



# Institut National Polytechnique

Félix HOUPHOUËT-BOIGNY

**EDP**  
École Doctorale Polytechnique

N° d'ordre : 53

**UMRI-78 (EEA)**

**Electronique et Electricité Appliquées**

## THESE UNIQUE

Pour l'obtention du grade de

**Docteur de l'Institut National Polytechnique Félix Houphouët Boigny de Yamoussoukro**

### Mention

SCIENCES INFORMATIQUES

### Spécialité

Traitement de Signal et Image

---

# Reconnaissance automatique des roches basée sur la représentation parcimonieuse des signaux combinée à des descripteurs statistiques et fréquentiels de texture couleur

---

Présentée et soutenue publiquement le 31 Janvier 2020

Par :

**VANGAH Wognin Joseph**

Devant le Jury composé de :

M. ZOUEU Thouakessh Jérémie	Professeur Titulaire	INP-HB, Yamoussoukro (Côte d'Ivoire)	Président
M. TIEDEU Alain	Professeur Titulaire	Université de Yaoundé 1 / ENSP, (Cameroun)	Rapporteur
M. ALLIALY Marc Ephrem	Maître de Conférences	UFHB Cocody-Abidjan (Côte d'Ivoire)	Rapporteur
M. N'ZI Modeste	Professeur Titulaire	UFHB Cocody-Abidjan (Côte d'Ivoire)	Examineur
M. OUATTARA Sié	Maître de Conférences	INP-HB, Yamoussoukro (Côte d'Ivoire)	Directeur de Thèse
M. OUATTARA Gbélé	Maître de Conférences	INP-HB, Yamoussoukro (Côte d'Ivoire)	Co-Directeur de Thèse

## DEDICACES

*A ma mère Juliette Ama, très tôt partie de ce monde, dont le souvenir est encore douloureux*

*A LIMA, mon épouse, pour son soutien inconditionnel*

*A mes enfants, Emmanuel, Archange et Marie-Samuel, pour n'avoir*

*pas toujours été là pour eux quand ils avaient besoin de moi*

*A mon père Antoine Wognin, mes frères et sœurs, pour leurs prières et soutiens.*

## Remerciements

Le cheminement de ces quatre (4) années de thèse a été pour nous un parcours d'acquisition de nouvelles connaissances et expériences. C'est le résultat d'un ensemble de trois (3) aptitudes : le savoir-faire, le savoir-vivre, le savoir-être. Toutes ces qualités ont été acquises grâce au soutien de personnes que nous tenons à remercier.

Ce travail n'aurait été possible sans l'accord de MM. **YAO Kouassi. Benjamin**, Professeur titulaire à l'INP-HB et Directeur de l'Ecole Doctorale Polytechnique (EDP) de l'INP-HB, **Jérémie ZOUEU**, Professeur titulaire à l'INP-HB, Directeur du Laboratoire d'Instrumentation et de Spectroscopie, également Directeur de l'UMRI 78.

Nous exprimons notre sincère reconnaissance à MM. **BABRI Michel** et **Souleymane OUMTANAGA**, tous deux Professeurs Titulaires à l'INP-HB et responsables du LARIT qui nous ont accueilli au sein de leur laboratoire (LARIT) et surtout pour leur vision.

Nous remercions particulièrement M. **LOUM Georges**, Professeur Titulaire à l'INP-HB, qui n'a posé aucune condition pour nous accepter dans l'équipe de recherche (SISE) qu'il dirige.

Dr. **SORO Doudjo**, Maître de conférences à l'INP-HB, Directeur des études de l'EDP et ses pairs, par leurs actions conjuguées, ils contribuent à la promotion de la recherche fondamentale et appliquée en Côte d'Ivoire.

Nos sincères remerciements à nos deux (2) directeurs de thèse : Dr **OUATTARA Sié**, Maître de conférences à l'INP-HB de Yamoussoukro, qui a cru en nous, en nous offrant la possibilité de travailler avec lui, et surtout soutenu par ses conseils pédagogiques tout au long du travail de thèse. C'est un homme pragmatique, disponible, ouvert, respectant les relations humaines. Dr. **OUATTARA Gbélé**, également Maître de conférences à l'INP-HB à Yamoussoukro, pour ses précieux conseils, ses critiques avérées et sa disponibilité. Ce fut un honneur de travailler avec vous.

Nous remercions tous les Docteurs et Doctorants du LARIT, sans exception, pour leur collaboration. Salutations distinguées et sincères remerciements au Dr **ANOAH**, Assistant à l'UVCI, qui nous a apporté son appui inestimable et corrigé nos travaux.

Nous remercions tous les membres de l'équipe SISE : M. **NOUHO**, Dr. **PANDRY**, Assistant à l'ESATIC et M. **ALICO Jérôme**, pour leur soutien et contribution.

Nous pensons à tous ceux qui, de près ou de loin, ont contribué à la réalisation de ce projet de thèse, qu'ils en soient sincèrement remerciés.

Dieu, Tout Puissant, n'est pas en reste.

# Table des matières

	Pages
DEDICACE.....	i
Remerciements.....	ii
Table des matières.....	iii
Liste des figures.....	vii
Liste des tableaux.....	ix
Acronymes.....	x
Résumé.....	xiii
Abstract.....	xv
Introduction générale.....	1
<b>1. Contexte et Motivation.....</b>	<b>1</b>
<b>2. Objectifs et Contributions.....</b>	<b>4</b>
<b>3. Organisation du manuscrit.....</b>	<b>6</b>
<b>Chapitre 1 Généralités sur les traitements d'images.....</b>	<b>7</b>
<b>1.1. Introduction.....</b>	<b>7</b>
<b>1.2. Notions d'images.....</b>	<b>7</b>
<b>1.2.1. Image au sens mathématique.....</b>	<b>7</b>
<b>1.2.2. Image numérique.....</b>	<b>8</b>
<b>1.3. Les différents types d'images numériques.....</b>	<b>9</b>
<b>1.3.1. Images matricielles ou bitmap.....</b>	<b>9</b>
<b>1.3.2. Images vectorielles.....</b>	<b>9</b>
<b>1.4. Les concepts et définitions de base.....</b>	<b>10</b>
<b>1.4.1. Le pixel.....</b>	<b>10</b>
<b>1.4.2. Le codage de pixel.....</b>	<b>10</b>
<b>1.4.3. Taille d'une image.....</b>	<b>10</b>
<b>1.4.4. Résolution d'une image.....</b>	<b>10</b>
<b>1.4.5. La luminance.....</b>	<b>11</b>
<b>1.4.6. Le bruit.....</b>	<b>11</b>
<b>1.5. Les différents types d'images numériques.....</b>	<b>11</b>
<b>1.5.1. Les images en niveaux de gris.....</b>	<b>11</b>
<b>1.5.2. Les images noir et blanc.....</b>	<b>12</b>
<b>1.5.3. Les images couleurs.....</b>	<b>12</b>
<b>1.5.4. Les images multi-composantes.....</b>	<b>13</b>
<b>1.6. Les espaces de codage de couleur.....</b>	<b>13</b>
<b>1.6.1. Les systèmes de primaires.....</b>	<b>15</b>
<b>1.6.2. Les systèmes perceptuellement uniformes.....</b>	<b>16</b>
<b>1.6.3. Les systèmes perceptuels.....</b>	<b>18</b>

1.6.4.	Les systèmes d'axes indépendants .....	19
1.6.5.	Les espaces hybrides.....	20
1.6.6.	Les espaces multidimensionnels .....	20
1.7.	Formats de fichier d'images .....	20
1.8.	Synthèse.....	22
1.9.	Les chaines de traitement d'images .....	22
1.10.	Quelques traitements d'images .....	24
1.10.1.	La segmentation d'images.....	24
1.10.2.	Segmentation basée sur la détection de discontinuité.....	25
1.10.3.	Filtrage d'une image .....	26
1.11.	Conclusion partielle.....	27
<b>Chapitre 2 Etat de l'art sur les méthodes d'analyse et de traitement des images de roche.....</b>		<b>28</b>
2.1.	Introduction .....	28
2.2.	Généralité sur les roches .....	29
2.2.1.	La classification géologique des roches .....	29
2.2.2.	Les roches magmatiques .....	31
2.2.3.	Les roches métamorphiques .....	31
2.2.4.	Les roches sédimentaires .....	32
2.2.5.	Importance des roches .....	32
2.3.	Systèmes d'acquisition des images de texture de roches.....	32
2.4.	Caractéristiques de texture et couleur des images de roches .....	32
2.4.1.	Différents types de textures.....	32
2.4.2.	Les méthodes statistiques.....	35
2.4.3.	Les méthodes spatio-fréquentielles.....	36
2.4.4.	Les méthodes structurales.....	36
2.4.5.	Les méthodes basées sur les modèles .....	36
2.5.	Les textures de roches .....	36
2.6.	La couleur .....	37
2.7.	Les espaces colorimétriques choisis .....	38
2.8.	Fusion de composantes couleur.....	40
2.9.	Couleur des roches .....	41
2.10.	Les descripteurs de texture et couleur des roches .....	42
2.11.	Les descripteurs de texture.....	42
2.12.	Descripteurs de couleur .....	43
2.13.	Descripteurs de texture couleur .....	44
2.13.1.	Caractéristiques géométriques .....	44
2.13.2.	Caractéristiques spatio-fréquentielles.....	45
2.13.3.	Caractéristiques statistiques .....	46
2.14.	Etat de l'art sur l'analyse et le traitement automatique des roches.....	48

2.15.	Caractéristiques statistiques et fréquentielles.....	49
2.15.1.	Caractéristiques statistiques : Local Binary Pattern (LBP).....	49
2.15.2.	Caractéristiques fréquentielles .....	53
2.16.	Etat de l'art sur les méthodes d'indexation des roches .....	54
2.16.1.	Introduction .....	54
2.16.2.	Méthodes d'indexation et de classification des roches .....	55
2.17.	Représentations parcimonieuses et apprentissage de dictionnaire avec K-SVD .....	57
2.17.1.	Introduction .....	57
2.17.2.	Formulation du problème .....	57
2.17.3.	Algorithmes de décomposition parcimonieuse .....	58
2.17.4.	Apprentissage de dictionnaire .....	59
2.18.	Conclusion partielle.....	63
<b>Chapitre 3 Analyse d'images de roches par la représentation parcimonieuse de signaux K-SVD et des descripteurs de textures couleur.....</b>		<b>64</b>
3.1.	Introduction .....	64
3.2.	Estimation des dictionnaires des images de roches .....	64
3.2.1.	Apprentissage de dictionnaire sur les images de roches .....	65
3.2.2.	Apprentissage de dictionnaire sur les images de textures couleur .....	71
3.2.3.	Impact de l'apprentissage de dictionnaire sur la réduction de la dimension des données	86
3.3.	Conclusion partielle.....	87
<b>Chapitre 4 Classification des roches basée sur des descripteurs de textures couleur et fréquentiels.....</b>		<b>89</b>
4.1.	Introduction .....	89
4.2.	Combinaison ALBPCSF et les filtres de Gabor pour l'extraction des caractéristiques	89
4.2.1.	Extraction des caractéristiques par les filtres de Gabor .....	90
4.2.2.	Framework des techniques d'extraction des caractéristiques des roches .....	92
4.2.3.	Nouvelle méthode d'extraction de caractéristiques des roches : G-ALBPCSF.....	93
4.3.	Combinaison ALBPCSF et la DCT pour l'extraction des caractéristiques .....	94
4.3.1.	Extraction de caractéristiques par la DCT .....	94
4.3.2.	Nouvelle méthode d'extraction de caractéristiques des roches : D-ALBPCSF.....	95
4.4.	Evaluation des méthodes et résultats expérimentaux .....	95
4.4.1.	Matériel utilisé.....	96
4.4.2.	Quelques moments statistiques utilisés .....	97
4.5.	Analyse et discussion .....	105
4.6.	Classification des roches par analyse d'histogrammes .....	105
4.6.1.	Mesures de similarité utilisées .....	105
4.6.2.	Comparaison entre HI_D-ALBPCSF et HI_LBP .....	107
4.6.3.	Matrice de confusion .....	108

4.7.	Conclusion partielle.....	111
<b>Chapitre 5 Nouvelle approche de classification des roches basée sur les représentations parcimonieuses.....</b>		
5.1.	Introduction .....	113
5.2.	Estimation du dictionnaire et de l'erreur de reconstruction des roches .....	114
5.2.1.	Principe de la méthode de classification des roches proposée .....	114
5.2.2.	Algorithme de classification de la méthode proposée.....	115
5.2.3.	Apprentissage de dictionnaires avec Gabor et DCT.....	115
5.2.4.	Apprentissage de dictionnaires avec G-ALBPCSF et D-ALBPCSF .....	116
5.3.	Impact de la combinaison des caractéristiques sur les dictionnaires.....	116
5.4.	Paramètres influençant l'apprentissage de dictionnaire.....	116
5.4.1.	Critère d'arrêt : Nombre d'itérations.....	117
5.4.2.	La taille du dictionnaire .....	117
5.5.	Influence des paramètres sur l'estimation de l'erreur du dictionnaire.....	117
5.6.	Organigramme du principe de reconnaissance d'une roche .....	118
5.7.	Expérimentations et résultats de la Classification des roches .....	120
5.7.1.	Mesure de similarité : distance euclidienne .....	120
5.7.2.	Matrices de confusion .....	121
5.7.3.	Discussion.....	127
5.8.	Systèmes multi-algorithmes.....	127
5.9.	Résultats de la fusion de caractéristiques.....	128
5.9.1.	Phase d'apprentissage .....	128
5.9.2.	Classification sur la base de test d'apprentissage .....	132
5.9.3.	Classification sur la base de test de validation de notre approche de classification .....	134
5.10.	Conclusion partielle.....	135
CONCLUSION GENERALE ET PERSPECTIVES .....		137
REFERENCES BIBLIOGRAPHIQUES .....		139
REFERENCES WEBOGRAPHIQUES .....		157
ANNEXE A.....		158
ANNEXE B .....		160
ANNEXE C.....		164

## Liste des figures

Figure 1-1: Images matricielles [19] .....	9
Figure 1-2: Image vectorielle [19].....	9
Figure 1-3: La résolution d'une image acquise : a) à 256 dpi, b) à 64 dpi, c) à 32 dpi [16] .....	11
Figure 1-4: Image numérique d'une fleur d'hibiscus dans les trois (3) canaux R, G, B [22].....	12
Figure 1-5: Les différentes familles de systèmes de représentation de la couleur [25].....	14
Figure 1-6: Représentation spatiale du modèle RVB [29] .....	15
Figure 1-7: Représentation spatiale de l'espace $L^*a^*b^*$ [27].....	18
Figure 1-8: Représentation spatiale du modèle cylindrique de l'espace HSL ou HSV [25].....	19
Figure 1-9: Exemple d'images codées dans différents espaces de couleur.....	20
Figure 1-10: Chaîne de traitement d'images [42] .....	23
Figure 2-1: Les différents types de roches .....	30
Figure 2-2: Cycle géologique des roches [59].....	31
Figure 2-3: Exemples de texture de l'album de Brodatz [69].....	33
Figure 2-4: Exemples de textures naturelles [70].....	33
Figure 2-5: Exemple de différentes textures de roches .....	37
Figure 2-6: Modèle de couleur TSI [58].....	39
Figure 2-7: Exemples d'images des huit (8) classes de roche avec différentes couleurs.....	41
Figure 2-8: Exemple de calcul de code LBP .....	50
Figure 2-9: Voisinages circulaires de pixel central avec différents voisins : a) $LBP_{8,1}$ et b) $LBP_{16,2}$ ....	51
Figure 2-10: Exemple de deux (2) textures différentes avec la même couleur (a) et (b) puis la même texture de pierre avec des couleurs différentes [36] .....	54
Figure 2-11: Principe de représentation parcimonieuse .....	58
Figure 3-1: Echantillons des onze (11) types d'images de roches de notre base de données .....	66
Figure 3-2: Images des textures de roches de différentes classes.....	67
Figure 3-3: Textures LBP des différentes images de roches .....	67
Figure 3-4: Principe de détermination du vecteur d'erreur de reconstruction .....	68
Figure 3-5: Organigramme du principe de l'approche proposée.....	73
Figure 3-6: Images de la classe 1 .....	74
Figure 3-7: Images de la classe 2 .....	75
Figure 3-8: Images de la classe 3 .....	76
Figure 3-9: Images de la classe 4 .....	77
Figure 4-1: Exemples d'une image filtrée par quatre (4) différents filtres de Gabor : (a1), (a2), (a3), (a'1), (a'2) et (a'3) sont les différentes images des amplitudes et (b1), (b2), (b3), (b'1), (b'2) et (b'3) sont les images des phases de Gabor pour deux (2) longueurs d'ondes ( $\lambda=4$ et $\lambda=8$ ) et pour différentes orientations.....	91
Figure 4-2: Un exemple d'image originale de granodiorite (a), son image LBP (b), son image ALBPCSF (c) (les 03 superposées), l'histogramme de l'image LBP (d) et l'histogramme ALBPCSF (e) .....	92
Figure 4-3: Framework des techniques d'extraction des caractéristiques .....	93
Figure 4-4: Image G-ALBPCSF de l'image originale de Granite5E pour $\lambda=4$ (en haut) et $\lambda=8$ (en bas) et pour différentes orientations ( $0^\circ$ ; $45^\circ$ ; $90^\circ$ ; $135^\circ$ ; $180^\circ$ ).....	94
Figure 4-5: image DCT (milieu) de l'image originale de granite5E (à gauche) et sa combinaison avec ALBPCSF (à droite).....	94
Figure 4-6: Exemples des huit (8) différentes classes des images de roches .....	97
Figure 4-7: Moyennes des coefficients DCT, D-ALBPCSF, et des amplitudes de Gabor, G-ALBPCSF .....	102
Figure 4-8 : Moyennes des écart-types des coefficients DCT, D-ALBPCSF, et des amplitudes de Gabor, G-ALBPCSF .....	103
Figure 4-9 : Moyennes des énergies des coefficients DCT, D-ALBPCSF, et des amplitudes de Gabor, G-ALBPCSF .....	104



---

Figure 4-10 : Intersection des histogrammes des roches avec LBP et D_ALBPCSF .....	107
Figure 4-11 : Indicateur de performance de LBP et D_ALBPCSF .....	111
Figure 5-1: Organigramme de la méthode de classification de roches proposée .....	115
Figure 5-2: Organigramme du principe de reconnaissance .....	119
Figure 5-3: Pourcentages des échantillons bien classés par roche et pour les différentes méthodes de classification .....	125
Figure 5-4: Pourcentages de taux moyen de bonne classification par méthode .....	126
Figure 5-5: Pourcentage de taux moyen de bonne classification par familles de roches .....	127
Figure 5-6: Indicateurs de performance de la combinaison de variante .....	135

## Liste des tableaux

Tableau 1-1: Tableau comparatif des caractéristiques des formats d'images [43] .....	21
Tableau 2-1: Résumé des descripteurs de texture [80].....	35
Tableau 2-2: Les principales catégories des méthodes de description de texture .....	42
Tableau 2-3: Les différentes catégories d'extension de LBP.....	52
Tableau 2-4: Méthodes d'indexation et de reconnaissance de roches .....	55
Tableau 2-5: Principaux algorithmes d'apprentissage de dictionnaire et leurs éléments constitutifs ...	61
Tableau 2-6: Avantages et inconvénients des méthodes appliquées aux structures rocheuses .....	62
Tableau 3-1: Erreurs calculées avec K-SVD et avec K-SVD+ operateur LBP.....	68
Tableau 3-2: Valeurs SSIM des échantillons des images photographiques de roches.....	69
Tableau 3-3: Erreurs de reconstructions calculées .....	78
Tableau 3-4: Analyse des variations d'erreur des roches de familles identiques .....	79
Tableau 3-5: Analyse des variations d'erreur des roches de familles différentes .....	80
Tableau 3-6: Erreurs relatives avec des roches de même famille.....	81
Tableau 3-7: Erreurs relatives avec des roches de nature différence.....	82
Tableau 3-8: Analyse des variations d'erreur des roches de même famille avec trois (3) métriques choisies : la moyenne (Moy), le maximum (Max) et la distance L2 .....	84
Tableau 3-9: Analyse des variations d'erreur des roches de familles différentes avec les trois (3) métriques : Moyenne (Moy), le maximum (Max) et la distance L2.....	85
Tableau 4-1: Moyenne des coefficients des amplitudes de Gabor .....	97
Tableau 4-2: Moyennes des coefficients des amplitudes de G-ALBPCSF .....	98
Tableau 4-3: Moyennes des coefficients DCT .....	98
Tableau 4-4: Moyennes des coefficients D-ALBPCSF.....	98
Tableau 4-5: Ecart-type des coefficients des amplitudes de Gabor sur les images originales .....	98
Tableau 4-6: Ecart-type des coefficients des amplitudes G-ALBPCSF.....	99
Tableau 4-7: Ecart-type des coefficients DCT sur les images originales.....	99
Tableau 4-8: Ecart-type des coefficients D-ALBPCSF.....	99
Tableau 4-9: Energies des amplitudes de Gabor .....	100
Tableau 4-10 : Energies des amplitudes de G-ALBPCSF.....	100
Tableau 4-11: Energies des coefficients DCT .....	100
Tableau 4-12: Energies des coefficients D-ALBPCSF .....	101
Tableau 4-13: Valeurs moyennes des HI des différentes méthodes utilisées .....	106
Tableau 4-14: Valeurs moyennes des $\chi^2$ des différentes méthodes utilisées .....	107
Tableau 4-15: Matrice de confusion avec la méthode D_ALBPCSF.....	109
Tableau 4-16: Indicateurs de performance des deux (2) méthodes .....	109
Tableau 4-17: Comparaison des méthodes LBP et D_ALBPCSF sur les différentes classes de roches .....	110
<i>Tableau 5-1 : Matrice de confusion réalisées pour la méthode KD-ALBPCSF.....</i>	<i>122</i>
Tableau 5-2 : Matrice de confusion réalisées pour la méthode K-Gabor .....	122
Tableau 5-3 : Matrice de confusion réalisées pour la méthode K-DCT .....	123
Tableau 5-4 : Matrice de confusion réalisées pour la méthode KG-ALBPCSF.....	123
Tableau 5-5 : Indicateurs de performance des quatre (4) méthodes.....	124
Tableau 5-6 : Pourcentages de taux de bonne classification des différentes méthodes.....	125
Tableau 5-7 : Pourcentage de taux moyen de bonne classification par familles de roche .....	126
Tableau 5-8 : Images de roches utilisées pour l'apprentissage .....	130
Tableau 5-9 : Matrice de confusion avec fusion des quatre (4) variantes .....	131
Tableau 5-10 : Indicateurs de performance de la combinaison des quatre (4) variantes de .....	132
Tableau 5-11 : Images de roches pour le test .....	133
Tableau 5-12 : Matrice de confusion avec notre méthode.....	134
Tableau 5-13 : Indicateurs de performance avec notre méthode.....	135
Tableau 5-14 : Indicateurs de performance .....	135

## Acronymes

2D ou 3D	2 ou 3 Dimensions
ACP	Analyse à Composante Principale
ALBPCSF	Adjacent Local Binary Pattern Based on Color Space Fusion
ANN/RNA	Artificial Network Neurones/Réseaux de neurones Artificielles
ASDH	Adaptive Sum and Difference Histograms
B/SP	Basis/ Subspace Pursuit
BMP	Bayesian MP
BMP	BitMaP
BOMP	Bayesian OMP
CCD	Charge-Coupled Devices
CCoLBP	Chromatic Co-occurrence of Local Binary Pattern
CCR	Coordinated Clusters Representation
CIE	Commission internationale d'Eclairage
CLAHE	Contrast Limited Adaptive Histogram Equalization
CMC	Chromatic Matrix Co-occurrence
CMJ	Cyan, Magneta, Jaune
CMOS	Complementary Metal Oxide Semi-Conductor
CMP	Complementary Matching Pursuit
CRPG	Centre de Recherches Pétrographiques et Géochimiques
D-ALBPCSF	Discret-Adjacent Local Binary Pattern Based on Color Space Fusion
DCD	Descripteurs Couleurs Discriminants
DCT	Discret Cosine Transform
DLENE	Learn overcomplete Dictionaries with Efficient Numbers of Elements
DPI	Dots Per Inch
E/OCLBP	Extend/Opponent Color LBP
EBU	European Broadcast Union
EDP	Ecole Doctorale Polytechnique
EEA	Electronique et Electricité Appliquée
Er	Erreur de reconstruction
ER	Erreur Relative

---

ESATIC	École Supérieure Africaine des Techniques de l'Information et de la Communication
FCC	Federal communications commission
FOCUSS	FOCal Underdetermined System Solver
G_ALBPCSF	Gabor-Adjacent Local Binary Pattern based on Color Space Fusion
GA	Genetic Algorithm
GCGSG	Génie Civil Géosciences et Sciences Géographiques
GIF	Graphics Interchange Format
GLCM	Gray-Level Co-Occurrence Matrix
GLOH	Gradient Location and Orientation Histogram
HI	Intersection of Histogram
HOG	Histograms of Oriented Gradients
HSI/L/V	Hue Saturation Intensity/Luminosité/Value
I/LBP	Improved/Local Binary Patterns
I/RLS-DLA	Iterative/recursive least squares dictionary learning algorithm
INP-HB	Institut National Polytechnique-Houphouët Boigny
IUGS	International Union of Geological Sciences
JPEG	Joint Photographic Expert Group
K-SVD	K-Singular Value Decomposition
LARIT	Laboratoire de Recherche en Informatique et Télécommunication
LASER	Light Amplification by Stimulated Emission of Radiation
LGBPH	Local Gabor Binary Patterns Histogram
LP(N)A	Lumière Polarisée (Non) Analysée
LTP	Local Ternary Patterns
LUT	Look-Up Table
MOD	Method of Optimal Directions
MPEG	Moving Picture Experts Group
MRF	Markov Random Fields
MV	Maximum de Vraisemblance
NN	Nearest Neighbor
ORL	Oto-Rhino-Laryngologiste
ORMP	Order Recursive Matching Pursuit
PHOG	Pyramid of Histograms Color of Oriented Gradients

---

PIXEL	Picture ELeMents
PNG	Portable Network Graphic
PPP	Pixel Par Pouce
RGB/RVB	Red Green Blue/Rouge Vert Bleu
RP	Représentation Parcimonieuse
SIFT	Scale-Invariant Feature Transform
SISE	Signal Image et Systèmes Électriques
SSIM	Structural SIMilarity
St/O/OMP	Stagewise/Optimizer/Orthogonal Matching Pursuit
SURF	Speeded Up Robust Features
SVM	Support Vector Machine
TAS	Total Alkadi Silica
TIFF	Tagged Image File Format
UMRI	Unité Mixte de Recherche et d'Innovation
UVCI	Université Virtuelle de Côte d'Ivoire

## Résumé

Cette étude a pour but de contribuer à l'identification automatique, simple et rapide des roches à partir d'images macroscopiques d'échantillons de vue directe de roches par la caractérisation et l'analyse de leur texture.

L'analyse des textures couleur est de plus en plus présente dans la littérature avec une grande variété de descripteurs de textures couleur proposée. Parmi eux, les motifs binaires locaux (Local Binary Pattern : LBP) occupent une place de choix dans cette liste exhaustive. Dans la plupart des applications d'imagerie couleur ou de reconnaissance de formes, ils sont particulièrement exploités dans les problèmes d'analyse de texture. Mais, leur utilisation dans l'étude des roches est encore à ses débuts. Le challenge des chercheurs est de trouver des techniques de traitement d'images copiant exactement la vision humaine.

Généralement, les images couleur, acquises par photographie, sont obtenues dans l'espace colorimétrique RGB. Toutefois, certains espaces couleur, tel l'espace couleur HSV ayant des propriétés spécifiques plus proches des propriétés visuelles humaines, dans la classification des textures, permettent d'obtenir de bonnes performances avec leur utilisation. Cela nous conduit à une stratégie multi-espace couleur permettant d'utiliser simultanément les propriétés de ces deux (2) espaces cités. A cause de l'hétérogénéité et de la grande variabilité des textures de roches, l'usage d'un seul descripteur ne suffit pas pour caractériser les roches. Ce travail de recherche s'inscrit dans cette dynamique. Il est donc axé sur la combinaison de méthodes d'extraction de caractéristiques. L'objectif de notre réflexion est de développer une méthode d'identification automatique des roches, s'appuyant sur une combinaison de méthodes d'extraction de caractéristiques. Nous avons, de prime abord, extrait les caractéristiques des roches avec le descripteur LBP, puis avec le descripteur colorimétrique ALBPCSF. Ce dernier descripteur cité, permettra dans un premier temps de rehausser les images et de prendre en compte l'information couleur présente dans les textures de roches. Nous avons ensuite, combiné le descripteur statistique ALBPCSF et les transformées fréquentielles pour prendre en compte la non homogénéité et la grande variabilité présentes dans les textures des roches. Enfin, nous avons fait une première classification, basée sur les méthodes D-ALBPCSF et LBP à partir d'une mesure de similarité entre les histogrammes. Le taux de bonne classification de ces méthodes fut de 95 %, avec une précision de plus de 80 %, pour la méthode D-ALBPCSF. Une seconde méthode de classification a été développée. Elle repose sur l'algorithme K-SVD combinée à quatre (4) techniques d'extraction de caractéristiques : la DCT, les filtres de Gabor, la D-ALBPCSF et la G-ALBPCSF. Les mesures de performance réalisées ont permis d'obtenir

les taux de bonne classification variant jusqu'à 50%. Ces taux ont été par la suite améliorés en concaténant les signatures des quatre (4) variantes de K-SVD (K-Gabor, K-DCT, KD-ALBPCSF et KG-ALBPCSF) en une seule signature pour obtenir 93,13 % de taux de bonne classification des roches dans leur ensemble avec 95,83 % en moyenne pour les roches magmatiques et 91,5 % pour les roches métamorphiques.

**Mots-clés** : Descripteur statistique, descripteurs fréquentiels, classification automatique des roches, textures couleur, K-SVD, KD-ALBPCSF, KG-ALBPCSF, images de roches.

## Abstract

The purpose of this work is to contribute to the automatic, simple and rapid identification of rocks from macroscopic images of direct-view samples of rocks by characterizing and analyzing their texture.

Indeed, the analysis of color textures is increasingly studied in the literature and a wide variety of color texture descriptors have been proposed. Among these, local binary patterns (LBPs) occupy a prominent place in this exhaustive list and in most color imaging or pattern recognition applications and are particularly used in texture analysis problems. However, their use in the study of rocks is still in its infancy. In addition, the challenge for researchers is to find image processing techniques that accurately copy human vision.

