributs extraits de l'image de luminance, mais implique d'autre part de considérer un nombre d'attributs plus important. Le paragraphe suivant montre que plusieurs problèmes peuvent alors apparaître et qu'il est nécessaire de procéder à une réduction de la dimension du vecteur d'attributs.

2.1.2 Réduction de la dimension du vecteur d'attributs

Pour être classées, les images sont représentées par des points-image projetés dans un espace appelé **espace d'attributs**. L'espace d'attributs est un espace vectoriel dont le repère est formé des vecteurs \mathbf{X}_l correspondant aux différents attributs X_l considérés pour discriminer les classes, X_l étant la dénomination utilisée pour désigner l'attribut d'indice l appartenant à l'espace initial d'attributs E de dimension D ($l = 1, \dots, D$) et $\mathbf{X}_l = [\mathbf{X}_l^{1,1}, \dots, \mathbf{X}_l^{N_\omega,1}, \mathbf{X}_l^{1,2}, \dots, \mathbf{X}_l^{N_\omega, N_C}]$ étant le vecteur des prototypes correspondant. Dans cet espace, les coordonnées du point associé à une image correspondent aux valeurs des différents attributs de la texture couleur considérée.

La figure 2.2 illustre la représentation de points-image provenant de quatre classes différentes dans un espace d'attributs de dimension 2. Dans cet exemple, les deux attributs sont nécessaires et suffisants pour discriminer les quatre nuages de points correspondant aux quatre classes. Cependant, il se peut que ce ne soit pas toujours le cas, comme le montre la figure 2.3(a), où le problème de la non-pertinence d'un attribut est soulevé. En effet, on voit aisément dans ce second exemple que l'attribut 1 ne permet pas de discriminer les différentes classes. Cet attribut n'apporte donc aucune information utile et peut même introduire un biais. Il est donc préférable de ne pas le considérer pour la classification.

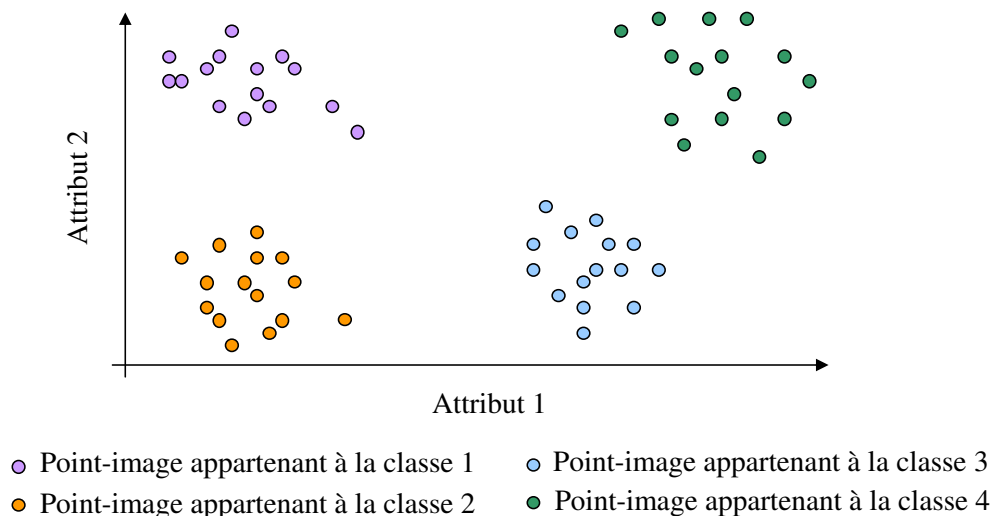



Figure 2.2 : Représentation de points-image provenant de quatre classes différentes dans un espace d'attributs de dimension 2.

La figure 2.3(b) soulève quand à elle le problème lié à la redondance d'un attribut par rapport à un autre. En effet, les attributs 1 et 2 permettent tous deux la discrimination des deux classes présentes dans cet exemple. Ils portent la même information et sont donc corrélés. Il est donc inutile de les considérer tous les deux pour la classification.


Considérer un nombre élevé d'attributs augmente alors le risque de considérer des attributs non pertinents [Bla06]. D'autre part, la caractérisation des images par de nombreux attributs engendre un coût important en stockage mémoire et en temps de calcul. Enfin, la prise en compte d'attributs corrélés par un algorithme de classification majore le poids de ces derniers lors de la décision.

Pour répondre à ce problème de surdimensionnalité, il existe un très grand nombre de méthodes dites "de réduction" qui permettent de réduire la dimension D de l'espace initial d'attributs E lors de l'apprentissage supervisé qui s'effectue hors-ligne [JDM00]. Pour cela, différents sous-espaces candidats E_d , composés de d ($d < D$) attributs notés Y_k ($k = 1, \dots, d$), sont évalués afin de déterminer le sous-espace d'attributs discriminant $E_{\hat{d}}$, composé de \hat{d} attributs notés \hat{Y}_k ($k = 1, \dots, \hat{d}$), qui sera utilisé lors de la phase de classification en-ligne. Nous notons :

- $\mathbf{Y}_k = [\mathbf{Y}_k^{1,1}, \dots, \mathbf{Y}_k^{N_\omega^1,1}, \mathbf{Y}_k^{1,2}, \dots, \mathbf{Y}_k^{N_\omega^{N_C},N_C}]$, le vecteur des prototypes de l'attribut Y_k ,
- $\mathbf{Y}^{i,j} = [\mathbf{Y}_1^{i,j}, \dots, \mathbf{Y}_k^{i,j}, \dots, \mathbf{Y}_d^{i,j}]^T$, le vecteur d'attributs d'un des N_ω^j prototypes $\omega^{i,j}$ ($i = 1, \dots, N_\omega^j$) appartenant à la classe C^j ($j = 1, \dots, N_C$).
- $\hat{\mathbf{Y}}_k = [\hat{\mathbf{Y}}_k^{1,1}, \dots, \hat{\mathbf{Y}}_k^{N_\omega^1,1}, \hat{\mathbf{Y}}_k^{1,2}, \dots, \hat{\mathbf{Y}}_k^{N_\omega^{N_C},N_C}]$, le vecteur des prototypes de l'attribut \hat{Y}_k ,
- et $\hat{\mathbf{Y}}^{i,j} = [\hat{\mathbf{Y}}_1^{i,j}, \dots, \hat{\mathbf{Y}}_k^{i,j}, \dots, \hat{\mathbf{Y}}_{\hat{d}}^{i,j}]^T$, le vecteur d'attributs discriminant d'un des N_ω^j prototypes $\omega^{i,j}$ ($i = 1, \dots, N_\omega^j$) appartenant à la classe C^j ($j = 1, \dots, N_C$).



(a) Illustration d'un attribut non pertinent pour la classification.



(b) Illustration de deux attributs redondants pour la classification.

Figure 2.3 : Illustration de la non pertinence et de la redondance d'un attribut.

Les méthodes de réduction peuvent être divisées en deux catégories [LM98] : la **sélection d'attributs** et l'**extraction d'attributs**. La sélection d'attributs consiste à choisir, parmi les attributs calculés, un nombre réduit d'entre eux qui sont les plus pertinents vis-à-vis de la base d'apprentissage considérée. Pour l'extraction d'attributs, il s'agit par contre d'extraire, à partir de l'ensemble initial d'attributs, un nouvel ensemble plus petit, qui porte la même information [LM98].

Le nombre de méthodes de réduction étant très important, nous avons choisi de nous restreindre dans ce chapitre à une brève vue d'ensemble des principales méthodes d'extraction (cf. paragraphe 2.2), pour permettre une analyse plus approfondie des méthodes de sélection (cf. paragraphe 2.3), qui seront exploitées dans nos travaux. Ce chapitre présentera également les différentes méthodes de validation destinées à mesurer la qualité de l'espace d'attributs sélectionné.

tionné lors de l'apprentissage et la pertinence des règles de décision utilisées pour la phase de classification (cf. § 2.4).

2.2 Extraction des attributs

L'extraction d'attributs consiste à extraire à partir de l'espace initial d'attributs E , un sous-espace $E_{\hat{d}}$ de dimension plus petite, qui porte la même information [LM98]. Les méthodes d'extraction les plus connues sont l'**Analyse Factorielle Discriminante** (AFD), l'**Analyse en Composantes Principales** (ACP) et l'**Analyse en Composantes Indépendantes** (ACI).

2.2.1 Analyse factorielle discriminante et analyse en composantes principales

L'ACP fait partie des méthodes les plus couramment utilisées. Cette technique permet de construire un sous-espace $E_{\hat{d}}$ de \hat{d} nouveaux attributs \hat{Y}_k ($k = 1, \dots, \hat{d}$), combinaisons linéaires des attributs initiaux X_l ($l = 1, \dots, D$) [Cas96].

Dans le cadre de la classification d'images, chaque image est représentée par un point-image dans l'espace d'attributs initial. Le principe de l'ACP est alors de chercher le plus petit sous-espace dans lequel les points-image sont les plus dispersés possible. Autrement dit, il s'agit de déterminer les \hat{d} axes de projection, appelés **axes principaux**, qui maximisent l'inertie du nuage de points projeté (l'inertie étant la moyenne pondérée des carrés des distances séparant les points projetés de leur centre de gravité). La figure 2.4 illustre ce propos.




Figure 2.4 : Illustration du principe de l'ACP.

L'axe qui porte la plus grande inertie (direction \hat{d}_1) est tout d'abord déterminé, puis l'axe orthogonal au précédent portant la plus grande inertie (direction \hat{d}_2), et ainsi de suite. Du point de vue géométrique, c'est un simple changement de base, qui a pour effet une nouvelle représentation dans des directions correspondant à des attributs décorrélés.

L'ACP ne nécessite pas de prototypes, contrairement à l'AFD qui s'applique à un ensemble d'images prototypes de classes connues. Le but de la méthode est alors, comme en ACP, de réduire la dimension de l'espace d'attributs en cherchant de nouveaux attributs, combinaisons linéaires des attributs initiaux, suivant lesquels les nuages de points correspondant aux différentes classes sont les mieux séparés et les plus compacts. Les axes factoriels discriminants successifs sont alors déterminés [Sap06].

La dimension \hat{d} du sous-espace $E_{\hat{d}}$ est le plus souvent déterminée grâce à un seuil sur la valeur de l'inertie des points projetés sur le $\hat{d}^{\text{ème}}$ axe ou sur la valeur des inerties cumulées.

L'ACP a par exemple été utilisée par Martinez-Alajarin dans le cadre de la classification d'images de texture couleur pour réduire la dimension de son espace d'attributs et éliminer les redondances d'information [MALDTB05].

2.2.2 Analyse en composantes indépendantes

L'ACP a révélé certaines limites dans le fait de ne rechercher que des attributs décorrélés car cela ne suffit pas à assurer l'indépendance des attributs entre eux. En effet, la non-corrélation est une propriété plus faible que l'indépendance car elle implique une analyse des moments jusqu'à l'ordre 2 alors que l'indépendance est analysée avec des moments d'ordre supérieur [ZC06].

L'utilisation de l'ACI permet de répondre à ce problème. En effet, cette méthode permet de réduire non seulement la dimension de l'espace d'attributs E , mais également les informations redondantes, par le biais du principe d'indépendance statistique et non plus seulement au sens de la non corrélation [Bar06].

L'ACI a été utilisée par Chindaro dans le cadre de la classification d'images de texture couleur pour non seulement décorréler les attributs, mais également pour réduire les dépendances statistiques entre ces derniers [CSF06].

2.2.3 Limites

Nous venons de présenter les méthodes d'extraction d'attributs les plus connues qui ont prouvé à plusieurs reprises leur efficacité dans divers domaines tels que le biomédical, l'analyse de signaux audio ou encore les télécommunications [LM98].

Cependant, il est parfois préférable d'utiliser une méthode de sélection d'attributs plutôt qu'une méthode d'extraction, notamment lorsque la réduction de l'espace d'attributs est destinée à une application de classification en-ligne où les coûts en temps de calcul doivent être les plus faibles possible. En effet, une méthode d'extraction nécessite le calcul des D attributs initiaux X_l ($l = 1, \dots, D$) pour ensuite extraire les \hat{d} attributs pertinents \hat{Y}_k ($k = 1, \dots, \hat{d}$), ces derniers étant obtenus en combinant, linéairement ou non, les attributs initiaux. En revanche, lorsqu'une

méthode de sélection est utilisée, il est uniquement nécessaire de calculer les \hat{d} attributs sélectionnés pour caractériser une image.

A nombre égal d'attributs pertinents, les méthodes de sélection permettent donc de caractériser plus rapidement les images de texture que les méthodes d'extraction, une fois que la réduction de la dimension de l'espace d'attributs a été effectuée.

2.3 Sélection des attributs

De nombreuses définitions de la **sélection d'attributs** ont été proposées dans la littérature, chacune accentuant plus particulièrement le point de vue de l'auteur qui la considère :

- Kira propose une définition très large de la sélection d'attributs : "The aim of the feature selection is to find the minimally sized feature subset that is necessary and sufficient to the target concept." [KR92].
- Narendra définit la sélection d'attributs de façon beaucoup plus classique : "The goal of the feature selection is to select a subset of \hat{d} features from a set of D features, $\hat{d} < D$, such that the value of a criterion function is optimized over all subsets of size \hat{d} ." [NF77].
- Une troisième définition, proposée par Koller, met l'accent sur la précision de la classification effectuée à la suite de la sélection : "The aim of the feature selection is to choose a subset of features for improving prediction accuracy or decreasing the size of the structure without significantly decreasing prediction accuracy of the classifier built using only the selected features." [KS96].

Notons que la sélection d'attributs est en fait un cas particulier de la **pondération d'attributs** [Bla06]. En effet, dans les deux cas, il s'agit de chercher des poids à assigner aux attributs selon leur pertinence. Lorsque ces poids ont des valeurs réelles, nous sommes dans le cas de la pondération d'attributs et lorsque les poids ont des valeurs binaires (0 ou 1), nous sommes dans le cas de la sélection d'attributs.

Les algorithmes de sélection peuvent être divisés en deux catégories : les **algorithmes de classement des attributs** et les **algorithmes de recherche de sous-espaces** [YL03]. La différence entre ces deux types d'algorithmes est que le premier mesure la pertinence des attributs en les appréciant de manière individuelle, tandis que le second évalue des sous-espaces d'attributs.

2.3.1 Algorithmes de classement

Les algorithmes de classement évaluent chaque attribut et lui assignent une note plus ou moins importante selon sa pertinence. Les différents attributs sont ensuite triés afin de sélectionner les plus discriminants et ainsi former un sous-espace pertinent d'attributs [Bla06].

La méthode Relief est une des méthodes de classement d'attributs les plus utilisées. Initia-

lement conçue pour classer des images en uniquement deux classes différentes, cette méthode a rapidement été étendue aux problèmes multi-classes grâce à l'extension nommée Relief-F [Kon94].

Lors de l'apprentissage, cette méthode prend en entrée les prototypes et retourne un vecteur de "pertinence". Celui-ci a pour dimension le nombre d'attributs et contient les notes qui reflètent le pouvoir discriminant de chaque attribut au sens d'une fonction d'évaluation J .

La pertinence de tous les attributs étant ainsi évaluée, il ne sera gardé que les attributs dont la note se trouve au dessus d'un certain seuil.

Le temps de traitement étant proportionnel au nombre d'attributs et au nombre d'images d'apprentissage, la méthode Relief-F fait partie des procédures de sélection les plus rapides [DL97]. Celebi utilise cet algorithme dans le cadre de la classification d'images de texture couleur, pour trier $D = 437$ attributs [CKU⁺07].

Cependant, les algorithmes de classement mesurent la pertinence des attributs en les appréciant de manière individuelle et ne permettent donc pas d'éliminer les attributs redondants, ce qui augmente le risque de ne pas sélectionner le sous-espace le plus discriminant. En revanche, les algorithmes de recherche de sous-espaces évaluent les sous-espaces d'attributs de manière globale.

2.3.2 Recherche de sous-espaces

A partir d'un espace donné d'attributs de dimension D , les méthodes de recherche de sous-espaces tentent de trouver le meilleur sous-espace d'attributs, au sens d'un critère donné, parmi les $2^D - 1$ sous-espaces candidats. Comme une recherche exhaustive est bien trop coûteuse en temps de calcul, les méthodes heuristiques qui permettent d'atteindre un compromis entre complexité et performance, sont le plus souvent utilisées [DL97].

Selon Dash, une procédure classique de recherche de sous-espaces d'attributs est composée de quatre étapes fondamentales, illustrées sur la figure 2.5 [DL97] :

- la procédure de génération,
- la fonction d'évaluation,
- le critère d'arrêt,
- la procédure de validation.

A chaque itération, la **procédure de génération** génère un sous-espace d'attributs qui va être évalué lors de la seconde étape. Cette procédure peut commencer soit avec aucun attribut, soit avec tous les attributs, soit avec un sous-espace aléatoire d'attributs. Dans les deux premiers cas, des attributs sont ensuite respectivement ajoutés ou retirés de manière itérative au sous-espace de départ. Pour le troisième cas, soit on ajoute ou on retire des attributs, comme dans les deux premiers cas, soit un nouveau sous-espace d'attributs est créé de manière aléatoire à

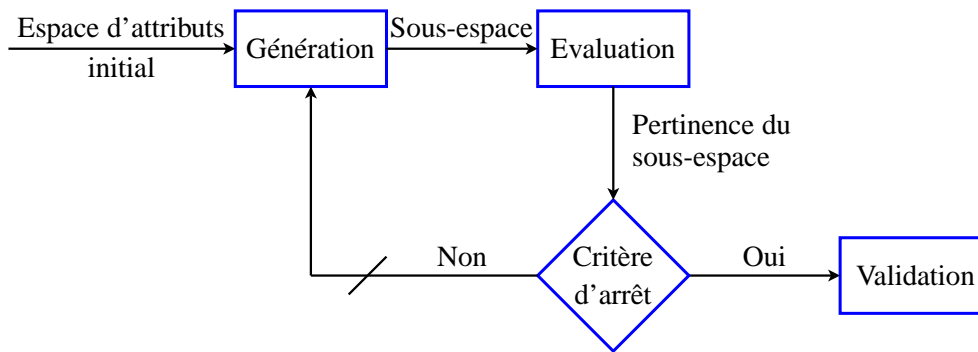


Figure 2.5 : Illustration de la procédure de sélection d'attributs avec étape de validation.

chaque itération (ce processus est appelé "**random generation**").

La **fonction d'évaluation** (ou **critère d'évaluation**), notée J , mesure la pertinence du sous-espace généré lors de la procédure de génération.

Lorsque que le **critère d'arrêt** est satisfait, la procédure de recherche de sous-espaces d'attributs s'arrête. La recherche est donc non-exhaustive, mais réalisable dans la pratique.

La **procédure de validation** ne fait en réalité pas partie du processus de recherche de sous-espaces d'attributs. Cependant, en pratique, toute méthode de sélection doit être validée. Cela consiste à tester la validité du sous-espace sélectionné en comparant par exemple les résultats de classification obtenus avec ce sous-espace et les résultats de classification obtenus avec d'autres sous-espaces.

Notons que la première étape est caractéristique des procédures de recherche de sous-espaces d'attributs, tandis que les trois autres s'appliquent également aux algorithmes de classement des attributs. C'est pourquoi nous allons insister sur cette étape de génération dans ce paragraphe, qui s'intéresse aux méthodes de recherche de sous-espace d'attributs et décrire les trois autres étapes dans les paragraphes suivants puisqu'elles s'appliquent aux méthodes de sélection en général.

Il existe trois approches de génération différentes :

- la génération complète,
- la génération aléatoire,
- la génération séquentielle.

Pour un espace d'attributs initial de dimension D , le nombre total de sous-espaces candidats qui peuvent être générés par la procédure de génération est de $2^D - 1$, ce qui représente généralement un nombre très important lorsque D prend une valeur élevée.

2.3.2.1 Génération complète

Dans le cadre des procédures de **génération complète**, une recherche exhaustive du sous-espace optimal (au sens de la fonction d'évaluation J utilisée) est effectuée [DL97]. Cependant, il ne s'agit pas d'évaluer l'ensemble des $2^D - 1$ sous-espaces candidats : la recherche du sous-espace optimal est réduite grâce à un processus de **backtracking** (processus permettant de revenir en arrière si la sélection s'engage dans une mauvaise direction de génération).

La méthode **Branch and Bound** (BB) est l'algorithme par génération complète le plus couramment utilisé. Cette méthode exige d'une part, que le nombre d'attributs à sélectionner \hat{d} soit connu *a priori*, et d'autre part que la fonction d'évaluation J soit **monotone** avec le nombre d'attributs sélectionnés [KS00]. Une fonction croissante (cas que nous allons considérer pour l'explication de l'algorithme BB) signifie que pour deux sous-espaces d'attributs E_d^1 et $E_{d'}^2$ de dimensions respectives d et d' ($d < d'$), si E_d^1 est un sous-ensemble de $E_{d'}^2$, alors $J(E_d^1) < J(E_{d'}^2)$.

L'exemple numérique suivant va nous permettre d'expliquer facilement le fonctionnement de l'algorithme BB :

Considérons le problème de la sélection de $\hat{d} = 2$ attributs parmi $D = 6$ attributs initiaux notés X_l ($l \in 1, 2, \dots, 6$). Une partie de l'arbre de décision correspondant à ce problème est présentée figure 2.6.

Les branches de cet arbre représentent différents sous-espaces dans lesquels certains attributs sont éliminés tour à tour. Par exemple, le sous-espace d'attributs $\{X_1, X_4, X_5, X_6\}$, repéré par le noeud vert, est obtenu en supprimant les attributs X_2 et X_3 . Le problème BB consiste alors à rechercher le meilleur chemin (c'est-à-dire la meilleure combinaison de $D - \hat{d} = 4$ attributs à éliminer), ce chemin étant celui qui maximise la fonction d'évaluation.

L'évaluation d'un premier chemin va permettre d'initialiser la valeur de J_{max} . Cette valeur sera ensuite automatiquement mise à jour dès qu'un des sous-espaces d'attributs de dimension \hat{d} présente une valeur d'évaluation supérieure.

Notons que l'ordre de présentation des attributs n'a pas d'importance vu que la procédure de génération est complète. Cependant, cela ne signifie pas que tous les chemins sont entièrement étudiés. En effet, l'exigence d'une fonction d'évaluation monotone va permettre d'effectuer un backtracking : un **noeud parent** possède un certain nombre de noeuds qui le suivent dans l'arbre, appelés **noeuds successeurs**, chacun d'entre eux correspondant à la suppression d'un attribut. Comme la fonction d'évaluation est monotone, la valeur d'évaluation $J(\text{successeur})$ des noeuds successeurs d'un noeud parent est automatiquement inférieure à la valeur d'évaluation du parent $J(\text{parent})$. Étant donné que l'algorithme BB cherche à maximiser la fonction d'évaluation, si la valeur d'évaluation d'un noeud parent est déjà inférieure à J_{max} , il est inutile de poursuivre l'évaluation des noeuds successeurs pour ce chemin. L'étude du chemin suivant peut alors immédiatement débiter.

Illustrons ces propos avec l'exemple de la figure 2.6 :




Figure 2.6 : Partie de l'arbre de décision "Branch and Bound" pour le problème de la sélection de $\hat{d} = 2$ attributs parmi $D = 6$.

- **Initialisation de J_{max} :** Dans un premier temps, il s'agit d'évaluer une première solution afin d'initialiser la valeur maximale de la fonction d'évaluation. Dans notre illustration, c'est le chemin bleu qui est entièrement parcouru permettant ainsi d'initialiser J_{max} : $J_{max} = J\{X_3, X_4\}$, $J\{X_3, X_4\}$ étant la valeur prise par la fonction d'évaluation pour le sous-espace $\{X_3, X_4\}$.
- **Évaluations successives :** Cette phase consiste ensuite à évaluer successivement les noeuds des différents chemins restants :

- Évaluation du sous-espace $\{X_1, X_2, X_4, X_5, X_6\}$ représenté dans l'arbre par le noeud entouré en rouge : $J\{X_1, X_2, X_4, X_5, X_6\} > J_{max}$.
 - Évaluation du sous-espace $\{X_1, X_4, X_5, X_6\}$ représenté dans l'arbre par le noeud entouré en vert : $J\{X_1, X_4, X_5, X_6\} > J_{max}$.
 - Évaluation du sous-espace $\{X_1, X_4, X_6\}$ représenté dans l'arbre par le noeud entouré en rose : $J\{X_1, X_4, X_6\} \leq J_{max}$. Il est inutile de poursuivre l'évaluation des noeuds successeurs pour ce chemin.
 - Évaluation du sous-espace $\{X_2, X_4, X_5, X_6\}$ représenté dans l'arbre par le noeud entouré en jaune : $J\{X_2, X_4, X_5, X_6\} > J_{max}$.
 - Évaluation du sous-espace $\{X_2, X_4, X_5\}$ représenté dans l'arbre par le noeud entouré en gris : $J\{X_2, X_4, X_5\} > J_{max}$.
 - Évaluation du sous-espace $\{X_2, X_4\}$ représenté dans l'arbre par le noeud entouré en mauve : $J\{X_2, X_4\} > J_{max}$.
- **Mise à jour de J_{max}** : Dès qu'un sous-espace de dimension $\hat{d} = 2$ (en l'occurrence le sous-espace $\{X_2, X_4\}$ dans notre exemple) possède une valeur d'évaluation supérieure à J_{max} , il est considéré comme la nouvelle solution du problème. J_{max} est alors mis à jour ($J_{max} = J\{X_2, X_4\}$) et l'évaluation des chemins suivants se poursuit selon le même schéma.

Différentes améliorations de la procédure de sélection BB ont été proposées :

- Pour la plupart des problèmes de classification, il est impossible de connaître *a priori* la dimension optimale du sous-espace d'attributs à sélectionner. La solution est alors de trouver le sous-espace d'attributs possédant la plus petite dimension possible sachant que la capacité discriminante de ce sous-espace ne doit pas être inférieure à un certain seuil [Doa92].
- Pour réduire le temps de calcul de l'algorithme BB, Somol propose la procédure de sélection **Fast BB** qui fait appel à une fonction de prédiction. Celle-ci permet de prédire les valeurs que prendra la fonction d'évaluation pour certains noeuds de l'arbre, et ainsi d'en éviter le calcul [SPK04]. La qualité de la sélection peut cependant être altérée par des erreurs de prédiction, mais le compromis entre rapidité et qualité n'en reste pas moins bon.
- D'autres auteurs ont également proposé des versions modifiées de l'algorithme BB pour améliorer la rapidité de la sélection [KS00, CC03, Che03, NC07]. Par exemple, Kudo utilise au préalable une méthode de sélection séquentielle afin d'initialiser au mieux J_{max} . En effet, plus cette valeur est importante au départ, moins il y aura de noeuds successeurs à évaluer. D'autre part, Nakariyakul remarque que lorsque $\hat{d} \ll D$, il est inutile de parcourir les branches situées près de la racine de l'arbre de décision. Il met alors en place une méthode qui lui permet de trouver le niveau de l'arbre où il pourra commencer à effectuer l'évaluation des noeuds, ce qui lui permet ainsi de réduire le temps de calcul.

Cependant, malgré les améliorations apportées, les algorithmes BB restent encore très coû-

teux en temps de calcul et il est recommandé de ne pas les utiliser si la dimension initiale D de l'espace d'attributs excède 50 [KS00].

Les méthodes de recherche de sous-espaces faisant appel à une procédure de génération complète ont été peu utilisées dans le cadre de la classification d'images de texture couleur, du fait de leur coût élevé en temps de calcul. Par contre, pour sélectionner un sous-espace d'attributs à partir d'un espace initial dont la dimension n'excède pas 50, cette méthode reste une des meilleures puisque elle permet de trouver la solution optimale [KS00]. Cette procédure de génération exhaustive a ainsi été utilisée par Van den Broek dans le cadre de la classification d'images de texture couleur pour sélectionner un sous-espace d'attributs discriminant à partir d'un espace initial de dimension $D = 32$ [BR04].

Lorsque la dimension initiale de l'espace d'attributs est supérieure à 50, il est préférable d'utiliser des procédures de génération non exhaustives. Cependant, la difficulté qu'engendre ce type de procédure est que la fonction d'évaluation peut atteindre un optimum local qui arrêterait prématurément la recherche du sous-espace discriminant, dans le cas où le critère d'arrêt est basé sur la fonction d'évaluation. Nous verrons dans le paragraphe 2.3.2.3 que certaines procédures de type séquentielle effectuent un "backtracking" pour pallier cet inconvénient et dans le paragraphe 2.3.2.2 que la procédure de génération aléatoire permet d'éviter, de part sa définition, les optima locaux de la fonction d'évaluation.

2.3.2.2 Génération aléatoire

Les procédures de **génération aléatoire** parcourent au hasard l'ensemble des $2^D - 1$ sous-espaces candidats. Cela permet de ne pas arrêter la recherche lorsque la fonction d'évaluation d'un sous-espace atteint un optimum local. Cependant, les $2^D - 1$ sous-espaces candidats ne sont pas tous évalués contrairement aux procédures de génération complète : un nombre maximal d'itérations est imposé afin que les temps de calcul restent raisonnables [DL97].

Les **algorithmes génétiques** (AG), initiés par Holland en 1975 [Hol75], sont les méthodes de génération aléatoire les plus couramment utilisées. Elles sont basées sur le principe de la sélection naturelle [Gol89].

La première étape de la conception d'un algorithme génétique est de représenter les $2^D - 1$ sous-espaces candidats sous forme de **chromosomes**, qui sont des chaînes de **gènes**, les gènes représentant les différents attributs considérés. La figure 2.7 représente la modélisation d'un sous-espace composé des attributs modélisés par les gènes égaux à 1 [KS00].

La population initiale est constituée d'un ensemble de N_{PI} chromosomes générés aléatoirement. A chaque itération, une nouvelle population est créée, cette génération consistant en des chromosomes mieux "adaptés" au sens de la fonction d'évaluation utilisée. La création de




Figure 2.7 : Illustration d'un chromosome.

cette nouvelle population se fait par application d'opérateurs génétiques tels que la sélection, le croisement et la mutation (cf. figure 2.8). Au fur et à mesure des itérations, les chromosomes vont donc tendre vers l'optimum de la fonction d'évaluation.

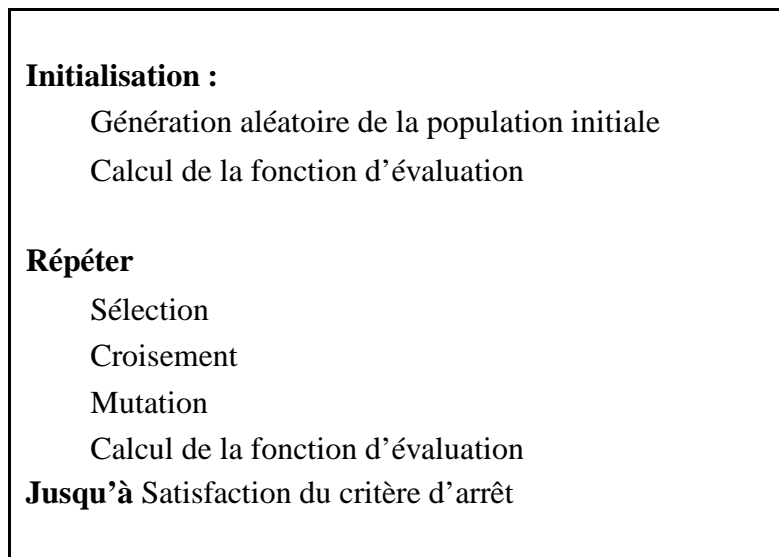


Figure 2.8 : Algorithme génétique.

La **sélection** des meilleurs chromosomes est la première opération effectuée par un algorithme génétique. Les N_{PI} chromosomes qui constituent la population initiale sont tout d'abord triés selon leur capacité de discrimination grâce à la fonction d'évaluation. Seuls les $\frac{N_{PI}}{2}$ premiers sont retenus. Ce sont ces chromosomes qui vont être dupliqués et servir de parents lors de l'application de l'opérateur de croisement [Gol89].

Lors de l'opérateur de **croisement**, $\frac{N_{PI}}{4}$ couples vont être formés, de manière aléatoire, à partir des $\frac{N_{PI}}{2}$ chromosomes précédemment sélectionnés. Le croisement de chaque couple donne alors naissance à 2 chromosomes "fils" [Gol89]. La figure 2.9 illustre ce propos. $\frac{N_{PI}}{2}$ nouveaux chromosomes sont alors considérés.

Enfin, l'opérateur de **mutation** modifie de manière aléatoire la composition d'un chromosome pris au hasard. Un attribut peut être ajouté ou retiré par exemple (cf. figure 2.10). Cela

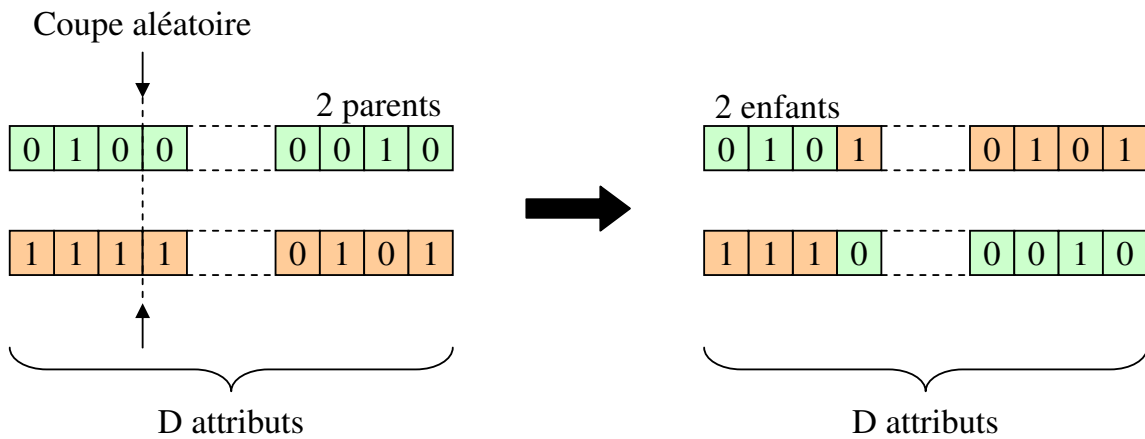


Figure 2.9 : Illustration de l'opération de croisement.

permet d'introduire et de maintenir la diversité au sein de la population de solutions [Gol89].

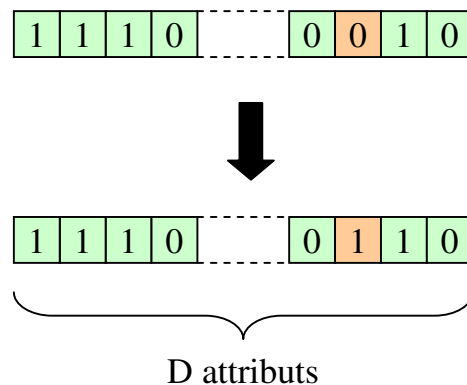


Figure 2.10 : Illustration de l'opération de mutation.

Les algorithmes génétiques ont été utilisés par Mäenpää pour sélectionner un sous-espace d'attributs utilisé par un algorithme de classification d'images de texture couleur [MVP03].

L'avantage de la procédure de génération aléatoire est qu'elle ne nécessite pas l'utilisation de fonction d'évaluation monotone. D'autre part, contrairement aux méthodes de génération complète dont la complexité est exponentielle vis-à-vis de la dimension initiale D de l'espace d'attributs, la complexité de calcul des méthodes basées sur une génération aléatoire est quadratique [KS00, DLM00]. C'est également le cas des méthodes de sélection basées sur les procédures de génération séquentielle.

2.3.2.3 Génération séquentielle

Le principe des procédures de génération séquentielle est d'ajouter ou de supprimer un ou plusieurs attributs au fur et à mesure des itérations. On distingue alors deux types d'algorithmes de génération séquentielle : les algorithmes de type "Forward", qui consistent à ajouter des attributs à partir d'un ensemble vide, et les algorithmes de type "Backward", qui consistent à supprimer des attributs à partir de l'ensemble initial complet.

L'algorithme de sélection séquentielle "Forward" (**Sequential Forward Selection** (SFS)), décrit sur la figure 2.11, consiste à ajouter itérativement des attributs à un ensemble initialement vide de la façon suivante :

- Tout d'abord, en entrée du processus de sélection SFS, on dispose de l'espace initial d'attributs E et de la fonction d'évaluation J . Dans cet exemple, la fonction d'évaluation sera à maximiser pour obtenir la meilleure capacité de discrimination.
- Comme la procédure de sélection séquentielle est de type "Forward", le sous-espace d'attributs évalué est initialement vide ($E_0 = \emptyset$).
- A chaque rang d'itération r de la procédure de sélection, on considère les $(D - r)$ sous-ensembles d'attributs $E_r \cup \{X_l\}$, formés des r attributs déjà sélectionnés et d'un des attributs candidats X_l . Les attributs candidats sont ceux qui n'ont pas encore été sélectionnés, c'est-à-dire ceux qui appartiennent au sous-ensemble $E \setminus E_r$. Le pouvoir discriminant $J(E_r \cup \{X_l\})$ de chacun de ces sous-ensembles est alors évalué grâce à la fonction d'évaluation J . L'attribut X_l qui maximise $J(E_r \cup \{X_l\})$ est noté X_+ et forme avec le sous-espace E_r d'attributs déjà sélectionnés, le sous-espace d'attributs sélectionnés E_{r+1} de dimension $r + 1$. La valeur de r est alors incrémentée ($r = r + 1$).
- Une fois le critère d'arrêt satisfait, la procédure de sélection s'arrête et $E_{\hat{d}} = E_r$.

Le principe est le même pour la sélection séquentielle de type "Backward" (**Sequential Backward Selection** (SBS)) qui consiste quant à elle, à éliminer itérativement des attributs à partir d'un espace initialement constitué de tous les attributs ($E_0 = E$).

Les méthodes SFS et SBS ne parcourent pas la totalité de l'espace des solutions. Par conséquent, elles sont plus simples à mettre en oeuvre et plus rapides que les méthodes de sélection basées sur les procédures de génération complète.

Il est également possible d'ajouter (ou de retirer) itérativement les attributs par groupe. On parle alors de sélection séquentielle "Forward" (ou "Backward") généralisée (**Generalized Sequential Forward Selection** et **Generalized Sequential Backward Selection** (GSFS et GSBS)). Ces méthodes permettent d'améliorer légèrement la performance des méthodes SFS et SBS, mais sont beaucoup plus coûteuses en temps de calcul. Kudo recommande de les utiliser si l'on désire que la dimension \hat{d} du sous-espace soit très faible (GSFS) ou très proche de la dimension initiale D de l'espace d'attributs (GSBS) [KS00].

Cependant, ces méthodes n'explorent pas tous les sous-espaces possibles d'attributs et n'ef-

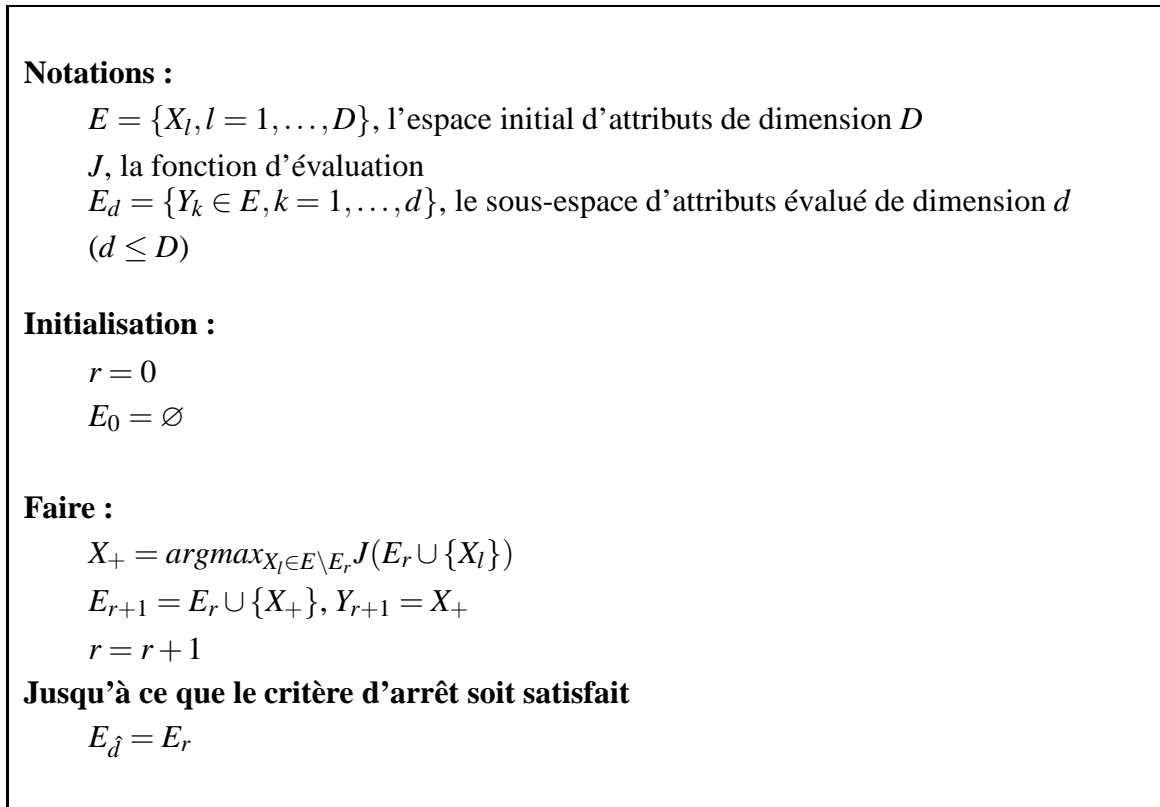


Figure 2.11 : Algorithme SFS.

fectuent pas de retour pendant la recherche. Cette limite peut réduire le niveau de performance atteint. C'est pourquoi, des méthodes alternent les procédures SFS et SBS, permettant ainsi d'ajouter des attributs, puis d'en retirer d'autres. C'est le cas de l'algorithme "**plus m -take away n** " (PTA) [KS00]. Cet algorithme consiste tout d'abord à élargir le sous-espace d'attributs en répétant m fois la procédure SFS, puis à éliminer n attributs en répétant n fois la procédure SBS. Notons que le choix des paramètres m et n influe sur la qualité des résultats ainsi que sur le temps de calcul.

Cette méthode peut également être généralisée (**Generalized plus m -take away n** (GPTA)) en répétant m fois la procédure GSFS et n fois la procédure GSBS. Cet algorithme généralisé est très performant lorsque l'on connaît *a priori* la dimension \hat{d} du sous-espace discriminant, mais il reste cependant très coûteux en temps de calcul.

Pour réduire les coûts de calcul, tout en tentant de conserver un niveau élevé de performance, on peut utiliser les méthodes flottantes, qui sont une extension de l'algorithme "plus m -take away n " [PNK94]. Les acronymes des versions "Forward" et "Backward" de ces méthodes sont respectivement SFFS (**Sequential Forward Floating Selection**) et SBFS (**Sequential Backward Floating Selection**). L'algorithme SFFS, décrit sur la figure 2.12, consiste à appliquer après chaque étape "Forward" des étapes "Backward" tant que le sous-espace d'attributs correspondant améliore la fonction d'évaluation (pour l'algorithme SBFS, le même principe est appliqué à la différence que les deux étapes sont inversées) :

- Tout d'abord, comme pour le processus de sélection SFS, on dispose de l'espace initial

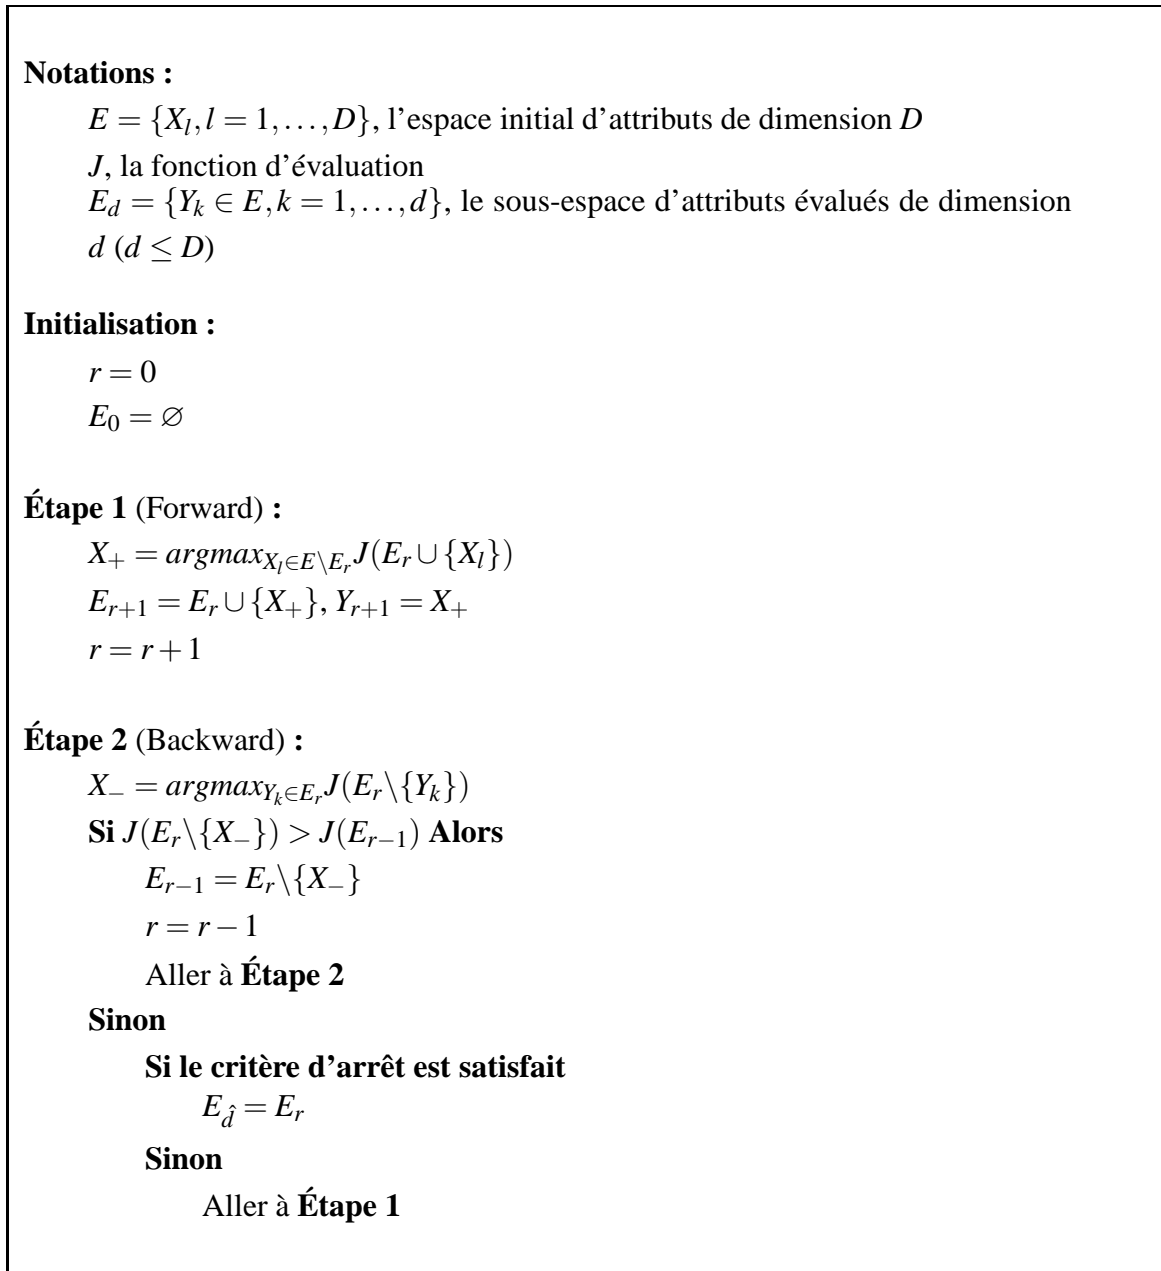


Figure 2.12 : Algorithme "Sequential Forward Floating Selection".

d'attributs E et de la fonction d'évaluation J . Dans cette illustration, la fonction d'évaluation est également à maximiser.

- Comme la procédure de sélection est de type "Forward", le sous-espace d'attributs à évaluer est initialement vide ($E_0 = \emptyset$), contrairement à une sélection de type SBFS où le sous-espace E_D est initialement constitué des D attributs initiaux ($E_D = E$).
- L'étape "Forward" correspond à une procédure de type SFS : à chaque rang d'itération r de la procédure de sélection, on considère les $(D - r)$ sous-ensembles d'attributs $E_r \cup \{X_l\}$ et on mesure leur pouvoir discriminant $J(E_r \cup \{X_k\})$. Parmi les attributs X_l appartenant au sous-ensemble $E \setminus E_r$, celui qui maximise $J(E_r \cup \{X_l\})$ est noté X_+ et forme avec le sous-espace E_r d'attributs déjà sélectionnés, le sous-espace d'attributs sélectionnés E_{r+1} de dimension $r + 1$. La valeur de r est alors incrémentée ($r = r + 1$).

- L'attribut X_+ sélectionné va influencer le reste de la procédure de recherche de sous-espaces. Pour éviter les optima locaux, il est nécessaire d'appliquer une ou plusieurs fois l'étape "Backward". Cette étape consiste à retirer du sous-espace E_r un attribut sélectionné Y_k et à mesurer le pouvoir discriminant correspondant $J(E_r \setminus \{Y_k\})$. Cette opération est effectuée pour chacun des attributs Y_k ($k = 1, \dots, r$) du sous-espace E_r et on note X_- , l'attribut Y_k qui maximise $J(E_r \setminus \{Y_k\})$. Il reste alors à vérifier si le fait d'avoir ôter cet attribut améliore ou non le pouvoir discriminant qui avait été obtenu à l'étape $r - 1$. Si c'est le cas ($J(E_r \setminus \{X_- \}) > J(E_{r-1})$), le sous-ensemble sélectionné à l'étape $r - 1$ devient $E_r \setminus \{X_- \}$ et on recommence l'étape "Backward" jusqu'à ce que le retrait d'attributs n'améliore plus la capacité de discrimination, c'est-à-dire dès que $J(E_r \setminus \{X_- \}) \leq J(E_{r-1})$. Dans ce cas, si le critère d'arrêt n'est pas satisfait, on peut commencer une nouvelle étape "Forward", sinon, la procédure de sélection s'arrête et $E_{\hat{d}} = E_r$.

L'algorithme SFFS est utilisé par Van de Wouwer dans le cadre de la classification des images de texture couleur issues de la base VisTex, pour sélectionner un sous-espace d'attributs discriminant de dimension $\hat{d} = 10$ à partir d'un espace initial de $D = 72$ attributs [dWSLD99].

Pydipati utilise également l'algorithme SFFS pour sélectionner un sous-espace de dimension $\hat{d} = 7$ parmi $D = 39$ attributs [PBL06]. Ce sous-espace discriminant d'attributs a ensuite été utilisé pour classer les feuillages des citronniers selon leur couleur et leur texture.

Ces méthodes flottantes sont considérées comme les méthodes sous-optimales les plus efficaces [JZ97]. Elles supportent l'utilisation de fonctions d'évaluation monotones ou non, comme les algorithmes génétiques, mais avec l'avantage d'être encore plus performantes même lorsque la dimension initiale D de l'espace d'attributs est grande [FPHK94].

2.3.2.4 Synthèse

Le tableau 2.1 synthétise une partie des travaux de Kudo [KS00], ainsi que les remarques effectuées dans les précédents paragraphes sur les différentes procédures de génération.

Ce tableau présente les méthodes de génération à utiliser selon l'objectif que l'on vise (objectifs A, B ou C), la dimension initiale D de l'espace d'attributs et le caractère monotone de la fonction d'évaluation.

La première colonne de ce tableau indique les différents objectifs visés.

Pour l'objectif A, il s'agit de trouver le sous-espace d'attributs le plus discriminant, au sens de la fonction d'évaluation utilisée, connaissant *a priori* sa dimension \hat{d} . Pour cet objectif, les fonctions d'évaluation non monotones sont rarement utilisées [KS00].

Les algorithmes BB, utilisés avec des fonctions d'évaluation monotones, et uniquement

Objectif	$D < 20$		$20 \leq D < 50$		$50 \leq D \leq 100$		$D > 100$
	M	NM	M	NM	M	NM	
A : Trouver le sous-espace le plus discriminant de dimension \hat{d} fixée.	BB	*	BB	*	SFFS SBFS AG	*	SFFS
B : Trouver le plus petit sous-espace avec un pouvoir discriminant supérieur à un seuil fixé.	BB	*	BB AG	*	AG	*	SFFS
C : Trouver un compromis entre \hat{d} et la capacité de discrimination.	*	AG SFFS SBFS	*	AG SFFS SBFS	*	AG	SFFS

* : Les situations repérées par un astérisque se présentent rarement et n'ont donc pas été étudiées [KS00].

M : Utilisation d'une fonction d'évaluation monotone.

NM : Utilisation d'une fonction d'évaluation non monotone.

Tableau 2.1 : Méthodes de sélection recommandées selon l'objectif visé, la dimension initiale D de l'espace d'attributs et le caractère monotone de la fonction d'évaluation.

lorsque la dimension initiale D n'excède pas 50, répondent à cet objectif. Kudo recommande par ailleurs d'utiliser sa version de l'algorithme BB, qui fait appel à une méthode de sélection séquentielle pour initialiser au mieux J_{max} afin d'augmenter l'efficacité de la sélection [KS00]. Lorsque D est compris entre 50 et 100, on peut utiliser soit les algorithmes génétiques soit une des deux procédures de sélection séquentielle SFFS ou SBFS. Enfin, lorsque D est supérieure à 100, les travaux de Ferri incitent à privilégier la procédure SFFS. En effet, il a montré que plus D augmente, plus la performance obtenue par les algorithmes génétiques se dégrade [FPHK94].

L'objectif B consiste à trouver le sous-espace d'attributs possédant la plus petite dimension \hat{d} possible, sachant que la capacité discriminante de ce sous-espace ne doit pas être inférieure à un certain seuil. Comme pour l'objectif A, les fonctions d'évaluation non monotones sont rarement utilisées.

Pour ce type d'objectif, on privilégiera les algorithmes BB lorsque la dimension initiale D de l'espace d'attributs n'excède pas 50 et/ou les algorithmes génétiques lorsque $20 < D \leq 100$ [KS00]. Enfin, pour $D > 100$, la procédure de sélection séquentielle SFFS semble la mieux adaptée d'après les travaux de Ferri [FPHK94].

L'objectif C consiste à faire un compromis entre les objectifs A et B, c'est-à-dire à trouver un sous-espace d'attributs possédant à la fois une petite dimension et une capacité discriminante élevée. Pour cet objectif, ce sont les fonctions d'évaluation non monotones qui sont privilégiées contrairement aux deux objectifs précédents.

Les méthodes permettant d'effectuer ce compromis sont l'algorithme SBFS (lorsque $D \leq 50$), les algorithmes génétiques (lorsque $D \leq 100$) et la méthode séquentielle SFFS.

Après avoir décrit les différentes méthodes de génération utilisées pour la recherche de sous-espaces d'attributs, le paragraphe suivant s'intéresse aux fonctions d'évaluation. Ces fonctions sont utilisées pour mesurer :

- la pertinence des attributs en les appréciant de manière individuelle, lorsqu'on utilise un algorithme de sélection par classement des attributs,
- la pertinence des sous-espaces d'attributs générés par l'une des différentes méthodes de génération présentées ci-dessus, lorsqu'un algorithme de recherche de sous-espaces discriminants est utilisé.

D'une manière générale, nous parlerons dans la suite de ce chapitre de l'évaluation des sous-espaces d'attributs (un attribut étant un sous-espace d'attributs composé d'un seul élément).

2.3.3 Fonction d'évaluation

Les cinq familles de mesures d'évaluation généralement utilisées dans le cadre de la sélection d'attributs sont les suivantes :

- la mesure du taux d'erreur de classification,

- la mesure de consistance,
- la mesure d'information,
- la mesure de dépendance,
- la mesure de distance.

La première mesure d'évaluation citée correspond à une approche de type **wrapper**. Pour ce type d'approche, la sélection se fait en utilisant des fonctions d'évaluation fondées sur le taux d'erreur de classification (ou sur la probabilité d'erreur de classification) et dépendent donc de la méthode de classification utilisée. Au contraire, pour les quatre autres mesures qui correspondent à une approche de type **filter**, les critères d'évaluation ne tiennent compte que des prototypes, et sont donc totalement indépendants de la méthode de classification [DL97].

2.3.3.1 Mesure du taux d'erreur de classification

Lorsqu'une approche "wrapper" est utilisée, les sous-espaces d'attributs sont évalués en fonction de la qualité de classification obtenue en les considérant. Le sous-espace d'attributs le plus discriminant est alors celui pour lequel le **taux d'erreur de classification** des prototypes est minimum [DLPT82] (en classification d'images, le taux d'erreur de classification est égal au rapport entre le nombre d'images qui n'ont pas été assignées à la bonne classe et le nombre total d'images présentées au processus pour être classées).

En plus d'évaluer la qualité de la classification, l'approche "wrapper" peut également permettre de trouver la dimension optimale du sous-espace d'attributs à sélectionner. En ce sens, elle joue également le rôle de critère d'arrêt. En effet, elle permet de mesurer, à chaque étape de la procédure de génération, le taux d'erreur de classification des prototypes obtenu en considérant le sous-espace sélectionné. On en déduit ainsi la dimension \hat{d} qui permet d'obtenir la meilleure qualité de classification des prototypes, par minimisation du taux d'erreur [GE03].

Ce critère d'évaluation est utilisé par Van den Broek pour sélectionner des attributs dans le but de classer les images de texture couleur de la base VisTex [BR04]. Il associe la mesure du taux d'erreur de classification des prototypes avec une procédure de génération exhaustive pour sélectionner un sous-espace d'attributs discriminant à partir d'un espace initial de dimension $D = 32$.

Van de Wouwer utilise également une approche "wrapper" pour sélectionner un sous-espace d'attributs discriminant destiné à caractériser les textures couleur de la base VisTex [dWSLD99].

Ce critère s'avère d'une grande précision, cependant il nécessite d'effectuer la classification des prototypes projetés dans chaque sous-espace candidat, ce qui peut devenir fort coûteux en temps de calcul lorsque :

- la dimension D de l'espace initial d'attributs est élevée,

- l’algorithme de classification ou de génération utilisé est lui-même coûteux en temps de calcul,
- le nombre de prototypes est élevé [YL03].

2.3.3.2 Mesure de consistance

Les mesures de consistance cherchent à évaluer si le sous-espace d’attributs étudié contient les informations nécessaires à la discrimination des classes. La figure 2.13 illustre un attribut consistant (attribut 2) et un attribut non consistant (attribut 1) : on voit aisément dans cette représentation que, contrairement à l’attribut 2, l’attribut 1 ne permet pas de discriminer les deux classes, car les valeurs prises par cet attribut appartiennent au même domaine de définition quelque soit la classe.




Figure 2.13 : Représentation d’un attribut consistant (attribut 2) et un attribut non consistant (attribut 1).

Les fonctions d’évaluation basées sur les mesures de consistance sont en général de la forme suivante [Sem04] :

$$J_1(E_d) = \sum_{j=1}^{N_C} \sum_{j'=1}^{N_C} P(C^j)P(C^{j'})D^{jj'}(E_d) \quad (2.1)$$

où $P(C^j)$ et $P(C^{j'})$ sont respectivement les probabilités *a priori* des classes C^j et $C^{j'}$ et $D^{jj'}(E_d)$, une mesure de séparation entre ces deux classes dans l’espace E_d . Cette mesure doit être choisie de manière à ce que le critère d’évaluation J_1 satisfasse les conditions suivantes :

- $J_1 \geq 0$.
- $J_1 = 0$ seulement lorsque les probabilités $P(\mathbf{Y}^{i,j}|C^j)$ et $P(\mathbf{Y}^{i,j}|C^{j'})$ sont égales pour des classes C^j et $C^{j'}$ différentes. Le terme $P(\mathbf{Y}^{i,j}|C^j)$ est la probabilité d’occurrence de $\mathbf{Y}^{i,j}$ pour les prototypes de la classe C^j . Si les attributs Y_k et $Y_{k'}$ sont indépendants quelque soit k et k' , on a $P(\mathbf{Y}^{i,j}|C^j) = \prod_{k=1}^d (P(\mathbf{Y}_k^{i,j}|C^j))$.

- J_1 prend sa valeur maximale lorsque les nuages de points représentant les classes ne se chevauchent pas dans l'espace de représentation considéré. Ce critère est donc à maximiser.

En examinant l'exemple de la figure 2.13, nous constatons que la probabilité $P(\text{attribut1} = V(\text{attribut1})|\text{Classe1})$ que l'attribut 1 prenne la valeur $V(\text{attribut1})$, sachant que l'on considère une image de la classe 1, est approximativement égale à $P(\text{attribut1} = V(\text{attribut1})|\text{Classe2})$, la probabilité que l'attribut 1 prenne la valeur $V(\text{attribut1})$, sachant que l'on considère une image de la classe 2, et ce, quelque soit la valeur $V(\text{attribut1})$ que peut prendre l'attribut 1. Ceci implique que, lorsqu'on ne considère que l'attribut 1, la mesure de séparation entre les deux classes D^{12} est approximativement nulle. La valeur du critère J_1 l'est donc également, ce qui correspond à un attribut non consistant.