Generally, color images acquired by photography are obtained in the RGB colorimetric space. However, some color spaces such as the HSV color space have specific properties closer to human visual properties in texture classification and provide good performance with their use. This leads us to a multi-color space strategy that allows us to use the properties of these two spaces simultaneously. However, due to the heterogeneity and high variability of rock textures, the use of a single descriptor is not sufficient to characterize rocks.

This research work is embedded in this dynamic and therefore is based on the combination of characteristic extraction methods. The aim of this thesis work is to develop a method for automatic rock identification based on a combination of characteristic extraction methods. We first extracted the characteristics of the rocks with the LBP descriptor, then with the ALBPCSF colorimetric descriptor. The latter will initially enhance the images and take into account the color information present in the rock textures. We then combined the statistical descriptor ALBPCSF and frequency transforms to take into account the non-homogeneity and high variability in rock textures. Finally, we made a first classification based on the D-ALBPCSF and LBP methods by measuring the similarity between the histograms. The good classification rate of these methods was 95 % with an accuracy of more than 80 % for the D-ALBPCSF method. Finally, a second classification method was developed. It is based on the K-SVD algorithm combined with four feature extraction techniques: DCT, Gabor filters, D-ALBPCSF and G-ALBPCSF. The performance measures carried out allowed us to obtain good classification rates of up to 50 %. These rates were subsequently improved by concatenating the signatures of the 04 K-SVD variants (K-Gabor, K-DCT, KD-ALBPCSF and KG-ALBPCSF) in a single signature to obtain a 93,13% good rate. classification of rocks as a whole with an average of 95,83 % for magmatic rocks and 91,5 % for metamorphic rocks.



**Keywords:** Statistical descriptor, frequency descriptors, rock automatic classification, color textures, K-SVD, KD-ALBPCSF, KG-ALBPCSF, images of rocks.

# Introduction générale

## 1. Contexte et Motivation

La caractérisation et l'analyse des structures géologiques fournit un aperçu de l'histoire et de la formation d'un site. Les analyses morphologiques, physiques et compositionnelles détaillées des roches ainsi que l'intégration de ces informations dans des modèles conceptuels, permettent de décrypter l'histoire d'une région.

Fort de ce constat, la reconnaissance des roches demeure un sujet inhérent à la géologie, particulièrement à la pétrographie. Malheureusement, l'exploration de certains sites géologiques est difficile d'accès, voire dangereuse.

De nombreux systèmes de classification existent : la classification chimique prenant en compte la teneur en silice, en carbonate ou en argile, la classification minéralogique - toutes deux faites à partir de lames minces- et la classification macroscopique, sur la base de la structure cristalline de la roche.

Aucun d'eux ne fait l'unanimité dans leur utilisation par les géologues, révélant le caractère subjectif de la reconnaissance manuelle. L'automatisation de la reconnaissance apparaît alors comme une façon adéquate d'optimiser les ressources pour endiguer la subjectivité et réduire le temps de reconnaissance. Elle permettra aussi d'éviter les dangers liés à l'exploration des sites géologiques, difficiles d'accès et servira de support aux géologues. Depuis les années 1970, l'on assiste à une augmentation constante de la quantité d'images et de son utilisation dans divers domaines d'activités : la géographie, la biologie, la médecine, la télédétection, la sécurité, l'astronomie, la géologie, etc [1].

Avec les progrès technologiques, l'amélioration des techniques d'acquisition et de stockage a fait de l'image numérique un outil incontournable d'information et de communication. Des gammes variées comme les images binaires, les images en niveaux de gris ou monochromes, les images multi-composantes - les images couleurs, multispectrales ou les images multimodales- sont tous les jours créées. Ces dernières citées sont assez utilisées car riches en informations [2 - 4] et reflètent mieux la réalité, surtout lorsqu'elles sont naturelles. Souvent acquises par le biais des smartphones, des appareils photographiques ou d'autres appareils dédiés, avec des caractéristiques diverses et variées, ces images sont souvent altérées lors de l'acquisition.

---

Dans la même veine, l'essor de l'intelligence artificielle, de ce dernier siècle, a permis de développer des techniques et méthodes efficaces de traitement d'images naturelles. En effet, les images de roches sont un exemple typique d'images couleurs naturelles et non-homogènes [5]. Leur reconnaissance manuelle demeure difficile et subjective ; d'où l'idée de la reconnaissance automatique. L'objectif d'une reconnaissance de roche, qu'elle soit manuelle ou automatique, consiste à identifier correctement et, de manière cohérente, les roches.

Cela fait de la reconnaissance automatique des roches, un sujet de recherche actif et d'investigation continue [6, 7]. Cependant, les techniques d'analyse et de traitement d'images de roches, doivent être choisies et utilisées de manière efficiente pour une bonne reconnaissance, face à la redondance des données et la dimension élevée des caractéristiques extraites. L'analyse et le traitement des données, se faisant, soit par photo-interprétation, soit par spectrophotométrie, présentent également deux (2) étapes essentielles : d'une part, l'étape primordiale d'extraction de caractéristiques visuelles de texture couleur, avec des méthodes statistiques et fréquentielles multi-échelles pour la plupart des travaux rencontrés ou par spectrométrie, d'autre part, l'étape cruciale de classification et de prise de décision.

Une meilleure classification est toujours précédée d'une bonne caractérisation des données dont les choix des méthodes dépendent des applications et objectifs visés. Des progrès ont été réalisés dans ce sens ces dernières années. Mais il est encore difficile de développer un système automatique universel, capable d'analyser efficacement les images de roches, à cause de la grande variabilité et de l'hétérogénéité de leurs caractéristiques.

Nonobstant les nombreux travaux réalisés dans ces domaines, le problème demeure sans réponse définitive. Dans la littérature, maintes stratégies de segmentation et d'apprentissage de dictionnaire, furent développées. Parmi les méthodes suggérées : les Réseaux de Neurones Artificielles (RNA), la SVM (Support à Vaste Marge), K-NN (K plus proche voisin), K-means, les algorithmes Boosting, MV (Maximum de Vraisemblance) [8]. Ces méthodes, pour la plupart, sont combinées à des méthodes de réduction de dimensions comme les ACP (Analyse à Composante Principale) ou les GA (Algorithme Génétique). Ces combinaisons aident à faire la classification. Toutefois, ces méthodes de réduction de dimensions introduisent, dans certains cas, du bruit lors de la classification ; d'où leur inefficacité à gérer un nombre élevé de dimensions des descripteurs de texture couleur et la redondance des données. Pour tenter d'apporter une solution à ces problèmes, nous explorons les représentations parcimonieuses.

---

Ces dernières années, la communauté scientifique réfléchit à une autre manière de représenter un signal, en déterminant son dictionnaire. Il existe différents procédés pour déterminer un dictionnaire. L'idée pionnière et originale était de calculer les dictionnaires par des fonctions mathématiques prédéfinies (fonction cosinusoidale, gaussienne...). Bien que simples, ces méthodes ne sont flexibles et ne s'adaptent pas à la dynamique du signal étudié. La seconde, est de calculer le dictionnaire à partir des méthodes d'apprentissage de dictionnaire mises en œuvre depuis les travaux de base de [9]. L'une des alternatives est la représentation parcimonieuse des signaux avec apprentissage de dictionnaire. K-SVD, est l'une des méthodes de représentations parcimonieuses, très active dans ce domaine, basée sur des dictionnaires redondants [10], avec une parcimonie sur chaque atome sans distorsion des données. Cette méthode de construction de dictionnaire, jugée flexible, simple et efficace par les chercheurs, fut utilisée, avec succès, dans plusieurs domaines d'activité dont les principaux : la compression, le débruitage, la structuration et l'apprentissage de dictionnaire, la super-résolution, la classification, la restauration et le filtrage d'images. Elle repose généralement sur l'algorithme glouton OMP, beaucoup utilisé à cause de sa simplicité à estimer efficacement le dictionnaire et l'erreur de reconstruction, contrairement à l'algorithme MP, etc. dont l'estimation n'est pas optimale. Elle a suscité l'intérêt des chercheurs comme [10, 11, 12]. Par exemple, dans les travaux de J. AGHAEI en 2015, avec les images satellitaires, l'accent a été mis sur l'utilisation des représentations parcimonieuses dans le cadre du codage des coefficients non nuls et des indices des atomes du dictionnaire auxquels ils correspondent. Cela permit de structurer les dictionnaires en arbres et à plusieurs niveaux pour caractériser des zones texturales à partir de l'erreur de reconstruction.

Cependant, la plupart des travaux n'insistent pas sur l'erreur de reconstruction du dictionnaire. Depuis une dizaine d'années, dans le domaine de l'analyse des textures, le Local Binary Pattern (LBP), introduit par Ojala et al., en 1996 [13], est apparu comme un outil dynamique, simple et facile à implémenter, pour l'extraction des caractéristiques de texture. C'est l'un des meilleurs opérateurs statistiques locaux, à l'heure actuelle. Son succès dans la reconnaissance de visage notamment, même dans la classification des granites, témoigne de son efficacité [14].

En effet, dans certaines applications de classification des textures, l'un des problèmes majeurs mis en relief, est la sensibilité à la rotation. La performance globale du classifieur de texture peut être totalement dégradée si les motifs inconnus à classer sont légèrement tournés par rapport aux échantillons d'apprentissage. L'attention a donc été accordée au développement de descripteurs de texture invariants par rapport à la rotation en modifiant les approches bien connues : les ondelettes, les champs de Markov et les filtres de Gabor. Le LBP a subi cette

---

amélioration pour supprimer la sensibilité à la rotation. Malheureusement, les images de roches n'échappent pas à ces transformations de rotation et d'illumination, bien gérées par le LBP. En 2011, Bianconi et al. [14], ont utilisé, avec succès, l'une des variantes de LBP à savoir ILBP, lors de la classification des images de texture de granite.

Dans le processus de filtrage des images de texture de Brodatz, l'erreur de reconstruction de dictionnaire a été un facteur discriminant [15]. Dans la reconnaissance des images faciales et des images de roches, pour une bonne extraction des caractéristiques, des combinaisons de méthodes statistiques et fréquentielles ont été adoptées. Toutes ces raisons susmentionnées ont donc motivé le choix de notre sujet intitulé : **Reconnaissance automatique des roches basées sur la représentation parcimonieuse des signaux combinée à des descripteurs statistiques et fréquentiels de texture couleur.**

Cette étude, initiée respectivement par les laboratoires de recherche Electronique et Electricité Appliqué (EEA), et Génie Civil Géosciences et Sciences Géographiques (GCGSG) de l'INP-HB de Yamoussoukro, se situe à l'intersection de deux (2) axes de recherches « Analyse et traitement d'images » et « Reconnaissance des roches ».

Etant donné que les images de roche sont identifiées comme des images de textures naturelles, multi-échelles et multi-composantes, les méthodes de traitement d'images, largement appliquées aux images couleurs ou en niveaux de gris, avec succès, prises individuellement, ne donnent pas une totale satisfaction.

Face à cette situation, la nécessité d'introduire des méthodes de caractérisation (classification), capables de prendre en compte tous ces paramètres précédemment évoqués s'impose.

## **2. Objectifs et Contributions**

Notre objectif principal, dans cette thèse, est de contribuer à l'identification automatique, simple et rapide des roches, en appliquant les représentations parcimonieuses et une combinaison de descripteurs statistiques et fréquentiels sur des échantillons d'images de vue directes de roches. Nous proposons dans cette étude une combinaison de descripteurs statistiques et fréquentiels, capable de modéliser et d'extraire des paramètres caractéristiques sur des images de texture couleur de roches pour une bonne reconnaissance lorsqu'elles sont couplées d'une part au LBP, d'autre part, aux représentations parcimonieuses avec K-SVD.

La méthode de parcimonie K-SVD résout efficacement les problèmes de dimensions élevées de descripteurs et de redondance de données sans sacrifier la performance de la classification. Cette méthode permet de déterminer, pour une roche donnée, un dictionnaire. La question, qui

---

se pose, est de savoir si elle permet d'obtenir le meilleur dictionnaire avec une erreur de reconstruction optimale, vue le fort contenu textural des roches ? C'est à cette question que tente de répondre cette première contribution. La première contribution présente d'abord une analyse des descripteurs de texture de Wang et de l'opérateur LBP colorimétrique composite nommé ALBPCSF, sur les images de vue directe de roches magmatiques et métamorphiques. Cette approche a mis en exergue certains paramètres discriminants relatifs aux différentes classes de roches. Ensuite, une autre analyse faite avec la représentation parcimonieuse des signaux K-SVD, à travers l'estimation du dictionnaire et des erreurs de reconstruction, nous a permis de montrer une similarité entre les roches d'une même classe à travers les erreurs de reconstruction. Cette dernière technique fut couplée au LBP couleur composite.

Notre deuxième contribution propose une nouvelle méthode de classification, fondée sur le descripteur de texture LBP d'une part, et la combinaison de descripteurs statistique et fréquentiel (D-ALBPCSF) d'autre part, en vue de tester la performance de la combinaison des descripteurs. Dans cette classification, l'usage d'une mesure de similarité axée sur l'analyse d'histogramme a permis d'avoir un taux de bonne classification de 95%, une précision de plus de 80%, pour la méthode D-ALBPCSF. Cependant, d'autres mesures ont été effectuées. Elles concernent, l'une à l'analyse des histogrammes sur des images de vue directe, l'autre à l'analyse d'histogramme sur des images, obtenues à partir de descripteurs de texture couleur composite ou de texture couleur combinés aux filtres de Gabor. Les résultats de ces dernières approches n'ont pas été satisfaisants. Quelques résultats sont présentés, à titre indicatif, dans les annexes.

La directionnalité, présente dans les textures de roches, nécessite l'utilisation des descripteurs spatio-fréquentielles. De tels descripteurs, peuvent-ils contribuer à la caractérisation des textures de roches pour obtenir le meilleur dictionnaire d'une roche, avec une erreur de reconstruction optimale ? Cette dernière contribution tente de répondre à cette question. La troisième contribution a permis de développer une seconde méthode de classification basée sur K-SVD combiné à quatre (4) techniques d'extraction de caractéristiques : la DCT, les filtres de Gabor, le D-ALBPCSF et le G-ALBPCSF. Dans cette approche, le taux de bonne classification varie jusqu'à 50 %. Ces taux ont par la suite été améliorés en concaténant les signatures des 4 variantes de K-SVD (K-Gabor, K-DCT, KD-ALBPCSF, KG-ALBPCSF) en une seule pour obtenir 93,13 % de taux de bonne classification des roches dans leur ensemble avec 95,83 % en moyenne pour les roches magmatiques et 91,5 % pour les roches métamorphiques.

---

### 3. Organisation du manuscrit

Pour rendre compte des travaux réalisés et présenter les différents aspects de notre étude, ce manuscrit est structuré en cinq (05) chapitres.

Le chapitre 1 introduit les fondamentaux théoriques sur les notions générales du traitement d'images. Il définit l'image numérique, présente les types d'images et les différents espaces de couleur qui les codent.

Le deuxième chapitre résume, dans une première partie, un état de l'art sur les méthodes d'indexation d'images et les méthodes d'extraction de caractéristiques de textures couleur associées, pour une bonne classification précisant, celles exploitées pour la classification des roches particulièrement. Dans une deuxième partie, nous nous focalisons d'une part, sur le descripteur LBP, ses variantes et extensions couleurs, d'autre part, sur les méthodes fréquentielles comme les filtres de Gabor et la DCT. Dans la troisième partie, un état de l'art sur les représentations parcimonieuses, mettant en exergue l'apprentissage de dictionnaire, clôt ce chapitre. Le chapitre 3 de cette thèse fait cas des méthodes d'analyse d'images de roches, par représentation parcimonieuse de signaux K-SVD et des descripteurs de textures couleur. Quant au chapitre 4, il propose une classification des roches basée sur des descripteurs de texture couleur et fréquentiels nommés G-ALBPCSF et D-ALBPCSF à partir des mesures de similarité entre les histogrammes. La performance de ces méthodes est évaluée à travers une matrice de confusion.

Le chapitre 5 de cette thèse suggère une nouvelle approche de classification basée sur les représentations parcimonieuses des signaux K-SVD nommées KD-ALBPCSF et KG-ALBPCSF et ses variantes dont les résultats de performance sont évalués à travers une matrice de confusion, réalisée à partir des erreurs de reconstruction des dictionnaires calculés.

Une conclusion générale, des références bibliographiques et webographiques, les publications réalisées au cours de cette thèse ainsi que les annexes, complètent ce manuscrit.

---

# Chapitre 1 Généralités sur les traitements d'images

*Ce chapitre a pour objectif de présenter un état de l'art sur les différents types d'images, les différents espaces colorimétriques qui les codent puis les relations existantes entre ces différents espaces de couleur. Ensuite, dans une seconde partie, il présente la chaîne de traitement des images et quelques techniques dans le traitement des images.*

## 1.1. Introduction

A notre époque, avec le développement des systèmes multimédias : microscopes, radiographies, photographies, etc, les progrès technologiques de l'imagerie numérique, des processeurs informatiques et des dispositifs de stockage de masse, plus de 90 % de l'information captée, reçue et diffusée par l'Homme, comme support de communication dans tous les domaines, est visuelle. Ces images denses et riches en information par leur contenu, constituent sans nul doute le moyen de communication universel, multidimensionnel et plus expressif voire plus compréhensif par des personnes d'horizons divers.

## 1.2. Notions d'images

Nombreuses sont les définitions de l'image présentes dans la littérature. Selon celle du LAROUSSE empruntée ensuite par [16], l'image est la représentation d'une personne ou d'une chose par la peinture, la sculpture, le dessin, la photo, le film ou la vidéo ... etc. Techniquement, une image est une représentation 2D d'une scène à trois (3) dimensions. Elle peut se présenter sous forme analogique avec le négatif, la photographie et la vidéo ou sous forme numérique (images compressées ou non, obtenue par les capteurs). Dans ce dernier cas, un traitement par ordinateur est possible [17]. Cette notion de l'image est la plus accessible.

Par adaptation, dans le cadre de notre étude, nous définissons l'image comme toute information issue d'un capteur optique tel l'œil, la caméra, le microscope, la photographie, la spectrométrie ...etc, ayant une signification et une interprétation pour l'œil humain.

### 1.2.1. Image au sens mathématique

En mathématique, une image est décrite sous la forme d'une fonction  $I(x, y)$  de brillance analogique continue, définie dans un domaine borné, tel que  $x$  et  $y$  sont les coordonnées spatiales d'un point de l'image;  $I$ , une fonction d'intensité de lumineuse et de couleur. Les images courantes sont les images 2D (à 2 dimensions ou matricielles) : les images binaires (images noir et blanc), les images à niveau de gris, les images couleurs et les images 3D (de



---

dimensions 3) ; les images médicales tomographiques, par exemple. Globalement, on distingue deux (2) types d'images numériques : les images bitmap ou matricielles et les images vectorielles.

### 1.2.2. Image numérique

Dans une définition étendue, une image numérique est un code qui est acquis et stocké sur un support informatique (clé USB, téléphone portable, ordinateur). Elle est obtenue grâce à des capteurs CCD (Charge-Coupled Devices) ou CMOS (Complementary Metal Oxide Semiconductor) couplés à un numériseur externe ou intégré pour une scène réelle.

Numériser une image, c'est passer de l'état d'image physique (image optique par exemple), caractérisée par l'aspect continu du signal qu'elle représente (une infinité de valeur de l'intensité lumineuse par exemple), à l'état d'image numérique, caractérisée par l'aspect discret (l'intensité lumineuse ne peut prendre que des valeurs quantifiées en un nombre fini de points distincts). Cette forme numérique permet une exploitation ultérieure par l'ordinateur [18].

Une image analogique, obtenue à partir d'un scanner par exemple, est échantillonnée spatialement en grilles régulières dont chaque case est appelée « pixel », de l'expression anglaise « picture elements », juxtaposées en lignes et en colonnes. On peut ainsi définir une image numérique comme le nombre de pixels la composant en largeur et en hauteur. A chaque pixel, est affecté un scalaire (exemple un niveau de gris) ou un vecteur attribut aussi appelé « tuple » (par exemple une couleur).

En définitive, une image numérisée est une image analogique ayant subi un échantillonnage et une quantification lors de l'acquisition. L'échantillonnage a pour but de diviser l'image en cellules élémentaires ou pixels, tandis que la quantification attribue une valeur numérique à chaque point de l'image, en fonction du niveau de gris.

En pratique, une image 2D signifie une image dont la résolution est définie par  $M \times N$ , où  $M$  désigne le nombre de lignes de l'image,  $N$ , le nombre de colonnes. Concrètement, la résolution d'une image est le nombre de pixels par unité de mesure (surface ou longueur).

De manière générale, une image est acquise dans plusieurs bandes spectrales (ou longueur d'ondes) ou selon différentes modalités, produisant ainsi une image multi-composante ou multispectrale.

Dans cette étude, les images ayant un intérêt certain pour nous, sont les images 2D ou matricielles. Elles se présentent sous forme scalaire, donc en niveau de gris, ou sous forme vectorielle.

### 1.3. Les différents types d'images numériques

#### 1.3.1. Images matricielles ou bitmap

Les images matricielles (de l'anglais bitmap) sont des images en mode point. Le système de codage consiste à les décomposer en un ensemble de pixels de dimensions données, caractérisés par leurs coordonnées spatiales et leurs couleurs (voir *figure 1-1*).



*Figure 1-1: Images matricielles [19]*

#### 1.3.2. Images vectorielles

Les images vectorielles sont celles dans lesquelles les données sont représentées par des formes géométriques simples : rectangles, cercles, segments etc, et décrites d'une façon mathématique. Pour ces types d'images, une succession d'opérations stockées conduisent au tracé, contrairement aux images matricielles où l'on se base sur un ensemble de points élémentaires. Ces images ont l'avantage d'être très peu gourmandes en espace mémoire et capables d'être redimensionnées, sans perte de qualité.



*Figure 1-2: Image vectorielle [19]*

---

## **1.4. Les concepts et définitions de base**

Dans la littérature, divers formats d'images existent, avec des niveaux de complexité très variables. Nous rappelons, dans cette section, la définition de certains concepts de base de l'image numérique [16].

### **1.4.1. Le pixel**

Le pixel désigne le point élémentaire constitutif d'une image numérique [20]. Sa valeur numérique représente une intensité lumineuse et une couleur ou un niveau de gris. Le pixel informe sur la qualité d'affichage d'une image. Plus le nombre de pixels dans une image est élevé, meilleure est la qualité de cette image.

### **1.4.2. Le codage de pixel**

Dans la pratique, la valeur d'un pixel est toujours désignée par un mot binaire, de longueur  $K$  bits pris entre 0 et  $2^K-1$ . La valeur  $K$  est appelée profondeur ou profondeur tonale de l'image. Toutes les valeurs prises par les pixels sont renseignées dans une matrice 2D, constituant l'image acquise finalement.

### **1.4.3. Taille d'une image**

Elle indique la longueur et la hauteur qu'une image occupe sur un écran. Elle s'exprime en pixel. La taille d'une image peut aussi désigner la résolution spatiale de l'image en photographie classique. Une image 256 x 256 contient au total 65536 pixels.

### **1.4.4. Résolution d'une image**

La résolution d'une image est la quantité de pixels composant l'écran. En imagerie, la résolution mesure la finesse de l'affichage ou de la capture d'une image. Elle s'exprime en pixel par pouce abrégé en PPP (Pixel Par Pouce où 1 pouce représente 2,54 cm) ou en DPI (Dots Per Inch, en anglais). Par exemple, une résolution de 256 dpi correspond à 256 colonnes et 256 rangées de pixels, soit au total 65536 pixels sur un pouce carré de surface. Cependant, plus la résolution d'une image est grande et meilleure est sa qualité (voir figure 1.3).




Figure 1-3: La résolution d'une image acquise : a) à 256 dpi, b) à 64 dpi, c) à 32 dpi [16]

La résolution est souvent confondue à la définition (taille) d'une image qui correspond au nombre de points constituant une image. Elle donne la " dimension " de cette image. Par exemple, une définition de 256 x 256 correspond à une image présentant 256 pixels en largeur, et 256 pixels en hauteur. La résolution permet ainsi d'établir le rapport entre la définition en pixels d'une image et la dimension réelle de sa représentation, sur un support physique.

#### 1.4.5. La luminance

La luminance correspond à l'éclat d'un objet et dépend de la sensibilité de l'œil humain. Elle définit le degré de luminosité de pixels dans l'image.

#### 1.4.6. Le bruit

Tous les systèmes traitant les images ne restituent pas l'image de manière parfaite ou identique à l'originale. On appelle bruit, toute information parasite qui s'ajoute, de manière aléatoire, à une image à l'instant de son acquisition jusqu'à son enregistrement. Ces perturbations dégradent la qualité de l'image. Les origines des bruits sont variées. Ils peuvent être produits en interne, on parle alors de « bruits de fond » ou d'origine externe ; dans ce cas, il s'agit de « parasites ». Ils peuvent aussi être produits par un système optique ou par des transformations réalisées sur l'image tel que le filtrage ou la compression. Quelle que soit l'origine du bruit, il provoque des effets semblables comme la perte de netteté sur les détails ou l'apparition de grains.

### 1.5. Les différents types d'images numériques

#### 1.5.1. Les images en niveaux de gris

Les images en niveaux de gris sont codées sur 8 bits dans lesquelles chaque pixel peut prendre l'une des valeurs de l'intervalle [0... 255] de niveaux de gris (au total  $2^8 = 256$  niveaux de gris), où la valeur 0 représente la brillance minimale, c'est-à-dire le noir ; 255 la brillance

maximale, c'est-à-dire le blanc. Ce type d'image est couramment utilisé pour reproduire les photos blanc noir ou les textes.

### 1.5.2. Les images noir et blanc

Les images binaires ou noir et blanc sont celles dont les pixels sont représentés par les deux (2) états logiques 0 (noir) et 1 (blanc). Ce codage de l'image est sur un (1) bit. Ce type d'image est en usage pour scanner un texte lorsque celui-ci est composé d'une seule couleur.

### 1.5.3. Les images couleurs

Depuis les travaux de Young, en 1802 [21], il a été mis en évidence que les images couleurs sont basées sur le mélange des trois (3) couleurs dites primaires : le Rouge, le Vert et le Bleu (R, V, B) en proportion unique. Chacune des composantes couleurs appelée « canal », a une longueur d'onde spécifique et codée sur 8 bits, dans un espace colorimétrique. Chaque pixel nécessite  $3 \times 8 = 24$  bits, pour coder les 3 composantes trichromatiques. Chaque composante couleur peut prendre l'une des valeurs de l'intervalle  $[0 \dots 255]$ . Enfin, chaque pixel d'une image couleur contient trois (3) nombres (R, V, B). Une image numérique couleur est ainsi composée de trois (3) images composantes et la couleur de chaque pixel est spécifiée dans un espace de couleur tridimensionnel, ce qui définit un système de coordonnées de couleur.



Image numérique couleur d'une fleur d'hibiscus



Canal Rouge

Canal Vert

Canal Bleu

Figure 1-4: Image numérique d'une fleur d'hibiscus dans les trois (3) canaux R, G, B [22]

---

#### 1.5.4. Les images multi-composantes

Ces images sont, en majorité, acquises dans plusieurs bandes spectrales ou modalités. Ces bandes sont généralement supérieures ou égales à trois ( $n \geq 3$ ) : il s'agit des images satellitaires multispectrales, des images hyperspectrales ou multimodales.

### 1.6. Les espaces de codage de couleur

La compréhension de l'information couleur est un problème complexe et ouvert. En imagerie, la manipulation des couleurs passe par le choix d'un espace de couleur. Le codage de la couleur, dans des images couleur, est effectué en utilisant divers espaces de représentation, appelés traditionnellement « espaces colorimétriques », lesquels espaces ont, pour la plupart, été construits en tenant compte des propriétés physiques, physiologiques ou psychologiques de la perception humaine de la couleur. La segmentation des images couleur a la capacité de présenter le résultat de manière très proche de la perception humaine. Le choix d'un espace de couleur adéquat est une question essentielle dans le processus de segmentation d'une image couleur et en analyse d'images, de façon générale. Il existe divers espaces colorimétriques dans la littérature. [23] les regroupe en trois (3) grandes familles : les espaces décorrélés, les espaces psychovisuels et les espaces perceptivement uniformes, tandis que les travaux réalisés par [24 - 26] les font en quatre (4) principales familles :

- Les systèmes de primaires, basés sur la théorie trichrome des récepteurs visuels de Young-Helmholtz, réduisent la perception de la couleur à la synthèse des trois (3) couleurs primaires.
- Les systèmes luminance-chrominance possèdent une composante appelée « luminance », permettant de quantifier la luminosité et deux (2) autres composantes de chrominance suffisantes pour quantifier le caractère chromatique d'une couleur.
- Les systèmes perceptuels sont basés sur nos propres sensations chromatiques. Ils quantifient la perception humaine, jugée subjective, de la couleur en la liant à la teinte, à la luminance et à la saturation.
- Les systèmes d'axes indépendants sont des systèmes de représentation de la couleur qui fonctionnent par application de l'Analyse à Composantes Principales (ACP) et de la transformation de Karhunen-Loeve sur les composantes de couleur dans le but de les décorréler ou les rendre indépendants.

La figure 1.5, ci-dessous, résume les différentes familles des espaces colorimétriques. Le paragraphe suivant étudiera dans le détail, mais brièvement, chacune des différentes familles sur la base des travaux de [27].