Par contre, on constate que la probabilité $P(\text{attribut2} \leq 0.5|\text{Classe1})$ que l'attribut 1 ait une valeur inférieure ou égale à 0.5, sachant que l'on considère une image de la classe 1, est très inférieure à $P(\text{attribut2} \leq 0.5|\text{Classe2})$, la probabilité que l'attribut 1 ait une valeur inférieure ou égale à 0.5, sachant que l'on considère une image de la classe 2. Dans ce cas, la distance D^{12} est maximale, ce qui implique que la valeur de J_1 l'est également. On peut en déduire que l'attribut 2 permet de discriminer les deux classes.

Il existe plusieurs mesures de séparation des classes vérifiant ces conditions [NC07] [MBN02]. Nous présentons en annexe B.1 les plus couramment utilisées pour la sélection des attributs, à savoir la distance de Bhattacharyya, de Kullback-Liebler et de Kolmogorov.

Les mesures de consistance permettent de sélectionner des sous-espaces d'attributs pertinents pour la classification. Cependant Dash constate qu'elles imposent un temps de calcul plus important que les autres mesures de type "filter", sans pour autant assurer de meilleures performances [DL97].

2.3.3.3 Mesure d'information

Issues de la théorie de l'information [CT91], les mesures d'information évaluent, de manière globale, le contenu informationnel des attributs via les probabilités *a posteriori* $P(C^j|\mathbf{Y}^{i,j})$ ($P(C^j|\mathbf{Y}^{i,j})$ est la probabilité d'appartenir à la classe C^j étant donné le vecteur d'attributs $\mathbf{Y}^{i,j} = [\mathbf{Y}_1^{i,j}, \dots, \mathbf{Y}_k^{i,j}, \dots, \mathbf{Y}_d^{i,j}]^T$). Lorsque les probabilités *a posteriori* d'appartenance à chacune des classes sont égales, l'information de discrimination qu'apportent les attributs considérés est alors minimale et l'entropie est maximale [BW00].

Il existe différentes mesures d'entropie H , présentées en annexe B.2. Pour chacune de ces mesures d'entropie, on peut définir une fonction d'évaluation à minimiser :

$$J_2(E_d) = \sum_{j=1}^{N_C} \sum_{i=1}^{N_\omega^j} H(\mathbf{Y}^{i,j})P(\mathbf{Y}^{i,j}) \quad (2.2)$$

où $P(\mathbf{Y}^{i,j})$ est la probabilité d'occurrence de $\mathbf{Y}^{i,j} : P(\mathbf{Y}^{i,j}) = \sum_{j'=1}^{N_C} P(C^{j'})P(\mathbf{Y}^{i,j}|C^{j'})$.

Ce type de critère d'évaluation est utilisé par Martins dans le cadre de la classification d'images de texture couleur pour évaluer les sous-espaces générés par un algorithme du type SFFS et ainsi sélectionner un sous-espace d'attributs discriminant [MCB06].

Semani propose également d'évaluer le contenu informationnel des attributs via les probabilités *a posteriori* $P(C^j|\mathbf{Y}^{i,j})$ en définissant un nouveau critère d'évaluation fondé sur ces probabilités, qu'il associe également à l'algorithme séquentiel SFFS [SFC04].

2.3.3.4 Mesure de dépendance entre attributs

Les mesures de dépendance, qui regroupent les mesures de corrélation, sont des cas particuliers des mesures de consistance et d'information [DL97]. Elles ont pour but de quantifier la dépendance des attributs les uns par rapport aux autres.

La mesure de corrélation la plus utilisée est celle proposée par Pearson [GGNZ06] :

Soient deux attributs Y_k et $Y_{k'}$, et leur vecteur des prototypes \mathbf{Y}_k et $\mathbf{Y}_{k'}$ associés ($\mathbf{Y}_k = [\mathbf{Y}_k^{1,1}, \dots, \mathbf{Y}_k^{N_\omega^1,1}, \mathbf{Y}_k^{1,2}, \dots, \mathbf{Y}_k^{N_\omega^{N_C},N_C}]$ et $\mathbf{Y}_{k'} = [\mathbf{Y}_{k'}^{1,1}, \dots, \mathbf{Y}_{k'}^{N_\omega^1,1}, \mathbf{Y}_{k'}^{1,2}, \dots, \mathbf{Y}_{k'}^{N_\omega^{N_C},N_C}]$),

$$J_3(\mathbf{Y}_k, \mathbf{Y}_{k'}) = \frac{\mathbf{cov}(\mathbf{Y}_k, \mathbf{Y}_{k'})}{\sqrt{\mathbf{var}(\mathbf{Y}_k)\mathbf{var}(\mathbf{Y}_{k'})}} \quad (2.3)$$

où \mathbf{cov} est la covariance entre deux attributs :

$$\mathbf{cov}(\mathbf{Y}_k, \mathbf{Y}_{k'}) = \frac{1}{N_C \times N_\omega^j} \times \sum_{j=1}^{N_C} \sum_{i=1}^{N_\omega^j} (\mathbf{Y}_k^{i,j} - m_k)(\mathbf{Y}_{k'}^{i,j} - m_{k'}) \quad (2.4)$$

et \mathbf{var} la variance statistique d'un attribut [Van00] :

$$\mathbf{var}(\mathbf{Y}_k) = \frac{1}{N_C \times N_\omega^j} \times \sum_{j=1}^{N_C} \sum_{i=1}^{N_\omega^j} (\mathbf{Y}_k^{i,j} - m_k)^2 \quad (2.5)$$

Un autre moyen d'évaluer la dépendance entre les attributs est d'utiliser la mesure d'information mutuelle [YL03]. Ce critère d'évaluation à minimiser, noté $J_4(\mathbf{Y}_k, \mathbf{Y}_{k'})$, s'exprime par :

$$J_4(\mathbf{Y}_k, \mathbf{Y}_{k'}) = P(\mathbf{Y}_k, \mathbf{Y}_{k'}) \log \frac{P(\mathbf{Y}_k, \mathbf{Y}_{k'})}{P(\mathbf{Y}_k)P(\mathbf{Y}_{k'})} \quad (2.6)$$

où $P(\mathbf{Y}_k, \mathbf{Y}_{k'})$ est la probabilité conjointe entre les attributs Y_k et $Y_{k'}$ et $P(\mathbf{Y}_k)$, la probabilité d'occurrence de \mathbf{Y}_k .

Si les attributs Y_k et $Y_{k'}$ sont indépendants, on a $P(\mathbf{Y}_k, \mathbf{Y}_{k'}) = P(\mathbf{Y}_k) \times P(\mathbf{Y}_{k'})$ et donc une mesure d'information mutuelle nulle. J_4 est plus robuste que la mesure de corrélation de Pearson car il permet non seulement de quantifier la corrélation entre les attributs, mais également la dépendance statistique entre ces derniers.

L'information mutuelle est utilisée par Celebi dans le cadre de la classification d'images de texture couleur pour évaluer les attributs de texture et les attributs de couleur, destinés à caractériser des lésions cancéreuses [CKU⁺07].

2.3.3.5 Mesure de distance

La mesure de distance, également appelée mesure de séparabilité, consiste à évaluer la compacité et la séparabilité des classes selon le sous-espace d'attributs considéré. Ce type d'évaluation s'inspire en fait du principe de l'analyse factorielle discriminante qui suppose que les classes forment des nuages de points linéairement séparables (c'est-à-dire où il est possible de construire dans l'espace des attributs, des hyperplans séparant les points-image représentatifs des classes prises deux à deux) [Fuk90]. En effet, le but est de rechercher le sous-espace d'attributs pour lequel on obtient à la fois :

- l'inertie inter-classes maximale, afin que les prototypes représentatifs des différentes classes forment dans l'espace de représentation des nuages de points les plus séparés possible les uns des autres,
- et l'inertie intra-classe minimale, afin que les nuages de points représentatifs de chaque classe soient les plus compacts possible.

La figure 2.14 illustre un ensemble de points-image provenant de deux classes et représentés dans deux sous-espaces différents : le premier sous-espace (cf. figure 2.14(a)), formé des attributs 1 et 2 est moins discriminant vis-à-vis des deux classes en présence que le second sous-espace (cf. figure 2.14(b)), composé des attributs 3 et 4.

Cette figure met en évidence que des classes globulaires, qui sont représentées par des nuages de points compacts et bien séparés les uns des autres, facilitent la discrimination et par conséquent la classification.

Pour évaluer les inerties intra et inter-classes, les mesures de distance sont en général basées sur l'évaluation des matrices de covariance intra et inter-classes [Rom73, SFC04] :


- Σ_W , **la matrice de covariance (ou dispersion) intra-classe**¹ (dans le cas où le nombre de prototypes par classe est le même pour toutes les classes) :

$$\Sigma_W = \frac{1}{N_C \times N_\omega^j} \times \sum_{j=1}^{N_C} \sum_{i=1}^{N_\omega^j} (\mathbf{Y}^{i,j} - \mathbf{M}^j)(\mathbf{Y}^{i,j} - \mathbf{M}^j)^T \quad (2.7)$$

avec $\mathbf{M}^j = [m_1^j, \dots, m_k^j, \dots, m_d^j]^T$, le vecteur des centres de gravité des prototypes de la classe C^j :


$$\mathbf{M}^j = \frac{1}{N_\omega^j} \times \sum_{i=1}^{N_\omega^j} \mathbf{Y}^{i,j}, \quad (2.8)$$

1. L'indice w est utilisé pour *within* en anglais.



○ Point-image appartenant à la classe 1 ● Point-image appartenant à la classe 2

(a) Cas d'un sous-espace non discriminant vis-à-vis des classes 1 et 2 : les nuages de points correspondant à chaque classe sont proches et étendus.



○ Point-image appartenant à la classe 1 ● Point-image appartenant à la classe 2

(b) Cas d'un sous-espace discriminant vis-à-vis des deux classes en présence : les nuages correspondant à chaque classe sont compacts et séparés.

Figure 2.14 : Illustration d'un sous-espace non discriminant et d'un sous-espace discriminant vis-à-vis d'une mesure de distance.

où m_k^j est le centre de gravité du $k^{\text{ème}}$ attribut des N_ω^j prototypes de la classe C^j :

$$m_k^j = \frac{1}{N_\omega^j} \times \sum_{i=1}^{N_\omega^j} \mathbf{Y}_k^{i,j}. \quad (2.9)$$

Σ_W représente une mesure de compacité des classes et est donc aussi appelée la **matrice de compacité**.

– Σ_B , la **matrice de covariance (ou dispersion) inter-classe**² (dans le cas où N_ω^j est le

2. L'indice B est utilisé pour *between* en anglais.

même pour toutes les classes) :

$$\Sigma_B = \frac{1}{N_C} \times \sum_{j=1}^{N_C} (\mathbf{M}^j - \mathbf{M})(\mathbf{M}^j - \mathbf{M})^T \quad (2.10)$$

avec $\mathbf{M} = [m_1, \dots, m_k, \dots, m_d]^T$, le vecteur des centres de gravité de tous les prototypes :

$$\mathbf{M} = \frac{1}{N_C} \times \sum_{j=1}^{N_C} \mathbf{M}^j = \frac{1}{N_C \times N_\omega^j} \times \sum_{j=1}^{N_C} \sum_{i=1}^{N_\omega^j} \mathbf{Y}^{i,j}, \quad (2.11)$$

où m_k est le centre de gravité du $k^{\text{ème}}$ attribut des N_ω^j prototypes des N_C classes :

$$m_k = \frac{1}{N_C} \times \sum_{j=1}^{N_C} m_k^j = \frac{1}{N_C \times N_\omega^j} \times \sum_{j=1}^{N_C} \sum_{i=1}^{N_\omega^j} \mathbf{Y}_k^{i,j}. \quad (2.12)$$

Σ_B est associée aux centres de gravité de chacune des classes et représente une mesure de séparabilité des classes. Σ_B est donc aussi appelée la **matrice de séparabilité**.

– Σ_T , la **matrice de covariance (ou dispersion) totale** :

$$\Sigma_T = \Sigma_W + \Sigma_B \quad (2.13)$$

Les principales mesures de distance qui découlent de l'évaluation de ces matrices de covariance intra et inter-classes sont [Van00] :

– **le critère de Wilks** :

$$J_9(E_d) = \frac{|\Sigma_W|}{|\Sigma_T|} \quad (2.14)$$

où $|\Sigma|$ est le déterminant de la matrice Σ .

Ce critère est à minimiser, car lorsque les nuages de points relatifs à chaque classe, projetés dans l'espace d'attributs considéré, sont compacts, l'inertie intra-classe est minimale. Dans ce cas, J_9 est proche de 0.

– **le critère de la trace** :

$$J_{10}(E_d) = \text{Tr}((\Sigma_T)^{-1} \Sigma_B) \quad (2.15)$$

où $\text{Tr}(\Sigma)$ est la trace de la matrice Σ .

Contrairement au critère précédent, le critère de la trace est à maximiser. En effet, lorsque les nuages de points relatifs à chaque classe, projetés dans l'espace d'attributs considéré, forment des ensembles bien séparés les uns des autres, l'inertie inter-classes est maximale. Dans ce cas, J_{10} est proche de 1.

– **le critère de Hotelling** :

$$J_{11}(E_d) = \text{Tr}((\Sigma_W)^{-1} \Sigma_B) \quad (2.16)$$

Ce critère est également à maximiser. En effet, la mesure de l'inertie inter-classes, qui est maximale pour des classes dont les nuages sont bien séparés, se trouve au numérateur, tandis que la mesure de l'inertie intra-classe, qui est minimale pour des classes dont les nuages sont bien compacts, se trouve au dénominateur. Le rapport des dispersions est donc à maximiser pour sélectionner un sous-espace d'attributs le plus discriminant possible.

Vandenbroucke étudie ces différents critères d'évaluation en les associant à une procédure de génération séquentielle SFS afin de sélectionner des attributs statistiques couleur pour la classification de pixels [Van00]. Les résultats obtenus diffèrent très peu par l'utilisation d'un de ces critères.

Pydipati associe quant à lui le critère de Wilks à une procédure de génération SFSS pour sélectionner un sous-espace discriminant dans le cadre de la classification d'images de texture couleur [PBL06].

2.3.3.6 Combinaison de l'approche "wrapper" et de l'approche "filter"

Le critère d'évaluation des approches de type "wrapper" étant le taux d'erreur de classification, cette approche permet de sélectionner le sous-espace d'attributs en fonction des résultats de classification des prototypes.

Cependant, ce qui est vrai pour un algorithme de classification ne l'est pas forcément pour un autre, car la performance obtenue par les méthodes "wrapper" dépend justement de l'algorithme de classification utilisé pour la sélection.

D'autre part, l'utilisation d'une telle méthode d'évaluation nécessite d'effectuer la classification des prototypes pour chaque sous-espace candidat, ce qui est coûteux en temps de calcul, particulièrement lorsque la dimension D de l'espace initial d'attributs est élevée [YL03].

Dans ce cas, il est préférable d'utiliser les approches de type "filter", qui sont moins coûteuses en temps de calcul. Cependant, les taux de classification atteints par les algorithmes de classification opérant dans des espaces sélectionnés par des approches de type "filter" peuvent être plus faibles que pour des espaces sélectionnés par des méthodes d'évaluation de type "wrapper".

Pour répondre au dilemme "taux de classification/temps de calcul" et ainsi combiner les avantages des deux approches, des algorithmes hybrides ont récemment été proposés [ZOD07, Das01, LCWE06] : il s'agit des algorithmes dits "**embedded**".

Dans ce type d'approche, une fonction d'évaluation de type "filter" est tout d'abord utilisée pour pré-sélectionner les sous-espaces d'attributs les plus discriminants pour différentes dimensions d . Puis, les taux d'erreur de classification des prototypes, obtenus en considérant chaque sous-espace discriminant précédemment sélectionné, sont comparés afin de déterminer le sous-espace final $E_{\hat{d}}$.

Les approches "embedded" constituent donc une bonne alternative pour atteindre un compromis entre la qualité de la classification des prototypes dans l'espace retenu et le temps de calcul nécessaire à la sélection des attributs [LCWE06].

Après avoir étudié les différentes approches de génération et d'évaluation, nous allons nous intéresser, dans le paragraphe suivant, aux principaux critères d'arrêt utilisés pour stopper la procédure itérative de sélection d'attributs et fixer ainsi la dimension du sous-espace sélectionné.

2.3.4 Critères d'arrêt

Le critère d'arrêt est un point essentiel d'une procédure itérative de sélection d'attributs. Son choix est très important car la dimension \hat{d} du sous-espace sélectionné en dépend directement ainsi que les taux de classification obtenus ensuite. Cependant ce choix reste très délicat.

Il existe de nombreux critères d'arrêt :

- Certains sont basés sur l'algorithme de génération [ZOD07] : on peut par exemple décider d'arrêter la recherche en fixant une borne sur le nombre d'attributs à sélectionner ou sur le nombre d'itérations. Cependant, dans de nombreuses applications, le nombre d'attributs à sélectionner est très difficile à fixer au préalable. De même, un critère fondé sur un nombre maximal d'itérations peut s'avérer brutal et arrêter trop tôt ou trop tard la sélection [Sem04].
- La plupart des auteurs préfèrent utiliser des critères basés sur l'évaluation [PPL97] : dans ce cas, on arrête la recherche en fixant un seuil soit sur la fonction d'évaluation, soit sur la différence entre la valeur d'évaluation à l'étape d et la valeur d'évaluation à l'étape $d - 1$, c'est-à-dire lorsque l'ajout ou la suppression d'un attribut n'apporte pas un gain de discrimination suffisant. Par exemple, lorsque l'approche "wrapper" ou l'approche "embedded" est utilisée, les taux de bonne classification obtenus par les différents sous-espaces sont comparés pour mesurer le gain d'information. On peut ainsi décider d'arrêter la procédure de sélection dès que ce taux diminue ou alors dès qu'il atteint un certain seuil. Ceci peut être utile pour les applications nécessitant de trouver un bon compromis entre les résultats de classification et la dimension du sous-espace sélectionné, qui va influencer sur le temps nécessaire à la classification en-ligne.

C'est ce type de critère d'arrêt, basé sur l'évaluation, qu'a utilisé Vandembroucke pour sélectionner des attributs de texture couleur pertinents [Van00]. En effet, il propose d'arrêter la procédure de sélection itérative dès que la valeur de la mesure de distance se stabilise.

Mäenpää, dans le cadre de la classification d'images de texture couleur, utilise également ce type de critère d'arrêt en stoppant la procédure de sélection dès que le taux d'images bien classées n'augmente pas de plus de 0.3% entre deux itérations successives.

- Il existe d'autres critères d'arrêt, qui sont quant à eux plus subtils :
 - Stoppiglia propose par exemple d'introduire un "attribut-sonde" parmi l'ensemble initial d'attributs. Dès que cet attribut est sélectionné, la procédure de sélection d'attributs est arrêtée [SDDO03].
 - Tusher utilise quant-à-lui de "faux attributs", créés en mélangeant aléatoirement les valeurs des attributs initiaux. L'introduction de ces "faux attributs" dans une procédure séquentielle de type "forward" ne perturbe pas la sélection car ils peuvent ensuite être écartés pour la classification. Le critère d'arrêt consiste alors à fixer un seuil sur le rapport $\frac{N_F}{N_V}$, N_F étant le nombre de "faux attributs" sélectionnés et N_V , le nombre de "vrais attributs" sélectionnés [TTC01].

Les trois premières phases de la sélection d'attributs viennent d'être présentées. La dernière étape, décrite dans le paragraphe suivant, est la procédure de validation.

2.4 Validation

La validation consiste à tester la pertinence du sous-espace d'attributs déterminé, le plus souvent en estimant l'erreur de classification d'un ensemble d'images test.

L'ensemble des images ξ est pour cela divisé en deux sous-ensembles distincts : un ensemble d'apprentissage Ω constitué des prototypes des classes et un ensemble de test τ . Selon la répartition entre ces deux ensembles, il existe différentes approches de validation. Les approches les plus souvent utilisées en classification d'images de texture couleur sont les suivantes :

- La méthode de **resubstitution** : l'ensemble d'apprentissage est utilisé comme ensemble de test ($\tau = \Omega = \xi$) [Pal04].
- La méthode **Holdout** : il s'agit de partitionner l'ensemble des images ξ en un ensemble d'apprentissage et un ensemble test, en général dans des proportions 1/2, 1/2 pour chacun des deux ensembles ou 2/3 pour l'ensemble d'apprentissage et 1/3 pour l'ensemble test [LM68].

De nombreux auteurs, comme Chindaro, Maënpää, Pietikäinen, Palm, Hiremath et Müntenmayer, utilisent cette partition pour valider leur approche de classification d'images de texture couleur [CSD05, MP04, PMV02, PKLS00, HSP06, MWHW05].

- La méthode **V-validation croisée** : l'ensemble des images est partitionné en V parties de tailles (approximativement) égales. Pour classer une image appartenant à l'un de ces V sous-ensembles, les $(V - 1)$ sous-ensembles restants sont réunis pour former l'ensemble d'apprentissage. On réalise alors V apprentissages, en permutant à chaque fois le sous-ensemble test, pour classer l'ensemble des images [NC03].

La méthode du **Leaving-one-out** est un cas particulier de la V -validation croisée pour lequel V est égal au nombre d'images N_ξ appartenant à l'ensemble ξ . L'ensemble test est alors constitué d'une seule image et la procédure de classification est répétée N_ξ fois,

ce qui la rend très coûteuse en temps de calcul, mais recommandée si l'ensemble ξ est de petite taille [Sem04].

Zheng, Hernandez, Palm, Münzenmayer, Martinez-Alajarin et Van de Wouwer utilisent la méthode du Leaving-one-out pour valider leur approche de classification d'images de texture couleur [ZSZ07, KH06, PL02, dWSLD99, MVK⁺02, MALDTB05].

- La méthode de **rééchantillonnage** ou **Bootstrap** : on tire avec remise, parmi les images présentes dans l'ensemble ξ , un ensemble d'apprentissage de taille N_ξ (une image de ξ peut ne pas appartenir à l'ensemble Ω , ou y figurer plusieurs fois). L'ensemble test utilisé correspond quant-à-lui à l'ensemble d'images ξ lui-même [Sem04].

Une fois la partition de la base d'images fixée, l'apprentissage est effectué avec l'ensemble des prototypes créé à cet effet et l'erreur de classification est mesurée sur l'ensemble test τ .

L'erreur de classification est calculée par le biais d'une méthode de classification. Les paragraphes suivants s'intéressent à ce type de méthodes et particulièrement à celles qui sont les plus couramment utilisées dans le cadre de la classification d'images de texture couleur, à savoir :

- les réseaux de neurones,
- les machines à vecteurs supports,
- la méthode des k plus proches voisins,
- la méthode du plus proche barycentre.

2.4.1 Réseaux de neurones

Les réseaux de neurones, fortement inspirés par le système nerveux biologique, sont composés d'éléments simples, appelés **neurones**, répartis sous forme de couches [Roj96]. Ces éléments sont connectés entre eux par des liaisons affectées de poids (les **synapses**). L'apprentissage de ces poids est effectué de sorte qu'à chaque vecteur d'attributs sélectionné $\hat{\mathbf{Y}}^{i,j}$ présenté à l'entrée du réseau, corresponde en sortie la classe C^j à laquelle le prototype $\omega^{i,j}$ correspondant appartient.

La figure 2.15 illustre la structure d'un neurone artificiel. Chaque neurone reçoit des valeurs provenant des neurones en amont via ses connexions synaptiques et traite ces valeurs via une **fonction de combinaison**. Le résultat de la combinaison est alors transformé par la **fonction d'activation** pour produire sa sortie. Cette fonction permet de seuiller le résultat pour obtenir une sortie binaire.

Le réseau de neurones le plus populaire est le perceptron multicouches (Multi-Layer Perceptron (MLP)). Sa structure est simple : il est constitué de plusieurs couches de neurones (une couche d'entrée, une couche de sortie et une ou plusieurs couches cachées) entièrement connectées entre elles (cf. figure 2.16) [Roj96]. Pour ce type de réseau, la fonction de combinaison renvoie le produit scalaire entre le vecteur des entrées et le vecteur des poids $\mathbf{W} = [\mathbf{W}_1, \dots, \mathbf{W}_d]^T$.

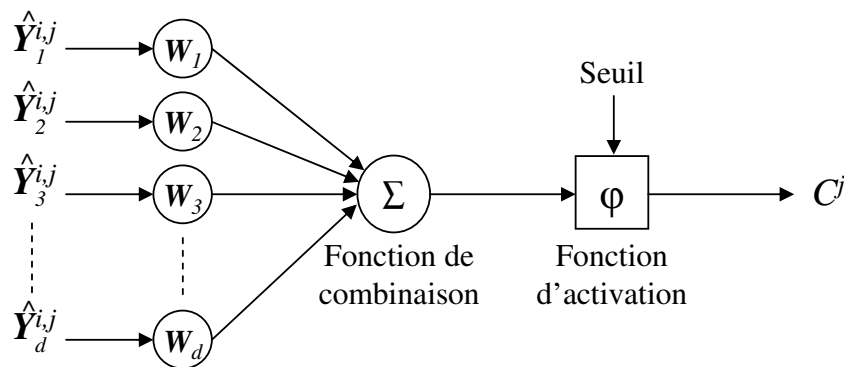


Figure 2.15 : Structure d'un neurone artificiel.




Figure 2.16 : Perceptron multicouches.

Il existe de nombreux autres types de réseaux de neurones disponibles à ce jour, comme par exemple les réseaux à fonction radiale (Radial Basic Functions (RBF)), qui ont pour architecture celle des MLP et pour fonction d'activation une gaussienne, ou encore les réseaux de Hopfield qui permettent un **feed-back** (retour en arrière) [Roj96].

Martinez-Alajarin utilise la méthode de validation du leaving-one-out couplée à la méthode de classification des réseaux de neurones pour valider la réduction d'un espace initial d'attributs de texture couleur [MALDTB05]. Il choisit d'utiliser un perceptron multicouches avec une fonction d'activation de type tangente hyperbolique.

D'autres auteurs, comme Hernandez, Drimbarean et Sengur, ont également utilisé les réseaux de neurones dans le cadre de la classification d'images de texture couleur [HCG⁺05, DW01, Sen08].

2.4.2 Machines à vecteurs supports

La méthode "Machines à vecteurs supports" (Support Vector Machines (SVM)), proposée par Vapnik en 1995 [Vap95], a initialement été définie pour un problème de discrimination à deux classes. De manière simple, il s'agit de construire, dans l'espace des attributs, un hyperplan séparant les points-image représentatifs des prototypes de chacune des deux classes. Cette technique, également appelée méthode des séparateurs à vastes marges, repose sur deux idées clés : la notion de marge maximale et la notion de noyau [RR04].

La **marge** est la distance entre la frontière de séparation (l'hyperplan) et les prototypes les plus proches de cette frontière. Ces prototypes sont appelés **vecteurs supports**. Dans les SVM, la frontière de séparation est choisie comme étant celle qui maximise la marge (cf. figure 2.17) [RR04].




Figure 2.17 : Illustration de la marge maximale et des vecteurs supports qui lui sont associés.

Afin de pouvoir traiter les cas où les nuages de points correspondant à chaque classe ne sont pas linéairement séparables, la deuxième idée clé des SVM est de transformer l'espace des attributs en un espace de dimension plus grande (éventuellement de dimension infinie), dans lequel il est probable qu'une frontière séparatrice linéaire existe [RR04]. Cette transformation non linéaire est réalisée via une fonction dite **noyau**. La figure 2.18 montre l'exemple de la répartition des points-image représentatifs de deux classes, dans l'espace d'attributs initial et dans l'espace d'attributs de plus grande dimension. On remarque que lorsque la dimension de l'espace est faible, il est impossible de déterminer l'hyperplan de séparation qui discrimine les deux classes en présence. Par contre, lorsque les points-prototypes sont représentés dans un espace de dimension supérieure, la construction de la frontière séparatrice linéaire est alors possible.




Figure 2.18 : Illustration du traitement des nuages de points correspondant à chaque classe qui ne sont pas linéairement séparables.

Une fois cette frontière déterminée, la classification d'une image se fait en comparant la position du point représentatif de cette image avec la position de l'hyperplan, dans l'espace des attributs [RR04].


La méthode des SVM a ensuite été étendue à la classification d'images avec un nombre de classes supérieur à 2 [WW99] :

- La méthode "one-versus-all" consiste à construire N_C classifieurs binaires, chacun d'entre eux permettant de distinguer l'une des N_C classes. La figure 2.19 illustre cette méthode : dans cet exemple, les points-prototypes représentatifs de $N_C = 3$ classes sont projetés dans un espace d'attributs de dimension $\hat{d} = 2$. $N_C = 3$ "hyperplans" sont tout d'abord déterminés, chacun d'entre eux permettant la distinction d'une des classes (cf. figure 2.19(a), 2.19(b) et 2.19(c)).


N_C scores positifs ou négatifs sont alors assignés au point-image test selon sa position par rapport aux N_C hyperplans. Si le point-image test se situe du côté des prototypes caractérisant la classe C^j , le score qui lui sera assigné sera positif, tandis que s'il se situe de l'autre côté de l'hyperplan distinguant la classe C^j , le score assigné sera négatif. La figure 2.20 illustre ce propos pour la classe 1.

En phase de test, la classe d'assignation est donnée par le classifieur renvoyant le plus grand score. La figure 2.21 illustre cette classification : la position du point-image test (étiqueté avec un carré rouge) est comparée, dans l'espace d'attributs, à la position des N_C hyperplans. Un score négatif est assigné à cette image par les classifieurs caractérisant les classes 1 et 2, contrairement au score relatif à la classe 3 qui est positif. Cette image est donc assignée à la troisième classe.


- La méthode "one-versus-one" consiste à construire $\frac{N_C(N_C-1)}{2}$ classifieurs binaires afin de confronter les N_C classes deux à deux. La figure 2.22 reprend l'exemple précédent et illustre cette fois-ci la construction des $\frac{N_C(N_C-1)}{2} = 3$ hyperplans destinés à la classification par la méthode "one-versus-one". En phase de test, le point-image à classer est analysé par chaque classifieur et un vote majoritaire permet de déterminer la classe



(a) Construction de l'hyperplan distinguant la classe 1.



(b) Construction de l'hyperplan distinguant la classe 2.



(c) Construction de l'hyperplan distinguant la classe 3.

Figure 2.19 : Construction des $N_C = 3$ hyperplans pour la classification par la méthode "one-versus-all".




Figure 2.20 : Assignment du score selon la position du point-image par rapport à l'hyperplan distinguant la classe C^1 .




Figure 2.21 : Classification par la méthode "one-versus-all".

correspondante. En cas d'égalité, la classe de l'image test est déterminée de manière aléatoire [XWZ⁺08].

La méthode de classification des SVM est utilisée par Iakovidis lors de son étude comparative sur différents attributs de texture couleur pour valider l'ensemble de sa méthode de classification d'images de texture couleur [IMK05].

2.4.3 k plus proches voisins

La méthode des k plus proches voisins (notée k -PPV) fait partie des méthodes de classification les plus couramment utilisées. Elle permet, tout comme les SVM, de traiter des nuages de points non linéairement séparables. A ce titre, elle est souvent exploitée pour valider la sélection dans le cadre de la classification d'images de texture couleur. Cette approche a l'avantage d'être à la fois simple et efficace. Le principe de cette méthode est de mesurer dans l'espace d'attributs sélectionné la similarité entre le point représentant une image test à classer et les points représentant les différents prototypes des classes. Cette similarité est généralement mesurée à l'aide de la distance euclidienne dans l'espace d'attributs considéré [Pal04]. Une fois que les k prototypes les plus proches sont déterminés, on s'intéresse à leur(s) classe(s). L'image test est alors assignée à la classe majoritaire des k -PPV.


L'image 2.23 illustre ce propos avec $k = 5$, pour des points-image projetés dans un espace d'attributs de dimension $\hat{d} = 2$ et pour un nombre de classes $N_C = 2$. Pour classer l'image test, dont le point représentatif dans le sous-espace d'attributs est rouge, on cherche tout d'abord les 5 points-prototypes les plus proches (au sens de la distance euclidienne dans cet exemple). Ces images sont celles présentes dans le cercle rouge centré sur le point représentatif de l'image à classer. Il y a 3 images appartenant à la classe 1 et 2 images appartenant à la classe 2. L'image test est donc assignée à la classe 1.

Dans le cas où il y a égalité, plusieurs solutions sont possibles [SHE07, Bou98] :


- soit l'image test est tout simplement assignée à la classe de l'image la plus proche,
- soit on choisit la classe dont la somme des distances est minimale,
- soit le choix se fait de manière aléatoire.

Le résultat de la discrimination dépend de la valeur de k . C'est pourquoi il est intéressant de faire varier k afin d'obtenir les meilleurs résultats possibles.


Van de Wouwer utilise les k plus proches voisins dans le cadre de la classification d'images de texture couleur pour valider son approche de sélection [dWSLD99]. D'autres auteurs, comme Mäenpää, Pietikäinen, Palm, Arivazhagan, Hiremath et Münzenmayer, ont également utilisé les k -PPV pour valider l'ensemble de leur méthode de classification [MP04, PMV02, PKLS00, AGA05, HSP06, MWHW05].



(a) Construction de l'hyperplan distinguant la classe 1 de la classe 2.



(b) Construction de l'hyperplan distinguant la classe 1 de la classe 3.



(c) Construction de l'hyperplan distinguant la classe 2 de la classe 3.

Figure 2.22 : Construction des $\frac{N_c(N_c-1)}{2} = 3$ hyperplans pour la classification par la méthode "one-versus-one".




Figure 2.23 : Illustration de la méthode des k -PPV avec $k = 5$.

2.4.4 Plus proche barycentre

La méthode des k plus proches voisins a montré à de nombreuses reprises son efficacité. Cependant, cette méthode nécessite de disposer d'un espace mémoire assez important pour y conserver les coordonnées de tous les points-prototypes. D'autre part, la durée de calcul peut être élevée lorsque le nombre de points-prototypes est très important. Dans ce contexte, et lorsque les nuages de points correspondant à chaque classe sont globulaires, il est préférable d'utiliser la méthode de classification par affectation au barycentre le plus proche.

Cette méthode consiste, comme son nom l'indique, à affecter l'image test à la classe dont le barycentre est le plus proche, au sens d'une distance donnée [BZ97].

L'exemple de la figure 2.24, où les points-prototypes représentatifs de $N_C = 2$ classes sont projetés dans un espace d'attributs de dimension $\hat{d} = 2$, illustre ce propos : pour classer l'image test, dont le point-image représentatif est labellisé en rouge, on détermine tout d'abord le barycentre des points-prototypes de chaque classe. La classe correspondant au barycentre le plus proche du point correspondant à l'image test (au sens de la distance euclidienne dans cet exemple) est alors assignée à cette dernière.

Les principales méthodes de classification, utilisées dans le cadre de la classification de textures couleur, pour valider la sélection viennent d'être présentées de manière non exhaustive.

Cependant, pour classer les images, il est également possible de combiner plusieurs classifieurs afin d'obtenir l'avis (les sorties) de plusieurs experts (les classifieurs) [CSD05].

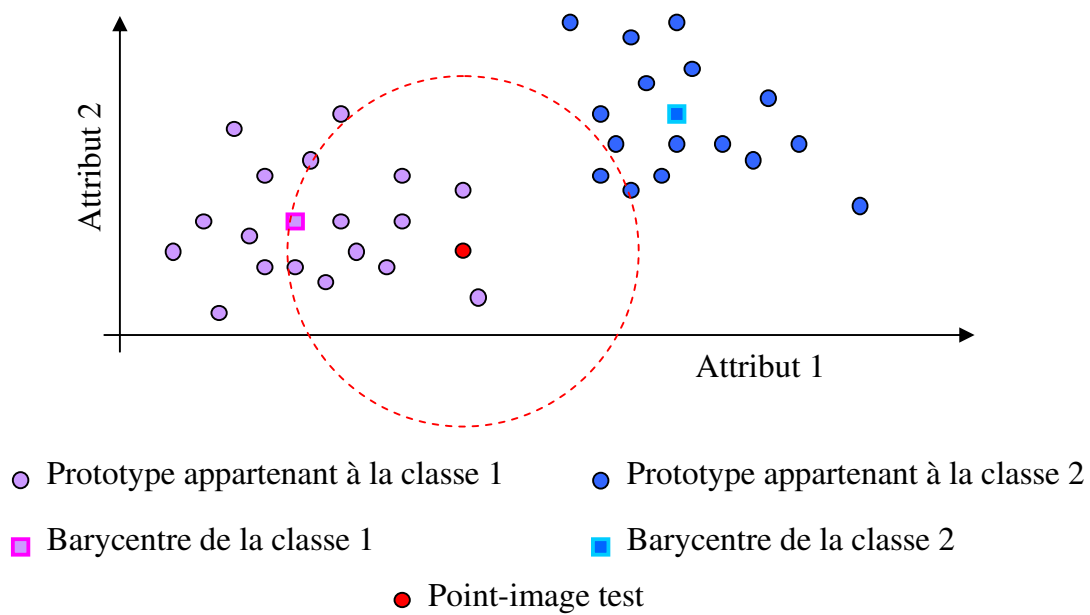


Figure 2.24 : Illustration de la méthode de classification par affectation au barycentre le plus proche.

2.4.5 Combinaison de plusieurs classifieurs

Plusieurs classifieurs peuvent donner des résultats différents sur l'assignation d'une image à une classe donnée. Ceci est dû au modèle de décision qui diffère selon le classifieur considéré [CSD05].

L'utilisation simultanée de plusieurs méthodes et de plusieurs paramétrages permet le plus souvent de cumuler les avantages de chaque classifieur et d'obtenir ainsi un résultat de classification plus performant.

La décision finale peut être obtenue de différentes manières :

- La technique du vote pondéré assigne un poids différent aux résultats, selon qu'ils proviennent d'un classifieur ou d'un autre. Le poids relatif à un classifieur est déterminé par rapport au taux d'erreur obtenu lors de la classification de la base d'apprentissage.
- La méthode du vote à la pluralité choisit au final la classe la plus représentée dans les sorties des différents classifieurs. C'est la méthode employée par Van Den Broek pour combiner les résultats de classification obtenus par une AFD, un réseau de neurones et une classification par les k plus proches voisins [BR04]. En cas d'égalité, le résultat choisi est celui donné par le classifieur qui obtient la meilleure précision (la précision étant le taux de prototypes bien classés) pendant l'apprentissage.
- Une autre solution consiste à effectuer la somme ou le produit des probabilités *a posteriori* associées à chacune des classes d'assignation en sortie des différents classifieurs [GK03]. C'est cette méthode qu'utilise Chindaro pour fusionner les informations prove-

nant de 7 classifieurs 5-PPV différents où les images sont codées dans 7 espaces couleurs différents [CSD05].

2.5 Conclusion

De nombreuses méthodes permettent de réduire la dimension de l'espace d'attributs afin d'améliorer la qualité de la classification. Les principales méthodes viennent d'être présentées, avec une attention particulière pour les méthodes de sélection, qui seront exploitées dans nos travaux. Les travaux traitant de classification d'images de texture couleur, dans lesquels des méthodes de réduction ont été utilisées, sont recensés dans le tableau C.1 de l'annexe C.

Ce tableau montre que le choix de la méthode à utiliser pour réduire la dimension de l'espace d'attributs, dans le cadre de la classification, reste un point délicat car il dépend de différents paramètres.

Tout d'abord, le nombre de prototypes considérés lors de l'apprentissage influe sur le choix de la méthode de réduction. Hua conseille de disposer d'un nombre suffisant de prototypes représentatifs des différentes classes pour utiliser une méthode de type "wrapper" [HTD09].

D'une manière générale, quelque soit la méthode de réduction choisie, il est préférable que le nombre de prototypes soit suffisamment important pour que l'ensemble d'apprentissage soit représentatif des classes en présence [JDM00, BSC09]. En effet, Jain montre que la qualité de la sélection augmente avec ce nombre [JZ97]. Pour cela, il considère des ensembles d'apprentissage de tailles différentes et évalue la qualité des sous-espaces sélectionnés en les comparant au sous-espace optimal préalablement déterminé par une recherche exhaustive. Cette qualité est mesurée en comptant le nombre d'attributs que le sous-espace considéré a en commun avec le sous-espace optimal.

C'est pourquoi, dans le cadre de la classification où les images sont en nombre restreint, de nombreux auteurs sont amenés à diviser les images en imgettes afin de disposer d'un nombre important de prototypes [Pal04, HCG⁺05, KH06, MP04, PMV02, DW01].

D'autre part, le tableau 2.1 présenté dans le paragraphe 2.3.2.4 nous montre que le choix de la méthode de sélection dépend :

- de l'objectif visé, à savoir trouver le sous-espace le plus discriminant de dimension \hat{d} fixée, ou le plus petit sous-espace avec un pouvoir discriminant supérieur à un seuil fixé, ou encore faire un compromis entre \hat{d} et la capacité de discrimination,
- de la dimension initiale D de l'espace d'attributs,
- du caractère monotone de la fonction d'évaluation.

Toutefois, lors du choix de la méthode de sélection, il n'est pas exclu d'adopter plusieurs fonctions d'évaluation pour déterminer le sous-espace d'attributs discriminant. Ce choix multiple permet alors de combiner les points forts relatifs à chaque mesure d'évaluation. C'est ce

que propose Celebi, qui choisit de réduire la dimension $D = 437$ de l'espace initial d'attributs en utilisant une mesure d'information mutuelle et une mesure de corrélation [CKU⁺07]. Vandembroucke choisit également de coupler plusieurs critères d'évaluation pour sélectionner des attributs de texture couleur pertinents [Van00]. En effet, il effectue à chaque itération de la procédure de sélection une mesure de corrélation entre chaque attribut candidat à la sélection et les attributs déjà sélectionnés. Si le niveau de corrélation est inférieur à un seuil fixé par l'utilisateur, le sous-espace formé par l'attribut candidat et les attributs déjà sélectionnés sera alors évalué par une mesure de distance [VMP00b].

Nous verrons dans le chapitre suivant que nous adopterons également plusieurs fonctions d'évaluation pour déterminer un sous-espace d'attributs discriminant.

Enfin, la construction des ensembles d'images d'apprentissage et d'images test est liée à la fonction d'évaluation retenue et à l'étape de validation. Nous verrons au chapitre suivant qu'il est nécessaire de construire avec soin ces deux ensembles afin que le sous-espace d'attributs retenu permette d'obtenir les meilleurs taux de bonne classification possibles.

De manière générale, c'est la méthode globale de classification qui sera présentée dans ce prochain chapitre, en justifiant les choix portant sur les différents éléments composant cette méthode.

Chapitre 3

Sélection d'attributs de texture couleur pour la classification d'images

3.1 Introduction

Dans ce chapitre, nous présentons la méthodologie de classification supervisée de textures couleur que nous avons développée. Dans un contexte industriel, cette méthodologie se décompose en deux phases : une phase d'apprentissage qui s'effectue hors-ligne et une phase de classification qui s'effectue en-ligne. Lors de la phase d'apprentissage hors-ligne, des attributs de texture couleur, parmi ceux présentés dans le chapitre 1, sont tout d'abord générés à partir d'images prototypes. Puis, l'espace d'attributs résultant est réduit grâce à l'une des méthodes de sélection présentées dans le chapitre 2. Cet apprentissage détermine un sous-espace d'attributs qui permet de discriminer les classes d'images de texture en présence. Lors de la phase de classification en-ligne, chaque image considérée est projetée dans ce sous-espace discriminant afin de déterminer sa classe d'appartenance. La figure 3.1 rappelle le processus de classification supervisée d'images de texture couleur.

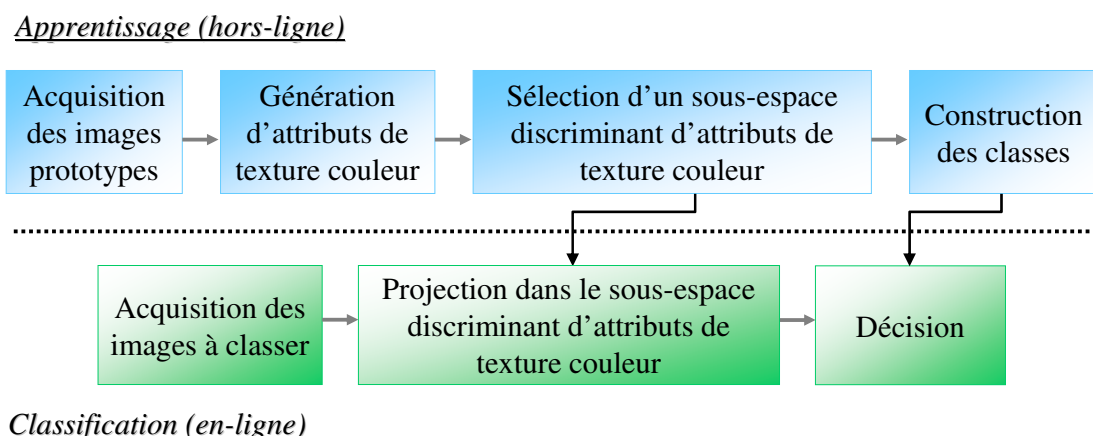


Figure 3.1 : Sélection d'attributs de texture couleur pour la classification supervisée d'images.

Les nombreux paramètres qui interviennent dans une méthode de classification supervisée d'images doivent être correctement ajustés. En effet, ils influencent non seulement les temps de traitement mais également la qualité de la classification. La synthèse des travaux portant sur la classification de textures couleur présentée en annexe C conforte cette idée. En effet, à chaque étude présentée dans cette synthèse correspond une combinaison de paramètres qui définit la méthode de classification de textures couleur utilisée et chaque combinaison induit une performance de classification particulière. L'analyse de chaque paramètre de la méthode proposée est donc importante en vue d'un choix adapté à l'application considérée.

C'est pourquoi, dans ce chapitre, nous accentuerons principalement notre analyse sur trois points, à savoir :

- l'espace couleur considéré,
- le type d'attributs de texture couleur,
- et la méthode de sélection.

En effet, c'est sur ces trois points qu'intervient notre contribution, et les choix effectués sur ces derniers constituent les principales originalités de nos travaux.

L'objectif de ces travaux étant de proposer une méthodologie de classification de textures couleur qui puisse être appliquée à des problématiques industrielles, il est nécessaire que la méthode développée soit performante en termes de qualité de classification et de temps de traitement.

Pour répondre au critère de performance sur les contraintes temporelles, nous proposons d'une part de réduire le nombre de couleurs présentes dans l'image analysée pour y extraire les attributs de texture couleur, et d'autre part de réduire le nombre de ces attributs grâce à une procédure de sélection séquentielle.

Cette procédure de sélection permet également de répondre au critère de performance sur la qualité de la classification. En effet, afin de disposer d'une description des textures couleur qui soit la plus complète possible, nous proposons d'extraire les attributs à partir d'images codées dans différents espaces couleur, afin de tenir compte de l'ensemble de leurs propriétés. La procédure de sélection permet alors de ne retenir que les attributs les plus pertinents au regard de l'application considérée, ce qui améliore la qualité de la classification.

Ainsi, dans le paragraphe 3.2, nous allons mettre en évidence l'intérêt d'utiliser une approche multi-espaces couleur pour obtenir une description plus complète des classes d'images de texture, par rapport à celle obtenue en ne considérant qu'un unique espace. Puis, dans le paragraphe 3.3, nous justifierons l'intérêt d'examiner les attributs d'Haralick extraits des matrices de co-occurrences chromatiques. Enfin, le paragraphe 3.4 présentera les différentes raisons qui nous ont amené à considérer une méthode de sélection de type "embedded" pour construire un sous-espace d'attributs discriminant.

Une fois ces différents points analysés, la méthode de classification de textures couleur mise en oeuvre sera présentée dans le paragraphe 3.5.

3.2 Approche multi-espaces couleur

Nous avons vu au paragraphe 1.3.2 que l'exploitation de la couleur permet d'améliorer les résultats en termes de classification d'images de texture couleur comparée à l'analyse de la seule information de luminance.

Pour rappel, la couleur de chaque pixel peut non seulement être représentée dans l'espace d'acquisition (R, G, B) mais également dans d'autres espaces couleur, qui possèdent chacun des propriétés particulières (cf. annexe A). Les valeurs des attributs de texture couleur dépendent donc de l'espace couleur retenu. Par conséquent, le choix de cet espace va influencer la qualité de la discrimination des classes en présence [Van00]. Se pose alors le problème de la détermination de l'espace couleur le mieux adapté à la discrimination de ces classes.

Au sein du paragraphe 3.2.1, nous analysons les travaux portant sur la classification de textures couleur où différents espaces couleur ont été utilisés pour discriminer les classes d'images de texture en présence. La synthèse de ces travaux nous conduira à considérer plusieurs espaces couleur, présentés au paragraphe 3.2.2, pour analyser les textures. Dans le paragraphe 3.2.3.1, nous verrons alors comment la couleur doit être codée pour adopter cette approche multi-espaces couleur. Enfin, nous présenterons dans le paragraphe 3.2.3.2 les méthodes de sous-quantification des composantes couleur qui s'avèreront utiles pour réduire le temps de calcul des attributs grâce à la réduction du nombre de couleurs présentes dans une image.

3.2.1 Choix de l'espace couleur

Certains auteurs travaillant sur la classification d'images de texture couleur ont comparé les résultats de classification obtenus en considérant différents espaces couleur, afin de déterminer le plus pertinent pour leur application :

- Palm effectue une comparaison des performances atteintes par l'analyse des attributs d'Haralick calculés avec des images codées dans deux espaces couleur différents (les espaces (R, G, B) et (L, U, V)). Il utilise la méthode de classification des k plus proches voisins avec $k = 5$ et met en évidence que l'espace (L, U, V) est mieux adapté que l'espace (R, G, B) à la discrimination des textures couleur des bases VisTex et BarkTex [Pal04].
- Van Den Broek suit une démarche similaire à la différence qu'il considère différents niveaux de quantification pour coder les matrices de co-occurrences dont sont extraits les indices d'Haralick. Pour évaluer la qualité de l'analyse des textures couleur de la base VisTex, il utilise une combinaison de trois classifieurs (AFD + Réseaux de neurones + 1-PPV) [BR04]. Il compare les performances atteintes par le biais de 6 espaces couleur différents (les espaces (R, G, B) , (H, S, V) , (Y', U', V') , (Y', I', Q') , (X, Y, Z) et (L^*, u^*, v^*)) et conclut que l'utilisation de l'espace (H, S, V) permet d'obtenir de meilleurs résultats en termes de classification d'images de texture couleur.

- Mäenpää présente les résultats de classification obtenus à l'aide de la méthode 1-PPV et de deux approches différentes pour caractériser les textures couleur des bases VisTex et OuTex :
 - les histogrammes des LBP,
 - les attributs extraits de la transformée de Gabor.
 Il montre que parmi les espaces (R, G, B) , (r, g, b) , (H, S, V) , (L^*, a^*, b^*) et $(I1, I2, I3)$, ce sont les espaces (L^*, a^*, b^*) et (R, G, B) qui permettent d'obtenir respectivement les meilleurs résultats de classification, lorsque les bases VisTex et OuTex sont caractérisées par des attributs de texture couleur [MP04].
- Drimbarean effectue la classification des images de la base VisTex à l'aide d'un réseau de neurones et utilise la transformée en cosinus discrète couleur pour caractériser les différentes classes d'images de texture [DW01]. Il met en évidence que l'espace (Y', I', Q') permet d'obtenir de meilleurs résultats que les espaces (R, G, B) , (X, Y, Z) , (L^*, a^*, b^*) et (H, S, I) .
- Hiremath analyse les résultats de classification des textures de la base VisTex obtenus en utilisant la méthode des k plus proches voisins avec $k = 3$ et les ondelettes comme attributs de texture couleur [HSP06]. Il en conclut que parmi les espaces (R, G, B) , (H, S, V) et (Y, Cb, Cr) , c'est l'espace (R, G, B) qui permet d'obtenir les meilleurs taux d'images bien classées.
- Sengur effectue une comparaison des performances atteintes par des attributs extraits de la transformée en ondelettes et calculés avec des images codées dans deux espaces couleur différents (les espaces (R, G, B) et $(I1, I2, I3)$). Pour évaluer la qualité de l'analyse des textures couleur de la base VisTex, il utilise les réseaux de neurones et met en évidence que l'espace $(I1, I2, I3)$ est mieux adapté que l'espace (R, G, B) à la discrimination de ces textures couleur [Sen08].
- Van de Wouwer caractérise les différentes classes d'images de la base VisTex grâce à des attributs pertinents extraits de la transformée en ondelettes, sélectionnés par une procédure de génération séquentielle SFFS associée à une mesure du taux d'erreur de classification. Il effectue la classification de ces images par le biais de la méthode des k -PPV et met en évidence que l'espace $(I1, I2, I3)$ permet d'obtenir de meilleurs résultats que les espaces (U, V, W) et (Y', I', Q') [dWSLD99].
- Xu effectue la classification des images de la base OuTex à l'aide de la méthode de classification des k plus proches voisins avec $k = 7$ et utilise des attributs extraits de la transformée en ondelettes pour caractériser les différentes classes de texture. Il met en évidence que l'espace (R, G, B) permet d'obtenir de meilleurs résultats que l'espace $(I1, I2, I3)$ [XYD05].

- Arivazhagan analyse les résultats de classification des textures de la base VisTex obtenus en utilisant la méthode des k plus proches voisins avec $k = 1$ et des attributs de texture couleur extraits de la transformée en ondelettes et des matrices de co-occurrences chromatiques. Il en conclut que parmi les espaces (H, S, I) et (Y', U', V') , c'est l'espace (Y', U', V') qui permet d'obtenir les meilleurs taux d'images bien classées [AGA05].
- Lopez considère des attributs statistiques de texture couleur du premier ordre, sélectionnés par une procédure de génération séquentielle SFS associée à une mesure du taux d'erreur de classification, pour caractériser différentes classes de textures de céramique [LVPF08]. Il utilise la méthode des k plus proches voisins avec $k = 1$ afin de comparer les performances atteintes par le biais de 3 espaces couleur différents (les espaces (R, G, B) , (L^*, u^*, v^*) et (L^*, a^*, b^*)) et conclut que l'utilisation de l'espace (L^*, a^*, b^*) permet d'obtenir de meilleurs résultats en termes de classification d'images de texture couleur.
- Martinez caractérise différentes classes de texture de marbre grâce à un sous-espace d'attributs pertinents extraits des histogrammes des sommes et des différences intra-composante et sélectionnés par ACP. Il effectue la classification de ces images par le biais d'un réseau de neurones et met en évidence que l'espace $(I1, I2, I3)$ permet d'obtenir de meilleurs résultats que les espaces (R, G, B) , (Y', I', Q') et (X_F, Y_F, Z_F) [MALDTB05].
- Iakovidis présente les résultats de classification obtenus à l'aide des SVM et de quatre approches différentes pour caractériser les textures couleur des bases VisTex et OuTex :
 - les histogrammes des LBP avec l'attribut de contraste,
 - les histogrammes des LBP sans l'attribut de contraste,
 - les moments chromatiques,
 - les attributs extraits de la transformée en ondelette.
 Il montre que parmi les espaces (R, G, B) , (H, S, V) , (L^*, a^*, b^*) et $(I1, I2, I3)$, ce sont globalement les espaces $(I1, I2, I3)$ et (H, S, V) qui permettent d'obtenir respectivement les meilleurs résultats de classification pour les bases VisTex et OuTex [IMK05].
- Akhloufi effectue une comparaison des performances atteintes par des attributs extraits des matrices de co-occurrences chromatiques intra-composante associés à une statistique d'image (entropie) et calculés avec des images codées dans trois espaces couleur différents (les espaces (R, G, B) , (H, S, L) et (L^*, a^*, b^*)) [AML08]. Pour évaluer la qualité de l'analyse de textures de bardeaux, il utilise la méthode de classification des k -PPV, avec $k = 1$ et met en évidence que l'espace (R, G, B) est le mieux adapté.
- Chindaro effectue une comparaison des performances atteintes par des attributs estimés à partir du modèle de Markov et calculés avec des images codées dans différents espaces couleur (les espaces (R, G, B) , (r, g, b) , (L^*, a^*, b^*) , (H, S, V) , (Y', I', Q') et (Y', U', V')).

Il utilise la méthode de classification des k plus proches voisins avec $k = 7$ et met en évidence que l'espace (H, S, V) permet d'obtenir de meilleurs résultats en termes de classification d'images de texture couleur des bases VisTex et Texture Library [CSD05].

La synthèse de ces travaux montre que le choix de l'espace couleur dépend de différents paramètres :

- Tout d'abord, les conclusions de Mäenpää montrent que le choix de l'espace couleur dépend de la base d'images utilisée et donc de l'application considérée. En effet, il utilise la même méthode pour classer les textures couleur de la base VisTex et celles de la base OuTex. Il montre alors que pour la base VisTex, l'espace (L^*, a^*, b^*) permet d'obtenir de meilleurs résultats que l'espace (R, G, B) , et inversement lorsqu'il s'agit de classer les images de la base OuTex [MP04].
- D'autre part, le choix de l'espace couleur dépend également du type d'attributs et de la méthode de classification choisis pour classer les images de texture couleur. En effet, on remarque une divergence entre la conclusion de Van Den Broek et celle d'Hiremath quant au choix de l'espace couleur le plus pertinent pour caractériser les textures de la base VisTex [BR04, HSP06]. Hiremath exploite les coefficients de la transformée en ondelettes pour classer les textures par la méthode des k plus proches voisins (avec $k = 3$). Il conclut que l'espace (R, G, B) est plus pertinent que les espaces (H, S, V) et (Y, Cb, Cr) . Cette conclusion diffère de celle obtenue par Van Den Broek, qui considère les indices d'Haralick extraits de matrices de co-occurrences et exploités par une combinaison de trois classifieurs [BR04]. En effet, il compare les performances atteintes par le biais de 6 espaces couleur différents (les espaces (R, G, B) , (H, S, V) , (Y', U', V') , (Y', I', Q') , (X, Y, Z) et (L^*, u^*, v^*)) et conclut que l'utilisation de l'espace (H, S, V) permet d'obtenir de meilleurs résultats en termes de classification de textures couleur.

Ces travaux montrent également qu'il n'existe pas d'espace couleur adapté à toutes les applications, puisque les auteurs proposent d'utiliser des espaces différents. Cette conclusion quant au choix de l'espace couleur rejoint celles formulées dans le cadre de la segmentation d'images couleur [BVM08a, Van00, VMP03].

Dans la plupart des applications de classification de textures, l'espace couleur est préalablement choisi de manière unique et seules les propriétés de cet espace sont exploitées. Des solutions sont néanmoins proposées par Chindaro, Charrier ou Vandembroucke afin de tenir compte des propriétés de plusieurs espaces couleur :

- Afin de prendre en compte de manière globale les propriétés de 7 espaces couleur, Chindaro propose de fusionner les informations provenant de 7 classifieurs différents où les images sont codées dans chacun des 7 espaces couleur [CSD05].
- Une approche similaire est proposée par Charrier dans le cadre de la segmentation d'images couleur par classification de pixels [CLL07].
- De la même manière, Vandembroucke propose de sélectionner des attributs statistiques,

Notations	Définition
(R, G, B)	Espace d'acquisition des images
(X, Y, Z)	Espace de référence colorimétrique de la CIE
(x, y, z)	Espace de référence colorimétrique normalisé de la CIE
(r, g, b)	Espace de primaires normalisées rouge, vert et bleu
(A, C_1, C_2)	Espace antagoniste défini par Faugeras et Garbay
(bw, rg, by)	Espace antagoniste défini par Ballard
(Y', I', Q')	Espace de télévision répondant à la norme NTSC
(Y', U', V')	Espace de télévision répondant à la norme PAL
(L^*, a^*, b^*)	Espace perceptuellement uniforme CIELAB
(L^*, u^*, v^*)	Espace perceptuellement uniforme CIELUV
(Y, Ch_1, Ch_2)	Espace luminance-chrominance défini par Carron
(Y, x, y)	Espace luminance-chrominance défini à partir des systèmes (x, y, z) et (X, Y, Z)
$(I1, r, g)$	Espace luminance-chrominance défini à partir des systèmes (r, g, b) et (R, G, B)
$(I1, I2, I3)$	Espace d'axes indépendants d'Ohta
(A, C_{C1C2}, h_{C1C2})	Espace de coordonnées polaires défini à partir du système (A, C_1, C_2)
(bw, C_{rgby}, h_{rgby})	Espace de coordonnées polaires défini à partir du système (bw, rg, by)
(Y', C_{IQ}, h_{IQ})	Espace de coordonnées polaires défini à partir du système (Y', I', Q')
(Y', C_{UV}, h_{UV})	Espace de coordonnées polaires défini à partir du système (Y', U', V')
(L^*, C_{ab}^*, h_{ab})	Espace de coordonnées polaires de la CIE défini à partir du système (L^*, a^*, b^*)
(L^*, C_{uv}^*, h_{uv})	Espace de coordonnées polaires de la CIE défini à partir du système (L^*, u^*, v^*)
$(L, C_{Ch1Ch2}, h_{Ch1Ch2})$	Espace de coordonnées polaires défini à partir du système (Y, Ch_1, Ch_2)
$(I1, C_{I2I3}, h_{I2I3})$	Espace de coordonnées polaires défini à partir du système $(I1, I2, I3)$
(L^*, S_{uv}^*, h_{uv})	Espace de coordonnées perceptuelles de la CIE défini à partir du système (L^*, u^*, v^*)
$(I1, S1, H1)$	Espace de coordonnées perceptuelles défini à partir du modèle de triangle avec minimum
$(I1, S2, H1)$	Espace de coordonnées perceptuelles défini à partir du modèle de triangle
$(I4, S3, H2)$	Espace de coordonnées perceptuelles défini à partir du modèle de cône hexagonal
$(I5, S4, H2)$	Espace de coordonnées perceptuelles défini à partir du modèle de cône hexagonal double
$(I1, S1, H3)$	Espace de coordonnées perceptuelles défini par Liang

Tableau 3.1 : Espaces couleur considérés.

calculés à partir de composantes couleur issues de différents espaces couleur [Van00].

C'est pourquoi nous proposons d'adopter ces démarches en choisissant de considérer une approche multi-espaces couleur pour analyser les textures.

3.2.2 Les 28 espaces couleur considérés

L'utilisation de plusieurs espaces couleur permet une description exhaustive des textures couleur car les propriétés de chaque espace couleur sont susceptibles d'être exploitées.

L'annexe A présente les différentes familles et sous-familles d'espaces couleur décrites dans la littérature. Parmi l'ensemble de ces espaces couleur, nous choisissons de considérer les $N_E = 28$ espaces présentés dans le tableau 3.1. L'**illuminant**¹ utilisé pour définir ces espaces est l'illuminant D_{65} , qui correspond à la lumière moyenne du jour.

La figure 3.2 illustre la répartition de ces différents espaces dans les familles et sous-familles qui leur sont associées, ainsi que les différentes passerelles qui existent entre ces es-

1. Certaines sources lumineuses correspondant à des conditions d'observation courantes ont été normalisées par la CIE (Commission Internationale de l'Eclairage) sous le nom d'illuminant [VM05]

paces. En effet, pour chacun de ces espaces, il existe une relation, linéaire ou non, permettant de transformer la couleur codée dans l'espace d'acquisition (R, G, B) vers un codage dans un autre espace de représentation de la couleur. Toutes ces relations sont définies dans la publication [VM05].

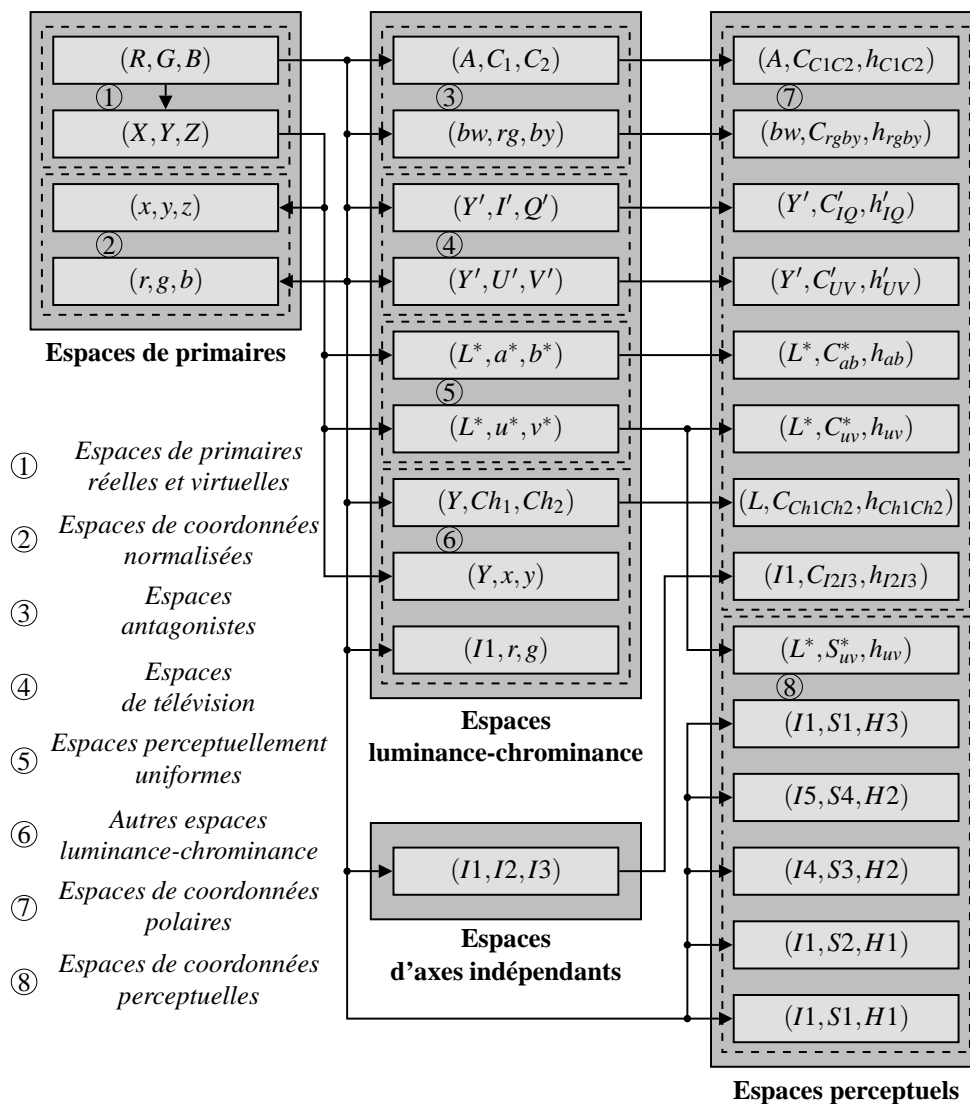


Figure 3.2 : Les $N_E = 28$ espaces couleur considérés pour caractériser les textures couleur.

Le choix de considérer ces 28 espaces fait suite aux travaux menés au laboratoire LAGIS par Vandenbroucke et Busin, qui ont recensé ces espaces couleur comme étant les plus souvent utilisés dans les problèmes d'analyse d'images couleur [Bus06, VMP00b, VMP03, Van00, BVMP05].

Cependant, cette considération multiple pose le problème du codage de la couleur abordé dans le paragraphe suivant.

3.2.3 Codage et quantification de la couleur

3.2.3.1 Codage de la couleur

La couleur des pixels d'une image est définie par trois composantes qui appartiennent à l'intervalle de valeurs entières non signées $[0, N - 1] \times [0, N - 1] \times [0, N - 1]$ (avec N , le niveau de quantification considéré). Or, le codage d'une image dans un autre espace couleur soulève le problème de la dynamique des valeurs transformées. En effet, si les composantes trichromatiques d'une couleur varient entre 0 et $N - 1$, il n'en est pas forcément de même lorsqu'elles ont subi une transformation. Il se peut qu'une valeur transformée soit supérieure à $N - 1$ ou inférieure à 0 et qu'elle appartienne alors à un intervalle de valeurs réelles signées [Van00].

Or, le calcul de certains descripteurs de texture couleur, comme les histogrammes des LBP ou les matrices de co-occurrences, nécessite que les composantes couleur des pixels soient quantifiées entre 0 et $N - 1$.

Pour respecter cette contrainte, il est nécessaire de réaliser un **codage** des espaces couleur de telle sorte que la dynamique des composantes soit identique quelque soit l'espace couleur considéré et afin que les propriétés relatives à chaque espace soient conservées [VMP00a].

Le codage d'un espace couleur s'effectue alors selon les étapes successives suivantes [Van00] :

- Décaler les valeurs des composantes de telle sorte qu'elles soient non signées. Cette opération nécessite de connaître la valeur minimale que peut prendre chacune des composantes de l'espace considéré.
- Normaliser les valeurs décalées des composantes de telle sorte qu'elles appartiennent à l'intervalle $[0, N - 1]$. Cette opération nécessite de connaître la dynamique de chacune des composantes de l'espace considéré, c'est-à-dire leurs valeurs minimales et maximales.
- Arrondir ou tronquer les valeurs décalées et normalisées des composantes afin d'obtenir des valeurs entières.

Ce processus de codage d'un espace couleur dépend de la famille d'espaces à laquelle il appartient [Van00]. L'annexe A indique comment les espaces couleur sont regroupés par familles en fonction de leurs propriétés. Ainsi, les espaces de primaires sont formés de composantes qui représentent la couleur selon le principe de la trichromie. Les espaces de luminance-chrominance séparent la couleur en une composante achromatique dite de "luminance" et en deux composantes de chrominance. Les espaces perceptuels caractérisent la couleur en trois composantes subjectives considérées indépendantes les unes des autres et les espaces d'axes indépendants décorrèlent les composantes couleur.

La majorité de ces espaces couleur sont définis en prenant comme hypothèse que la couleur est représentée par trois entités non dissociables qui respectent des propriétés physiques, psychologiques ou physiologiques. Dans ce cas, le codage doit donc être réalisé en considérant

l'ensemble des trois composantes couleur représentées dans un système de coordonnées cartésiennes, ce qui correspond à un **codage non séparé** [Van00].

Par contre, ce codage ne peut pas s'appliquer aux espaces perceptuels dont les composantes sont indépendantes et représentées dans un système de coordonnées polaires. Nous leur appliquons donc un **codage séparé** où les valeurs de normalisation et de décalage sont évaluées séparément pour les trois composantes [Van00].

Une présentation plus approfondie de ces deux codages est présentée en annexe D.

Peu d'auteurs ont abordé le problème lié au codage des espaces couleur dans le cadre de la classification d'images de texture couleur. Seuls Burks, ainsi que Martinez-Alajarin, qui utilisent respectivement l'espace (H, S, I) et les espaces (R, G, B) , (Y', I', Q') , (X, Y, Z) et (I_1, I_2, I_3) , soulignent qu'ils effectuent une "mise à l'échelle" pour ajuster les valeurs des composantes couleur, sans pour autant préciser comment est effectuée cette mise à l'échelle [BSP00] [MALDTB05]. Or, ne pas tenir compte d'un codage adapté à chaque espace peut provoquer la modification des propriétés de l'espace considéré.

3.2.3.2 Quantification des composantes couleur

En général, les composantes couleur des pixels sont codées sur 8 bits, ce qui correspond au niveau de quantification $N = 2^8 = 256$. Il est parfois utile de réduire le nombre de couleurs présentes dans une image, notamment si l'on désire réduire le temps de calcul de certains attributs. On effectue pour cela une **sous-quantification** des composantes couleur de l'image.

On distingue principalement deux catégories de sous-quantification : la sous-quantification statique (ou uniforme) et la sous-quantification dynamique [TFMB04].

La première méthode consiste à discrétiser uniformément les composantes couleur d'un espace, comme le montre la figure 3.3, qui illustre cette opération pour passer de $N = 256$ niveaux à $N = 32$.




Figure 3.3 : Sous-quantification uniforme pour passer de $N = 256$ niveaux à $N = 32$.

Cette opération est effectuée en supprimant autant de bits de poids faible que nécessaire pour atteindre le niveau de quantification voulu.

La sous-quantification dynamique consiste quant-à-elle à discrétiser l'espace couleur de manière adaptative, c'est-à-dire en fonction des couleurs les plus présentes dans l'image [TFMB04].

De nombreux auteurs ont montré qu'il est possible d'utiliser la méthode de sous-quantification uniforme pour réduire le temps de calcul des attributs qu'ils considèrent :

- Van Den Broek ou Van Rikxoort utilisent les attributs d'Haralick extraits des matrices de co-occurrences chromatiques intra-composantes pour caractériser les textures couleur de la base VisTex après avoir sous-quantifié de manière uniforme les composantes couleur des images analysées [BR04, Rik04].
- Burks utilise également ces attributs et cette méthode de sous-quantification pour caractériser des textures d'herbes [BSP00].
- Enfin, Arvis montre que les attributs d'Haralick extraits des matrices de co-occurrences chromatiques peuvent être appliqués aux problèmes de classification en temps réel lorsqu'une sous-quantification préalable des composantes couleur de l'image analysée est effectuée [ADBB04].

Comme l'objectif de nos travaux est de développer une méthode de classification de textures couleur qui puisse être appliquée à des problématiques industrielles, il semble intéressant d'examiner l'apport que pourrait amener la quantification uniforme des composantes couleur en terme de temps de traitement sans dégrader la qualité de la classification. C'est ce que nous proposons d'évaluer dans le paragraphe 3.3.3.

3.2.4 Conclusion

L'étude des différents travaux menés dans le cadre de la classification de textures couleur montre d'une part qu'il n'existe pas un espace couleur unique adapté à toutes les applications et d'autre part, que les algorithmes proposés n'exploitent les propriétés que d'un seul espace couleur choisi préalablement. C'est pourquoi, nous proposons de considérer un ensemble de $N_E = 28$ espaces couleur afin de tirer avantage de toutes les propriétés de ces espaces.

Après avoir présenté les points liés à la représentation multi-espaces des couleurs présentes dans les images, à savoir le codage relatif à chaque espace et la quantification des composantes couleur, nous présentons dans le paragraphe suivant les attributs de texture couleur qui vont être utilisés dans notre approche.

3.3 Attributs de texture couleur retenus

Les principaux attributs utilisés dans le cadre de la classification de textures couleur ont été présentés dans le chapitre 1. La conclusion de ce chapitre a mis en évidence que le choix de ces attributs est un des points délicats dans l'élaboration d'une stratégie pour la classification.

Le paragraphe 3.3.1 s'intéresse aux nombreux critères retenus pour choisir les attributs de texture couleur en fonction de la stratégie que nous désirons adopter, à savoir appliquer notre méthode dans un contexte industriel. Nous verrons que la principale contrainte liée à cette application est d'atteindre un compromis entre les résultats de classification et les temps d'exécution. Le paragraphe 3.3.2 s'intéressera donc aux travaux portant sur les systèmes d'analyse de tex-

tures couleur destinées aux applications industrielles. La synthèse de ces travaux permettra au paragraphe 3.3.3 de préciser les attributs de texture couleur considérés par la méthode de classification supervisée que nous avons développée.

3.3.1 Critères de choix des attributs de texture couleur

Le paragraphe 1.10 a permis de mettre en évidence les principaux critères suivants qui influencent le choix des attributs de texture couleur à considérer :

- les textures à discriminer,
- les contraintes liées à l'application, à savoir les conditions d'acquisition des images, les conditions d'observation des textures et les temps d'exécution requis par l'apprentissage hors-ligne et par la classification en-ligne.

Nous choisissons de motiver le choix des attributs de texture couleur vis-à-vis d'une application en milieu industriel. Dans ce contexte, il est préférable de considérer des attributs capables de caractériser tous les types de textures. Les attributs géométriques sont donc exclus car ils sont, de part leur définition, adaptés aux textures observées à un niveau macroscopique (cf. § 1.6).

En ce qui concerne les conditions d'acquisition, nous faisons l'hypothèse qu'elles sont contrôlées, ce qui est généralement le cas en milieu industriel. Par contre, il est préférable de considérer des attributs invariants aux transformations engendrées par la modification des conditions d'observation, telles que la rotation et la translation.

Enfin, les applications industrielles imposent généralement le respect d'une cadence élevée de production. Ceci implique une courte durée dédiée à la classification en-ligne. Il semble donc opportun de ne considérer que des attributs de texture couleur peu coûteux en temps de calcul.

Mis à part les attributs géométriques, de nombreux attributs de texture couleur semblent être appropriés pour caractériser n'importe quel type de texture, dans des conditions d'acquisition et d'observation contrôlées. Il reste donc à choisir parmi ces attributs, ceux qui offrent le meilleur compromis entre les résultats de classification et les temps de calcul.

3.3.2 Attributs de texture utilisés pour des applications industrielles

Divers travaux ont été menés sur l'analyse de textures couleur destinée à des applications industrielles [LVPF08, MVP03, ADBB04, MALDTB05, PS04, XM07]. Trois stratégies de caractérisation de textures couleur, présentées dans le paragraphe 1.3.2, y ont été suivies, à savoir :

- associer des attributs de texture extraits de l'image de luminance avec des attributs statistiques caractérisant la distribution des couleurs,
- considérer des attributs de texture couleur qui ne tiennent compte que des relations spatiales intra-composantes,

- considérer des attributs de texture couleur qui tiennent compte à la fois des relations spatiales intra et inter-composantes.

Afin de déterminer les attributs qui semblent être les mieux appropriés à des applications industrielles, nous proposons de recenser une partie de ces travaux en fonction de chacune des trois stratégies. Notons que nous ne détaillerons pas les résultats de classification et les méthodes qui leur sont associées, mais présenterons uniquement les attributs de texture utilisés et les méthodes de réduction exploitées pour construire le sous-espace d'attributs discriminant.

3.3.2.1 Attributs de texture extraits de l'image de luminance et attributs statistiques caractérisant la distribution des couleurs

Pour discriminer les textures couleur dans le cadre d'applications industrielles, certains auteurs proposent simplement d'associer des attributs de texture portant exclusivement sur la luminance avec des attributs statistiques caractérisant la distribution des couleurs au sein des espaces couleur [LVPF08, MVP03, MMK⁺99, TTSR99, KP00] :

- De nombreux auteurs se sont intéressés à la problématique liée à l'utilisation excessive d'herbicides, en proposant différentes méthodes qui permettent de caractériser et d'identifier les espèces d'herbes, afin de ne traiter que celles qui le nécessitent [MMK⁺99, TTSR99]. Par exemple, Meyer couple des attributs d'Haralick, extraits des matrices de co-occurrences calculées à partir de l'image de luminance, avec un attribut original caractérisant la couleur, nommé "Excess green index" [MMK⁺99]. Cette approche permet de traiter en 20 à 30 secondes une image de taille 1023×682 pixels, avec un PC cadencé à 66 MHz.
- Dans le cadre d'une application de contrôle qualité de parquets, Kyllönen étudie les résultats de classification obtenus avec plusieurs associations entre des attributs caractérisant la couleur et des attributs de texture extraits de l'image de luminance [KP00]. Lors d'un apprentissage supervisé, un sous-espace pertinent d'attributs statistiques caractérisant la distribution des couleurs de dimension $\hat{d} = 13$ est sélectionné par une procédure de sélection SFFS à partir d'un espace initial de dimension $D = 117$. Ce sous-espace est ensuite utilisé séparément avec trois descripteurs de texture extraits de l'image de luminance, à savoir, la matrice de co-occurrences, l'histogramme des LBP et l'histogramme des différences signées. C'est avec cette dernière association que les meilleurs résultats de classification sont obtenus. Cependant, aucune étude sur les temps de calcul n'a été menée.
- Pour détecter et caractériser des défauts présents sur du bois, Mäenpää utilise un ensemble pertinent d'attributs formé d'une mesure de LBP extraite de l'image de luminance et de $\hat{d} = 8$ attributs statistiques caractérisant la distribution des couleurs [MVP03]. Les $\hat{d} = 8$ attributs statistiques sont sélectionnés parmi un espace initial de dimension $D = 117$ par le biais d'une procédure **Beam Search**. La procédure de génération Beam Search correspond à une méthode de type Branch and Bound tronquée [Saa08]. En effet, toutes les branches de l'arbre de recherche ne sont pas évaluées, seules les plus perti-

nelles vis-à-vis de la fonction d'évaluation considérée le sont. Le temps de calcul de l'histogramme des LBP est de 0.067 ms pour une image de taille 32×32 pixels, avec un PC cadencé à 450 MHz.

- Dans le but de choisir un ensemble d'attributs pertinents pour le classement de surfaces de marbre, Lopez compare les résultats de classification obtenus par trois approches différentes de caractérisation de textures couleur [LVPF08]. En effet, il analyse les taux d'images bien classées et les temps de classification obtenus en considérant :
 - soit des attributs statistiques de texture couleur du premier ordre,
 - soit des histogrammes d'images,
 - soit des LBP extraits de l'image de luminance et associés à des attributs couleur.

Il montre que les meilleurs résultats de classification sont obtenus en considérant les histogrammes d'images. Cependant, ces descripteurs sont également les plus coûteux en temps de calcul. En effet, le temps de classification atteint en considérant les histogrammes d'images est environ trois fois plus important qu'avec les deux autres approches. De plus, même si les résultats obtenus avec les deux autres approches sont inférieurs à ceux obtenus avec les histogrammes d'images, ils restent satisfaisants du point de vue de l'application considérée qui exige un taux de bonne classification d'au moins 95%.

3.3.2.2 Attributs de texture couleur intra-composantes

Certains auteurs préfèrent considérer des attributs de texture couleur qui ne tiennent compte que des relations spatiales intra-composantes pour discriminer les textures couleur dans le cadre d'applications industrielles [ADBB04, MALDTB05, AML08, BSP00] :

- Pour caractériser différentes classes de textures d'herbes, Burks utilise des attributs extraits des matrices de co-occurrences chromatiques intra-composantes sous-quantifiées [BSP00]. Lors d'un apprentissage supervisé, la sélection d'un sous-espace d'attributs discriminant de dimension $\hat{d} = 11$ est effectuée parmi les $D = 33$ attributs initiaux, par le biais d'une procédure de génération séquentielle SFFS associée au critère de Wilks. Cependant aucune étude sur les temps de calcul n'est précisée.
- Des attributs extraits des histogrammes des sommes et des différences intra-composantes, issus d'images codées dans l'espace couleur $(I1, I2, I3)$, sont utilisés par Martinez Alajarin dans le cadre de la classification en temps réel de surfaces de marbre [MALDTB05]. Afin de réduire la dimension $D = 21$ de l'espace initial d'attributs, il effectue une analyse en composantes principales aboutissant à un sous-espace discriminant de dimension $\hat{d} = 10$. Cependant, à nouveau, aucune étude sur les temps de traitement n'a été menée.
- Akhloufi propose de contrôler la qualité de différents objets (bardeaux, bois, fibres organiques, tissus) en caractérisant la texture couleur de leur surface par :
 - des attributs extraits des matrices de co-occurrences chromatiques intra-composantes, associés à une statistique d'image (entropie),

- des attributs extraits des images de LBP intra-composantes, associés à la même statistique d'image [AML08].

Il montre que le premier ensemble d'attributs permet d'obtenir de meilleurs résultats de classification que ceux obtenus avec les attributs extraits des images de LBP. Cependant, comme pour les travaux de Martinez-Alajarin, les temps de traitement n'ont pas été présentés.

3.3.2.3 Attributs de texture couleur intra et inter-composantes

Enfin, pour caractériser la texture couleur dans le cadre d'applications industrielles, certains auteurs proposent de considérer des attributs de texture couleur qui tiennent compte à la fois des relations spatiales intra et inter-composantes [ADBB04, PS04, XM07] :

- Xie propose un nouvel attribut de texture couleur, appelé "Texems", basé sur la modélisation des textures [XM07]. Cet attribut, qui permet de représenter et d'analyser des textures aléatoires, est appliqué à la détection et à la localisation des défauts présents sur des dalles de céramique. Cependant, avec un temps de traitement d'au minimum 12 secondes pour détecter et localiser un défaut présent sur une image de taille 256×256 pixels (temps obtenu avec un PC cadencé à 2.8 GHz), cet attribut de texture couleur ne peut pas être exploité par la majorité des systèmes industriels qui doivent respecter des contraintes de temps de calcul nettement inférieures.
- Arvis étudie les temps de traitements nécessaires au calcul des attributs d'Haralick extraits des matrices de co-occurrences chromatiques [ADBB04]. Ces derniers sont calculés à partir d'images dont les composantes couleur sont sous-quantifiées pour pouvoir être employés dans le cadre d'applications avec des contraintes temporelles. Il extrait 5 attributs d'Haralick de chacune des 6 matrices de co-occurrences chromatiques calculées avec des images couleur de taille 128×128 pixels. Il construit ensuite un sous-espace d'attributs par analyse factorielle discriminante à partir de l'espace initial de dimension $D = 30$. Le temps de calcul écoulé pour extraire ces 30 attributs, avec un PC cadencé à 1.5 GHz, est de 1845 ms pour 256 niveaux de quantification des composantes couleur et 107 ms pour 32 niveaux de quantification.
- Pour identifier les différents types de sols en vue d'une application de guidage de véhicules, Tessier considère les attributs de texture couleur retenus par Arvis [Tes04]. Il classe ainsi une image de taille 100×100 pixels en 86 ms, avec un PC cadencé à 1.5 GHz.

3.3.2.4 Synthèse

Les travaux présentés dans les paragraphes précédents, ainsi que d'autres encore [MBF97, BVV99, GCGG04, LKV05, CGGC08], montrent que de nombreux attributs ont été utilisés pour caractériser les textures couleur dans le cadre d'applications industrielles. Cependant, il est difficile de faire ressortir de cette étude un attribut mieux adapté qu'un autre au contexte industriel. En effet, ces attributs ne sont d'une part, pas utilisés pour les mêmes applications et,

dans la majorité des cas, il manque des informations concernant le temps de traitement à ne pas dépasser, la taille des images analysées, le matériel informatique utilisé ou encore le nombre d'attributs sélectionnés quand c'est le cas. D'autre part, les temps présentés sont rarement ceux nécessaires au calcul des attributs. En effet, les auteurs présentent généralement les temps requis pour classer une image et ces derniers ne permettent pas de conclure sur la pertinence des attributs utilisés car ils dépendent également de la méthode de classification proposée et non du seul calcul des attributs.

Cependant, il est intéressant de noter que les attributs qui caractérisent à la fois les relations spatiales intra et inter-composantes peuvent être utilisés dans le cadre d'applications avec des contraintes temporelles, bien qu'ils soient généralement plus coûteux en temps de calcul que les attributs de texture couleur intra-composantes et que les attributs extraits de l'image de luminance associés aux attributs caractérisant la distribution des couleurs.

D'autre part, l'analyse des attributs de texture couleur intra et inter-composantes permet d'obtenir de meilleurs résultats de classification que celle exploitant des attributs obtenus par les deux autres stratégies de caractérisation. C'est ce que montre Arvis qui compare les résultats de classification obtenus par l'analyse :

- d'attributs d'Haralick extraits de l'image de luminance associés à des attributs caractérisant la distribution des couleurs,
- d'attributs d'Haralick qui ne tiennent compte que des relations intra-composantes,
- d'attributs d'Haralick qui tiennent compte des relations intra et inter-composantes [ADBB04].

Avec la première méthode de caractérisation, les résultats de classification obtenus atteignent 75.0% pour les textures couleur issues de la base VisTex et 66.0% pour celles issues de la base OuTex. Avec des attributs d'Haralick ne tenant uniquement compte que des relations spatiales intra-composantes, les taux d'images bien classées atteignent 97.5% pour la base VisTex et 90.7% pour la base OuTex. Enfin, lorsque les textures couleur sont caractérisées par des attributs d'Haralick intra et inter-composantes, ces taux augmentent puisqu'ils atteignent 97.9% pour la base VisTex et 94.1% pour la base OuTex.

Les travaux présentés précédemment montrent donc d'une part, qu'il n'existe pas d'attribut de texture couleur adapté à toutes les applications industrielles et d'autre part, que les attributs tenant compte des relations spatiales intra et inter-composantes semblent être les plus performants car ils permettent d'obtenir les taux de classification les plus élevés tout en ayant des temps de calcul compatibles avec des applications industrielles.

Pour caractériser les textures couleur, nous proposons d'utiliser les attributs d'Haralick extraits des matrices de co-occurrences chromatiques. Ces dernières sont des descripteurs de texture invariants à la translation et également à la rotation lorsque plusieurs directions θ sont considérées dans leur calcul. Elles ont montré leur efficacité dans de nombreux travaux de re-

cherche, en particulier ceux menés au laboratoire LAGIS [SMP00, Mus05]. D'autre part, les matrices de co-occurrences chromatiques permettent effectivement de calculer des attributs qui tiennent compte des relations spatiales intra et inter-composantes et les attributs d'Haralick sont parmi les attributs de texture couleur les plus utilisés en analyse de textures.

Afin que le calcul des attributs d'Haralick puisse respecter de fortes contraintes temporelles, nous proposons de retenir les matrices de co-occurrences chromatiques isotropiques de taille réduite présentées dans le paragraphe suivant.

La bibliographie présentée dans le premier chapitre montre cependant que d'autres attributs de texture couleur pourraient également être utilisés par notre approche. Il serait donc intéressant de comparer la pertinence des attributs d'Haralick vis-à-vis d'attributs basés sur la modélisation spatiale des textures, comme les LBP, ou vis-à-vis d'attributs spatio-fréquentiels, comme les attributs extraits de la transformée en ondelettes, par exemple.

3.3.3 Matrices de co-occurrences chromatiques isotropiques de taille réduite

Les matrices de co-occurrences chromatiques sont des descripteurs de texture dont le stockage est coûteux en espace mémoire, ce qui implique également un temps de calcul coûteux des attributs extraits de ces matrices.

Afin de réduire le temps nécessaire au calcul de ces attributs, nous proposons dans un premier temps de réduire la place mémoire occupée par les matrices de co-occurrences en diminuant le nombre de couleurs de l'image grâce à la sous-quantification uniforme des composantes couleur. En effet, la sous-quantification est utilisée dans le cadre d'applications industrielles où il est nécessaire de calculer des attributs de texture couleur tenant compte des relations spatiales intra et inter-composantes [BR04, ADBB04, BSP00, Rik04, Tes04]. Cette réduction permet de définir les "matrices de co-occurrences de taille réduite" au paragraphe 3.3.3.1.

Ensuite, dans le paragraphe 3.3.3.2, nous montrerons que le choix du voisinage considéré lors du calcul des matrices de co-occurrences influence également le temps de calcul des attributs extraits de ces matrices. Afin de réduire ce temps, nous proposerons d'utiliser les matrices de co-occurrences chromatiques isotropiques et nous illustrerons le bénéfice qu'offrent ces descripteurs en terme de temps de calcul des attributs extraits.

3.3.3.1 Intérêt des matrices de co-occurrences chromatiques de taille réduite

Il est intéressant de constater que les textures couleur présentes dans les images sont relativement bien préservées après avoir appliqué une sous-quantification uniforme des composantes couleur. Les figures 3.4 et 3.5 illustrent ce propos où une sous-quantification uniforme a été appliquée respectivement aux images VisTex et OuTex des figures 3.4(a) et 3.5(a), dont les composantes couleur ont initialement été codées avec $N = 256$ niveaux dans l'espace (R, G, B) .

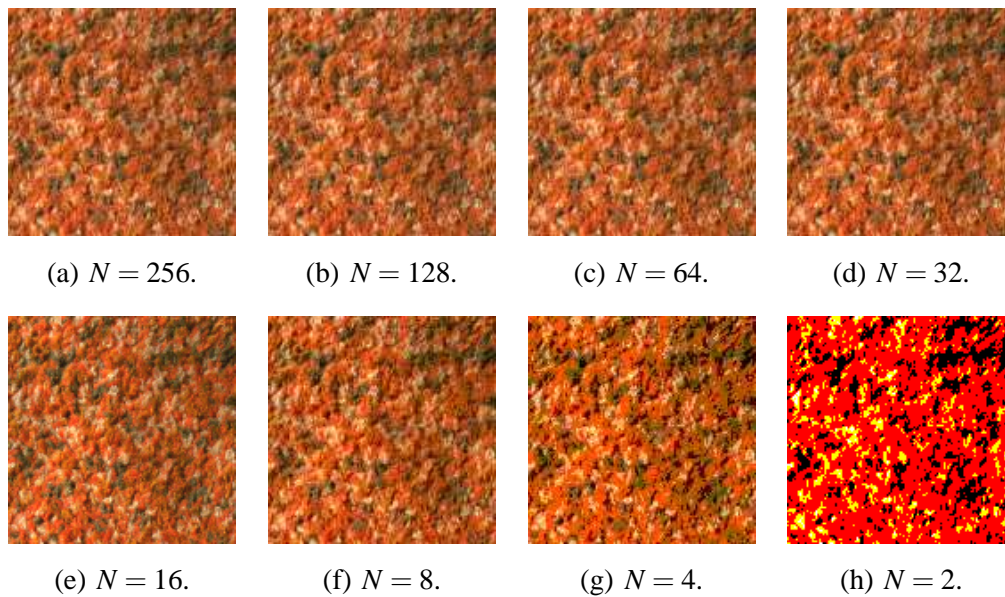


Figure 3.4 : Sous-quantification uniforme de l'image 3.4(a) dans l'espace couleur (R, G, B) .

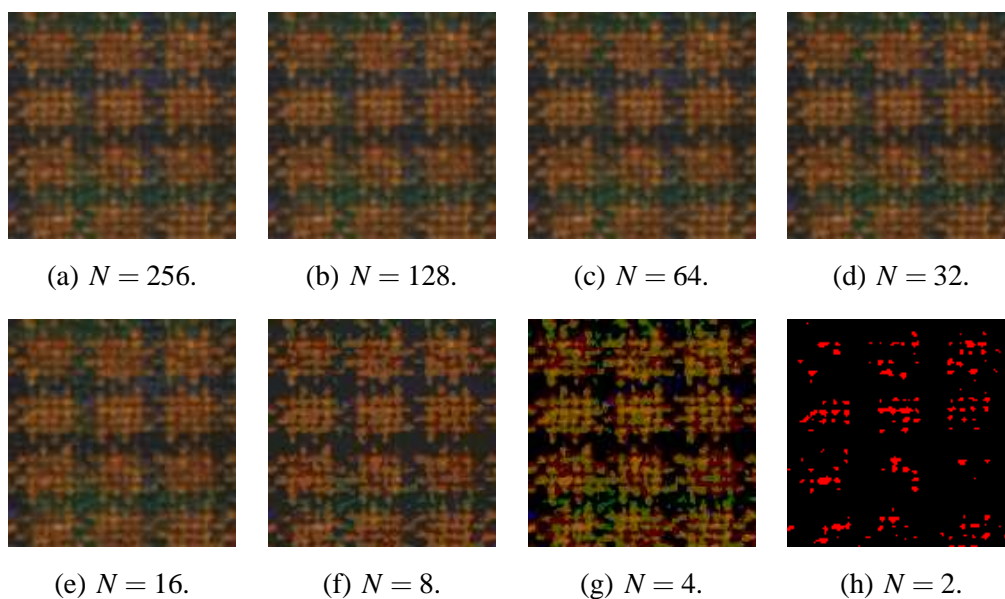


Figure 3.5 : Sous-quantification uniforme de l'image 3.5(a) dans l'espace couleur (R, G, B) .

En examinant visuellement les images 3.4(b) à 3.4(h) et les images 3.5(b) à 3.5(h), on remarque que la texture couleur présente dans les images 3.4(a) et 3.5(a) est relativement bien préservée tant que N est supérieur ou égal à 16.

D'autre part, lors du calcul des attributs d'Haralick extraits des matrices de co-occurrences chromatiques, utiliser un niveau de quantification inférieur à $N = 256$ (par exemple $N = 16$) permet non seulement de réduire le coût de stockage en mémoire (par exemple, la place mémoire nécessaire pour chaque matrice est divisée par $16^2 = 256$ lorsqu'on considère un niveau de quantification $N = 16$ au lieu de $N = 256$), mais aussi de réduire le temps nécessaire au calcul des attributs, puisque le nombre de cellules de la matrice est diminué. Arvis constate en

effet que le calcul des attributs d'Haralick qui tiennent compte des relations spatiales intra et inter-composantes est 17 fois plus rapide pour un niveau de quantification $N = 32$ par rapport au niveau $N = 256$ [ADBB04]. Ce gain de temps permet de se rapprocher du temps de calcul obtenu en considérant simplement les attributs d'Haralick extraits de l'image de luminance et associés à des attributs caractérisant la distribution des couleurs (107 ms vs. 95 ms) [ADBB04].

La sous-quantification des composantes couleur permet donc de construire des "matrices de co-occurrences chromatiques de taille réduite", à savoir des matrices constituées de $N \times N$ cellules avec $N < 256$. Le nombre de cellules étant réduit par rapport à celui des matrices de co-occurrences originales de taille 256×256 , on peut extraire en un temps plus court des attributs qui tiennent compte à la fois des relations spatiales intra et inter-composantes. D'autre part, même si une méthode de sous-quantification dynamique semble être plus performante que la sous-quantification uniforme, les résultats présentés dans les travaux d'Arvis montrent que la sous-quantification uniforme est suffisante puisqu'elle ne détériore pas la qualité de la classification lorsque N passe de 256 à 32. Nous proposons donc d'étudier l'influence du niveau de quantification N sur les performances de classification au chapitre suivant.

Après avoir montré l'intérêt des matrices de co-occurrences chromatiques de taille réduite, le paragraphe suivant montre qu'il est possible de réduire d'avantage le temps de calcul des attributs extraits de ces matrices en retenant le voisinage isotropique pour calculer ces dernières.

3.3.3.2 Intérêt des matrices de co-occurrences chromatiques isotropiques

Le paragraphe 1.9.2.3 a mis en évidence les différents voisinages utilisés lors du calcul des matrices de co-occurrences. N'ayant aucun *a priori* sur les textures à analyser, il est nécessaire de considérer un voisinage où les quatre directions θ (0° , 45° , 90° et 135°) sont équitablement prises en compte pour analyser les relations spatiales entre pixels voisins. Cette considération multiple permet d'autre part d'obtenir une caractérisation des textures couleur invariante à la rotation.

La première solution consiste à considérer la moyenne et la variance des 14 attributs d'Haralick $f_i^{C_k, C_{k'}, v, \theta}$ ($i = 1, 2, \dots, 14$) déterminés selon les quatre directions θ (cf. équations 1.2 à 1.17). La figure 3.6 illustre le calcul des $6 \times 2 \times 14 = 168$ attributs ainsi générés à partir des 6 matrices de co-occurrences chromatiques d'une image codée dans l'espace (R, G, B) .

La deuxième solution utilise le "8-voisinage" pour calculer les matrices de co-occurrences chromatiques. En effet, ce voisinage permet également de caractériser les interactions spatiales entre pixels voisins selon toutes les directions. La figure 3.7 illustre le calcul des 14 attributs d'Haralick extraits des 6 matrices de co-occurrences où le "8-voisinage" est considéré. Ces matrices sont elles même calculées à partir d'une image également codée dans l'espace (R, G, B) .




Figure 3.6 : Illustration du calcul de la moyenne et la variance des 14 attributs d'Haralick selon les quatre directions $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$.




Figure 3.7 : Illustration du calcul des attributs d'Haralick extraits des matrices de co-occurrences où le "8-voisinage" est considéré.

Avec cette méthode, seulement une matrice et $14 \times 6 = 84$ attributs sont calculés pour caractériser les textures couleur.

L'utilisation de la moyenne et la variance des attributs d'Haralick impose quant à elle le calcul de quatre matrices de co-occurrences chromatiques et de quatre fois plus d'attributs avant d'évaluer la moyenne et la variance de ces derniers. L'utilisation du "8-voisinage" permet donc de réduire non seulement le nombre de matrices considérées, et par conséquent le coût en stockage mémoire et le temps de calcul des attributs, mais également le temps d'apprentissage. Nous utiliserons donc le "8-voisinage" lors du calcul des matrices de co-occurrences chromatiques de taille réduite pour réduire autant que possible le temps de calcul des attributs générés.

Le "8-voisinage" est généralement associé à la distance spatiale $v = 1$ pour caractériser les textures couleur. Cette association définit les matrices de co-occurrences isotropiques qui ont montré leur efficacité dans le contexte industriel [BSP00, ADBB04, AML08]. Nous choisissons donc de retenir ce type de matrices pour caractériser les textures couleur.

L'intérêt d'utiliser les matrices de co-occurrences chromatiques de taille réduite associées au voisinage isotropique nous amène à définir les "matrices de co-occurrences chromatiques isotropiques de taille réduite". Les attributs d'Haralick extraits de ces matrices constituent les attributs de texture couleur considérés dans l'approche proposée. Cependant, nous choisissons de ne considérer que les treize premiers attributs définis par Haralick pour caractériser les textures couleur. En effet, le coefficient de corrélation maximal $f_{14}^{C_k, C_{k'}, v, \theta}$ (cf. équation 1.15) impose le calcul des valeurs propres d'un produit de matrices de taille $N \times N$, ce qui engendre un temps de calcul élevé, particulièrement lorsque la valeur de N est importante.

Pour rappel, nous avons choisi dans le paragraphe 3.2 de considérer un ensemble de $N_E = 28$ espaces couleur afin de disposer de toutes les propriétés de ces espaces. Par conséquent, pour chaque image codée dans un des 28 espaces couleur, 6 matrices de co-occurrences chromatiques isotropiques de taille réduite sont calculées, et pour chacune de ces matrices, 13 attributs d'Haralick sont extraits. $D = 28 \times 6 \times 13 = 2184$ attributs de texture couleur sont donc considérés pour discriminer les différentes classes d'images.

Cependant, opérer la classification dans l'espace original d'attributs de texture couleur sans procéder à une réduction de sa dimension ne permet généralement pas de satisfaire les contraintes industrielles en termes de résultats et de temps de classification [MVP03]. C'est la raison pour laquelle nous procédons à la sélection d'un sous-espace d'attributs discriminant.

3.4 Procédure de sélection proposée

Dans le chapitre précédent, nous avons vu l'intérêt d'opérer une réduction de la dimension de l'espace d'attributs dans le cadre de la classification de textures. Tout d'abord, cela permet d'éliminer les attributs peu significatifs ou non pertinents pour discriminer les classes en présence. D'autre part, un nombre trop élevé d'attributs peut détériorer la qualité de la discrimination car le risque de considérer des attributs corrélés est alors important. Enfin, le temps nécessaire à la classification dépend du nombre d'attributs considérés.

Les principales méthodes utilisées pour réduire la dimension de l'espace d'attributs ont été présentées dans le chapitre précédent. Nous y avons vu qu'il est préférable d'utiliser des algorithmes de recherche de sous-espaces plutôt que des algorithmes de classement des attributs. En effet, comme ces derniers mesurent la pertinence des attributs en les appréciant de manière individuelle, ils ne permettent pas d'éliminer les attributs redondants. Par conséquent, nous nous

tourçons vers l'ensemble des algorithmes de recherche de sous-espaces.

Rappelons qu'une procédure classique de recherche de sous-espaces d'attributs est composée de trois points principaux, généralement suivis d'une procédure de validation :

- la procédure de génération,
- la fonction d'évaluation,
- le critère d'arrêt.

L'approche que nous proposons émane du constat que le choix du critère d'arrêt de la procédure itérative de sélection pas à pas est un problème actuellement encore ouvert. En effet, quelque soit la méthode de sélection d'attributs considérée, on ne sait pas comparer *a priori* le pouvoir discriminant de deux sous-espaces de dimensions différentes. Pour arrêter la procédure itérative de sélection, la solution qui nous semble être la plus pertinente vis-à-vis de la qualité de la classification et du temps nécessaire à l'apprentissage est d'utiliser une approche "embedded" décrite au paragraphe 2.3.3.6.

Nous proposons donc tout d'abord de pré-sélectionner, à partir de la base d'apprentissage, des sous-espaces d'attributs candidats pour différentes dimensions d . Cette pré-sélection s'effectue grâce à une méthode de génération et une fonction d'évaluation de type "filter" décrites dans le paragraphe 3.4.1. Parmi les approches "filter", nous choisissons une procédure ascendante où d varie de 1 à d_{max} , d_{max} étant fixée à une valeur dépendante de l'application considérée. En effet, étant donné que nous souhaitons sélectionner un nombre minimum d'attributs parmi un grand nombre, une approche ascendante sera plus rapide qu'une approche descendante.

Puis, les taux d'erreur de classification obtenus en considérant chacun des d_{max} sous-espaces candidats précédemment sélectionnés, sont comparés afin de déterminer le sous-espace final de dimension \hat{d} (cf. § 3.4.2). Par contre, contrairement aux approches classiques, nous choisissons de mesurer le taux d'erreur de classification non pas sur l'ensemble d'apprentissage, mais sur un ensemble d'images test, fusionnant ainsi les étapes d'évaluation et de validation. Cette procédure de sélection va donc nous permettre de déterminer la dimension du sous-espace d'attributs pour laquelle le taux d'erreur de classification des images test est le plus faible.

3.4.1 Construction des sous-espaces candidats

Dans ce paragraphe, nous proposons de définir la méthode de génération et la fonction d'évaluation de type "filter" utilisées pour pré-sélectionner les d_{max} sous-espaces candidats à partir de la base d'apprentissage.

Choix de la procédure de génération

Nous avons vu au paragraphe 2.3.2.4 que le choix de la procédure de génération dépend de différents critères, à savoir :

- l'objectif visé ("trouver le sous-espace le plus discriminant connaissant \hat{d} ", ou "trouver le plus petit sous-espace avec un pouvoir discriminant supérieur à un seuil fixé", ou encore "faire un compromis entre \hat{d} et la capacité de discrimination"),
- la dimension initiale D de l'espace d'attributs,
- le caractère monotone de la fonction d'évaluation.

Dans notre cas, l'objectif visé est d'atteindre un compromis entre les résultats de classification et le temps de calcul en-ligne. Il s'agit donc de répondre à l'objectif C du tableau 2.1, qui est d'atteindre un compromis entre la capacité de discrimination (qui influe sur la qualité de la classification) et \hat{d} , la dimension du sous-espace sélectionné (qui influe sur le temps de classification en-ligne).

En ce qui concerne la dimension initiale D de l'espace d'attributs, nous considérons le cas où $D > 100$. En effet, comme nous venons de le voir dans le paragraphe 3.3, nous avons choisi de caractériser les textures couleur par un ensemble de $D = 28 \times 6 \times 13 = 2184$ attributs.

D'après le tableau 2.1, nous pouvons constater que, quelque soit le caractère monotone de la fonction d'évaluation et quelque soit l'objectif fixé, le fait de considérer une dimension initiale $D > 100$ nous amène à retenir une procédure de génération séquentielle flottante SFSS décrite au paragraphe 2.3.2.3. Cependant, dans le contexte de problématiques industrielles, la contrainte liée au temps d'apprentissage impose de considérer une procédure de génération peu coûteuse en temps d'exécution. Nous proposons donc d'utiliser une autre procédure de génération séquentielle, la procédure SFS décrite au paragraphe 2.3.2.3, qui semble certes être moins performante mais qui nécessite un temps de calcul réduit.

Après avoir motivé le choix de la procédure de génération SFS, le paragraphe suivant s'intéresse au choix de la fonction d'évaluation utilisée pour mesurer la pertinence des sous-espaces.

Choix de la fonction d'évaluation

Le chapitre précédent a permis de mettre en évidence quatre familles de mesures d'évaluation de type "filter" :

- les mesures de consistance,
- les mesures d'information,
- les mesures de dépendance,
- les mesures de distance.

Nous choisissons dans un premier temps d'exclure les mesures de consistance qui, selon Dash, imposent un temps de sélection plus important que les autres mesures de type "filter", sans pour autant assurer de meilleurs résultats de classification [DL97]. Pour ce qui est du choix

parmi les trois familles de mesures restantes, aucune étude n'a, à notre connaissance, précisément étudié l'influence du choix de la mesure d'évaluation sur la qualité de la classification.

Nous proposons d'utiliser une méthode d'évaluation qui a montré son efficacité dans le cadre de la sélection d'attributs statistiques couleur pour la segmentation par classification de pixels. Il s'agit de la méthode proposée par Vandembroucke, où deux critères d'évaluation sont utilisés conjointement pour déterminer le sous-espace d'attributs discriminant [Van00] : à chaque itération de la procédure de sélection SFS, une mesure de corrélation (décrite au paragraphe 2.3.3.4) entre chaque attribut candidat à la sélection et chacun des attributs déjà sélectionnés est effectuée. Si le niveau de corrélation est inférieur à un seuil fixé par l'utilisateur, nous considérons que l'attribut examiné est peu corrélé avec les attributs déjà sélectionnés. Le sous-espace formé par l'attribut examiné et les attributs déjà sélectionnés est alors évalué par une deuxième fonction d'évaluation de type filter, qui fait partie de la famille des mesures de distance (cf. § 2.3.3.5) [VMP00b].

Vandembroucke a étudié la pertinence de différentes mesures de distance dans le cadre de la sélection d'attributs statistiques couleur [Van00]. Il en ressort que le critère de la trace, décrit par l'équation (2.15), permet d'obtenir d'excellents résultats en termes de classification de pixels. Il remarque également que le critère de Wilks, décrit par l'équation (2.14), se comporte de manière similaire et offre des résultats de classification semblables par rapport à ceux obtenus avec le critère de la trace. Le critère de Wilks étant légèrement moins coûteux en temps de calcul que le critère de la trace, nous choisissons de considérer cette fonction d'évaluation pour déterminer les d_{max} sous-espaces d'attributs candidats par minimisation de ce critère.

Vandembroucke a également étudié l'influence de la valeur du seuil de corrélation sur les résultats de segmentation des images couleur [Van00]. Il montre que fixer ce seuil à 0,75 permet d'obtenir un sous-espace d'attributs pertinent vis-à-vis des résultats de la classification de pixels. Nous choisissons de considérer cette même valeur de seuil lors de l'étape d'évaluation.

Cette étape de pré-sélection consiste à itérer d_{max} fois la procédure de sélection pas à pas, afin d'obtenir les d_{max} sous-espaces d'attributs candidats pour différentes dimensions d ($1 \leq d \leq d_{max}$).

Le paragraphe suivant présente l'approche mise en place pour déterminer, parmi ces d_{max} sous-espaces candidats, celui qui sera retenu lors de la phase de classification en-ligne.

3.4.2 Sélection du sous-espace d'attributs le plus discriminant

Les taux d'erreur de classification obtenus en opérant dans chacun des d_{max} sous-espaces candidats sont comparés afin de déterminer le sous-espace final. Nous avons choisi de mesurer ces taux d'erreur de classification non pas sur l'ensemble d'apprentissage, mais sur un ensemble d'images test, fusionnant ainsi les étapes d'évaluation et de validation. Nous proposons de dé-

terminer la dimension \hat{d} du sous-espace d'attributs à sélectionner, par recherche du minimum du taux d'erreur de classification d'un ensemble d'images test. Notons que si plusieurs des d_{max} sous-espaces pré-sélectionnés permettent d'atteindre le taux d'erreur de classification minimum, nous considérons celui dont la dimension est la plus faible.

Pour définir cette étape de sélection du sous-espace d'attributs le plus discriminant, il est nécessaire de déterminer :

- la méthode de classification considérée pour classer les images de texture couleur,
- l'ensemble d'images test utilisé.

Choix de la méthode de classification

Concernant le choix de la méthode de classification, la synthèse des travaux portant sur la classification d'images de texture couleur présentée en annexe C permet d'identifier les principales méthodes de classification utilisées pour classer les textures couleur, à savoir :

- les réseaux de neurones,
- les machines à vecteur support,
- la méthode des k plus proches voisins,
- la méthode du plus proche barycentre,
- l'analyse factorielle discriminante,
- la combinaison de plusieurs classifieurs.

Il en ressort que dans près de 70% des travaux que nous avons recensés, la méthode des k plus proches voisins est utilisée et plus particulièrement la méthode 1-PPV. Ce choix majoritairement fait par les auteurs est dû au fait que cette méthode de classification est à la fois simple et robuste et qu'elle permet de traiter des classes non linéairement séparables. Une récente étude comparant les performances atteintes par plusieurs approches de classification conforte cette idée tout en soulignant que d'autres méthodes, plus sophistiquées, permettent d'obtenir de meilleures performances de classification [TTS⁺05].

C'est donc cette méthode de classification que nous retenons pour évaluer les d_{max} sous-espaces d'attributs et sélectionner ainsi celui qui permet d'obtenir le meilleur taux d'images test bien classées.

Notons que cette méthode étant basée sur une mesure de distance, elle nécessite que les nuages de points représentatifs des différentes classes soient représentés dans un repère normé. Or, les valeurs des attributs d'Haralick appartiennent à des domaines de définition de dynamiques très différentes. Il est donc nécessaire de procéder à un centrage et à une normalisation des attributs sélectionnés pour caractériser les textures couleur.

Choix de l'ensemble d'images test

Afin de sélectionner le sous-espace d'attributs le plus discriminant parmi les d_{max} sous-espaces candidats, nous proposons donc d'analyser le taux de classification obtenu sur un ensemble d'images test par la méthode du plus proche voisin.

Pour définir les règles de décision du classifieur, la plupart des approches considèrent comme images test les mêmes images prototypes que celles utilisées lors de la sélection de l'ensemble des sous-espaces candidats. Or, pour chaque test, il est nécessaire de retirer un des prototypes de la base d'apprentissage afin de le classer. La conséquence de cette démarche est qu'elle modifie, pour chaque prototype à classer, la partition de l'espace d'attributs. La figure 3.8 illustre ce propos avec un nombre de classes $N_C = 3$ et un sous-espace d'attributs de dimension $d = 2$.

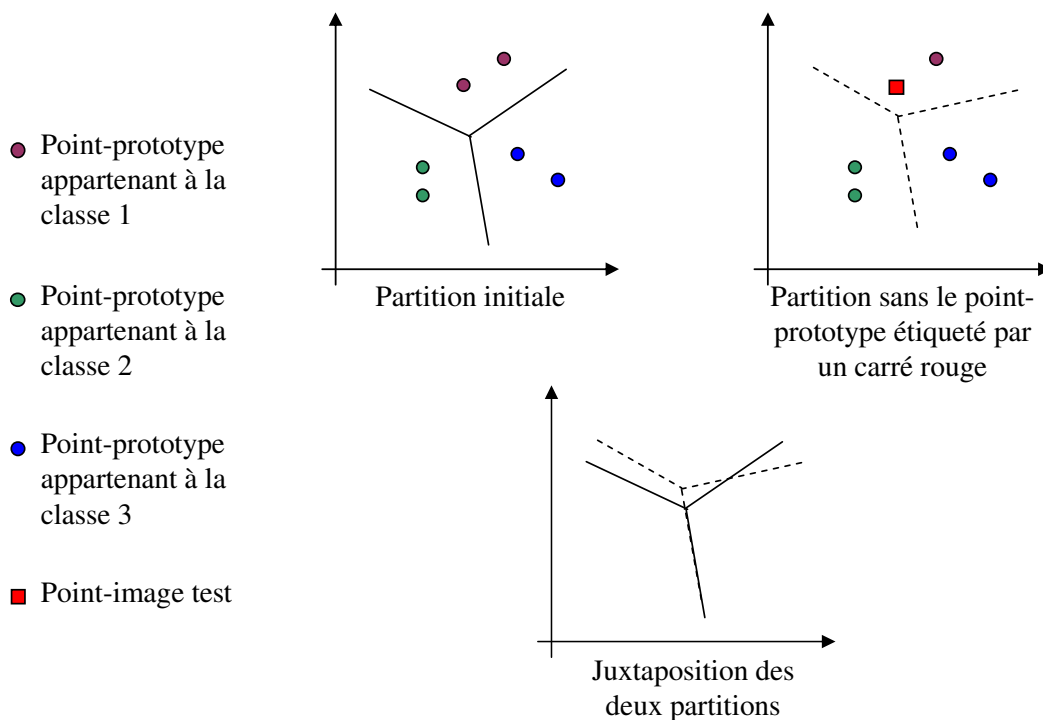


Figure 3.8 : Illustration de la modification de la partition de l'espace d'attributs lorsque les images test sont issues de l'ensemble des prototypes.

Lorsque le prototype de la classe 1 est retiré de la base d'apprentissage pour être classé, la partition initiale de l'espace d'attributs, définie à l'aide de tous les prototypes et représentée par des traits pleins sur l'illustration de gauche, est modifiée. La nouvelle partition considérée, représentée par des traits en pointillés sur l'illustration de droite, est alors définie par l'ensemble initial des prototypes auquel on a retiré le prototype à classer étiqueté par un carré rouge. Les règles de décision sont donc différentes d'un prototype à l'autre et ne correspondent pas aux règles qui seront finalement utilisées lors de l'étape de classification en-ligne.

Or, l'évaluation des performances d'un classifieur nécessite d'évaluer une unique partition de l'espace d'attributs. C'est pourquoi, nous proposons d'employer une base de test totalement différente de la base d'apprentissage pour analyser le taux de classification obtenu. Ainsi, la partition de l'espace d'attributs est identique pour classer les images test et les images à classer en-ligne. Chaque taux mesure donc la performance d'un unique classifieur qui sera celui effec-

tivement utilisé lors de l'étape de classification en-ligne. La figure 3.9 illustre la conservation de la partition de l'espace d'attributs lorsque l'ensemble d'images d'apprentissage et l'ensemble d'images test sont totalement indépendants.

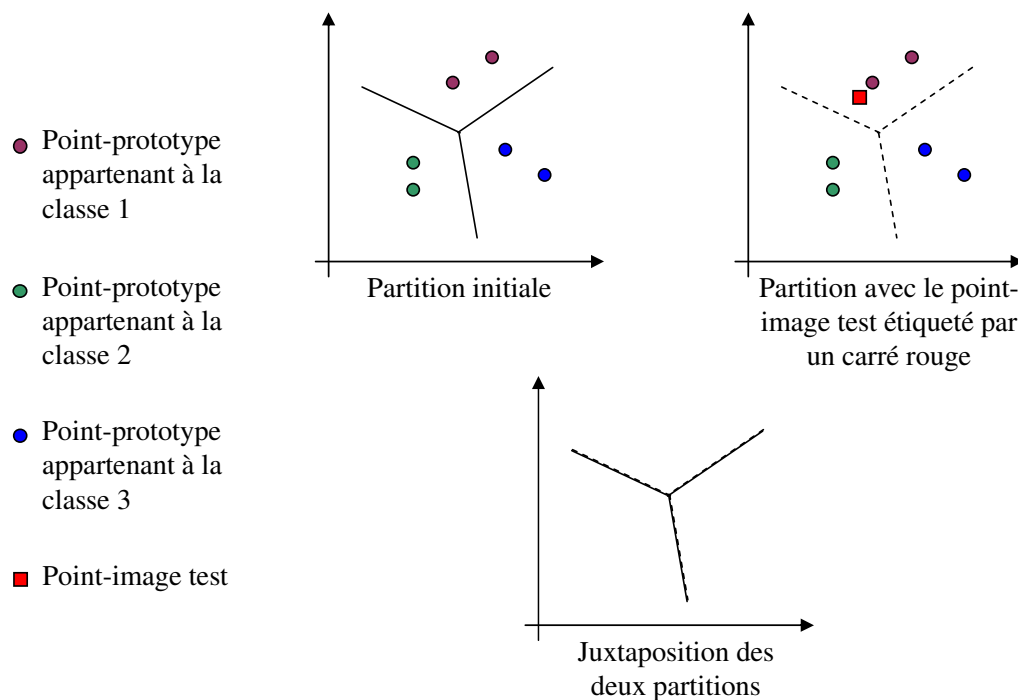


Figure 3.9 : Illustration de la conservation de la partition de l'espace d'attributs lorsque l'ensemble d'apprentissage et l'ensemble d'images test sont totalement indépendants.

Lorsque l'on désire classer une image test qui n'appartient pas à l'ensemble des prototypes, la partition initiale de l'espace d'attributs est inchangée et les règles de décision restent les mêmes quelque soit l'image test à classer.

Nous avons vu au chapitre 2 qu'il existe différentes manières de partitionner une base de données en base d'apprentissage et en base de test. Cependant, la seule méthode de partitionnement qui garantit l'obtention d'une base d'apprentissage et d'une base de test totalement indépendantes est la méthode Holdout. En effet, dans les autres méthodes, les prototypes servent à la fois à la définition des règles de décision et à l'évaluation du classifieur. Seule la méthode Holdout permet donc d'évaluer une partition unique de l'espace d'attributs.

Nous choisissons de partitionner l'ensemble des images ξ en un ensemble d'apprentissage et un ensemble test dans des proportions 1/2, 1/2. Cette partition est en effet couramment utilisée dans le cadre de la classification de textures couleur comme nous le verrons au paragraphe 4.2.

La stratégie proposée permet donc d'une part de déterminer la dimension du sous-espace d'attributs discriminant et d'autre part, d'évaluer les performances du classifieur.

Nous venons de présenter la méthode de sélection proposée pour réduire la dimension de l'espace initial d'attributs de texture couleur. Cette méthode, basée sur une approche "embedded" et une évaluation en deux temps par la mesure de corrélation et le critère de Wilks, a été élaborée en vue d'atteindre un compromis entre la qualité de la classification et le temps nécessaire à l'apprentissage. Elle s'inscrit ainsi dans la continuité du choix des attributs de texture couleur qui a été guidé en vue d'appliquer la méthodologie mise en oeuvre à un contexte industriel. Le paragraphe suivant présente la méthodologie de classification de textures couleur que nous avons développée.

3.5 Méthode de classification supervisée développée

La méthode de classification de textures couleur que nous avons développée se décompose en deux phases : la phase d'apprentissage hors-ligne, décrite dans le paragraphe 3.5.1, et la phase de classification en-ligne, présentée dans le paragraphe 3.5.2.

3.5.1 Apprentissage

Lors de la phase d'apprentissage, les attributs de texture couleur sont calculés pour chaque image d'apprentissage.

Pour extraire les attributs de texture couleur d'une image quelconque \mathbf{I} , nous codons tout d'abord cette image dans les $N_E = 28$ espaces couleur présentés au paragraphe 3.2.2, puis nous appliquons sur chaque image codée la méthode de sous-quantification uniforme afin de quantifier chaque composante couleur sur N niveaux de quantification. Ensuite, nous construisons à partir de chaque image codée, les 6 matrices de co-occurrences chromatiques isotropiques de taille réduite, dont sont extraits de chacune les $N_A = 13$ attributs d'Haralick [PVM07b, PVM07a]. Un ensemble de $D = 28 \times 6 \times 13 = 2184$ attributs est donc considéré pour caractériser les textures couleur.

La construction du sous-espace d'attributs discriminant est ensuite effectuée grâce à la méthode de sélection présentée au paragraphe 3.4 : d_{max} sous-espaces d'attributs candidats de différentes dimensions d ($d = 1, \dots, d_{max}$) sont tout d'abord pré-sélectionnés grâce à une procédure de sélection itérative SFS associée à une évaluation en deux temps par la mesure de corrélation et le critère de Wilks. Puis, les taux d'images bien classées obtenus en considérant chacun de ces d_{max} sous-espaces sont évalués sur une base d'images test, puis comparés afin de déterminer le sous-espace final de dimension \hat{d} pour lequel le taux d'erreur de classification des images test est le plus faible.