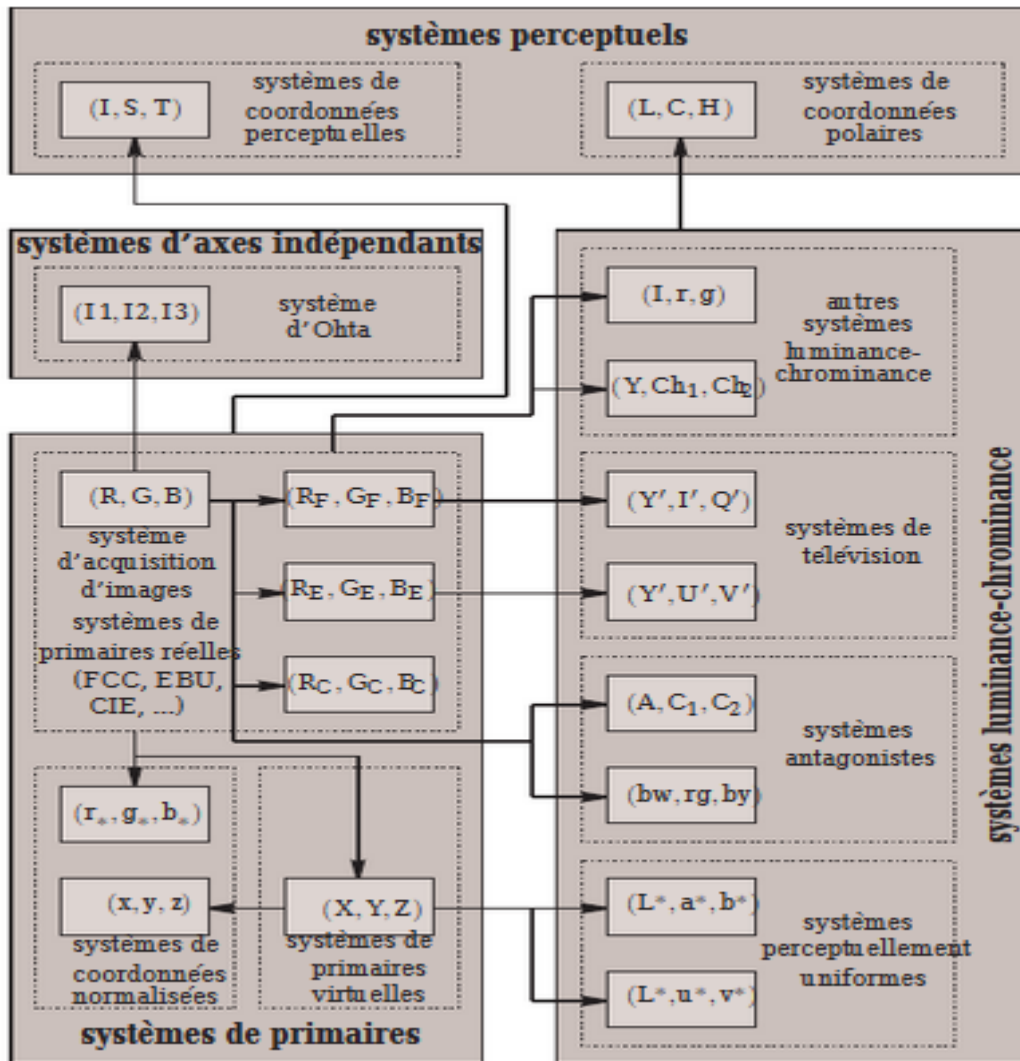


Figure 1-5: Les différentes familles de systèmes de représentation de la couleur [25]

Les rectangles colorés en gris représentent les quatre (4) différentes familles ; les flèches en noir indiquent les transformations présentées. Ces flèches relient, directement ou indirectement, chacun des systèmes présentés au système d'acquisition d'images (R, G, B). Dans chaque famille, il existe des sous-familles, représentées par des rectangles aux contours discontinus.

### 1.6.1. Les systèmes de primaires

Les espaces colorimétriques primaires sont basés sur la théorie trichromatique, consistant à déterminer n'importe quelle couleur, en mélangeant des quantités appropriées de trois (3) couleurs primaires.

#### 1.6.1.1. L'espace de couleur RVB (Rouge, Vert, Bleu)

L'espace de couleur RVB se fonde sur le modèle du tristimulus et dépend du périphérique. C'est un système de synthèse additive qui décompose les couleurs en trois (3) quantités de combinaison des trois (3) couleurs primaires : le Rouge, le Vert et le Bleu [28]. Les couleurs primaires sont standardisées depuis 1931 par la Commission Internationale d'Eclairage (CIE). Les longueurs d'ondes exactes pour les couleurs primaires, définies par la commission (CIE), sont 700 nm pour le rouge, 546,1 nm pour le vert et 435,8 nm pour le bleu. Il est possible d'obtenir des couleurs secondaires par addition des couleurs primaires. Le modèle de couleurs secondaires contenant ces trois (3) couleurs est nommé modèle CMJ (Cyan, Magenta et Jaune). Ce système est couramment utilisé dans les images couleur et les moniteurs. Le modèle RVB utilise le système de coordonnées cartésiennes. La diagonale qui lie le blanc (1,1,1) au noir (0,0,0) représente les niveaux de gris. Le modèle de couleur RVB peut être présenté dans un système de coordonnées cartésiennes comme l'indique la figure 1.6 ci-dessous.

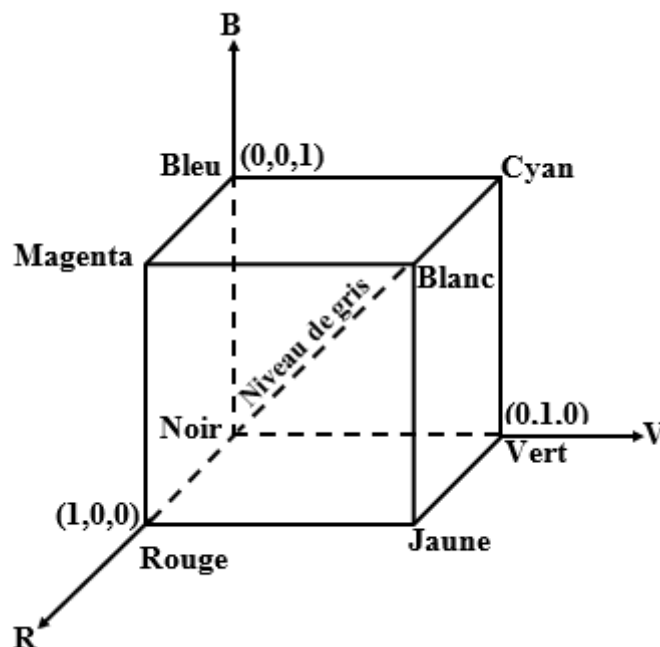


Figure 1-6: Représentation spatiale du modèle RVB [29]



---

### 1.6.1.2. L'espace de couleur XYZ

En 1931, la CIE a établi le système de référence pour pallier les inconvénients du système RVB afin d'avoir des fonctions colorimétriques à valeurs positives. Le système XYZ est obtenu par changement de primaire ou par l'intermédiaire d'une matrice de passage, à partir de n'importe quel système RVB. L'espace XYZ est donc obtenu par transformation linéaire de l'espace RVB et est indépendant du périphérique [30].

Les espaces couleurs primaires peuvent être normalisés en divisant la valeur de chaque composante couleur par la somme des valeurs des trois (3) composantes en vue d'obtenir des espaces de coordonnées normalisées tels que les espaces de couleur rvb [31] et xyz [30].

### 1.6.2. Les systèmes perceptuellement uniformes

Les espaces colorimétriques perceptuellement uniformes proposent une métrique pour établir une correspondance entre une différence de couleur perçue par un observateur humain et une distance mesurée dans l'espace colorimétrique [29].

#### 1.6.2.1. L'espace de couleur L\*u\*v\*

Des décennies plus tard, face au manque d'uniformité dans le système XYZ à savoir que deux (2) couleurs, à la même distance d'une autre, ne sont pas nécessairement perceptuellement équidistantes [32], la CIE a proposé un nouveau système tridimensionnel perceptuellement uniforme : le système CIELUV, encore appelé système (L\*u\*v\*). Dans ce système, le blanc de référence utilisé est alors caractérisé par ses composantes trichromatiques qui sont notées  $X_0$ ,  $Y_0$  et  $Z_0$  respectivement pour les primaires X, Y et Z. L'information de luminance correspond ici à la clarté qui, dans le vocabulaire de la CIE, représente la réponse de l'œil à un niveau de luminance. Les composantes de luminance et de chrominance sont données par les équations suivantes :

$$L^* = \begin{cases} 116 \times \sqrt[3]{\frac{Y}{Y_0}} - 16 & \text{si } \frac{Y}{Y_0} > 0.008856, \\ 903.3 \times \frac{Y}{Y_0} & \text{si } \frac{Y}{Y_0} \leq 0.008856. \end{cases} \quad (1.1)$$

$$u^* = 13 \times L^* \times (u' - u'_0), \quad (1.2)$$

$$v^* = 13 \times L^* \times (v' - v'_0), \quad (1.3)$$

$$\text{avec } u' = \frac{4X}{X + 15Y + 3Z} \quad \text{et } v' = \frac{9Y}{X + 15Y + 3Z}$$

$X_0$ ,  $Y_0$  et  $Z_0$  sont les composantes trichromatiques pour les primaires X et Y d'un blanc de référence.  $v'_0$  et  $u'_0$  sont les composantes de chrominances respectives correspondant  $v'$  et  $u'$  au blanc de référence.

### 1.6.2.2. L'espace de couleur $L^*a^*b^*$

En 1976, la CIE propose, dans le même temps, le système CIELAB ou l'espace  $L^*a^*b^*$ , basé sur le modèle des couleurs opposées et établit par les relations non linéaires à partir des primaires X, Y et Z. La variable  $L^*$  mesure l'information de la luminance (l'opposition noir-blanc) ou de clarté par une valeur entre 0 (noir) et 100 (blanc) (équation 1.1). Les composantes de chrominance indiquées par les variables  $a^*$  et  $b^*$  sont données par les équations 1.4 et 1.5.

$$a^* = 500 \times \left( f\left(\frac{X}{X_0}\right) - f\left(\frac{Y}{Y_0}\right) \right), \quad (1.4)$$

$$b^* = 200 \times \left( f\left(\frac{Y}{Y_0}\right) - f\left(\frac{Z}{Z_0}\right) \right), \quad (1.5)$$

$$\text{avec } f(x) = \begin{cases} \sqrt[3]{x} & \text{si } x > 0.008856, \\ 7.787x + \frac{16}{116} & \text{si non} \end{cases}$$

Ici, l'information de luminance est indépendante de l'information de chrominance. Le système  $L^*a^*b^*$  est aussi un système perceptuellement uniforme c'est-à-dire que les écarts de couleur dans cet espace sont les mêmes que les écarts de couleur de la perception humaine. Sa représentation spatiale est donnée par une sphère (figure 1.7).




Figure 1-7: Représentation spatiale de l'espace  $L^*a^*b^*$  [27]

### 1.6.3. Les systèmes perceptuels

Les espaces colorimétriques perceptuels quantifient la perception humaine de la couleur [30]. Dérivé d'une synthèse soustractive, l'espace de couleur TSL (Teinte, Saturation, Luminosité) et ses dérivés HSI (Hue, Saturation, Intensity) et HSV (Hue, Saturation, Value) sont basés sur les trois (3) grandeurs physiologiques complémentaires : la teinte, la saturation et la luminance. Ces trois (3) composantes de l'espace colorimétrique TSL peuvent ainsi se définir :

- La luminance caractérise l'énergie ou l'intensité de la lumière perçue par l'observateur, indépendamment de la couleur. Elle s'exprime en lumen (lm) et s'oriente du bas vers le haut, c'est-à-dire du noir au blanc.
- La teinte caractérise la dominance de la couleur perçue. Dans l'espace de couleur TSL, elle est calculée à partir de la position angulaire de l'axe central où les six (06) principales valeurs sont le rouge à  $0^\circ$  ou  $360^\circ$ , le jaune à  $60^\circ$ , le vert à  $120^\circ$ , le cyan à  $180^\circ$ , le bleu à  $240^\circ$  et le magenta à  $300^\circ$ .
- La saturation indique la pureté de la teinte dominante. La distance séparant l'axe central et les périphériques donne la valeur de saturation qui croît en allant vers la périphérie.

Tandis que la luminance et la saturation sont codées classiquement par des valeurs scalaires, la teinte est, pour sa part, angulaire. L'avantage majeur de ces espaces est la séparation distincte de la composante luminance des composantes chromatiques. Ces espaces sont dérivés de

l'espace RGB et sont décrits par les équations suivantes, dans le modèle de cône hexagonal [25].

$$T = \begin{cases} \frac{G-B}{V - \min(R, G, B)} & \text{si } V = R, \\ 2 + \frac{B-R}{V - \min(R, G, B)} & \text{si } V = G, \\ 4 + \frac{R-G}{V - \min(R, G, B)} & \text{si } V = B \end{cases} \quad (1.6)$$

$$S = 1 - \frac{\min(R, G, B)}{V} \quad (1.7)$$

$$V = \max(R, G, B) \quad (1.8)$$

La représentation de cet espace, dans l'espace euclidien RGB, est donnée à la figure 1.8.




Figure 1-8: Représentation spatiale du modèle cylindrique de l'espace HSL ou HSV [25]

#### 1.6.4. Les systèmes d'axes indépendants

Les systèmes d'axes indépendants ( $I_1 I_2 I_3$ ) corrigent l'inconvénient majeur des autres systèmes dont toutes les composantes sont plus ou moins corrélées. Son but est d'établir une décorrélation complète entre les composantes de couleur afin de les rendre toutes indépendantes. Plusieurs auteurs ont déterminé des systèmes de représentation de la couleur aux composantes indépendantes et portent des informations distinctes. L'une des solutions consiste à réaliser l'analyse en composantes principales (ACP) d'un système de représentation ; par la suite réaliser la transformation de Karhnen-Loeve et rendre les composantes moins corrélées. Dans ce travail, nous ne présentons pas le détail de cette transformation et autres transformations

possibles de même que les systèmes qui en découlent. Le lecteur intéressé, pourra consulter [25].

### 1.6.5. Les espaces hybrides

Ces espaces colorimétriques sont construits en combinant les composantes chromatiques des systèmes luminance-chrominances aux composantes des systèmes de primaire [33].

### 1.6.6. Les espaces multidimensionnels

Les espaces multidimensionnels sont utilisés dans la représentation des images multicomposantes ( $n \geq 3$ ) c'est-à-dire les images multispectrales, hyperspectrales et multimodales en fausses couleurs. L'ordre des composantes n'a pas de sens dans ce cas. Cependant, le choix des composantes retenues est lié à leurs pertinences qui, elles, dépendent de la bande spectrale ou de la modalité.

Une image couleur peut ainsi être représentée dans ces différents espaces de couleur. La figure 1.9 illustre l'image des feuilles codée en RVB (a),  $L^*a^*b^*$  (b),  $I_1I_2I_3$  (c) puis en HSV (d).




Figure 1-9: Exemple d'images codées dans différents espaces de couleur

Visuellement, les différents espaces colorimétriques donnent différentes représentations de la même image. Cependant, ces différences pourraient, dans une certaine mesure, être intéressantes car permettent d'analyser une même texture sous différents points de vue ; ce qui augmente les possibilités de représentation précise des textures couleurs.

## 1.7. Formats de fichier d'images

Un format de fichier d'images est un moyen normalisé d'organisation et de stockage des images numériques. Un fichier d'images numériques est composé de données numériques dans l'un de ces formats. Il peut être pixellisé et utilisé sur un écran d'ordinateur ou une imprimante. La plupart des formats sont composés d'un en-tête de fichier contenant des attributs (dimension de l'image, type de codage, LUT, etc.), suivi des données (l'image proprement dite). La structuration des attributs et des données diffère d'un format à un autre. Il existe plusieurs types de formats d'images et se distinguent par leur variation, selon la profondeur des pixels, l'espace colorimétrique, le support de compression. Nous présentons, dans le tableau 1.1, les

Tableau 1-1: Tableau comparatif des caractéristiques des formats d'images [43]

BMP	<p><b>Description</b> : BMP a été largement utilisé sur la plate-forme Windows. Bien que prenant en charge la compression de données et les canaux alpha, ces fonctionnalités n'ont pas été largement utilisées car n'étaient pas prises en charge par tous les éditeurs d'images.</p> <p><b>Avantages</b> : -Non compressé pour des images parfaites - Compatibilité quasi universelle -Compression efficace (ZIP, etc.)</p> <p><b>Inconvénients</b> : Grande taille de fichier</p> <p><b>Utilisations</b> : Pour édition d'image</p>
GIF	<p><b>Description</b> : GIF est un format d'image bitmap permettant une compression sans perte, en réduisant l'image à 256 couleurs distinctes. Il fut remplacé par la PNG, après la peur suscitée par les problèmes de brevets. Il est beaucoup utilisé pour l'animation : c'est un seul format prenant en charge l'animation et assez pris en charge par les navigateurs.</p> <p><b>Avantages</b> : -Animations simples / clips vidéo courts - Format largement supporté -Support de transparence - Compression sans perte - Taille de fichier réduite.</p> <p><b>Inconvénients</b> : -Limité à 256 couleurs -Couleurs Web uniquement -Pas de transparence</p> <p><b>Utilisations</b> : Animation ; Graphiques web simples.</p>
JPEG	<p><b>Description</b> : JPEG est le format d'image le plus couramment usité par les appareils photos numériques. Il s'agit du format le plus courant pour le stockage et la transmission d'images photographiques sur le World Wide Web.</p> <p><b>Avantages</b> : -Petite taille de fichier. - Format largement supporté. - Compatibilité -Bonne gamme de couleurs</p> <p><b>Inconvénients</b> : -La compression avec perte -Pas génial pour le texte, les graphiques simples ou les illustrations.</p> <p><b>Utilisations</b> : -Les images photographiques par voie électronique et sur le Web -La photographie -Impression de photographies.</p>
PNG	<p><b>Description</b> : PNG a été créé pour améliorer le format de fichier image GIF, éliminer les problèmes de licence de brevet à ce moment-là ; et en supprimant la limite de 256 couleurs.</p> <p><b>Avantages</b> : -Format largement accepté - Sans perte - Support de transparence.</p> <p><b>Inconvénients</b> : -Les fichiers image plus complexes et volumineux peuvent être volumineux - Prend en charge uniquement les couleurs Web (RVB) - Compatibilité limitée.</p> <p><b>Utilisations</b> : - Les icônes - Graphiques Web simples comme des logos - Illustrations ou rendu de texte matriciel.</p>
TIFF	<p><b>Description</b> : TIFF permet de stocker des images sans perte. Il est largement pris en charge par les applications de manipulations d'images : la numérisation, la télécopie, le traitement de texte, la reconnaissance optique de caractères et d'autres applications.</p> <p><b>Avantages</b> : -Sans perte -Image de haute qualité -Compatible avec les PC et les MAC - Plusieurs images et pages peuvent être enregistrées dans un seul fichier.</p> <p><b>Inconvénients</b> : -Grand fichier -Pas génial pour les graphiques web -Problèmes mineurs de compatibilité logicielle.</p> <p><b>Utilisations</b> : -Images du scanner - Imagerie HD - Travailler avec des photographies, sans perte de qualité d'image.</p>
JPEG 2000	<p><b>Description</b> : C'est une amélioration de la norme JPEG. Il supporte la transparence, stocke des données, sans perte. C'est aussi avoir un meilleur niveau de compression. Non pris en charge par plusieurs navigateurs, il n'a pas été largement utilisé sur internet.</p> <p><b>Avantage</b> : Petite taille de fichier</p> <p><b>Inconvénient</b> : Processeur intensif</p> <p><b>Utilisations</b> : Remplacement JPEG ; imagerie HD</p>

---

caractéristiques de quelques-uns des fichiers d'images les plus fréquemment utilisés en traitement d'images. De cette comparaison, nous constatons que, dans le cadre de nos travaux, le format TIFF offre la plus grande liberté en termes de structure et de représentation.

## 1.8. Synthèse

Plusieurs autres systèmes d'espaces colorimétriques existent. Nous avons énuméré seulement les espaces colorimétriques couramment utilisés en traitement d'images, particulièrement en analyse des images de roches. La pluralité et la diversification des espaces colorimétriques rendent difficiles leur regroupement en différentes familles. Cette tâche est rendue plus difficile par manque de propriétés communes. Par exemple, [18] suggère que les espaces colorimétriques soient classés en tant qu'espaces colorimétriques dépendant du périphérique (RVB, HSV, ..., etc) et indépendant du périphérique ( $L^*a^*b^*$ ). D'autres comme Ohta [35] les regroupent en systèmes correspondant à des transformations linéaires et des systèmes de transformation non linéaires. L'article [36] donne des informations complémentaires sur le sujet. En parcourant la littérature, il a été démontré que le choix d'un espace colorimétrique, dans le cadre du traitement d'images, est crucial et influence directement le résultat du traitement [37]. Cependant, ce choix est ardu par la multitude d'espaces colorimétriques existants et reste une question ouverte.

Dans le cadre de la segmentation d'images couleurs, il n'existe pas d'espace colorimétrique mieux adapté à un type d'image [38]. Le meilleur choix dépend des caractéristiques de l'image à analyser d'une part, de la méthode utilisée et de l'objectif visé, d'autre part. Pour la segmentation de l'image couleur, les recherches sont de plus en plus orientées vers les espaces de couleur hybride qui apparaissent plus discriminants vis-à-vis des classes colorimétriques en présence [39]. Notre choix se fera au chapitre suivant, avec les raisons qui le motivent. Notons que les chercheurs, en collaboration avec la CIE, continuent de travailler sur cette thématique, devenue, sujet de débat dans le domaine du traitement d'images [40].

## 1.9. Les chaînes de traitement d'images

Le traitement d'images est, de nos jours, l'une des grandes orientations du traitement de l'information acquise à partir des capteurs offrant des capacités de plus en plus importantes [41]. Les chaînes de traitement d'images contiennent un ensemble de méthodes ou de techniques ayant pour objectifs, soit de transformer des images afin d'améliorer l'apparence, ou les coder de manière plus compacte en vue d'une transmission, soit d'en extraire de l'information pour une application quelconque.

---

Une chaîne de traitement commence par l'acquisition de données physiques, sous la forme d'une image. Cette image peut être :

- Soit numérique, c'est-à-dire obtenue par des systèmes d'acquisition numériques (caméra, CCD, capteur CMOS, etc.).
- Soit analogique, d'où la nécessité de passer par une étape de numérisation avant tout traitement informatique.

D'une manière générale, le processus dans une chaîne de traitement comprend trois (3) étapes essentielles : l'étape de prétraitement, l'étape de traitement, puis le post-traitement permettant de prendre une décision et peuvent être imagées à travers la figure 1.10:

- L'étape de prétraitement réside dans l'amélioration de la qualité de l'image acquise. Cette étape consiste à préparer l'image au traitement et à l'analyse. Il peut s'agir d'éliminer le bruit ou de rehausser le contraste.

- L'étape suivante est celle de la segmentation. C'est l'étape primordiale en traitement d'image. Elle consiste à extraire de l'image, certaines régions d'intérêt pour l'inspection. De cette façon, l'objet à classer est isolé des autres objets et du fond de l'image. Cette étape peut être suivie par le post-traitement dont l'objectif est d'affiner la segmentation afin d'améliorer les résultats obtenus.

- La troisième étape est l'extraction de caractéristiques ayant pour but de caractériser l'objet à reconnaître, en utilisant des mesures dont les valeurs sont très similaires aux objets de la même catégorie et également très différentes des objets de catégories différentes [42]. Les caractéristiques forment souvent des vecteurs de caractéristiques, aussi appelés descripteurs, capables de décrire le contenu de l'image.

- La quatrième étape est la classification. L'idée de la classification est d'attribuer l'image inconnue à l'une des catégories. Si des catégories prédéfinies sont utilisées, la classification est dite supervisée, si non elle est non supervisée.

- Enfin, au stade du post-traitement, le résultat de la classification peut être estimé à l'aide de différentes méthodes de validation. L'interprétation et la décision suivront. Elles consisteront à extraire l'information sémantique de l'image en identifiant les différents objets qui la constituent et décider d'une action à engager.



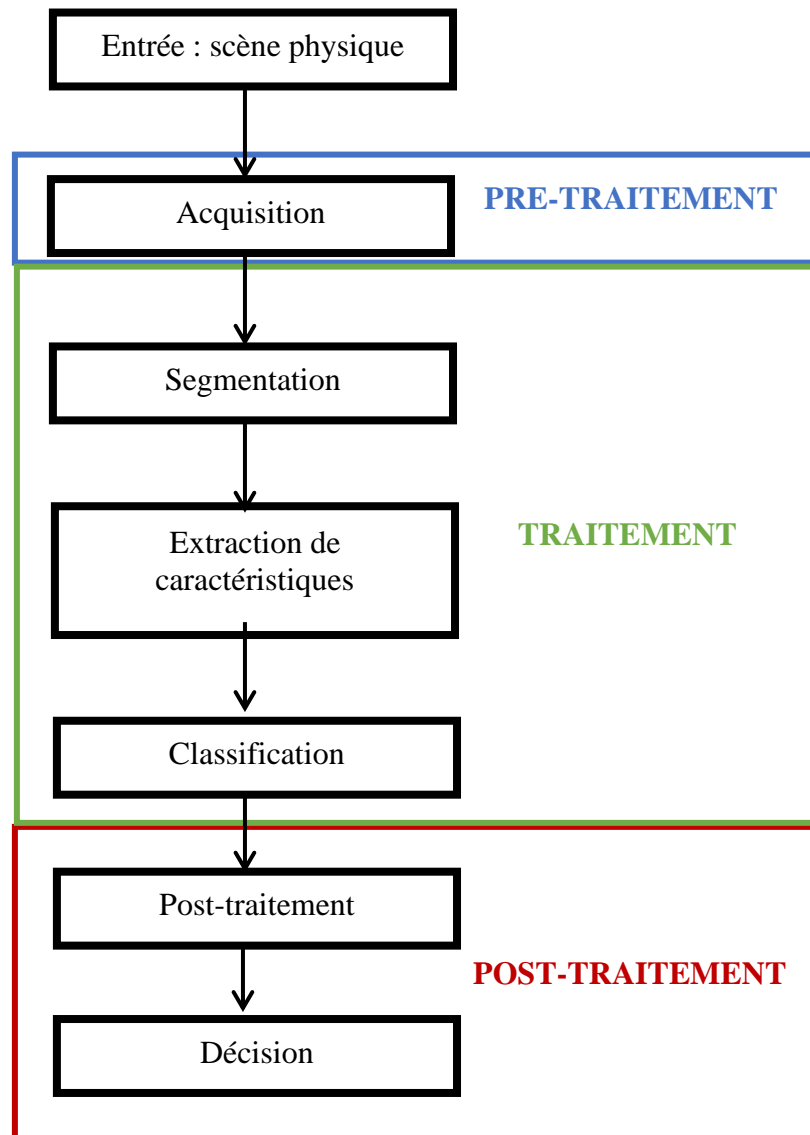


Figure 1-10 : Chaîne de traitement d'images [42]

## 1.10. Quelques traitements d'images

Dans cette section, nous nous intéressons à quelques traitements d'images souvent rencontrés dans l'analyse des images. Nous détaillerons par la suite les différentes méthodes de segmentation des images couleur.

### 1.10.1. La segmentation d'images

L'objectif principal de la segmentation d'images est d'extraire diverses caractéristiques de l'image pouvant être fusionnées ou redistribuées, afin de créer des objets d'intérêt sur lesquels l'analyse et l'interprétation peuvent être portées. La segmentation d'images consiste à diviser une image en segments ou régions significatives, en fonction de certaines caractéristiques

---

comme le niveau de gris, le spectre, la texture, la couleur, etc [44]. En fait, les partitions sont des objets différents dans l'image ayant la même texture et/ou couleur. La segmentation d'images se présente comme l'étape primordiale de l'analyse des images et d'extraction de données, à partir des images numériques. Elle demeure un domaine de recherche actif, vu son rôle fondamental et son application très répandue. [45] met en évidence les principes de base de la segmentation, avec différentes techniques de segmentation variée et étendue. Les techniques de traitement ont pour objectif premier la recherche d'une amélioration des images, en vue d'une analyse visuelle ultérieure plus fine. Le choix d'une technique de segmentation se fait sur la base de la nature de l'image et des objectifs poursuivis. La segmentation est un sujet complexe et suscite un intérêt soutenu chez les chercheurs. Plusieurs techniques de segmentation d'images existent dans la littérature. Fondamentalement, on peut les regrouper en deux (2) grandes catégories avec pour critères la similarité et la discontinuité : la segmentation basée sur la détection de discontinuité et la segmentation basée sur la détection de similarité.

### **1.10.2. Segmentation basée sur la détection de discontinuité**

Les méthodes basées sur la détection de discontinuité sont des approches axées sur les régions de discontinuité pour la segmentation d'une image. Ces méthodes recherchent les changements brusques d'intensité indiquant les discontinuités dans l'image. Ces méthodes sont assez utilisées en reconnaissance d'objets, dans les applications telles que le traitement d'images médicales, la biométrie, etc. Les méthodes de détection de discontinuité incluent des opérateurs de détection de contours et sont regroupés en deux (2) classes : les dérivées de 1<sup>er</sup> ordre comme l'opérateur de Prewitt, l'opérateur de Sobel, l'opérateur de canny ; et les dérivées de second ordre tel que l'opérateur Laplacien, l'opérateur de passage à zéro.

#### **1.10.2.1. Segmentation basée sur la détection de similarité**

Les méthodes de détection de similarité sont focalisées sur la recherche des régions similaires, continues où les intensités sont communes au sein des pixels voisins. Ces méthodes sont susceptibles d'être utilisées pour regrouper les données. Les algorithmes de segmentation fondés sur la similarité sont relativement simples et plus robustes au bruit. Les algorithmes de segmentation par région sont nombreux. Les approches division-fusion des régions, les techniques de seuillage, approche par croissance de région, etc en sont des exemples.

Cependant, une étude plus détaillée des techniques de segmentation est faite dans [19, 44- 46]. Les auteurs y présentent trois (3) regroupements en perspective, pour mieux comprendre ces différentes méthodes :

- 
- Approche par région : c'est une approche de segmentation basée sur la détection de similarité.
  - Approche de détection de contours : elle est une approche de segmentation par détection de discontinuité.
  - Approche de clustering de données : Ici, c'est une approche de segmentation reposant sur la détection de similarité

Nous définirons quelques-unes de ces méthodes qui nous serviront de support pour la suite de nos travaux, dans le cadre de la reconnaissance des roches. Il s'agit de l'approche par seuillage, approche par filtrage, approche par histogramme.

### **1.10.2.2. Seuillage d'une image**

La méthode de seuillage est une méthode de segmentation basée sur la région. Elle est la plus simple, la plus répandue et la plus utilisée pour la segmentation des images. Son essence est de déterminer automatiquement le seuil optimal en fonction d'un certains critères et d'utiliser ces pixels en fonction du niveau de gris pour réaliser le regroupement. L'algorithme de segmentation de seuil le plus couramment utilisé est la méthode de variance d'interclasse d'OTSU [47]. Une flopée de méthodes de seuillage existe dans la littérature : les méthodes de segmentation de seuil basée sur l'entropie, la méthode d'erreur minimale, la méthode de matrice de co-occurrence, les méthodes statistiques simples. L'opérateur LBP (Local Binary Pattern) s'appuie sur cette technique pour produire une nouvelle texture de l'image à partir d'une image initiale.

### **1.10.3. Filtrage d'une image**

Ce terme, emprunté au traitement de signal et à la physique, est aujourd'hui une opération fondamentale en traitement d'images. Le filtrage a pour but de nettoyer et d'améliorer l'aspect (en accentuant le détail par exemple) ou certaines dégradations d'une image numérique en éliminant par exemple l'effet des perturbations, sans modifier les informations essentielles de l'image (contours, dynamique, textures etc.). Dans la pratique, il s'agit de la création d'une nouvelle image sur la base des informations de l'image d'origine afin de faciliter son analyse. Les méthodes de filtrage peuvent être classées en deux (2) groupes : les méthodes de filtrage linéaire et les méthodes de filtrage non linéaire. Le choix d'une technique de filtrage dépend du type de bruit à atténuer. Un filtre non-linéaire est un opérateur qui donne une valeur à un pixel de l'image en utilisant une combinaison non-linéaire des valeurs des pixels voisins (filtre

---

médian, filtre de Perona et Malik). Un filtre linéaire résulte d'une opération de convolution (filtre de Sobel, filtre Gaussien, etc) ou d'une transformation mathématique permettant de modifier la valeur des pixels voisins. C'est un système linéaire continu qui vérifie les propriétés de causalité et d'invariance temporelle.

### **1.11. Conclusion partielle**

Le traitement d'images, dans son essence, consiste à appliquer des transformations mathématiques sur des images, dans le but d'améliorer leur qualité ou d'en extraire une information jugée pertinente. Pour y parvenir, nous avons, présenté, dans ce premier chapitre, de manière succincte, les différents types d'images et différents espaces colorimétriques de la littérature couramment utilisés dans le cadre de la reconnaissance des structures géologiques et leurs caractéristiques détaillées. Nous avons par la suite présenté les différents concepts fondamentaux liés à l'image numérique, ses différents formats et quelques traitements de ces images numériques rencontrés souvent en traitement d'image dont l'étape fondamentale est l'étape de segmentation. Nous avons également introduit les méthodes de segmentation traitées dans la littérature, vu leur importance pour l'extraction des caractéristiques discriminantes de l'image étant entendu que ces méthodes de segmentation nous seront d'un apport capital dans le processus d'une meilleure reconnaissance des roches. Il faut retenir que, bien que la segmentation permette d'identifier les contours ou les régions, elle entraîne une réduction de la quantité d'informations nécessaire pour la description de l'image.

## Chapitre 2 Etat de l'art sur les méthodes d'analyse et de traitement des images de roche

*Ce chapitre présente une généralité sur les roches et les méthodes permettant de les classifier géologiquement. Il présente aussi les principales méthodes d'extraction de caractéristiques et les différentes méthodes de classification automatique des roches. L'importance de la texture et de la couleur comme éléments fondamentaux dans l'analyse et le traitement des roches est mise en exergue. L'accent a été focalisé sur les méthodes statistiques et fréquentielles pour l'extraction des caractéristiques. Ce chapitre se termine par un état de l'art sur les représentations parcimonieuses des signaux avec K-SVD.*

### 2.1. Introduction

A notre époque, avec la réduction du coût des appareils technologiques numériques (scanners, caméras, appareils photos, etc) et le développement des méthodes de traitement et d'analyse d'images, l'utilisation de l'image numérique a connu une ascension dans divers domaines de la vie. Désormais, il est courant d'utiliser les outils d'imagerie dans divers domaines nécessitant naguère une inspection et une surveillance manuelles. En science, particulièrement en géologie, l'image est devenue un outil indispensable et un précieux moyen d'analyse des phénomènes (structures géologiques). On trouve dans cette gamme d'images, des images satellitaires, des photographies aériennes, des images tomographiques, des images sismiques, des images de vue de terrains, des images d'échantillons de roches, etc. Ces images numérisées sont issues de différents appareils dédiés, ayant des caractéristiques diverses et variées. Les méthodes d'analyse et de traitement d'images sont largement utilisées dans diverses tâches de surveillance et d'analyse dans les domaines tels que la médecine, le contrôle qualité, la sécurité, la télécommunication, la télédétection. Comparée à la classification et à l'inspection manuelle, l'utilisation des méthodes d'analyse d'images automatisées pour ces tâches, fournit plus d'avantages et s'avère bénéfique. Elles réduisent la fatigue, la part de subjectivité due au rôle central joué par l'homme dans ce processus et font gagner énormément du temps.

De ce qui précède, l'analyse précise et automatique des images de textures de la roche est perçue par la communauté scientifique comme une tâche très importante [48-58] et innovante pour la géologie moderne en général, la pétrographie en particulier. Cependant, les images de roches ainsi que la plupart des images naturelles telles que les nuages, le brouillard, les végétations ou la glace, sont rarement homogènes, rendant souvent leur classification ardue et problématique.

En effet, les propriétés de couleur, de texture et de forme de la roche peuvent varier considérablement, même avec le même type de roche.

Dans le cadre de notre étude, nous nous intéressons à l'analyse automatique des roches, utilisant comme objets des images de vue directes d'échantillons de roches magmatiques et métamorphiques. Généralement, dans la reconnaissance manuelle, les roches sont classées par composition chimique et minéralogique, par propriétés physiques et radiométriques (couleur et textures) ou par origine de formation (genèse) [48,54]. Sur la base de ces différents critères, les roches sont classées en trois (3) grandes familles : les roches magmatiques, les roches métamorphiques et les roches sédimentaires. Ce chapitre présente les principales méthodes d'extraction de caractéristiques (texture et/ou couleur) et de classification automatique de roche rencontrées dans la littérature. Ces méthodes sont, pour la plupart, appliquées pour l'identification des minéraux à partir des images microscopiques, en LPA ou LPNA, de lames minces d'échantillon de roches [7, 49, 50]. Rares sont les travaux réalisés sur les images macroscopiques [51, 53, 54].

## **2.2. Généralité sur les roches**

### **2.2.1. La classification géologique des roches**

La classification des roches est un problème inhérent à la géologie, singulièrement à la pétrographie. Si la géologie regroupe l'ensemble des sciences de la terre qui étudient et identifient les roches et les minéraux, la pétrographie, elle, est spécifiquement la science ayant pour objet de décrire, d'étudier et de classer les roches. Une roche se définit comme un agencement de minéraux les uns par rapport aux autres, avec une disposition, une architecture et une forme particulière. Le géologue distingue deux (2) grandes catégories de roches de part de leur origine : les roches exogènes (origine extérieure) opposées aux roches endogènes (origine intérieure). Dans les roches magmatiques par exemple, c'est encore la genèse qui a conduit à la séparation des roches plutoniques et des roches volcaniques. La figure 2-1 ci-après présente une classification synthétique permettant d'aboutir à ces deux (2) catégories de roches.

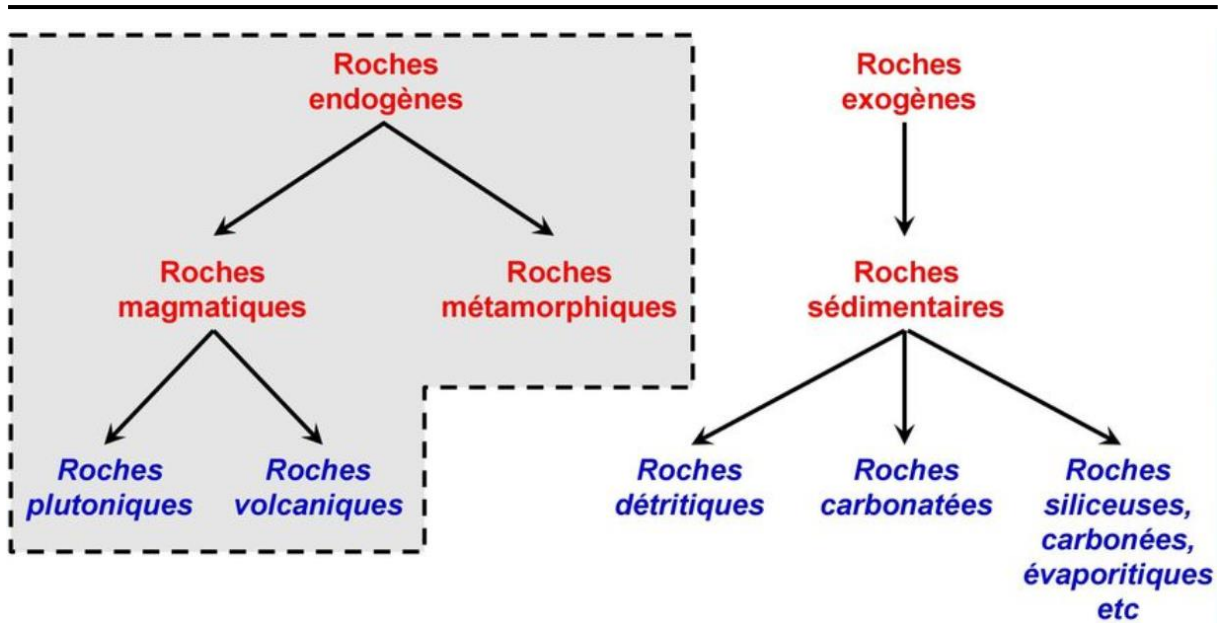


Figure 2-1: Les différents types de roches

La classification des roches n'est pas une tâche aisée car repose sur de nombreux critères. En première approximation, la classification des roches, faite par les géologues, se base sur l'origine et les conditions géologiques de la formation ou genèse des roches. On distingue, à cet effet, trois (3) types de roches : les roches sédimentaires (66%), les roches métamorphiques et les roches magmatiques (34%) [59]. L'encadré, en traits discontinus sur la figure 2-1, indique les deux familles de roches sur lesquelles notre étude va porter.

Une multitude de méthodes de classification ont été proposées sur les bases :

- D'observations visuelles texturales et/ou colorimétrique
- Chimiques : analyse ou composition chimique par le diagramme de TAS (Total Alkali Silica : Teneur total de Silice Alcalin) [60- 62] pour les roches magmatiques.
- Minéralogique : analyse minéralogique basée sur les proportions des minéraux obtenus (les plus abondants sont choisis) à partir du compteur de points et du diagramme de Streckeisen par exemple.
- Mixte : analyse géochimique

L'IUGS (International Union of Geological Sciences) recommande la classification basée sur les bases chimiques et minéralogiques [61, 62]. Le géologue ou le pétrographe use beaucoup de temps à identifier les roches et à faire une classification. La figure suivante présente les trois (3) différentes familles de roches et le processus conduisant à leur formation, appelé : « le cycle géologique des roches ».

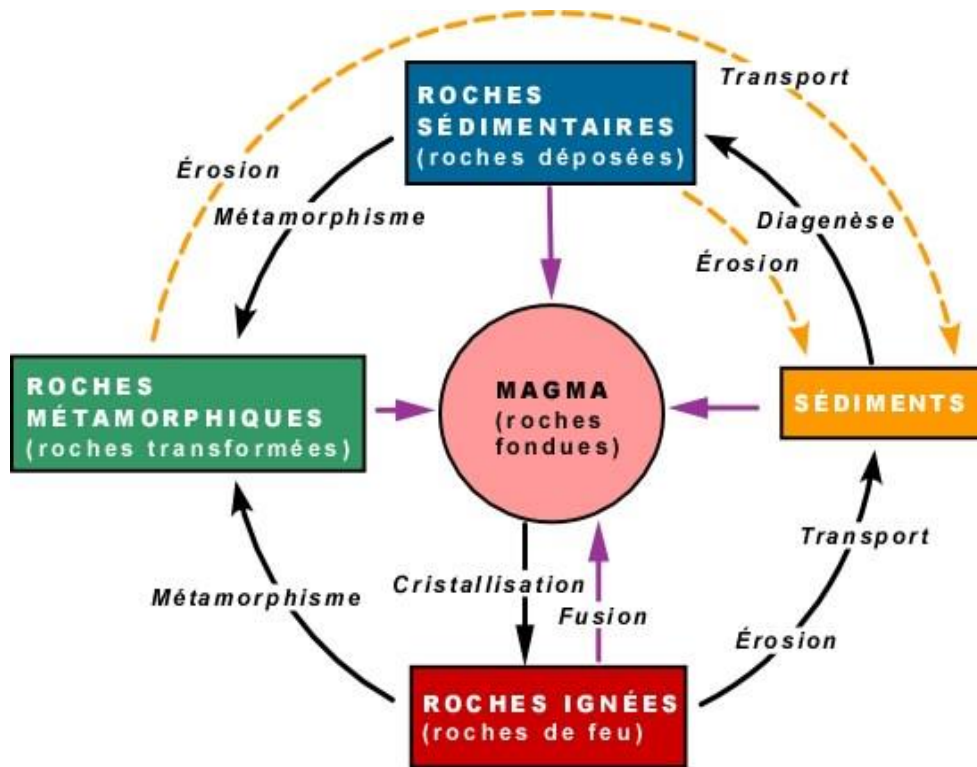


Figure 2-2: Cycle géologique des roches [59]

Les paragraphes suivants définissent brièvement les trois (3) différentes familles de roches en donnant un exemple pour chaque famille de roche. Notre étude sera fondée sur les deux (2) premières familles de roches encadrées en traits discontinus à la *figure 2-1*.

### 2.2.2. Les roches magmatiques

Les roches magmatiques se forment lorsque les roches fondues appelées magma ou lave, se refroidissent après leur intrusion dans la croûte terrestre [59]. On distingue :

- Les roches plutoniques qui se forment quand le magma refroidit lentement en profondeur avec des cristaux bien visibles (exemple du granite).
- Les roches volcaniques se forment lorsque le magma arrive rapidement à la surface de la terre par une cheminée volcanique (exemple du basalte).

### 2.2.3. Les roches métamorphiques

Une roche métamorphique se forme sous la surface de la terre suite à une métamorphose d'une vieille roche qui peut être ignée, métamorphique ou sédimentaire, exposée à une intense chaleur et/ou forte pression (exemple des marbres).



#### **2.2.4. Les roches sédimentaires**

Les roches sédimentaires se forment lorsque les débris d'origine minérale (dégradation de d'autres roches), organique (restes de végétaux ou d'animaux, fossiles) ou de précipitation chimique, sont accumulés ou compactés à la surface de la terre ou au fond des eaux (Exemple du calcaire), à des températures et pressions relativement basses [63].

#### **2.2.5. Importance des roches**

Les roches sont présentes dans notre quotidien, sous plusieurs formes, avec divers usages. Elles sont utilisées dans la construction d'habitations et des monuments, la fabrication du goudron, l'embellissement des façades de maison et salles de bain, etc. Elles permettent également de comprendre l'histoire géologique d'un site.

### **2.3. Systèmes d'acquisition des images de texture de roches**

Il existe plusieurs types de systèmes d'acquisition des images de texture. Actuellement, les applications en imagerie se basent sur les images numériques obtenues à partir des appareils photos numériques, des scanners ou des caméras CCD ou CMOS par exemple. Dans les applications géo-ingénieries, différents types de scanners ont permis l'acquisition de routine en ingénierie souterraine [48]. Les images de roches, utilisées dans notre thèse, furent prises sur les sites [64] et [65]. Ces images capturées dans l'espace colorimétrique RGB, ont été rognées à la taille de 256x256, enregistrées puis sauvegardées au format TIFF pour sa qualité inestimable de stockage sans perte d'information.


### **2.4. Caractéristiques de texture et couleur des images de roches**

#### **2.4.1. Différents types de textures**


En traitement d'images, l'analyse de la texture est primordiale. Elle sert à identifier les objets dans l'image. Malgré son importance, il est difficile de la caractériser de façon précise. On distingue deux (2) types de texture : les textures naturelles et les textures artificielles. Quantité de types de propriétés physiques de la roche peuvent être estimés à partir de la texture. Toutefois, certaines propriétés particulières à la roche complexifient le travail d'analyse. La plus importante d'entre elles est la non-homogénéité des images de texture de roches [57]. Cette section examine l'importance de la texture des images de roches.

Sans nul doute, la texture est l'une des plus importantes caractéristiques de l'image des roches. La majorité des algorithmes de segmentation s'appuie sur la texture pour segmenter les images en régions ou en objets distincts. La classification et la reconnaissance des différentes surfaces

sont souvent basées sur les propriétés de texture. Dans [66], Van Gool et al. en 1985, ont classé les textures en deux (2) catégories : les textures stochastiques opposées aux textures déterministes [67]. Pour eux, une texture déterministe se caractérise par des motifs ou primitives de base ou encore élément de texture (texel en anglais ou appelé textons par Julesz [68]) se répétant de manière ordonnée ou régulière. Les auteurs affirment que la quasi-totalité des textures présentes dans la nature sont des textures stochastiques ; dans ces textures, les motifs n'obéissent à aucune loi statistique : On les appelle des macro-textures. A l'opposé, les micro-textures ou les textures stochastiques ont un contenu irrégulier, avec des motifs parfois difficiles à extraire. Contrairement aux textures déterministes, les textures stochastiques ou probabilistes ou encore aléatoires (observations microscopiques) sont décrites par des lois statistiques. Ce type de textures montre un aspect désordonné tout en apparaissant globalement homogène. On peut distinguer un autre type de textures pour lequel la texture n'est pas totalement aléatoire et n'est pas aussi déterministe. Ce type de texture se caractérise essentiellement par certaines orientations. La figure 2.3 ci-dessous présente des échantillons de texture de l'album Brodatz [69] dans lequel un tissu de laine et un mur de briques illustrent des textures déterministes, tandis que l'herbe et l'écorce sont des exemples de textures stochastiques. Ces textures sont homogènes, contrairement aux textures d'images de roches qui sont non-homogènes. La figure 2.4 montre des exemples de textures naturelles.



*Figure 2-3: Exemples de texture de l'album de Brodatz [69]*



*Figure 2-4: Exemples de textures naturelles [70]*

Haralick [67, 71], l'un des pionniers dans l'analyse et la classification des textures avec la matrice de co-occurrence, compare la texture d'une image à la structure des atomes qui

constituent la matière. Pour lui, la texture est un phénomène à deux (2) dimensions : la première concerne le type de primitive composant la texture ; la seconde, l'interaction entre les primitives. Cette dépendance peut être structurelle, probabiliste ou fonctionnelle. Dans [72], les auteurs définissent la texture comme une structure contenant plus ou moins des éléments ou motifs orientés. Une autre définition, plus adaptée à la géologie, dit que la texture est un ensemble de caractères définissant l'agencement et les relations spatiales des minéraux d'une roche. Toutefois, il n'existe encore pas de modèles mathématiques suffisamment génériques pour couvrir toute la diversité de textures dans les images naturelles. Tamura et al. [73], eux, définissent la texture comme un simple modèle mathématique  $T$  :

$$T = R(t) \quad (2.1)$$

dans lequel  $R$  correspond à une organisation de primitive de textures  $t$ .

Plusieurs travaux sur la perception humaine de la texture ont valorisé cette thématique. La texture semble évidente pour l'homme mais n'a pas de définition précise, universelle et consensuelle en analyse d'image. La notion de texture est très diversifiée. De nombreuses définitions sont proposées dans la littérature de la vision par ordinateur. Cependant, les définitions mathématiques ne parviennent pas à englober la diversité des cas. En effet, la texture peut être définie tel un concept intuitif ou psychologique de la perception humaine qui décrit les propriétés visuelles telle la finesse, la rugosité, la granularité, la régularité, le contraste et la directionnalité [74-76]. Ces propriétés décrivent les informations locales et globales de la texture. Selon [77-78], les propriétés de textures les plus essentielles dans la perception humaine sont la directionnalité, la périodicité, la granularité et la complexité ou le caractère aléatoire de la texture. Mais, toutes ces propriétés dérivées de la perception humaine sont impropres et non quantitatives. Or, il faut des descriptions quantitatives pour faciliter l'analyse automatique. Partant du principe de la perception visuelle humaine, Julesz [68], suggère deux (2) caractéristiques de base de textures : les caractéristiques prises comme des modèles et les caractéristiques basées sur la fréquence. Selon Julesz, la perception des caractéristiques basées sur les modèles, obéit aux caractéristiques de la texture appelées *textons*. Dans le modèle fréquentiel, la texture de l'image est perçue comme une distribution de fréquences. Julesz a proposé de décrire la texture par un modèle mathématique mais, affirme qu'il est difficile de distinguer deux (2) textures dont les statistiques d'ordres un (1) et deux (2) ont les mêmes valeurs [79].

En définitive, devant la complexité de la texture et la pluralité des applications de l'analyse de texture dans les domaines de télédétection, de l'imagerie médicale, dans l'identification de la qualité des matériaux (bois, cuir, textile, etc.), la détection d'empreinte digitale, une étude récente, réalisée par Dounia Awad, en 2014 [80], a regroupé les outils de caractérisation de texture en quatre (4) familles : les méthodes statistiques, les méthodes géométriques ou structurelles, les méthodes à base de modèles probabilistes et les méthodes fréquentielles. Une étude comparative des différentes méthodes a été faite dans [70, 80]. La liste des exemples de chaque méthode est exhaustive. Nous résumons dans le tableau 2.1 ci-dessous quelques exemples pour chaque famille. Une étude détaillée des différentes méthodes suivra dans les paragraphes suivants.

Tableau 2-1: Résumé des descripteurs de texture [80]

Méthode structurelle ou géométrique : Rosenfeld et Thruston [81]	<p><b>Description :</b> Décrit les textures structurelles où deux (2) éléments sont distingués : primitives et leurs relations spatiales.</p> <p><b>Avantages :</b> Valorise l'aspect forme des primitives.</p> <p><b>Inconvénients :</b> Spécifique.</p>
Méthode statistique : Matrice de cooccurrence [67, 71]	<p><b>Description :</b> Décrit les interrelations spatiales des niveaux de gris des textures.</p> <p><b>Avantages :</b> Invariants aux transformations monotones des niveaux de gris.</p> <p><b>Inconvénients :</b> Coûteux en temps et en mémoire.</p>
Méthode Fréquentielle ou par filtrage : Transformée de Fourier [82]	<p><b>Description :</b> Décrit la fréquence spatiale.</p> <p><b>Avantages :</b> Indépendant du niveau de gris moyen.</p> <p><b>Inconvénients :</b> Fonction complexe.</p>
Méthode à base de modèle : Modèle autorégressif [83]	<p><b>Description :</b> Décrit l'interaction entre l'intensité de chaque pixel et la somme pondérée de celle de ses voisins.</p> <p><b>Avantages :</b> Fournit la meilleure description des données avec une très faible biais d'erreur.</p> <p><b>Inconvénients :</b> Coûteux en temps de calcul.</p>

Après la présentation des méthodes d'extraction usuelles d'analyse, nous détaillons dans les paragraphes suivants, les méthodes d'extraction de texture, jugées pertinentes en rapport avec ce travail de recherche, comme les méthodes statistiques (LBP) et les méthodes fréquentielles (les filtres de Gabor et la DCT). Ces dernières sont détaillées au chapitre 4.

#### 2.4.2. Les méthodes statistiques

Dans les méthodes statistiques, la texture est vue comme la réalisation d'un processus stochastique stationnaire. Ainsi, des paramètres statistiques sont estimés pour chaque pixel de l'image. Suivant la modalité des images à étudier, la signature la plus discriminante de la texture

est à rechercher soit dans des méthodes exploitant directement les propriétés statistiques de la texture telles que les matrices de cooccurrences, la LBP, la fonction d'autocorrélation, etc., soit dans des méthodes qui exploitent les propriétés statistiques à partir d'un plan transformé dans lequel on réécrit l'image de texture comme la densité spectrale, la transformation de Fourier, celle de Karhunen-Loeve, ou des filtres numériques. Les plus rencontrées sont celles qui exploitent les propriétés statistiques dans l'analyse des textures.

#### **2.4.3. Les méthodes spatio-fréquentielles**

Ces méthodes prennent en compte à la fois les informations globales et locales. Elles sont bien adaptées aux signaux quasi périodiques. En effet, la plupart des textures rencontrées sont des signaux quasi périodiques ayant une énergie fréquentielle localisée. Ces méthodes permettent même de caractériser les textures à différentes échelles et orientations. C'est le cas des filtres de Gabor et de la DCT.

#### **2.4.4. Les méthodes structurelles**

Tenant compte de la structure des primitives et des relations spatiales, elles sont mieux adaptées aux textures macroscopiques. Les primitives des textures sont extraites des images en utilisant comme techniques les algorithmes de détection de contours ou de morphologie mathématique [27, 41]. Ces méthodes sont particulièrement appliquées à la description et à la synthèse de textures ayant une organisation régulière, donc périodiques. Or, ce type de textures ne représente qu'une faible proportion des textures rencontrées dans les images naturelles. Pour faire l'analyse, on identifie d'abord les éléments constitutifs, puis on définit les règles de placement.

#### **2.4.5. Les méthodes basées sur les modèles**

Elles reposent sur les modèles stochastiques, très coûteuses en temps de calcul. La grande partie de leur temps de calcul est consacré à estimer les paramètres du modèle. Les modèles les plus rencontrés sont les modèles Autorégressifs, le modèle de Markov et la généralisation des champs Markoviens [83].

### **2.5. Les textures de roches**

Les images de roches font partie de la grande famille des images naturelles. Les textures des roches sont stochastiques ainsi que la plupart des autres textures naturelles. Leurs caractères non homogènes apparaissent comme l'une des caractéristiques les plus significatives. Pour pallier leurs caractères non homogènes, certains auteurs tel que Lepistö divise la texture en de petits blocs homogènes [84]. De plus, d'autres propriétés, à l'instar de la granularité et la

directionnalité sont très essentielles dans l'analyse des textures de roches [85]. C'est d'ailleurs ces deux (2) propriétés qui guideront le choix de nos descripteurs et les méthodes d'extraction de caractéristiques. Elles varient selon le type de roches. Ces deux (2) propriétés de texture sont des facteurs importants dans la perception humaine de la texture. Elles sont donc prises en compte dans l'analyse manuelle et traditionnelle. La figure 2.5 présente quatre (4) différents types de texture de roches avec différentes textures, granularités et souvent différentes orientations.




Figure 2-5: Exemple de différentes textures de roches

En regardant ces textures de roches, on peut immédiatement dire qu'une texture, qu'elle soit homogène ou non homogène, présente des propriétés de directionnalité (Roches C et D) et de granularité (Roche A, B et D). Ce sont donc des propriétés discriminantes essentielles pour l'analyse des roches [85].

## 2.6. La couleur

En plus de la texture, la couleur est un facteur très important de la vision humaine, par ricochet du traitement des images numériques. Les images couleur contiennent plus d'informations discriminantes que les images en niveaux de gris. Il a été démontré, que prendre en compte la couleur dans les images améliore considérablement les performances de nombreuses tâches de reconnaissance de formes [72, 86-90]. Gonzales et Woods [91] présentent deux (2) motivations de base pour l'utilisation de la couleur dans l'analyse des images. Premièrement, en analyse automatique d'image, la couleur est un puissant descripteur qui simplifie souvent l'identification et l'extraction des objets d'une scène. Deuxièmement, dans l'analyse d'image réalisée par les humains, la couleur est motivée par le fait que l'œil peut discerner plusieurs nuances et d'intensité de couleur contre environ deux douzaines de nuances de gris. Pour caractériser la texture de couleur, il est nécessaire de s'intéresser à la représentation de la couleur et de la texture dans les images. Les sections suivantes discutent de l'importance de la couleur dans le traitement et l'analyse automatique des images couleur numériques. Elles

présentent d'abord les différents espaces colorimétriques classiques utilisés dans l'analyse d'images, la définition de la texture de couleur, d'autre part, passe en revue les principales caractéristiques de texture de couleur en usage dans l'analyse de texture de couleur.

## 2.7. Les espaces colorimétriques choisis

La couleur est le résultat de la perception de la lumière dans une région visible du spectre électromagnétique. La rétine de l'œil humain possède trois (3) types de cellule photoréceptrices de couleur, répondant aux rayonnements incidents, avec des courbes de réponses spectrales quelques peu différentes [28]. De ce fait, trois (3) composantes couleurs suffisent pour représenter une couleur. Une image numérique couleur comporte trois (3) images composantes. La couleur de chaque pixel est spécifiée dans un espace de couleur tridimensionnel ; ce qui définit un système de coordonnées de couleur (voir la figure 1.4 du chapitre 1). C'est pourquoi, la plupart des images couleur sont acquises par des périphériques qui codent les couleurs dans l'espace RVB. D'autres espaces colorimétriques existent et peuvent être calculés à partir de l'espace RVB, au moyen de transformations linéaires ou non linéaires [28, 91]. De plus, certains de ces nombreux espaces colorimétriques, prenant en compte différents facteurs physiques, physiologiques et les propriétés psycho-visuelles, ont été définis. Un résumé de ces espaces colorimétriques a été fait dans le chapitre 1 de ce document. Cet espace colorimétrique RVB facilite la segmentation d'une image couleur par seuillage. Un autre espace de couleur utilisé dans notre thèse est l'espace de couleur TSI (HSI en anglais). Dans le modèle TSI, la Teinte, la Saturation et la Luminosité ou l'Intensité sont considérées séparément. Gonzales et Woods, dans [91], ont montré que cela fut bénéfique pour deux (2) raisons : d'abord, dans une image, la composante intensité (I) est découplée de l'information couleur. Deuxièmement, la teinte (T) et la saturation (S) sont identiques à la perception humaine de la couleur. Les composantes chromatiques du modèle sont définies en suivant le triangle des couleurs ou triangle de Maxwell [91], présenté à la figure 2.6.a. Dans cette figure, la valeur de teinte du point de couleur P est l'angle du vecteur indiqué par rapport à l'axe du rouge. Par exemple, lorsque la teinte est  $0^\circ$ , la couleur est rouge, quand elle est  $60^\circ$ , la couleur est jaune, et ainsi de suite. La saturation est proportionnelle à la distance qui sépare le point P et le centre du triangle, de sorte que, plus P est proche du centre du triangle, plus la couleur est saturée. Lorsqu'on intègre la composante d'intensité, la structure devient tridimensionnelle et en forme de pyramide tel que le montre la figure 2.6.b. Comme vu pour le modèle en triangle de la figure 2.6.a, la valeur de teinte du point P est toujours déterminée par l'angle du vecteur indiqué par rapport à l'axe du rouge. Tout point à la surface de cette structure représente une couleur purement saturée. L'intensité dans

ce modèle est mesurée par rapport à la ligne perpendiculaire au triangle et la droite passant par son centre.