Comme nous avons choisi d'utiliser la méthode de classification du plus proche voisin pour déterminer ce sous-espace d'attributs discriminant, les \hat{d} attributs de texture couleur sélectionnés doivent préalablement être centrés et normés.

Après avoir décrit l'algorithme d'apprentissage permettant de construire les classes d'images de texture couleur, le paragraphe suivant présente la seconde phase de la méthode de classification qui consiste à appliquer en-ligne les règles de décision préalablement déterminées.

3.5.2 Classification

Une fois le sous-espace d'attributs discriminant sélectionné, le point caractérisant chaque image à classer est projeté dans ce sous-espace afin d'être comparé aux points-prototypes des classes dans le but de déterminer leur classe d'appartenance.

La méthode de classification utilisée pour déterminer les classes d'appartenance pourrait différer de celle utilisée lors de l'apprentissage pour déterminer la dimension \hat{d} du sous-espace d'attributs final. Cependant, nous choisissons de rester cohérents entre ces deux méthodes, en considérant également la méthode de classification du plus proche voisin pour classer les images lors de la phase de classification en-ligne.

3.6 Conclusion

Afin d'obtenir des taux de classification répondant aux contraintes d'une application industrielle, nous proposons une méthodologie originale de classification de textures couleur qui tient compte d'une part, des propriétés de plusieurs espaces couleur pour discriminer les textures en présence et d'autre part, des relations spatiales intra et inter-composantes au moyen des matrices de co-occurrences chromatiques.

Pour obtenir des temps de calcul satisfaisant aux contraintes temporelles d'une application industrielle, nous proposons dans un premier temps de réduire le nombre de couleurs de l'image grâce à la sous-quantification uniforme des composantes couleur et dans un second temps, de considérer le voisinage isotropique lors du calcul des matrices de co-occurrences, définissant ainsi les "matrices de co-occurrences chromatiques isotropiques de taille réduite".

Enfin, une procédure de sélection séquentielle permet de réduire significativement le nombre d'attributs de texture couleur extraits de ces matrices. Le temps nécessaire pour classer les images en-ligne est alors considérablement réduit et nous verrons au chapitre suivant que la qualité de la classification est améliorée. Notre stratégie, qui consiste à fusionner les étapes d'évaluation et de validation constitue un autre point original de notre méthode. Ceci nécessite alors de bien séparer la base d'apprentissage et la base de test. La base d'apprentissage est utilisée lors de la première étape de notre algorithme de sélection, qui consiste à identifier d_{max} sous-espaces candidats de dimension variant entre 1 et d_{max} . La base de test est exploitée par

la seconde étape qui détermine le sous-espace le plus discriminant parmi les d_{max} sous-espaces candidats. Cette approche a pour mérite d'intégrer l'outil de classification utilisé dans la sélection du sous-espace d'attributs final.

Le chapitre suivant présente les résultats expérimentaux obtenus en appliquant cette méthode sur les trois bases d'images de référence présentées au paragraphe 1.4. Nous montrerons alors l'apport des choix qui ont été motivés dans ce chapitre, à savoir :

- l'approche multi-espaces couleur,
- l'utilisation des matrices de co-occurrences chromatiques isotropiques de taille réduite,
- la sélection d'un sous-espace discriminant d'attributs de texture couleur.

Chapitre 4

Résultats expérimentaux

4.1 Introduction

La méthodologie que nous avons développée a été élaborée en vue de répondre aux contraintes que peut imposer une application industrielle en termes de résultats de classification et de temps de traitement. En effet, afin d'obtenir des taux de classification satisfaisants, la méthodologie proposée tient compte d'une part d'une approche multi-espaces couleur et d'autre part, des relations spatiales intra et inter-composantes au moyen des matrices de co-occurrences chromatiques. De plus, afin de répondre aux contraintes temporelles, nous avons choisi de considérer des attributs extraits des "matrices de co-occurrences chromatiques isotropiques de taille réduite". Nous utilisons enfin une procédure de sélection séquentielle des attributs qui permet d'améliorer la qualité de la classification tout en réduisant le temps nécessaire pour classer les images en-ligne.

Avant d'appliquer au chapitre suivant la méthodologie développée au contrôle qualité des décors de verres produits par l'entreprise Arc International, nous proposons de montrer dans ce chapitre la pertinence de la méthode proposée en la testant sur des bases d'images de textures couleur de référence.

Ainsi, le paragraphe 4.2 décrit les ensembles d'images classiquement utilisés pour tester les méthodes de classification de textures couleur. Nous justifierons dans ce paragraphe le choix de considérer trois ensembles d'images extraits des bases de référence OuTex, VisTex et BarkTex, présentées au chapitre 1.

Les résultats de classification et les temps de traitement obtenus avec ces ensembles seront alors présentés dans les paragraphes 4.3 et 4.4. Une comparaison de ces résultats avec ceux obtenus dans les travaux antérieurs portant sur la classification de textures couleur sera ensuite menée dans le paragraphe 4.5. Cette comparaison permettra de mettre en évidence la pertinence de la méthode développée.

D'autre part, afin d'étudier la robustesse de la méthode vis-à-vis des principaux paramètres qui la définissent, nous analyserons dans le paragraphe 4.6 l'influence de ces paramètres sur les performances de classification.

Enfin, nous évaluerons dans le paragraphe 4.7 l'apport de l'approche multi-espaces pour discriminer les textures couleur, le bénéfice que présente la considération conjointe des relations spatiales intra et inter-composantes, et enfin l'apport de la procédure de sélection.

4.2 Ensembles d'images utilisés pour classer les textures couleur

Dans ce paragraphe, nous proposons de décrire brièvement les ensembles d'images de textures couleur qui ont été utilisés dans le cadre de la classification afin de mettre en évidence ceux qui permettent la comparaison de nos résultats avec un maximum d'autres travaux.

4.2.1 Choix des ensembles d'images

Les trois principales bases d'images utilisées dans les travaux de classification de textures couleur sont les bases de référence OuTex, VisTex et BarkTex, présentées dans le paragraphe 1.4. La plus utilisée dans les travaux que nous avons recensés est la base VisTex : plus d'une quinzaine de travaux utilise cette base pour illustrer les résultats de leur approche [Pal04, BR04, HCG⁺05, ADBB04, KH06, MP04, PMV02, DW01, MVK⁺02, IMK05, PL02, PKLS00, AGA05, dWSLD99, HSP06, Rik04, MWHW05, Sen08]. Les bases OuTex et BarkTex sont quant à elles employées respectivement 5 [ADBB04, MP04, PMV02, XYD05, IMK05] et 7 fois [Pal04, MVK⁺02, PL02, PVM08b, PVM07b, PVM07a, PVM08a] pour tester les procédures de classification de textures couleur mises en place par les différents auteurs.

D'autres bases d'images sont également utilisées. On retrouve notamment la base Texture Library, qui est employée par Chindaro en 2005 pour tester une nouvelle méthode de classification de textures, basée sur la fusion d'informations provenant de différents espaces couleur [CSD05]. Cependant, cette base n'est actuellement plus disponible sur l'Internet. Les autres bases d'images utilisées sont quant à elles directement issues de l'application considérée : on retrouve entre autres les travaux de Zheng qui examine des textures de viandes [ZSZ07], ceux de Lopez qui considère des textures de céramiques [LVPF08], ou encore ceux de Pydipati qui exploite une base d'images formée de différentes textures de feuilles de citronniers [PBL06], ...

De nombreuses bases d'images sont donc utilisées pour tester les performances atteintes par les méthodes proposées par les différents auteurs. Néanmoins, afin de pouvoir comparer nos résultats avec un maximum d'autres travaux, il est préférable d'utiliser les bases d'images les plus couramment utilisées, c'est-à-dire les bases VisTex, OuTex et BarkTex.

Cependant, ces bases d'images se déclinent le plus souvent en différents ensembles utilisés dans la littérature. La synthèse des travaux portant sur la classification de textures couleur présentée en annexe C montre en effet que la plupart des auteurs utilise des tailles d'images et des partitions de l'ensemble d'images différentes. Il est donc important d'identifier ces ensembles, ainsi que leurs différences, afin de ne retenir que les plus couramment utilisés et permettre ainsi

une comparaison avec un maximum d'autres auteurs.

Les tableaux 4.1, 4.2 et 4.3 recensent les caractéristiques des ensembles d'images, respectivement issus des bases OuTex, VisTex et BarkTex, et utilisés dans les principaux travaux portant sur la classification d'images de textures couleur :

- La première colonne de ces tableaux indique la référence de l'article, ainsi que l'auteur et l'année de parution.
- La seconde colonne spécifie le nombre de classes d'images de textures couleur présentes dans chaque ensemble.
- La troisième colonne mentionne le nombre total d'images présentes dans chaque ensemble.
- La quatrième colonne indique le nombre d'images par classe.
- La cinquième colonne spécifie la taille des images utilisées.
- Enfin, la dernière colonne de ces tableaux mentionne la méthode utilisée pour partitionner l'ensemble d'images en base d'apprentissage et base de test, parmi celles présentées dans le paragraphe 2.4.

Référence	Nombre de classes	Nombre total d'images	Nombre d'images par classe	Taille des images	Méthode de partition
Pietikäinen 2002 [PMV02]	68	1360	20	128 × 128	Holdout (1/2 - 1/2)
Mäenpää 2004 [MP04]					
Arvis 2004 [ADBB04]					
Iakovidis 2005 [IMK05]					
Xu 2005 [XYD05]					

Tableau 4.1 : Caractéristiques des ensembles d'images issus de la base OuTex, utilisés dans le cadre de la classification d'images de textures couleur.

Par exemple, la première ligne du tableau 4.2 présente l'ensemble d'images utilisé par Hernandez pour tester sa méthode de classification de textures couleur sur la base VisTex : il considère un ensemble composé de 7680 images de taille 64×64 pixels, réparties de manière variable en 73 classes, et utilise une partition de type Holdout pour construire sa base d'apprentissage (2/3 des images) et sa base de test (1/3 des images) [HCG⁺05].

D'après le tableau 4.1, un seul ensemble d'images extrait de la base OuTex est considéré dans la littérature. Nous choisissons donc d'utiliser également cette partition afin de pouvoir comparer notre approche avec celles des autres auteurs. Le paragraphe 4.2.2 décrit plus précisément cet ensemble d'images.

Référence	Nombre de classes	Nombre total d'images	Nombre d'images par classe	Taille des images	Méthode de partition
Hernandez 2005 [HCG ⁺ 05]	73	7680	Variable	64 × 64	Holdout (2/3 - 1/3)
Khotanzad 2006 [KH06]	16	1024	64	64 × 64	Leaving-one-out
Khotanzad 2006 [KH06]	16	1024	64	16 × 16	Leaving-one-out
Pietikäinen 2002 [PMV02]	54	864	16	128 × 128	Holdout (1/2 - 1/2)
Mäenpää 2004 [MP04]					
Arvis 2004 [ADBB04]					
Iakovidis 2005 [IMK05]					
Drimbarean 2001 [DW01]	16	8640	540	32 × 32	Holdout (1/18 - 17/18)
Palm 2002 2004 [Pal04, PL02]	30	1920	64	64 × 64	Leaving-one-out
Van de Wouwer 1999 [dWSLD99]					
Palm 2000 [PKLS00]	30	900	30	64 × 64	Holdout (1/2 - 1/2)
Hiremath 2006 [HSP06]	20	1280	64	64 × 64	Holdout (1/2 - 1/2)
Münzenmayer 2002 [MVK ⁺ 02]	32	320	10	64 × 64	Leaving-one-out
Münzenmayer 2005 [MWHW05]	32	640	20	64 × 64	Holdout (1/2 - 1/2)
Sengur 2008 [Sen08]	16	1920	120	128 × 128	Holdout (1/6 - 5/6)
Permuter 2006 [PFJ06]	24	6144	256	32 × 32	Holdout (3/8 - 5/8)
Qazi 2009 [QABFM09]					

Tableau 4.2 : Caractéristiques des ensembles d'images issus de la base VisTex, utilisés dans le cadre de la classification d'images de textures couleur.

Concernant le choix de l'ensemble d'images extrait de la base VisTex, nous remarquons dans le tableau 4.2 une grande disparité entre les ensembles d'images VisTex utilisés par les auteurs travaillant sur la classification de textures couleur. En effet, sur les 18 travaux recensés, 12 ensembles d'images différents ont été utilisés. Il est difficile de conclure sur une partition appropriée, d'autant plus que la qualité de la classification dépend également des autres paramètres

Référence	Nombre de classes	Nombre total d'images	Nombre d'images par classe	Taille des images	Méthode de partition
Palm 2002 2004 [PL02, Pal04]	6	408	68	200 × 300	Leaving-one-out
Münzenmayer 2002 [MVK ⁺ 02]	6	1632	272	64 × 64	Leaving-one-out
Porebski 2007 2008 [PVM08b, PVM07b, PVM07a, PVM08a]	6	408	68	80 × 140	Holdout (1/2 - 1/2)

Tableau 4.3 : Caractéristiques des ensembles d'images issus de la base BarkTex, utilisés dans le cadre de la classification d'images de textures couleur.

définissant les méthodes proposées par les différents auteurs. Cependant, nous choisissons d'utiliser l'ensemble d'images pour lequel le plus grand nombre de travaux ont été effectués, à savoir l'ensemble utilisé par Pietikäinen, Mäenpää, Arvis et Iakovidis. Cet ensemble est présenté dans le paragraphe 4.2.3.

Enfin, pour la base BarkTex, trois partitions différentes, présentées dans le tableau 4.3, ont été utilisées dans le cadre de la classification de textures couleur. Dans les trois cas, les auteurs ont cherché une solution afin de ne pas considérer le fond de l'image, ce dernier perturbant la caractérisation des écorces d'arbres, comme nous l'avons vu dans le paragraphe 1.4.2. Pour exclure ce fond, nous avons proposé dans des travaux précédents de délimiter une zone d'étude de taille 80 × 140 pixels, centrée sur la texture de l'écorce présente dans des images de taille 128 × 192 [PVM08b, PVM07b, PVM07a, PVM08a]. Palm propose également cette solution mais délimite quant à lui une zone de taille 200 × 300 pixels, centrée sur la texture présente dans des images de taille 256 × 384 [Pal04, PL02]. Münzenmayer choisit par contre de considérer une région d'intérêt de taille 128 × 128 pixels, centrée sur l'écorce présente dans les images de taille 256 × 384, et d'en extraire ensuite 4 imageries de taille 64 × 64. Après avoir examiné ces trois propositions, il s'avère que les deux premières ne permettent pas d'exclure totalement le fond pour certaines images de la base. Nous choisissons donc d'utiliser la partition proposée par Münzenmayer, ce qui permet en plus de considérer un maximum de prototypes pour la sélection et un maximum d'images test pour la classification. Cet ensemble d'images est décrit dans le paragraphe 4.2.4.

En ce qui concerne la taille et la résolution des images à utiliser, aucune analyse précise n'a, à notre connaissance, étudié l'influence de ces paramètres sur la qualité de la classification. Il semble certain que ces différents paramètres dépendent des textures contenues dans les images considérées. Seul Khotanzad compare les résultats de classification obtenus d'une part

en considérant des images de taille 16×16 pixels et d'autre part des images de taille 64×64 pixels. Il construit pour cela deux bases distinctes formées de 1024 images issues de la base VisTex uniformément réparties en 16 classes, et valide son approche avec une partition de type Leaving-one-out [KH06]. Il en ressort que la classification des images de taille 64×64 pixels donne de meilleurs résultats que la classification des images de taille 16×16 pixels. Cependant, cette étude ne permet pas de conclure de manière générale sur une taille et une résolution d'images appropriées.

4.2.2 Ensemble d'images OuTex

L'ensemble d'images OuTex que nous utilisons est constitué de 68 classes avec 20 images de taille 128×128 pixels par classe, ce qui représente un total de 1 360 images. La moitié d'entre elles est utilisée pour l'apprentissage et les images restantes sont utilisées pour tester la méthode de classification.

Cet ensemble d'images est créé à partir de 68 images différentes de taille 746×538 pixels, dont sont extraites 20 imagettes de taille 128×128 . Chaque classe est donc construite à partir d'une unique image originale. La figure 4.1 illustre quelques unes de ces 68 textures couleur. Ces images sont acquises avec une lampe à incandescence et une résolution de 100 dpi, et les textures contenues dans ces images ne subissent aucune rotation.




Figure 4.1 : Exemples de textures couleur issues de la base OuTex.

La figure 4.2 illustre la manière dont sont créées les 20 imagettes et comment elles sont assignées à la base d'images d'apprentissage et à la base d'images test. La taille de l'image d'origine n'étant pas un multiple de 128 pixels, on arrête une zone d'étude, centrée sur l'image et dont la taille est proportionnelle à 128, pour créer les imagettes.

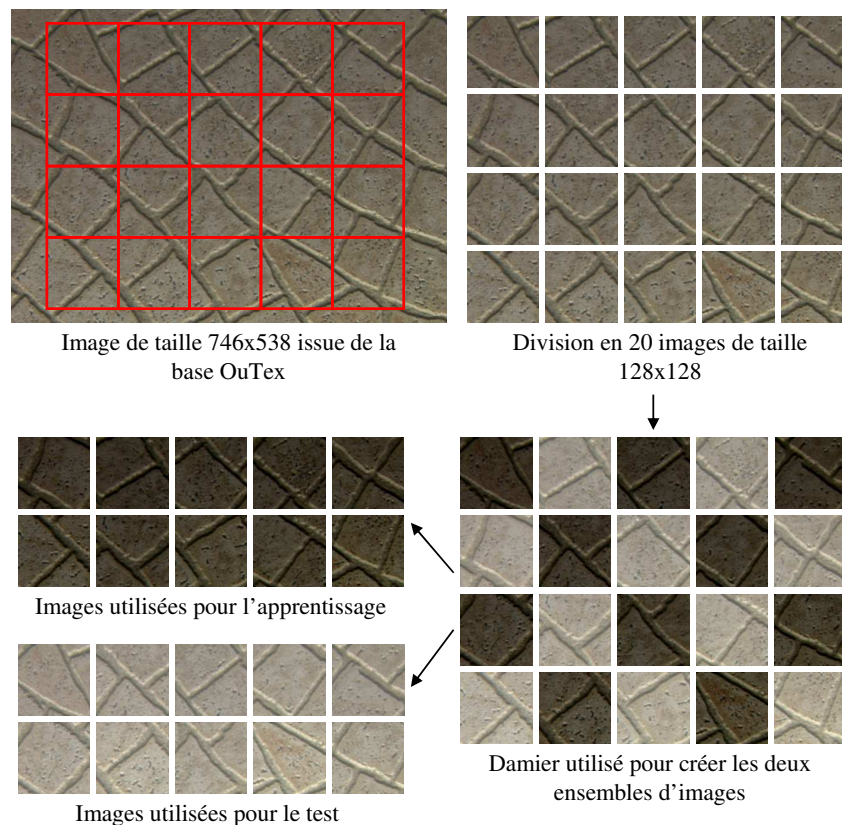


Figure 4.2 : Création de la base d'apprentissage et de la base de test OuTex.

Cet ensemble d'images est disponible à l'adresse <http://www.outex.oulu.fi/index.php?page=classification> sous le nom OUTEX-TC-00013.

4.2.3 Ensemble d'images VisTex

L'ensemble d'images VisTex que nous utilisons est créé de la même manière que l'ensemble d'images OuTex que nous venons de présenter, mis à part qu'ici, 54 images de taille 512×512 pixels sont utilisées pour créer chacune 16 imagettes de taille 128×128 pixels. La figure 4.3 illustre quelques unes de ces 54 textures couleur, tandis que la figure 4.4 illustre la création des 16 imagettes et la manière dont elles sont assignées à la base d'images d'apprentissage et à la base d'images test.

54 classes avec 16 images par classe, soit 864 images, forment donc l'ensemble d'images VisTex considéré, avec la moitié de ces images qui est utilisée pour l'apprentissage et les images restantes, pour tester la méthode de classification.

Cet ensemble d'images est disponible à l'adresse <http://www.outex.oulu.fi/index.php?page=contributed> sous le nom CONTRIBUT-TC-00006.




Figure 4.3 : Exemples de textures couleur issues de la base VisTex.

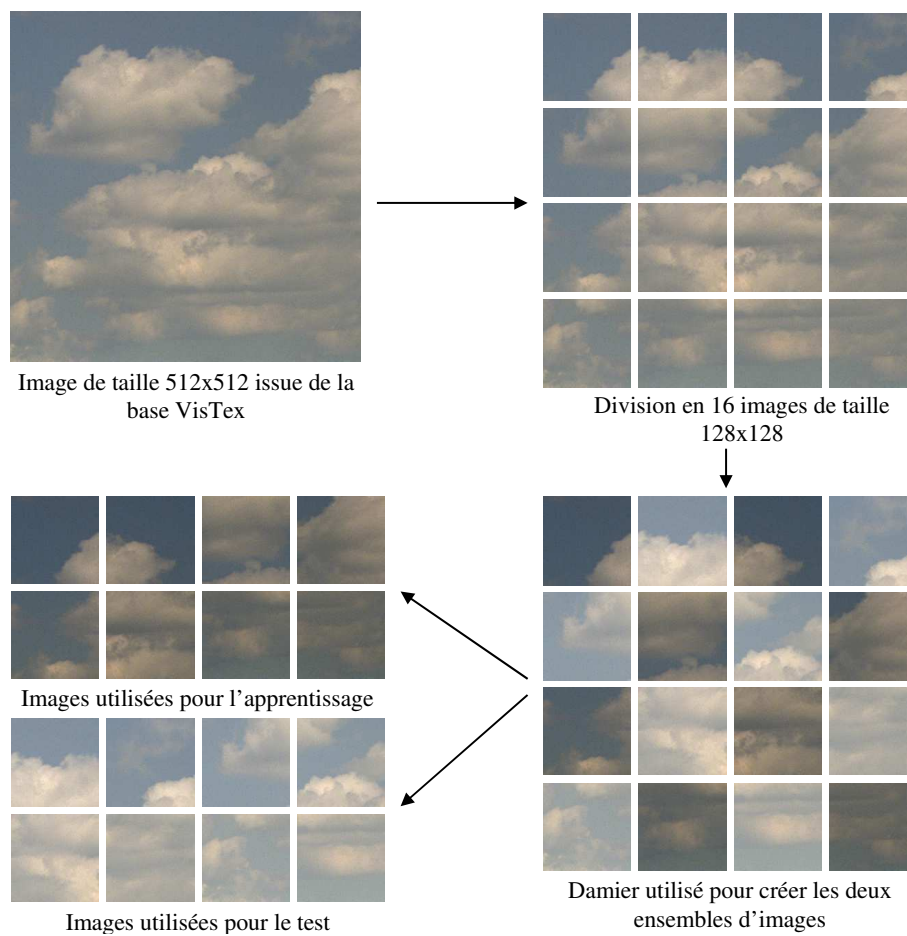


Figure 4.4 : Création de la base d'apprentissage et de la base de test VisTex.

4.2.4 Ensemble d'images BarkTex

La base BarkTex comporte 6 classes d'images de texture couleur, avec 68 images par classe, disponibles en différentes tailles : 128×192 pixels et 256×384 pixels [Lak]. Nous avons choisi d'utiliser l'ensemble d'images proposé par Münzenmayer. Pour construire cet ensemble, il faut tout d'abord délimiter une zone d'étude de taille 128×128 pixels centrée sur l'écorce présente dans les images de taille 256×384 . Il s'agit ensuite d'extraire de chaque zone d'intérêt 4 imagerettes de taille 64×64 , comme le montre la figure 4.5.

On obtient alors un ensemble de $68 \times 4 = 272$ imagerettes de taille 64×64 pixels pour chacune des 6 classes, soit 1632 images. Les bases d'apprentissage et de test sont créées de la même manière que pour les ensembles d'images VisTex et OuTex.

Notons que les classes qui définissent l'ensemble d'images BarkTex que nous utilisons proviennent de différentes images, contrairement aux ensembles VisTex et OuTex définis aux paragraphes 4.2.3 et 4.2.2, où chaque classe provient d'une seule et même image originale. La discrimination des classes de la base BarkTex semble donc plus complexe.




Figure 4.5 : Extraction de 4 imagerettes d'une des images de la base BarkTex.

Nous venons de présenter les ensembles d'images qui seront utilisés pour tester la méthodologie de classification de textures couleur développée. Nous choisissons de présenter les détails des résultats expérimentaux uniquement sur l'ensemble d'images OuTex afin de ne pas alourdir le chapitre. Le choix de considérer cet ensemble plutôt que les ensembles extraits des bases VisTex et BarkTex est motivé par le fait que la base OuTex est plus récente et que les conditions d'acquisition des images y sont contrôlées.

Le paragraphe suivant détaille donc tout d'abord les résultats expérimentaux obtenus après avoir appliqué notre approche sur la base d'images OuTex. Puis, nous analyserons de manière

plus générale dans le paragraphe 4.4, les résultats expérimentaux figurant en annexe E, obtenus avec les ensembles VisTex et BarkTex.

4.3 Résultats expérimentaux obtenus avec la base de référence OuTex

Dans ce paragraphe, nous présentons les résultats et les temps d'exécution obtenus avec l'ensemble d'images OuTex lors des étapes de génération et de sélection des attributs de texture couleur. Nous avons choisi de décrire plus particulièrement ces étapes car elles constituent l'originalité de notre approche de classification. Ainsi, nous présentons dans le paragraphe 4.3.1 les temps d'exécution obtenus lors de l'étape de génération des attributs d'Haralick extraits des matrices de co-occurrences chromatiques isotropiques de taille réduite. Puis, dans le paragraphe 4.3.2, nous examinons les résultats de la sélection et les temps d'exécution correspondants.

Notons que nous avons choisi de fixer le nombre N de quantification des niveaux des composantes couleur à 16 pour présenter ces résultats et ces temps de calcul. En effet, nous verrons dans le paragraphe 4.6.1.1 que cette valeur de quantification permet d'obtenir le meilleur compromis entre les résultats de classification et les temps de traitement.

4.3.1 Temps de calcul des attributs d'Haralick

Lors de la phase d'apprentissage, les attributs de texture couleur sont calculés pour chaque image d'apprentissage :

- Les images prototypes sont tout d'abord codées dans les $N_E = 28$ espaces couleur présentés au paragraphe 3.2.2.
- Puis leurs composantes couleur sont sous-quantifiées en $N = 16$ niveaux par la méthode de sous-quantification uniforme décrite au paragraphe 3.2.3.2.
- Ensuite, les 6 matrices de co-occurrences chromatiques isotropiques, présentées au paragraphe 1.9.2.3, sont calculées à partir de chaque image codée.
- Enfin les 13 premiers attributs d'Haralick décrits au paragraphe 1.9.2.2 sont extraits de chaque matrice.

Afin d'alléger les notations, nous notons ici :

- $m^{C_k, C_{k'}}$ (plutôt que $m^{C_k, C_{k'}}(1, 8 - \text{voisinage})$), la matrice de co-occurrences chromatique isotropique qui mesure l'interaction spatiale entre les composantes couleur C_k et $C_{k'}$ des pixels pris deux à deux.
- $f_i^{C_k, C_{k'}}$ (plutôt que $f_i^{C_k, C_{k'}}(1, 8 - \text{voisinage})$), le $i^{\text{ème}}$ attribut extrait de la matrice de co-occurrences chromatique isotropique $m^{C_k, C_{k'}}$.

Le temps de calcul de ces $D = 28 \times 6 \times 13 = 2184$ attributs, générés à partir d'une image de taille 128×128 pixels, est de 2,34 s. Cela correspond à un temps de calcul moyen Te de 1,07

ms par attribut. Notons que ces temps sont obtenus avec un PC cadencé à 2.08 GHz équipé de 448 Mo de RAM.

Une fois l'étape de génération effectuée, l'ensemble des attributs est réduit par la méthode de sélection présentée au paragraphe 3.4. Le paragraphe suivant décrit les résultats de cette sélection et les temps de traitement associés à cette étape.

4.3.2 Résultats et temps de traitement obtenus lors de la sélection

La méthode de sélection que nous avons développée se divise en deux étapes : la construction des d_{max} sous-espaces candidats, décrite au paragraphe 3.4.1, et la sélection de l'espace d'attributs le plus discriminant, présentée dans le paragraphe 3.4.2.

Pour tester notre méthode de classification de textures couleur sur les bases de référence, nous choisissons de considérer $d_{max} = 50$ sous-espaces candidats. Bien qu'elle soit *a priori* trop importante dans le contexte d'une application industrielle, cette valeur nous permettra d'obtenir des données suffisamment représentatives pour analyser les résultats et les temps de traitement de la sélection.

4.3.2.1 Construction des $d_{max} = 50$ sous-espaces candidats

Le tableau 4.4 présente les trois premiers attributs de texture couleur sélectionnés, formant les trois premiers sous-espaces d'attributs candidats pour discriminer les textures couleur de la base OuTex.

d	Espace couleur	Matrice	Attribut	J_9
1	$(I1, S1, H1)$	$m^{S1, H1}$	$f_{10}^{S1, H1}$	$6,76 \times 10^{-3}$
2	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, h_{C1C2}}$	$f_5^{C_{C1C2}, h_{C1C2}}$	$7,36 \times 10^{-5}$
3	(x, y, z)	$m^{z, z}$	$f_7^{z, z}$	$1,09 \times 10^{-6}$

Tableau 4.4 : Les trois premiers sous-espaces candidats pour discriminer les textures couleur de la base OuTex.

Chaque ligne de ce tableau correspond à une itération de la procédure de construction des d_{max} sous-espaces candidats et indique donc l'attribut ajouté au sous-espace d'attributs sélectionné à l'itération précédente. Ce tableau renseigne également, pour chaque itération de rang d , la valeur du critère de Wilks J_9 (cf. équation 2.14) mesurant le pouvoir discriminant du sous-espace d'attributs sélectionné de dimension d , composé des d attributs sélectionnés lors des d itérations successives.

Lors de la première itération, l'attribut le plus discriminant, c'est-à-dire celui qui minimise le critère de Wilks J_9 , est le dixième attribut d'Haralick $f_{10}^{S1, H1}$ extrait de la matrice de co-occurrences chromatique isotropique de taille réduite $m^{S1, H1}$, issue de l'espace $(I1, S1, H1)$. La valeur du critère J_9 de cet attribut est $6,76 \times 10^{-3}$.

A la seconde itération, $f_{10}^{S1,H1}$ est couplé à chacun des attributs qui n'ont pas encore été sélectionnés et dont la corrélation avec $f_{10}^{S1,H1}$ n'excède pas 0,75. Le sous-espace d'attributs de dimension $d = 2$ qui minimise le critère de Wilks J_9 est ici composé de $f_{10}^{S1,H1}$ et du cinquième attribut d'Haralick $f_5^{C_{C1C2},h_{C1C2}}$ extrait de la matrice de co-occurrences chromatique isotropique de taille réduite $m^{C_{C1C2},h_{C1C2}}$ calculée dans l'espace (A, C_{C1C2}, h_{C1C2}) . Le pouvoir discriminant de ce couple d'attributs est $7,36 \times 10^{-5} \dots$

Nous n'avons pas jugé utile d'indiquer ici les 47 attributs suivants sélectionnés par notre méthode. Toutefois, l'ensemble des $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de l'ensemble d'images OuTex est présenté en annexe E dans le tableau E.1.

Il est intéressant de noter que lorsque la méthode de classification de textures couleur est appliquée à l'ensemble d'images OuTex, l'attribut d'Haralick le plus souvent sélectionné est l'attribut f_5 . En effet, cet attribut, qui caractérise l'homogénéité locale au sein des textures, est sélectionné 14 fois sur 50. D'autre part, les espaces couleur qui semblent discriminer au mieux les textures de cette base sont les espaces (x, y, z) et $(I4, S3, H2)$, car ils sont les plus souvent associés à un attribut sélectionné (10% des cas).

L'opération de construction des $d_{max} = 50$ sous-espaces d'attributs candidats se réalise en 576 s, soit 10 min environ, avec un PC cadencé à 2.08 GHz. Les attributs sélectionnés sont ensuite centrés et réduits. Cette opération est réalisée en 125 ms environ.

Une fois les d_{max} sous-espaces d'attributs candidats déterminés, la sélection du sous-espace d'attributs le plus discriminant est effectuée grâce à la méthode présentée dans le paragraphe 3.4.2.

4.3.2.2 Sélection du sous-espace d'attributs le plus discriminant

Lors de cette étape, les taux d'images test bien classées obtenus en considérant chacun des d_{max} sous-espaces précédemment déterminés sont comparés. La figure 4.6 illustre les taux T de bonne classification des images test de la base OuTex, obtenus en classant les images dans chaque sous-espace d'attributs candidat de dimension d , par la méthode du plus proche voisin.

Par exemple, le taux d'images test OuTex bien classées obtenu en considérant le sous-espace mono-dimensionnel formé de l'attribut $f_{10}^{S1,H1}$ est 12.65%. De même, le taux obtenu en considérant le sous-espace bi-dimensionnel formé des deux premiers attributs sélectionnés atteint 40.00%.

Nous remarquons que le taux d'images test bien classées se stabilise à environ 94% à partir de la dimension $d = 8$.

La figure 4.7 présente les temps T_c (en secondes) requis pour classer les 680 images test




Figure 4.6 : Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat.

de la base OuTex en fonction de la dimension d du sous-espace d'attributs candidat. Ces temps comprennent non seulement le temps de calcul des d attributs sélectionnés, mais surtout le temps de classification des 680 images test par la méthode du plus proche voisin, qui est prépondérant.




Figure 4.7 : Temps de classification (en secondes) des 680 images test de la base OuTex, en fonction de la dimension d du sous-espace d'attributs candidat.

Le temps T_c varie de 85 s, lorsque les 680 images test de la base OuTex sont caractérisées par l'attribut $f_{10}^{S1,H1}$, à 2 644 s, soit environ 44 min, lorsqu'elles sont représentées dans le sous-espace d'attributs de dimension $d_{max} = 50$. Nous pouvons remarquer que ce temps est

proportionnel à la dimension d du sous-espace candidat.

Pour calculer ces $d_{max} = 50$ taux, 50 exécutions de classification sont ainsi effectuées en 66 600 secondes environ (18 h 30 min), ce qui correspond à la somme des temps T_c relatifs à chaque dimension.

Une fois calculés, ces d_{max} taux sont comparés afin de déterminer le sous-espace final de dimension \hat{d} qui offre le meilleur taux de classification d'images test. Cette étape conclut la phase d'apprentissage qui se déroule globalement en 68 760 s (19 h 6 min). Ce temps d'exécution est très important du fait que nous avons choisi de considérer $d_{max} = 50$ sous-espaces candidats afin de disposer de données suffisamment représentatives pour analyser, dans ce chapitre, les résultats et les temps de traitement de la sélection. Lors de l'application de la méthode dans un contexte industriel, nous travaillerons *a priori* avec une valeur de d_{max} beaucoup plus faible.

Dans le cas de la classification des images de la base OuTex, le meilleur taux d'images test bien classées est obtenu avec le sous-espace formés des $\hat{d} = 38$ premiers attributs sélectionnés et atteint 95.44%.

En considérant ce sous-espace d'attributs de dimension $\hat{d} = 38$, le temps nécessaire pour classer une image de taille 128×128 pixels est d'environ 3 s.

Après avoir détaillé les résultats de classification et les temps d'exécution obtenus avec l'ensemble d'images OuTex, le paragraphe suivant analyse les mesures obtenues avec les bases VisTex et BarkTex.

4.4 Tests sur les autres bases

Dans ce paragraphe, nous présentons les performances de classification atteintes avec les ensembles d'images VisTex et BarkTex. Pour cela nous étudions les taux d'images test bien classées obtenus avec ces deux ensembles. Ils sont présentés respectivement sur les figures 4.8 et 4.9.

Les $d_{max} = 50$ sous-espaces candidats sélectionnés en considérant chacune de ces deux bases de référence sont présentés en annexe E dans les tableaux E.2 et E.3.

Pour l'ensemble d'images VisTex, c'est l'attribut f_{10} (20% des cas) et les espaces couleur (L^*, a^*, b^*) et (L^*, S_{uv}^*, h_{uv}) (12% des cas) qui sont les plus souvent retenus, et pour l'ensemble d'images BarkTex, c'est l'attribut f_5 (22% des cas) et les espaces couleur (L^*, u^*, v^*) et (L^*, S_{uv}^*, h_{uv}) (12% des cas chacun) qui sont les plus souvent sélectionnés.

En analysant les résultats de manière globale sur les trois bases d'images, nous pouvons remarquer que l'attribut d'Haralick f_5 (20% des cas) et l'espace couleur (L^*, S_{uv}^*, h_{uv}) (9% des cas) sont particulièrement pertinents pour discriminer les textures couleur car ils sont les plus

souvent retenus. Par contre, l'attribut f_4 et les espaces couleur (Y, Ch_1, Ch_2) et $(L, C_{Ch_1Ch_2}, h_{Ch_1Ch_2})$ sont les moins souvent sélectionnés (0.007% des cas).




Figure 4.8 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat.




Figure 4.9 : Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat.

Nous remarquons visuellement sur les figures 4.8 et 4.9 que les taux d'images test bien classées se stabilisent à partir d'une dimension d relativement faible :

- $d = 12$, lorsque l'ensemble d'images VisTex est examiné,
- $d = 17$, lorsque l'ensemble d'images BarkTex est considéré.

Concernant les temps nécessaires à la classification mesurés avec les bases VisTex et BarkTex, ils sont sensiblement identiques à ceux obtenus avec l'ensemble OuTex, proportionnellement à la taille d'image considérée, et augmentent également de manière quasi-linéaire avec la dimension d du sous-espace d'attributs candidat. Nous ne présentons pas ces données ici pour ne pas alourdir cette partie. Toutefois, elles sont disponibles dans l'annexe E sur les figures E.1 et E.2.

L'analyse des performances de classification montre qu'il est important de bien fixer la valeur de d_{max} . En effet, une valeur trop faible de d_{max} ne permet pas d'obtenir des résultats de classification satisfaisants et une valeur trop importante est inutile puisque cela augmente les temps d'apprentissage et de classification, sans pour autant améliorer les taux d'images bien classées. Cette valeur doit donc être fixée en fonction des contraintes de l'application, à savoir le taux minimum d'images bien classées que l'on doit obtenir et les temps d'apprentissage et de classification à ne pas dépasser.

Pour rappel, dans le cas de la classification des images de la base OuTex, le meilleur taux d'images test bien classées que nous avons obtenu est de 95.44% pour un sous-espace de dimension $\hat{d} = 38$.

Pour l'ensemble d'images VisTex, le meilleur taux d'images test bien classées est 99.07%. Il est obtenu avec un sous-espace d'attributs discriminant de dimension $\hat{d} = 26$.

Enfin, pour l'ensemble d'images BarkTex, le meilleur taux d'images test bien classées est obtenu avec un sous-espace de dimension $\hat{d} = 50$ et atteint 93.87%.

Nous obtenons des résultats de classification encourageants pour les trois ensembles d'images. Ces taux montrent la pertinence de notre méthode, comme nous allons le vérifier dans le paragraphe suivant, où nos résultats sont comparés avec ceux obtenus par les autres auteurs ayant utilisé ces ensembles d'images.

4.5 Comparaison des résultats de classification avec les travaux antérieurs

Nous avons choisi de considérer trois ensembles d'images couramment utilisés, extraits des bases VisTex, OuTex et BarkTex, afin de pouvoir comparer la pertinence de notre approche avec un maximum d'autres méthodes de classification d'images de texture couleur. Les tableaux 4.5, 4.6 et 4.7 recensent les résultats de classification obtenus par ces méthodes avec les ensembles d'images OuTex, VisTex et BarkTex présentés au paragraphe 4.2 :

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Méthode de classement	Taux
Pietikäinen 2002 [PMV02]	Histogramme d'image	(R, G, B)	-	16^3	3-PPV	94.7%
Mäenpää 2004 [MP04]	Histogramme d'image	(H, S, V)	-	16^3	1-PPV	95.4%
Arvis 2004 [ADBB04]	Attributs extraits des matrices de co-occurrences chromatiques	(R, G, B)	Construction d'un sous-espace discriminant par AFD à partir de l'espace d'attributs initial de dimension $D = 30$	-	5-PPV	94.9% avec $N = 32$
Xu 2005 [XYD05]	Attributs extraits de la transformée en ondelettes	(R, G, B)	-	5	7-PPV	85.2%
Iakovidis 2005 [IMK05]	Histogramme des LBP	(H, S, V)	-	4608	Machines à vecteur support	93.5%

Tableau 4.5 : Méthodes ayant été testées sur l'ensemble d'images OuTex.

- La première colonne de ces tableaux indique la référence de l'article, ainsi que l'auteur et l'année de parution.
- La seconde colonne montre les attributs de texture couleur utilisés pour caractériser les différentes classes d'images, parmi ceux présentés dans le chapitre 1.
- La troisième colonne énumère les différents espaces couleur qui ont été considérés pour classer les textures, parmi ceux présentés dans l'annexe A.
- La quatrième colonne indique si il y a eu une réduction de la dimension de l'espace d'attributs, et si oui, la méthode employée, parmi celles présentées dans le chapitre 2.
- La dimension de l'espace d'attributs utilisé lors de la phase de classification est spécifiée dans la cinquième colonne.
- La sixième colonne indique la méthode de validation et/ou de classification utilisée, parmi celles présentées dans le paragraphe 2.4.
- Enfin, la dernière colonne présente les résultats de classification obtenus.

Les meilleurs résultats de classification obtenus avec l'ensemble d'images OuTex atteignent 95.4% [MP04]. Mäenpää obtient ce taux d'images bien classées en caractérisant les textures

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Méthode de classement	Taux
Pietikäinen 2002 [PMV02]	Histogramme d'image	$(I1, I2, I3)$	-	16^3	3-PPV	99.8%
Mäenpää 2004 [MP04]	Histogramme d'image	$(I1, I2, I3)$	-	32^3	1-PPV	100%
Mäenpää 2004 [MP04]	Histogramme des LBP intra-composante	(L^*, a^*, b^*)	-	3×256	1-PPV	100%
Arvis 2004 [ADBB04]	Attributs extraits des matrices de co-occurrences chromatiques	(R, G, B)	Construction d'un sous-espace discriminant par AFD à partir de l'espace d'attributs initial de dimension $D = 30$	-	5-PPV	97.9% avec $N = 256$ et 97.7% avec $N = 32$
Iakovidis 2005 [IMK05]	Histogramme des LBP	(R, G, B)	-	4608	Machines à vecteur support	99.8%

Tableau 4.6 : Méthodes ayant été testées sur l'ensemble d'images VisTex.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Méthode de classement	Taux
Münzenmayer 2002 [MVK ⁺ 02]	Attributs extraits des histogrammes des sommes et des différences	(R, G, B)	-	15	Leaving one out + 1-PPV	87%

Tableau 4.7 : Méthodes ayant été testées sur l'ensemble d'images BarkTex.

couleur par un histogramme 3D extrait à partir d'images codées dans l'espace (H, S, V) et dont les composantes couleur sont uniformément sous-quantifiées pour passer d'un niveau de quantification $N = 256$ à un niveau $N = 16$. La similarité entre les textures couleur est mesurée par le biais d'une intersection d'histogrammes, qui est couplée avec la méthode de classification du plus proche voisin pour classer les images de texture couleur.

Notons que pour arriver au choix de considérer l'espace (H, S, V) et le niveau de quantification $N = 16$, Mäenpää a comparé les résultats de classification obtenus en codant les images dans quatre espaces couleur différents $((R, G, B), (I1, I2, I3), (L^*, a^*, b^*)$ et (H, S, V)) et selon deux niveaux de quantification ($N = 16$ et $N = 32$). La combinaison (H, S, V) et $N = 16$ a permis d'obtenir les meilleurs résultats de classification parmi les huit combinaisons possibles.

Les meilleurs résultats de classification obtenus avec l'ensemble d'images VisTex atteignent quant à eux 100% [MP04]. C'est également Mäenpää qui obtient ce taux d'images bien classées avec deux méthodes de classification différentes :

- La première méthode caractérise les textures couleur par un histogramme 3D extrait à partir d'images codées dans l'espace $(I1, I2, I3)$ et dont les composantes couleur sont uniformément sous-quantifiées pour passer d'un niveau de quantification $N = 256$ à un niveau $N = 32$. En effet, pour l'ensemble d'images VisTex, c'est cette combinaison parmi les huit présentées ci-dessus qui a permis d'obtenir les meilleurs résultats de classification. La similarité entre les textures couleur est alors également mesurée par le biais d'une intersection d'histogrammes et la méthode de classification utilisée est la méthode du plus proche voisin.
- La seconde méthode qu'utilise Mäenpää pour obtenir ce taux d'images test bien classées caractérise quant à elle les textures couleur par un histogramme des LBP extrait à partir d'images codées dans l'espace (L^*, a^*, b^*) . La mesure du maximum de vraisemblance est alors couplée à la méthode du plus proche voisin pour classer les images test.

Enfin, les meilleurs résultats de classification obtenus avec la base d'images BarkTex atteignent 87% [MVK⁺02]. Ce taux est obtenu par Münzenmayer, qui choisit de caractériser les textures couleur par $D = 15$ attributs extraits des histogrammes des sommes et des différences, calculés à partir d'images codées dans l'espace (R, G, B) . Pour construire l'ensemble d'images test, il propose de considérer une partition de type Leaving one out, contrairement à notre approche où une partition Holdout est utilisée, et classe les textures couleur par la méthode du plus proche voisin.

Notons que le choix de Münzenmayer de considérer une partition de type Leaving-one-out associée à une méthode de classement du plus proche voisin, équivaut à utiliser une partition de type "resubstitution". En effet, cette approche, également utilisée par d'autres auteurs [Pal04, KH06, ZSZ07, PL02], revient à classer les prototypes et non un ensemble d'images différent de celui utilisé lors de l'apprentissage.

Pour rappel, les résultats obtenus avec la méthode de classification de textures couleur que nous avons développée sont :

- 99.07% avec $\hat{d} = 26$, pour l'ensemble d'images VisTex,
- 95.44% avec $\hat{d} = 38$, pour l'ensemble d'images OuTex,
- 93.87% avec $\hat{d} = 50$, pour l'ensemble d'images BarkTex.

Pour l'ensemble d'images VisTex, le résultat de classification que nous obtenons est proche de l'excellent taux obtenu par Mäenpää et pour l'ensemble d'images OuTex, nous obtenons la même performance que ce dernier.

Concernant la base BarkTex, les résultats obtenus avec notre approche sont très encourageants puisque nous améliorons de près de 7% le taux d'images test bien classées obtenu par Münzenmayer.

Cependant les résultats qu'obtient Mäenpää avec les histogrammes d'images nous interpellent. En effet, lorsqu'il utilise ces histogrammes 3D, les textures couleur sont caractérisées par des attributs de texture du premier ordre qui n'exploitent que la distribution des couleurs et négligent les relations spatiales entre les pixels. Cette méthode pourrait donc être mise à défaut dans le cas où les distributions couleur des classes sont similaires, mais les répartitions spatiales des couleurs sont différentes. Les figures 4.10 et 4.11 illustrent ce propos :

- Sur la figure 4.10, trois textures différentes sont présentées. Les couleurs de ces textures respectent des répartitions spatiales différentes mais des distributions similaires, comme le montre l'histogramme 3D commun à chacune de ces textures et présenté sur la figure 4.10(d).
- La figure 4.11 présente quant-à-elle les taux T de bonne classification des images test de la base BarkTex obtenus en fonction de la dimension d du sous-espace d'attributs sélectionné et selon que la texture couleur est caractérisée par les attributs d'Haralick ou de simples attributs statistiques du premier ordre.

Les attributs statistiques utilisés sont les suivants :

- | | |
|-------------------------------|-------------------------------------|
| ▪ la moyenne | ▪ l'écart-type autour de la moyenne |
| ▪ la médiane | ▪ l'écart-type autour de la médiane |
| ▪ le mode | ▪ l'écart-type autour du mode |
| ▪ le minimum | ▪ la symétrie autour de la moyenne |
| ▪ le maximum | ▪ la symétrie autour de la médiane |
| ▪ l'étendue | ▪ la symétrie autour du mode |
| ▪ l'intervalle inter-quartile | |

La caractérisation des images de la base BarkTex avec ces attributs statistiques donne de moins bons résultats de classification que ceux obtenus avec les attributs d'Haralick extraits des matrices de co-occurrences chromatiques. Ceci est très certainement dû au fait que les classes d'images de la base BarkTex se différencient principalement par la répartition spatiale des couleurs et moins par la distribution de ces dernières dans l'espace de représentation considéré.

Au contraire, pour les bases OuTex et VisTex, chaque classe est caractérisée par une distribution de couleur particulière, qui diffère assez fortement de celle des autres classes

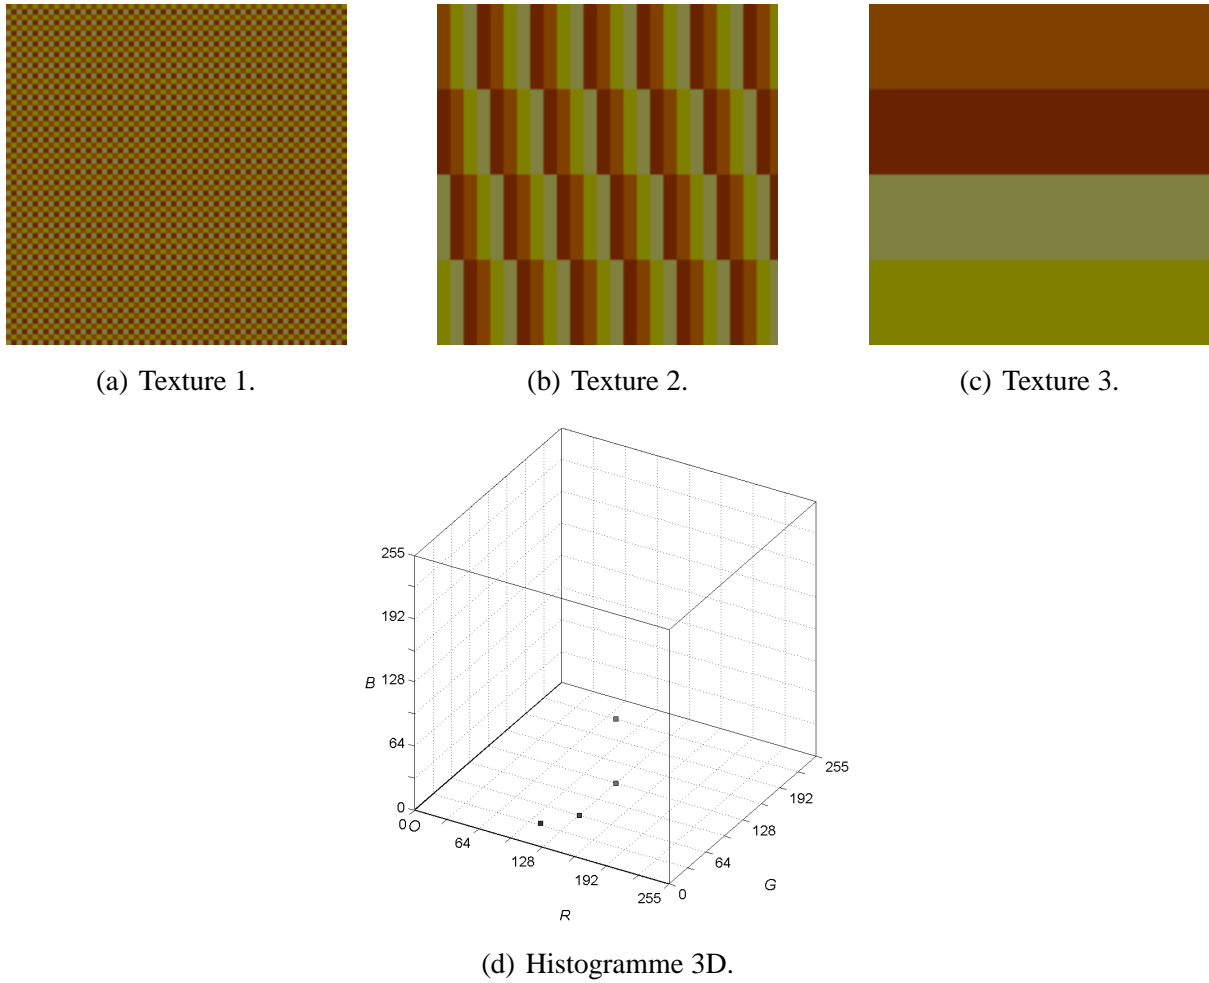


Figure 4.10 : Illustration de trois textures différentes et de leur histogramme 3D commun.




Figure 4.11 : Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.

contenues dans la base. C'est pourquoi, les attributs de texture couleur du premier ordre semblent être suffisants pour discriminer les classes de ces deux bases. Ceci explique sans doute les excellents résultats obtenus par Mäenpää avec les histogrammes 3D.

Cette idée est confortée par les figures E.3 et E.4 de l'annexe E où sont présentés les taux T de bonne classification des images test des bases OuTex et VisTex obtenus en fonction de la dimension d du sous-espace d'attributs sélectionné. La texture couleur est caractérisée soit par les attributs d'Haralick, soit par les attributs statistiques présentés ci-dessus. En effet, nous pouvons constater que les taux de classification obtenus avec les attributs du premier ordre se rapprochent des résultats obtenus en caractérisant les textures couleur par des attributs d'ordre supérieur.

Ces résultats mettent également en évidence qu'il serait nécessaire de construire une nouvelle base d'images de texture couleur où les classes ne sont pas principalement caractérisées par les distributions des couleurs.

Après avoir comparé les résultats de classification avec ceux obtenus lors de travaux antérieurs, nous étudions dans le paragraphe suivant l'influence des paramètres de la méthode que nous avons développée sur les résultats de classification et les temps de traitement.

4.6 Influence des paramètres de la méthode développée

Les paramètres de la méthode qui vont être étudiés dans ce paragraphe portent sur deux niveaux :

- ceux qui agissent sur les matrices de co-occurrences et donc sur la caractérisation des textures couleur :
 - le nombre N de quantification des niveaux des composantes couleur,
 - le voisinage utilisé lors du calcul des matrices de co-occurrences.
- ceux qui agissent sur la procédure de sélection des attributs :
 - la procédure de génération séquentielle (SFS ou SFFS),
 - la mesure du pouvoir discriminant des sous-espaces d'attributs.

A chaque fois que l'influence d'un de ces paramètres sera étudiée, les autres paramètres seront fixés aux valeurs qui définissent la méthode de classification de textures couleur développée, à savoir :

- le niveau N de quantification est fixé à 16,
- le "8-voisinage" est associé à la distance spatiale $\nu = 1$ pour calculer les matrices de co-occurrences,
- la procédure de génération séquentielle de type SFS est considérée,
- le critère de Wilks est utilisé comme mesure du pouvoir discriminant des sous-espaces d'attributs.

4.6.1 Influence des paramètres de caractérisation des textures couleur

4.6.1.1 Influence du niveau N de quantification

Pour étudier l'influence du niveau N de quantification sur les résultats de classification et les temps de traitements, nous proposons de considérer 8 niveaux de quantification différents ($N = 2, 4, 8, 16, 32, 64, 128$ et 256) et d'analyser les résultats de classification et les temps de traitements obtenus avec ces différentes valeurs de quantification.

Les figures 4.12, 4.13 et 4.14 illustrent, pour différents niveaux N de quantification, les taux T d'images test bien classées en fonction de la dimension d du sous-espace d'attributs candidat, respectivement sur les bases OuTex, VisTex et BarkTex.




Figure 4.12 : Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents niveaux de quantification N .

La figure 4.15 illustre quant à elle le temps moyen T_e (en millisecondes et présenté avec l'échelle logarithmique) pour extraire un attribut d'une image OuTex de taille 128×128 , en fonction du niveau N de quantification.

Les meilleurs résultats de classification sont obtenus avec :

- $\hat{d} = 26$ et $N = 32$ pour la base OuTex (95.74%),
- $\hat{d} = 26$ et $N = 16$ pour la base VisTex (99.07%),
- $\hat{d} = 49$ et $N = 256$ pour la base BarkTex (94.85%).

Il est intéressant de noter que les taux les plus élevés ne sont pas forcément obtenus avec le niveau de quantification maximal $N = 256$.

De manière globale, nous remarquons que dès que d est supérieur ou égal à 12 et quelque soit la base d'image utilisée, les résultats de classification obtenus lorsque N varie de 4 à 256




Figure 4.13 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents niveaux de quantification N .




Figure 4.14 : Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents niveaux de quantification N .

sont quasiment similaires. En effet, dans ce cas, l'écart moyen entre les taux d'images test bien classées obtenus avec les différents niveaux de quantification est de 1% avec l'ensemble OuTex, 0.6% avec l'ensemble VisTex et 2.7% avec l'ensemble BarkTex.




Figure 4.15 : Temps moyen Te (en millisecondes) pour extraire un attribut d'une image OuTex de taille 128×128 , en fonction du niveau de quantification N .

D'autre part, quelque soit d et lorsque N est supérieur ou égal à 16, la quantification des composantes couleur n'influence pas de manière significative les taux d'images bien classées. Dans ce cas, l'écart moyen entre les taux d'images test bien classées est dans ce cas de 0.7% lorsque l'ensemble OuTex est considéré, 0.3% avec l'ensemble VisTex et 1.2% avec l'ensemble d'images BarkTex.

Bien que les résultats de classification obtenus avec $N = 16$ (matrice de co-occurrences de taille réduite) soient similaires à aux résultats obtenus avec $N = 256$ (matrice de co-occurrences standard), les sous-espaces d'attributs candidats sélectionnés en considérant chacun de ces deux niveaux de quantification sont constitués d'attributs différents. En effet, les tableaux E.1 et E.4 de l'annexe E montrent que seul le premier attribut est commun.

Cependant, la figure 4.15 montre que, contrairement aux résultats de classification, le temps de calcul des attributs dépend significativement du niveau de quantification, particulièrement lorsque N est supérieur ou égal à 64.

Or, le temps de calcul des attributs influence quant à lui les temps de traitement des phases d'apprentissage et de classification. En effet, la phase d'apprentissage est divisée en deux étapes successives, le calcul des attributs et la sélection d'un sous-espace discriminant. De même, la phase de classification se divise en deux parties, le calcul des attributs précédemment sélectionnés et la décision d'assignation de l'image considérée.

Le tableau 4.8 présente les temps de traitement des phases d'apprentissage et de classification mesurés avec l'ensemble d'images OuTex, pour les 7 niveaux de quantification considérés.

Les temps nécessaires à la sélection et à la classification sont présentés pour une dimension $d = \hat{d} = 38$, dimension qui a permis d'obtenir les meilleurs résultats de classification pour l'ensemble d'images OuTex (cf. § 4.3.2.2).

	Apprentissage (pour 68x10 images de taille 128x128 pixels)				Classification en-ligne (pour une image de taille 128x128 pixels)		
	Calcul des $D = 2184$ attributs	Sélection ($\hat{d} = 38$)		Total	Calcul des $\hat{d} = 38$ attributs	Centrage- Réduction + Classification	Total
		Construction des $d_{max} = 50$ sous-espaces candidats	Sélection du sous- espace d'attributs le plus discriminant				
$N = 2$	1 490 s (2.3 %)	489 s	63 487 s	65 466 s	0,038 s (1.3 %)	2,868 s	2,906 s
$N = 4$	1 492 s (2.2 %)	687 s	66 444 s	68 623 s	0,038 s (1.2 %)	3,056 s	3,094 s
$N = 8$	1 506 s (2.2 %)	630 s	66 449 s	68 585 s	0,039 s (1.3 %)	2,894 s	2,932 s
$N = 16$	1 588 s (2.3 %)	576 s	66 597 s	68 761 s	0,041 s (1.4 %)	2,862 s	2,903 s
$N = 32$	2 150 s (3.1 %)	572 s	66 463 s	69 185 s	0,055 s (1.8 %)	2,992 s	3,047 s
$N = 64$	6 335 s (8.6 %)	549 s	66 468 s	73 352 s	0,162 s (5.3 %)	2,891 s	3,053 s
$N = 128$	37 606 s (35.9 %)	552 s	66 468 s	104 626 s	0,962 s (23.8 %)	3,081 s	4,043 s
$N = 256$	283 513 s (80.9 %)	542 s	66 470 s	350 525 s	8,654 s (73.8 %)	3,072 s	11,726 s

Tableau 4.8 : Temps de traitement des phases d'apprentissage et de classification.

Par exemple, pour un niveau de quantification $N = 16$, l'apprentissage à partir des 680 prototypes de taille 128×128 pixels dure 68 761 s, soit environ 19 heures. 2.3% de ce temps est consacré au calcul des $D = 2184$ attributs de textures couleur et le temps restant est consommé par la sélection du sous-espace d'attributs discriminant de dimension $\hat{d} = 38$, et plus particulièrement par la classification qui est faite pour chacune des dimensions. Lors de la phase de classification en-ligne, le calcul des $\hat{d} = 38$ attributs à partir d'une image test dure 41 ms, soit 1.4% du temps total et la classification de cette image par la méthode du plus proche voisin dure 2,9 s.

En analysant les temps présentés dans ce tableau, nous remarquons que plus le niveau de quantification augmente, plus la part allouée au temps de calcul des attributs est importante. Cette dernière atteint même 80.9% du temps d'apprentissage lorsque $N = 256$. Le temps de calcul des attributs tient donc une part significative lors de l'apprentissage. Il est également non négligeable lors de la phase de classification en-ligne, particulièrement lorsque le niveau de quantification est supérieur à 32.