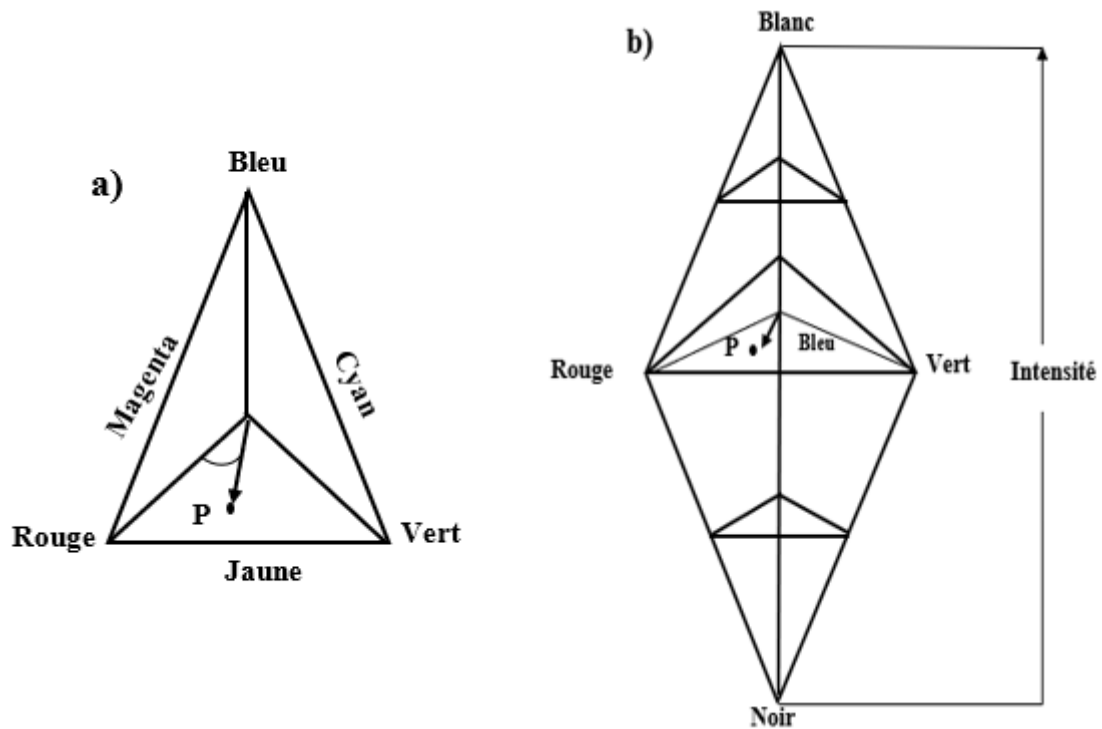


Figure 2-6: Modèle de couleur TSI [58]

Le modèle de couleur RVB peut être converti en modèle TSI ou HSV [91] selon les équations suivantes :

$$H = \cos^{-1} \left\{ \frac{\frac{1}{2}[(R-G) + (R-B)]}{[(R-G)^2 + (R-B)(G-B)]^{1/2}} \right\} \quad (2.2)$$

$$S = 1 - \frac{3}{(R+G+B)} [\min(R, G, B)] \quad (2.3)$$

$$I = \frac{1}{3}(R+G+B) \quad (2.4)$$

Cette conversion est également décrite dans le détail au niveau de l'ouvrage *Practical Algorithms For Image Analysis* [92]. L'espace de couleur RVB est un espace colorimétrique non-uniforme parce que les différences dans cet espace colorimétrique ne correspondent pas directement aux différences de couleur perçues par l'homme [28]. Par ailleurs, l'espace de couleur TSI ne représente pas les couleurs sur les espaces uniformes. Pour toutes ces raisons, la CIE a introduit les espaces de couleur perceptuellement uniformes comme par exemples  $L^*a^*b^*$  et  $L^*u^*v^*$  [28]. Ces espaces ont été définis afin de faciliter l'évaluation de la distance de perception entre



les couleurs [93]. L'espace colorimétrique RVB est l'espace utilisé par les appareils d'acquisition des images de roches. Etant donné que ces images sont naturelles, leurs couleurs correspondent plus aux couleurs primaires en usage dans ces appareils d'acquisition. Dans la littérature, beaucoup de travaux optent pour cet espace [94]. Nous avons aussi relevé dans la littérature que l'espace HSI correspond à la perception humaine de la couleur et est non uniforme, permettant donc de faire la différence entre les couleurs, contrairement à l'espace RVB. Relevant les avantages des deux (2) espaces colorimétriques RVB et TSI, nous les avons pris en compte dans ce travail, en fusionnant les différents canaux R, V et B de l'espace colorimétrique RVB et le canal I de l'espace TSI, pour obtenir les combinaisons suivantes : (R, I), (V, I) et (B, I) [95]. Cela a été effectué dans l'objectif de rehausser la luminance des couleurs dans les trois (3) canaux R, V et B dans les images de roches afin de mieux les distinguer.

## 2.8. Fusion de composantes couleur

Par une combinaison linéaire, on obtient la fusion de deux (2) composantes couleur. La formule suivante traduit cette fusion [27] :

$$I_{CL}(x, y) = I_{C_1C_2C_3}^{C_i}(x, y) \times (1 - \alpha) + I'_{C_1C_2C_3}(x, y) \times \alpha \quad (2.5)$$

où  $I_{C_1C_2C_3}^{C_i}(x, y)$  désigne la composante  $C_i$  de l'image couleur  $I$  dans l'espace couleur  $C_1C_2C_3$ . La fusion se fait avec deux (2) composantes couleur provenant des espaces colorimétriques RVB,  $L^*u^*v^*$  et  $L^*a^*b^*$  et HSL.  $\alpha$  est le coefficient de pondération de la deuxième image ( $\alpha \in [0, 1]$ ). L'image  $I_{CL}(x, y)$  est la résultante de la combinaison linéaire de  $I(x, y)$  et  $I'(x, y)$  et représente leur fusion. La difficulté est de définir les composantes couleur utilisée, d'évaluer la pertinence d'une fusion et choisir le coefficient  $\alpha$ . Pour cela, il est commode d'utiliser les informations à priori pour apprendre à fusionner les composantes couleur et construire une image monochromatique donnant une représentation optimale de la couleur. Dans [96], les auteurs utilisent l'algorithme CLAHE (Contrast Limited Adaptive Histogram Equalization) pour améliorer le contraste local dans les images sous-marines. Ils transforment d'abord les images RGB en images HSV puis ajustent les canaux S et V de cette nouvelle image afin de rendre la couleur plus naturelle et améliorer le contraste global de l'image. D'autres méthodes de fusion plus simples existent dans la littérature.

## 2.9. Couleur des roches

Dans la reconnaissance automatique ou manuelle de la roche, la couleur est l'une des caractéristiques les plus importantes pour décrire les propriétés des roches. La figure 2.7 présente quelques roches avec différentes couleurs. En pétrographie surtout, la notion de couleur des roches est quelque peu relative et différentes de celle que donne le traitement d'images. Le pétrographe utilise les notions de roches leucocrates, mesocrates et melanocrates liées à une certaine proportion de ferromagnésiens pour désigner respectivement les roches de couleur claires, moyennement sombres et plus sombres (noires). En traitement d'images, dans la description des roches basée sur la couleur, le problème est similaire à celui de la description des textures et les couleurs sont bien identifiées. La distribution des couleurs est souvent non-homogène. Cela peut se remarquer par exemple avec les échantillons des classes 3 et 7 de la figure 2.7 dans lesquels le noir et le gris sont illégalement distribués pour la classe 3 et dans la classe 7 le rouge et le vert aussi illégalement reparties. Dans la caractérisation des propriétés visuelles des roches, le choix de l'espace couleur est essentiel. Cependant, dans plusieurs études consultées, outre l'espace de couleur RVB conventionnel, un autre espace de couleur tel que HSI, est utilisé pour améliorer la description des couleurs car plus proche du système perceptuel humain.




Figure 2-7: Exemples d'images des huit (8) classes de roche avec différentes couleurs

Les travaux de Autio et al. en 2004 [48], ont aussi montré que certaines images de roches sont également obtenues en utilisant des longueurs d'onde de lumière hors du spectre visible supplémentaires pour discriminer certains minéraux ou éléments chimiques.

## 2.10. Les descripteurs de texture et couleur des roches

Dans la littérature, de nombreux descripteurs ont été proposés pour identifier le contenu des images d'une manière générale. Les descripteurs sont des paramètres servant à caractériser les différentes propriétés comme la forme, la texture et la couleur d'un objet, dans le but de faire une classification, une comparaison ou une identification des objets. Deux (2) objets sont similaires si leurs descripteurs ont des valeurs semblables. Deux (2) catégories d'approches principales peuvent être considérées pour combiner les informations de couleur et de texture : les méthodes traitant l'information de texture et de couleur séparément [86, 98, 99] et celles qui considèrent la texture et la couleur conjointement [87, 97, 179]. Dans la section suivante, nous présentons les descripteurs de texture et de couleur.

## 2.11. Les descripteurs de texture

La texture est une thématique ayant intéressé plusieurs chercheurs. En raison de l'absence de définition formelle et générale de celle-ci, maintes techniques furent proposées dans la littérature pour la décrire. Dans [80,100], les auteurs ont catégorisé les méthodes de description de texture en quatre (4) grandes familles : les méthodes statistiques, les méthodes de traitement de signal ou méthodes spatio-fréquentielles, les méthodes géométriques et les méthodes basées sur les modèles. Dans le tableau 2-2 ci-dessous, nous avons résumé les différents descripteurs de chacune des différentes méthodes. Ces méthodes ont été brièvement passées en revue dans cette section, bien que l'accent soit mis sur les méthodes fréquentielles et les méthodes statistiques qui ont retenu notre attention dans l'étude que nous souhaitons réaliser sur les roches.

Tableau 2-2: Les principales catégories des méthodes de description de texture

Méthodes de description de textures			
Statistique	Géométrique	Basées sur les modèles	Traitement de signal
- Fonction d'autocorrélation - Matrice de Cooccurrence - Différence de niveau de gris - Histogramme de Cooccurrence	- Méthodes morphologiques - Spectre de motifs - Tessellation de Voronoi	- Modèles autorégressives - Champs aléatoires de Markov (MRF) - Champs aléatoires de Markov Gaussien (GMRF)	- LBP (local Binary Pattern) - Filtres de Gabor - Transformée d'ondelette - Filtres passe bande

Les méthodes statistiques sont beaucoup utilisées en analyse de texture en général, pour la description des textures de roches, en particulier. Ces techniques sont basées sur la description

de l'organisation spatiale des images de niveaux de gris [57, 84]. Parmi elles, la matrice de cooccurrence de niveau de gris (GLCM), développée par Haralick et al. [71], permet l'analyse des textures en niveau de gris. Le GLCM, considérant les paires de pixels, estime la fonction de densité de probabilité conjointe du deuxième ordre [54, 57, 84, 101] et représente un histogramme à deux (2) dimensions.

## 2.12. Descripteurs de couleur

La distribution de couleur est une caractéristique typique en usage dans la classification d'images, et peut être décrite par les méthodes statistiques parmi lesquelles les différents moments statistiques (moyenne, écart type, l'énergie, l'entropie, la dissymétrie (S), etc), formulés par les équations (2.6), (2.7), (2.8) ci-dessous, les histogrammes couleur, les matrices de cooccurrence couleur, le corrélogramme, etc.

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.6)$$

$$\hat{\sigma}_x^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \quad (2.7)$$

$$S = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{\left( \sum_{i=1}^n (x_i - \bar{x})^2 \right)^{3/2}} \quad (2.8)$$

Stricker et Orengo en 1995 [102], ont utilisé les moments de couleur pour décrire la distribution de couleur d'une image. L'histogramme est l'outil statistique couramment utilisé pour la description du contenu des images couleur [103]. C'est une mesure statistique de premier (1<sup>er</sup>) ordre qui estime la probabilité d'occurrence de certaines couleurs dans l'image. Par conséquent, l'histogramme est une distribution normalisée de valeurs de pixels. Si le nombre de niveau de couleur dans une image est n, l'histogramme H peut être exprimé comme un vecteur de longueur n. Le i<sup>ème</sup> composant du vecteur est défini comme :

$$H(i) = \frac{N_i}{N} \quad i = 0, 1, 2, \dots, n-1 \quad (2.9)$$

où N est le nombre total de pixels et N<sub>i</sub> le nombre de pixels de couleur i. Dans [51], les auteurs ont extrait les caractéristiques de textures et de couleur en utilisant l'histogramme couleur local et les moments statistiques dans les différents canaux des espaces colorimétriques RVB et HSI.

L'avantage de l'histogramme est sa faible dimension et son calcul rapide. L'inconvénient principal est qu'il ne tient pas compte des relations spatiales de la couleur dans l'image. Pour cette raison, plusieurs mesures statistiques de second ordre ont été introduites pour mieux décrire l'image. Entre autres la fonction d'autocorrélation, le corrélogramme introduit par Huang et al., en 1997 [104], pour décrire les relations spatiales de paires de pixels à une distance  $d$  dans une image.

### **2.13. Descripteurs de texture couleur**

La couleur et la texture sont naturellement deux (2) caractéristiques fondamentales liées de l'image, ces caractéristiques sont parfois analysées séparément. Cependant, la couleur, qui est souvent présente dans l'image des textures, est une importante caractéristique décrivant le contenu de l'image. Dans certains cas, il est plus pratique de présenter les propriétés de texture et de couleur d'une image à l'aide d'un seul descripteur. Cela permet de caractériser conjointement la distribution spatiale et la couleur. Ces dernières années, plusieurs études ont été consacrées au problème de la représentation conjointe de la texture et de la couleur. Une kyrielle de chercheurs ont démontré que les caractéristiques de texture incorporant des informations de couleur sont susceptibles d'améliorer la discrimination de textures naturelles observées dans des conditions d'éclairage fixe [72, 86, 105]. Selon Mäenpää et Pietikäinen, l'analyse de la texture couleur peut être grossièrement divisée en deux (2) catégories, tel qu'indiqué dans [87]. Une évaluation des descripteurs ou attributs de texture couleur est présentée dans [106, 107]. Typiquement, les attributs de texture peuvent être divisés en trois (3) catégories définies en termes de caractéristiques géométriques, spatio-fréquentielles, statistiques [100].

#### **2.13.1. Caractéristiques géométriques**

Ces caractéristiques prennent en compte la structure et le contexte des images. Elles sont bien adaptées pour décrire la texture observée au niveau macroscopique. La description géométrique d'une texture inclut l'extraction de plusieurs primitives (angle, arête, points, lignes, courbes ou surfaces) et les règles d'agencement ou d'organisation spatiale de ces primitives. Zheng et al. [108], ont proposé un ensemble de caractéristiques géométriques spécifiques (taille, orientation et contraste) pour les textures couleurs, sensibles à la texture régulière de la viande. Cependant, ce type de fonctionnalités ne permet pas de caractériser les textures irrégulières perceptibles généralement dans les images naturelles.

### 2.13.2. Caractéristiques spatio-fréquentielles

Les caractéristiques spatio-fréquentielles peuvent être divisées en trois (3) domaines : le domaine spatial, le domaine fréquentiel et le domaine spatio-fréquentiel.

- Le domaine spatial implique les caractéristiques définissant la texture en termes de nombres de transitions par unité de surface, contrairement aux textures plus grossières. Les filtres Cumani, Laplace et Sobel sont tous des exemples de filtres largement utilisés pour la détection des bords de couleur [109]. Ce type de caractéristiques n'a encore pas été appliqué à la classification des images de textures couleur.
- La transformée de Fourier (FT) ou la transformée en Cosinus Discrète (DCT) donne une représentation alternative de textures basée purement sur le domaine fréquentiel. Ces attributs sont particulièrement bien adaptés au cas des images contenant des textures grossières, où il existe une continuité considérable entre les niveaux de chaque composante de couleur de pixel. Etant donné que les hautes fréquences sont limitées aux changements locaux des niveaux de composants, il est possible d'exprimer toutes les informations présentes dans l'image en utilisant seulement un petit nombre de coefficients correspondant aux basses fréquences. Drimbarean et al. [72] ont utilisé la transformée en cosinus discrète et son extension de couleur pour caractériser les textures dans leurs expériences.
- Le domaine spatio-fréquentiel implique des caractéristiques combinant les deux (2) représentations décrites précédemment. Les filtres de Gabor et les ondelettes sont les plus largement utilisés dans la caractérisation, la segmentation et la classification des textures couleurs car sont très efficaces pour l'analyse des micro-textures et des macro-textures. Plusieurs auteurs ont fait usage des filtres de Gabor sur des images couleur et montré que la prise en compte des caractéristiques de texture et de couleur conjointement, améliore les résultats de la classification par rapport à ceux obtenus par l'utilisation de caractéristiques de niveau de gris [53, 57, 72, 86, 110]. Dans [57], Lepistö et al., ont appliqué les filtres de Gabor multi-résolution sur les composantes couleur d'une image de texture couleur dans l'espace colorimétrique TSI. En 2005, ces mêmes auteurs ont appliqué un filtre Gaussien passe bande sur les différents canaux de couleur des images prises dans les espaces colorimétriques RVB et TSI. Thai et Hailey en 2000 [111], proposent une méthode de filtrage spatial basée sur la transformée de Fourier dans l'analyse de textures couleur. Cette méthode utilise l'espace colorimétrique RVB. Palm et al. en 2000 [86] ont utilisé l'espace de couleur TSI dans l'analyse des texture

couleur. Ils présentent les composantes de teinte et de saturation sous forme de coordonnées polaires et leur appliquent la transformée de Fourier. Dans l'analyse de texture couleur, le choix de l'espace couleur est une tâche essentielle. Paschos en 2001 [112], a comparé les espaces de couleur RVB, TSI et  $L^*a^*b^*$  dans l'analyse de texture couleur, basée sur les filtres de Gabor. Les résultats expérimentaux indiquent que l'espace TSI donne les meilleurs résultats de classification. Cependant, cette méthode présente deux (2) inconvénients : la nécessité de définir chaque fois des paramètres d'orientation, d'échelle ou de longueur d'onde pour les filtres et le temps de calcul très long pour caractériser les textures couleur. En outre, les caractéristiques basées sur les filtres de Gabor et les ondelettes ont des parallèles avec le processus du système visuel humain [113]. Plusieurs auteurs ont étudié les problèmes de classification des textures couleur par l'utilisation de la transformée en ondelettes [114, 115]. Malgré les nombreux avantages de cette transformation, Iakovidis et al. [116] ont révélé que les caractéristiques obtenues à partir des ondelettes ne sont toujours pas les plus appropriées pour la caractérisation de la texture.

### **2.13.3. Caractéristiques statistiques**

En plus des méthodes basées sur le filtrage, les méthodes statistiques sont très souvent employées dans l'analyse des textures couleur. Toutefois, les caractéristiques statistiques peuvent être utilisées pour caractériser tout type de textures. Pour ce type de caractéristiques, une texture est définie en termes de niveau de gris ou de variation de couleur dans un voisinage ; c'est la relation entre un pixel et ses voisins qui est examinée. Dans la littérature, une large gamme de caractéristiques statistiques est en usage pour la classification des textures couleur. Celles-ci incluent les statistiques de l'image, les histogrammes d'images, les matrices de cooccurrence chromatique (CMC) et les histogrammes de somme et de différence, les modèles binaires locaux (LBP), etc. Ces différents descripteurs peuvent être regroupés en plusieurs catégories en fonction de leur ordre ; l'ordre de l'attribut dépendant du type d'interaction spatiale entre les pixels en question. Les histogrammes d'images sont un exemple de fonctions statistiques du premier ordre. Ils décrivent la distribution des niveaux de composantes de couleur dans l'image d'entrée [87, 117]. En revanche, les matrices de cooccurrence, par exemple, considèrent des paires de pixels ; ce qui signifie qu'elles sont des attributs de second ordre. Ce descripteur, introduit par Haralick et al. [71], a été initialement mis en œuvre pour les images en niveaux de gris. Comme l'utilisation de la couleur peut améliorer les résultats de la classification des textures, Palm a proposé d'étendre le concept de matrices de cooccurrence

---

aux images en couleur, à partir de la définition des matrices de cooccurrence multicanaux proposée par Rosenfeld [118]. Les caractéristiques de Haralick, obtenues à partir des matrices de cooccurrence chromatique, ont été utilisées par différents auteurs dans le contexte de la classification des textures de couleur [54, 72, 104, 119]. Lakmann, en 1997 dans [120], calcule une matrice de cooccurrence pour chaque canal de couleur. Paschos [112] a étudié les textures colorées en utilisant la chromaticité de la couleur. L'idée sous-jacente à son approche est que la fonction de corrélation a été calculée pour les composantes chromatiques de l'image. Dans le travail de Shim et Choi en 2003 [121], la matrice de cooccurrence est utilisée pour décrire les relations spatiales entre les niveaux de teinte dans l'image. En 2012, T. Harinie [54], dans la classification des textures de roches, compare ses résultats obtenus à partir des caractéristiques de Tumara à ceux obtenus à partir des méthodes statistiques tels que GLCM, la matrice de cooccurrence couleur (CMC) et les moments statistiques. Les histogrammes de somme et de différence qui appartiennent également à la stratégie du second ordre, possèdent une capacité de discrimination presque identique à la matrice de cooccurrence chromatique, avec l'avantage que leurs calculs sont beaucoup moins exigeants en termes de besoins en mémoire [122, 124]. Un autre descripteur de second ordre est le motif binaire local couleur (LBP couleur), utilisé à maintes reprises par de nombreux auteurs dans leurs études sur l'utilisation conjointe de la texture et de la couleur pour la classification des images [87, 97, 123, 125, 126].

Au cours des dernières années, divers descripteurs locaux et globaux discriminants de texture, efficaces en temps de calcul, ont été introduits. Leur apparition a permis des avancées significatives dans l'analyse de la texture couleur pour de nombreux problèmes de vision par ordinateur. Plusieurs méthodes d'analyse de textures couleur, basées sur une caractéristique globale, incluent le filtrage couleur de Gabor [110], le modèle de champ aléatoire de Markov [127]. Parmi les méthodes de caractéristiques locales efficaces, citons la transformation de couleur par transformée invariante par échelle (SIFT) [128], la plus populaire, et ses variantes telles que PCA-SIFT [129], le descripteur des caractéristiques robustes accélérées (SURF) [130], l'histogramme d'orientation et de localisation de gradient (GLOH) [131], la pyramide des histogrammes couleur de gradient orientés (PHOG) [132], les descripteurs de couleurs discriminants (DCD) [89], histogrammes de somme et de différence adaptative-3D (3D-ASDH) [133], motif binaire local couleurs [125, 87], Co-occurrence Chromatique du motif binaire local (CCoLBP) [134] et bien d'autres.

Parmi les descripteurs de textures proposés, présentés dans le tableau 2.2, présentant un état de l'art des descripteurs de textures couleur utilisés dans le cadre de la classification des textures



couleur, l'opérateur LBP est l'un des descripteurs les plus efficaces pour caractériser les images de texture. Les avantages distinctifs de LBP sont sa facilité de mise en œuvre, son invariance aux changements d'illumination monotone et sa faible complexité de calcul [135].

## **2.14. Etat de l'art sur l'analyse et le traitement automatique des roches**

Les deux décennies passées ont connu un regain d'intérêt dans l'analyse et le traitement d'images de roche. Les études successives et les articles parus témoignent de l'intérêt accordé à ce domaine d'étude. Lindqvist et Akesson [136], ont présenté une revue de littérature de l'analyse d'images appliquée à la géologie, dans laquelle les axes centraux sont portés sur la structure de la roche et l'analyse de la texture des roches en utilisant les méthodes d'analyse d'images. Dans Singh et al. en 2004 [137], les caractéristiques de textures pour la classification des roches sont comparées. Dans cette comparaison, la meilleure performance de classification fut réalisée en utilisant la loi des masques et des matrices de cooccurrence. Paclik et al., [138] et Duarte et Fernlund [139] en 2005, ont également utilisé les caractéristiques texturales calculées à partir de la matrice de cooccurrence dans l'analyse des images de roche. Dans ces études, l'entropie et la corrélation de texture ont été jugées les plus significatifs, dans la caractérisation des échantillons de granite. Lepistö et al. [84] utilisent le contraste et l'entropie extraits de la cooccurrence dans la classification des échantillons des roches non-homogènes. Dans Salinas et al., en 2005 [140], la taille de fragments de roche est estimée au moyen d'un système de vision par ordinateur en usant la segmentation, le filtrage et les opérations morphologiques. Dans [55] en 2010, les auteurs ont caractérisé la texture et la couleur des roches en utilisant les moments statistiques (moyenne, entropie, écart type, etc), les caractéristiques de régions et les caractéristiques des images (histogramme, opérateur de canny). En 2011, A. Fernandez et al. [52, 179] ont fait une évaluation de plusieurs descripteurs (LBP, CCR, ILBP) de textures, dans la classification des textures de granite. Les auteurs ont montré la robustesse de LBP et ses variantes dans l'extraction des caractéristiques de texture. Dans [94], F. Bianconi et al. ont, en utilisant les méthodes statistiques (LBP, CMC) et fréquentielles (filtres de Gabor), montré que la classification basée, sur la couleur et la texture, donnait de meilleurs résultats que lorsque la texture est seulement prise en compte. C. Vivek et S. Audithan [141] ont appliqué les filtres de Gabor sur des images de textures de roches pour extraire différentes tailles et orientations de texture dans un environnement bidimensionnel, principalement dans les deux (2) directions horizontale et verticale. Dans [50], M. Ladniak et M. Mlynarczuk ont utilisé les paramètres statistiques (moyenne, écart type, variogramme, etc) au moyen des méthodes de traitement d'images numériques (gradient morphologique) pour

estimer les caractéristiques de couleurs et de textures dans dix-neufs (19) types de roches. Dans la dynamique de la combinaison de méthodes d'extraction de caractéristiques, F. Galdames et al., 2018 [142] ont combiné les caractéristiques de Gabor et de LBP sur des images couleur de portée LASER.

Les descripteurs statistiques, utilisés dans la caractérisation des roches et présentés dans cette session, permettent de décrire les interrelations spatiales des niveaux de gris de textures. Ils décrivent l'interaction entre l'intensité de chaque pixel et la somme pondérée de celle de ses voisins. Ces méthodes ont l'avantage d'être invariantes aux transformations monotones des niveaux de gris. Ils fournissent aussi une meilleure description des données avec une très faible biais d'erreur. L'inconvénient majeur est qu'ils sont coûteux en temps de calcul et en mémoire. En ce qui concerne les descripteurs spatio-fréquentiels, ils permettent de décrire la fréquence spatiale. Ils sont insensibles aux variations d'éclairage et ont l'avantage d'être indépendants du niveau de gris. Cependant, ils dépendent du contraste et de l'échelle d'une image : ils sont très complexes dans leur utilisation.

Les performances réalisées avec LBP, dans la reconnaissance des images faciales puis récemment avec les images de roches, l'utilisation des méthodes fréquentielles (filtres de Gabor, DCT) pour leur caractère multi-échelle et dans la prise en compte de la directionnalité témoignent de l'efficacité de ces méthodes. Dans la suite de nos travaux, au regard de toutes ces raisons citées, nous allons les combiner afin de tirer profit des avantages de ces méthodes. De ce fait, nous présenterons dans la section qui suit LBP et ses extensions couleur, les filtres de Gabor et la DCT.

## **2.15. Caractéristiques statistiques et fréquentielles**

### **2.15.1. Caractéristiques statistiques : Local Binary Pattern (LBP)**

#### **2.15.1.1. Descripteur LBP original**

Dans la version originale, proposée par Ojala et al. [13], l'opérateur  $LBP_{3 \times 3}$  caractérise la texture locale microscopique de l'image en faisant un seuillage dans un voisinage carré  $3 \times 3$ . Comme le montre la figure 2.8, l'opérateur étiquète les pixels d'une image avec des nombres décimaux, appelés motifs binaires locaux ou codes LBP, qui codent la structure locale autour de chaque pixel central, définit, comme seuil pour le voisinage  $3 \times 3$ . Chaque pixel est comparé à ses huit (8) voisins en soustrayant la valeur du pixel central à celle de chacun de ces voisins. Les valeurs strictement négatives résultantes sont codées avec 0, les autres avec 1. Un nombre binaire est obtenu en concaténant tous les pixels, suivant le sens de l'aiguille d'une montre. La

valeur décimale est utilisée pour l'étiquetage. L'histogramme des motifs binaires calculés sur une région est généralement utilisé comme la caractéristique LBP.

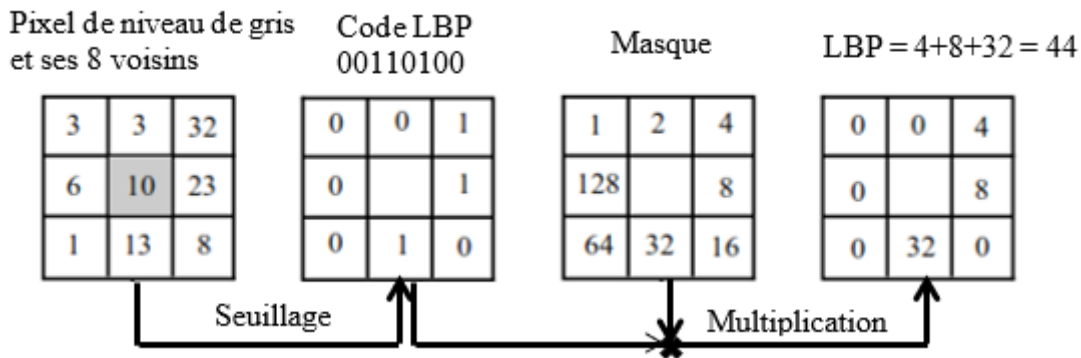


Figure 2-8: Exemple de calcul de code LBP

L'opérateur a été ensuite généralisé pour explorer les valeurs d'intensité des points situés dans un voisinage circulaire. Le calcul du code LBP de chaque pixel de l'image peut être exprimé mathématiquement comme suit :

$$LBP_{P,R} = \sum_{i=0}^{P-1} s(p_i - p_c) \times 2^i, \quad s(x) = \begin{cases} 1 & \text{si } x \geq 0 \\ 0 & \text{si non} \end{cases} \quad (2.10)$$

où  $p_c$  est la valeur de gris du pixel central,  $p_i$  est la valeur de gris des pixels voisins,  $P$  est le nombre de pixels voisins sur le cercle,  $R$  est le rayon du cercle du voisinage. En modifiant  $R$  et  $P$ , il est possible de calculer des caractéristiques LBP pour traiter la texture à différentes échelles. Par exemple,  $LBP_{16,2}$  fait référence à 16 voisins dans un voisinage circulaire de rayon 2. La caractéristique LBP produit  $2^P$  différentes valeurs de sortie et donne lieu à un histogramme de  $2^P$ -dimensions. La figure suivante montre des exemples de voisinage circulaire autour de pixel central ayant différents rayons et nombre de voisins. Le nombre de bins de l'histogramme LBP est de 256 ou 65536 si l'on considère respectivement 8 et 16 pixels voisins.