Réduire ce niveau de quantification permet donc de diminuer les temps de calcul des attributs et donc les temps d'apprentissage et de classification. En effet, pour $\hat{d} = 38$, le temps de traitement de la phase d'apprentissage est réduit de 80.4% lorsque N est égal à 16 au lieu de 256 (68 761 s contre 350 525 s) et le temps de traitement de la phase de classification en-ligne

est réduit de 75.2% (2.903 s contre 11.726 s). Par ailleurs, cette réduction du temps de calcul ne se fait pas au détriment de la qualité de classification des images test.

Après avoir analysé l'influence du niveau de quantification de la couleur sur les performances de classification, nous en déduisons que le choix de fixer le niveau N de quantification à 16 permet d'obtenir un bon compromis entre les résultats de classification et les temps de traitement sur les bases étudiées.

Le paragraphe suivant analyse l'influence du voisinage considéré lors du calcul des matrices de co-occurrences sur les performances de classification. Cette analyse nécessite d'étudier non seulement l'influence du paramètre θ caractérisant la structure du voisinage, c'est-à-dire la ou les directions considérées pour analyser les relations spatiales entre les pixels (cf. figure 1.22), mais également l'influence de la distance spatiale ν séparant le pixel central de ses voisins.

4.6.1.2 Influence de la structure du voisinage

Influence de la structure du voisinage sur les résultats de classification

Cas des textures orientées Dans une précédente publication, nous avons étudié l'influence de la structure du voisinage considéré lors du calcul des matrices de co-occurrences sur la qualité de la discrimination des textures couleur orientées [PVM08b]. Nous avons comparé pour cela les résultats de classification des images de la base BarkTex obtenus en considérant les 7 voisinages différents présentés figure 1.22.

L'ensemble d'images BarkTex qui a été utilisé est celui décrit dans la dernière ligne du tableau 4.3. La méthode de classification de textures couleur considérée est quant-à-elle semblable à la méthode présentée dans le chapitre 3 à la différence suivante :

- aucune sous-quantification de la couleur n'est effectuée. Nous présentons donc les résultats pour un niveau de quantification N égal à 256.
- le critère de la trace est utilisé à la place du critère de Wilks.
- la dimension \hat{d} du sous-espace discriminant correspond au nombre de classes moins un.
- enfin, les résultats présentés sont obtenus avec la méthode de classification par affectation au barycentre le plus proche.

Le tableau 4.9 présente le taux T d'images bien classées obtenu en appliquant cette méthode sur la base BarkTex, en fonction du voisinage considéré lors du calcul des matrices de co-occurrences.

L'analyse de ce tableau montre que la considération du "2-voisinage" basé sur la direction horizontale ($\theta = 0^\circ$) permet d'obtenir les meilleurs résultats de classification. Ensuite, le meilleur taux est obtenu en considérant le "4-voisinage 1", qui contient également la direction $\theta = 0^\circ$ et le troisième meilleur résultat de classification est obtenu avec le "8-voisinage", voisi-

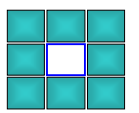
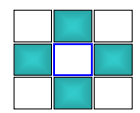
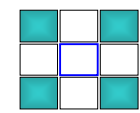
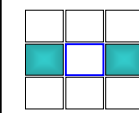
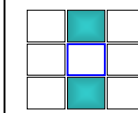
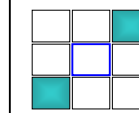
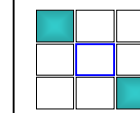
Voisinage							
T	72.22%	75%	64.35%	76.39%	54.17%	55.09%	56.02%

Tableau 4.9 : Taux T d'images BarkTex bien classées en fonction du voisinage considéré lors du calcul des matrices de co-occurrences.

nage incluant aussi la direction horizontale.

Or, les textures de la base BarkTex contiennent quant à elles des motifs verticaux. Ces motifs semblent être mieux discriminés avec des voisinages intégrant la direction horizontale. Le choix de la structure du voisinage dépend donc des textures analysées. Dans le cas de textures orientées, comme celles de la base BarkTex, il faut choisir une direction d'orientation adéquate.

Cas des textures quelconques Lorsque les textures analysées ne portent pas de directions privilégiées, comme pour les bases OuTex et Vistex, deux solutions semblent convenir pour caractériser ces textures :

- extraire les attributs d'Haralick à partir des matrices de co-occurrences calculées avec le "8-voisinage". En effet, ce voisinage caractérise les interactions spatiales entre les pixels selon les quatre directions $\theta = 0^\circ$, $\theta = 45^\circ$, $\theta = 90^\circ$ et $\theta = 135^\circ$.
- utiliser la moyenne $f_i^{C_k, C_{k'}, v, moy}$ (cf. équation 1.16) et la variance $f_i^{C_k, C_{k'}, v, var}$ (cf. équation 1.17) des attributs d'Haralick extraits des matrices de co-occurrences selon chaque direction θ (0° , 45° , 90° et 135°).

La figure 4.16 présente les taux d'images test bien classées obtenus avec la méthode de classification supervisée de textures couleur que nous avons développée en considérant d'une part les attributs d'Haralick extraits des matrices de co-occurrences isotropiques de taille réduite et d'autre part la moyenne et la variance des attributs d'Haralick extraits des matrices de co-occurrences selon chaque direction θ . Ces taux T , obtenus en considérant les sous-espaces d'attributs candidats pour chaque dimension d , sont présentés ici pour l'ensemble d'images OuTex. Les $d_{max} = 50$ sous-espaces d'attributs candidats sélectionnés en considérant la moyenne et la variance des attributs d'Haralick sont présentés en annexe E dans le tableau E.5. Il est intéressant de noter que très peu de variances d'attributs d'Haralick ont été sélectionnées et que la caractérisation des textures couleurs de la base OuTex se fait presque exclusivement avec la moyenne de ces attributs. D'autre part, les cinq premiers attributs utilisant la moyenne sont les mêmes que les cinq premiers attributs obtenus avec les matrices de co-occurrences isotropiques.

En analysant les résultats de classification des bases OuTex et VisTex présentés respectivement sur les figures 4.16 et E.5, nous remarquons que les taux d'images test bien classées obtenus avec chacune des deux structures de voisinage sont relativement proches.




Figure 4.16 : Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes structures de voisinage considérées lors du calcul des matrices de co-occurrences.

Les meilleurs taux de classification atteignent 95.44% ($\hat{d} = 38$) avec le "8-voisinage" et 96.76% ($\hat{d} = 31$) avec la moyenne et la variance des attributs d'Haralick. Ce dernier taux représente d'ailleurs le meilleur résultat de classification jamais atteint avec l'ensemble d'images OuTex.

Les résultats de classification obtenus avec l'ensemble d'images VisTex, qui contient également des textures couleur qui ne présentent pas de directions privilégiées, sont également disponibles dans l'annexe E sur la figure E.5. Avec cet ensemble, 99.07% ($\hat{d} = 26$) des images test ont été correctement classées en considérant le "8-voisinage" contre 98.61% ($\hat{d} = 44$) avec la moyenne et la variance des attributs d'Haralick.

Nous remarquons que pour la base OuTex, le meilleur taux de classification est obtenu en considérant la moyenne et la variance des attributs d'Haralick et inversement pour la base VisTex. Le choix entre ces deux structures de voisinage pour des textures qui n'ont pas de directions privilégiées importe donc peu vis-à-vis des résultats de classification.

Influence de la structure du voisinage sur le temps calcul des attributs

Selon le voisinage, une ou plusieurs directions sont considérées :

- les "2-voisinages" caractérisent les interactions spatiales entre les pixels selon une unique direction (horizontale, première diagonale, verticale ou deuxième diagonale),

- les "4-voisinages" caractérisent les interactions entre pixels selon deux directions,
- le "8-voisinage" caractérise les interactions spatiales selon les quatre directions.

Le temps de calcul des attributs dépend du nombre de directions à analyser. C'est pourquoi lorsque les textures considérées possèdent des motifs dans une direction particulière, choisir le "2-voisinage" qui caractérise les interactions spatiales selon la direction perpendiculaire aux motifs des textures analysées permet non seulement d'obtenir les meilleurs résultats de classification, comme nous l'avons vu précédemment, mais également de réduire le temps de calcul des attributs par rapport à l'utilisation d'un "4-voisinage" ou d'un "8-voisinage".

Lorsque les textures analysées ne présentent pas de directions privilégiées, nous avons vu qu'utiliser le "8-voisinage" permet d'obtenir des résultats de classification similaires par rapport à la considération de la moyenne et de la variance des attributs d'Haralick extraits des matrices de co-occurrences selon chaque direction θ (0° , 45° , 90° et 135°). Cependant, la caractérisation des textures couleur par la moyenne et la variance des attributs d'Haralick aboutit à un nombre d'attributs deux fois plus important que lorsque le "8-voisinage" est considéré. Le temps requis pour construire les d_{max} sous-espaces candidats lors de la sélection en est alors augmenté. Par exemple, pour construire les $d_{max} = 50$ sous-espaces d'attributs discriminant les textures couleur de la base OuTex, 1 886 s sont nécessaires lorsque la moyenne et la variance des attributs d'Haralick sont considérées contre 576 s, lorsque le "8-voisinage" est utilisé.

La structure du voisinage a donc une influence significative sur les temps de calcul et de sélection des attributs, et par conséquent sur les temps de traitement des phases d'apprentissage et de classification.

Afin d'atteindre un bon compromis entre les résultats de classification et les temps d'exécution, nous recommandons d'utiliser :

- le "2-voisinage" qui caractérise les interactions spatiales selon la direction perpendiculaire aux motifs des textures analysées, lorsque celles-ci présentent une direction privilégiée,
- le "8-voisinage", lorsque les textures analysées ne portent pas de directions privilégiées.

Après avoir analysé l'influence de la structure du voisinage sur les résultats de classification et les temps de traitement, nous nous intéressons dans le paragraphe suivant à l'influence de la distance spatiale ν séparant le pixel central de ses voisins lors du calcul des matrices de co-occurrences.

4.6.1.3 Influence de la distance spatiale ν

La plupart des auteurs utilisant les attributs d'Haralick fixe la distance spatiale ν à 1 lors du calcul des matrices de co-occurrences pour caractériser les textures couleur [BR04, ADBB04, AML08, BSP00, PBL06]. Très peu d'auteurs ont en fait étudié l'influence de cette distance sur

les résultats de classification de textures couleur. Seul Palm compare les taux de classification des bases VisTex et BarkTex obtenus en considérant différentes valeurs de ν : $\nu = 1, 5, 10, 15, 20$. Il montre que le choix de la distance spatiale ν dépend de la base d'images utilisée [Pal04].

Partant de ce constat, il semble intéressant de retenir plusieurs valeurs de ν pour adapter une méthode à un maximum de bases d'images. Cependant, cette considération multiple impose un temps d'apprentissage plus important. En effet, plus le nombre de distances spatiales considérées est élevé, plus la dimension de l'espace initial d'attributs est importante, et plus les temps nécessaires au calcul et à la sélection des attributs augmentent. Il est donc intéressant de mesurer la pertinence d'une telle considération vis-à-vis des résultats de classification et des temps de traitement.

Pour cela, nous proposons de comparer les résultats de classification et les temps d'apprentissage obtenus en considérant :

- une seule distance ν fixée à 1,
- une seule distance ν fixée à 5,
- et 5 distances ν fixées respectivement à 1,2,3,4 et 5.

Le choix de retenir ces distances fait suite aux travaux de Palm, qui montre que parmi les distances $\nu = 1, 5, 10, 15$ et 20, les distances $\nu = 1$ et $\nu = 5$ permettent d'obtenir les meilleurs résultats de classification pour les bases Vistex et BarkTex [Pal04]. Nous faisons donc l'hypothèse que choisir des distances comprises entre $\nu = 1$ et $\nu = 5$ permet d'obtenir une bonne caractérisation pour différentes bases d'images de texture couleur.

La figure 4.17 illustre les taux d'images test bien classées obtenus avec notre approche en considérant la distance $\nu = 1$, la distance $\nu = 5$ et les 5 distances $\nu = 1, 2, 3, 4$ et 5 pour calculer les attributs de texture couleur. Ces taux T d'images test bien classées, obtenus en fonction de la dimension d du sous-espace d'attributs candidat, sont présentés ici avec l'ensemble d'images OuTex. Les $d_{max} = 50$ sous-espaces d'attributs candidats sélectionnés en considérant la distance $\nu = 5$ et les 5 distances $\nu = 1, 2, 3, 4$ et 5 sont présentés en annexe E respectivement dans les tableaux E.6 et E.7. D'autre part, les résultats de classification obtenus avec les ensembles d'images VisTex et BarkTex sont également disponibles dans cette même annexe sur les figures E.6 et E.7.

En analysant les résultats de classification présentés sur la figure 4.17, nous remarquons que les taux d'images test bien classées obtenus en considérant plusieurs distances spatiales sont similaires aux résultats obtenus lorsque une unique distance est considérée. D'autre part, quelque soit la ou les distances spatiales utilisées, les tout premiers attributs sélectionnés sont identiques (cf. tableaux E.1, E.6 et E.7).

Les meilleurs taux de classification atteignent 95.44% ($\hat{d} = 38$) avec $\nu = 1$ et 94.85%, que ce soit avec $\nu = 5$ ($\hat{d} = 46$) ou avec les 5 distances $\nu = 1, 2, 3, 4$ et 5 ($\hat{d} = 36$).

Pour la base VisTex, les meilleurs taux obtenus atteignent 97.69% avec $\nu = 5$ ($\hat{d} = 26$) et 99.07%, que ce soit avec $\nu = 1$ ($\hat{d} = 26$) ou avec les 5 distances $\nu = 1, 2, 3, 4$ et 5 ($\hat{d} = 39$). Enfin,




Figure 4.17 : Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes distances spatiales considérées lors du calcul des matrices de co-occurrences.

pour la base BarkTex, les meilleurs taux de classification atteignent 93.87% ($\hat{d} = 50$) avec la distance $\nu = 1$, 90.2% ($\hat{d} = 28$) avec la distance $\nu = 5$ et 94.00% ($\hat{d} = 49$) avec $\nu = 1, 2, 3, 4$ et 5.

L'analyse de ces résultats montre que la considération de plusieurs distances spatiales ν lors du calcul des matrices de co-occurrences n'améliore pas forcément les taux de bonne classification. Ce phénomène est vraisemblablement dû au fait que nous utilisons des procédures de sélection d'attributs non exhaustives pour pré-sélectionner les d_{max} sous-espaces d'attributs candidats, et que la sélection de ces sous-espaces peut être perturbée par une dimension trop importante de l'espace initial d'attributs.

Dans ce contexte, considérer une distance $\nu = 1$ reste donc le meilleur compromis entre les résultats de classification et les temps de calcul, quelque soit l'ensemble d'images considéré.

Après avoir analysé l'influence des paramètres liés à la caractérisation des textures couleur sur les résultats de classification et les temps de traitement, nous examinons dans le paragraphe suivant l'influence des paramètres considérés pour sélectionner un sous-espace d'attributs discriminant.

4.6.2 Influence des paramètres de la sélection d'attributs

4.6.2.1 Influence de la procédure de génération

L'étude des méthodes de sélection, présentée dans les paragraphes 2.3 et 3.4, a mis en évidence que la procédure séquentielle flottante SFFS est particulièrement bien adaptée dans le cas où la dimension D de l'espace initial d'attributs est supérieure à 100, ce qui est notre cas. Cependant, la contrainte liée au temps d'apprentissage nous a amené à considérer une procédure de génération séquentielle SFS moins gourmande en temps d'exécution. Cette dernière semble moins performante que la procédure SFFS car elle n'effectue pas de "backtracking". C'est ce que nous proposons de vérifier dans ce paragraphe en comparant les résultats de classification obtenus avec ces deux procédures de génération.

La figure 4.18 illustre les taux d'images test bien classées obtenus avec la méthode de classification supervisée de textures couleur que nous avons développée en considérant d'une part la procédure de génération SFS et d'autre part la procédure de génération SFFS. Ces taux T d'images test bien classées, obtenus en fonction de la dimension d du sous-espace d'attributs candidat, sont présentés ici avec l'ensemble d'images OuTex. Les $d_{max} = 50$ sous-espaces d'attributs candidats sélectionnés en considérant la procédure de génération SFFS sont présentés en annexe E dans le tableau E.8. Les résultats obtenus avec les ensembles VisTex et BarkTex sont également présentés dans cette annexe E dans les figures E.8 et E.9.




Figure 4.18 : Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes procédures de génération.

En analysant les résultats de classification présentés sur la figure 4.18, nous remarquons que les taux d'images test bien classées obtenus avec chacune des deux procédures de génération sont très similaires. D'autre part, quelque soit la procédure de génération considérée, les trois premiers attributs sélectionnés sont identiques (cf. tableaux E.1 et E.8).

Les meilleurs taux de classification atteignent 95.44% que ce soit avec la procédure de génération SFS ($\hat{d} = 38$) ou avec la procédure de génération SFFS ($\hat{d} = 24$). Ici, la procédure SFFS sélectionne un sous-espace discriminant de dimension plus faible que celui retenu par la procédure SFS tout en conservant les mêmes performances.

Avec l'ensemble d'images extrait de la base VisTex, les meilleurs taux de classification sont eux aussi identiques et atteignent 99.07% avec les procédures SFS ($\hat{d} = 26$) et SFFS ($\hat{d} = 32$). Dans ce cas, c'est la dimension du sous-espace retenu par la méthode SFS qui est la plus faible.

Enfin, avec la base BarkTex, les meilleurs taux de classification obtenus atteignent 93.87% ($\hat{d} = 50$) avec la procédure de génération SFS et 93.38% ($\hat{d} = 50$) avec la procédure de génération SFFS.

La considération de la procédure de génération SFFS n'améliore donc pas les résultats de classification par rapport à l'utilisation de la procédure séquentielle basique SFS. Cette conclusion rejoint celle récemment émise par Schenk, qui compare les performances de reconnaissance d'écritures atteintes en considérant chacune de ces deux procédures de génération [SKR09]. Les travaux de Lézoray confirment également que les procédures SFS et SFFS se comportent globalement de la même manière [Léz00]. Il compare pour cela les nombres d'attributs sélectionnés et les taux de reconnaissance obtenus avec différentes bases de données en considérant, entre autres, les procédures séquentielles SFS et SFFS.

L'approche SFS, qui n'effectue pas de retour en arrière lors de la recherche du sous-espace discriminant, est d'autre part moins coûteuse en temps de calcul. En effet, le temps requis pour sélectionner les $d_{max} = 50$ attributs pertinents discriminant les textures couleur de la base OuTex passe de 576 s, lorsque la procédure SFS est considérée, à 1 391 s, lorsque la procédure SFFS est utilisée. La procédure séquentielle SFS semble donc offrir le meilleur compromis entre les résultats de classification et le temps nécessaire à l'apprentissage.

Après avoir mis en évidence que la procédure SFS est adaptée à la classification de textures, nous nous intéressons dans le paragraphe suivant à l'influence du critère du pouvoir discriminant considéré pour évaluer les sous-espaces d'attributs générés.

4.6.2.2 Influence du critère du pouvoir discriminant

Dans le paragraphe 3.4.1, nous avons motivé le choix d'associer la mesure de corrélation au critère de Wilks pour évaluer le pouvoir discriminant des sous-espaces d'attributs générés lors de la procédure de sélection. Vandembroucke, qui a étudié la pertinence de différentes mesures de distance dans le cadre de la sélection d'attributs, a montré que les critères de la trace et de

Wilks permettent d'obtenir des résultats de classification de pixels équivalents [Van00]. Dans ce paragraphe, nous proposons de vérifier cette conclusion dans le cadre de la classification de textures couleur.

La figure 4.19 illustre les taux d'images test bien classées obtenus avec la méthode de classification supervisée de textures couleur que nous avons développée en considérant d'une part le critère de la trace (cf. équation (2.15)) et d'autre part le critère de Wilks (cf. équation (2.14)). Ces taux T d'images test bien classées, obtenus en fonction de la dimension d du sous-espace d'attributs candidat, sont présentés ici avec l'ensemble d'images OuTex. Les $d_{max} = 50$ sous-espaces d'attributs candidats sélectionnés en considérant le critère de la trace sont présentés en annexe E dans le tableau E.9. Les résultats obtenus avec les ensembles VisTex et BarkTex sont également présentés dans cette annexe E dans les figures E.10 et E.11.




Figure 4.19 : Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes mesures de distance.

En analysant les résultats de classification présentés sur la figure 4.19, nous remarquons que les taux d'images test bien classées obtenus avec les deux mesures de distance sont assez proches. D'autre part, quelque soit le critère considéré, les six premiers attributs sélectionnés sont identiques (cf. tableaux E.1 et E.9).

Les meilleurs taux de classification atteignent 94.56% ($\hat{d} = 22$) avec le critère de la trace et 95.44% ($\hat{d} = 38$) avec le critère de Wilks.

Avec l'ensemble d'images extrait de la base VisTex, les meilleurs résultats de classification

atteignent 98.61% ($\hat{d} = 35$) avec le critère de la trace et 99.07% ($\hat{d} = 26$) en considérant le critère de Wilks. Enfin, avec l'ensemble d'images extrait de la base BarkTex, les meilleurs taux atteignent 93.26% ($\hat{d} = 48$) avec le critère de la trace et 93.87% ($\hat{d} = 50$) avec le critère de Wilks.

De manière globale, le critère de Wilks offre des résultats de classification d'images qui sont légèrement supérieurs par rapport à ceux obtenus en considérant le critère de la trace. D'autre part, la complexité de calcul du critère de la trace étant légèrement supérieure à celle du critère de Wilks, la sélection opérée en considérant ce dernier est sensiblement plus rapide : le temps nécessaire pour sélectionner les $d_{max} = 50$ attributs pertinents discriminant les textures couleur de la base OuTex requiert 576 s, lorsque le critère de Wilks est considéré, et 599 s, lorsque le critère de la trace est utilisé.

Après avoir analysé l'influence de la mesure de distance sur les résultats de classification et les temps d'exécution, le paragraphe suivant dresse une conclusion des différentes études qui ont été menées pour mesurer l'influence des différents paramètres de notre méthode.

4.6.3 Conclusion

Après avoir analysé l'influence des différents paramètres de notre méthode, nous remarquons que le niveau N de quantification influence de manière significative à la fois le temps nécessaire à l'apprentissage, mais également le temps nécessaire à la classification.

Les paramètres qui influent quant-à-eux fortement sur le temps d'apprentissage seul sont la procédure de génération utilisée lors de la sélection et le voisinage considéré lors du calcul des matrices de co-occurrences.

Nous pouvons d'autre part dresser une conclusion quant aux valeurs des paramètres qui offrent un bon compromis entre les résultats de classification et les temps d'exécution :

- Tout d'abord, le choix de fixer un niveau N de quantification à 16 permet d'obtenir d'aussi bons résultats de classification que lorsqu'un niveau de quantification $N = 256$ est considéré, mais avec des temps de traitement beaucoup plus courts.
- Concernant le voisinage utilisé lors du calcul des matrices de co-occurrences, nous recommandons de fixer la distance spatiale ν à 1, et de l'associer :
 - au "2-voisinage" qui caractérise les interactions spatiales selon la direction perpendiculaire aux motifs des textures analysées, lorsque celles-ci portent une direction privilégiée,
 - au "8-voisinage", lorsque les textures analysées ne présentent pas de directions privilégiées.
- Enfin, concernant la méthode de sélection, nous avons montré que la procédure de génération séquentielle SFS permet d'obtenir les mêmes performances que la procédure

SFFS. Elle sera donc privilégiée pour des applications nécessitant un temps d'apprentissage court. La mesure du pouvoir discriminant retenue est celle du critère de Wilks.

Nous allons mettre en évidence dans le paragraphe suivant les apports qu'offre la méthode développée en termes de résultats de classification.

4.7 Apports de la méthode de classification de textures couleur

Dans ce paragraphe, nous proposons d'évaluer la pertinence de la stratégie proposée au chapitre précédent. Pour cela, nous allons mesurer l'apport de la couleur en termes de résultats de classification, et plus particulièrement l'opportunité de considérer plusieurs espaces couleur pour caractériser les textures. Nous allons d'autre part montrer expérimentalement que la considération conjointe des relations intra et inter-composantes permet d'améliorer les résultats en termes de classification de textures couleur. Enfin, nous montrerons expérimentalement les avantages que présente la procédure de sélection des attributs.

4.7.1 Apport de l'approche multi-espaces couleur

Afin de mesurer le bénéfice qu'offre la considération de plusieurs espaces couleur pour caractériser les textures, nous proposons d'appliquer la méthode de classification de textures couleur que nous avons développée sur les ensembles d'images OuTex, VisTex et BarkTex, en caractérisant les textures couleur de quatre manières différentes. Pour cela, nous considérons séparément :

- les attributs d'Haralick extraits des matrices de co-occurrences calculées avec la seule information de luminance,
- les attributs d'Haralick extraits des matrices de co-occurrences chromatiques qui tiennent compte à la fois des relations intra et inter-composantes au sein d'un unique espace couleur :
 - nous mesurons tout d'abord les résultats de classification en codant les images dans l'espace (R, G, B) , qui est l'espace d'acquisition des images couleur par la caméra,
 - nous évaluons également les résultats de classification en codant les images dans l'espace couleur qui a permis d'obtenir les meilleurs taux d'images bien classées dans les travaux antérieurs. Ainsi, pour les bases OuTex et VisTex, Mäenpää montre que les espaces $(I4, S3, H2)$ et $(I1, I2, I3)$ permettent d'obtenir respectivement les meilleurs taux d'images OuTex et VisTex bien classées [MP04]. Pour l'ensemble BarkTex, c'est l'espace couleur (R, G, B) qui a permis d'obtenir les résultats de classification de Münzenmayer [MVK⁺02]. Nous ne présentons donc les taux d'images BarkTex bien classées que pour cet espace.

- les attributs d’Haralick extraits des matrices de co-occurrences qui tiennent compte à la fois des relations intra et inter-composantes et qui sont calculées à partir d’images codées dans les $N_S = 28$ espaces couleur différents présentés au paragraphe 3.2.2.

Les figures 4.20, 4.21 et 4.22 illustrent les taux T de bonne classification des images test des bases OuTex, VisTex et BarkTex, obtenus avec chacun des ces quatre modes de caractérisation de la couleur, en fonction de la dimension d du sous-espace d’attributs sélectionné.




Figure 4.20 : Taux T d’images test OuTex bien classées, en fonction de la dimension d du sous-espace d’attributs candidat, pour différents modes de caractérisation de la couleur.

Il est à noter que lorsque les textures couleur sont caractérisées par les attributs d’Haralick définis avec la seule information de luminance, l’espace initial d’attributs est formé de $D = 13$ attributs de texture. La valeur de d_{max} ne pouvant pas être assignée à 50, nous choisissons de considérer sa valeur maximale, à savoir $d_{max} = D = 13$.

Nous pouvons remarquer que, lorsque les textures couleur sont caractérisées avec les attributs définis avec la seule information de luminance ou encore lorsqu’elles sont caractérisées avec les attributs extraits à partir d’images codées dans un unique espace, les résultats de classification obtenus progressent plus rapidement pour des dimensions d faibles, par rapport aux résultats obtenus en considérant les $N_S = 28$ espaces couleur. Cependant, lorsque d est supérieur ou égal à 6, ces résultats se stabilisent à un taux de classification inférieur aux résultats obtenus avec l’approche multi-espaces.




Figure 4.21 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation de la couleur.




Figure 4.22 : Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation de la couleur.

Le tableau 4.10 présente les meilleurs taux T de bonne classification des images test des bases OuTex, VisTex et BarkTex, obtenus en considérant les sous-espaces d'attributs discrimi-

nants de dimension \hat{d} , en fonction du mode de caractérisation de la couleur.

Caractérisation des textures couleur	OuTex		VisTex		BarkTex	
	T	\hat{d}	T	\hat{d}	T	\hat{d}
Luminance	72.94%	13	81.94%	13	58.58%	12
(R, G, B)	88.09%	45	92.36%	23	80.88%	12
Meilleur espace	91.91%	20	96.99%	23	80.88%	12
Multi-espaces couleur	95.44%	38	99.07%	26	93.87%	50

Tableau 4.10 : Taux T de bonne classification des images test des bases OuTex, VisTex et BarkTex, obtenus en considérant les sous-espaces d'attributs discriminants de dimension \hat{d} , en fonction du mode de caractérisation de la couleur.

En comparant les résultats de classification obtenus avec les attributs définis avec la seule information de luminance avec ceux obtenus en considérant les attributs de texture couleur calculés à partir d'images codées dans l'espace (R, G, B) , nous remarquons que la prise en compte de la couleur améliore de manière significative la discrimination des textures couleur.

D'autre part, la comparaison des résultats de classification obtenus en codant les images dans l'espace (R, G, B) avec ceux obtenus en codant les images dans l'espace qui a permis d'obtenir les meilleurs taux d'images bien classées dans les travaux de Mäenpää montre que choisir de manière pertinente l'espace couleur pour discriminer les textures permet d'améliorer significativement les résultats de classification. Cependant, le choix de cet espace est difficile *a priori*. La procédure de sélection reste donc un bon moyen pour déterminer ces espaces discriminants.

Enfin, la différence entre les résultats de classification obtenus en considérant l'espace couleur pertinent et les résultats obtenus en considérant les $N_S = 28$ espaces couleur montre quant à elle le bénéfice qu'offre le fait de considérer les propriétés de plusieurs espaces couleur pour caractériser les textures.

En moyenne, pour la base OuTex, les taux de classification obtenus avec le multi-espaces couleur sont augmentés de :

- 3.7% par rapport à la caractérisation avec l'espace $(I4, S3, H2)$ seul,
- 8% par rapport à la caractérisation avec l'espace (R, G, B) seul,
- près de 20% par rapport à la caractérisation avec la seule information de luminance.

Le paragraphe suivant s'intéresse à l'apport qu'offre la considération conjointe des relations intra et inter-composantes.

4.7.2 Apport de la considération conjointe des relations intra et inter-composantes

Afin de mesurer le bénéfice qu'offre la considération conjointe des relations intra et inter-composantes pour caractériser les textures, nous proposons d'appliquer la méthode de classification de textures couleur que nous avons développée sur l'ensemble d'images OuTex en caractérisant les textures couleur d'une part, avec les matrices de co-occurrences chromatiques qui ne tiennent uniquement compte que des relations intra-composantes, et d'autre part, avec les matrices de co-occurrences chromatiques qui tiennent compte à la fois des relations intra et inter-composantes.

Les figures 4.23, 4.24 et 4.25 illustrent les taux T de bonne classification des images test des bases OuTex, VisTex et BarkTex, obtenus avec chacun de ces deux modes de caractérisation de la texture couleur, en fonction de la dimension d du sous-espace d'attributs sélectionné.




Figure 4.23 : Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.

Nous pouvons remarquer que la considération conjointe des relations intra et inter-composantes permet le plus souvent l'obtention de meilleurs résultats de classification que lorsque les relations intra-composantes sont considérées seules. Cette remarque est particulièrement valable pour les bases d'images Outex et VisTex, où la distribution des couleurs joue un rôle important dans la discrimination des classes. Par contre, pour l'ensemble d'images BarkTex, les résultats de classification obtenus en considérant d'une part les relations intra-composantes et d'autre part les relations intra et inter-composantes sont quasiment identiques




Figure 4.24 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.




Figure 4.25 : Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.

(cf. figure 4.22).

Le choix de considérer conjointement les relations intra et inter-composantes se révèle également judicieux après analyse des tableaux E.1, E.2 et E.3, où sont présentés les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer respectivement les textures couleur des bases OuTex, VisTex et BarkTex. En effet, nous remarquons que, quelque soit la base d'images considérée, les attributs caractérisant les relations spatiales inter-composantes sont plus souvent retenus que les attributs caractérisant les relations intra-composantes :

- 33 attributs inter-composantes contre 17 attributs intra-composantes, pour l'ensemble d'images OuTex,
- 27 attributs inter-composantes contre 23 attributs intra-composantes, pour l'ensemble d'images VisTex,
- 31 attributs inter-composantes contre 19 attributs intra-composantes, pour l'ensemble d'images BarkTex.

Cela montre l'intérêt de prendre en compte les relations spatiales inter-composantes vis-à-vis de la discrimination des classes d'images de texture couleur.

Le tableau 4.11 présente les meilleurs taux T de bonne classification des images test des bases OuTex, VisTex et BarkTex, obtenus en considérant les sous-espaces d'attributs discriminants de dimension \hat{d} , selon que les relations intra-composantes sont considérées seules ou conjointement avec les relations inter-composantes.

Caractérisation des textures couleur	OuTex		VisTex		BarkTex	
	T	\hat{d}	T	\hat{d}	T	\hat{d}
Multi-espaces couleur - intra	93,97%	21	97.45%	33	93.75%	48
Multi-espaces couleur – intra et inter	95.44%	38	99.07%	26	93.87%	50

Tableau 4.11 : Taux T de bonne classification des images test des bases OuTex, VisTex et BarkTex, obtenus en considérant les sous-espaces d'attributs discriminants de dimension \hat{d} , selon différentes caractérisations des textures couleur.

La différence entre les résultats de classification obtenus en considérant les relations intra et inter-composantes et les résultats obtenus en ne considérant que les relations intra-composantes montre le bénéfice qu'offre le fait de considérer conjointement les relations intra et inter-composantes lors du calcul des matrices de co-occurrences.

En moyenne, pour la base OuTex, les taux de classification obtenus en considérant les relations intra et inter-composantes sont augmentés de 1.6% par rapport à l'unique considération des relations intra-composantes.

Le paragraphe suivant s'intéresse à l'apport qu'offre la sélection d'un sous-espace d'attributs discriminant pour caractériser les textures.

4.7.3 Apport de la sélection

Afin de mesurer l'apport qu'offre la sélection des attributs de texture couleur sur les résultats de classification, nous proposons d'appliquer la méthode de classification de textures couleur développée sur les ensembles d'images VisTex, OuTex et BarkTex sans procéder à la sélection d'un sous-espace d'attributs discriminant. L'espace initial d'attributs de dimension $D = 2184$ sera donc ici utilisé pour caractériser les textures couleur.

Avec l'ensemble d'images OuTex, le taux d'images test bien classées obtenu avec l'espace initial d'attributs de dimension $D = 2184$ atteint 93.82%. Pour rappel, lorsque le sous-espace d'attributs de dimension $\hat{d} = 38$ qui discrimine au mieux les textures de cette base est sélectionné, ce taux atteint 95.44%.

Avec l'ensemble d'images VisTex, le taux d'images test bien classées obtenu avec l'espace initial d'attributs atteint 97.69%. Lorsque le sous-espace d'attributs de dimension $\hat{d} = 26$ qui discrimine au mieux les textures de la base VisTex est sélectionné, ce taux atteint 99.07%.

Enfin, avec l'ensemble d'images BarkTex, le taux d'images test bien classées obtenu sans procéder à la sélection d'un sous-espace d'attributs discriminant atteint 93.63%. Pour rappel, ce taux atteint 93.87% lorsque le sous-espace d'attributs de dimension $\hat{d} = 50$ est sélectionné.

Lorsque la sélection du sous-espace discriminant est effectuée, le temps d'apprentissage est augmenté et passe de 1 588 s (environ 26 minutes) à 68 761 s (environ 19 heures) lorsque l'ensemble d'images OuTex est utilisé. Par contre, la projection dans ce sous-espace lors de la phase de classification permet non seulement d'améliorer les taux d'images test bien classées, mais également de réduire significativement le temps de classification en-ligne. Ce dernier passe en effet de 117 s (environ 2 minutes) à 2,9 s lorsqu'une image de taille 128×128 de la base OuTex est classée par le sous-espace d'attributs de dimension $\hat{d} = 38$ plutôt que par l'espace initial d'attributs de dimension $D = 2184$.

La sélection d'un sous-espace d'attributs discriminant permet donc non seulement d'améliorer la discrimination des textures couleur, mais surtout de réduire les temps nécessaires à la classification en-ligne. Cette étape est donc essentielle lorsque la dimension initiale de l'espace d'attributs est importante. La méthode de classification peut alors être appliquée à un contexte industriel où le temps requis pour classer les images en-ligne est soumis aux contraintes de production.

4.8 Conclusion

Chaque espace couleur possède des propriétés qui lui sont propres et qui permettent de discriminer plus ou moins bien certaines textures couleur. L'approche multi-espaces intégrée au sein de la méthode de classification de textures couleur que nous avons développée permet donc d'exploiter les propriétés de chacun d'entre eux et ainsi d'améliorer significativement les résultats de classification obtenus par rapport à l'exploitation des propriétés d'un unique espace couleur choisi préalablement ou de la seule information de luminance.

D'autre part, la considération conjointe des relations intra et inter-composantes permet également d'améliorer les résultats de classification par rapport à la prise en compte des relations intra-composantes seules.

Nous avons enfin montré expérimentalement le bénéfice qu'apporte la méthode de sélection d'attributs mise en place en termes de résultats de classification et de temps de traitement.

Les tests effectués sur les bases de référence VisTex, OuTex et BarkTex ont permis de comparer les résultats obtenus par notre méthode avec ceux parus dans la littérature. Ces tests ont néanmoins mis en évidence les limites des ensembles d'images utilisés. En effet, les classes d'images considérées dans les ensembles issus des bases OuTex et VisTex peuvent aisément être discriminées par de simples attributs statistiques couleur du premier ordre. Elles se différencient plus par la distribution des couleurs que par la répartition spatiale de ces dernières. Ce n'est pas le cas de la base BarkTex, où la distribution des couleurs est relativement similaire quelque soit la classe considérée, malgré que les conditions d'éclairage lors de l'acquisition des images de cette base ne soient pas contrôlées. En ce qui concerne les autres bases d'images, comme la base Texture Library ou les bases directement issues des applications considérées, elles ne permettent la comparaison des résultats qu'avec très peu de méthodes parues dans la littérature. Il n'existe donc pas actuellement de base d'images de texture couleur qui permette de comparer de manière satisfaisante les performances de discrimination atteintes par différents algorithmes.

La sélection parmi des attributs de texture couleur considérant les relations spatiales intra et inter-composantes évaluées à partir de différents espaces couleur constitue la principale originalité de nos travaux.

Ce chapitre a montré que la considération de plusieurs espaces couleur, l'utilisation des matrices de co-occurrences chromatiques isotropiques de taille réduite et la procédure de sélection mise en place ont permis d'atteindre des performances de classification susceptibles de satisfaire les contraintes d'une application industrielle.

Cependant, afin de réduire les temps d'exécution des phases d'apprentissage et de classification, il serait intéressant d'étudier la pertinence :

- d'autres critères permettant de déterminer la dimension du sous-espace d'attributs discriminant : en effet, celui utilisé dans notre approche impose le calcul des taux de classification obtenus en considérant les différents sous-espaces candidats, ce qui augmente

considérablement le temps d'apprentissage. Un critère basé directement sur la mesure d'évaluation du pouvoir discriminant des sous-espaces candidats semblerait plus pertinent.

- d'autres méthodes de classement : en effet, celle du plus proche voisin nécessite le calcul de nombreuses distances entre le point-image à classer et les points-prototypes. La méthode "Fast-kNN" semblerait être une approche réduisant le nombre d'évaluations de distances [HW98].

Afin de mesurer l'efficacité de notre méthodologie dans le cadre d'une application industrielle, nous proposons d'appliquer dans le chapitre suivant la méthode développée au contrôle qualité de décors de verres produits par l'entreprise Arc International.

Chapitre 5

Application à l'identification de défauts sur les décors de verres

5.1 Introduction

Dans ce chapitre, la méthodologie de classification de textures couleur que nous avons développée est appliquée à un ensemble d'images de décors de verres en vue d'évaluer son efficacité vis à vis d'une application de contrôle qualité en milieu industriel. Les résultats de classification et les temps de traitement obtenus vont alors être mesurés afin de vérifier que la méthode répond aux contraintes de production imposées, à savoir effectuer la classification en-ligne de chaque décor en respectant la cadence de production d'un verre par seconde.

La première partie de ce chapitre présente le processus de sérigraphie ainsi que les défauts d'aspect qui peuvent être générés durant la décoration des verres. Puis, le paragraphe 5.3 décrit brièvement les premiers travaux de recherche initiés par Laurent Busin sur le contrôle qualité des décors de verres. La limite de ces travaux sera alors mise en évidence et le paragraphe 5.4 présentera les résultats obtenus par notre approche.

5.2 Les défauts à détecter

La sérigraphie des articles verriers est réalisée par des machines équipées de pochoirs en inox sur lesquels de la peinture émaillée est apposée. Cette peinture se fige immédiatement sur le verre, qui est ensuite recuit afin de fixer définitivement le décor. Cependant, le processus de décoration peut générer différents défauts d'aspect, qui peuvent être regroupés en quatre familles [BVM08a] :

- Les défauts appelés "tâchés" sont des tâches de couleur présentes sur les décors des verres. Ce type de défauts peut avoir deux origines :
 - soit une goutte parasite de peinture est tombée sur le verre lors de l'étape de sérigraphie,
 - soit deux verres qui n'étaient pas encore secs se sont touchés avant d'être recuits.

La figure 5.1 illustre ce type de défauts : l'image de la figure 5.1(a) est une image du décor d'un verre sur lequel il n'y a pas de défaut, contrairement aux images des figures 5.1(b) et 5.1(c), qui montrent respectivement l'image d'un verre avec un défaut de "tâché" lorsqu'une goutte parasite de peinture est tombée lors de l'étape de sérigraphie et lorsque deux verres qui n'étaient pas encore secs se sont touchés.



(a) Image du décor d'un verre sans défaut.

(b) Image d'un défaut de "tâché" dû à une goutte parasite de peinture.

(c) Image d'un défaut de "tâché" dû au contact de verres non secs.

Figure 5.1 : Illustration du défaut de "tâché".

- Les défauts appelés "manques" sont repérables par l'absence de la totalité ou d'une partie d'une ou plusieurs couleurs lors de la sérigraphie du décor. La figure 5.2 montre le décor d'un verre sans défaut sur l'image 5.2(a) et le décor d'un verre avec un défaut de "manque" sur l'image 5.2(b).
- Les défauts dits de "décalage" sont provoqués par le décalage de deux écrans de couleur différents. La figure 5.3 montre le décor d'un verre sans défaut sur l'image 5.3(a) et le décor d'un verre avec un défaut de "décalage" sur l'image 5.3(b).
- Les défauts de "nuance" sont repérables par une couleur répartie de manière non homogène sur l'ensemble de la surface imprimée. Ils peuvent par exemple provenir d'une mauvaise quantité de peinture lors de l'impression du décor. La figure 5.4 montre le décor d'un verre sans défaut sur l'image 5.4(a) et le décor d'un verre avec un défaut de "nuance" sur l'image 5.4(b).

Comme les verres présentant de tels défauts ne peuvent être vendus au client, il est nécessaire d'effectuer un contrôle qualité en ligne des décors des verres en sortie de production.

Cependant, ce contrôle s'avère délicat pour les raisons suivantes :



Figure 5.2 : Illustration du défaut de "manque".




Figure 5.3 : Illustration du défaut de "décalage".

- la géométrie cylindrique de la surface à inspecter,
- l'aspect coloré et texturé des décors imprimés,
- la cadence de production relativement élevée (un verre par seconde),
- la variabilité des défauts générés.




Figure 5.4 : Illustration du défaut de "nuance".

Actuellement, le contrôle des verres décorés par sérigraphie est réalisé par vision humaine, ce qui est fastidieux, peu robuste et surtout très fatigant pour l'opérateur. C'est pourquoi les travaux de recherche de Laurent Busin ont été initiés en 2003 en vue d'automatiser ce contrôle.

Le paragraphe suivant présente les résultats obtenus sur des décors de couleurs homogènes à la suite de ces premiers travaux.

5.3 Contrôle qualité des décors de verres présentant des couleurs homogènes

Lors de sa thèse de doctorat soutenue en 2006, Laurent Busin a mené les premiers travaux de recherche abordant le sujet du contrôle qualité des décors imprimés par sérigraphie sur les produits verriers [Bus06]. Il a mis en place une méthode de contrôle automatique, présentée dans le paragraphe 5.3.2, qui permet de détecter les défauts sur les décors des verres au moyen d'une approche de segmentation d'images couleur. Avant de décrire succinctement cette méthode, nous présentons dans le paragraphe 5.3.1 le poste d'acquisition que L. Busin a développé afin d'inspecter de manière automatisée les décors des verres.

5.3.1 Présentation du poste d'acquisition

Le poste d'acquisition développé par L. Busin est basé sur un montage mécanique dont le principe de fonctionnement est illustré sur la figure 5.5. Nous pouvons voir sur cette figure

que le verre inspecté est maintenu verticalement par un système de préhension. Ce système est relié à un moteur via l'arbre moteur qui assure la rotation du verre autour de son axe principal d'inertie à la vitesse d'un tour par seconde. L'acquisition d'images-ligne successives par une caméra linéaire couleur permet alors d'obtenir une représentation couleur bidimensionnelle de la surface du verre grâce à sa rotation [BVM08b].




Figure 5.5 : Principe de fonctionnement du poste d'acquisition.

La figure 5.6 montre deux photographies du poste d'acquisition [BVM08b].


L'image de la figure 5.6(a) montre une vue de face du poste d'acquisition sur laquelle sont repérés :

- le système de préhension reliant le verre à l'arbre moteur,
- l'arbre moteur qui relie le système de préhension au moteur,
- un codeur incrémental, fixé sur l'arbre moteur, permettant le déclenchement de l'acquisition des images-ligne.


L'image de la figure 5.6(b) montre une vue de côté du poste d'acquisition sur laquelle sont repérés :

- un diffuseur, qui est connecté à une fibre optique et qui permet de répartir la lumière provenant d'une source selon une forme linéaire afin d'éclairer le verre dans le sens de la hauteur,
- la caméra linéaire couleur,
- un filtre infra-rouge, placé devant l'objectif de la caméra, qui empêche les rayons infra-rouges de sensibiliser le capteur.

L'image de la figure 5.8, acquise grâce au dispositif présenté ci-dessus, représente le décor du verre de la figure 5.7.



(a) Vue de face du poste d'acquisition.



(b) Vue de côté du poste d'acquisition.

Figure 5.6 : Poste d'acquisition.



Figure 5.7 : Verre.



Figure 5.8 : Image du verre de la figure 5.7.

Une fois que l'image d'un verre à contrôler est acquise, la méthode développée par L. Busin y est appliquée afin de détecter d'éventuels défauts d'aspect sur le décor. Le paragraphe suivant décrit brièvement cette méthode et montre ses limites.

5.3.2 Contrôle qualité des décors de verres par segmentation d'images couleur

Le principe de la méthode de contrôle qualité développée par L. Busin est basé sur une comparaison entre l'image du décor à contrôler et une image de référence sans défaut, afin de détecter d'éventuelles différences qui correspondent à la présence d'un défaut d'aspect sur le décor.

L. Busin montre qu'une simple comparaison des couleurs entre les pixels homologues de chaque image ne permet pas d'atteindre des taux de détection de défauts satisfaisants. C'est la raison pour laquelle il développe une méthode de segmentation d'images couleur qu'il applique à l'image du verre à contrôler et à l'image du verre de référence sans défaut afin de comparer les images segmentées résultantes [Bus06].

L'originalité de son approche porte sur la sélection des espaces couleur qui permettent de discriminer au mieux les classes de pixels en présence. Cette approche multi-espaces couleur ne tient compte que des distributions des couleurs présentes dans les images et d'excellents résultats ont été obtenus pour le contrôle des verres dont le décor présente des zones de couleurs homogènes. Cependant, comme la répartition spatiale des couleurs n'est pas prise en compte, la méthode s'est avérée être mal adaptée aux décors présentant des zones de textures couleur.

Nous avons encadré une zone de couleur homogène et une zone de texture couleur dans l'image de la figure 5.9 qui représente le décor du verre de la figure 5.7. Les couleurs des pixels présents dans le cadre cyan sont homogènes alors que celles des pixels présents dans le cadre orange forment une texture.



Figure 5.9 : Image du verre de la figure 5.7 : le cadre cyan montre une zone d'analyse de couleur homogène, tandis que le cadre orange, une zone de texture couleur.

Afin de détecter les défauts d'aspect se situant dans les zones portant des textures couleur, une solution serait d'enrichir la méthode de segmentation par classification de pixels proposée par L. Busin, en utilisant des attributs de texture couleur calculés au voisinage de chaque pixel. En effet, ces attributs tiennent compte des interactions spatiales entre les composantes couleur. Cependant, calculer ces attributs pour chaque pixel peut être très coûteux en temps d'exécution. C'est pourquoi, afin de répondre aux contraintes temporelles qu'impose le contrôle qualité des décors de verres, nous proposons de classer directement des zones de l'image du décor où sont présentes les textures, plutôt que de classer tous les pixels de l'image.

Le paragraphe suivant décrit l'approche mise en place afin de détecter les défauts d'aspect sur les décors de verres présentant des textures couleur, ainsi que les résultats de classification obtenus.

5.4 Contrôle qualité des décors de verres présentant des textures couleur

L'approche mise en place doit permettre de détecter les défauts d'aspect se situant dans des zones de textures couleur. Cependant, l'examen automatique de textures soulève plusieurs problèmes :

- Tout d'abord, les motifs texturés peuvent varier d'un verre à l'autre, au sein d'une même série, à cause du procédé de sérigraphie qui n'est pas constant dans le temps.
- D'autre part, divers motifs texturés peuvent être présents au sein d'un même décor.
- Enfin, la variabilité des formes et des couleurs des défauts d'aspect est importante.

Pour pallier ces difficultés, nous proposons de considérer la méthode de classification supervisée de textures couleur que nous avons développée en construisant des classes d'images suffisamment représentatives de la variation des motifs texturés présente au sein des décors avec ou sans défaut.

Une première classe sera tout d'abord utilisée pour regrouper les motifs texturés sans défaut. Puis, quatre autres classes seront considérées, chacune regroupant les motifs texturés avec un des quatre types de défauts présentés au paragraphe 5.2.

Cette approche nécessite de disposer d'un nombre important d'échantillons, non seulement afin que la variation des motifs texturés puisse être totalement représentée, mais également car une approche de classification supervisée nécessite un nombre important de prototypes pour être robuste.

Les petites séries étant de plus en plus nombreuses pour proposer des nouveaux produits aux consommateurs, les temps de changements de série doivent être limités. Il n'est donc pas toujours possible de disposer d'échantillons avec défauts pour chaque lancement de fabrication. En effet, le problème généralement posé par les applications de contrôle qualité par vision industrielle est le nombre insuffisant d'échantillons avec défaut disponibles lorsqu'une nouvelle série est mise en production.

En revanche, les défauts générés par sérigraphie peuvent être modélisés lorsque nous disposons de connaissances *a priori* sur les décors à imprimer et l'ordre d'impression des couleurs. Il est donc possible de simuler leur présence au sein des décors. Nous proposons donc une approche qui génère artificiellement des échantillons avec défaut afin de disposer de suffisamment d'échantillons de chaque type de défaut.

Le paragraphe suivant présente l'outil de simulation de défauts mis en place afin de générer les échantillons avec défauts nécessaires à la phase d'apprentissage.

5.4.1 Construction des bases d'images de décors de verres par simulation de défauts

Dans le cadre d'un projet informatique, nous avons encadré deux étudiants en seconde année d'école d'ingénieurs pour la réalisation d'une bibliothèque de fonctions générant des défauts à partir d'images de décors de verres sans défaut [WD09]. Dans un premier temps, nous avons expérimenté notre approche sur deux types de défauts : les défauts de nuance et de manque. Pour cela, nous nous sommes inspirés des quelques échantillons disponibles présentant de réels défauts. La figure 5.10 illustre de tels échantillons pour le décor "Sprite". La taille des images considérées dans cet exemple est 128×128 pixels.




Figure 5.10 : Exemples d'échantillons de décors "Sprite" avec et sans défaut.

Chaque défaut est caractérisé par une forme et une couleur particulières qui modifient la texture du décor et qui donnent naissance à une nouvelle texture qu'il est possible de modéliser. La forme est simulée grâce à des courbes générées à l'aide de fonctions aléatoires tandis que les changements de couleur sont modélisés de manière grossière par le biais d'opérations d'addition et/ou de soustraction sur les composantes couleur R , G et B . Plus de détails concernant cette modélisation sont disponibles dans le rapport de projet informatique [WD09].

Les figures 5.11 et 5.12 illustrent le résultat de la simulation des défauts de nuance et de manque pour des décors "Fanta" et "Sprite" :

- la figure 5.11 illustre des défauts de nuance réels et des défauts de nuance générés artificiellement à partir de décors "Fanta" et "Sprite" sans défaut,
- la figure 5.12 illustre, pour ces deux types de décors, des défauts de manque réels et simulés.

A partir de ces échantillons générés artificiellement, nous construisons, pour chaque décor, une base d'images prototypes et une base d'images test qui vont être utilisées lors de la phase d'apprentissage pour représenter de manière équiprobable les trois classes suivantes :

- une classe d'images de texture représentative des décors sans défaut,
- une classe d'images de texture représentative des décors avec un défaut de nuance,
- et une classe d'images de texture représentative des décors avec un défaut de manque.

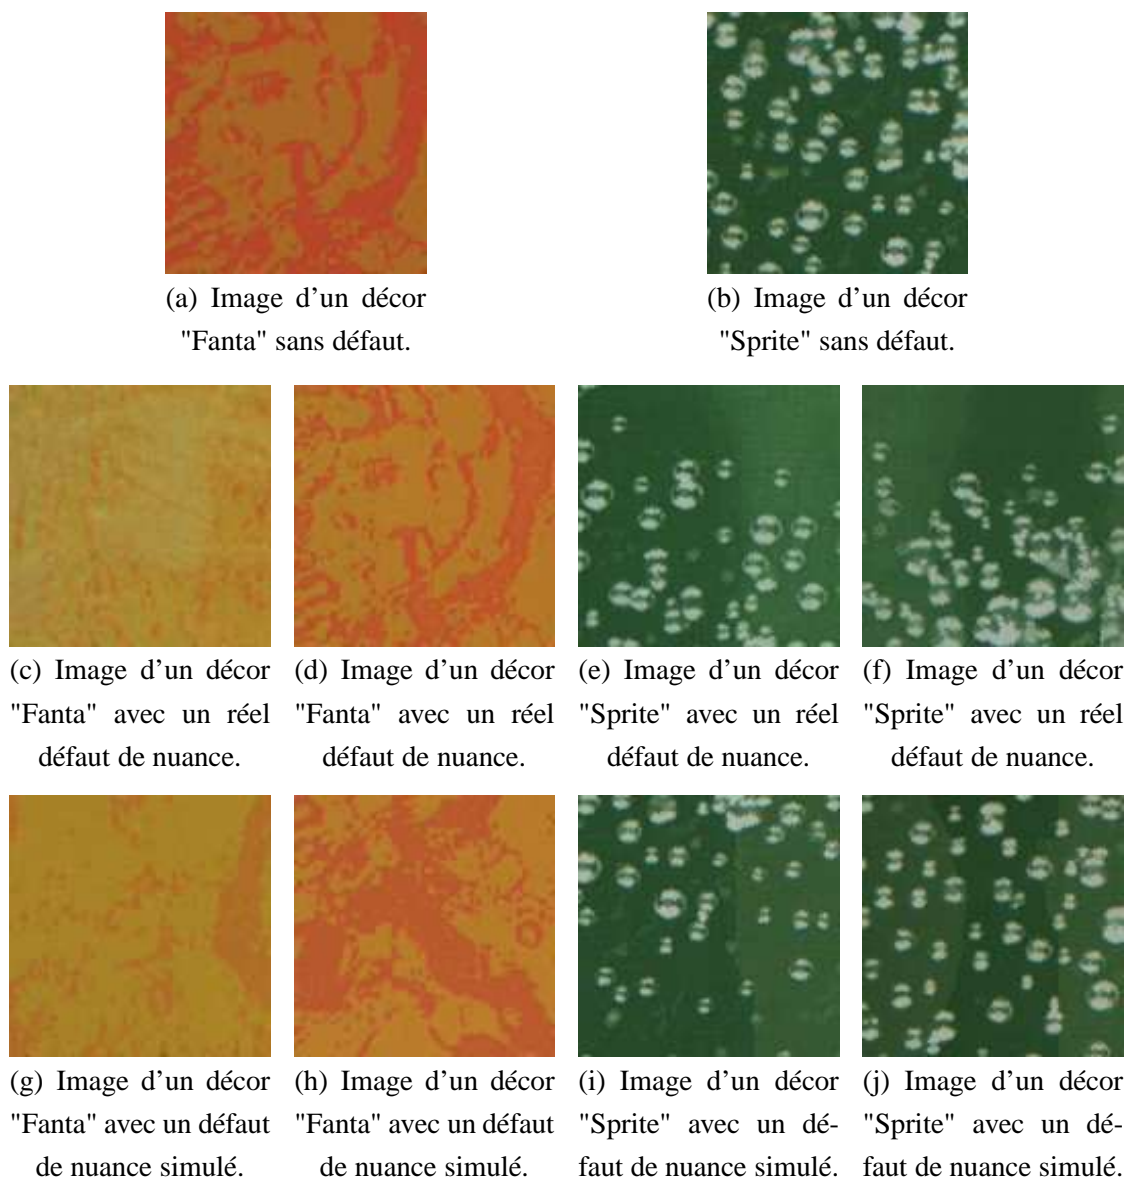


Figure 5.11 : Exemples de défauts de nuance simulés pour les décors "Fanta" et "Sprite".

Les défauts de tâché et de décalage n'étant pas encore modélisés, nous ne présenterons les résultats du contrôle qualité que pour la détection des défauts de nuance et de manque.

Pour chaque décor, nous choisissons de considérer $3 \times 128 = 384$ échantillons de taille 128×128 pixels. 128 échantillons sont issus des décors réels sans défaut afin de construire la première classe d'images. Les 256 autres échantillons sont quant-à-eux générés artificiellement, à partir des 128 échantillons réels sans défaut, afin de construire les classes d'images représentatives des décors avec les défauts de nuance et de manque.

La moitié des 384 échantillons est utilisée comme prototypes pour déterminer les sous-espaces d'attributs candidats, tandis que les échantillons restant constituent la base d'images test utilisée pour sélectionner le sous-espace le plus discriminant.

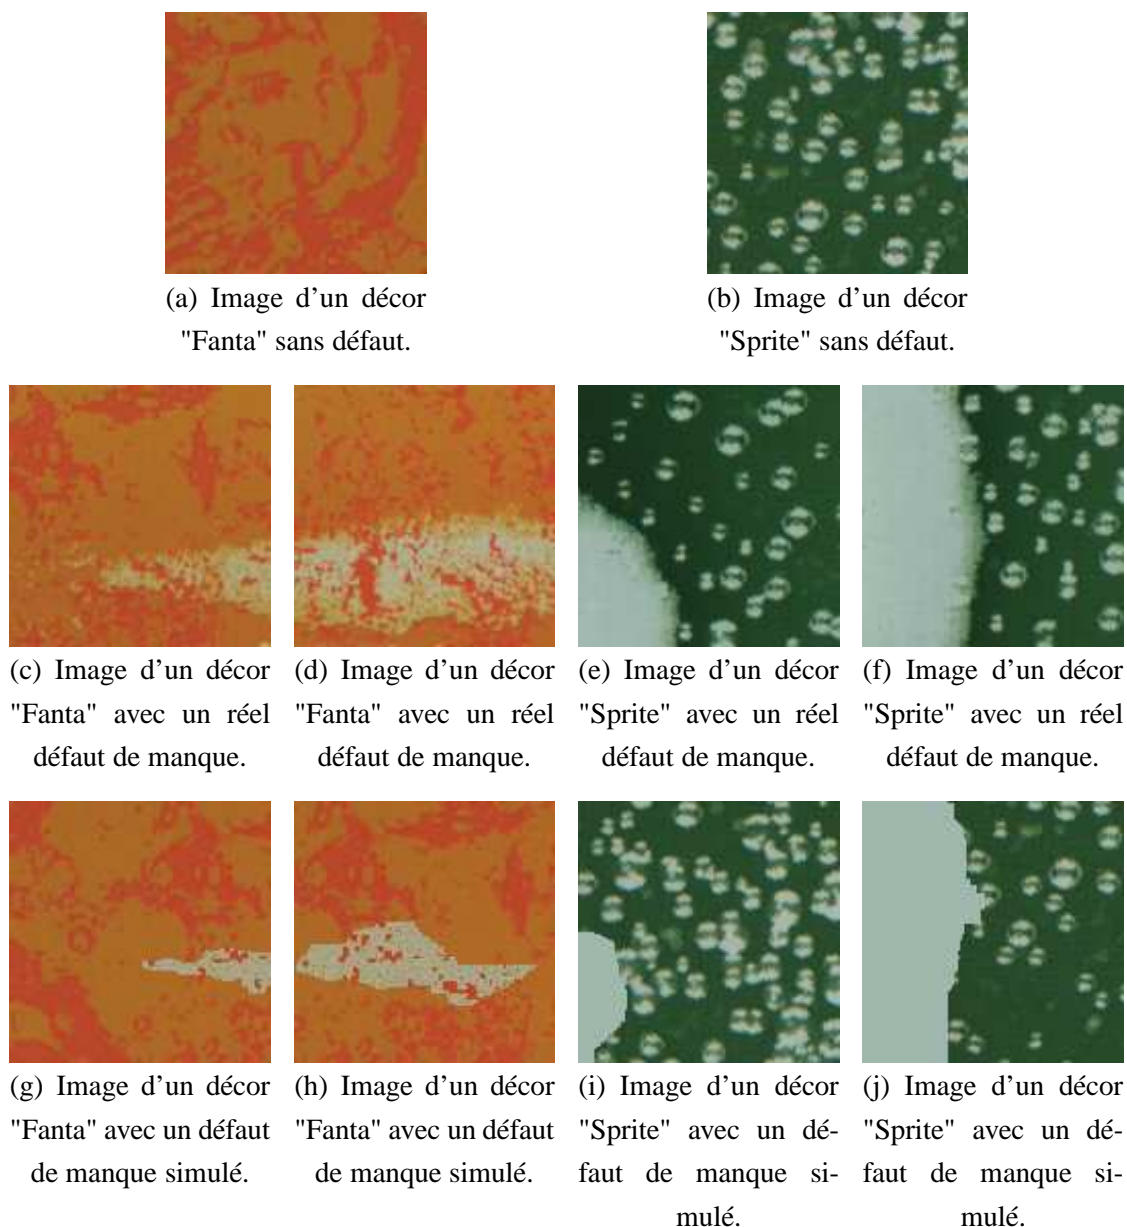


Figure 5.12 : Exemples de défauts de manque simulés pour les décors "Fanta" et "Sprite".