Figure 2-9: Voisinages circulaires de pixel central avec différents voisins : a)  $LBP_{8,1}$  et b)  $LBP_{16,2}$

Bien que la LBP originale ait plusieurs avantages cités précédemment, elle présente également d'importants inconvénients : elle est sensible à la rotation des images et au bruit, capture uniquement la structure très locale de la texture et ne détecte pas les structures texturales à grande échelle [115]. Depuis les travaux de Ojala, de nombreuses variantes de l'opérateur LBP ont été proposées dans la littérature afin de résoudre les différents problèmes rencontrés à savoir sa robustesse face au bruit, accroître son pouvoir discriminant pour des applications dans l'analyse des images faciales, la biométrie, l'analyse des images médicales, la récupération basée sur le contenu et l'analyse des images de roche [52, 95, 143-153].

### 2.15.1.2. Les extensions de LBP

Après les extensions primitives, prenant en compte les voisinages de tailles différentes, l'utilisation des voisinages circulaires, ont suivi l'interpolation bilinéaire des valeurs de pixels et l'utilisation des motifs uniformes, utilisées pour estimer les pixels ne se trouvant pas exactement au centre des pixels.  $LBP_{P,R}^{riu}$  et  $LBP_{P,R}^{riu2}$  sont respectivement invariant par rotation de LBP et invariant par rotation uniforme de LBP. Ces deux (2) opérateurs de LBP, améliorés, ont été proposés par Ojala et al. en 2002 [154] et leur modélisation mathématique se présente ainsi :

$$LBP_{P,R}^{riu2} = \begin{cases} \sum_{i=0}^{P-1} s(p_i - p_c) & \text{si } U(LBP_{P,R}) \leq 2 \\ p+1 & \text{si non} \end{cases} \quad (2.11)$$

où l'exposant riu2 se réfère aux motifs uniformes invariants de rotation qui ont une valeur U ( $U \leq 2$ ). La mesure d'uniformité U correspondant au nombre de transitions de zéro (0) à un (1) ou de un (1) à zéro (0) entre bits successifs dans la représentation circulaire du code binaire  $LBP_{P,R}$ , est aussi définie comme :

$$U(LBP_{P,R}) = |s(p_{p-1} - p_c) - s(p_0 - p_c)| + \sum_{i=1}^{P-1} |s(p_i - p_c) - s(p_{i-1} - p_c)| \quad (2.12)$$

Tous les motifs non uniformes sont classés comme un motif pour  $LBP_{P,R}^{riu2}$ . Le mappage de  $LBP_{P,R}$  à  $LBP_{P,R}^{riu2}$ , qui a  $(P + 2)$  valeurs de sortie distinctes, peut être implémenté avec une table de recherche. Ces extensions sont appelées extensions traditionnelles de LBP par Liu et al. [134]. Dans [155], une première étude sur LBP et ses variantes a été réalisée. Plus récemment, [134] a proposé une analyse complète et plus détaillée des variantes de LBP, basée sur une analyse d'échelle de gris pouvant être regroupées en plusieurs catégories, confirmation des travaux de Brahnam et al. 2014 [156]. Nous ne faisons pas une étude exhaustive mais un bref résumé de ces différentes catégories dans le tableau 2-3.

Tableau 2-3: Les différentes catégories d'extension de LBP

Catégories	Propriétés et variations	Années et références
Extension LBP traditionnel	Approche fondamentale et classique caractérisant une structure spatiale de motif de textures locales d'images par seuillage. Introduction des descripteurs LBP invariants	1996 [13, 52], 2000 [157], 2002 [142,154]
Topologie et échantillonnage de voisinage	Pixels ou motifs de pixels avec une certaine topologie de voisinage, échantillonnés pour former des vecteurs locaux : topologies elliptique, parabolique, hyperbolique et spirales. Variantes LBP liées aux patches.	2013 [145], 2016 [150] 2007 [158] 2010 [159] 2003 [160] 2011 [161]
Seuillage et quantification	Binarisation ou éventuellement quantification à plusieurs niveaux sur la base d'un certain seuil. Modification du schéma de seuillage et le nombre de niveau de quantification pour obtenir la robustesse au bruit.	2007 [143, 163] 2012 [148] 2004 [162]
Combinaison de caractéristiques complémentaires	Combinaison des descripteurs de type LBP complémentaires ou combinaison des descripteurs de type LBP avec d'autres descripteurs : LBP + Gabor, LBP+HOG, LBP+LTP, LBP+SIFT, LBP+ Haar, etc.	2018 [142] 2007 [143] 2009 [164, 166, 170, 169] 2005 [165] 2010 [167, 178] 2013 [168] 2016 [171]

En parcourant les extensions de LBP, l'on remarque que les extensions couleur ont reçu moins d'attention dans la littérature. La sous-section suivante propose quelques-unes des extensions couleur de LBP.

---

### 2.15.1.3. Descripteurs LBP couleur

L'opérateur LBP original est calculé sur des images en niveaux de gris. Cependant, il a été démontré que l'information de couleur est très importante et discriminante pour représenter la texture couleur, particulièrement dans les textures des images naturelles [53, 72, 84, 86]. Dans la littérature, l'extension de la LBP original à la couleur suit les trois (3) stratégies de combinaison de couleur et de texture :

- a) Dans la première stratégie, l'opérateur LBP original est calculé à partir de la luminance de l'image et combiné aux caractéristiques statistiques de couleurs (l'histogramme couleur, le contraste, percentiles, etc) [87, 97, 126, 172]. Bianconi et al. [3, 14], ont utilisé la concaténation de LBP et les statistiques de couleurs (percentiles) calculés sur les différents canaux de couleurs dans la classification automatique des granites.
- b) La deuxième stratégie consiste à appliquer l'opérateur LBP d'origine, de manière indépendante, sur chacun des trois (3) composantes de l'image couleur, sans tenir compte des interactions spatiales entre les niveaux de deux (2) composantes de couleurs différentes. Le descripteur de textures est obtenu en concaténant les trois (3) histogrammes LBP [88, 117].
- c) La troisième stratégie consiste à prendre en compte les interactions spatiales à l'intérieur et entre les composantes de la couleur. Pour décrire les textures couleur, l'Opponent Color LBP (OCLBP) et l'EOCLBP ont souvent été utilisés pour classer les images de texture couleur [87, 173, 174]. Récemment, Wang et al. en 2015 [175], ont proposé une autre variante de LBP couleur nommé ALBPCSF qui prend en compte l'information couleur dans les espaces de couleur RGB et HSV et ajoutent les relations de structures spatiales aux vecteurs caractéristiques.

### 2.15.2. Caractéristiques fréquentielles

En traitement d'images, des méthodes très variées peuvent être employées suivant une application visée. Ainsi, les filtres de Gabor et la DCT, bien qu'utilisées pour comprimer l'information, peuvent s'appliquer dans de nombreuses autres situations telles que la segmentation ou l'extraction de caractéristiques dans une image. Ces transformées linéaires fréquentielles employées dans ce manuscrit seront vues dans le détail au chapitre 4, aux paragraphes 4.2.1 et 4.3.1.

## 2.16. Etat de l'art sur les méthodes d'indexation des roches

### 2.16.1. Introduction

La classification d'images numériques est une étape importante pour l'interprétation des images et la prise de décision en traitement d'images. De manière simple, elle consiste à affecter un objet donné à l'une des classes de cet objet. C'est une question fondamentale de l'analyse d'image, jouant un rôle essentiel dans de nombreuses applications comme l'analyse d'images biomédicales, l'inspection industrielle, l'analyse d'imagerie satellitaire ou aérienne, l'analyse de document, l'identification du visage, la biométrie et bien d'autres. La classification des textures couleur est alors devenue un sujet de défi en vision par ordinateur car les images naturelles, celles des roches, présentent souvent un degré élevé de complexité, de caractère aléatoire et d'irrégularité. Par exemple, deux (2) images contenant la même couleur avec des motifs de textures différents ou le même motif de textures, mais des couleurs différentes sont considérées comme des textures de couleur différentes [72]. La figure 2-10 présente un cas de deux (2) images (de la base de données USPTex) avec la même couleur mais des textures différentes de granite (images a et b). Les images (c) et (d) illustrent la texture de pierres de couleurs différentes.




Figure 2-10: Exemple de deux (2) textures différentes avec la même couleur (a) et (b) puis la même texture de pierre avec des couleurs différentes [36]

Le processus de classification de textures couleur peut être décomposé en trois (3) sous-problèmes : la représentation, la classification proprement dite, enfin la prise de décision [14, 100].

- Représentation : Etablir des classes de descripteurs.

- Classification : Classifier l'image à partir des classes des descripteurs.
- Prise de décision : Evaluer les précisions des résultats de classification.

## 2.16.2. Méthodes d'indexation et de classification des roches

### 2.16.2.1. Approches supervisées et Approches non-supervisées

Dans la littérature sur les roches, deux (2) catégories de méthodes de classification de textures couleur se dégagent, en fonction de la manière dont les classes de descripteurs sont établies : (i) les méthodes non supervisées où le motif est attribué à une classe jusqu'alors inconnue. Les classes sont apprises en fonction de la similitude des objets et (ii) les méthodes supervisées où l'objet ou le motif d'entrée est comme un membre d'une classe prédéfinie. Jain et al. [176] proposent une étude bibliographique exhaustive sur les méthodes de classification. Le tableau 2-4 fait un résumé de ces deux (2) catégories de méthodes utilisées pour l'indexation et la reconnaissance des roches.

Tableau 2-4: Méthodes d'indexation et de reconnaissance de roches

Catégories de méthodes		Principes ou description	Avantages	Inconvénients	Méthodes
Méthodes supervisées	Paramétriques	Création des classes en déterminant des zones d'entraînement ou d'échantillons d'apprentissage en fonction de leur signature.	Simple et facile à implémenter. Robuste par rapport au bruit.	Nécessite une connaissance à priori des classes. Importance du choix de la distance à utiliser.	MV [138], GLCM [54, 101]
	Non paramétriques				SVM [51, 56, 3, 142], K-NN [49, 84], Réseaux de neurones [55,49], Arbres de décision [51], Boosting[141]
Méthodes non supervisées	Non paramétriques	Classes créées automatiquement suivant une similitude des signatures	Stable et Rapide même sur les grands jeux de données. Pas de phase d'entraînement	Difficile d'interpréter à priori la nature des classes établies Choix des classes lié au choix de la mesure de similarité à utiliser. Coûteuse en espace mémoire.	K-means, c-means [137,177]



Une méthode est dite paramétrique lorsqu'elle associe à la signature spectrale une distribution statistique connue, la loi normale ou multi normale, le plus fréquemment pour le traitement d'images. Pour une étude détaillée sur chacune de ces méthodes, vous pouvez consulter [36].

#### **2.16.2.2. Dimensionnalité des descripteurs**

La dimension des descripteurs de textures et de couleurs étant souvent très élevée, il est parfois difficile de visualiser l'espace des caractéristiques. Cependant, la haute dimensionnalité des vecteurs de caractéristiques et la redondance des données peuvent également entraîner une diminution de la performance des algorithmes de classification et d'extraction des caractéristiques. Ce problème peut considérablement influencer le résultat de la classification malgré la performance des algorithmes utilisés, en particulier avec une petite quantité de données d'apprentissage. C'est ce que Duda et al. [42] appellent « la malédiction de la dimensionnalité ».

Le nombre de dimensions dans une tâche de classification ou d'indexation d'images dépend du type de descripteur utilisé. Par exemple, les histogrammes de couleurs sont souvent évalués pour l'ensemble des couleurs de l'image. Ainsi, le nombre typique de « bins » dans l'histogramme est de 256. En outre, si les histogrammes sont définis pour trois (3) canaux de couleurs, le nombre de dimensions est de 768. Lorsque les mesures statistiques de second ordre, telles que les corrélogrammes, sont également utilisées comme descripteurs, alors la dimensionnalité peut être encore plus élevée. Avec les descripteurs de textures, la dimensionnalité peut de même être un problème. Les caractéristiques de textures présentées sous forme d'histogramme sont de grandes dimensions. Les filtres de Gabor, avec plusieurs échelles et orientations, sont tout aussi capables de produire un nombre remarquable de coefficients.

En dépit de l'utilisation des descripteurs de faibles dimensions comme la moyenne ou l'écart type et de certains des descripteurs de texture du standard MPEG-7 [179, 180], le problème de la dimensionnalité des descripteurs demeure. Pour réduire la dimension des caractéristiques de textures couleur, une pléthore de techniques sont proposées. La meilleure, connue, est l'analyse en composante principale (ACP), méthode non supervisée pour la sélection des « vraies » caractéristiques de données [42].

Dans la classification des roches, afin de résoudre ce problème de dimensionnalité élevée des descripteurs, les auteurs combinent l'ACP ou les algorithmes génétiques à la méthode de classification proprement dite choisie. Mais, face à la redondance des données, cette technique introduit par moment du bruit. Cela est un véritable obstacle pour les méthodes jusque-là

utilisées pour l'identification et la reconnaissance des roches. Pour une approche de solution, nous utiliserons, dans cette thèse, les représentations parcimonieuses avec pour méthode d'apprentissage de dictionnaire, l'algorithme K-SVD [10], présenté dans la section suivante.

## 2.17. Représentations parcimonieuses et apprentissage de dictionnaire avec K-SVD

### 2.17.1. Introduction

Les représentations parcimonieuses (RP) des signaux sont devenues un sujet de recherche très actif, ces dix dernières années. En effet, transformer un signal de façon parcimonieuse revient à le représenter dans un autre espace en utilisant un plus petit nombre de coefficients non nuls. Ce nouvel espace de représentation est défini par une matrice appelée « dictionnaire » dont les colonnes sont nommées « atomes ». Ce sont des techniques utilisées dans maints domaines : les statistiques, l'apprentissage automatique, le traitement d'images avec la classification, la compression, la restauration d'images dégradées ou inpainting, la super-résolution, le débruitage, etc. Elles sont basées sur le principe de la parcimonie [181], lequel principe consiste à représenter un vecteur de données avec le minimum de coefficients non nuls, à partir d'un dictionnaire [182]. Cela part du fait que l'information utile se trouve enfouie dans des données bien conservées dans des sous-espaces de petites dimensions.

Dans cette section, nous procéderons par la formulation du problème des représentations parcimonieuses comme un problème d'optimisation et présenterons, ensuite, quelques algorithmes de décomposition parcimonieuses permettant de le résoudre. Nous nous intéresserons à l'apprentissage de dictionnaire.

### 2.17.2. Formulation du problème

Les représentations parcimonieuses (RP) représentent généralement un signal comme une combinaison linéaire des atomes d'un dictionnaire sur-complet.

Soit un signal réel de taille  $n$  ( $y \in \mathbb{R}^n$ ) à décomposer sur un dictionnaire  $D$  sur-complet contenant  $K$  atomes ou vecteurs ( $D \in \mathbb{R}^{n \times K}$ ) avec  $n < K$  sous une contrainte de parcimonie c'est-à-dire une contrainte sur le nombre d'atomes de  $D$  choisies pour la décomposition (figure 2.11) :

$$\min_x \|x\|_0 \text{ sous la contrainte } y = Dx \quad (2.13)$$

Où  $x \in \mathbb{R}^K$  est la représentation parcimonieuse de  $y$ .  $\|x\|_0$  représente la norme -  $\ell_0$  et correspondant au nombre de valeurs non nulles de  $x$ . Les atomes  $d_k$  ( $k = 1, \dots, K$ ) de  $D$  sont tous normalisés. Il existe une infinité de solutions  $x$  au problème posé (2.13) ; l'objectif est de trouver la solution la plus parcimonieuse possible. En pratique, on peut rechercher une approximation du signal en minimisant l'erreur de représentation après avoir fixé une contrainte de parcimonie sur  $x$  : le problème devient :

$$\min_x \|y - Dx\|_2, \text{ sous la contrainte } \|x\|_0 \leq L \quad (2.14)$$

Avec  $L > 0$ , la contrainte de parcimonie. Cependant, résoudre ce problème est en général NP-difficile [183]. Plusieurs algorithmes de décomposition parcimonieuses dits « gloutons » ont été proposés dans la littérature [183-185] pour résoudre le problème de façon approximative.



Figure 2-11: Principe de représentation parcimonieuse

### 2.17.3. Algorithmes de décomposition parcimonieuse

Dans cette section, nous rappelons l'utilisation de quelques algorithmes de décomposition de faible complexité communément appelés « algorithmes de poursuite » dans la littérature, servant à résoudre le problème (2.14).

- Les algorithmes « gloutons » permettent d'obtenir une approximation sous-optimale du problème. Leur principe consiste à trouver à chaque itération le vecteur parcimonieux ou atome le plus corrélé au résidu courant, mis à jour après la sélection de chaque nouvel atome. Le résidu courant à une itération donnée est défini en faisant la différence entre le signal original et son approximation courante à travers les atomes jusque-là sélectionnés. Ainsi, l'erreur de reconstruction est progressivement réduite [184]. Pour accélérer la convergence, d'autres évitent de sélectionner plusieurs fois un atome. On citera notamment : l'algorithme Orthogonal Matching Pursuit (OMP) [185], Stagewise

Orthogonal Matching Pursuit (StOMP) [186], Subspace Pursuit (SP) [187], Optimized Orthogonal Matching Pursuit (OOMP) [188], ou les algorithmes Complementary Matching Pursuit (CMP) [190]. Enfin, [190, 191] font une excellente revue sur les méthodes itératives de seuillage et celles des algorithmes de Pursuit.

- Les algorithmes basés sur un relâchement de la norme  $\ell_0$ . Afin de régler le problème aux méthodes heuristiques devenues parfois contraignantes, une approche différente a consisté à remplacer la pseudo-norme  $\ell_0$  par la norme  $\ell_1$ . Ces algorithmes utilisent les techniques de programmation linéaire pour minimiser la norme  $\ell_1$  de la décomposition. On peut citer l'algorithme Basis Pursuit (BP) [192] et FOCal Underdetermined System Solver (FOCUSS) [193].
- Les algorithmes bayésiens expriment le problème des représentations parcimonieuses comme la solution d'un problème d'inférence bayésien afin d'appliquer des outils statistiques pour sa résolution. On peut nommer les algorithmes gloutons bayésiens tels que le Bayesian MP (BMP), Bayesian OMP (BOMP, KBOMP) décrits dans [194].

Nous retenons les algorithmes gloutons OMP dans la suite de nos travaux pour leur simplicité, rapidité et caractère séquentiel.

#### 2.17.4. Apprentissage de dictionnaire

Au-delà du critère de choix de l'algorithme de décomposition, une représentation parcimonieuse de qualité dépend fortement de l'espace dans lequel le signal est représenté. L'apprentissage de dictionnaire est une étape essentielle pour rendre les atomes plus efficaces que possible. C'est une approche très récente, dans la conception des dictionnaires. Les études ont montré qu'un dictionnaire appris, offre une meilleure qualité de reconstruction qu'un dictionnaire prédéfini [10].

##### 2.17.4.1. Formulation du problème

L'apprentissage de dictionnaire consiste à apprendre un dictionnaire  $D \in \mathbb{R}^{n \times K}$  sur un ensemble de  $N$  vecteurs d'apprentissage  $Y \in \mathbb{R}^{n \times N}$ , sous certaines contraintes de parcimonie. Son objectif est de trouver le dictionnaire optimal qui permettra de représenter efficacement l'ensemble des vecteurs d'apprentissage de façon parcimonieuse, de sorte que  $Y \approx DX$ , avec  $X \in \mathbb{R}^{K \times N}$  une matrice dont chaque colonne  $x_i, i = 1, \dots, N$  est parcimonieux. Le problème devient :

$$\min_{D, X} \|Y - DX\|_F^2, \text{ sous les contraintes } \|x_i\|_0 \leq L \forall i \text{ et } \|d_k\|_2 = 1 \forall k \quad (2.15)$$

où  $L > 0$  est la contrainte de parcimonie appliquée à chaque colonne  $x_i$  de  $X$  et désignant le nombre maximal de coefficients non nuls de chaque colonne  $x_i, i = 1, \dots, N$  et  $\|\cdot\|_F$  est la norme

de Frobenius :  $\|A\|_F = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2}$ .

Pour résoudre le problème (2.15), diverses méthodes d'apprentissage de dictionnaire ont été suggérées. Elles se composent de deux (2) étapes majeures : une première étape de représentation parcimonieuse dite étape de « codage parcimonieux » où les vecteurs parcimonieux sont appris par fixation du dictionnaire  $D$  afin de calculer  $X$  en utilisant les algorithmes de décomposition parcimonieuse et une deuxième étape où le dictionnaire  $D$  est mis à jour de façon itérative jusqu'à atteindre un critère d'arrêt. Le problème du codage parcimonieux peut alors s'écrire :

$$\min_{x_i} \|y_i - Dx_i\|_2^2, \text{ sous la contrainte } \|x_i\|_0 \leq L \quad \forall i \quad (2.16)$$

Pour la mise à jour du dictionnaire, le problème peut se résumer à :

$$\min_D \|Y - DX\|_F^2, \text{ sous les contraintes } \|d_k\|_2 = 1 \quad \forall k \quad (2.17)$$

Différentes méthodes de mise à jour du dictionnaire existent ; nous en présenterons quelques-unes dans la section suivante. Le lecteur, désireux de comprendre ces deux (2) étapes, pourra consulter la thèse de Aghaei [11].

#### 2.17.4.2. Dictionnaire

Ces dix dernières années ont connu un regain d'intérêt dans la recherche sur les représentations parcimonieuses, avec une attention particulière portée sur l'étude de dictionnaire et leur influence dans la représentation parcimonieuse [182, 195-197, 199]. Plusieurs types de dictionnaires sont nés de ces études : les dictionnaires parcimonieux [197, 200], les dictionnaires en ligne [201], les dictionnaires structurés [15], les dictionnaires avec une contrainte de non-négativité [10], les dictionnaires à signature d'image [203]. En effet, pour les tâches de classification ou d'indexation, il est intéressant de pouvoir concentrer toute l'information présente dans l'image, dans quelques coefficients seulement [203].

#### 2.17.4.3. Méthodes d'apprentissage de dictionnaires

Les méthodes d'apprentissage constituent le point focal de l'apprentissage automatique. Elles consistent à la résolution du problème de minimisation donné à l'équation 2.15. Les méthodes

d'apprentissage de dictionnaire utilisées pour apporter une solution à ce problème sont nombreuses ; quelques-unes sont résumées dans le tableau 2-5 ci-dessous. Elles obéissent toutes à deux (2) étapes : une étape de codage parcimonieux par l'usage des algorithmes « glouton », lorsqu'il s'agit de la pseudo norme  $\ell_0$ , tout en maintenant la contrainte sur le nombre d'éléments non nuls et une étape de mise à jour du dictionnaire  $D$ , par l'utilisation, dans le cas de K-SVD, de la décomposition à valeurs singulières (SVD). Pour ces méthodes, le critère d'arrêt peut être par exemple une fixation d'une erreur de représentation des vecteurs d'apprentissage à atteindre, un test de convergence de cette erreur ou un nombre maximum d'itération fixé.

*Tableau 2-5: Principaux algorithmes d'apprentissage de dictionnaire et leurs éléments constitutifs*

Nom des méthodes d'apprentissage	Approximations parcimonieuses	Mise à jour	Type
Approches probabilistes (Maximum de vraisemblance) [9]	Descente de gradient (calcul de coefficients) puis approximation parcimonieuse	Descente de gradient	Batch
MOD puis ILS-DLA, SGK (MOD + mise à jour séquentiel) [203, 207]	OMP, ORMP, FOCUSS [206]	Moindre carré	Batch
K-SVD [10]	OMP, MP	SVD+ moindre carré	Batch
Online K-SVD [200]	LARS [206]	Descente de gradient	Online
RLS-DLA. [204]	OMP	Moindre carré	Online

L'algorithme K-SVD [10], efficace et moins complexe que MOD, a montré de belles performances dans l'apprentissage et la mise à jour du dictionnaire dans des applications telles que la compression [208], la classification [198, 209], l'indexation d'images [210], etc.

Dans le but d'apprendre les dictionnaires parcimonieux, certains algorithmes d'apprentissage de dictionnaire imposant des contraintes aux dictionnaires, ont vu le jour tel que sparse K-SVD [200]. D'autres améliorations permettant d'apprendre les dictionnaires non- négative [10], des dictionnaires en ligne basés sur des approximations stochastiques [201] ont été proposées. Le tableau 2-6 présente les avantages et les inconvénients de chacune des méthodes couramment

utilisées dans l'apprentissage des structures rocheuses. Dans le tableau 2-6, les points noirs indiquent les avantages et les ronds blancs les inconvénients.

Tableau 2-6: Avantages et inconvénients des méthodes appliquées aux structures rocheuses

Méthodes de réduction de dimensions, d'apprentissage et de classification	Avantages et inconvénients
<b>ACP (Analyse à Composante Principale)</b>	<ul style="list-style-type: none"> <li>• <b>Temps d'exécution rapide</b></li> <li>○ Non performant devant un nombre élevé de caractéristiques</li> <li>○ Présence de bruit dans la réduction de dimensions des caractéristiques.</li> </ul>
<b>ANNs (Réseaux de neurone Artificiels),</b>	<ul style="list-style-type: none"> <li>• <b>Capacité d'un apprentissage superlatif</b> (s'adapte à une grande variété de problèmes)</li> <li>○ Non performant devant un nombre élevé de caractéristiques (beaucoup de paramètres à optimiser), apprentissage lent et difficile</li> <li>○ Choix du nombre de couches.</li> <li>○ Performance incohérente et imprévisible dans les données bruyantes donc associer un algorithme</li> </ul>
<b>SVM (Support à Vaste Marge)</b>	<ul style="list-style-type: none"> <li>• <b>Capacité d'un apprentissage superlatif, ne se prête pas à une utilisation en mode séquentiel car repose sur une optimisation globale sur l'ensemble des données d'apprentissage.</b></li> <li>○ Non performant devant un nombre élevé de caractéristiques</li> <li>○ Associer un algorithme de réduction de dimensions</li> </ul>
<b>K-Means, K-NN (K plus proche Voisin)</b>	<ul style="list-style-type: none"> <li>• <b>Rapide, Simple, robuste et facile à comprendre</b></li> <li>• <b>Capacité d'un apprentissage superlatif</b></li> <li>○ Performance liée au choix de K, d'un meilleur espace de couleur et sujet à la malédiction de la dimension, sensible au bruit.</li> <li>○ Coût important en stockage et en temps</li> </ul>
<b>Algorithme Boosting (AdaBoost)</b>	<ul style="list-style-type: none"> <li>• <b>Bonne performance et sur-apprentissage accepté</b></li> <li>○ Sensible au bruit, importance du choix des classifieurs faibles.</li> </ul>

Récemment, les recherches portées sur l'apprentissage de dictionnaires multi-échelle structurés [211, 15] ont vu le jour. Ces dictionnaires sont basés sur l'idée d'adapter chaque dictionnaire à

une itération de l'algorithme de poursuite, de sorte que les atomes soient sélectionnés séquentiellement dans les dictionnaires à différents niveaux en descendant les branches lors du codage parcimonieux. L'algorithme a l'avantage d'être aussi utilisé dans un apprentissage supervisé [212]. De cette approche, sont nés plusieurs algorithmes améliorés de K-SVD comme le Label Consistent K-SVD (LCK-SVD) [209], le Discriminative K-SVD (DK-SVD) [213]. Une récente étude, réalisée par Aghaei et al., en 2018 [15], fait une revue de toutes ces améliorations de K-SVD.

En parcourant les méthodes jusque-là utilisées pour l'indexation des structures rocheuses (voir tableau 2-6), nous constatons l'absence des méthodes de représentations parcimonieuses comme K-SVD. Nous pensons qu'elle peut être d'une grande utilité pour deux (2) raisons : la première est qu'elle est une généralisation de K-means, utilisée pour l'indexation des roches. La seconde raison est que, devant la redondance des données et la dimensionnalité élevée des descripteurs, cette méthode n'a pas besoin de combinaison avec d'autres méthodes pour être performante : les nombreuses études réalisées le confirment. De même, la structure de ces dictionnaires est bien adaptée aux grandes dimensions.

#### **2.17.4.4. Représentation parcimonieuse en indexation d'image**

Les représentations parcimonieuses permettent de représenter, de façon concise, l'information présente dans un signal ou dans une image. Plusieurs applications du traitement d'images comme la classification, la compression, l'indexation font usage de cette technique pour traiter les données d'une image. En indexation d'images, les caractéristiques des images sont représentées sous forme de vecteurs caractéristiques ou de signatures. Cette technique de classification est appliquée pour classer les images.

### **2.18. Conclusion partielle**

Dans ce chapitre, nous avons présenté l'état de l'art des différentes techniques d'extraction et d'analyse des caractéristiques de roches. Nous retenons que, même si la question sur la texture reste encore non maîtrisée, elle demeure, avec la couleur, les attributs les plus importants et les plus utilisés en traitement d'images, plus particulièrement dans le cas de l'analyse des roches. En outre, leur association améliore beaucoup la reconnaissance des roches. Cependant, le panel des travaux réalisés sur le motif binaire local ou Local Binary Pattern (LBP) avec leurs performances d'une part, d'autre part avec le rôle que jouent les filtres de Gabor et la DCT pour l'orientation dans les images de roches, nous retenons ces descripteurs pour l'extraction des caractéristiques locales et globales des roches.



## **Chapitre 3 Analyse d'images de roches par la représentation parcimonieuse des signaux K-SVD et des descripteurs de textures couleur**

*Ce chapitre comporte deux (2) parties. La première présente une analyse des roches en se basant sur les représentations parcimonieuses des signaux K-SVD pour l'estimation du dictionnaire et le descripteur de texture de Wang pour l'extraction des caractéristiques des roches. La deuxième partie fait l'analyse des roches en suivant le même processus avec la prise en compte de l'information couleur à partir du descripteur LBP couleur composite.*

### **3.1. Introduction**

Dans le précédent chapitre, nous avons vu que dans une approche classique, une bonne indexation des roches est toujours précédée d'une méthode ou d'une combinaison de méthodes discriminantes d'extraction des caractéristiques de textures couleur des roches. Ces méthodes doivent être robustes au bruit, à la rotation, au changement d'illumination, etc. De plus, avec les images de roches qui présentent des textures stochastiques, non-homogènes et directionnelles dans leur grande majorité, il est ardu d'extraire les caractéristiques des roches et faire une bonne classification. La complexité de traitement des textures de roches et le manque de définition universelle de la texture compliquent leur caractérisation. Pour toutes ces raisons, plusieurs méthodes ont été proposées dans la littérature : les méthodes les plus rencontrées sont les méthodes statistiques, fréquentielles et multi-échelles. Dans ce chapitre, nous présentons une analyse des roches faite en se basant sur les méthodes statistiques d'extraction de texture et de couleur : LBP et ALBPCSF. Cette analyse permet de discuter de la similarité entre les roches à travers dictionnaires estimés et appris avec K-SVD.