Les figures 5.13 et 5.14 illustrent une partie des bases d'images prototypes représentatives de la variation des motifs texturés au sein des décors "Fanta" et "Sprite".

Bien que la simulation des défauts de nuance et de manque par la bibliothèque de fonctions créée soit parfois grossière, elle suffit à caractériser les défauts réels, comme le montre le paragraphe suivant.

5.4.2 Résultats du contrôle qualité des décors "Fanta" et "Sprite"

A partir des bases d'images prototypes et d'images test créées artificiellement, nous caractérisons lors de la phase d'apprentissage hors-ligne les trois classes d'images de texture couleur afin d'identifier les décors sans défaut et les décors présentant des défauts de nuance et de




Images prototypes issues des décors « Fanta » réels sans défaut

Images prototypes simulées, représentatives des décors « Fanta » avec un défaut de nuance

Images prototypes simulées, représentatives des décors « Fanta » avec un défaut de manque

Figure 5.13 : Illustration d'une partie de la base d'images prototypes "Fanta".



Images prototypes issues des décors « Sprite » réels sans défaut

Images prototypes simulées, représentatives des décors « Sprite » avec un défaut de nuance

Images prototypes simulées, représentatives des décors « Sprite » avec un défaut de manque

Figure 5.14 : Illustration d'une partie de la base d'images prototypes "Sprite".

manque lors de la phase de classification en-ligne.

Pour cela, les $D = 28 \times 6 \times 13 = 2184$ attributs de texture couleur présentés au paragraphe 3.3.3 sont tout d'abord calculés pour chaque image prototype.

Puis, la construction du sous-espace d'attributs discriminant est effectuée grâce à la méthode de sélection présentée au paragraphe 3.4. Lors de cette étape, d_{max} sous-espaces d'attributs candidats de différentes dimensions d ($d = 1, \dots, d_{max}$) sont tout d'abord pré-sélectionnés grâce à une procédure de sélection itérative SFS associée à une évaluation en deux temps par le critère de Wilks et la mesure de corrélation.

Nous choisissons de fixer d_{max} à 10 car cette valeur permet de limiter le temps d'apprentissage. D'autre part, le temps nécessaire à la classification d'une image devant être inférieur à une seconde, il est inutile de considérer une valeur de d_{max} trop importante.

Les taux d'images test bien classées, obtenus par la méthode de classement du plus proche voisin opérant dans chacun des $d_{max} = 10$ sous-espaces, sont ensuite comparés afin de déterminer le sous-espace final de dimension \hat{d} pour lequel le taux d'images test bien classées est le plus élevé.

Les paragraphes 5.4.2.1 et 5.4.2.2 présentent respectivement les résultats obtenus pour les ensembles d'images de décors des verres "Fanta" et "Sprite". Notons que les temps présentés dans ces paragraphes sont obtenus avec un PC cadencé à 2.40 GHz avec 3.25 Go de RAM.

5.4.2.1 Résultats obtenus pour le contrôle des décors "Fanta"

Apprentissage hors-ligne des décors "Fanta"

Pour l'ensemble d'images de décors "Fanta", l'apprentissage requiert 1 232 secondes, soit une vingtaine de minutes. Le tableau 5.1 présente les $d_{max} = 10$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base de décors "Fanta". Il indique également le taux T d'images test bien classées obtenu avec chaque sous-espace d'attributs candidat pour les différentes dimensions d considérées, ainsi que le temps Tc (en secondes) nécessaire pour classer une image.

Le sous-espace final, qui va être considéré lors de la classification en-ligne des décors réels des verres "Fanta", est le sous-espace d'attributs de dimension $\hat{d} = 2$. En effet, ce sous-espace permet d'obtenir le meilleur taux d'images test bien classées (100%) avec la dimension d la plus faible.

Notons que ce n'est pas l'espace d'acquisition (R, G, B) qui est associé à l'attribut de texture couleur le plus discriminant, mais l'espace (A, C_{C1C2}, h_{C1C2}) . D'autre part, il est intéressant de constater que la dimension du sous-espace d'attributs discriminant est particulièrement faible ($\hat{d} = 2$). Les prototypes "Fanta" semblent facilement discriminables.

d	Espace couleur	Matrice	Attribut	T	Tc
1	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, C_{C1C2}}$	$f_3^{C_{C1C2}, C_{C1C2}}$	91.67%	0.12
2	$(I1, I2, I3)$	$m^{I3, I3}$	$f_{10}^{I3, I3}$	100%	0.17
3	(Y', I', Q')	$m^{I', I'}$	$f_{11}^{I', I'}$	100%	0.22
4	$(I1, I2, I3)$	$m^{I1, I2}$	$f_6^{I1, I2}$	100%	0.27
5	(L^*, u^*, v^*)	m^{u^*, v^*}	$f_{12}^{u^*, v^*}$	100%	0.33
6	(Y', C'_{IQ}, h'_{IQ})	$m^{C'_{IQ}, C'_{IQ}}$	$f_{12}^{C'_{IQ}, C'_{IQ}}$	100%	0.39
7	(R, G, B)	$m^{R, R}$	$f_7^{R, R}$	100%	0.43
8	(Y', I', Q')	$m^{I', Q'}$	$f_{10}^{I', Q'}$	100%	0.48
9	(r, g, b)	$m^{b, b}$	$f_{11}^{b, b}$	100%	0.53
10	$(I4, S3, H2)$	$m^{S3, S3}$	$f_5^{S3, S3}$	100%	0.58

Tableau 5.1 : Les $d_{max} = 10$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base de décors "Fanta".

Classification en-ligne des décors réels "Fanta"

Pour tester la pertinence de la méthodologie proposée lors de la phase de classification en-ligne, nous disposons de 65 échantillons réels à classer de taille 128×128 pixels :

- 45 appartiennent à la classe d'images de décors sans défaut,
- 13 appartiennent à la classe d'images de décors avec un défaut de nuance,
- et 7 appartiennent à la classe d'images de décors avec un défaut de manque.

La figure 5.15 illustre une partie de ces échantillons.

La taille originale des images acquises par le dispositif présenté au paragraphe 5.3.1 est de 1320×1947 pixels. Cette taille est trop importante pour pouvoir traiter l'image entière du décor en un temps inférieur à la seconde. D'autre part, il n'est pas nécessaire d'analyser toutes les zones de cette image. C'est pourquoi, nous avons choisi de traiter une région d'intérêt de taille 128×128 pixels.

En considérant le sous-espace d'attributs de dimension $\hat{d} = 2$ précédemment sélectionné, le taux de bonne classification des échantillons réels "Fanta" atteint 96.9%. En effet, toutes les images ont été correctement classées sauf deux images de la classe des décors avec un défaut de nuance qui ont été assignées à la classe des décors sans défaut. Il s'agit donc d'une sous-détection des défauts. Le temps requis pour classer une image avec le sous-espace sélectionné n'est que de 0.17 s, ce qui représente un temps nettement inférieur à une seconde.

5.4.2.2 Résultats obtenus pour le contrôle des décors "Sprite"

Apprentissage hors-ligne des décors "Sprite"

Comme pour les décors "Fanta", les bases d'images prototypes et d'images test "Sprite" contiennent également 64 images de taille 128×128 pixels par classe. L'apprentissage requiert donc également une vingtaine de minutes. Le tableau 5.2 présente les $d_{max} = 10$ sous-espaces d'attributs candidats sélectionnés pour discriminer les textures couleur de la base de décors

"Sprite" et indique le taux T d'images test bien classées obtenu avec chaque sous-espace d'attributs candidat pour les différentes dimensions d considérées, ainsi que le temps Tc (en secondes) nécessaire pour classer une image.

d	Espace couleur	Matrice	Attribut	T	Tc
1	$(I1, S1, H3)$	$m^{S1, H3}$	$f_{13}^{S1, H3}$	77.08%	0.12
2	(x, y, z)	$m^{y, z}$	$f_6^{y, z}$	92.71%	0.17
3	(x, y, z)	$m^{x, y}$	$f_{13}^{x, y}$	97.92%	0.22
4	(R, G, B)	$m^{R, R}$	$f_{12}^{R, R}$	99.48%	0.27
5	(Y, x, y)	$m^{x, x}$	$f_{13}^{x, x}$	99.48%	0.33
6	(A, C_1, C_2)	m^{C_1, C_2}	$f_8^{C_1, C_2}$	98.44%	0.39
7	(Y', I', Q')	$m^{I', Q'}$	$f_5^{I', Q'}$	97.92%	0.44
8	(bw, rg, by)	$m^{rg, by}$	$f_{13}^{rg, by}$	97.92%	0.49
9	(A, C_1, C_2)	m^{C_1, C_2}	$f_3^{C_1, C_2}$	97.92%	0.54
10	$(I1, I2, I3)$	$m^{I1, I2}$	$f_{13}^{I1, I2}$	97.40%	0.59

Tableau 5.2 : Les $d_{max} = 10$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base de décors "Sprite".

Le sous-espace final, qui va être considéré lors de la classification en-ligne des décors réels des verres "Sprite", est le sous-espace d'attributs de dimension $\hat{d} = 4$. En effet, ce sous-espace permet d'obtenir le meilleur taux d'images test "Sprite" bien classées (99.48%) avec la dimension d la plus faible. Les prototypes semblent ici plus difficiles à classer car la dimension du sous-espace d'attributs discriminant est plus importante que précédemment.

Classification en-ligne des décors réels "Sprite"

Nous disposons de 64 échantillons réels à classer de taille 128×128 pixels :

- 45 appartiennent à la classe des images de décors sans défaut,
- 12 appartiennent à la classe des images de décors avec un défaut de nuance,
- et 7 appartiennent à la classe des images de décors avec un défaut de manque.

La figure 5.16 illustre une partie de ces échantillons.

Avec le sous-espace discriminant de dimension $\hat{d} = 4$ sélectionné, le temps requis pour classer une image est de 0.27 s. Le taux de classification obtenu atteint 92.2%. En effet, cinq images de la classe des décors avec un défaut de nuance ont été assignées à la classe des décors avec un défaut de manque. 100% des défauts ont donc été détectés. Nous sommes confrontés ici à une mauvaise identification des défauts provoquée par des prototypes qui ne sont pas encore suffisamment représentatifs.

Une amélioration de la méthode de synthèse de textures couleur utilisée pour simuler la présence des défauts pourrait permettre une meilleure distinction entre ces deux classes et ainsi accroître les résultats de classification.

Images issues des décors « Fanta »
réels sans défaut




Images issues des décors « Fanta »
réels avec un défaut de nuance

Images issues des décors « Fanta »
réels avec un défaut de manque

Figure 5.15 : Illustration d'une partie des images réelles "Fanta" à classer.

Images issues des décors « Sprite »
réels sans défaut



Images issues des décors « Sprite »
réels avec un défaut de nuance

Images issues des décors « Sprite »
réels avec un défaut de manque

Figure 5.16 : Illustration d'une partie des images réelles "Sprite" à classer.

5.4.3 Bénéfices d'une telle approche pour l'entreprise

L'approche originale proposée offre un avantage non négligeable pour l'entreprise. En effet, outre les performances de classification satisfaisantes, elle permet non seulement de détecter les défauts présents sur les décors des verres, mais surtout de les identifier. Cela est intéressant car des statistiques sur les défauts les plus présents vont pouvoir être effectuées afin de cibler les actions correctives sur la cause du plus grand nombre de rebuts.

D'autre part, cette approche offre aux entreprises une nouvelle perspective plus efficace concernant le contrôle qualité. En effet, la simulation de la présence des défauts peut être effectuée en amont, dès la fin de la phase de conception d'un nouveau produit, à l'aide du verre "prototype" validé par le client avant la mise en production. Cette démarche, où le contrôle qualité est intégré dès la conception, permet de déterminer les règles de décision avant même la mise en production du produit. Ceci est intéressant car la conjoncture économique actuelle impose la production de séries de plus en plus petites et donc, des changements de séries de plus en plus fréquents. L'approche proposée répond alors à ce problème en permettant de disposer d'un réglage décidé en amont, et non décidé lors du changement de série comme cela se fait fréquemment. Cela pourrait permettre de réduire les temps de changement de série, et également permettre d'uniformiser la procédure de contrôle qualité.

5.5 Conclusion

Nous avons appliqué la méthode de classification supervisée de textures couleur que nous avons développée à l'identification de défauts sur des décors de verres. Ce chapitre a montré que les performances atteintes par notre méthode en termes de taux de détection de défauts sont satisfaisantes.

La méthode développée répond également à la contrainte de production imposée par l'application industrielle qui est d'inspecter automatiquement un verre en un temps inférieur à la seconde. Bien sûr, le temps de classification en-ligne dépend de la taille de l'image à traiter que nous avons fixée ici à 128×128 pixels. Le problème de la détermination dans l'image originale d'une région d'intérêt de cette taille reste encore ouvert. Ces régions doivent correspondre à des zones de textures couleur du décor où la présence de défauts n'est pas tolérable. Plusieurs régions d'intérêt pourraient même être traitées en parallèle pour contrôler une plus grande surface du décor. Il est également envisagé d'étudier la solution du sous-échantillonnage spatial de l'image pour diminuer les temps de traitement en-ligne.

Comme les échantillons disponibles ne sont pas suffisamment représentatifs qualitative-ment et quantitativement des différentes classes de défauts à discriminer, nous avons proposé de générer des images de synthèse présentant des défauts d'aspect. Ces images constituent ici l'ensemble des images prototypes.

Bien que la simulation de la présence des défauts soit parfois grossière, elle suffit à caracté-

riser les défauts réels puisque les résultats de classification des images réelles sont satisfaisants.

Bien sûr, il est nécessaire de poursuivre cette étude de faisabilité en améliorant la méthode de synthèse de textures couleur utilisée pour simuler les défauts de nuance et de manque. Il est également envisagé de créer de nouvelles fonctions permettant de modéliser les défauts de tâche et de décalage, afin d'identifier la totalité des défauts. Enfin, de nouveaux tests sur d'autres décors de verres portant des textures couleur font également partie de nos perspectives industrielles.

Conclusion générale et perspectives

Dans ce mémoire, nous présentons notre contribution au domaine de la classification de textures couleur. L'approche que nous proposons s'inscrit dans un contexte industriel et a été élaborée en vue d'atteindre des performances élevées en termes de résultats et de temps de traitement. L'objectif est en effet de pouvoir appliquer la méthode développée au contrôle qualité des décors de verres produits par l'entreprise Arc International, mais également de l'étendre à d'autres applications industrielles. Ce projet de recherche a été soutenu par la Région Nord Pas-de-Calais et le pôle de compétitivité MAUD (Matériaux & Applications pour une Utilisation Durable).

Laurent Busin, qui a obtenu sa thèse de doctorat en 2006, a mené les premiers travaux de recherche abordant le sujet du contrôle qualité des verres décorés par sérigraphie. Il a développé un poste d'acquisition, destiné à acquérir les images des décors imprimés sur les verres, et a mis en place une méthode de contrôle automatique qui permet de détecter les défauts d'aspect au moyen d'une segmentation d'images couleur par classification de pixels. L'originalité de son approche réside dans la sélection non supervisée des espaces couleur qui permettent de discriminer au mieux chacune des classes de pixels. Cette méthode a donné d'excellents résultats pour des verres dont le décor présente des zones de couleurs homogènes, mais a montré ces limites lorsque les décors présentent des zones de textures couleur. Par ailleurs, les performances atteintes par cette méthode dépendent fortement des décors inspectés.

Afin d'enrichir les travaux initiaux développés par L. Busin, nous avons proposé de discriminer les zones de textures sans défaut des zones de textures avec défaut en les classant de manière supervisée. Cela impose de construire, lors de l'apprentissage supervisé, des classes d'images suffisamment représentatives des textures contrôlées avec et sans défaut. Le nombre de classes correspond alors au nombre de types de défauts à inspecter, plus une classe correspondant aux décors sans défaut. Cette répartition des images permet non seulement de détecter les défauts présents sur les décors des verres, mais également de les identifier.

Pour discriminer les différentes classes en présence, nous proposons de considérer une approche multi-espaces couleur qui consiste à représenter les couleurs des pixels dans plusieurs espaces couleur issus notamment de la colorimétrie.

Cependant, l'examen des zones de textures impose de caractériser non seulement la distri-

bution des couleurs au sein des espaces, mais également leur répartition spatiale. Cela nous a amené à combiner l'approche multi-espaces couleur avec des attributs de texture, qui caractérisent la répartition spatiale des couleurs au sein des images. Cette caractérisation est d'autant plus efficace lorsque les attributs modélisent les relations spatiales entre les différentes composantes couleur de chaque espace.

L'un des points clés de notre approche consiste alors à sélectionner un sous-espace d'attributs le plus discriminant possible parmi des attributs de texture évalués à partir de différents espaces couleur et qui prennent en compte les relations spatiales intra et inter-composantes. C'est la raison pour laquelle les deux premiers chapitres de ce mémoire s'intéressent respectivement aux attributs de texture couleur et à leur sélection.

Dans le premier chapitre, nous avons dressé un état de l'art des principaux attributs de texture couleur utilisés dans le cadre de la classification d'images. Cette étude a permis de mettre en évidence que le choix des attributs à considérer est un des points délicats dans l'élaboration d'une méthode de classification. Comme ce choix dépend de différents paramètres, tels que le type de textures à discriminer, les contraintes de performance liées à l'application ou encore les conditions d'acquisition des images et les conditions d'observation des textures, il n'existe pas d'attributs qui permettent de discriminer toutes les classes d'images de texture couleur.

D'autre part, quelque soit le type d'attributs de texture couleur choisi, les auteurs sont généralement amenés à considérer un nombre important d'attributs pour discriminer les classes de manière satisfaisante. Cela peut pénaliser la qualité de la discrimination et imposer un temps de calcul trop important pour être compatible avec une application industrielle. C'est pourquoi le second chapitre de ce mémoire est consacré aux différentes méthodes permettant la réduction de l'ensemble d'attributs, avec une attention particulière pour les méthodes de sélection qui sont exploitées dans nos travaux.

Tout comme le choix des attributs de texture couleur, celui de la méthode à utiliser pour réduire la dimension de l'espace d'attributs doit être mené avec soin. Les méthodes de type "embedded", combinant à la fois les approches "wrapper" et "filter", nous ont semblé être les plus pertinentes pour être appliquées à un contexte industriel. En effet, dans ce type de méthodes, une fonction d'évaluation est tout d'abord utilisée pour évaluer les sous-espaces d'attributs (approche "filter") et pré-sélectionner les sous-espaces candidats pour différentes dimensions. Puis, les taux d'erreur de classification des prototypes, obtenus en considérant chaque sous-espace candidat, sont comparés afin de déterminer le sous-espace d'attributs final (approche "wrapper"). L'approche "embedded" offre donc un bon compromis entre la qualité de la sélection de l'approche "wrapper" et le temps d'exécution obtenu par l'approche "filter".

Ensuite, le choix de la fonction d'évaluation permettant de mesurer la pertinence des sous-espaces candidats s'est avéré être lui aussi délicat. Nous avons alors mis en évidence qu'il est opportun de considérer plusieurs fonctions d'évaluation pour déterminer le sous-espace d'attributs discriminant. C'est pourquoi nous avons choisi d'adopter une telle approche lors de l'apprentissage supervisé de notre méthode, en associant une mesure de distance à un mesure

de corrélation.

Afin d'obtenir des taux de classification répondant aux contraintes d'une application industrielle, la méthodologie originale de classification proposée au troisième chapitre tient compte d'une part, d'une représentation multi-espaces couleur et d'autre part, des relations spatiales intra et inter-composantes, au moyen des attributs d'Haralick extraits des matrices de co-occurrences chromatiques. Afin d'obtenir des temps de calcul satisfaisant aux contraintes temporelles d'une application industrielle, nous avons choisi dans un premier temps, de réduire le nombre de couleurs de l'image grâce à la sous-quantification uniforme des composantes couleur et dans un second temps, d'utiliser le voisinage isotropique lors du calcul des matrices de co-occurrences, définissant ainsi les "matrices de co-occurrences chromatiques isotropiques de taille réduite".

D'autre part, nous avons développé une procédure de sélection séquentielle afin de réduire significativement le nombre d'attributs de texture couleur, diminuant ainsi le temps nécessaire pour classer les images en-ligne, tout en améliorant la qualité de la classification. Lors de cette procédure de sélection, d_{max} sous-espaces d'attributs candidats sont tout d'abord pré-sélectionnés pour différentes dimensions d ($d = 1, \dots, d_{max}$) à partir d'un ensemble d'images prototypes. Pour cela, le critère de Wilks et la mesure de corrélation ont été associés à une procédure itérative SFS (Sequential Forward Selection). Il pourrait être judicieux de remplacer la mesure de corrélation basique par une mesure plus pertinente comme l'information mutuelle, qui permet non seulement de quantifier la corrélation entre les attributs, mais également la dépendance statistique entre ces derniers. Les taux de classification obtenus sur l'ensemble d'images test (différent de l'ensemble des images prototypes) par la méthode du plus proche voisin opérant dans chacun de ces d_{max} sous-espaces sont ensuite calculés et comparés afin de déterminer le sous-espace final de dimension \hat{d} qui minimise l'erreur de classification.

La sélection parmi les attributs d'Haralick extraits des matrices de co-occurrences chromatiques, calculées à partir d'images codées dans différents espaces couleur, constitue en elle-même l'originalité principale de notre méthodologie. Cette approche permet d'une part de tirer avantage des propriétés de plusieurs espaces couleur. D'autre part, elle prend en compte la répartition spatiale de chaque composante d'un même espace couleur, mais également l'interaction spatiale entre les composantes couleur définissant chacun de ces espaces.

L'emploi d'une base de test totalement différente de la base d'apprentissage, pour comparer les taux de classification obtenus lors de l'étape de sélection, constitue un autre point original de notre méthode. En effet, la procédure de sélection permet dans ce cas d'évaluer les performances du classifieur retenu, contrairement à la plupart des approches qui utilisent les images prototypes comme images test et qui, par cela, modifient les règles de décision à chaque fois qu'une image prototype est classée.

Lors du chapitre 4, nous avons présenté les résultats expérimentaux obtenus en appliquant l'approche proposée sur trois bases d'images de référence. Pour la classification de ces bases, nous avons fixé la valeur de d_{max} à 50. Dans ce contexte, le meilleur taux d'images test bien

classées que nous avons obtenu est :

- 95.44% avec un sous-espace d'attributs de dimension $\hat{d} = 38$, pour les images de la base OuTex,
- 99.07% avec un sous-espace d'attributs de dimension $\hat{d} = 26$, pour les images de la base VisTex,
- 93.87% avec un sous-espace d'attributs de dimension $\hat{d} = 50$, pour les images de la base BarkTex.

Nous avons également étudié l'influence des paramètres de la méthode développée sur les performances de classification, afin de déterminer les valeurs qui offrent un bon compromis entre les résultats de classification et les temps de calcul. Nous avons remarqué que le niveau de quantification N influe de manière significative à la fois sur le temps nécessaire à l'apprentissage, mais également sur le temps nécessaire à la classification en-ligne. La procédure de génération utilisée lors de la sélection des attributs et le nombre de distances spatiales considérées lors du calcul des matrices de co-occurrences influencent quant-à-eux fortement le temps d'apprentissage seul.

Plus particulièrement, nous avons montré que fixer le nombre de niveaux de quantification des composantes couleur à 16 permet d'obtenir d'aussi bons résultats de classification que lorsque les composantes couleur sont quantifiées avec 256 niveaux, mais avec des temps de traitement beaucoup plus courts. Il serait intéressant d'introduire une méthode de sous-quantification non uniforme des composantes couleur, afin de ne pas altérer la distribution des couleurs. La méthode développée par A.S. Capelle et basée sur la théorie des fonctions de croyance mériterait d'être associée à notre approche [CCFM06].

Concernant le voisinage utilisé lors du calcul des matrices de co-occurrences, nous recommandons de fixer la distance spatiale ν à 1, et de l'associer :

- au "2-voisinage" qui caractérise les interactions spatiales selon la direction perpendiculaire aux motifs des textures analysées, lorsque celles-ci portent une direction privilégiée,
- au "8-voisinage", lorsque les textures analysées ne présentent pas de directions privilégiées.

Ensuite, concernant la méthode de sélection, nous avons montré que la procédure de génération séquentielle SFS est aussi performante que la procédure SFFS et qu'il est donc préférable de la retenir pour des applications nécessitant un temps d'apprentissage court.

Enfin, nous avons montré que le nombre maximal d_{max} de sous-espaces candidats doit être fixé en fonction des contraintes de l'application, à savoir le taux minimum d'images bien classées que l'on doit obtenir et les temps d'apprentissage et de classification à ne pas dépasser.

Par ailleurs, nous pouvons déduire de ce chapitre des conclusions plus générales. En effet, nous avons évalué l'apport de la méthode mise en place en montrant tout d'abord que l'approche multi-espaces couleur améliore significativement les résultats de classification obtenus, par rapport à l'exploitation des propriétés d'un unique espace couleur choisi préalablement. D'autre part, la considération conjointe des relations spatiales intra et inter-composantes s'est révélée être également porteuse d'améliorations des résultats de classification par rapport à la

prise en compte des relations spatiales intra-composantes seules. Nous avons enfin montré le bénéfice qu'apporte la méthode de sélection d'attributs mise en place en termes de résultats de classification et de temps de traitement en-ligne.

Toutefois, il est à noter que la stratégie de classification de textures couleur proposée dans ce mémoire offre un cadre de travail général et qu'elle peut parfaitement être exploitée avec d'autres espaces couleur et d'autres attributs de texture. Il paraît ainsi intéressant de comparer la pertinence des attributs d'Haralick vis-à-vis d'autres attributs, comme les attributs extraits de la transformée en ondelettes ou les LBP, qui sont des descripteurs de texture couleur simples à implémenter, peu coûteux en temps de calcul et qui ont déjà permis d'obtenir des résultats de classification très satisfaisants dans d'autres travaux.

D'autre part, afin de réduire le temps d'exécution de la phase d'apprentissage, il serait également intéressant d'étudier la pertinence d'autres critères permettant de déterminer la dimension du sous-espace d'attributs discriminant, sans qu'il soit nécessaire d'opérer une classification d'une base d'images de textures. En effet, le critère utilisé par notre méthode impose le calcul de plusieurs taux de classification. Cette approche permet d'évaluer le classifieur retenu mais augmente considérablement le temps d'apprentissage. Un critère basé directement sur la mesure du pouvoir discriminant des sous-espaces d'attributs semblerait plus pertinent. Toutefois, comme il n'existe pas à notre connaissance de critère disponible permettant la comparaison du pouvoir discriminant de sous-espaces de dimensions différentes, nous avons retenu la solution "embedded".

Enfin, afin de réduire les temps d'exécution de la phase de classification, il est envisagé d'étudier d'autres méthodes de classement que celle du plus proche voisin qui nécessite le calcul de nombreuses distances entre le point-image à classer et les points-prototypes. Cette méthode de classement est coûteuse en temps de calcul et la méthode "Fast-kNN" semblerait être une première approche intéressante.

Dans le chapitre 5, nous avons mesuré la pertinence de notre méthodologie vis-à-vis de l'application de contrôle qualité des décors de verres produits par Arc International. Pour répondre au problème de sous-représentativité des prototypes lié à cette application, une approche classique consiste à mener un apprentissage semi-supervisé. C'est la problématique sur laquelle travaille Mariam Kalakech, actuellement en thèse de doctorat au laboratoire LAGIS, en exploitant des méthodes de classification spectrale. Nous proposons quant à nous une approche originale, dédiée au contrôle qualité en milieu industriel, basée sur la génération d'images de synthèse présentant les défauts à détecter.

Dans la plupart des cas, le contrôle qualité des produits manufacturés est une étape de la production qui est menée après la phase d'industrialisation et seulement lorsque les premiers articles sont fabriqués et que les premiers défauts apparaissent. Nous proposons au contraire d'étudier cette phase de contrôle qualité dès la conception même du nouveau produit. Cette étude nécessite de modéliser les caractéristiques et la méthode de fabrication du produit inspecté. Il devient alors possible de prédire les défauts qui apparaîtront sur le produit.

Dans le cas du contrôle qualité par vision industrielle, ces défauts peuvent être simulés par synthèse d'images, ce qui permet de les caractériser avant même le lancement en production. On dispose ainsi d'un réglage décidé en amont, et non lors du changement de séries. Cette approche est intéressante, particulièrement dans la conjoncture actuelle où les gammes de produits sont sans cesse renouvelées, ce qui impose une modification fréquente des décors. Ainsi, la mise au point du système de contrôle qualité lors de la phase de conception du produit permet de réduire les temps de changement de séries des décors.

La procédure de simulation de défauts mise en place permet alors de constituer la base d'images utilisée lors de la phase d'apprentissage hors-ligne. Cette procédure de simulation s'est révélée être suffisamment pertinente pour caractériser les défauts réels à détecter. En effet, nous avons obtenu un taux de bonne classification de 96.9% pour les décors de type "Fanta" et de 92.2% pour les décors de type "Sprite". D'autre part, nous avons pu remarquer que l'ensemble des choix qui ont été faits pour élaborer la méthode de classification de textures couleur permet d'atteindre des performances de classification satisfaisant aux contraintes du contrôle qualité des décors de verres. Le temps requis pour classer en-ligne une image de taille 128×128 pixels avec le sous-espace sélectionné pour chacun des deux types de verres est respectivement de 0.17 s et 0.27 s, ce qui satisfait la contrainte de production de traiter au minimum un verre à la seconde.

Bien sûr, il est envisagé d'améliorer la méthode de synthèse de textures couleur utilisée pour simuler les défauts de nuance et de manque. La création de nouvelles fonctions permettant de modéliser les défauts de tâché et de décalage, et de nouveaux tests sur d'autres décors de verres portant ou non des textures couleur font également partie de nos perspectives. Enfin, le problème de la détermination d'une région d'intérêt dans l'image du verre à contrôler sera également abordé, avec une première piste consistant à utiliser plusieurs régions d'intérêt traitées en parallèle pour contrôler une plus grande surface du décor.

Annexe A

Les principaux systèmes de représentation de la couleur

Dans cette annexe, nous nous attacherons à décrire les espaces couleur les plus utilisés dans la littérature. Ces espaces sont regroupés en quatre familles [Van00], à savoir :

- les espaces de primaires,
- les espaces luminance-chrominance,
- les espaces perceptuels,
- et les espaces d’axes indépendants.

A.1 Espaces de primaires

La perception humaine de la couleur peut être représentée par des données tridimensionnelles. Tout **stimulus de couleur** (ensemble de rayons lumineux réfléchis ou transmis par un matériau) peut être reproduit par le mélange de trois autres stimuli : le rouge, le vert et le bleu, appelés **primaires** ou **stimuli de référence**. Ce principe de **trivariance visuelle** est connu sous les noms de **théorie de Young-Helmholtz**, **théorie trichromatique** ou encore **synthèse de la couleur**. Trois primaires sont donc nécessaires et suffisantes pour reproduire toute couleur et la **colorimétrie**, science de la mesure de la couleur, est basée sur cette théorie. Les quantités de chacune des primaires nécessaires pour reproduire une couleur sont appelées **composantes trichromatiques**. La reproduction de cette couleur peut être obtenue par **synthèse additive** (juxtaposition de lumières colorées, correspondant chacune à une des trois primaires).

Il existe une multitude d’espaces (R, G, B) qui dépendent des primaires utilisées pour reproduire la couleur. Nous présentons ici l’espace (R_C, G_C, B_C) de la CIE.

A.1.1 L’espace (R_C, G_C, B_C) de la CIE

L’espace (R_C, G_C, B_C) de la CIE (Commission Internationale de l’Éclairage) a été défini en 1931. L’indice C est ici utilisé en référence à cette commission. Selon le principe présenté

au paragraphe § 1.3.1, chaque stimulus de couleur est représenté par un point C qui définit le vecteur couleur \vec{OC} . Les coordonnées de ce vecteur sont les composantes trichromatiques R_C , G_C et B_C . Les points correspondant à des stimuli de couleur sont contenus dans un cube, connu sous le nom de **cube des couleurs** (cf. figure A.1).




Figure A.1 : Cube des couleurs.

L'origine O correspond au noir ($R_C = G_C = B_C = 0$) tandis que le blanc de référence est défini par le mélange unitaire des trois primaires ($R_C = G_C = B_C = 1$). Le choix du blanc de référence conditionne donc les valeurs unitaires des trois primaires. La droite passant par les points **Noir** et **Blanc** est appelée **axe des gris**, **axe des couleurs neutres** ou encore **axe achromatique**. En effet, les points de cette droite représentent des nuances de gris allant du noir au blanc.

A.1.2 L'espace (r_C, g_C, b_C)

Les composantes trichromatiques d'un stimulus de couleur de l'espace (R_C, G_C, B_C) sont liées à sa luminance. Deux stimuli de couleur peuvent ainsi posséder le même caractère chromatique, que nous appellerons **chrominance**, mais avoir des composantes trichromatiques R_C , G_C et B_C différentes dû au caractère achromatique (appelé ici luminance) différents de ces stimuli. Afin d'obtenir des composantes qui ne tiennent compte que de la chrominance, il convient donc de normaliser les valeurs des composantes trichromatiques par rapport à la luminance. Ceci est réalisé en divisant chaque composante par la somme des trois. Les composantes ainsi obtenues sont appelées **coordonnées trichromatiques**, **coordonnées réduites** ou encore **composantes normalisées**. Pour l'espace (R_C, G_C, B_C) de la CIE, elles sont notées r_C , g_C , b_C et sont définies par :

$$\begin{cases} r_C = \frac{R_C}{R_C + G_C + B_C}, \\ g_C = \frac{G_C}{R_C + G_C + B_C}, \\ b_C = \frac{B_C}{R_C + G_C + B_C}. \end{cases}$$

L'espace couleur associé aux coordonnées trichromatiques est appelé l'**espace** (r_C, g_C, b_C) **normalisé**. Comme $r_C + g_C + b_C = 1$, deux composantes suffisent à représenter la chrominance d'une couleur. Ainsi, Wright et Guild ont proposé un diagramme appelé **diagramme de chromaticité** (r, g) représenté par la figure A.2.




Figure A.2 : Diagramme de chromaticité (r_C, g_C) de la CIE.

Nous voyons sur cette figure que cette représentation entraîne l'existence de coordonnées négatives. Ces coordonnées représentent des couleurs physiquement non réalisables par **synthèse additive**. D'autre part, comme ces coordonnées dépendent des primaires et du blanc de référence choisis, il existe une multitude d'espaces (R, G, B) . Pour palier ces problèmes, la CIE a établi le **système de référence colorimétrique** (X, Y, Z) .

A.1.3 L'espace (X, Y, Z) de la CIE

Dans cet espace, les primaires $[X]$, $[Y]$ et $[Z]$, dites **primaires de référence**, ont été créées de telle sorte que toutes les couleurs soient exprimées par des composantes trichromatiques positives. Ces primaires sont donc virtuelles, sans réalité physique. On peut ainsi reproduire toutes les couleurs du visible par synthèse additive. La primaire $[Y]$ représente une information achromatique (plus précisément Y représente la **luminance visuelle**). On peut noter qu'il est possible de passer de n'importe quel espace (R, G, B) à l'espace (X, Y, Z) par l'intermédiaire d'une matrice de passage dont les coefficients sont conditionnés par le choix des primaires $[R]$, $[G]$ et $[B]$ utilisées et du blanc de référence considéré.

De même que pour l'espace (R_C, G_C, B_C) , la CIE a défini les coordonnées trichromatiques de l'espace (X, Y, Z) :

$$\begin{cases} x = \frac{X}{X+Y+Z}, \\ y = \frac{Y}{X+Y+Z}, \\ z = \frac{Z}{X+Y+Z}. \end{cases}$$

Comme $x + y + z = 1$, z peut être déduit à partir de x et y , ce qui permet de représenter la

couleur dans un plan et donc de construire le diagramme de chromaticité (x, y) , représenté par la figure A.3.

On voit sur ce diagramme que toutes les couleurs sont exprimées par des coordonnées trichromatiques positives, contrairement au diagramme de la figure A.2.




Figure A.3 : Diagramme de chromaticité (x, y) .

A.2 Espaces luminance-chrominance

Les espaces luminance-chrominance possèdent une composante dite de "luminance", qui permet de quantifier le caractère achromatique d'un stimuli de couleur, et deux autres composantes de chrominance (notées Chr_1 et Chr_2) permettant de quantifier le caractère chromatique d'un stimulus de couleur. Il existe différents espaces luminance-chrominance. On trouve, entre autres, les espaces perceptuellement uniformes (où la composante de luminance est notée L), les espaces antagonistes (où la composante de luminance est notée A) ou encore les espaces de télévision (où la composante de luminance est notée Y).

A.2.1 Les espaces perceptuellement uniformes

L'espace (X, Y, Z) n'est pas perceptuellement uniforme car il existe des zones dans le diagramme de chromaticité (x, y) où les différences de couleurs ne sont pas perceptibles par un observateur. En effet, des couleurs perceptuellement proches peuvent correspondre à des écarts de couleurs importants dans l'espace de représentation de la couleur adopté tandis que des couleurs perceptuellement très différentes peuvent correspondre à des écarts de couleurs faibles dans cet espace, d'où la nécessité dans certains cas d'utiliser des espaces perceptuellement uniformes, comme par exemple les espaces (U, V, W) et (L, U, V) .

Les espaces (L^*, u^*, v^*) et (L^*, a^*, b^*) sont deux espaces perceptuellement uniformes définis par le CIE. Les points correspondant à des stimuli de couleur sont contenus dans une

sphère, comme l'illustre la figure A.4. Dans le cas des espaces perceptuellement uniformes, la composante de luminance est appelée **clarté**.




Figure A.4 : Espace couleur (L^*, a^*, b^*) .

A.2.2 Les espaces antagonistes

Cette famille d'espaces de représentation de la couleur a été créée pour tenter de modéliser le système visuel humain. Afin de parvenir à ce but, quelques auteurs ont proposés différents modèles appliqués à l'analyse d'image. On retrouve notamment les travaux de Faugeras [Fau76] (espace (L, M, S)), ou ceux de Garbay et Chassery [Gar79] (espace (A, C_1, C_2)), ou encore ceux de Ballard (espace (bw, rg, by)). Ces travaux sont basés sur la théorie des couleurs opposées de Hering. Selon cette théorie, l'information couleur captée par l'oeil est transmise au cerveau sous la forme de trois composantes, une composante achromatique (L ou A) et deux composantes de chrominance, correspondant respectivement à un signal d'opposition vert-rouge et à un signal d'opposition jaune-bleu. En ce sens, les espaces (L^*, u^*, v^*) et (L^*, a^*, b^*) présentés précédemment peuvent être considérés comme des espaces antagonistes.

A.2.3 Les espaces de télévision

Le codage des signaux de télévision en couleur a été réalisé de façon à rester compatible avec les téléviseurs noir et blanc qui doivent pouvoir recevoir en noir et blanc les émissions en couleur. De même, les téléviseurs couleur doivent pouvoir recevoir en noir et blanc les émissions en noir et blanc. Pour satisfaire ces deux contraintes, les signaux de télévision séparent donc l'information de luminance de celle de chrominance. Cette séparation peut être réalisée par une transformation linéaire des composantes trichromatiques du système (R, G, B) . La luminance correspond à la composante Y du système (X, Y, Z) . Les composantes de chrominance Chr_1 et

Chr_2 sont alors calculées par les relations suivantes :

$$\begin{cases} Chr_1 = a_1(R_C - Y) + b_1(B_C - Y) \\ Chr_2 = a_2(R_C - Y) + b_2(B_C - Y) \end{cases}$$

Les coefficients a_1 , b_1 , a_2 et b_2 sont spécifiques aux différents standards de transmission (NTSC, PAL, SECAM, ...). Ainsi, le standard NTSC définit l'espace couleur (Y', I', Q') , le standard PAL utilise le système (Y', U', V') , alors que l'espace (Y, Cb, Cr) correspond au codage numérique des signaux de télévision.

A.3 Espaces perceptuels

Dans ce type d'espace, la couleur est décrite de manière subjective telle que l'homme la qualifie, c'est-à-dire par rapport à la **luminosité**, la **teinte** et la **saturation**. La luminosité caractérise le niveau lumineux d'un stimulus de couleur. La teinte correspond aux dénominations des couleurs telles que rouge, vert, bleu, jaune, ... La saturation, elle, est une grandeur permettant d'estimer le niveau de coloration d'une teinte indépendamment de sa luminosité.

Les espaces perceptuels sont en fait des cas particuliers des espaces luminance-chrominance. Il existe de nombreux espaces de ce type dans la littérature, présentés sous différentes dénominations telles que (I, S, H) , (H, S, L) , (H, S, I) , (H, S, V) , (L, T, S) , ... On retrouve notamment les espaces de coordonnées polaires et les espaces de coordonnées perceptuelles.

A.3.1 Les espaces de coordonnées polaires

Cette famille se déduit directement des espaces luminance-chrominance dans lesquels, la représentation de la couleur se fait avec un axe pour la luminosité et un plan pour la chrominance comme le montre la figure A.5.

Un point P aura alors pour coordonnées (L, C, H) , L étant la luminosité, C la **chroma** (qui est une grandeur permettant d'estimer le niveau de coloration d'une teinte, en tenant compte de sa luminosité) et H l'information de teinte. Les espaces de coordonnées polaires sont en fait une transposition des coordonnées cartésiennes des espaces luminance-chrominance en coordonnées polaires. C représente alors le module des coordonnées du point P et H l'angle d'orientation, dans un plan perpendiculaire à l'axe représentant la luminosité.

A.3.2 Les espaces de coordonnées perceptuelles

Ces espaces sont directement évalués à partir d'un espace de primaires et représentent la couleur en terme d'intensité I , de saturation S et de teinte T . L'intensité correspond à l'information de luminosité, mais elle est désignée ainsi principalement dans un souci de la différencier des espaces de coordonnées polaires.

Il existe de nombreux modèles d'espaces de coordonnées perceptuelles [Lia87, Shi95] : le modèle triangulaire, le modèle de cône hexagonal, le modèle de cône hexagonal double, ... qui




Figure A.5 : Espace de coordonnées polaires.

se différencient par les relations exprimant l'intensité, la teinte ou la saturation. Chaque modèle correspond en fait à une projection particulière du cube des couleurs sur l'axe achromatique et sur des plans perpendiculaires à cet axe.

A.4 Espaces d'axes indépendants

Un des inconvénients des espaces (R, G, B) est que ses trois composantes sont fortement corrélées, c'est-à-dire qu'elles portent en elle une information commune qui correspond au caractère achromatique d'une couleur. Cette corrélation peut être plus ou moins importante selon les cas. Ainsi, de nombreux auteurs ont tenté de déterminer des espaces de représentation de la couleur dont les composantes sont indépendantes, c'est-à-dire des composantes qui portent des informations différentes et non redondantes. La principale solution consiste à réaliser l'analyse en composantes principales d'un système de représentation en y appliquant la transformation de Karhunen-Loeve. Cette transformation est donc présentée dans le paragraphe suivant ainsi que l'espace qui en découle.

A.4.1 L'analyse en composantes principales

L'analyse en composantes principales (ACP) est une méthode d'analyse de données multidimensionnelles. Son but est d'analyser un ensemble de données quantitatives, représentées dans un espace multidimensionnel, afin d'obtenir un espace de représentation de la couleur de dimension éventuellement réduite dont les composantes, appelées composantes principales, sont décorrélées, c'est-à-dire qu'elles ne portent pas le même type d'information. Dans le cas

où les données sont les composantes trichromatiques R , G et B , par exemple, l'analyse en composantes principales fournit un espace de représentation de la couleur dont les composantes sont non corrélées et qui peuvent être traitées indépendamment. Pour cela, l'ensemble des données traitées est caractérisé par sa matrice de covariance qui est modifiée de telle sorte que toutes les covariances croisées soient nulles. Il s'agit donc de diagonaliser la matrice de covariance pour en calculer les valeurs propres et d'extraire les vecteurs propres correspondants notés w_i . Le calcul des nouvelles composantes X_i se fait donc par la relation :

$$X_i = w_i [R \ G \ B]^T$$

L'ACP, également connue sous le nom de transformation de Karhunen-Loeve, consiste donc à appliquer cette relation à chacune des nouvelles composantes.

Le problème de l'analyse en composantes principales est qu'elle dépend des propriétés statistiques d'un ensemble de données. En analyse d'images, il faut donc réaliser l'ACP de chaque image pour déterminer la transformation correspondante, ce qui est fort coûteux en temps de calcul.

Pour éviter ce problème, Ohta tente de déterminer des espaces d'axes indépendants par approximation de la transformation de Karhunen-Loeve, pour un ensemble d'images liées à une application spécifique [OKS80].

A.4.2 L'espace d'Ohta

Dans le domaine du traitement d'images couleur, une expérience menée par Ohta en 1980 sur une série de huit images différentes a permis de déterminer un espace de représentation de la couleur basé sur une analyse en composantes principales [OKS80]. Il propose de segmenter ces images en régions par la méthode de seuillage récursif de Ohlander [OPR78] et d'appliquer une analyse en composantes principales à chaque itération de l'algorithme. Il montre alors qu'il existe une transformation unique appelée $(I1, I2, I3)$ modélisant l'analyse en composantes principales et se montrant tout aussi efficace que cette dernière. Cette transformation est définie par les équations suivantes :

$$\begin{cases} I1 = \frac{R+G+B}{3}, \\ I2 = \frac{R-B}{2}, \\ I3 = \frac{2G-R-B}{4}. \end{cases}$$

Un certain nombre d'espaces de représentation de la couleur viennent d'être présentés. Les hypothèses et propriétés sous-jacentes à chacun de ces espaces ont été décrites. Cette liste est loin d'être exhaustive car il existe de nombreux autres espaces parfois spécifiques à une application particulière. Néanmoins, elle regroupe les espaces couleur les plus couramment utilisés en analyse d'images.

Annexe B

Évaluation des sous-espaces d'attributs

Cette annexe constitue un complément d'information relatif à la définition de certaines fonctions d'évaluation présentées dans le paragraphe 2.3.3.

B.1 Mesures de séparation des classes utilisées dans la définition des mesures de consistance

Les équations suivantes représentent, sans interprétation, les mesures de séparation des classes les plus couramment utilisées dans la définition des mesures de consistance [Sem04] :

- la **distance de Bhattacharyya** :

$$D^{jj'}(E_d) = -\log \sum_{i=1}^{N_{\omega}^j} \sqrt{P(\mathbf{Y}^{i,j}|C^j)P(\mathbf{Y}^{i,j}|C^{j'})} \quad (\text{B.1})$$

- la **distance de Kullback-Liebler** :

$$D^{jj'}(E_d) = \sum_{i=1}^{N_{\omega}^j} (P(\mathbf{Y}^{i,j}|C^j) - P(\mathbf{Y}^{i,j}|C^{j'})) \log \frac{P(\mathbf{Y}^{i,j}|C^j)}{P(\mathbf{Y}^{i,j}|C^{j'})} \quad (\text{B.2})$$

- la **distance de Kolmogorov** :

$$D^{jj'}(E_d) = \sum_{i=1}^{N_{\omega}^j} |P(\mathbf{Y}^{i,j}|C^j) - P(\mathbf{Y}^{i,j}|C^{j'})| \quad (\text{B.3})$$

B.2 Mesures d'entropie utilisées dans la définition des mesures d'information

Les équations suivantes représentent, sans interprétation, les mesures d'entropie les plus couramment utilisées dans la définition des mesures d'information :

– **Entropie de Shannon** [Sha48] :

$$H_{Sh}(\mathbf{Y}^{i,j}) = - \sum_{j'=1}^{N_C} P(C^{j'} | \mathbf{Y}^{i,j}) \log P(C^{j'} | \mathbf{Y}^{i,j}) \quad (\text{B.4})$$

– **Entropie de Renyi** [TGE03] :

$$H_{Re}(\mathbf{Y}^{i,j}) = \frac{1}{1-\alpha} \log \sum_{j'=1}^{N_C} (P(C^{j'} | \mathbf{Y}^{i,j}))^\alpha \quad (\text{B.5})$$

avec α , une constante strictement positive.

– **Entropie quadratique** [Sem04] :

$$H_{Qu}(\mathbf{Y}^{i,j}) = \sum_{j'=1}^{N_C} P(C^{j'} | \mathbf{Y}^{i,j}) (1 - P(C^{j'} | \mathbf{Y}^{i,j})) \quad (\text{B.6})$$

Annexe C

Synthèse des travaux portant sur la classification d'images de texture couleur

Le tableau C.1 recense une grande partie des travaux qui traitent de la classification d'images de texture couleur. D'autres travaux portant sur la segmentation par classification de pixels permettraient d'enrichir cette synthèse. Cependant, afin de ne pas surcharger ce tableau, nous nous sommes restreints au domaine de la classification d'images.

- La première colonne de ce tableau indique la référence de l'article, ainsi que l'auteur et l'année de parution.
- La seconde colonne montre les attributs de texture couleur utilisés pour caractériser les différentes classes d'images, parmi ceux présentés dans le chapitre 1.
- La troisième colonne énumère les différents espaces couleur qui ont été considérés pour classer les textures, parmi ceux présentés dans l'annexe A.
- La quatrième colonne indique si il y a eu une réduction de la dimension de l'espace d'attributs, et si oui, la méthode employée, parmi celles présentées dans le chapitre 2.
- La dimension de l'espace d'attributs utilisé lors de la phase de classification est spécifiée dans la cinquième colonne.
- La sixième colonne indique la base d'images de texture couleur utilisée (BP signifie "Base d'images Prototypes" et BT "Base d'images Test").
- Enfin, la dernière colonne présente les résultats de classification obtenus, ainsi que la méthode de validation et/ou de classification utilisée, parmi celles présentées dans le paragraphe 2.4.

Par exemple, la première ligne de ce tableau synthétise les travaux de Zheng, qui utilise des attributs géométriques et des attributs extraits des matrices de longueurs de plages pour classer des images présentant des textures de viandes [ZSZ07]. Ces images, de taille 128×128 , sont codées dans l'espace couleur (R, G, B) et sont réparties dans 3 classes, avec 20 images par classe. L'espace d'attributs géométriques est de dimension 8 et celui des attributs extraits des matrices de longueurs de plages est de dimension 15. Aucune réduction de ces dimensions n'est effectuée. Après avoir représenté les images dans ces espaces d'attributs, la classification est

effectuée, à l'aide de la méthode de validation du leaving-one-out, associée à la méthode de classification des 5-PPV. Les résultats obtenus sont 81.7% lorsque les attributs géométriques sont utilisés et 35% lorsque les textures sont caractérisées par les attributs extraits des matrices de longueurs de plages.

Tableau C.1 : Récapitulatif des travaux portant sur la classification d'images de texture couleur.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Zheng 2007 [ZSZ07]	Attributs géométriques (A1) + attributs extraits des matrices de longueurs de plages (A2)	(R, G, B)	-	8 (A1) et 15 (A2)	Textures de viandes : 3 classes avec 20 images de taille 128×128 par classe	Leaving one out + 5-PPV \rightarrow 81.7% (A1) et 35% (A2)
Hernandez 2005 [HCG+05]	Attributs estimés à partir des modèles MSAR (A1) + Markov (A2) + Pseudo Markov (A3)	(R, G, B)	-	40 (A1) et 28 (A2 et A3)	VisTex : 7680 images de taille 64×64 réparties en 73 classes / BP : 2560 images / BT : 5120 images	Réseaux de neurones \rightarrow 89.2% (A1), 90.3% (A2) et 90.4% (A3)
Khotanzad 2006 [KH06]	Attributs estimés à partir des modèles MSAR (A1) + Markov (A2) + Pseudo Markov (A3)	(R, G, B)	-	38 (A1) et 26 (A2 et A3)	VisTex : 16 classes avec 64 images de taille 64×64 par classe	Leaving one out + 1-PPV \rightarrow 100% (A1 et A2) et 99.9% (A3)
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Khotanzad 2006 [KH06]	Attributs estimés à partir des modèles MSAR (A1) + Markov (A2) + Pseudo Markov (A3)	(R, G, B)	-	38 (A1) et 26 (A2 et A3)	VisTex : 16 classes avec 64 images de taille 16×16 par classe	Leaving one out + 1-PPV \rightarrow 98.5% (A1) et 95.9% (A2 et A3)
Chindaro 2005 [CSD05]	Attributs estimés à partir du modèle de Markov	(R, G, B) (r, g, b) (H, S, V) (Y', I', Q') (Y', U', V') (L^*, a^*, b^*)	-	18	VisTex + Texture Library [Tex] : 60 classes avec 100 images par classe / BP : 50 images par classe / BT : 50 images par classe	Combinaison de 6 classifieurs (un classifieur 7-PPV par espace couleur / la classe choisie au final est celle qui maximise les probabilités en sortie de chaque classifieur) \rightarrow 93.3%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Lakmann 2002 [Lak02]	Attributs estimés à partir du modèle de covariance couleur	(R, G, B)	Sélection d'un sous-espace de dimension $\hat{d} = 30$ parmi $D = 549$ attributs : procédure de génération complète associée à une mesure du taux d'erreur de classification	30	VisTex : 320 images réparties en 32 classes / Répartition en BP et BT par la méthode Holdout (1/2 - 1/2)	1-PPV \rightarrow 74.4%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Lakmann 2002 [Lak02]	Attributs estimés à partir du modèle de covariance couleur	(R, G, B)	Sélection d'un sous-espace de dimension $\hat{d} = 36$ parmi $D = 549$ attributs : procédure de génération complète associée à une mesure du taux d'erreur de classification	36	VisTex : 408 images réparties en 6 classes / Répartition en BP et BT par la méthode Holdout (1/2 - 1/2)	1-PPV \rightarrow 77%
Mäenpää 2004 [MP04]	Histogramme des LBP (A1) et attributs extraits de la transformée de Gabor (A2)	(R, G, B)	-	1 histogramme (A1) et 120 (A2)	VisTex : 54 classes avec 16 images de taille 128×128 par classe / BP : 8 images par classe / BT : 8 images par classe	1-PPV \rightarrow 99.5%(A1) et 97.9% (A2)

Suite à la page suivante

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Mäenpää 2004 [MP04]	Histogramme des LBP (A1) et attributs extraits de la transformée de Gabor (A2)	(R, G, B)	-	1 histogramme (A1) et 120 (A2)	OuTex : 68 classes avec 20 images de taille 128×128 par classe / BP : 10 images par classe / BT : 10 images par classe	1-PPV \rightarrow 92.4% (A1) et 81.2% (A2)
Mäenpää 2004 [MP04]	Histogramme des LBP (A1) et attributs extraits de la transformée de Gabor (A2)	(R, G, B)	-	1 histogramme (A1) et 120 (A2)	OuTex avec éclairage variable : 68 classes avec 30 images de taille 128×128 par classe / BP : 10 images par classe / BT : 20 images par classe	1-PPV \rightarrow 47.1% (A1) et 47.4% (A2)
Pietikäinen 2002 [PMV02]	Histogramme des LBP (A1) et attributs extraits de la transformée de Gabor (A2)	(R, G, B)	-	1 histogramme (A1) et 120 (A2)	VisTex : 54 classes avec 16 images de taille 128×128 par classe / BP : 8 images par classe / BT : 8 images par classe	3-PPV \rightarrow 98.8%(A1) et 97.9% (A2)
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Pietikäinen 2002 [PMV02]	Histogramme des LBP (A1) et attributs extraits de la transformée de Gabor (A2)	(R, G, B)	-	1 histogramme (A1) et 120 (A2)	OuTex : 68 classes avec 20 images de taille 128×128 par classe / BP : 10 images par classe / BT : 10 images par classe	3-PPV \rightarrow 91.2% (A1) et 81.2% (A2)
Pietikäinen 2002 [PMV02]	Histogramme des LBP (A1) et attributs extraits de la transformée de Gabor (A2)	(R, G, B)	-	1 histogramme (A1) et 120 (A2)	OuTex avec éclairage variable : 68 classes avec 30 images de taille 128×128 par classe / BP : 10 images par classe / BT : 20 images par classe	3-PPV \rightarrow 10.9% (A1) et 53.3% (A2)
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Drimbarean 2001 [DW01]	Attributs extraits de la transformée en cosinus discrète intra-composante (A1), de la transformée de Gabor intra-composante (A2) et des matrices de co-occurrences intra-composante (A3)	(R, G, B) (X, Y, Z) (H, S, I) (Y', I', Q') (L^*, a^*, b^*)	-	27 (A1), 36 (A2) et 15 (A3)	VisTex : 16 classes avec 540 images de taille 32×32 par classe / BP : 30 images par classe / BT : 510 images par classe	Réseau de neurones → Comparaison des 3 méthodes en considérant l'espace (R, G, B) : 90.6% (A1), 82.1% (A2) et 72.5% (A3) / Comparaison des résultats obtenus avec les différents espaces, en considérant les attributs A1 : 87.2% (H, S, I) , 89.5% (L^*, a^*, b^*) , 90.6% (R, G, B) , 91.1% (X, Y, Z) et 92.3% (Y', I', Q')
Tang 1999 [TTSR99]	Attributs extraits de la transformée de Gabor intra-composante	(R, G, B)	-	4	Textures de feuilles et d'herbes : 40 images de taille 300×250 réparties en 5 classes / BP : 20 images / BT : 20 images	Réseau de neurones → 100%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Palm 2002 [PL02]	Attributs extraits de la transformée de Gabor	(R, G, B)	-	36	VisTex : 30 classes avec 64 images de taille 64×64 par classe	Leaving one out + 5-PPV \rightarrow 85.6%
Palm 2002 [PL02]	Attributs extraits de la transformée de Gabor	(R, G, B)	-	48	BarkTex : 6 classes avec 68 images de taille 200×300 par classe	Leaving one out + 5-PPV \rightarrow 82.6%
Palm 2000 [PKLS00]	Attributs extraits de la transformée de Gabor (A1 : Tous les attributs sont considérés) (A2 : seuls les attributs intra-composante sont considérés)	(R, G, B)	-	82 (A1) et 46 (A2)	VisTex : 30 classes avec 64 images de taille 64×64 par classe / BP : 15 images par classe / BT : 15 images par classe	5-PPV \rightarrow 61% (A1) et 92% (A2)
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Hiremath 2006 [HSP06]	Attributs extraits de la transformée en ondelettes intra-composante	(R, G, B) (H, S, V) (Y, Cb, Cr)	-	1152	VisTex : 20 classes avec 64 images de taille 64×64 par classe / BP : 640 images choisies aléatoirement / BT : images restantes	3-PPV \rightarrow Obtention des meilleurs résultats avec l'espace (R, G, B) : 97.9%
Sengur 2008 [Sen08]	Attributs extraits de la transformée en ondelettes	(R, G, B) $(I1, I2, I3)$	-	18	VisTex : 16 classes avec 120 images de taille 128×128 par classe / BP : 20 images par classe / BT : 100 images par classe	Réseaux de neurones \rightarrow Obtention des meilleurs résultats avec l'espace $(I1, I2, I3)$: 96.1%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Van de Wouwer 1999 [dWSLD99]	Attributs extraits de la transformée en ondelettes	(U, V, W) (Y', I', Q') $(I1, I2, I3)$	Sélection d'un sous-espace de dimension $\hat{d} = 10$ parmi $D = 72$ attributs : procédure de génération séquentielle SFFS associée à une mesure du taux d'erreur de classification	10	VisTex : 30 classes avec 64 images de taille 64×64 par classe	Leaving one out + k-PPV → Obtention des meilleurs résultats avec l'espace $(I1, I2, I3)$: 97.5%
Xu 2005 [XYD05]	Attributs extraits de la transformée en ondelettes	(R, G, B) $(I1, I2, I3)$	-	5 (choix de l'auteur)	OuTex : 68 classes avec 20 images de taille 128×128 par classe / BP : 680 images choisies aléatoirement / BT : images restantes	7-PPV → Obtention des meilleurs résultats avec l'espace (R, G, B) : 85.2%

Suite à la page suivante

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Iakovidis 2004 [IMK ⁺ 04]	Attributs extraits de la transformée en ondelettes et des matrices de co-occurrences chromatiques intra-composantes sous-quantifiées	(R, G, B) (r, g, b) (H, S, V) (L^*, u^*, v^*) (L^*, a^*, b^*) $(I1, I2, I3)$	-	72	Textures de lésions cancéreuses : 2 classes d'images de taille 128×128 / BP : 2401 images / BT : 7203 images	Machines à vecteur support → Obtention des meilleurs résultats avec l'espace (R, G, B) : 95.7%
Arivazhagan 2005 [AGA05]	Attributs extraits de la transformée en ondelettes et des matrices de co-occurrences chromatiques	(H, S, I) (Y', U', V')	-	25	VisTex : 20 classes d'images / BP : 1 image par classe (apprentissage sur les images de taille 512×512) / BT : 84 images de taille 64×64 par classe	1-PPV → Obtention des meilleurs résultats avec l'espace (Y', U', V') : 97.8%

Suite à la page suivante

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Lopez 2008 [LVPF08]	Attributs statistiques de texture couleur du premier ordre (moyenne et variance des composantes couleur, moments d'histogrammes)	(R, G, B) (L^*, u^*, v^*) (L^*, a^*, b^*)	Sélection d'un sous-espace pertinent : procédure de génération séquentielle SFS associée à une mesure du taux d'erreur de classification	6	Textures de céramiques : 960 images, dont taille varie entre 16×16 et 33×33 , réparties en 42 classes	1-PPV \rightarrow Obtention des meilleurs résultats avec l'espace (L^*, a^*, b^*) : 96.5%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Van Den Broek 2004 [BR04]	Attributs extraits des matrices de co-occurrences chromatiques intra-composante sous-quantifiées	(R, G, B) (H, S, V) (Y', U', V') (Y', I', Q') (X, Y, Z) (L^*, u^*, v^*)	Sélection d'un sous-espace de dimension $\hat{d} = 4$ parmi $D = 32$ attributs : procédure de génération exhaustive associée à une mesure du taux d'erreur de classification	4	VisTex : 248 images de taille 64×64 réparties en 4 classes	Combinaison de 3 classifieurs (vote majoritaire) : AFD + réseaux de neurones + 1-PPV → Obtention des meilleurs résultats avec les espaces (L, U, V) et (H, S, V) : 58%
Van Rikxoort 2004 [Rik04]	Attributs extraits des matrices de co-occurrences chromatiques intra-composante sous-quantifiées	(R, G, B)	-	12 (choix de l'auteur)	VisTex : 3 classes / BP : 40 images	Combinaison de 3 classifieurs (vote majoritaire) : AFD + réseaux de neurones + 2-PPV → 66%

Suite à la page suivante

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Burks 2000 [BSP00]	Attributs extraits des matrices de co-occurrences chromatiques intra-composante sous-quantifiées	(H, S, I)	Sélection d'un sous-espace de dimension $\hat{d} = 11$ parmi $D = 33$ attributs : procédure de génération séquentielle SFFS associée au critère de Wilks	33	Textures d'herbes : 6 classes d'images de taille 64×64 avec 40 images par classe / BP : 20 images par classe	AFD \rightarrow 91.7%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Pydipati 2006 [PBL06]	Attributs extraits des matrices de co-occurrences chromatiques intra-composante	(H, S, I)	Sélection d'un sous-espace de dimension $\hat{d} = 7$ parmi $D = 39$ attributs : procédure de génération séquentielle SFSS associée au critère de Wilks	7	Textures de feuilles de citronniers : 4 classes d'images de taille 240×320 / BP : 20 images par classe	AFD \rightarrow 100%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Akhloufi 2008 [AML08]	Attributs extraits des matrices de co-occurrences chromatiques intra-composantes associés à une statistique d'image (entropie) (A1) + Attributs extraits des images de LBP associés à une statistique d'image (A2)	(R, G, B) (H, S, L) (L^*, a^*, b^*)	-	54	2650 textures réparties en 4 bases d'images (bardeaux, bois, fibres organiques, tissus)	1-PPV → Comparaison des résultats de classification d'une des 4 bases, obtenus avec les différents espaces, en considérant les attributs A1 : 94% (R, G, B) , 93% (H, S, L) et 71% (L^*, a^*, b^*) / Comparaison des 2 méthodes en considérant l'espace (R, G, B) (moyenne des résultats des 4 bases) : 92.5% (A1) et 80.5% (A2)
Palm 2004 [Pal04]	Attributs extraits des matrices de co-occurrences chromatiques	(R, G, B) (L, U, V)	-	96	VisTex : 30 classes avec 64 images de taille 64×64 par classe	Leaving one out + 5-PPV → Obtention des meilleurs résultats avec l'espace (L, U, V) : 98.6%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Palm 2004 [Pal04]	Attributs extraits des matrices de co-occurrences chromatiques	(R, G, B) (L, U, V)	-	96	BarkTex : 6 classes avec 68 images de taille 200×300 par classe	Leaving one out + 5-PPV → Obtention des meilleurs résultats avec l'espace (L, U, V) : 86.3%
Arvis 2004 [ADBB04]	Attributs extraits des matrices de co-occurrences chromatiques sous-quantifiées	(R, G, B)	Construction d'un sous-espace discriminant par AFD à partir de l'espace d'attributs initial de dimension $D = 30$	-	VisTex : 54 classes avec 16 images de taille 128×128 par classe / BP : 8 images par classe / BT : 8 images par classe	5-PPV → 97.7%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Arvis 2004 [ADBB04]	Attributs extraits des matrices de co-occurrences chromatiques sous-quantifiées	(R, G, B)	Construction d'un sous-espace discriminant par AFD à partir de l'espace d'attributs initial de dimension $D = 30$	-	OuTex : 68 classes avec 20 images de taille 128×128 par classe / BP : 10 images par classe / BT : 10 images par classe	5-PPV \rightarrow 94.9%
Tessier 2004 [Tes04]	Attributs extraits des matrices de co-occurrences chromatiques sous-quantifiées (A1) + attributs extraits de la transformation de Fourier (A2)	(R, G, B)	Construction d'un sous-espace discriminant par AFD à partir de l'espace d'attributs initial de dimension $D = 30$ pour A1 et $D = 7$ pour A2	-	Textures de sols : 8 classes avec 70 images de taille 100×100 par classe / BP : 30 images par classe / BT : 40 images par classe	Affectation au barycentre le plus proche \rightarrow 93% (A1) et 65% (A2)
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Martinez 2005 [MALDTB05]	Attributs extraits des histogrammes des sommes et des différences intra-composante	(R, G, B) (Y', I', Q') (X_F, Y_F, Z_F) $(I1, I2, I3)$	Construction d'un sous-espace de dimension $\hat{d} = 10$ par ACP à partir de l'espace d'attributs initial de dimension $D = 21$	10	Textures de marbre : 3 classes avec 25 images par classe	Leaving one out + Réseaux de neurones → Obtention des meilleurs résultats avec l'espace $(I1, I2, I3)$: 98.9%
Münzenmayer 2002 [MVK ⁺ 02]	Attributs extraits des histogrammes des sommes et des différences	(R, G, B)	-	15	VisTex : 32 classes avec 10 images de taille 64×64 par classe	Leaving one out + 1-PPV → 98%
Münzenmayer 2002 [MVK ⁺ 02]	Attributs extraits des histogrammes des sommes et des différences	(R, G, B)	-	15	BarkTex : 6 classes avec 272 images de taille 64×64 par classe	Leaving one out + 1-PPV → 87%

Suite à la page suivante

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Münzenmayer 2005 [MWHW05]	Attributs invariants aux conditions d'illumination extraits des histogrammes des sommes et des différences	(R, G, B) avec 6 types d'illuminations	-	14	VisTex : 32 classes avec 20 images de taille 64×64 par classe / BP : 10 images par classe / BT : 10 images par classe	k-PPV \rightarrow Obtention des meilleurs résultats avec l'illumination 5000K : 76%
Paschos 2000 [Pas00]	Moments chromatiques	(X, Y, Z)	-	10	Texture de marbre et de granite : 100 classes avec 125 images de taille 250×250 par classe / BP : 25 images par classe / BT : 100 images par classe	1-PPV \rightarrow 99.9%
Suite à la page suivante						

Tableau C.1 : Suite du tableau récapitulatif.