Ce chapitre est ainsi organisé : dans la section 2, nous analysons le rôle que jouent les méthodes d'extraction de caractéristiques de textures et de couleur dans l'estimation du dictionnaire d'une roche. La section 3 présente l'impact de l'apprentissage de dictionnaire sur la réduction de dimension des données. Nous terminons ce chapitre par une conclusion sur ces méthodes et l'application prochaine de combinaison de méthode d'extraction avec l'algorithme K-SVD pour l'estimation du dictionnaire des roches, dans le chapitre 4.

### **3.2. Estimation des dictionnaires des images de roches**

Pour mesurer la qualité d'estimation d'un dictionnaire, notre choix a porté sur la mesure de l'erreur de reconstruction. Cette erreur apparaît ici comme un facteur discriminant. L'objectif visé est de mesurer la corrélation entre les dictionnaires appris des roches. Dans la pratique, si


le dictionnaire estimé d'une roche correspond au dictionnaire d'une roche, ils sont fortement corrélés, donc similaires ; la variation d'erreur dans ce cas est plus faible.

### **3.2.1. Apprentissage de dictionnaire sur les images de roches**

L'un des aspects importants dans la représentation parcimonieuse des signaux repose sur la sélection du dictionnaire. Généralement, les données sont bien représentées par des dictionnaires génériques comme les bases de Fourier, les ondelettes et la DCT [216, 217]. Cependant, une autre stratégie, de plus en plus utilisée, consiste à prendre un ensemble de signaux qu'on veut représenter ; on les ajuste ensuite pour une généralisation. Dans [10], il a été introduit la méthode K-SVD pour l'ajustement des dictionnaires qui a fourni d'excellents résultats dans différents domaines. A notre connaissance, il n'y a, pour l'instant, aucune étude proposée pour l'apprentissage de dictionnaire avec les représentations parcimonieuses sur les images de roches. En 2014, Vivek et Auduithan [141] ont effectué une étude dans laquelle les caractéristiques extraites des roches sont décomposées par le biais d'un modèle de matrice de décomposition en valeurs singulières (SVD) pour obtenir une meilleure extraction des caractéristiques. Ils ont, par la suite, utilisé un algorithme Boosting, précisément le LPBoosting, en vue de la classification des roches.

#### **3.2.1.1. Analyse préliminaire**

La première étape dans ce processus concerne l'analyse faite sur les images de roches que nous avons appelées « images de vue directe ». Les attributs retenus dans cette analyse sont la couleur et la texture. Ces images, présentées à la figure 3.1, ont été prises dans la collection Roches Plutoniques et Métamorphiques-CRPG, Nancy : [64, 65]. Elles furent capturées dans l'espace colorimétrique RGB, rognées puis sauvegardées au format TIFF, avec une résolution 550\*380. Les images de vue directe de roches traitées ont révélé des différences concernant la couleur et la texture. Elles appartiennent donc à un groupe d'images dites « naturelles et non-homogènes ». Cela signifie qu'il y a un changement visible dans leurs propriétés visuelles. Dans notre étude, la texture représente des caractéristiques telles que l'agencement de zones hétérogènes à l'intérieur d'une image, c'est-à-dire la façon dont les minéraux dans une roche ont été ordonnés spatialement. Il y a ainsi parfois de fortes différences dans la directionnalité, la granularité, des propriétés texturales ou même de couleur, même quand les roches sont du même type.



*Figure 3-1: Echantillons des onze (11) types d'images de roches de notre base de données*  
Ces roches ont été regroupées en quatre (04) classes de roches, en tenant compte spécifiquement de la similarité entre les textures dans un premier temps (voir fig.3.2).

### **3.2.1.2. Apprentissage de dictionnaire sur les images de vue directe et sur les images de textures de Wang**

Dans la seconde étape de cette étude, la texture est caractérisée par le descripteur de textures de Wang appelé aussi descripteur LBP. L'algorithme K-SVD est utilisé pour l'apprentissage du dictionnaire. Nous appliquons ensuite K-SVD sur une série d'images couleurs de vue directe des différentes textures de roches plutoniques et métamorphiques de la figure 3.1, sous MATLAB. Dans un premier temps, nous avons appliqué directement K-SVD sur chaque image de roches de la figure 3.1, en vue de produire les dictionnaires correspondants. Puis, à ces mêmes images, nous appliquons l'opérateur LBP pour ensuite calculer le dictionnaire avec K-SVD. Ces nouvelles images de textures, obtenues par application de l'opérateur LBP, sont présentées à la figure 3-3.




Figure 3-2: Images des textures de roches de différentes classes




Figure 3-3: Textures LBP des différentes images de roches

A chaque exécution de l'algorithme, l'erreur de reconstruction du dictionnaire de chaque roche est déterminée et stockée dans le tableau 3-1 de la page suivante.

Le principe de la méthode proposée est présenté ainsi : L'approche suggérée est présentée à la figure 3.4. Elle consiste, d'abord à élaborer à travers K-SVD à partir d'une image initiale, à estimer un dictionnaire  $D_1$ , la matrice parcimonieuse  $X_1$  et l'erreur de reconstruction  $ER_1$ . Puis, un descripteur de textures de Wang est appliqué à l'image initiale pour produire une nouvelle image de textures. L'algorithme K-SVD est à nouveau utilisé sur la nouvelle image pour produire un nouveau dictionnaire  $D_2$ , une nouvelle matrice parcimonieuse  $X_2$  et une nouvelle

erreur de reconstruction  $ER_2$ . Le paramètre de signature retenu, visant à caractériser de façon discriminante une roche, est le vecteur d'erreur de reconstruction  $ER = (ER_1, ER_2)$ , obtenu à partir des deux (2) erreurs calculées précédemment. L'algorithme de l'approche proposée (voir figure 3-4) a été appliqué sur différentes images de vue directe de roche. Les résultats expérimentaux obtenus montrent la pertinence de la stratégie d'identification.




Figure 3-4: Principe de détermination du vecteur d'erreur de reconstruction

### 3.2.1.3. Résultats et discussions

Au niveau de cette étude, les paramètres utilisés dans ces expériences avec K-SVD sont : une taille de patch de  $64 \times 64$  pixels, le nombre de patch  $N=1500$  éléments et une contrainte de parcimonie fixée  $L=3$ . Il est à noter que l'algorithme est implémenté tel que décrit dans l'article [10], avec quelques changements au niveau des paramètres comme par exemple le nombre d'itérations. A chaque exécution, l'erreur de reconstruction est calculée, attestée par le tableau 3-1 ci-dessous.

Tableau 3-1: Erreurs calculées avec K-SVD et avec K-SVD+ operateur LBP

Images	$\epsilon_{\text{DIRECT}}=Er_1$	$\epsilon_{\text{LBP}}=Er_2$
Granite	<b>14,1168</b>	<b>81,909</b>
Migmatite831	<b>16,093</b>	77,9629
Gabbro	16,9709	<b>81,8896</b>
Granodiorite	17,5487	84,9519
Schiste936	20,693	88,323
Schiste951	25,7352	<b>81,8566</b>
Schiste31	19,7523	79,2792
Eclogite632	21,2636	75,6325
Corneenne53	<b>16,4047</b>	79,4652
Corneenne10	17,5066	<b>81,7228</b>
Cipolin	<b>14,5617</b>	<b>82,6792</b>

A l'analyse des résultats obtenus, le constat est que les images présentant des textures similaires de roches plutoniques ou/et métamorphique, appartenant à la même famille ou de familles différentes, ont des erreurs de reconstruction très proches ou voisines après un certain nombre d'itération (500-1000 itérations).

Il ressort que K-SVD, appliqué au descripteur LBP, fournit un dictionnaire avec des erreurs de reconstruction plus élevées que K-SVD, appliquée directement aux images de roche. La question est de savoir si cela est dû au fait que LBP a été appliquée à l'image avant K-SVD. En effet, les descripteurs LBP capturent les informations importantes et permettent une meilleure caractérisation de la texture de l'image. Les récentes recherches le confirment. Cela pourrait occasionner une erreur de reconstruction plus importante, contrairement au cas où le descripteur LBP n'a pas été appliquée à une image. Ces erreurs élevées sont aussi liées à la taille des images. Cependant, lorsque nous incluons le descripteur de couleur, couplé à un espace de couleur tel que HSI qui correspond bien à la vision humaine, l'erreur de reconstruction est améliorée.

L'application du descripteur LBP + K-SVD aux images de roches révèle deux (02) avantages essentiels :

- Une similarité plus accentuée par rapport au cas où K-SVD est appliqué uniquement et des valeurs de SSIM (Structural SIMilarity) [218] (voir tableau 3.2) calculées confirment cette information (supérieur à 50% de similarité). Ces valeurs du SSIM montrent que la plus grande majorité des minéraux des roches d'un type se retrouve dans d'autres types de roches quand même elles n'appartiennent pas à la même famille, confirmant la difficulté rencontrée dans l'analyse des roches non-homogènes.
- L'application du descripteur LBP sur la texture des roches suivie de K-SVD rend la méthode plus discriminante certifiée par les résultats du tableau 3.2 ci-dessous.

*Tableau 3-2: Valeurs SSIM des échantillons des images photographiques de roches*

<b>Valeurs en % des SSIM des échantillons des images photographiques de roches sélectionnées de notre base de données</b>											
Images	1-1	1-2	1-3	1-4	1-5	1-6	1-7	1-8	1-9	1-10	1-11
K-SVD	100,00	42,45	48,84	47,32	45,19	44,46	46,06	48,05	43,59	46,07	45,94
LBP_K-SVD	100,00	56,62	59,16	56,01	54,64	55,93	55,90	55,55	56,93	57,63	56,05

Une autre analyse plus complète et descriptive montre que :

- **Analyse1 : Granite – Cipolin** : La valeur de  $Er_1$  justifie la similarité se traduisant par la géométrie des grains (texture grenue et granoblastique). Cependant, avec le descripteur LBP, la valeur  $Er_2$  révèle le caractère « degré de cristallisation ». En effet, bien que ces roches soient cristallisées (grenue et granoblastique), l'expression « forme propre » s'exprime mieux chez le granite, avec une légère différence au niveau de la composition minéralogique.
- **Analyse 2 : Migmatite- Gabbro- Cornéenne53** : La similarité exprimée par la texture grenue et granoblastique est due à des températures de cristallisation semblables. En effet, le Gabbro (roche magmatique), la Migmatite (roche métamorphique) et la Cornéenne (roche métamorphique de contact) ont des degrés de cristallisation élevés. Mais, il existe des Cornéennes à températures basses ; c'est ce qui explique la différence de valeur des  $Er_1$  avec les Cornéennes10.
- **Analyse 3 : Gabbro-Cornéenne10** : Les valeurs similaires de  $Er_2$  dans ce cas, montrent que le Gabbro et la Cornéenne10 ont des structures semblables et conformes à celles du granite.

Cependant, la différence entre l'erreur de reconstruction des patches avec K-SVD et LBP\_K-SVD, montre qu'elle apparaît ici comme un facteur discriminant pour le calcul de dictionnaire dans la reconnaissance. Les résultats de simulation confirment la précision dans le calcul de dictionnaire réalisé par les méthodes de clustering que nous avons rencontrées dans la littérature.

L'indexation et la recherche d'images par le contenu pour la reconnaissance automatique des roches, sont des problèmes très complexes mais incontournables étant donné l'importance attachée à l'image numérique dans notre quotidien. Le travail dans cette partie s'inscrit dans le cadre de l'utilisation des techniques de traitement d'image pour améliorer de la performance la reconnaissance des roches. A cet effet, nous avons présenté dans cette section la méthode K-SVD appliquée à des images de roches avec l'apprentissage de dictionnaire puis avons associée à LBP, un descripteur de texture beaucoup utilisé, dans l'analyse des textures, donnant de bons indices de discrimination avec des images naturelles. Comme constaté, la recherche de similarité faite directement à partir d'images de vue directe ne nous permet pas de trouver une correspondance totale entre les roches. Il est donc nécessaire d'en extraire au préalable les

informations représentatives avec des descripteurs de textures. Cependant, la couleur demeure l'une des caractéristiques fondamentales dans l'analyse de la texture couleur.

### 3.2.2. Apprentissage de dictionnaire sur les images de textures couleur

Dans cette section, une nouvelle représentation des caractéristiques, basées, sur l'analyse de la texture couleur pour la reconnaissance des roches, est utilisée. L'objectif est d'associer la couleur à la texture pour une meilleure caractérisation des roches. Le principe adopté exploite à la fois les caractéristiques discriminantes de couleur et de texture d'une image de roche à partir d'un descripteur LBP composite dans le but de faire une identification automatique, rapide et efficace des roches. En effet, le descripteur de texture colorimétrique ALBPCSF (Adjacent Local Binary Pattern based on Color Space Fusion) dérive de la concaténation des caractéristiques LBP de texture et les caractéristiques de couleur avec la fusion des deux (02) espaces colorimétriques RGB et HSV. Dans notre méthodologie, nous avons d'abord appliqué ALBPCSF sur des images de deux (02) différentes familles de roches : les roches magmatiques et les roches métamorphiques, afin de produire des images de textures colorimétriques. Ensuite, l'algorithme de dictionnaire  $K$ -SVD ( $K$ -Singular Value Decomposition), avec un choix de paramètres adéquats, est appliqué aux dites images de textures produites, pour calculer une signature des roches de notre base d'images. Pour l'apprentissage de dictionnaire, la méthode  $K$ -SVD utilise l'Orthogonal Matching Pursuit (OMP) comme algorithme de codage parcimonieux des coefficients.

#### 3.2.2.1. Principe de la méthode

La caractérisation de la reconnaissance des roches s'appuie ici sur le paramètre erreur de reconstruction  $E_r$  défini et estimé dans l'algorithme  $K$ -SVD. Le principe de l'approche proposée est présenté à la figure 3.5. Trois (3) erreurs de reconstruction sont calculées de différentes manières. La première erreur, nommée  $E_{r_1}$  est calculée en appliquant directement l'algorithme  $K$ -SVD sur chaque image de vue directe des roches de la base d'image. La deuxième erreur, notée  $E_{r_2}$  est obtenue en appliquant d'abord l'algorithme LBP à chaque image de la base, produisant ainsi des images de textures, suivie de l'application de l'algorithme  $K$ -SVD sur les images de textures. La troisième erreur, notée  $E_{r_3}$  est calculée de la même manière que la deuxième, sauf que le LBP est remplacé par l'algorithme de textures couleur (ALBPCSF). Nous avons opté pour une personnalisation de l'algorithme ALBPCSF en considérant deux (2) pixels centraux appariés avec comme valeur de paramètres un rayon d'un (1) pixel et une distance de deux (2) pixels entre les deux (2) centres de pixels de LBP paire. En effet, quatre (4) voisins



connexes sont considérés. Ces voisins sont pris sur la verticale et l'horizontale de chacun des deux centres de pixel choisis. En considérant le premier LBP de centre de pixel  $(i, j)$ , le second LBP apparié a pour centre de pixel  $(i, j+3)$ . Soient  $I_1$  et  $I_2$  respectivement deux (2) images issues des deux (2) canaux spectraux RGB et HSV. Soient  $T_{11}$  et  $T_{12}$  les matrices, contenant chacune les quatre (4) voisins centrés du LBP paire issu de l'image  $I_1$ , et  $T_{21}$  et  $T_{22}$  les matrices, contenant chacune les quatre (4) voisins du LBP paire de l'image  $I_2$ . Les matrices  $T_{11}$ ,  $T_{12}$ ,  $T_{21}$  et  $T_{22}$  sont calculées par la différence entre les pixels centraux et leurs voisins à partir de la formule (3.1).

$$\begin{aligned} T_{1i}(k) &= I_1(g_k) - I_1(g_c) \\ T_{2i}(k) &= I_2(g_k) - I_2(g_c) \end{aligned} \quad (3.1)$$

où  $i = 1, 2$  et  $k \in \{0, 1, 2, 3\}$ ;  $T_{1i}(k)$  et  $T_{2i}(k)$  sont les matrices;  $I_1(g_k)$  est la valeur du pixel voisin dans le canal RVB.  $I_1(g_c)$  et  $I_2(g_c)$  sont les valeurs des pixels centraux des canaux RVB et HSV.

Une binarisation des matrices  $T_{11}$ ,  $T_{12}$ ,  $T_{21}$  et  $T_{22}$  est réalisée et stockée dans des matrices  $T_U$  et  $T_L$  définies par les formules (3.2) et (3.3) ci-dessous :

$$T_U = \begin{cases} 1 & \text{si } T_{11}(k) > 0 \text{ et } T_{21}(k) > 0 \\ 0 & \text{sinon} \end{cases} \quad (3.2)$$

$$T_L = \begin{cases} 1 & \text{si } T_{12}(k) < 0 \text{ et } T_{22}(k) < 0 \\ 0 & \text{sinon} \end{cases} \quad (3.3)$$

$$\text{Codage}U = \sum_{k=0}^3 T_U(k) \times 2^k \quad (3.4)$$

$$\text{Codage}L = \sum_{k=0}^3 T_L(k) \times 2^k \quad (3.5)$$

Un codage décimal est ensuite effectué sur les matrices  $T_U$  et  $T_L$  pour obtenir des scalaires nommés  $\text{Codage}U$  et  $\text{Codage}L$  exprimés par les formules (3.4) et (3.5), variant entre 0 et 15 avec enfin la combinaison de leur paire qui varie entre 0 et 255.

Soit une image couleur  $I$ , de composante colorimétrique  $I_R$ ,  $I_G$  et  $I_B$  dans l'espace RGB initial. Sa transformation dans l'espace HSV donne lieu aux composantes colorimétriques  $I_H$ ,  $I_S$  et  $I_V$ . Un appariement de composante  $I_V$  aux composantes  $I_R$ ,  $I_G$  et  $I_B$  est par la suite effectué. A ces appariements, est appliqué l'algorithme ALBPCSF pour obtenir une image couleur de type U notée  $\text{Image}U$  et une image couleur de type L notée  $\text{Image}L$ . A la fin, nous avons retenu l'image couleur de type U, la seule contenant des informations exploitables pour notre cas. C'est à cette

image que nous avons appliqué l'algorithme K-SVD et obtenir l'erreur colorimétrique notée  $Er_3$ .

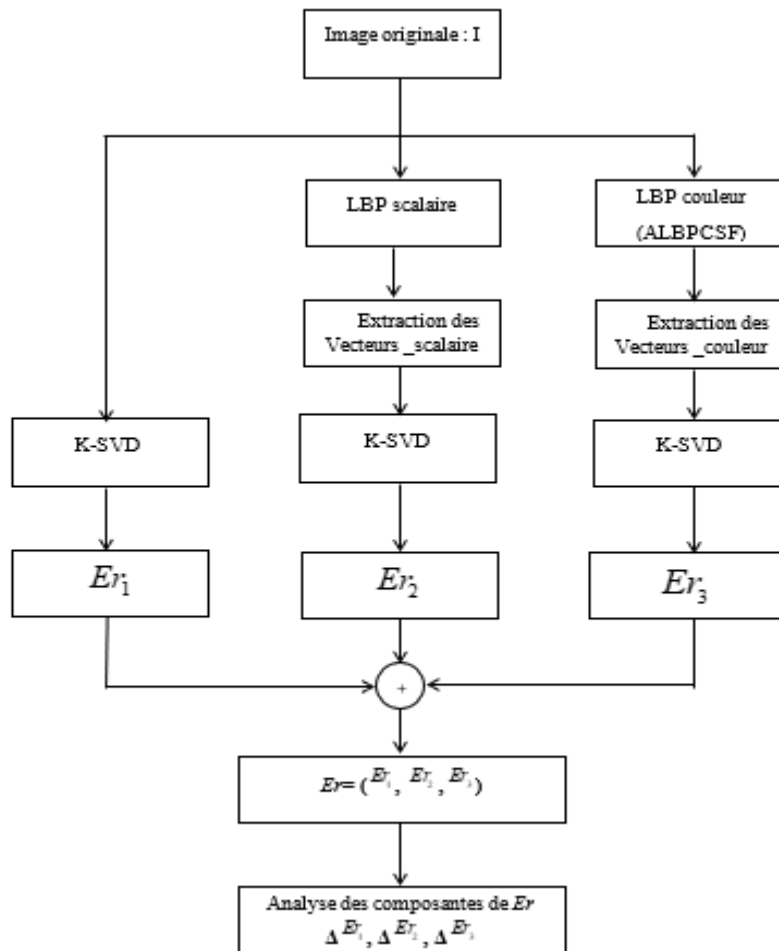


Figure 3-5: Organigramme du principe de l'approche proposée

### 3.2.2.2. Résultats et discussion

Cette section présente les résultats expérimentaux détaillés du principe adopté. Onze (11) images de vue directe de différentes roches de familles magmatique et métamorphique de notre base de données sont utilisées dans cette section pour mettre en évidence les performances de notre approche. Le matériel de recherche utilisé dans cette étude est un ensemble de onze (11) images photographiées de différents types de roches avec des caractéristiques différentes. Ce sont : le granite, le granodiorite, le gabbro, les schistes, la migmatite, l'éclogite, les cornéennes et le cipolin. Ces images, capturées dans l'espace colorimétrique RGB, une fois prises, ont été sauvegardées au format TIFF, avec une résolution 256\*256. Nous avons regroupé les images en quatre (4) classes (classe 1, classe 2, classe 3, classe 4), selon certaines similarités texturales et colorimétriques visuelles, présentées à la figure 3.2 du paragraphe 3.2.1.1.

Dans la classe 4 de la figure 3.2, les textures des roches sont assez régulières, avec une faible granularité (structure homogène) mais différentes dans la directionnalité. Cependant, la directionnalité dans les textures des classes 1, 2 et 3 sont clairement non homogènes, avec des textures montrant une variation de structures en gros grains (forte granularité). Lepisto et al. [85] confirment que la classification des textures de roches prend en compte la taille des grains (forte granularité ou non), leur directionnalité et les propriétés colorimétriques.

L'exécution de notre programme sous MATLAB est réalisée avec un ordinateur HP Notebook Processeur Intel(R) Core (TM) i5-7200U CPU @ 2.50GHz, 2701 MHz, 2 cœur(s), 4 processeur(s) logique(s), carte graphique Radeon avec un Windows 10 système entreprise.

Pour la tâche de classification, nous avons utilisé des images couleur RGB de vue directe de roche de dimensions 256x256x3. En appliquant les algorithmes ALBPCSF et LBP scalaire, nous obtenons les images de textures couleur et des images de textures en niveaux de gris présentées aux figures 3-6, 3-7, 3-8 et 3-9.

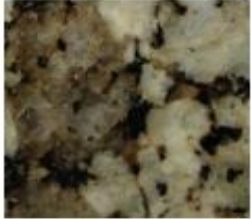
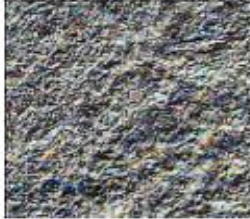
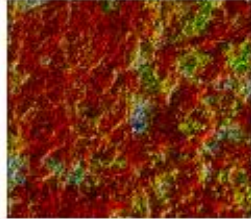


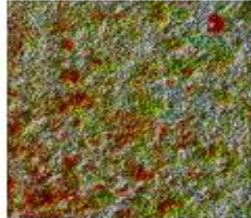
Granite			
	Image originale	Image LBP en niveau de gris	Image LBP couleur
Granodiorite			
	Image originale	Image LBP en niveau de gris	Image LBP couleur

Figure 3-6: Images de la classe 1



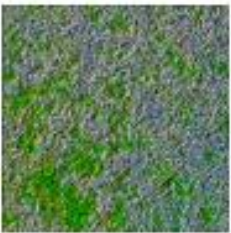
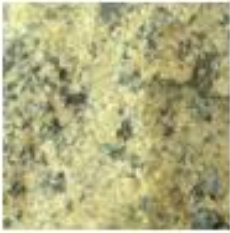

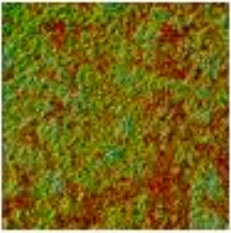

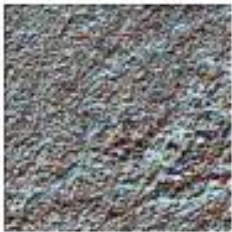
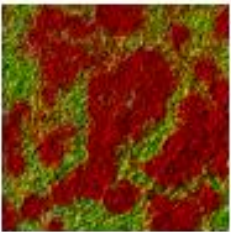
<i>Schiste951</i>			
	Image originale	Image LBP en niveau de gris	Image LBP couleur
<i>Schiste31</i>			
	Image originale	Image LBP en niveau de gris	Image LBP couleur
<i>Cipolin</i>			
	Image originale	Image LBP en niveau de gris	Image LBP couleur

Figure 3-7: Images de la classe 2



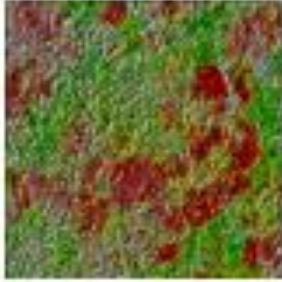


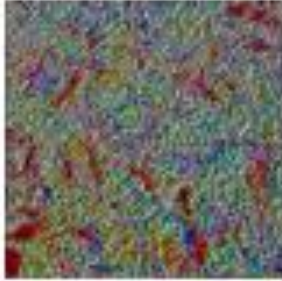

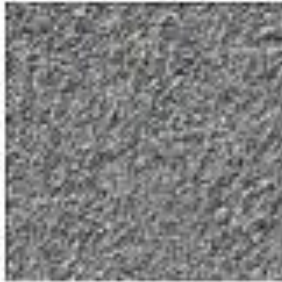

<b>Eclogite</b>			
	Image originale	Image LBP en niveau de gris	Image LBP couleur
<b>Gabbro</b>			
	Image originale	Image LBP en niveau de gris	Image LBP couleur
<b>Migmatite</b>			
	Image originale	Image LBP en niveau de gris	Image LBP couleur

Figure 3-8: Images de la classe 3



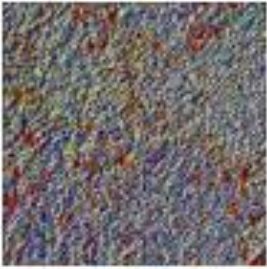
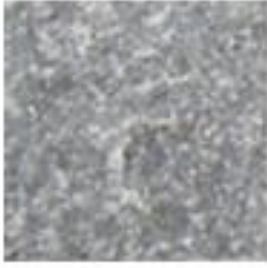

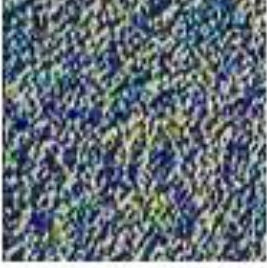
<b>Cornéenne53</b>			
	Image originale	Image LBP en niveau de gris	Image LBPcouleur
<b>Cornéenne10</b>			
	Image originale	Image de texture en niveau de gris	Image de texture couleur

Figure 3-9: Images de la classe 4

Notre méthode de classification est une méthode de calcul et d'apprentissage non supervisé. Les erreurs de reconstructions calculées pour chaque type de textures d'images par notre approche sont présentées dans différents tableaux (Tableau 3.3, Tableau 3.4, Tableau 3.5), suivies de l'analyse et l'interprétation des données dans les sections ou paragraphes, juste après. Dans le tableau 3-3, ce sont les résultats de calcul des différentes erreurs de reconstruction. La première analyse faite sur les valeurs des erreurs de reconstruction ( $Er_1$ ,  $Er_2$  et  $Er_3$ ), montre que chacune des différentes méthodes (K-SVD, K-SVD\_LBP et K-SVD\_ALBPCSF) joue un rôle important dans la classification des roches. Il n'existe pas de corrélation linéaire visible entre les différentes valeurs des erreurs de reconstruction. Cela se justifie par l'hétérogénéité de leurs caractéristiques et confirme dès lors les difficultés rencontrées dans la classification manuelle. En effet, la colonne 4 du tableau 3.3 révèle que  $Er_2 = 16,673$  pour la cornéenne53 est la plus petite valeur de cette colonne. Ces valeurs confrontent la texture fine de la cornéenne53 à la texture granoblastique des autres roches (magmatiques et plutoniques) du tableau 3.3 et confirment l'efficacité de l'opérateur LBP sur la texture des roches comme révélé dans [52]. Les trois (3) valeurs plus faibles de la 3<sup>ème</sup> colonne correspondent à des images où les couleurs

claires sont dominantes. La deuxième colonne ( $Er_1$ ) montre une similarité géométrique des grains avec d'un côté, les valeurs plus faibles pour les fortes granularités, et de l'autre, des valeurs plus élevées lorsque les grains sont plus petits.

Tableau 3-3: Erreurs de reconstruction calculées

Images de roche	$Er_1$	$Er_2$	$Er_3$
Granite	1,1694	18,9879	16,6968
Granodiorite	1,9671	19,8687	<b>20,2557</b>
Gabbro	2,2284	18,3108	<b>19,6160</b>
Cipolin	1,5716	20,0325	16,9661
Migmatite381	1,9809	19,2034	<b>19,3918</b>
Eclogite632	3,1678	19,1813	<b>19,8531</b>
Cornéenne53	2,0213	<b>16,673</b>	<b>19,8962</b>
Cornéenne10	2,4666	18,0263	<b>20,0042</b>
Schiste31	2,2651	18,3735	17,4324
Schiste951	4,2882	18,4481	<b>20,5470</b>
Schiste936	3,0896	17,0726	<b>20,3171</b>

A l'analyse de ce tableau, hormis le granite, le Cipolin et le Schiste31, les valeurs des erreurs LBP couleur ( $Er_3$ ) sont supérieures à celles des erreurs LBP standard ( $Er_2$ ) mais, avec des variations d'erreur beaucoup plus faibles pour ces 03 images, montrant une grande similarité entre ces roches. Cela est aussi dû au fait que les caractéristiques couleurs aient été prises en compte et sont discriminantes, comme indiqué dans [3]. En outre, dans ces images, les textures grenues et granoblastiques sont plus révélées.

Les valeurs de LBP couleurs ( $Er_3$ ) laissent voir une similarité dans la couleur et révèlent des textures grenues ayant des orientations similaires avec des températures de cristallisation plus élevées. Toutefois, quelques différences : c'est le cas de la cornéenne10.

Les valeurs de LBP couleurs (Er3) montrent une similarité dans la texture (texture microlitique) mais mettent en relief une très grande différence entre les minéraux existant dans ces roches. Dans le tableau 3.4, les variations d'erreur de reconstruction sont calculées par familles de roches afin de dégager d'éventuelles similarités entre les roches.