Référence	Attributs de texture couleur	Espaces couleur	Sélection ou non	Dimension	Base d'images	Classification
Iakovidis 2005 [IMK05]	Histogramme des LBP avec (A1) ou sans (A2) l'attribut de contraste, moments chromatiques ¹ (A3), attributs extraits de la transformée en ondelette (A4)	(R, G, B) (H, S, V) (L^*, a^*, b^*) $(I1, I2, I3)$	-	2304 (A1), 4608 (A2), 20 (A3) et 72 (A4)	VisTex : 54 classes avec 16 images de taille 128×128 par classe / BP : 8 images par classe	Machines à vecteur support → Résultats présentés dans le tableau C.2
Iakovidis 2005 [IMK05]	Histogramme des LBP avec (A1) ou sans (A2) l'attribut de contraste, moments chromatiques (A3), attributs extraits de la transformée en ondelette (A4)	(R, G, B) (H, S, V) (L^*, a^*, b^*) $(I1, I2, I3)$	-	2304 (A1), 4608 (A2), 20 (A3) et 72 (A4)	OuTex : 68 classes avec 20 images de taille 128×128 par classe / BP : 10 images par classe	Machines à vecteur support → Résultats présentés dans le tableau C.3
Fin du récapitulatif						

1. Les moments chromatiques ne peuvent être utilisés ici qu'avec l'espace (R, G, B) de part leur définition [Pas00]

	A1	A2	A3	A4
(R, G, B)	99.5%	99.8%	67.8%	98.4%
$(I1, I2, I3)$	99.5%	99.5%	-	98.8%
(H, S, V)	99.5%	99.5%	-	98.6%
(L^*, a^*, b^*)	99.3%	99.5%	-	97.3%

Tableau C.2 : Résultats de classification obtenus pour les textures de la base VisTex.

	A1	A2	A3	A4
(R, G, B)	92.7%	93.1%	61.5%	88.5%
$(I1, I2, I3)$	89%	90.4%	-	89.6%
(H, S, V)	93.4%	93.5%	-	89%
(L^*, a^*, b^*)	91.6%	91.5%	-	89.7%

Tableau C.3 : Résultats de classification obtenus pour les textures de la base OuTex.

La première ligne des tableaux C.3 et C.2 indique le type d'attributs utilisé, et la première colonne l'espace couleur considéré pour caractériser les différentes classes de texture.

Que ce soit pour la classification des textures de la base VisTex ou celles de la base OuTex, les meilleurs résultats de classification sont obtenus en caractérisant les textures avec les histogrammes des LBP et la mesure de contraste associée (99.8% et 93.5%). Pour la base VisTex, c'est lorsque ces attributs ont été extraits des images codées en (R, G, B) que les meilleurs résultats ont été obtenus, et pour la base OuTex, c'est la considération de l'espace (H, S, V) qui a permis la meilleure caractérisation.

Annexe D

Codage des espaces couleur

D.1 Principe et notations

Le codage d'un espace couleur quelconque (C_1, C_2, C_3) s'effectue en plusieurs étapes successives [Van00]. Il s'agit de :

- **Décaler** les valeurs des composantes de telle sorte qu'elles soient non signées. Cette opération nécessite de connaître la valeur minimale que peut prendre chacune des composantes de l'espace considéré.
- **Normaliser** les valeurs décalées des composantes de telle sorte qu'elles appartiennent à l'intervalle $[0, N]$. Cette opération nécessite de connaître la dynamique de chacune des composantes de l'espace couleur considéré, c'est-à-dire leurs valeurs maximales et minimales.
- **Arrondir** les valeurs décalées et normalisées des composantes afin d'obtenir des valeurs entières. Nous choisissons d'arrondir à l'entier le plus proche.

Pour cela, nous notons m_k la valeur minimale de la composante C_k ($k = 1, \dots, 3$) de l'espace considéré et M_k , sa valeur maximale. La grandeur m_k permet de déterminer la valeur du décalage à effectuer et $\Delta_k = M_k - m_k$, qui représente la dynamique de la composante considérée, permet de déterminer un coefficient de normalisation en fonction de la dynamique des valeurs des composantes R , G et B .

D.2 Codage séparé

Le codage séparé consiste à coder chaque composante C_k indépendamment des deux autres selon l'équation :

$$C_{k'} = (C_k - m_k) \times \frac{N}{\Delta_k}. \quad (\text{D.1})$$

L'application du codage séparé implique que les valeurs des composantes sont multipliées par un coefficient de normalisation qui est propre à chacune des composantes, ce qui est intéressant lorsque les dynamiques des composantes d'un espace couleur sont très différentes [Van00].

Nous appliquerons le codage séparé exclusivement à la famille des espaces perceptuels.

D.3 Codage non séparé

Le codage non séparé consiste à coder chaque composante C_k en tenant compte des deux autres [Van00]. Pour cela, il faut d'abord déterminer la composante C_k de l'espace couleur considéré qui présente la dynamique maximale. Cette valeur est notée Δ_{max} . Le codage de chaque composante est alors réalisé selon l'équation suivante :

$$C_{k'} = (C_k - m_k) \times \frac{N}{\Delta_{max}}. \quad (\text{D.2})$$

Le codage non séparé permet d'appliquer un coefficient de normalisation identique sur chacune des composantes d'un espace couleur. Nous appliquerons le codage non séparé à la famille des espaces de primaires, à celle des espaces luminance-chrominance et aux espaces d'axes indépendants.

Annexe E

Autres résultats expérimentaux

Cette annexe offre un complément d'informations relatif aux résultats expérimentaux présentés dans le chapitre 4.

Ainsi, le paragraphe E.1 présente les sous-espaces candidats sélectionnés pour discriminer les textures couleur, selon la méthodologie considérée. Les paragraphes E.2 et E.3 présentent quant-à-eux un complément d'informations relatif aux temps et aux résultats de classification.

E.1 Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur

E.1.1 Résultats obtenus avec la méthodologie développée

Les tableaux E.1, E.2 et E.3 présentent les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer respectivement les textures couleur des bases OuTex, VisTex et BarkTex.

E.1.2 Résultats obtenus avec le niveau de quantification $N = 256$

Le tableau E.4 présente les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque le niveau de quantification $N = 256$ est considéré.

E.1.3 Résultats obtenus lorsque la moyenne et la variance des attributs d'Haralick sont considérées

Le tableau E.5 présente les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque la moyenne et la variance des attributs d'Haralick sont considérées.

E.1.4 Résultats obtenus lorsque les distances spatiales $\nu = 5$ et $\nu = 1, 2, 3, 4$ et 5 sont considérées

Les tableaux E.6 et E.7 présentent les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, respectivement lorsque la distance spatiale $\nu = 5$ et les distances spatiales $\nu = 1, 2, 3, 4$ et 5 sont considérées.

E.1.5 Résultats obtenus lorsque la procédure SFFS est considérée

Le tableau E.8 présente les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque la procédure de génération SFFS est considérée.

E.1.6 Résultats obtenus lorsque le critère de la trace est considéré

Le tableau E.9 présente les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque le critère de la trace est considéré.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{S1, H1}$	$f_{10}^{S1, H1}$	26	$(I1, S1, H3)$ ou $(I1, S1, H1)$	$m^{S1, S1}$	$f_2^{S1, S1}$
2	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, h_{C1C2}}$	$f_5^{C_{C1C2}, h_{C1C2}}$	27	(A, C_1, C_2)	m^{C_2, C_2}	$f_{10}^{C_2, C_2}$
3	(x, y, z)	$m^{z, z}$	$f_7^{z, z}$	28	(A, C_1, C_2)	m^{C_2, C_2}	$f_6^{C_2, C_2}$
4	(r, g, b)	$m^{r, b}$	$f_5^{r, b}$	29	(X, Y, Z)	$m^{X, Z}$	$f_5^{X, Z}$
5	(L^*, S_{uv}^*, h_{uv})	m^{L^*, S_{uv}^*}	$f_5^{L^*, S_{uv}^*}$	30	(Y', C'_{UV}, h'_{UV})	$m^{Y', h'_{UV}}$	$f_5^{Y', h'_{UV}}$
6	$(I4, S3, H2)$	$m^{I4, I4}$	$f_{11}^{I4, I4}$	31	(A, C_{C1C2}, h_{C1C2})	$m^{A, h_{C1C2}}$	$f_5^{A, h_{C1C2}}$
7	$(I1, S2, H1)$	$m^{S2, H1}$	$f_5^{S2, H1}$	32	$(I5, S4, H2)$	$m^{I5, S4}$	$f_5^{I5, S4}$
8	(Y', I', Q')	$m^{Y', Q'}$	$f_6^{Y', Q'}$	33	(X, Y, Z)	$m^{Z, Z}$	$f_{13}^{Z, Z}$
9	$(I1, S2, H1)$	$m^{S2, S2}$	$f_{10}^{S2, S2}$	34	(x, y, z) ou (Y, x, y)	$m^{x, y}$	$f_8^{x, y}$
10	$(I4, S3, H2)$	$m^{S3, H2}$	$f_5^{S3, H2}$	35	(r, g, b) ou $(I1, r, g)$	$m^{r, g}$	$f_{10}^{r, g}$
11	$(I4, S3, H2)$	$m^{I4, S3}$	$f_2^{I4, S3}$	36	(Y', C'_{UV}, h'_{UV})	$m^{Y', h'_{UV}}$	$f_7^{Y', h'_{UV}}$
12	(bw, C_{rgby}, h_{rgby})	$m^{bw, h_{rgby}}$	$f_6^{bw, h_{rgby}}$	37	(A, C_1, C_2)	m^{C_1, C_1}	$f_1^{C_1, C_1}$
13	(x, y, z)	$m^{z, z}$	$f_2^{z, z}$	38	$(I1, S1, H3)$	$m^{H3, H3}$	$f_1^{H3, H3}$
14	$(I1, C_{I2I3}, h_{I2I3})$	$m^{C_{I2I3}, h_{I2I3}}$	$f_2^{C_{I2I3}, h_{I2I3}}$	39	$(I5, S4, H2)$	$m^{I5, H2}$	$f_{11}^{I5, H2}$
15	$(I1, r, g)$	$m^{I1, g}$	$f_2^{I1, g}$	40	(L^*, a^*, b^*)	m^{L^*, b^*}	$f_5^{L^*, b^*}$
16	$(I1, S1, H3)$	$m^{I1, H3}$	$f_{10}^{I1, H3}$	41	(L^*, u^*, v^*)	m^{u^*, u^*}	$f_8^{u^*, u^*}$
17	(bw, rg, by)	$m^{bw, rg}$	$f_{13}^{bw, rg}$	42	(x, y, z)	$m^{x, z}$	$f_2^{x, z}$
18	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{I1, H1}$	$f_5^{I1, H1}$	43	(bw, C_{rgby}, h_{rgby})	$m^{bw, h_{rgby}}$	$f_2^{bw, h_{rgby}}$
19	$(I4, S3, H2)$	$m^{I4, S3}$	$f_5^{I4, S3}$	44	(Y', U', V')	$m^{U', V'}$	$f_6^{U', V'}$
20	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', h'_{IQ}}$	$f_{10}^{Y', h'_{IQ}}$	45	$(I1, r, g)$	$m^{I1, r}$	$f_2^{I1, r}$
21	(x, y, z) ou (Y, x, y)	$m^{x, x}$	$f_{11}^{x, x}$	46	(L^*, S_{uv}^*, h_{uv})	$m^{S_{uv}^*, h_{uv}}$	$f_2^{S_{uv}^*, h_{uv}}$
22	$(L, C_{Ch1Ch2}, h_{Ch1Ch2})$	$m^{C_{Ch1Ch2}, h_{Ch1Ch2}}$	$f_5^{C_{Ch1Ch2}, h_{Ch1Ch2}}$	47	$(I5, S4, H2)$	$m^{I5, H2}$	$f_6^{I5, H2}$
23	(A, C_1, C_2)	m^{C_1, C_2}	$f_6^{C_1, C_2}$	48	(L^*, u^*, v^*)	m^{v^*, v^*}	$f_9^{v^*, v^*}$
24	$(I5, S4, H2)$ ou $(I4, S3, H2)$	$m^{H2, H2}$	$f_7^{H2, H2}$	49	$(I1, S2, H1)$	$m^{S2, S2}$	$f_1^{S2, S2}$
25	(r, g, b) ou $(I1, r, g)$	$m^{g, g}$	$f_6^{g, g}$	50	(r, g, b) ou $(I1, r, g)$	$m^{r, r}$	$f_5^{r, r}$

Tableau E.1 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	(Y', C'_{UV}, h'_{UV})	$m^{C'_{UV}, C'_{UV}}$	$f_7^{C'_{UV}, C'_{UV}}$	26	(Y', U', V')	$m^{Y', V'}$	$f_5^{Y', V'}$
2	(X, Y, Z)	$m^{X, Y}$	$f_{13}^{X, Y}$	27	(x, y, z) ou (Y, x, y)	$m^{y, y}$	$f_{10}^{y, y}$
3	(Y', U', V')	$m^{U', V'}$	$f_5^{U', V'}$	28	(bw, rg, by)	$m^{bw, rg}$	$f_7^{bw, rg}$
4	(Y', C'_{IQ}, h'_{IQ})	$m^{C'_{IQ}, C'_{IQ}}$	$f_{10}^{C'_{IQ}, C'_{IQ}}$	29	(Y', U', V')	$m^{V', V'}$	$f_{13}^{V', V'}$
5	(L^*, u^*, v^*)	m^{u^*, v^*}	$f_2^{u^*, v^*}$	30	(L^*, a^*, b^*)	m^{L^*, b^*}	$f_{13}^{L^*, b^*}$
6	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, C_{C1C2}}$	$f_1^{C_{C1C2}, C_{C1C2}}$	31	(x, y, z) ou (Y, x, y)	$m^{x, y}$	$f_{13}^{x, y}$
7	(L^*, u^*, v^*) ou (L^*, S_{uv}^*, h_{uv}) ou ...	m^{L^*, L^*}	$f_5^{L^*, L^*}$	32	(R, G, B)	$m^{B, B}$	$f_2^{B, B}$
8	(r, g, b)	$m^{r, b}$	$f_2^{r, b}$	33	(L^*, S_{uv}^*, h_{uv})	$m^{S_{uv}^*, h_{uv}}$	$f_{13}^{S_{uv}^*, h_{uv}}$
9	(L^*, a^*, b^*)	m^{L^*, b^*}	$f_3^{L^*, b^*}$	34	(L^*, C_{uv}^*, h_{uv}) ou (L^*, S_{uv}^*, h_{uv})	$m^{h_{uv}, h_{uv}}$	$f_2^{h_{uv}, h_{uv}}$
10	(L^*, S_{uv}^*, h_{uv})	$m^{S_{uv}^*, S_{uv}^*}$	$f_{10}^{S_{uv}^*, S_{uv}^*}$	35	(r, g, b) ou $(I1, r, g)$	$m^{r, g}$	$f_3^{r, g}$
11	(A, C_1, C_2)	m^{C_1, C_2}	$f_{10}^{C_1, C_2}$	36	(bw, C_{rgby}, h_{rgby})	$m^{C_{rgby}, h_{rgby}}$	$f_3^{C_{rgby}, h_{rgby}}$
12	$(I4, S3, H2)$	$m^{S3, S3}$	$f_{10}^{S3, S3}$	37	(Y', I', Q')	$m^{Q', Q'}$	$f_{13}^{Q', Q'}$
13	(A, C_{C1C2}, h_{C1C2}) ou (A, C_1, C_2)	$m^{A, A}$	$f_2^{A, A}$	38	(L^*, S_{uv}^*, h_{uv})	m^{L^*, S_{uv}^*}	$f_6^{L^*, S_{uv}^*}$
14	(L^*, C_{ab}^*, h_{ab})	$m^{h_{ab}, h_{ab}}$	$f_{12}^{h_{ab}, h_{ab}}$	39	(R, G, B)	$m^{R, G}$	$f_5^{R, G}$
15	(L^*, S_{uv}^*, h_{uv})	m^{L^*, S_{uv}^*}	$f_8^{L^*, S_{uv}^*}$	40	(A, C_{C1C2}, h_{C1C2})	$m^{A, h_{C1C2}}$	$f_{12}^{A, h_{C1C2}}$
16	(R, G, B)	$m^{R, R}$	$f_{12}^{R, R}$	41	(A, C_1, C_2)	m^{C_1, C_1}	$f_{10}^{C_1, C_1}$
17	(L^*, a^*, b^*)	m^{L^*, a^*}	$f_3^{L^*, a^*}$	42	$(I1, C_{I2I3}, h_{I2I3})$	$m^{h_{I2I3}, h_{I2I3}}$	$f_8^{h_{I2I3}, h_{I2I3}}$
18	$(I1, r, g)$	$m^{I1, r}$	$f_5^{I1, r}$	43	(Y', C'_{UV}, h'_{UV})	$m^{Y', h'_{UV}}$	$f_2^{Y', h'_{UV}}$
19	$(I4, S3, H2)$	$m^{I4, S3}$	$f_7^{I4, S3}$	44	$(I1, r, g)$	$m^{I1, g}$	$f_{11}^{I1, g}$
20	(x, y, z) ou (Y, x, y)	$m^{x, y}$	$f_{12}^{x, y}$	45	$(I5, S4, H2)$ ou $(I4, S3, H2)$	$m^{H2, H2}$	$f_{10}^{H2, H2}$
21	(L^*, a^*, b^*)	m^{a^*, a^*}	$f_{11}^{a^*, a^*}$	46	$(I4, S3, H2)$	$m^{I4, I4}$	$f_{10}^{I4, I4}$
22	(L^*, a^*, b^*)	m^{a^*, a^*}	$f_{10}^{a^*, a^*}$	47	(A, C_1, C_2)	m^{A, C_2}	f_3^{A, C_2}
23	(bw, rg, by)	$m^{by, by}$	$f_{11}^{by, by}$	48	(Y', U', V')	$m^{Y', V'}$	$f_{12}^{Y', V'}$
24	(L^*, C_{ab}^*, h_{ab})	$m^{L^*, h_{ab}}$	$f_7^{L^*, h_{ab}}$	49	(L^*, u^*, v^*)	m^{L^*, u^*}	$f_3^{L^*, u^*}$
25	(L^*, u^*, v^*)	m^{u^*, u^*}	$f_{10}^{u^*, u^*}$	50	(A, C_1, C_2) ou (A, C_{C1C2}, h_{C1C2})	$m^{A, A}$	$f_7^{A, A}$

Tableau E.2 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base VisTex.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	(X, Y, Z)	$m^{X,Y}$	$f_1^{X,Y}$	26	(r, g, b) ou $(I1, r, g)$	$m^{g,g}$	$f_{12}^{g,g}$
2	(R, G, B)	$m^{R,R}$	$f_{13}^{R,R}$	27	(r, g, b) ou $(I1, r, g)$	$m^{r,g}$	$f_{12}^{r,g}$
3	(Y', C'_{UV}, h'_{UV})	$m^{Y',h'_{UV}}$	$f_{10}^{Y',h'_{UV}}$	28	(L^*, S^*_{uv}, h_{uv})	$m^{S^*_{uv},h_{uv}}$	$f_{13}^{S^*_{uv},h_{uv}}$
4	(R, G, B)	$m^{R,G}$	$f_5^{R,G}$	29	$(I4, S3, H2)$	$m^{I4,S3}$	$f_{10}^{I4,S3}$
5	(A, C_{C1C2}, h_{C1C2})	$m^{h_{C1C2},h_{C1C2}}$	$f_{12}^{h_{C1C2},h_{C1C2}}$	30	$(I1, C_{I2I3}, h_{I2I3})$	$m^{h_{I2I3},h_{I2I3}}$	$f_1^{h_{I2I3},h_{I2I3}}$
6	(L^*, S^*_{uv}, h_{uv})	$m^{L^*,S^*_{uv}}$	$f_{13}^{L^*,S^*_{uv}}$	31	$(I1, S1, H3)$	$m^{H3,H3}$	$f_7^{H3,H3}$
7	(r, g, b) ou $(I1, r, g)$	$m^{g,g}$	$f_2^{g,g}$	32	(L^*, S^*_{uv}, h_{uv}) ou (L^*, C^*_{uv}, h_{uv})	$m^{h_{uv},h_{uv}}$	$f_2^{h_{uv},h_{uv}}$
8	(L^*, S^*_{uv}, h_{uv}) ou (L^*, u^*, v^*) ou ...	m^{L^*,L^*}	$f_7^{L^*,L^*}$	33	(L^*, u^*, v^*)	m^{u^*,v^*}	$f_{10}^{u^*,v^*}$
9	(Y', C'_{UV}, h'_{UV})	$m^{C'_{UV},h'_{UV}}$	$f_9^{C'_{UV},h'_{UV}}$	34	(Y, Ch_1, Ch_2)	m^{Ch_1,Ch_1}	$f_{10}^{Ch_1,Ch_1}$
10	(L^*, S^*_{uv}, h_{uv})	$m^{S^*_{uv},h_{uv}}$	$f_3^{S^*_{uv},h_{uv}}$	35	(L^*, u^*, v^*)	m^{L^*,v^*}	$f_{10}^{L^*,v^*}$
11	$(I4, S3, H2)$	$m^{S3,H2}$	$f_5^{S3,H2}$	36	(L^*, C^*_{ab}, h_{ab})	$m^{L^*,C^*_{ab}}$	$f_{12}^{L^*,C^*_{ab}}$
12	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2},h_{C1C2}}$	$f_{10}^{C_{C1C2},h_{C1C2}}$	37	$(I1, I2, I3)$	$m^{I1,I3}$	$f_3^{I1,I3}$
13	(L^*, C^*_{ab}, h_{ab})	$m^{C^*_{ab},C^*_{ab}}$	$f_{12}^{C^*_{ab},C^*_{ab}}$	38	(L^*, C^*_{ab}, h_{ab})	$m^{L^*,C^*_{ab}}$	$f_5^{L^*,C^*_{ab}}$
14	$(I1, S2, H1)$	$m^{S2,H1}$	$f_9^{S2,H1}$	39	(R, G, B)	$m^{G,B}$	$f_5^{G,B}$
15	$(I1, I2, I3)$	$m^{I1,I2}$	$f_5^{I1,I2}$	40	$(I1, C_{I2I3}, h_{I2I3})$	$m^{h_{I2I3},h_{I2I3}}$	$f_{10}^{h_{I2I3},h_{I2I3}}$
16	$(I4, S3, H2)$	$m^{S3,S3}$	$f_5^{S3,S3}$	41	(L^*, S^*_{uv}, h_{uv})	$m^{S^*_{uv},h_{uv}}$	$f_5^{S^*_{uv},h_{uv}}$
17	(Y', U', V')	$m^{V',V'}$	$f_{11}^{V',V'}$	42	$(I1, S1, H3)$ ou $(I1, S1, H1)$	$m^{I1,S1}$	$f_2^{I1,S1}$
18	(Y', C'_{IQ}, h'_{IQ})	$m^{h'_{IQ},h'_{IQ}}$	$f_{13}^{h'_{IQ},h'_{IQ}}$	43	(X, Y, Z)	$m^{X,Z}$	$f_5^{X,Z}$
19	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1,h_{I2I3}}$	$f_5^{I1,h_{I2I3}}$	44	(A, C_1, C_2)	m^{C_1,C_2}	$f_3^{C_1,C_2}$
20	$(I1, C_{I2I3}, h_{I2I3})$	$m^{C_{I2I3},h_{I2I3}}$	$f_{10}^{C_{I2I3},h_{I2I3}}$	45	(L^*, u^*, v^*)	m^{L^*,u^*}	$f_{10}^{L^*,u^*}$
21	(A, C_{C1C2}, h_{C1C2}) ou (A, C_1, C_2)	$m^{A,A}$	$f_{11}^{A,A}$	46	(bw, rg, by)	$m^{rg,by}$	$f_{10}^{rg,by}$
22	(bw, C_{rgby}, h_{rgby})	$m^{C_{rgby},C_{rgby}}$	$f_{11}^{C_{rgby},C_{rgby}}$	47	(L^*, u^*, v^*)	m^{u^*,u^*}	$f_{11}^{u^*,u^*}$
23	(r, g, b) ou $(I1, r, g)$	$m^{g,g}$	$f_8^{g,g}$	48	$(I4, S3, H2)$	$m^{I4,S3}$	$f_5^{I4,S3}$
24	(Y', C'_{UV}, h'_{UV})	$m^{C'_{UV},h'_{UV}}$	$f_3^{C'_{UV},h'_{UV}}$	49	(R, G, B)	$m^{G,B}$	$f_4^{G,B}$
25	(L^*, u^*, v^*)	m^{u^*,u^*}	$f_{12}^{u^*,u^*}$	50	(r, g, b)	$m^{r,b}$	$f_5^{r,b}$

Tableau E.3 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base BarkTex.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{S1, H1}$	$f_{10}^{S1, H1}$	26	(bw, C_{rgby}, h_{rgby})	$m^{bw, h_{rgby}}$	$f_{10}^{bw, h_{rgby}}$
2	(A, C_1, C_2)	m^{C_2, C_2}	$f_7^{C_2, C_2}$	27	$(L, C_{Ch1Ch2}, h_{Ch1Ch2})$	$m^{L, C_{Ch1Ch2}}$	$f_5^{L, C_{Ch1Ch2}}$
3	$(I5, S4, H2)$ ou $(I4, S3, H2)$	$m^{H2, H2}$	$f_6^{H2, H2}$	28	(Y, Ch_1, Ch_2)	m^{Ch_1, Ch_2}	$f_{10}^{Ch_1, Ch_2}$
4	(A, C_1, C_2)	m^{A, C_2}	f_5^{A, C_2}	29	(bw, rg, by)	$m^{rg, by}$	$f_5^{rg, by}$
5	(A, C_{C1C2}, h_{C1C2}) ou (A, C_1, C_2)	$m^{A, A}$	$f_{11}^{A, A}$	30	(A, C_{C1C2}, h_{C1C2})	$m^{A, h_{C1C2}}$	$f_{10}^{A, h_{C1C2}}$
6	$(I1, S2, H1)$	$m^{S2, S2}$	$f_{10}^{S2, S2}$	31	(L^*, u^*, v^*)	m^{L^*, u^*}	$f_5^{L^*, u^*}$
7	(Y', C'_{UV}, h'_{UV})	$m^{C'_{UV}, h'_{UV}}$	$f_2^{C'_{UV}, h'_{UV}}$	32	(L^*, u^*, v^*)	m^{L^*, u^*}	$f_3^{L^*, u^*}$
8	(R, G, B)	$m^{B, B}$	$f_{13}^{B, B}$	33	(R, G, B)	$m^{3, 3}$	$f_3^{B, B}$
9	$(I1, I2, I3)$	$m^{I1, I2}$	$f_2^{I1, I2}$	34	$(I1, C_{I2I3}, h_{I2I3})$	$m^{C_{I2I3}, C_{I2I3}}$	$f_1^{C_{I2I3}, C_{I2I3}}$
10	(R, G, B)	$m^{R, R}$	$f_1^{R, R}$	35	$(I5, S4, H2)$	$m^{I5, H2}$	$f_5^{I5, H2}$
11	$(I1, I2, I3)$	$m^{I2, I3}$	$f_5^{I2, I3}$	36	(x, y, z) ou (Y, x, y)	$m^{y, y}$	$f_5^{y, y}$
12	$(I1, S2, H1)$	$m^{S2, H1}$	$f_5^{S2, H1}$	37	$(I1, S1, H1)$	$m^{I1, S1}$	$f_5^{I1, S1}$
13	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}}$	$f_6^{I1, h_{I2I3}}$	38	$(I4, S3, H2)$	$m^{S3, H2}$	$f_5^{S3, H2}$
14	(R, G, B)	$m^{B, B}$	$f_1^{B, B}$	39	$(I1, C_{I2I3}, h_{I2I3})$	$m^{C_{I2I3}, h_{I2I3}}$	$f_{10}^{C_{I2I3}, h_{I2I3}}$
15	$(I5, S4, H2)$	$m^{I5, S4}$	$f_2^{I5, S4}$	40	(L^*, C_{uv}^*, h_{uv})	$m^{L^*, h_{uv}}$	$f_6^{L^*, h_{uv}}$
16	(A, C_1, C_2)	m^{C_2, C_2}	$f_2^{C_2, C_2}$	41	(L^*, a^*, b^*)	m^{L^*, a^*}	$f_5^{L^*, a^*}$
17	$(I1, C_{I2I3}, h_{I2I3})$	$m^{C_{I2I3}, h_{I2I3}}$	$f_5^{C_{I2I3}, h_{I2I3}}$	42	$(I5, S4, H2)$	$m^{I5, S4}$	$f_5^{I5, S4}$
18	(X, Y, Z)	$m^{X, Y}$	$f_5^{X, Y}$	43	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}}$	$f_{10}^{I1, h_{I2I3}}$
19	$(I4, S3, H2)$	$m^{I4, H2}$	$f_{10}^{I4, H2}$	44	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}}$	$f_7^{I1, h_{I2I3}}$
20	(Y', C'_{IQ}, h'_{IQ}) ou (Y', C'_{UV}, h'_{UV}) ou ...	$m^{Y', Y'}$	$f_2^{Y', Y'}$	45	(L^*, S_{uv}^*, h_{uv})	$m^{S_{uv}^*, h_{uv}}$	$f_2^{S_{uv}^*, h_{uv}}$
21	(X, Y, Z)	$m^{X, Z}$	$f_5^{X, Z}$	46	$(I4, S3, H2)$	$m^{I4, I4}$	$f_{13}^{I4, I4}$
22	(L^*, a^*, b^*)	m^{L^*, b^*}	$f_{10}^{L^*, b^*}$	47	(Y', I', Q')	$m^{I', Q'}$	$f_5^{I', Q'}$
23	(A, C_1, C_2)	m^{C_1, C_2}	$f_{11}^{C_1, C_2}$	48	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, C_{C1C2}}$	$f_1^{C_{C1C2}, C_{C1C2}}$
24	$(I1, S1, H3)$	$m^{H3, H3}$	$f_7^{H3, H3}$	49	(L^*, u^*, v^*)	m^{L^*, u^*}	$f_{13}^{L^*, u^*}$
25	(L^*, C_{ab}^*, h_{ab})	$m^{h_{ab}, h_{ab}}$	$f_{10}^{h_{ab}, h_{ab}}$	50	$(I1, C_{I2I3}, h_{I2I3})$	$m^{C_{I2I3}, h_{I2I3}}$	$f_9^{C_{I2I3}, h_{I2I3}}$

Tableau E.4 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque le niveau de quantification $N = 256$ est considéré.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{S1, H1} \text{ moy}$	$f_{10}^{S1, H1}$	26	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, h_{C1C2}} \text{ moy}$	$f_9^{C_{C1C2}, h_{C1C2}}$
2	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, h_{C1C2}} \text{ moy}$	$f_5^{C_{C1C2}, h_{C1C2}}$	27	(x, y, z)	$m^{x, z} \text{ moy}$	$f_5^{x, z}$
3	(x, y, z)	$m^{z, z} \text{ moy}$	$f_7^{z, z}$	28	$(I1, S1, H3)$	$m^{I1, H3} \text{ moy}$	$f_5^{I1, H3}$
4	(r, g, b)	$m^{r, b} \text{ moy}$	$f_5^{r, b}$	29	$(I5, S4, H2)$	$m^{I5, S4} \text{ moy}$	$f_2^{I5, S4}$
5	(X, Y, Z)	$m^{X, Y} \text{ var}$	$f_5^{X, Y}$	30	$(I1, S1, H3)$ ou $(I1, S1, H1)$	$m^{I1, S1} \text{ moy}$	$f_8^{I1, S1}$
6	(L^*, S_{uv}^*, h_{uv})	$m^{L^*, S_{uv}^*} \text{ moy}$	$f_5^{L^*, S_{uv}^*}$	31	(Y', C'_{IQ}, h'_{IQ}) ou (Y', C'_{UV}, h'_{UV}) ou ...	$m^{Y', Y'} \text{ moy}$	$f_{12}^{Y', Y'}$
7	(L^*, u^*, v^*)	$m^{L^*, v^*} \text{ var}$	$f_{12}^{L^*, v^*}$	32	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, C_{I2I3}} \text{ var}$	$f_{11}^{I1, C_{I2I3}}$
8	$(I1, S2, H1)$	$m^{S2, H1} \text{ moy}$	$f_5^{S2, H1}$	33	(Y', C'_{UV}, h'_{UV})	$m^{Y', h'_{UV}} \text{ var}$	$f_7^{Y', h'_{UV}}$
9	(L^*, u^*, v^*)	$m^{L^*, v^*} \text{ moy}$	$f_5^{L^*, v^*}$	34	(A, C_1, C_2)	$m^{A, C_1} \text{ moy}$	f_3^{A, C_1}
10	(R, G, B)	$m^{R, R} \text{ var}$	$f_{12}^{R, R}$	35	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', h'_{IQ}} \text{ moy}$	$f_{10}^{Y', h'_{IQ}}$
11	$(I1, S1, H1)$ ou $(I1, S1, H3)$	$m^{I1, S1} \text{ moy}$	$f_5^{I1, S1}$	36	(A, C_1, C_2)	$m^{C_1, C_1} \text{ moy}$	$f_7^{C_1, C_1}$
12	$(I1, S1, H1)$ ou $(I1, S1, H3)$	$m^{I1, S1} \text{ var}$	$f_{11}^{I1, S1}$	37	(A, C_1, C_2)	$m^{C_1, C_1} \text{ var}$	$f_9^{C_1, C_1}$
13	$(I4, S3, H2)$	$m^{S3, H2} \text{ moy}$	$f_5^{S3, H2}$	38	(L^*, u^*, v^*)	$m^{L^*, v^*} \text{ var}$	$f_{10}^{L^*, v^*}$
14	(r, g, b)	$m^{b, b} \text{ var}$	$f_{10}^{b, b}$	39	$(x, y, z) / (Y, x, y)$	$m^{x, y} \text{ moy}$	$f_{11}^{x, y}$
15	(x, y, z)	$m^{x, z} \text{ moy}$	$f_{11}^{x, z}$	40	(X, Y, Z)	$m^{X, Z} \text{ moy}$	$f_5^{X, Z}$
16	(R, G, B)	$m^{R, G} \text{ moy}$	$f_1^{R, G}$	41	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}} \text{ moy}$	$f_2^{I1, h_{I2I3}}$
17	(A, C_1, C_2)	$m^{C_2, C_2} \text{ moy}$	$f_{10}^{C_2, C_2}$	42	$(r, g, b) / (I1, r, g)$	$m^{g, g} \text{ moy}$	$f_6^{g, g}$
18	(R, G, B)	$m^{R, B} \text{ var}$	$f_5^{R, B}$	43	$(I4, S3, H2)$	$m^{I4, I4} \text{ var}$	$f_{13}^{I4, I4}$
19	$(I1, S1, H3)$	$m^{I1, H3} \text{ moy}$	$f_{10}^{I1, H3}$	44	(A, C_{C1C2}, h_{C1C2})	$m^{A, h_{C1C2}} \text{ moy}$	$f_5^{A, h_{C1C2}}$
20	$(I1, S1, H3)$ ou $(I1, S1, H1)$	$m^{S1, S1} \text{ moy}$	$f_{10}^{S1, S1}$	45	(L^*, u^*, v^*)	$m^{v^*, v^*} \text{ moy}$	$f_{11}^{v^*, v^*}$
21	$(I1, I2, I3)$	$m^{I3, I3} \text{ moy}$	$f_{10}^{I3, I3}$	46	(A, C_1, C_2)	$m^{C_2, C_2} \text{ var}$	$f_1^{C_2, C_2}$
22	(Y', C'_{UV}, h'_{UV})	$m^{Y', h'_{UV}} \text{ moy}$	$f_2^{Y', h'_{UV}}$	47	(L^*, u^*, v^*)	$m^{u^*, u^*} \text{ moy}$	$f_8^{u^*, u^*}$
23	(L^*, S_{uv}^*, h_{uv})	$m^{L^*, S_{uv}^*} \text{ moy}$	$f_6^{L^*, S_{uv}^*}$	48	(L^*, S_{uv}^*, h_{uv})	$m^{S_{uv}^*, h_{uv}} \text{ moy}$	$f_3^{S_{uv}^*, h_{uv}}$
24	$(I1, S1, H3)$	$m^{S1, H3} \text{ moy}$	$f_6^{S1, H3}$	49	$(I5, S4, H2)$	$m^{S4, S4} \text{ moy}$	$f_2^{S4, S4}$
25	$(L, C_{Ch1Ch2}, h_{Ch1Ch2})$	$m^{C_{Ch1Ch2}, h_{Ch1Ch2}} \text{ moy}$	$f_5^{C_{Ch1Ch2}, h_{Ch1Ch2}}$	50	(bw, rg, by)	$m^{rg, rg} \text{ var}$	$f_{13}^{rg, rg}$

Tableau E.5 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque la moyenne et la variance des attributs d'Haralick sont considérées.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{S1, H1}$	$f_{10}^{S1, H1}$	26	$(I1, r, g)$	$m^{I1, r}$	$f_2^{I1, r}$
2	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, h_{C1C2}}$	$f_5^{C_{C1C2}, h_{C1C2}}$	27	(A, C_1, C_2)	m^{C_2, C_2}	$f_{10}^{C_2, C_2}$
3	(x, y, z)	$m^{z, z}$	$f_7^{z, z}$	28	(L^*, u^*, v^*)	m^{v^*, v^*}	$f_2^{v^*, v^*}$
4	(Y', U', V')	$m^{V', V'}$	$f_{10}^{V', V'}$	29	$(I5, S4, H2)$	$m^{I5, S4}$	$f_5^{I5, S4}$
5	(L^*, S_{uv}^*, h_{uv})	m^{L^*, S_{uv}^*}	$f_5^{L^*, S_{uv}^*}$	30	(L^*, a^*, b^*)	m^{L^*, b^*}	$f_5^{L^*, b^*}$
6	$(I1, S2, H1)$	$m^{S2, S2}$	$f_{10}^{S2, S2}$	31	$(I5, S4, H2)$	$m^{S4, H2}$	$f_9^{S4, H2}$
7	(R, G, B)	$m^{R, B}$	$f_9^{R, B}$	32	$(x, y, z) / (Y, x, y)$	$m^{x, y}$	$f_8^{x, y}$
8	(Y', I', Q')	$m^{Y', Q'}$	$f_6^{Y', Q'}$	33	(Y', U', V')	$m^{U', V'}$	$f_6^{U', V'}$
9	$(I4, S3, H2)$	$m^{S3, H2}$	$f_5^{S3, H2}$	34	(x, y, z)	$m^{x, z}$	$f_2^{x, z}$
10	$(I4, S3, H2)$	$m^{I4, S3}$	$f_2^{I4, S3}$	35	(R, G, B)	$m^{G, B}$	$f_5^{G, B}$
11	(x, y, z)	$m^{x, z}$	$f_{11}^{x, z}$	36	(bw, C_{rgby}, h_{rgby})	$m^{bw, h_{rgby}}$	$f_2^{bw, h_{rgby}}$
12	$(I1, I2, I3)$	$m^{I2, I2}$	$f_{10}^{I2, I2}$	37	$(r, g, b) / (I1, r, g)$	$m^{r, g}$	$f_{10}^{r, g}$
13	$(I1, I2, I3)$	$m^{I3, I3}$	$f_{10}^{I3, I3}$	38	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}}$	$f_2^{I1, h_{I2I3}}$
14	$(I5, S4, H2)$	$m^{I5, H2}$	$f_{10}^{I5, H2}$	39	(Y', C'_{UV}, h'_{UV})	$m^{h'_{UV}, h'_{UV}}$	$f_2^{h'_{UV}, h'_{UV}}$
15	$(L, C_{Ch1Ch2}, h_{Ch1Ch2})$	$m^{L, h_{Ch1Ch2}}$	$f_5^{L, h_{Ch1Ch2}}$	40	(A, C_1, C_2)	m^{C_1, C_1}	$f_{11}^{C_1, C_1}$
16	$(I1, S1, H3)$	$m^{S1, H3}$	$f_5^{S1, H3}$	41	(Y', U', V')	$m^{V', V'}$	$f_1^{V', V'}$
17	(L^*, S_{uv}^*, h_{uv})	$m^{S_{uv}^*, h_{uv}}$	$f_{13}^{S_{uv}^*, h_{uv}}$	42	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, C_{I2I3}}$	$f_5^{I1, C_{I2I3}}$
18	$(I4, S3, H2)$	$m^{I4, S3}$	$f_5^{I4, S3}$	43	$(I4, S3, H2)$	$m^{I4, H2}$	$f_7^{I4, H2}$
19	$(I1, S1, H3)$ ou $(I1, S1, H1)$	$m^{S1, S1}$	$f_2^{S1, S1}$	44	$(x, y, z) / (Y, x, y)$	$m^{y, y}$	$f_6^{y, y}$
20	$(I1, r, g)$	$m^{I1, g}$	$f_2^{I1, g}$	45	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', h'_{IQ}}$	$f_2^{Y', h'_{IQ}}$
21	(A, C_1, C_2)	m^{C_2, C_2}	$f_6^{C_2, C_2}$	46	(Y', C'_{UV}, h'_{UV})	$m^{Y', h'_{UV}}$	$f_5^{Y', h'_{UV}}$
22	(bw, rg, by)	$m^{rg, by}$	$f_5^{rg, by}$	47	(Y', U', V')	$m^{U', U'}$	$f_6^{U', U'}$
23	$(I1, S1, H3)$	$m^{H3, H3}$	$f_1^{H3, H3}$	48	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, C_{C1C2}}$	$f_{11}^{C_{C1C2}, C_{C1C2}}$
24	$(x, y, z) / (Y, x, y)$	$m^{x, y}$	$f_5^{x, y}$	49	(L^*, u^*, v^*)	m^{u^*, v^*}	$f_2^{u^*, v^*}$
25	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', h'_{IQ}}$	$f_{10}^{Y', h'_{IQ}}$	50	(A, C_{C1C2}, h_{C1C2})	$m^{A, h_{C1C2}}$	$f_5^{A, h_{C1C2}}$

Tableau E.6 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque la distance spatiale $v = 5$ est considérée.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{S1, H1} \nu = 1$	$f_{10}^{S1, H1}$	26	(L^*, u^*, v^*)	$m^{\nu^*, \nu^*} \nu = 4$	$f_2^{\nu^*, \nu^*}$
2	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, h_{C1C2}} \nu = 1$	$f_5^{C_{C1C2}, h_{C1C2}}$	27	(R, G, B)	$m^{R, B} \nu = 1$	$f_2^{R, B}$
3	$(x, y, z) / (Y, x, y)$	$m^{y, y} \nu = 5$	$f_7^{y, y}$	28	(Y', U', V')	$m^{Y', V'} \nu = 5$	$f_6^{Y', V'}$
4	(Y', U', V')	$m^{V', V'} \nu = 3$	$f_{10}^{V', V'}$	29	$(I5, S4, H2)$	$m^{I5, S4} \nu = 1$	$f_5^{I5, S4}$
5	(L^*, S_{uv}^*, h_{uv})	$m^{L^*, S_{uv}^*} \nu = 2$	$f_5^{L^*, S_{uv}^*}$	30	(X, Y, Z)	$m^{Z, Z} \nu = 1$	$f_{13}^{Z, Z}$
6	$(I4, S3, H2)$	$m^{I4, I4} \nu = 1$	$f_{11}^{I4, I4}$	31	(X, Y, Z)	$m^{X, Z} \nu = 4$	$f_1^{X, Z}$
7	$(I1, S1, H3)$ ou $(I1, S1, H1)$	$m^{S1, S1} \nu = 2$	$f_{10}^{S1, S1}$	32	$(x, y, z) / (Y, x, y)$	$m^{x, y} \nu = 2$	$f_8^{x, y}$
8	(Y', I', Q')	$m^{Y', Q'} \nu = 1$	$f_6^{Y', Q'}$	33	(A, C_1, C_2)	$m^{C_1, C_1} \nu = 1$	$f_{11}^{C_1, C_1}$
9	$(I4, S3, H2)$	$m^{S3, H2} \nu = 2$	$f_5^{S3, H2}$	34	(A, C_{C1C2}, h_{C1C2})	$m^{C, C} \nu = 1$	$f_{11}^{C, C}$
10	$(I5, S4, H2)$ ou $(I4, S3, H2)$	$m^{H2, H2} \nu = 5$	$f_2^{H2, H2}$	35	(Y', C'_{UV}, h'_{UV})	$m^{Y', C'_{UV}} \nu = 5$	$f_5^{Y', C'_{UV}}$
11	$(I1, I2, I3)$ ou $(I1, S1, H1)$ ou ...	$m^{I1, I1} \nu = 5$	$f_{10}^{I1, I1}$	36	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', C'_{IQ}} \nu = 5$	$f_2^{Y', C'_{IQ}}$
12	(x, y, z)	$m^{x, z} \nu = 1$	$f_{11}^{x, z}$	37	(Y', C'_{UV}, h'_{UV})	$m^{h'_{UV}, h'_{UV}} \nu = 1$	$f_2^{h'_{UV}, h'_{UV}}$
13	$(I1, I2, I3)$	$m^{I3, I3} \nu = 4$	$f_{10}^{I3, I3}$	38	(L^*, a^*, b^*)	$m^{L^*, b^*} \nu = 1$	$f_5^{L^*, b^*}$
14	$(I5, S4, H2)$	$m^{I5, H2} \nu = 4$	$f_{10}^{I5, H2}$	39	(bw, C_{rgby}, h_{rgby})	$m^{h_{rgby}, h_{rgby}} \nu = 2$	$f_1^{h_{rgby}, h_{rgby}}$
15	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{I1, H1} \nu = 4$	$f_5^{I1, H1}$	40	(L^*, C_{ab}^*, h_{ab})	$m^{h_{ab}, h_{ab}} \nu = 1$	$f_{10}^{h_{ab}, h_{ab}}$
16	$(I1, S1, H3)$ ou $(I1, S1, H1)$	$m^{S1, S1} \nu = 2$	$f_2^{S1, S1}$	41	(X, Y, Z)	$m^{X, X} \nu = 2$	$f_{12}^{X, X}$
17	(A, C_1, C_2)	$m^{C_2, C_2} \nu = 2$	$f_{10}^{C_2, C_2}$	42	(bw, C_{rgby}, h_{rgby})	$m^{bw, C_{rgby}} \nu = 5$	$f_2^{bw, C_{rgby}}$
18	(A, C_1, C_2)	$m^{A, C_1} \nu = 1$	f_{13}^{A, C_1}	43	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}} \nu = 1$	$f_2^{I1, h_{I2I3}}$
19	(L^*, a^*, b^*)	$m^{a^*, a^*} \nu = 4$	$f_{13}^{a^*, a^*}$	44	(L^*, a^*, b^*)	$m^{b^*, b^*} \nu = 1$	$f_2^{b^*, b^*}$
20	$(I4, S3, H2)$	$m^{I4, S3} \nu = 2$	$f_5^{I4, S3}$	45	$(r, g, b) / (I1, r, g)$	$m^{g, g} \nu = 5$	$f_2^{g, g}$
21	$(I1, S1, H3)$	$m^{S1, H3} \nu = 1$	$f_5^{S1, H3}$	46	(Y, x, y)	$m^{Y, y} \nu = 1$	$f_3^{Y, y}$
22	(bw, rg, by)	$m^{bw, by} \nu = 5$	$f_5^{bw, by}$	47	(Y', U', V')	$m^{V', V'} \nu = 5$	$f_2^{V', V'}$
23	$(I1, r, g)$	$m^{I1, g} \nu = 5$	$f_{10}^{I1, g}$	48	$(x, y, z) / (Y, x, y)$	$m^{x, y} \nu = 1$	$f_5^{x, y}$
24	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', h'_{IQ}} \nu = 1$	$f_{10}^{Y', h'_{IQ}}$	49	(L^*, u^*, v^*)	$m^{u^*, v^*} \nu = 1$	$f_{10}^{u^*, v^*}$
25	$(I1, S1, H3)$	$m^{S1, H3} \nu = 1$	$f_8^{S1, H3}$	50	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, C_{I2I3}} \nu = 5$	$f_1^{I1, C_{I2I3}}$

Tableau E.7 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque les distances spatiales $\nu = 1, 2, 3, 4$ et 5 sont considérées.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{S1, H1}$	$f_{10}^{S1, H1}$	26	(bw, C_{rgby}, h_{rgby})	$m^{h_{rgby}, h_{rgby}}$	$f_6^{h_{rgby}, h_{rgby}}$
2	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, h_{C1C2}}$	$f_5^{C_{C1C2}, h_{C1C2}}$	27	(L^*, a^*, b^*)	m^{L^*, b^*}	$f_5^{L^*, b^*}$
3	(x, y, z)	$m^{z, z}$	$f_7^{z, z}$	28	$(I1, S1, H3)$	$m^{S1, H3}$	$f_5^{S1, H3}$
4	(L^*, S_{uv}^*, h_{uv})	m^{L^*, S_{uv}^*}	$f_5^{L^*, S_{uv}^*}$	29	(A, C_1, C_2)	m^{C_1, C_1}	$f_7^{C_1, C_1}$
5	$(I4, S3, H2)$	$m^{I4, I4}$	$f_{11}^{I4, I4}$	30	(bw, C_{rgby}, h_{rgby})	$m^{h_{rgby}, h_{rgby}}$	$f_1^{h_{rgby}, h_{rgby}}$
6	$(I1, S2, H1)$	$m^{S2, S2}$	$f_{10}^{S2, S2}$	31	(L^*, C_{ab}^*, h_{ab})	$m^{C_{ab}^*, C_{ab}^*}$	$f_{11}^{C_{ab}^*, C_{ab}^*}$
7	$(I4, S3, H2)$	$m^{S3, H2}$	$f_5^{S3, H2}$	32	(Y', C'_{UV}, h'_{UV})	$m^{h'_{UV}, h'_{UV}}$	$f_4^{h'_{UV}, h'_{UV}}$
8	$(I4, S3, H2)$	$m^{I4, S3}$	$f_2^{I4, S3}$	33	$(I5, S4, H2)$	$m^{I5, S4}$	$f_5^{I5, S4}$
9	(x, y, z)	$m^{x, z}$	$f_9^{x, z}$	34	$(I4, S3, H2)$	$m^{I4, H2}$	$f_8^{I4, H2}$
10	(bw, rg, by)	$m^{bw, rg}$	$f_{13}^{bw, rg}$	35	(L^*, C_{ab}^*, h_{ab})	$m^{h_{ab}, h_{ab}}$	$f_{10}^{h_{ab}, h_{ab}}$
11	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}}$	$f_6^{I1, h_{I2I3}}$	36	(L^*, u^*, v^*)	m^{v^*, v^*}	$f_9^{v^*, v^*}$
12	(bw, rg, by)	$m^{rg, by}$	$f_5^{rg, by}$	37	$(I1, I2, I3)$	$m^{I2, I2}$	$f_3^{I2, I2}$
13	(bw, C_{rgby}, h_{rgby})	$m^{bw, h_{rgby}}$	$f_2^{bw, h_{rgby}}$	38	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, C_{C1C2}}$	$f_1^{C_{C1C2}, C_{C1C2}}$
14	$(I4, S3, H2)$	$m^{I4, H2}$	$f_{10}^{I4, H2}$	39	$(I1, I2, I3)$	$m^{I2, I2}$	$f_5^{I2, I2}$
15	$(r, g, b) / (I1, r, g)$	$m^{r, g}$	$f_9^{r, g}$	40	$(I4, S3, H2)$	$m^{I4, H2}$	$f_2^{I4, H2}$
16	(A, C_1, C_2)	m^{C_1, C_1}	$f_6^{C_1, C_1}$	41	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, C_{I2I3}}$	$f_5^{I1, C_{I2I3}}$
17	$(I5, S4, H2)$	$m^{I5, H2}$	$f_5^{I5, H2}$	42	$(I5, S4, H2)$	$m^{I5, H2}$	$f_7^{I5, H2}$
18	(bw, rg, by)	$m^{by, by}$	$f_{10}^{by, by}$	43	(X, Y, Z)	$m^{Y, Y}$	$f_{12}^{Y, Y}$
19	$(r, g, b) / (I1, r, g)$	$m^{g, g}$	$f_{10}^{g, g}$	44	(X, Y, Z)	$m^{Y, Z}$	$f_{13}^{Y, Z}$
20	$(I1, r, g)$	$m^{I1, r}$	$f_2^{I1, r}$	45	(R, G, B)	$m^{B, B}$	$f_1^{B, B}$
21	$(I5, S4, H2)$	$m^{S4, H2}$	$f_2^{S4, H2}$	46	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', h'_{IQ}}$	$f_2^{Y', h'_{IQ}}$
22	(R, G, B)	$m^{R, B}$	$f_2^{R, B}$	47	$(r, g, b) / (I1, r, g)$	$m^{r, g}$	$f_2^{r, g}$
23	(R, G, B)	$m^{G, G}$	$f_6^{G, G}$	48	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}}$	$f_3^{I1, h_{I2I3}}$
24	$(I5, S4, H2)$	$m^{S4, S4}$	$f_2^{S4, S4}$	49	(bw, rg, by)	$m^{rg, rg}$	$f_5^{rg, rg}$
25	$(x, y, z) / (Y, x, y)$	$m^{x, y}$	$f_5^{x, y}$	50	(L^*, S_{uv}^*, h_{uv}) ou (L^*, C_{uv}^*, h_{uv}) ou (L^*, S_{uv}^*, h_{uv})	$m^{L^*, h_{uv}}$	$f_5^{L^*, h_{uv}}$

Tableau E.8 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque la procédure de génération SFFS est considérée.

d	Espace couleur	Matrice	Attribut	d	Espace couleur	Matrice	Attribut
1	$(I1, S1, H1)$ ou $(I1, S2, H1)$	$m^{S1, H1}$	$f_{10}^{S1, H1}$	26	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', h'_{IQ}}$	$f_{10}^{Y', h'_{IQ}}$
2	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, h_{C1C2}}$	$f_5^{C_{C1C2}, h_{C1C2}}$	27	(X, Y, Z)	$m^{Z, Z}$	$f_{13}^{Z, Z}$
3	(x, y, z)	$m^{z, z}$	$f_7^{z, z}$	28	(A, C_{C1C2}, h_{C1C2})	$m^{C_{C1C2}, C_{C1C2}}$	$f_{11}^{C_{C1C2}, C_{C1C2}}$
4	(r, g, b)	$m^{r, b}$	$f_5^{r, b}$	29	(Y', C'_{IQ}, h'_{IQ})	$m^{C'_{IQ}, h'_{IQ}}$	$f_{10}^{C'_{IQ}, h'_{IQ}}$
5	(L^*, S_{uv}^*, h_{uv})	m^{L^*, S_{uv}^*}	$f_5^{L^*, S_{uv}^*}$	30	(x, y, z)	$m^{y, z}$	$f_{10}^{y, z}$
6	$(I4, S3, H2)$	$m^{I4, I4}$	$f_{11}^{I4, I4}$	31	$(x, y, z) / (Y, x, y)$	$m^{x, y}$	$f_{11}^{x, y}$
7	$(I1, S1, H3)$	$m^{S1, H3}$	$f_5^{S1, H3}$	32	(A, C_{C1C2}, h_{C1C2})	$m^{A, h_{C1C2}}$	$f_5^{A, h_{C1C2}}$
8	(Y', I', Q')	$m^{Y', Q'}$	$f_6^{Y', Q'}$	33	$(I1, I2, I3)$	$m^{I2, I2}$	$f_5^{I2, I2}$
9	$(I4, S3, H2)$	$m^{S3, H2}$	$f_5^{S3, H2}$	34	(L^*, a^*, b^*)	m^{b^*, b^*}	$f_2^{b^*, b^*}$
10	$(I4, S3, H2)$	$m^{I4, S3}$	$f_2^{I4, S3}$	35	(bw, rg, by)	$m^{rg, rg}$	$f_1^{rg, rg}$
11	(A, C_1, C_2)	m^{C_2, C_2}	$f_{10}^{C_2, C_2}$	36	$(I1, S1, H3)$	$m^{I1, H3}$	$f_5^{I1, H3}$
12	(x, y, z)	$m^{x, z}$	$f_{11}^{x, z}$	37	$(I5, S4, H2)$	$m^{S4, H2}$	$f_1^{S4, H2}$
13	(A, C_1, C_2)	m^{C_2, C_2}	$f_6^{C_2, C_2}$	38	$(I1, r, g)$	$m^{I1, r}$	$f_2^{I1, r}$
14	(bw, rg, by)	$m^{bw, rg}$	$f_{13}^{bw, rg}$	39	(Y', U', V')	$m^{U', V'}$	$f_8^{U', V'}$
15	$(I1, I2, I3)$	$m^{I2, I2}$	$f_{10}^{I2, I2}$	40	(Y', U', V')	$m^{U', U'}$	$f_{10}^{U', U'}$
16	$(I4, S3, H2)$	$m^{I4, S3}$	$f_5^{I4, S3}$	41	(X, Y, Z)	$m^{X, Z}$	$f_1^{X, Z}$
17	(bw, rg, by)	$m^{rg, by}$	$f_5^{rg, by}$	42	(Y, x, y)	$m^{Y, Y}$	$f_{12}^{Y, Y}$
18	$(I1, S1, H3)$	$m^{H3, H3}$	$f_1^{H3, H3}$	43	(Y', C'_{IQ}, h'_{IQ})	$m^{Y', h'_{IQ}}$	$f_3^{Y', h'_{IQ}}$
19	$(I5, S4, H2)$	$m^{I5, H2}$	$f_{10}^{I5, H2}$	44	(X, Y, Z)	$m^{X, Z}$	$f_3^{X, Z}$
20	$(I1, C_{I2I3}, h_{I2I3})$	$m^{I1, h_{I2I3}}$	$f_5^{I1, h_{I2I3}}$	45	(R, G, B)	$m^{G, G}$	$f_{10}^{G, G}$
21	(X, Y, Z)	$m^{X, Z}$	$f_5^{X, Z}$	46	(Y', I', Q')	$m^{Y', Q'}$	$f_{13}^{Y', Q'}$
22	$(I1, C_{I2I3}, h_{I2I3})$	$m^{C_{I2I3}, h_{I2I3}}$	$f_{10}^{C_{I2I3}, h_{I2I3}}$	47	$(r, g, b) / (I1, r, g)$	$m^{r, g}$	$f_{10}^{r, g}$
23	(Y', C'_{UV}, h'_{UV})	$m^{Y', h'_{UV}}$	$f_5^{Y', h'_{UV}}$	48	$(I1, S1, H3)$ ou $(I1, S1, H1)$	$m^{I1, S1}$	$f_5^{I1, S1}$
24	(L^*, u^*, v^*)	m^{v^*, v^*}	$f_{13}^{v^*, v^*}$	49	$(I1, C_{I2I3}, h_{I2I3})$	$m^{h_{I2I3}, h_{I2I3}}$	$f_2^{h_{I2I3}, h_{I2I3}}$
25	$(I1, S2, H1)$	$m^{S2, S2}$	$f_2^{S2, S2}$	50	(L^*, a^*, b^*)	m^{L^*, a^*}	$f_{13}^{L^*, a^*}$

Tableau E.9 : Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque le critère de la trace est considéré.

E.2 Temps requis pour classer les images test

Les figures E.1 et E.2 présentent les temps requis pour classer les images test des l'ensembles VisTex et BarkTex selon le sous-espace d'attributs candidat de dimension d .




Figure E.1 : Temps de classification (en secondes) des 432 images test de taille 128×128 issues de la base VisTex, en fonction de la dimension d du sous-espace d'attributs candidat.




Figure E.2 : Temps de classification (en secondes) des 816 images test de taille 64×64 issues de la base BarkTex, en fonction de la dimension d du sous-espace d'attributs candidat.

E.3 Résultats de classification obtenus

E.3.1 Résultats de classification obtenus en considérant des attributs statistiques

Les figures E.3 et E.4 présentent les taux T de bonne classification des images test des bases OuTex et VisTex obtenus en fonction de la dimension d du sous-espace d'attributs sélectionné et selon que la texture couleur est caractérisée par les attributs d'Haralick ou les attributs statistiques classiques.




Figure E.3 : Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.




Figure E.4 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.

E.3.2 Résultats de classification obtenus en fonction de la structure du voisinage

La figure E.5 présente les taux T de bonne classification des images test de la base Vis-
Tex obtenus en considérant les sous-espaces d'attributs candidats pour chaque dimension d , en
fonction de la structure du voisinage considéré lors du calcul des matrices de co-occurrences.




Figure E.5 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes structures du voisinage considérées lors du calcul des matrices de co-occurrences.

E.3.3 Résultats de classification obtenus en fonction des distances spatiales

Les figures E.6 et E.7 présentent les taux T de bonne classification des images test des bases VisTex et BarkTex obtenus en considérant les sous-espaces d'attributs candidats pour chaque dimension d , en fonction des distances spatiales considérées pour calculer les attributs d'Haralick.




Figure E.6 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes distances spatiales considérées pour calculer les attributs d'Haralick.




Figure E.7 : Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes distances spatiales considérées pour calculer les attributs d'Haralick.

E.3.4 Résultats de classification obtenus en fonction de la procédure de génération

Les figures E.8 et E.9 présentent les taux T de bonne classification des images test des bases VisTex et BarkTex obtenus en considérant les sous-espaces d'attributs candidats pour chaque dimension d , en fonction de la procédure de génération considérée.




Figure E.8 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes procédures de génération.




Figure E.9 : Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes procédures de génération.

E.3.5 Résultats de classification obtenus en fonction de la mesure de distance

Les figures E.10 et E.11 présentent les taux T de bonne classification des images test des bases VisTex et BarkTex obtenus en considérant les sous-espaces d'attributs candidats pour chaque dimension d , en fonction de la mesure de distance considérée.




Figure E.10 : Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes mesures de distance.




Figure E.11 : Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes mesures de distance.

Bibliographie

- [ADBB04] V. Arvis, C. Debain, M. Berducat, et A. Benassi. Generalization of the cooccurrence matrix for colour images : application to colour texture classification. *Image Analysis and Stereology*, 23 :63–72, 2004.
- [AGA05] S. Arivazhagan, L. Ganesan, et V. Angayarkanni. Color texture classification using wavelet transform. In *Proceedings of the Sixth International Conference on Computational Intelligence and Multimedia Applications (ICCIMA '05)*, pages 315–320, 2005.
- [AH95] H. Anys et D.C. He. Evaluation of textural and multipolarization radar features for crop classification. *IEEE Transactions on Geoscience and Remote Sensing*, 23 :1169–1181, 1995.
- [AML08] M.A. Akhloufi, X. Maldague, et W.B. Larbi. A new color-texture approach for industrial products inspection. *Journal of Multimedia*, 3(3) :44–50, 2008.
- [ATR03] A. Akono, E. Tonyé, et J.P. Rudant. Classification texturale d’une image radar à synthèse d’ouverture dans une région volcanique : le cas de la région du mont cameroun. *Téledétection*, 3(2) :187–200, 2003.
- [Bar06] P. Barbedor. *Analyse en composantes indépendantes par ondelettes*. Thèse de doctorat, Université Paris7, Décembre 2006.
- [BK98] J. Bennett et A. Khotanzad. Multispectral random field models for synthesis and analysis of color images. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(3) :327–332, 1998.
- [Bla06] A. Blansché. *Classification non supervisée avec pondération d’attributs par des méthodes évolutionnaires*. Thèse de doctorat, Université Louis Pasteur de Strasbourg, Septembre 2006.
- [Bou98] M. Bouayad. *Prétopologie et reconnaissance de formes*. Thèse de doctorat, Institut National des Sciences Appliquées de Lyon, Décembre 1998.
- [BR04] E.L. Van Den Broek et E.M. Van Rikxoort. Evaluation of color representation for texture analysis. In *Proceedings of the Belgium-Dutch Conference on Artificial Intelligence*, pages 35–42, 2004.
- [BSC09] V. Bombardier, E. Schmitt, et P. Charpentier. A fuzzy sensor for color matching vision system. *Measurement*, 42(2) :189–201, 2009.

- [BSP00] T.F. Burks, S.A. Shearer, et F.A. Payne. Classification of weed species using color texture features and discriminant analysis. *Transactions of the American Society of Agricultural Engineers*, 43(2) :441–448, 2000.
- [Bus06] L. Busin. *Sélection automatique d'espaces couleur pour la segmentation d'images. Application au contrôle qualité de motifs de verres sérigraphiés*. Thèse de doctorat, Université des Sciences et Technologies de Lille, Décembre 2006.
- [BVM08a] L. Busin, N. Vandenbroucke, et L. Macaire. Color spaces and image segmentation. *Advances in Imaging and Electron Physics*, 151(2) :65–168, 2008.
- [BVM08b] L. Busin, N. Vandenbroucke, et L. Macaire. Contrôle d'aspect par vision linéaire couleur. *Techniques de l'ingénieur*, S7603 :1–16, 2008.
- [BVMP05] L. Busin, N. Vandenbroucke, L. Macaire, et J.G. Postaire. Colour space selection for unsupervised colour image segmentation by analysis of connectedness properties. *International Journal of Robotics and Automation*, 20(2) :70–77, 2005.
- [BVV99] R. Baldrich, M. Vanrell, et J.J. Villanueva. Texture-color features for tile classification. In *Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series*, volume 3826, pages 124–135, 1999.
- [BW00] D. Bell et H. Wang. A formalism for relevance and its application in feature subset selection. *Machine Learning*, 41(2) :175–195, 2000.
- [BZ97] M. Bardos et W.H. Zhu. Comparaison de l'analyse discriminante linéaire et des réseaux de neurones. Application à la détection de défaillance d'entreprises. *Revue de Statistique Appliquée*, 45(4) :65–92, 1997.
- [Cas96] P. Casin. L'analyse en composantes principales généralisée. *Revue de Statistique Appliquée*, 44(3) :63–81, 1996.
- [CC03] D. Casasent et X.W. Chen. Waveband selection for hyperspectral data : optimal feature selection. In *Proceedings of Society of Photographic Instrumentation Engineers*, volume 5106, pages 259–270, 2003.
- [CCFM04] A.S. Capelle, O. Colot, et C. Fernandez-Maloigne. Evidential segmentation scheme of multi-echo mr images for the detection of brain tumors using neighborhood information. *Information Fusion*, 5(3) :203–216, 2004.
- [CCFM06] A.S. Capelle, O. Colot, et C. Fernandez-Maloigne. TBM for color image processing : a quantization algorithm. In *Proceedings of the 9th International Conference on Information Fusion - Fusion 2006*, pages 1–7, 2006.
- [CGGC08] F. Cointault, D. Guérin, J.P. Guillemain, et B. Chopinet. In-field triticum aestivum ear counting using colour-texture image analysis. *New Zealand Journal of Crop and Horticultural Science*, 36 :117–130, 2008.
- [Che03] X.W. Chen. An improved branch and bound algorithm for feature selection. *Pattern Recognition Letters*, 24(12) :1925–1933, 2003.

- [CKU⁺07] M. Celebi, H. Kingravi, B. Uddin, H. Iyatomi, Y. Aslandogan, W. Stoecker, et R. Moss. A methodological approach to the classification of dermoscopy images. *Computerized Medical Imaging and Graphics*, 31(6) :362–373, 2007.
- [CLL07] C. Charrier, G. Lebrun, et O. Lézoray. Evidential segmentation of microscopic color images with pixel classification posterior probabilities. *Journal of Multimedia*, 2(3) :57–65, 2007.
- [Cos01] J.P. Da Costa. *Analyse statistique de textures directionnelles. Application à la caractérisation de matériaux composites*. Thèse de doctorat, Université de Bordeaux, 2001.
- [Cou98] F. De Coulon. *Traité d'électricité (volume VI) : Théorie et traitement des signaux*. Presses Polytechniques et Universitaires Romandes, 1998.
- [CP95] J.P. Cocquerez et S. Philipp. *Analyse d'images : filtrage et segmentation*. Editions Masson, 1995.
- [CRFM01] P. Carré, N. Richard, et C. Fernandez-Maloigne. *Analyse et caractérisation des signaux bidimensionnels*, chapter Représentation en ondelettes. *Traité I2C*, Hermès, Juin 2001.
- [CSD05] S. Chindaro, K. Sirlantzis, et F. Deravi. Texture classification system using colour space fusion. *Electronics Letters*, 41(10) :589–590, 2005.
- [CSF06] S. Chindaro, K. Sirlantzis, et M.C. Fairhurst. ICA-based multi-colour space texture classification system. *Electronics Letters*, 42(21) :1208–1210, 2006.
- [CT91] T. Cover et J. Thomas. *Elements of information theory*. Wiley-Interscience, 1991.
- [Das01] S. Das. Filters wrappers and a boosting-based hybrid for feature selection. In *Proceedings of the 8th International Conference on Machine Learning (ICML'01)*, pages 74–81, 2001.
- [DCFM07] P. Denis, P. Carré, et C. Fernandez-Maloigne. Spatial and spectral quaternionic approaches for colour images. *Computer Vision and Image Understanding*, 107 :74–87, 2007.
- [DL97] M. Dash et H. Liu. Feature selection for classification. *Intelligent Data Analysis*, 1(3) :131–156, 1997.
- [DLM00] M. Dash, H. Liu, et H. Motoda. Consistency based feature selection. In *Proceedings of the 4th International Conference on Knowledge Discovery and Data Mining*, pages 98–109, 2000.
- [DLPT82] E. Diday, J. Lemaire, J. Pouget, et F. Testu. *Éléments d'analyse de données*. Editions Dunod, 1982.
- [Doa92] J. Doak. An evaluation of feature selection methods and their application to computer security. Technical Report CSE-92-18, Davis, University of California, Department of Computer Science, 1992.

- [DW01] A. Drimbarean et P.F. Whelan. Experiments in colour texture analysis. *Pattern Recognition Letters*, 22(10) :1161–1167, 2001.
- [dWLS97] G. Van de Wouwer, S. Livens, P. Scheunders, et D. Van Dyck. Color texture classification by wavelet energy correlation signatures. In *Proceedings of the 9th International Conference on Image Analysis and Processing (ICIAP'97)*, volume 1, pages 327–334. Springer-Verlag, 1997.
- [dWLS99] G. Van de Wouwer, P. Scheunders, S. Livens, et D. Van Dyck. Wavelet correlation signatures for color texture characterization. *Pattern Recognition*, 32 :443–451, 1999.
- [Fau76] O.D. Faugeras. *Digital color image processing and psychophysics within the framework of a human visual model*. Ph.d. thesis, University of Utah, Juin 1976.
- [FGDT04] I. Foucherot, P. Gouton, J.C. Devaux, et F. Truchetet. New methods for analysing colour texture based on the karhunen-loeve transform and quantification. *Pattern Recognition*, 37(8) :1661–1674, 2004.
- [FPHK94] F.J. Ferri, P. Pudil, M. Hatef, et J. Kittler. Comparative study of techniques for large-scale feature selection. *Pattern Recognition in Practice IV*, pages 403–413, 1994.
- [Fuk90] K. Fukunaga. *Introduction to statistical pattern recognition*. Academic Press, 1990.
- [Gal75] M.M. Galloway. Texture analysis using gray level run lengths. *Computer Graphics and Image Processing*, 4 :172–179, 1975.
- [Gar79] C. Garbay. *Modélisation de la couleur dans le cadre de l'analyse d'images et de son application à la cytologie automatique*. Thèse de doctorat, Institut National Polytechnique de Grenoble, Décembre 1979.
- [GCGG04] D. Guérin, F. Cointault, C. Gee, et J.P. Guillemin. Etude de faisabilité d'un système de comptage d'épis de blé par vision. *Traitement du Signal*, 21(5) :549–560, 2004.
- [GE03] I. Guyon et A. Elisseeff. An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3 :1157–1182, 2003.
- [GGNZ06] I. Guyon, S.R. Gunn, M. Nikravesh, et L. Zadeh. *Feature extraction, foundations and applications*. Editions Springer-Verlag, 2006.
- [GK03] Z. Ghahramani et H. Kim. Bayesian classifier combination. Technical report, Gatsby, 2003.
- [Gol89] David E. Goldberg. *Genetic algorithms in search optimization and machine learning*. Addison-Wesley Editions, 1989.
- [Han02] A. Hanbury. *Morphologie mathématique sur le cercle unité avec applications aux teintes et aux textures orientées*. Thèse de doctorat, Ecole Nationale Supérieure des Mines de Paris, 2002.

- [HCG⁺05] O.J. Hernandez, J. Cook, M. Griffin, C. De Rama, et M. McGovern. Classification of color textures with random field models and neural networks. *Journal of Computer Science & Technology*, 5(3) :150–157, 2005.
- [Her99] S. Herlidou. *Caractérisation tissulaire en IRM par l'analyse de texture : Etude du tissu musculaire et de tumeurs intracrâniennes*. Thèse de doctorat, Université de Rennes 1, 1999.
- [HK04] O.J. Hernandez et A. Khotanzad. Color image segmentation using multispectral random field texture model and color content features. *Journal of Computer Science & Technology*, 4(3) :141–146, 2004.
- [Hol75] J.H. Holland. *Adaptation in natural and artificial systems*. Ann Arbor, The University of Michigan Press, 1975.
- [HSD73] R. Haralick, K. Shanmugan, et I. Dinstein. Textural features for image classification. *IEEE Transactions on Systems, Man and Cybernetics*, 3(6) :610–621, 1973.
- [HSP06] P.S. Hiremath, S. Shivashankar, et J. Pujari. Wavelet based features for color texture classification with application to CBIR. *International Journal of Computer Science and Network Security (IJCSNS)*, 6(9) :124–133, 2006.
- [HTD09] J. Hua, W.D. Tembe, et E.R. Dougherty. Performance of feature-selection methods in the classification of high-dimension data. *Pattern Recognition*, 42(3) :409–424, 2009.
- [HW98] W.J. Hwang et K.W. Wen. Fast kNN classification algorithm based on partial distance search. *Electronics Letters*, 34(21) :2062–2063, 1998.
- [IMK⁺04] D.K. Iakovidis, D.E. Maroulis, S.A. Karkanis, P. Papageorgas, et M. Tzivras. Texture multichannel measurements for cancer precursors' identification using support vector machines. *Measurement*, 36 :297–313, 2004.
- [IMK05] D. Iakovidis, D. Maroulis, et S. Karkanis. A comparative study of color-texture image features. In *Proceedings of 12th International Workshop on Systems, Signals & Image Processing (IWSSIP'05)*, pages 203–207, Chalkida, Greece, 2005.
- [JDM00] A.K. Jain, R.P.W. Duin, et J. Mao. Statistical pattern recognition : A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(1) :4–37, 2000.
- [JG07] G.W. Jiji et L. Ganesan. Comparative analysis of colour models for colour textures based on feature extraction. *International Journal of Soft Computing*, 2(3) :361–366, 2007.
- [JMF99] A.K. Jain, M.N. Murty, et P.J. Flynn. Data clustering : a review. *ACM Computing Surveys*, 31(3) :264–323, 1999.
- [Jul81] B. Julesz. Textons, the elements of texture perception and their interactions. *Nature*, 290 :91–97, 1981.

- [JZ97] A. Jain et D. Zongker. Feature selection : evaluation, application and small sample performance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(2) :153–158, 1997.
- [KH06] A. Khotanzad et O.J. Hernandez. A classification methodology for color textures using multispectral random field mathematical models. *Mathematical and Computational Applications*, 11(2) :111–120, 2006.
- [KIM⁺03] S.A. Karkanis, D.K. Iakovidis, D.E. Maroulis, D.A. Karras, et M. Tzivras. Computer-aided tumor detection in endoscopic video using color wavelet features. *IEEE Transactions on Information Technology in Biomedicine*, 7(3) :141–152, 2003.
- [Kle08] J. Klein. *Suivi robuste d'objets dans les séquences d'images par fusion de sources. Application au suivi de véhicules dans les scènes routières*. Thèse de doctorat, Université de Rouen, 2008.
- [Kon94] I. Kononenko. Estimating attributes : Analysis and extensions of relief. In *European Conference on Machine Learning*, pages 171–182, 1994.
- [KP00] J. Kyllönen et M. Pietikäinen. Visual inspection of parquet slabs by combining color and texture. In *Proceedings of the IAPR Workshop on Machine Vision Applications (MVA'00)*, pages 187–192, Tokyo, Japan, 2000.
- [KR92] K. Kira et L.A. Rendell. The feature selection problem : Traditional methods and a new algorithm. In *Proceedings of the 9th National Conference on Artificial Intelligence*, pages 129–134, 1992.
- [KS96] D. Koller et M. Sahami. Toward optimal feature selection. In *Proceedings of the International Conference on Machine Learning*, pages 129–134, 1996.
- [KS00] M. Kudo et J. Sklansky. Comparaison of algorithms that select features for pattern classifiers. *Pattern Recognition*, 33(1) :25–41, 2000.
- [Lak] R. Lakmann. Base d'images couleur texturées Barktex. Université Koblenz-Landau, [ftp ://ftphost.uni-koblenz.de/outgoing/vision/Lakmann/BarkTex](ftp://ftphost.uni-koblenz.de/outgoing/vision/Lakmann/BarkTex).
- [Lak02] R. Lakmann. Textural features in multi-channel color images. In *Proceedings of the 5th Asian Conference on Computer Vision (ACCV2002)*, pages 199–204, Melbourne, Australia, 2002.
- [LCWE06] T. Lal, O. Chapelle, J. Weston, et A. Elisseeff. *Embedded methods*, pages 137–165. Editions Springer-Verlag, 2006.
- [Lia87] L. Liang. *Contribution à la segmentation chromatique des images. Application à l'identification d'objets colorés*. Thèse de doctorat, Institut National Polytechnique de Toulouse, Juillet 1987.
- [LKV05] L. Lepistö, I. Kunttu, et A. Visa. Rock image classification using color features in gabor space. *Journal of Electronic Imaging*, 14(4) :1–3, 2005.

- [LM68] P. Lachenbruch et M. Mickey. Estimation of error rates in discriminant analysis. *Technometrics*, 10(1) :1–11, 1968.
- [LM98] H. Liu et H. Motoda. *Feature extraction construction and selection : a data mining perspective*. Kluwer Academic Publishers, 1998.
- [LVPF08] F. Lopez, J.M. Valiente, J.M. Prats, et A. Ferrer. Performance evaluation of soft color texture descriptors for surface grading using experimental design and logistic regression. *Pattern Recognition*, 41(5) :1761–1772, 2008.
- [Léz00] O. Lézoray. *Segmentation d'images couleur par morphologie mathématique et classification de données par réseaux de neurones : application à la classification de cellules en cytologie des séreuses*. Thèse de doctorat, Université de Caen, Janvier 2000.
- [MALDTB05] J. Martinez-Alajarin, J.D. Luis-Delgado, et L.M. Tomas-Balibrea. Automatic system for quality-based classification of marble textures. *IEEE Transactions on Systems, Man and Cybernetics*, 35(4) :488–497, 2005.
- [Mav01] S. Mavromatis. *Analyse de texture et visualisation scientifique*. Thèse de doctorat, Université de la méditerranée, 2001.
- [MBF97] J.A. Penaranda Marques, L. Briones, et J. Florez. Color machine vision system for process control in ceramics industry. In *Society of Photo-Optical Instrumentation Engineers (SPIE) Conference Series*, volume 3101, pages 182–192, 1997.
- [MBN02] L.C. Molina, L. Belanche, et A. Nebot. Feature selection algorithms : a survey and experimental evaluation. In *Proceedings of IEEE International Conference on Data Mining (ICDM)*, pages 306–313, 2002.
- [MCB06] D. Martins, R. Cesar, et J. Barrera. W-operator window design by minimization of mean conditional entropy. *Pattern Analysis and Applications*, 9 :139–153, 2006.
- [MMK⁺99] G.E. Meyer, T. Mehta, M.F. Kocher, D.A. Mortensen, et A. Samal. Textural imaging and discriminant analysis for distinguishing weeds for spot spraying. *Transactions of the American Society of Agricultural Engineers*, 41(4) :1189–1197, 1999.
- [MP04] T. Mäenpää et M. Pietikäinen. Classification with color and texture : jointly or separately ? *Pattern Recognition*, 37(8) :1629–1640, 2004.
- [Mus05] D. Muselet. *Reconnaissance automatique d'objets sous éclairage non contrôlé par analyse d'images couleur*. Thèse de doctorat, Université des Sciences et Technologies de Lille, Juillet 2005.
- [MVK⁺02] C. Münzenmayer, H. Volk, C. Küblbeck, K. Spinnler, et T. Wittenberg. Multispectral texture analysis using interplane sum- and difference-histograms. In *German Association for Pattern Recognition Symposium*, pages 42–49. Editions Springer-Verlag, 2002.

- [MVP03] T. Mäenpää, J. Viertola, et M. Pietikäinen. Optimising colour and texture features for real-time visual inspection. *Pattern Analysis and Applications*, 6(3) :169–175, 2003.
- [MWHW05] C. Münzenmayer, S. Wilharm, J. Hornegger, et T. Wittenberg. Illumination invariant color texture analysis based on sum- and difference-histograms. In *German Association for Pattern Recognition Symposium*, pages 17–24. Editions Springer-Verlag, 2005.
- [NC03] J.-P. Nakache et J. Confais. *Statistique explicative appliquée, analyse discriminante, modèle logistique, segmentation par arbre*. Editions Technip, 2003.
- [NC07] S. Nakariyakul et D.P. Casasent. Adaptive branch and bound algorithm for selecting optimal features. *Pattern Recognition Letters*, 28(12) :1415–1427, 2007.
- [NF77] P. Narendra et K. Fukunaga. A branch and bound algorithm for feature subset selection. *IEEE Transactions on Computers*, 26(9) :917–922, 1977.
- [OKS80] Y.I. Ohta, T. Kanade, et T. Sakai. Color information for region segmentation. *Computer Graphics and Image Processing*, 13 :222–241, 1980.
- [OMP⁺02] T. Ojala, T. Mäenpää, M. Pietikäinen, J. Viertola, J. Kyllönen, et S. Huovinen. Outex new framework for empirical evaluation of texture analysis algorithms. In *Proceedings of the 16th International Conference on Pattern Recognition*, volume 1, pages 701–706, 2002.
- [OPH96] T. Ojala, M. Pietikäinen, et D. Harwood. A comparative study of texture measures with classification based on feature distributions. *Pattern Recognition*, 29(1) :51–59, 1996.
- [OPR78] R. Ohlander, K. Price, et D.R. Reddy. Picture segmentation using a recursive region splitting method. *Computer Graphics and Image Processing*, 8 :313–333, 1978.
- [Pal04] C. Palm. Color texture classification by integrative co-occurrence matrices. *Pattern Recognition*, 37(5) :965–976, 2004.
- [Paq03] S. Paquis. *Reconnaissance des surfaces de chaussée par analyse de texture image*. Thèse de doctorat, Université Jean Monnet de Saint-Étienne, Juin 2003.
- [Pas98] G. Paschos. Chromatic correlation features for texture recognition. *Pattern Recognition Letters*, 19 :643–650, 1998.
- [Pas00] G. Paschos. Fast color texture recognition using chromaticity moments. *Pattern Recognition Letters*, 21(9) :837–841, 2000.
- [PBL06] R. Pydipati, T.F. Burks, et W.S. Lee. Identification of citrus disease using color texture features and discriminant analysis. *Computers and Electronics in Agriculture*, 52 :49–59, 2006.

- [PFJ06] H. Permuter, J. Francos, et I. Jermyn. A study of gaussian mixture models of color and texture features for image classification and segmentation. *Pattern Recognition*, 39 :695–706, 2006.
- [PGM⁺] R. Picard, C. Graczyk, S. Mann, J. Wachman, L. Picard, et L. Campbell. Base d'images couleur texturées Vistex. Media Laboratory, Massachusetts Institute of Technology (MIT), Cambridge, <http://vis-mod.media.mit.edu/pub/VisTex/VisTex.tar.gz>.
- [PKLS00] C. Palm, D. Keysers, T.M. Lehmann, et K. Spitzer. Gabor filtering of complex hue saturation images for color texture classification. In *Proceedings of the 5th Joint Conference on Information Science*, pages 45–49, 2000.
- [PL02] C. Palm et T.M. Lehmann. Classification of color textures by gabor filtering. *Machine Graphics and Vision International Journal*, 11(2) :195–219, 2002.
- [PMV02] M. Pietikäinen, T. Mäenpää, et J. Viertola. Color texture classification with color histograms and local binary patterns. In *Proceedings of the 2nd International Workshop on Texture Analysis and Synthesis*, pages 109–112, 2002.
- [PNK94] P. Pudil, J. Novovicova, et J. Kittler. Floating search methods in feature selection. *Pattern Recognition Letters*, 15 :1119–1125, 1994.
- [PP03] G. Paschos et M. Petrou. Histogram ratio features for color texture classification. *Pattern Recognition Letters*, 24(3) :309–314, 2003.
- [PPL97] S. Della Pietra, V.J. Della Pietra, et J.D. Lafferty. Inducing features of random fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 19(4) :380–393, 1997.
- [PS04] W. Polzleitner et G. Schwinghagl. Real-time color-based texture analysis for sophisticated defect detection on wooden surfaces. *Intelligent Robotics and Computer Vision XXII : Algorithms, Techniques and Active Vision*, 5608 :54–69, 2004.
- [PVM07a] A. Porebski, N. Vandenbroucke, et L. Macaire. Iterative feature selection for color texture classification. In *Proceedings of the 14th IEEE International Conference on Image Processing (ICIP'07)*, volume 3, pages 509–512, San Antonio, Texas, USA, 2007.
- [PVM07b] A. Porebski, N. Vandenbroucke, et L. Macaire. Sélection automatique d'attributs pour la classification de textures couleur. In *Proceedings du onzième congrès francophone des jeunes chercheurs en vision par ordinateur (ORASIS'07)*, Obernai, France, 2007.
- [PVM08a] A. Porebski, N. Vandenbroucke, et L. Macaire. Haralick feature extraction from LBP images for color texture classification. In *Proceedings of the first IEEE International Workshops Image Processing Theory, Tools & Applications (IPTA'08)*, pages 1–8, Sousse, Tunisia, 2008.

- [PVM08b] A. Porebski, N. Vandenbroucke, et L. Macaire. Neighborhood and haralick feature extraction for color texture analysis. In *Proceedings of the 4th European Conference on Colour in Graphics, Imaging and Vision (CGIV'08)*, pages 316–321, Terrassa - Barcelona, Spain, 2008.
- [PVM09] A. Porebski, N. Vandenbroucke, et L. Macaire. Attributs de texture couleur. In *École d'Hiver sur l'Imagerie Numérique Couleur (EHINC'09)*, pages 95–108, Toulon, 2009. Fred Valou Editions.
- [QABFM09] I.U.H. Qazi, O. Alata, J.C. Burie, et C. Fernandez-Maloigne. Colour spectral analysis for spatial structure characterization of textures in IHLS colour space. *Pattern Recognition*, 2009.
- [Rik04] E.M. Van Rikxoort. Texture analysis. Technical report, Radboud University Nijmegen, 2004.
- [RM05] C. Rivero-Moreno. *Contribution à la caractérisation des images par transformée polynomiale : Application à l'indexation des images et des vidéos*. Thèse de doctorat, Institut National des Sciences Appliquées de Lyon, 2005.
- [Roj96] R. Rojas. *Neural networks : a systematic introduction*. Editions Springer-Verlag, 1996.
- [Rom73] J.-M. Romeder. *Méthodes et programmes d'analyse discriminante*. Editions Dunod, 1973.
- [RR04] K.M. Rajpoot et N.M. Rajpoot. Wavelets and support vector machines for texture classification. In *Proceedings of 8th International Multitopic Conference*, pages 328–333, 2004.
- [Saa08] T. Saadi. *Résolution séquentielle et parallèle des problèmes de découpe/placement*. Thèse de doctorat, Université de Paris 1, 2008.
- [San05] C. Castellanos Sanchez. *Modèle connexionniste neuromimétique pour la perception visuelle embarquée du mouvement*. Thèse de doctorat, Université Henri Poincaré Nancy 1, Octobre 2005.
- [Sap06] G. Saporta. *Probabilités, analyse des données et statistique*. Editions TECHNIP, 2006.
- [SDDO03] H. Stoppiglia, G. Dreyfus, R. Dubois, et Y. Oussar. Ranking a random feature for variable and feature selection. *Journal of Machine Learning Research*, 3 :1399–1414, 2003.
- [Sem04] D. Semani. *Une méthode supervisée de sélection et de discrimination avec rejet. Application au projet Aquathèque*. Thèse de doctorat, Université de La Rochelle, Mai 2004.
- [Sen08] A. Sengur. Wavelet transform and adaptive neuro-fuzzy inference system for color texture classification. *Expert Systems with Applications*, 34(3) :2120–2128, 2008.

- [SFC04] D. Semani, C. Frélicot, et P. Courtellemont. Combinaison d'étiquettes floues/possibilistes pour la sélection de variables. In *14ième Congrès Francophone de Reconnaissance des Formes et Intelligence Artificielle, RFIA'04*, volume 2, pages 479–488, Toulouse, 2004.
- [SH94] A.C. She et T.S. Huang. Segmentation of road scenes using color and fractal-based texture classification. In *IEEE International Conference on Image Processing (ICIP'94)*, volume 3, pages 1026–1030, 1994.
- [SH99] P.H. Suen et G. Healey. Modeling and classifying color textures using random fields in a random environment. *Pattern Recognition*, 32(6) :1009–1017, 1999.
- [Sha48] C. Shannon. A mathematical theory of communication. *Bell System Technical Journal*, 27(3) :379–423, 1948.
- [Sha01] M. Sharma. *Evaluation of image segmentation and texture extraction methods in scene analysis*. Ph.d. thesis, University of Exeter, January 2001.
- [SHE07] H.M. Sahbani, K. Hamrouni, et N. Ellouze. Identification de texture par fusion d'attributs multi-résolutionnels et invariants à la rotation. In *Proceedings of the 4th International Conference : Sciences of Electronic, Technologies of Information and Telecommunications (SETIT'07)*, Tunisie, 2007.
- [Shi95] T.Y. Shih. The reversibility of six geometric color spaces. *Photogrammetric Engineering and Remote Sensing*, 61(10) :1223–1232, 1995.
- [Sk178] J. Sklansky. Image segmentation and feature extraction. *IEEE Transactions on Systems, Man and Cybernetics*, 8 :237–247, 1978.
- [SKR09] J. Schenk, M. Kaiser, et G. Rigoll. Selecting features in on-line handwritten whiteboard note recognition : SFS or SFFS ? In *Proceedings of the 10th International Conference on Document Analysis and Recognition, ICDAR 2009*, pages 1251–1254, Barcelona, Spain, 2009. IEEE.
- [SMP00] M. Skrzypniak, L. Macaire, et J-G. Postaire. Indexation d'images de personnes par analyse de matrices de co-occurrences couleur. In *Journées d'études et d'échanges sur la compression et représentation des signaux audiovisuels, CO-RESA2000*, 2000.
- [SPK04] P. Somol, P. Pudil, et J. Kittler. Fast branch & bound algorithms for optimal feature selection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 26(7) :900–912, 2004.
- [SS01] M. Sharma et S. Singh. Evaluation of texture methods for image analysis. In *Proceedings of the 7th Australian and New Zealand Intelligent Information Systems Conference*, pages 117–121, 2001.
- [Tes04] C. Tessier. *Détection de type de sol par analyse de texture pour le guidage de véhicules*. Mémoire de master, Université Blaise Pascal de Clermont-Ferrand, Septembre 2004.

- [Tex] Base d'images couleur texturées. <http://textures.forrest.cz>.
- [TFMB04] A. Trémeau, C. Fernandez-Maloigne, et P. Bonton. *Image numérique couleur. De l'acquisition au traitement*. Editions Dunod, 2004.
- [TGE03] K. Torkkola, I. Guyon, et A. Elisseeff. Feature extraction by non-parametric mutual information maximization. *Journal of Machine Learning Research*, 3 :1415–1438, 2003.
- [TJ98] M. Tuceryan et A. K. Jain. Texture analysis. In *The Handbook of Pattern Recognition and Computer Vision*, pages 207–248. Editions World Scientific Publishing Co., 1998.
- [TMY78] H. Tamura, S. Mori, et Y. Yamawaki. Textural features corresponding to visual perception. *IEEE Transactions on Systems, Man and Cybernetics*, 8 :460–473, 1978.
- [TTC01] V.G. Tusher, R. Tibshirani, et G. Chu. Significance analysis of microarrays applied to the ionizing radiation response. *Proceedings of the National Academy of Sciences (PNAS)*, 98 :5116–5121, 2001.
- [TTS⁺05] Q.L. Tran, K.A. Toh, D. Srinivasan, K.L. Wong, et Q.C. Low Shaun. An empirical comparison of nine pattern classifiers. *IEEE Transactions on Systems, Man and Cybernetics*, 35(5) :1079–1091, 2005.
- [TTSR99] L. Tang, L.F. Tian, B.L. Steward, et J.F. Reid. Texture-based weed classification using gabor wavelets and neural network for real-time selective herbicide applications. *Transactions of the American Society of Agricultural Engineers*, (99-3036), 1999.
- [Uns86] M. Unser. Sum and difference histogram for texture classification. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 8(1) :118–125, 1986.
- [Van00] N. Vandenbroucke. *Segmentation d'images couleur par classification de pixels dans des espaces d'attributs colorimétriques adaptés. Application à l'analyse d'images de football*. Thèse de doctorat, Université des Sciences et Technologies de Lille, Décembre 2000.
- [Vap95] V.N. Vapnik. *The nature of statistical learning theory*. Editions Springer-Verlag, 1995.
- [VB00] C. Vertan et N. Boujemaa. Color texture classification by normalized color space representation. In *Proceedings of the International Conference on Pattern Recognition (ICPR'00)*, 2000.
- [VCBFM02] C. Vertan, M. Ciuc, V. Buzuloiu, et C. Fernandez-Maloigne. Compact color-texture run-length description for ornamental stones recognition and indexing. *The hyperion scientific Journal*, 3A(1) :79–86, 2002.
- [VLC03] P. Vannoorenberghe, E. Lefevre, et O. Colot. Traitement d'images et théorie des fonctions de croyance. In *Actes des XII^{èmes} Rencontres Francophones sur la Logique Floue et ses Applications - LFA'03*, pages 287–294, Tours, 2003.

- [VM05] N. Vandenbroucke et L. Macaire. Représentation de la couleur en analyse d'images. *Techniques de l'ingénieur*, S7602 :1–21, 2005.
- [VMP00a] N. Vandenbroucke, L. Macaire, et J.-G. Postaire. Color systems coding for color image processing. In *International Conference on Color in Graphics and Image Processing*, volume 1, pages 180–185, Saint-Etienne, 2000.
- [VMP00b] N. Vandenbroucke, L. Macaire, et J.G. Postaire. Color image segmentation by supervised pixel classification in a color texture feature space. application to soccer image segmentation. *15th International Conference on Pattern Recognition (ICPR'00)*, 3 :3625, 2000.
- [VMP03] N. Vandenbroucke, L. Macaire, et J.G. Postaire. Color image segmentation by pixel classification in an adapted hybrid color space. application to soccer image analysis. *Computer Vision and Image Understanding*, 90 :190–216, 2003.
- [WD09] A. Wagnon et F. Dobin. *Création d'une bibliothèque de fonctions pour la simulation de défauts*. Rapport de projet informatique, Ecole d'Ingénieurs du Pas-de-Calais (EIPC), 2009.
- [WW99] J. Weston et C. Watkins. Support vector machines for multiclass pattern recognition. In *Proceedings of the 7th European Symposium On Artificial Neural Networks*, 1999.
- [XM07] X. Xie et M. Mirmehdi. Texems : Texture exemplars for defect detection on random textured surfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 29(8) :1454–1464, 2007.
- [XWZ⁺08] W. Xu, M. Wang, X. Zhang, L. Wang, et H. Feng. SDED : A novel filter method for cancer-related gene selection. *Bioinformatics*, 2(7) :301–303, 2008.
- [XYD05] Q. Xu, J. Yang, et S. Ding. Color texture analysis using the wavelet-based hidden markov model. *Pattern Recognition Letters*, 26 :1710–1719, 2005.
- [YL03] L. Yu et H. Liu. Feature selection for high-dimensional data : a fast correlation-based filter solution. In *Proceedings of the 20th International Conference on Machine Learning (ICML'03)*, pages 856–863, 2003.
- [ZC06] K. Zhang et L.-W. Chan. ICA by PCA approach : relating higher-order statistics to second-order moments. In *Independent Component Analysis and Blind Signal Separation*, volume 3889, pages 311–318, 2006.
- [Zen86] S. Di Zenzo. A note on the gradient of a multi-image. *Computer Vision, Graphics and Image Processing (CVGIP)*, 33 :116–125, 1986.
- [ZOD07] Z. Zhu, Y.S. Ong, et M. Dash. Wrapper-filter feature selection algorithm using a memetic framework. *IEEE Transactions on Systems, Man and Cybernetics*, 37(1) :70–76, 2007.
- [ZSZ07] C. Zheng, D.W. Sun, et L. Zheng. A new region-primitive method for classification of colour meat image texture based on size, orientation and contrast. *Meat Science*, 76(4) :620–627, 2007.

Table des figures

I.1	Verre décoré par sérigraphie.	20
I.2	Image du décor du verre de la figure I.1 : le cadre cyan montre une zone d'analyse de couleur homogène, tandis que le cadre orange, une zone de texture couleur.	20
I.3	La classification supervisée.	21
1.1	Exemples de textures.	28
1.2	Illustration des approches microscopique et macroscopique de la texture.	29
1.3	Illustration d'une texture orientée (image de taille 256×384 extraite de la base BarkTex).	30
1.4	Le pixel encadré en blanc dont les composantes couleur sont C_1 , C_2 et C_3 donne naissance à un point C dans l'espace (C_1, C_2, C_3)	31
1.5	Les couleurs des pixels de l'image donnent naissance à des nuages de points dans l'espace (C_1, C_2, C_3)	32
1.6	Caractérisation de la texture couleur par des attributs de texture extraits de l'image de luminance et des attributs caractérisant la distribution des couleurs dans l'espace (C_1, C_2, C_3)	33
1.7	Caractérisation de la texture couleur par des attributs de texture couleur qui ne tiennent compte que des relations intra-composantes dans l'espace (C_1, C_2, C_3)	34
1.8	Caractérisation de la texture couleur par des attributs de texture couleur qui tiennent compte à la fois des relations intra et inter-composantes dans l'espace (C_1, C_2, C_3)	34
1.9	Exemple d'images de taille 128×128 extraites de la base VisTex.	36
1.10	Exemple d'images de taille 128×192 extraites de la base BarkTex.	37
1.11	Exemples d'images de la base BarkTex appartenant à deux classes différentes mais qui semblent visuellement très proches.	38
1.12	Exemple d'une image de la base BarkTex où sont représentées deux textures (fond et écorce).	38
1.13	Exemple d'images de la base BarkTex acquises avec des conditions d'éclairage différentes.	39
1.14	Image de taille 746×538 contenant la texture d'un plastique acquise avec un éclairage du type "soleil à l'horizon", une résolution de 100 dpi et un angle de rotation de 0°	40

1.15	Images représentant la même texture que la figure 1.14 acquise avec différentes conditions d'éclairage, différentes résolutions et différents angles de rotation de la texture autour de l'axe optique de la caméra.	41
1.16	Le 8-voisinage et les cliques associées.	43
1.17	Illustration du calcul de $LBP[P]^{C_1, C_1}$, $LBP[P]^{C_1, C_2}$ et $LBP[P]^{C_2, C_1}$ pour un pixel couleur P codé dans l'espace (C_1, C_2, C_3) avec $N = 8$	45
1.18	Exemples de voisinages utilisés pour le calcul des LBP.	46
1.19	Les 4 directions considérées.	52
1.20	Illustration de la distance ν	53
1.21	Image couleur \mathbf{I} et ses matrices de co-occurrences associées ($N = 4$).	54
1.22	Illustration pour une distance $\nu = 1$ des différents voisinages considérés lors du calcul des matrices de co-occurrences.	61
1.23	Image couleur \mathbf{I} et les histogrammes des sommes et des différences associés ($N = 4$).	63
1.24	Image couleur \mathbf{I} et ses matrices de longueur de plages $\mathcal{P}^{C_1}[\mathbf{I}](0^\circ)$ et $\mathcal{P}^{C_1}[\mathbf{I}](45^\circ)$ associées ($N = 4$).	68
2.1	La classification supervisée d'images.	74
2.2	Représentation de points-image provenant de quatre classes différentes dans un espace d'attributs de dimension 2.	75
2.3	Illustration de la non pertinence et de la redondance d'un attribut.	76
2.4	Illustration du principe de l'ACP.	77
2.5	Illustration de la procédure de sélection d'attributs avec étape de validation.	81
2.6	Partie de l'arbre de décision "Branch and Bound" pour le problème de la sélection de $\hat{d} = 2$ attributs parmi $D = 6$	83
2.7	Illustration d'un chromosome.	86
2.8	Algorithme génétique.	86
2.9	Illustration de l'opération de croisement.	87
2.10	Illustration de l'opération de mutation.	87
2.11	Algorithme SFS.	89
2.12	Algorithme "Sequential Forward Floating Selection".	90
2.13	Représentation d'un attribut consistant (attribut 2) et un attribut non consistant (attribut 1).	95
2.14	Illustration d'un sous-espace non discriminant et d'un sous-espace discriminant vis-à-vis d'une mesure de distance.	99
2.15	Structure d'un neurone artificiel.	105
2.16	Perceptron multicouches.	105
2.17	Illustration de la marge maximale et des vecteurs supports qui lui sont associés.	106
2.18	Illustration du traitement des nuages de points correspondant à chaque classe qui ne sont pas linéairement séparables.	107

2.19	Construction des $N_C = 3$ hyperplans pour la classification par la méthode "one-versus-all".	108
2.20	Assignation du score selon la position du point-image par rapport à l'hyperplan distinguant la classe C^1	109
2.21	Classification par la méthode "one-versus-all".	109
2.22	Construction des $\frac{N_C(N_C-1)}{2} = 3$ hyperplans pour la classification par la méthode "one-versus-one".	111
2.23	Illustration de la méthode des k -PPV avec $k = 5$	112
2.24	Illustration de la méthode de classification par affectation au barycentre le plus proche.	113
3.1	Sélection d'attributs de texture couleur pour la classification supervisée d'images.	117
3.2	Les $N_E = 28$ espaces couleur considérés pour caractériser les textures couleur.	124
3.3	Sous-quantification uniforme pour passer de $N = 256$ niveaux à $N = 32$	126
3.4	Sous-quantification uniforme de l'image 3.4(a) dans l'espace couleur (R, G, B)	134
3.5	Sous-quantification uniforme de l'image 3.5(a) dans l'espace couleur (R, G, B)	134
3.6	Illustration du calcul de la moyenne et la variance des 14 attributs d'Haralick selon les quatre directions $\theta = 0^\circ, 45^\circ, 90^\circ, 135^\circ$	136
3.7	Illustration du calcul des attributs d'Haralick extraits des matrices de co-occurrences où le "8-voisinage" est considéré.	136
3.8	Illustration de la modification de la partition de l'espace d'attributs lorsque les images test sont issues de l'ensemble des prototypes.	142
3.9	Illustration de la conservation de la partition de l'espace d'attributs lorsque l'ensemble d'apprentissage et l'ensemble d'images test sont totalement indépendants.	143
4.1	Exemples de textures couleur issues de la base OuTex.	152
4.2	Création de la base d'apprentissage et de la base de test OuTex.	153
4.3	Exemples de textures couleur issues de la base VisTex.	154
4.4	Création de la base d'apprentissage et de la base de test VisTex.	154
4.5	Extraction de 4 imageries d'une des images de la base BarkTex.	155
4.6	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat.	159
4.7	Temps de classification (en secondes) des 680 images test de la base OuTex, en fonction de la dimension d du sous-espace d'attributs candidat.	159
4.8	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat.	161
4.9	Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat.	161
4.10	Illustration de trois textures différentes et de leur histogramme 3D commun.	167

4.11	Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.	167
4.12	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents niveaux de quantification N . .	169
4.13	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents niveaux de quantification N . .	170
4.14	Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents niveaux de quantification N . .	170
4.15	Temps moyen Te (en millisecondes) pour extraire un attribut d'une image OuTex de taille 128×128 , en fonction du niveau de quantification N	171
4.16	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes structures de voisinage considérées lors du calcul des matrices de co-occurrences.	175
4.17	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes distances spatiales considérées lors du calcul des matrices de co-occurrences.	178
4.18	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes procédures de génération. .	179
4.19	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes mesures de distance.	181
4.20	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation de la couleur.	184
4.21	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation de la couleur.	185
4.22	Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation de la couleur.	185
4.23	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.	187
4.24	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.	188
4.25	Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.	188
5.1	Illustration du défaut de "tâché".	194

5.2	Illustration du défaut de "manque".	195
5.3	Illustration du défaut de "décalage".	195
5.4	Illustration du défaut de "nuance".	196
5.5	Principe de fonctionnement du poste d'acquisition.	197
5.6	Poste d'acquisition.	198
5.7	Verre.	199
5.8	Image du verre de la figure 5.7.	199
5.9	Image du verre de la figure 5.7 : le cadre cyan montre une zone d'analyse de couleur homogène, tandis que le cadre orange, une zone de texture couleur.	200
5.10	Exemples d'échantillons de décors "Sprite" avec et sans défaut.	202
5.11	Exemples de défauts de nuance simulés pour les décors "Fanta" et "Sprite".	203
5.12	Exemples de défauts de manque simulés pour les décors "Fanta" et "Sprite".	204
5.13	Illustration d'une partie de la base d'images prototypes "Fanta".	205
5.14	Illustration d'une partie de la base d'images prototypes "Sprite".	205
5.15	Illustration d'une partie des images réelles "Fanta" à classer.	209
5.16	Illustration d'une partie des images réelles "Sprite" à classer.	209
A.1	Cube des couleur.	220
A.2	Diagramme de chromaticité (r_C, g_C) de la CIE.	221
A.3	Diagramme de chromaticité (x, y).	222
A.4	Espace couleur (L^*, a^*, b^*).	223
A.5	Espace de coordonnées polaires.	225
E.1	Temps de classification (en secondes) des 432 images test de taille 128×128 issues de la base VisTex, en fonction de la dimension d du sous-espace d'attributs candidat.	266
E.2	Temps de classification (en secondes) des 816 images test de taille 64×64 issues de la base BarkTex, en fonction de la dimension d du sous-espace d'attributs candidat.	266
E.3	Taux T d'images test OuTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.	267
E.4	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différents modes de caractérisation des textures couleur.	268
E.5	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes structures du voisinage considérées lors du calcul des matrices de co-occurrences.	269
E.6	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes distances spatiales considérées pour calculer les attributs d'Haralick.	270

E.7	Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes distances spatiales considérées pour calculer les attributs d'Haralick.	271
E.8	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes procédures de génération. . .	272
E.9	Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes procédures de génération. . .	273
E.10	Taux T d'images test VisTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes mesures de distance.	274
E.11	Taux T d'images test BarkTex bien classées, en fonction de la dimension d du sous-espace d'attributs candidat, pour différentes mesures de distance.	274

Table des tableaux

2.1	Méthodes de sélection recommandées selon l'objectif visé, la dimension initiale D de l'espace d'attributs et le caractère monotone de la fonction d'évaluation.	92
3.1	Espaces couleur considérés.	123
4.1	Caractéristiques des ensembles d'images issus de la base OuTex, utilisés dans le cadre de la classification d'images de textures couleur.	149
4.2	Caractéristiques des ensembles d'images issus de la base VisTex, utilisés dans le cadre de la classification d'images de textures couleur.	150
4.3	Caractéristiques des ensembles d'images issus de la base BarkTex, utilisés dans le cadre de la classification d'images de textures couleur.	151
4.4	Les trois premiers sous-espaces candidats pour discriminer les textures couleur de la base OuTex.	157
4.5	Méthodes ayant été testées sur l'ensemble d'images OuTex.	163
4.6	Méthodes ayant été testées sur l'ensemble d'images VisTex.	164
4.7	Méthodes ayant été testées sur l'ensemble d'images BarkTex.	164
4.8	Temps de traitement des phases d'apprentissage et de classification.	172
4.9	Taux T d'images BarkTex bien classées en fonction du voisinage considéré lors du calcul des matrices de co-occurrences.	174
4.10	Taux T de bonne classification des images test des bases OuTex, VisTex et BarkTex, obtenus en considérant les sous-espaces d'attributs discriminants de dimension \hat{d} , en fonction du mode de caractérisation de la couleur.	186
4.11	Taux T de bonne classification des images test des bases OuTex, VisTex et BarkTex, obtenus en considérant les sous-espaces d'attributs discriminants de dimension \hat{d} , selon différentes caractérisations des textures couleur.	189
5.1	Les $d_{max} = 10$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base de décors "Fanta".	207
5.2	Les $d_{max} = 10$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base de décors "Sprite".	208
C.1	Récapitulatif des travaux portant sur la classification d'images de texture couleur.	231

C.1	Suite du tableau récapitulatif.	232
C.1	Suite du tableau récapitulatif.	233
C.1	Suite du tableau récapitulatif.	234
C.1	Suite du tableau récapitulatif.	235
C.1	Suite du tableau récapitulatif.	236
C.1	Suite du tableau récapitulatif.	237
C.1	Suite du tableau récapitulatif.	238
C.1	Suite du tableau récapitulatif.	239
C.1	Suite du tableau récapitulatif.	240
C.1	Suite du tableau récapitulatif.	241
C.1	Suite du tableau récapitulatif.	242
C.1	Suite du tableau récapitulatif.	243
C.1	Suite du tableau récapitulatif.	244
C.1	Suite du tableau récapitulatif.	245
C.1	Suite du tableau récapitulatif.	246
C.1	Suite du tableau récapitulatif.	247
C.1	Suite du tableau récapitulatif.	248
C.1	Suite du tableau récapitulatif.	249
C.1	Suite du tableau récapitulatif.	250
C.1	Suite du tableau récapitulatif.	251
C.2	Résultats de classification obtenus pour les textures de la base VisTex.	252
C.3	Résultats de classification obtenus pour les textures de la base OuTex.	252
E.1	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex.	257
E.2	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base VisTex.	258
E.3	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base BarkTex.	259
E.4	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque le niveau de quantification $N = 256$ est considéré.	260
E.5	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque la moyenne et la variance des attributs d'Haralick sont considérées.	261
E.6	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque la distance spatiale $\nu = 5$ est considérée.	262
E.7	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque les distances spatiales $\nu = 1, 2, 3, 4$ et 5 sont considérées.	263

E.8	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque la procédure de génération SFFS est considérée.	264
E.9	Les $d_{max} = 50$ sous-espaces candidats sélectionnés pour discriminer les textures couleur de la base OuTex, lorsque le critère de la trace est considéré. . .	265

Communications écrites par la candidate

A. Porebski and N. Vandenbroucke and L. Macaire, Sélection automatique d'attributs pour la classification de textures couleur, In *Proceedings du onzième congrès francophone des jeunes chercheurs en vision par ordinateur (ORASIS'07)*, Obernai, France, 2007.

A. Porebski and N. Vandenbroucke and L. Macaire, Iterative feature selection for color texture classification, In *Proceedings of the 14th IEEE International Conference on Image Processing (ICIP'07)*, San Antonio, Texas, USA, 3 :509-512, 2007.

A. Porebski and N. Vandenbroucke and L. Macaire, Neighborhood and haralick feature extraction for color texture analysis, In *Proceedings of the 4th European Conference on Colour in Graphics, Imaging and Vision (CGIV'08)*, Terrassa - Barcelona, Spain, pages 316-321, 2008.

A. Porebski and N. Vandenbroucke and L. Macaire, Haralick feature extraction from LBP images for color texture classification, In *Proceedings of the first IEEE International Workshops Image Processing Theory, Tools & Applications (IPTA'08)*, Sousse, Tunisia, pages 1-8, 2008.

A. Porebski and N. Vandenbroucke and L. Macaire, Attributs de texture couleur, In *Proceedings de l'École d'Hiver sur l'Imagerie Numérique Couleur (EHINC'09)*, Toulon, France, 2009.

A paraître : A. Porebski and N. Vandenbroucke and L. Macaire, Selection of color texture features from reduced size chromatic co-occurrence matrices, In *Proceedings of the IEEE International Conference on Signal and Image Processing Applications (ICSIPA'09)*, Malaysia, 2009.

RÉSUMÉ en français

Dans le cadre du contrôle qualité de décors verriers par analyse d'image, nous proposons une méthodologie originale de classification supervisée de textures couleur pour identifier les défauts d'aspect présents sur les décors. Cette méthodologie consiste à construire un espace d'attributs de texture couleur discriminant de dimension réduite lors d'un apprentissage hors ligne afin d'y représenter les textures à classer en ligne. Afin de satisfaire aux contraintes exigées par une application industrielle en termes de qualité de résultats et de temps de calcul, l'originalité de notre approche consiste à sélectionner automatiquement un nombre réduit d'attributs qui, d'une part sont évalués à partir d'images codées dans plusieurs espaces couleur exploitant des propriétés différentes et d'autre part, tiennent compte des relations spatiales intra et inter-composantes existant au sein de ces espaces. Nous montrons alors que les indices d'Haralick extraits des matrices de co-occurrences chromatiques sont des attributs répondant à ces objectifs lorsque le nombre de couleurs de l'image est réduit grâce à une sous-quantification des composantes couleur et qu'un voisinage isotropique est utilisé. L'approche proposée est d'abord appliquée à trois bases d'images de textures couleur de référence afin de montrer l'apport de l'approche multi-espaces couleur et le bénéfice que présente la sélection d'attributs, avant d'être appliquée au contrôle qualité des décors verriers. Pour répondre au problème de sous-représentativité des prototypes lié à cette application, nous introduisons une approche originale basée sur la génération d'images de synthèse présentant les défauts à détecter.

TITRE en anglais

Color texture feature selection for image classification. Application to flaw identification on decorated glasses printing by a silk-screen process.

RÉSUMÉ en anglais

In the framework of decorated glasses quality control by image analysis, we propose an original methodology of supervised color texture classification in order to identify aspect flaws on patterns. This methodology consists in determining a low dimensional discriminating color texture feature space during an off-line learning stage in order to perform an on-line texture classification in this selected feature space. To satisfy constraints required by industrial applications about processing time and quality of texture classification, the originality of our approach consists in automatically selecting a reduced number of features which, on one hand are evaluated from images coded in several color spaces with different properties and on the other hand, which take into account the spatial relationships within and between the color components of each space. Then, we show that Haralick features extracted from color co-occurrence matrices answer to these goals when the number of colors in the image is reduced thanks to a quantization of color components and when an isotropic neighborhood is used. The proposed approach is firstly applied on three color texture benchmark databases in order to show the contribution of the multi color space approach and the advantage of feature selection. The method is then applied to decorated glasses quality control. In order to answer to the lack of prototypes, we introduce an original approach based on the generation of synthetic images where aspect flaws are present.

DISCIPLINE

Automatique, Génie Informatique, Traitement du Signal et des Images

MOTS-CLÉS

Texture couleur, espaces couleur, sélection d'attributs, classification supervisée, matrices de co-occurrences chromatiques, indices d'Haralick, contrôle qualité industriel.

Laboratoire d'Automatique **LAGIS**.

Bâtiment P2 – Université Lille 1 - Sciences et technologies – 59655 Villeneuve d'Ascq