*Tableau 3-4: Analyse des variations d'erreur des roches de familles identiques*

Type de roche	Roches de même famille	$ \Delta\varepsilon_{LBPcouleur} $	$ \Delta\varepsilon_{LBP} $	$ \Delta\varepsilon_{DIRECT} $
Roches magmatiques	Granite - Gabbro	2.9192	<b>0.6771</b>	1.0590
	Granite – Granodiorite	3.5589	<b>0.8808</b>	<b>0.7977</b>
	Gabbro - Granodiorite	<b>0.6397</b>	1.5579	<b>0.2613</b>
Roches métamorphiques	Schiste31 – Cornéenne53	2.4638	1.7005	<b>0.2438</b>
	Cornéenne10- Schiste951	<b>0.5428</b>	<b>0.4218</b>	1.8216
	Cornéenne10 - cipolin	3.0381	2.0062	<b>0.8950</b>
	Schiste951 - Cipolin	3.5809	1.5844	2.7166
	Schiste31 – Schiste936	2.8847	1.3009	<b>0.8239</b>
	Migmatite – Cornéenne53	<b>0.5044</b>	2.5304	<b>0.0404</b>
	Schiste31-Schiste951	3.1146	<b>0.0746</b>	2.0231
	Cornéenne10-Cornéenne53	<b>0.1080</b>	1.3533	<b>0.4453</b>
	Migmatite – Cornéenne10	<b>0.6124</b>	1.1771	<b>0.4857</b>
	Migmatite – Cipolin	2.4257	<b>0.8291</b>	<b>0.4093</b>
	Migmatite -Schiste31	1.9594	0.8299	<b>0.2842</b>
	Migmatite -Schiste951	1.1552	<b>0.7553</b>	2.3073
	Migmatite -Schiste936	<b>0.9253</b>	2.1308	1.1089
	Cipolin – Schiste31	<b>0.4663</b>	1.6590	<b>0.6935</b>
	Cipolin – Schiste951	3.5809	1.5844	2.7166
Cipolin – Schiste936	3.3510	2.9599	1.5180	

Les valeurs en gras des erreurs de reconstruction, de vue directe, LBPcouleur et LBP, inférieures à un (1), montrent une bonne relation de correspondance entre les dictionnaires des roches croisées. La similarité entre deux (2) dictionnaires de roches est plus accentuée quand les valeurs sont plus faibles et quant aux moins deux valeurs du croisement sont en gras.

- Ce tableau révèle des similarités de structures (texture grenue, granoblastique et microlitique) entre les roches appartenant à la même famille (magmatique ou métamorphique)



- Le tableau montre une relation particulière entre le granite et le granodiorite au niveau de la structure, avec une grande différence de couleur, prouvant ici une différence de minéraux.
- Les roches Migmatite, Cornéenne10 et Schiste936 ont une certaine similarité de couleur avec des minéraux en commun, mais une grande similarité de structure entre les deux (2) premières roches et le Schiste31. Entre la cornéenne53 et la migmatite, il y a une certaine ressemblance.

### 3.2.2.3. Similarité des roches de familles différentes

L'identification des roches est une étude ardue et particulière. Quelques roches de familles différentes peuvent avoir des ressemblances avérées par l'observation visuelle concernant la couleur pour marquer la présence de minéraux identiques, la texture et la directionnalité dans la texture. Notre étude réalisée vient le confirmer. Le tableau 3.5 montre les variations d'erreur de reconstruction calculées pour des familles de roches différentes afin de dégager d'éventuelles similarités entre ces roches.

Tableau 3-5: Analyse des variations d'erreur des roches de familles différentes

Roches de familles différentes				
Roches magmatiques	Roches métamorphiques	$ \Delta\varepsilon_{LBP} $	$ \Delta\varepsilon_{DIRECT} $	$ \Delta\varepsilon_{LBPcouleur} $
Granite	Migmatite831	<b>0.2155</b>	<b>0.8115</b>	2.6950
	Schiste31	<b>0.6144</b>	1.0957	<b>0.7356</b>
	Cipolin	1.0446	<b>0.4022</b>	<b>0.2693</b>
Gabbro	Cornéenne10	<b>0.8926</b>	<b>0.2382</b>	<b>0.3882</b>
	Schiste951	<b>0.1373</b>	2.0559	<b>0.9310</b>
	Migmatite831	<b>0.8926</b>	<b>0.2475</b>	<b>0.2318</b>
	Cornéenne53	<b>0.8926</b>	<b>0.2071</b>	<b>0.2802</b>
	Eclogite632	<b>0.8705</b>	<b>0.9394</b>	<b>0.2371</b>
Granodiorite	Cornéenne10	1.8424	<b>0.4995</b>	<b>0.2515</b>

L'analyse des variations met en exergue de très grandes similarités de couleur, de structures et de textures entre des roches de familles différentes, confirmant ainsi, la présence de minéraux identiques dans ces roches. Cela atteste que certaines roches métamorphiques sont d'origine magmatique (c'est le cas par exemple de l'Eclogite et le Schiste 951). On note précisément une

forte ressemblance dans la structure (directionnalité et l'orientation) et la couleur entre le Gabbro et les roches métamorphiques (couleur sombre) telles que la Migmatite, la Cornéenne53, la Cornéenne10, comme stipulé au paragraphe 3.2.2). Une autre similarité entre le granite et les roches métamorphiques : le schiste31, la migmatite831 et le cipolin, est assez palpable. Ce tableau dévoile l'existence d'une très grande régularité entre la reconnaissance visuelle et notre algorithme proposé.

### 3.2.2.4. Calcul d'erreur relative

Les tableaux (3.6) et (3.7) font état des erreurs relatives obtenues à partir d'erreurs de reconstruction de dictionnaire.

*Tableau 3-6: Erreurs relatives avec des roches de même famille*

Erreur relative calculée sur les erreurs de reconstruction de dictionnaire				
Familles de roches	Roches de même famille	Erreur relative LBP couleur	Erreur relative LBP	Erreur relative Direct
Roches magmatiques	Granite-Gabbro	0,1488	0,0357	0,4752
	Granite-Granodiorite	0,1756	0,0443	0,4055
	Gabbro-Granodiorite	0,0316	0,0784	0,1173
Roches métamorphiques	Schiste31 – Cornéenne53	<b>0,1238</b>	<b>0,0926</b>	<b>0,1076</b>
	Cornéenne10- Schiste951	0,0264	0,0229	0,4248
	Cornéenne10 - cipolin	0,1519	0,1112	0,3628
	Schiste951 - Cipolin	0,1743	0,0828	0,6335
	Schiste31 – Schiste936	0,1516	0,0040	0,4718
	Migmatite – Cornéenne53	<b>0,0254</b>	<b>0,1317</b>	<b>0,0200</b>
	Schiste31-Schiste951	0,1516	0,0040	0,4718
	Cornéenne10-Cornéenne53	0,0054	0,0751	0,1805
	Migmatite – Cornéenne10	0,0306	0,0432	0,1969
	Migmatite – Cipolin	0,1251	0,0414	0,2066
	Migmatite -Schiste31	0,1010	0,0432	0,1255
	Migmatite -Schiste951	0,0562	0,0393	0,5381
	Migmatite -Schiste936	0,0455	0,1110	0,3588
	Cipolin – Schiste31	0,0267	0,0828	0,3062
Cipolin- Schiste 936	0,1649	0,1478	0,4913	

Ces erreurs relatives mettent à nu une certaine similarité des dictionnaires calculés pour les différentes combinaisons de roches. Les similarités sont plus accentuées avec les dictionnaires calculés, tenant compte des caractéristiques de texture et de couleur.

L'erreur relative commise est plus grande, lorsqu'aucune méthode d'extraction n'est employée pour extraire les caractéristiques avant l'application de l'algorithme K-SVD : l'extraction des caractéristiques est donc une étape essentielle dans le processus d'identification des roches. Quelle méthode ou quelles combinaisons de méthodes faudra-il utiliser afin d'aboutir à une efficiente classification ?

Tableau 3-7: Erreurs relatives avec des roches de nature différence

Erreur relative calculée sur les erreurs de reconstruction de dictionnaire				
Roches magmatiques	Roches métamorphiques	Erreur relative LBP couleur	Erreur relative LBP	Erreur relative Direct
Granite	Migmatique831	0,1390	0,0112	0,4097
	Schiste31	0,0422	0,0323	0,4837
	Cipolin	0,0159	0,0521	0,2559
Gabbro	Cornéenne10	<b>0,0194</b>	<b>0,0155</b>	<b>0,0966</b>
	Schiste951	0,0453	0,0074	0,4803
	Migmatite831	0,0114	0,0465	0,1111
	Cornéenne53	<b>0,0141</b>	<b>0,0894</b>	<b>0,0929</b>
	Eclogite632	0,0119	0,0454	0,2965
Granodiorite	Cornéenne10	0,0124	0,0927	0,2025

### 3.2.2.5. Similarité des roches à partir de l'utilisation des métriques : la moyenne, le maximum et la distance L2

En traitement d'images, dans les applications de classification, la similarité entre deux (2) classes peut s'exprimer par le biais d'une mesure de distance. Plusieurs métriques de distance existent dans la littérature. Pour mesurer la similarité entre deux (2) roches, nous utilisons trois mesures de distance qui sont : la moyenne, le maximum et la distance L2. Dans le principe, deux (2) roches sont jugées similaires par une métrique de distance, si elle donne la plus petite valeur pour leur croisement. Cependant, lorsque les trois (3) métriques de distance donnent les plus petites valeurs, alors la similarité entre les roches croisées est plus grande, si non la similarité peut être soit au niveau de la couleur, de la texture soit de la structure. Les tableaux (3.8) et (3.9) donnent le calcul avec les trois (3) métriques de distance pour les croisements

entre roches magmatiques ensuite les roches métamorphiques enfin entre roches de différentes familles.

Tableau 3-8: Analyse des variations d'erreur des roches de même famille avec trois (3) métriques choisies : la moyenne (Moy), le maximum (Max) et la distance L2

Type de roche	Roches de même famille	$ \Delta\epsilon_{fLBPcouleur} $	$ \Delta\epsilon_{fLBP} $	$ \Delta\epsilon_{fDIRECT} $	Mesure 1 : Moy	Mesure 2 : Max	Mesure 3 : Distance L2
Roches magmatiques	Granite - Gabbro	2,6480	<b>0,6771</b>	1,0590	1,4614	2,648	2,9312
	Granite – Granodiorite	3,5589	<b>0,8808</b>	<b>0,7977</b>	1,7458	3,5589	3,7520
	Gabbro - Granodiorite	<b>0,6397</b>	1,5579	<b>0,2613</b>	<b>0,8196</b>	1,5579	1,7043
Roches métamorphiques	Schiste31 – Cornéenne53	2,4638	1,7005	<b>0,2438</b>	1,4694	2,4638	3,004
	Cornéenne10- Schiste951	<b>0,5428</b>	<b>0,4218</b>	1,8216	<b>0,9287</b>	1,8216	1,9470
	Cornéenne10 - cipolin	3,0381	2,0062	<b>0,895</b>	1,980	3,0381	3,7491
	Schiste31 – Schiste936	2,8847	1,3009	<b>0,8239</b>	1,6698	2,8847	3,270
	Migmatite – Cornéenne53	<b>0,5044</b>	2,5304	<b>0,0404</b>	1,0251	2,5304	2,5805
	Schiste31-Schiste951	3,1146	<b>0,0746</b>	2,0231	1,7374	3,1146	3,7147
	Cornéenne10-Cornéenne53	<b>0,108</b>	1,3533	<b>0,4453</b>	<b>0,6355</b>	1,3533	1,4288
	Migmatite – Cornéenne10	<b>0,6124</b>	1,1771	<b>0,4857</b>	<b>0,7584</b>	1,1771	1,4130
	Migmatite – Cipolin	2,4257	<b>0,8291</b>	<b>0,4093</b>	1,2214	2,4257	2,5959
	Migmatite -Schiste31	1,9594	0,8299	<b>0,2842</b>	1,0245	1,9594	2,1468
	Migmatite -Schiste951	1,1552	<b>0,7553</b>	2,3073	1,4059	2,3073	2,6886
	Migmatite – Schiste 936	<b>0,9253</b>	2,1308	<b>1,1089</b>	1,3883	2,1308	2,5741
	Cipolin – Schiste31	<b>0,4663</b>	1,659	<b>0,6935</b>	<b>0,9396</b>	1,659	1,8576
	Cipolin – Schiste951	3,5809	1,5844	2,7166	2,6273	3,5809	4,7658
Cipolin – Schiste936	3,351	2,9599	1,518	2,6096	3,351	4,7217	

Tableau 3-9: Analyse des variations d'erreur des roches de familles différentes avec les trois (3) métriques : Moyenne (Moy), le maximum (Max) et la distance L2

Roches de familles différentes							
Roches magmatiques	Roches métamorphiques	$\Delta\epsilon_{\text{FLBP}}$	$\Delta\epsilon_{\text{DIRECT}}$	$\Delta\epsilon_{\text{ALBPCSF}}$	Mesure1 : Moy	Mesure 2 : Max	Mesure 3 : Distance L2
Granite	Migmatite	0,2155	0,8115	2,695	1,2407	2,695	2,8227
	Schiste31	0,6144	1,0957	0,7356	0,8152	1,0957	1,4557
	Cipolin	1,0446	0,4022	0,2693	0,5720	1,0446	1,1513
Gabbro	Cornéenne10	<b>0,8926</b>	<b>0,2382</b>	<b>0,3882</b>	<b>0,5063</b>	<b>0,8926</b>	<b>1,0021</b>
	Schiste951	<b>0,1373</b>	2,05598	<b>0,931</b>	1,0414	2,056	2,2611
	Migmatite	<b>0,8926</b>	<b>0,2475</b>	<b>0,2318</b>	<b>0,4573</b>	<b>0,8926</b>	<b>0,9548</b>
	Cornéenne53	<b>0,8926</b>	<b>0,2071</b>	<b>0,2802</b>	<b>0,4600</b>	<b>0,8926</b>	<b>0,9582</b>
	Eclogite	<b>0,8705</b>	<b>0,9394</b>	<b>0,2371</b>	0,6823	0,9394	1,3025
Granodiorite	Cornéenne10	1,8424	<b>0,4995</b>	<b>0,2515</b>	0,8445	1,8424	1,9254

L'analyse des tableaux 3.8 et 3.9 ci-dessus révèlent quelques similarités entre les roches de même famille ou de familles différentes :

Pour les roches magmatiques, le gabbro laisse voir une similarité plus avérée avec la granodiorite qu'avec les autres roches de la même famille.

Dans le cas des roches métamorphiques, la cornéenne10, la cornéenne53 et la migmatite sont très similaires, au regard des valeurs données par les trois (03) métriques de distance. Quelques remarques peuvent être faites :

- 1) Le Gabbro, le Granodiorite et la Cornéenne10 ont une relation de similarité de couleur, traduite par la métrique Moyenne, indiquée dans les tableaux 3.8 et 3.9 ci-dessus qui donnent des valeurs inférieures à 1.

- 2) Les roches métamorphiques (Cornéenne53, Cornéenne10 et Migmatite) ont une relation de similarité de couleur avec le Gabbro et entre elles, confirmée par la métrique Moyenne des mêmes tableaux. De façon particulière, les trois (3) métriques montrent une très grande similarité entre le Gabbro, la cornéenne53 et la Migmatite. Elles présentent toutefois une très faible similarité de couleur avec le Schiste951 et l'Eclogite.
- 3) En ce qui concerne la relation entre les roches magmatiques, de faibles similarités de structures (opposition des formes des grains : petits grains et gros grains) existent entre elles, avec cependant une similarité plus élevée de couleur entre le Gabbro et le Granodiorite, confirmée par la métrique Moyenne. Les similarités de directionnalité et d'orientation dans la texture ne sont pas trop visibles dans ces roches. A cet effet, les valeurs des métriques : Max et Distance L2 le confirment.
- 4) Les roches métamorphiques étudiées ici présentent, dans leur grande majorité, des similarités de structure (granularité petite et fine), des similarités de directionnalité, d'orientation et plus significativement, de couleur avec le Gabbro. Ces propriétés visuelles sont mises en exergue par les métriques (Moyenne et Max). Cette analyse corrobore les analyses 2 et 3 du paragraphe 3.2.1.3.
- 5) En outre, d'autres roches métamorphiques comme le Schiste31, le Cipolin et la Migmatite présentent des similarités moyennes de couleurs, de faibles similarités de granularité et directionnalité avec le granite, en se référant aux valeurs des métriques Moyenne et Max dans les tableaux 3.8 et 3.9 ci-dessus. Cette analyse atteste celle réalisée à partir du SSIM au paragraphe 3.2.1.3 avec l'analyse 1.

### **3.2.3. Impact de l'apprentissage de dictionnaire sur la réduction de la dimension des données**

Dans le traitement des textures et des couleurs des images naturelles (le cas précis des images de roches, images non homogènes), les données obtenues de ces ensembles d'images se regroupent dans différents types de dictionnaires dont les performances dépendent des méthodes ou techniques utilisées et des applications visées. Ces dictionnaires dits génériques tels que les wavelets [219], les curvelets [220], les DCT [221], les transformées de FOURIER [222], fournissent des transformations spécifiques avec des implémentations rapides mais, produisent des vecteurs de données caractéristiques redondantes et de grandes dimensions. Ces dictionnaires, fixes toutefois structurés, sont limités dans leur capacité à s'adapter à des données de signaux plus générales. Une question importante est de savoir comment déterminer les sous-

espaces où se trouvent les données observées. Le choix de ces sous-espaces est crucial pour une réduction efficace de leur dimensionnalité. Cette interrogation a déclenché l'émergence de l'apprentissage des dictionnaires [223, 224] qui se concentrent sur le développement de nouveaux algorithmes pour la construction de dictionnaires d'atomes ou de sous-espaces fournissant des représentations efficaces des classes de signaux. Les contraintes de parcimonie sont les clés de la plupart de ces algorithmes qui résolvent les problèmes d'apprentissage du dictionnaire. Ils imposent l'identification des causes les plus importantes des données observées et favorisent la représentation exacte des informations pertinentes [195]. Par exemple, dans les méthodes de classification où l'erreur résiduelle est utilisée comme variable de décision pour l'affectation, l'apprentissage de dictionnaire donne un effet de précision important sur les dictionnaires prédéfini en échantillonnant l'ensemble de formation. En effet, les algorithmes avancés d'apprentissage automatique aident à extraire la texture, la couleur et la forme de la roche en fonction des paramètres de classification qui ont été mesurés au moyen des descripteurs de textures et de couleur. C'est l'exemple de la matrice de cooccurrence, les filtres de Gabor et les moments de couleur. Ces travaux mettant en évidence l'importance de l'apprentissage de dictionnaires par rapport à des dictionnaires prédéfinis en se montrant plus discriminants pour une reconstruction et une classification précise et robuste. De plus, dans l'apprentissage de dictionnaire, la parcimonie et la redondance des données sont complémentaires.

### **3.3. Conclusion partielle**

Dans cette section, nous avons appliqué, de façon inédite, ce nouveau descripteur de caractéristique d'image appelé ALBPCSF aux images de vue directe de roches. Dans la classification des images de textures des roches, il a été bénéfique de combiner les caractéristiques de textures et l'information couleur en vue de faire une meilleure classification. Cependant, il est à remarquer que les textures des roches sont très difficiles à caractériser pour deux (2) raisons : la première à cause de leur nature très variée, irrégulière et hétérogène ; la deuxième parce que les roches métamorphiques ont subi d'importantes transformations, soit d'ordre structural ou purement minéralogique, soit d'ordre structural et minéralogique en même temps. En somme, les métamorphismes ayant contribué à la formation de ces roches compliquent l'identification de ces dernières. ALBPCSF a compensé le déficit de LBP et convient mieux à la classification des images de textures couleurs. Dans le principe, nous avons fusionné les espaces colorimétriques RGB et HSV pour obtenir les informations de couleurs et les relations de structure spatiale afin d'améliorer les performances de classification. La



métrique moyenne décrit convenablement la similarité de couleur dans les images pendant que les similarités de structure et de directionnalité/orientation sont décrites par le Max et la distance L2. Le descripteur de textures couleur permet de différencier efficacement ou de trouver une similitude entre les roches de familles identiques et même celles de familles différentes. Les résultats des différents tableaux présentés ont montré que les performances de l'algorithme ALBPCSF + K-SVD sont meilleures que celles avec K-SVD. Nous remarquons en effet, une bonne concordance entre l'identification ou la reconnaissance visuelle et la réponse de notre méthode ; confirmant ainsi le bon choix des caractéristiques des roches et les méthodes utilisées pour leurs extractions. En outre, les difficultés rencontrées résultent de la diversification importante des propriétés des roches dues à la différence liée à leur genèse (depuis leur formation originelle). Ces mêmes écueils ont été évoqués dans l'analyse ou la reconnaissance manuelle. En perspective, nous pensons introduire les filtres de Gabor et/ou la DCT pour peaufiner nos résultats.

---

## Chapitre 4 Classification des roches basée sur des descripteurs de textures couleur et fréquentiels

*Une meilleure classification repose sur une bonne extraction des caractéristiques. Ce chapitre comprend deux (2) sections. Dans la première, nous proposons deux (2) techniques d'extraction de caractéristiques de roches. Ces techniques sont des combinaisons de l'opérateur LBP couleur composite et des transformées fréquentielles. La seconde section présente d'abord une analyse faite à partir de trois (3) moments statistiques choisis, ensuite les résultats d'une classification à partir de l'analyse des histogrammes.*

### 4.1. Introduction

Dans la classification automatique des textures naturelles colorées, l'idée de construire des méthodes qui copient la perception humaine suscite l'engouement des chercheurs du domaine des traitements d'images et de la vision par ordinateur. Par conséquent, l'espace couleur et les méthodes d'analyse de couleur et de textures doivent être discriminants pour correspondre à la vision humaine. Les images de roches sont un exemple typique des images naturelles et leur analyse est cruciale dans l'industrie des roches. Dans nos travaux, nous étudions l'action combinée des descripteurs statistique (LBP) et fréquentiels tels que les filtres de Gabor et la DCT nommées respectivement Gabor Adjacent Local Binary Pattern Colour Space Fusion (G-ALBPCSF) et Discret Adjacent Local Binary Pattern Colour Space Fusion (D-ALBPCSF), pour l'extraction des caractéristiques visuelles texturales et colorimétriques des textures des images de vue directe des roches. En effet, la combinaison du descripteur local LBP et des descripteurs globaux tels que les filtres de Gabor et la DCT est de plus en plus sollicitée vu les résultats obtenus avec les premières expérimentations dans la reconnaissance faciale [165, 214, 215] et récemment, dans l'identification des roches [141]. L'idée sous-jacente de la combinaison de ces méthodes est de profiter amplement des avantages de ces différentes méthodes face au bruit, à l'illumination, etc.

### 4.2. Combinaison ALBPCSF et les filtres de Gabor pour l'extraction des caractéristiques

Pour augmenter l'applicabilité de l'opérateur LBP, des modifications de celui-ci ont été émises. Par exemple, Zhang et al. [165] ont proposé l'extraction de caractéristiques LBP à partir d'images obtenues par filtrage d'une image faciale avec 40 filtres de Gabor, à différentes

échelles et orientations, pour obtenir des résultats remarquables. Dans [142], l'opérateur LBP a été calculé sur des images de textures couleur de roche transformées dans l'espace couleur HSV, après avoir appliqué les filtres de Gabor sur chacun des trois (3) canaux indépendamment. Dans cette même logique, nous fusionnons les deux (2) espaces colorimétriques RGB et HSV, en mettant en première ligne la relation entre la structure spatiale et les caractéristiques couleurs des roches, indiqué dans [95].

#### 4.2.1. Extraction des caractéristiques par les filtres de Gabor

Les filtres de Gabor multi-résolution et multi-échelle sont des filtres de fréquences localisés dans l'espace, avec des orientations particulières commodes pour l'extraction et la détection des contours. Ils sont appliqués dans le but de décomposer les images d'entrée pour l'extraction séquentielle des caractéristiques en changeant simplement deux (2) paramètres : la fréquence et l'orientation. Les filtres de Gabor permettant de calculer ces deux (2) paramètres sont définis par [9] :

$$\Psi_{\nu,\mu}(x,y) = \exp\left(-\frac{|\vec{k}|^2|\vec{r}|^2}{2\sigma^2}\right) (\exp(i\vec{k}\cdot\vec{r}) - \exp(-\sigma^2/2)) \quad (4.1)$$

$$\vec{r} = \begin{bmatrix} x \\ y \end{bmatrix} \quad \text{et} \quad \vec{k} = \frac{\pi}{2f^\nu} \begin{bmatrix} \cos(\mu\pi/8) \\ \sin(\mu\pi/8) \end{bmatrix}, \quad f = \sqrt{2}, \sigma = \pi$$

où  $\mu = \{0, \dots, 7\}$  et  $\nu = \{0, \dots, 4\}$  définissent respectivement les orientations et les échelles des filtres de Gabor utilisés.

La transformation de Gabor d'une image qu'on peut appeler image de Gabor est définie comme la convolution de l'image originale  $I(x, y)$  avec les filtres de Gabor  $\Psi_{\mu,\nu}(x, y)$  :

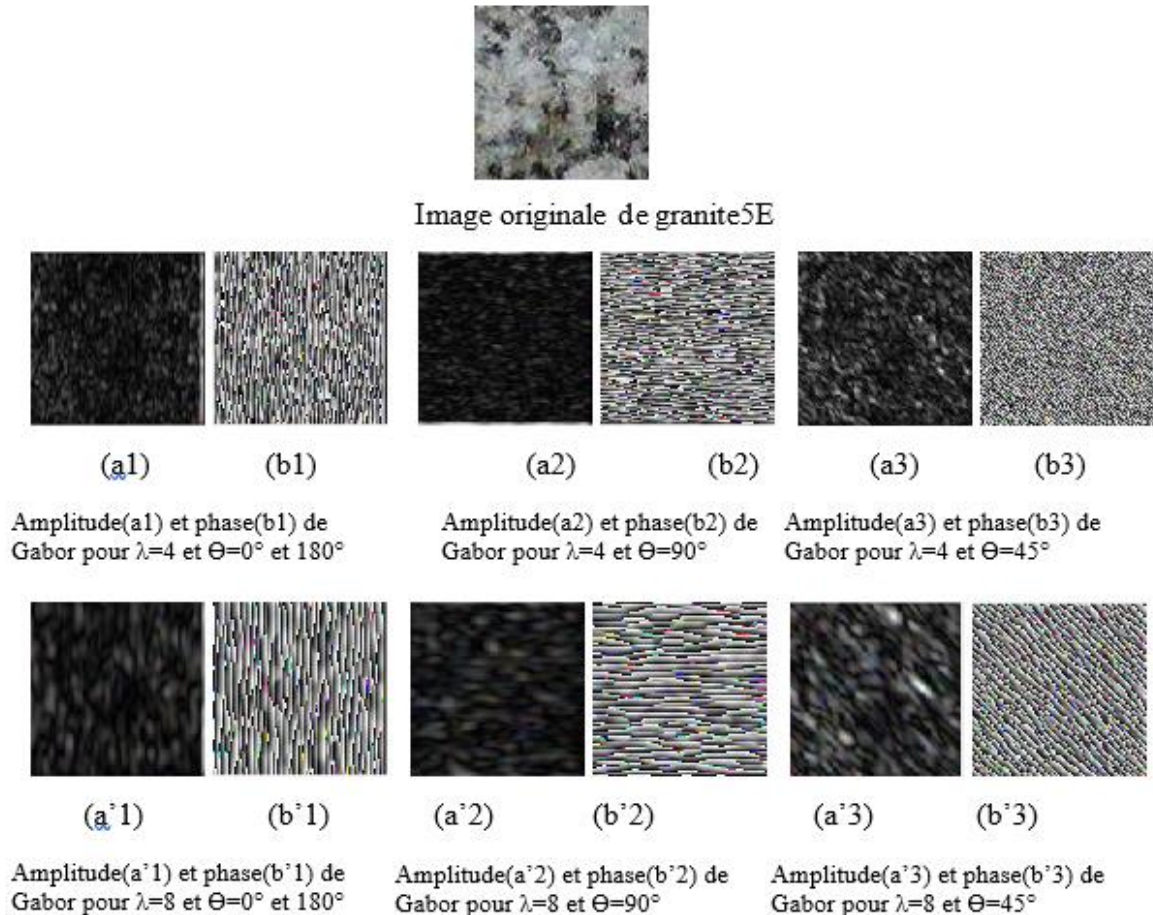
$$G_{\mu,\nu}(x, y) = I(x, y) * \Psi_{\mu,\nu}(x, y) \quad (4.2)$$

La transformation de Gabor est une fonction complexe, et peut être séparée en amplitude  $A_{\mu,\nu}(x, y)$  et en phase  $\theta_{\mu,\nu}(x, y)$  et donc peut être réécrite comme suit :

$$G_{\mu,\nu}(x, y) = A_{\mu,\nu} \exp(i\theta_{\mu,\nu}(x, y)) \quad (4.3)$$

L'équation (4.3) est une représentation complexe de la transformation de Gabor de l'image. A partir de cette transformation, un vecteur de caractéristiques est créé (amplitude  $A_{\mu,\nu}(x, y) = |G_{\mu,\nu}(x, y)|$  ; phase  $\theta_{\mu,\nu}(x, y) = \arg(G_{\mu,\nu}(x, y))$ ). Il faut rappeler que comme l'information de phase varie dans le temps (donc très sensible), en général, seule l'amplitude est explorée. Ainsi, pour chaque filtre de Gabor, une valeur d'amplitude est calculée

à chaque position du pixel, ce qui donne au total 40 amplitudes (5 échelles et 8 orientations). La figure 4-1 illustre une image de granite et d'autres images de mêmes tailles appelées images de Gabor dont les caractéristiques : amplitude et phase ont été extraites pour deux (2) longueurs d'onde et quatre (4) orientations (16 images de Gabor dont 4 sont identiques donc 12 ont été représentées).



*Figure 4-1: Exemples d'une image filtrée par quatre (4) différents filtres de Gabor : (a1), (a2), (a3), (a'1), (a'2) et (a'3) sont les différentes images des amplitudes et (b1), (b2), (b3), (b'1), (b'2) et (b'3) sont les images des phases de Gabor pour deux (2) longueurs d'ondes ( $\lambda=4$  et  $\lambda=8$ ) et pour différentes orientations.*

Ces images montrent clairement d'une part que l'information de textures est mieux représentée dans l'image de l'amplitude de Gabor, d'autre part que, quelle que soit l'orientation et/ou l'échelle, la granularité et la structure restent les éléments les plus importants et diffèrent significativement de celles que montrent les images LBP (figure 4-2). Cependant, notons que les filtres de Gabor transforment une image donnée en seulement trois (3) directions : vertical ( $0^\circ$  ou  $180^\circ$ ), horizontal ( $90^\circ$ ) et diagonale ( $45^\circ$  et  $135^\circ$ ).

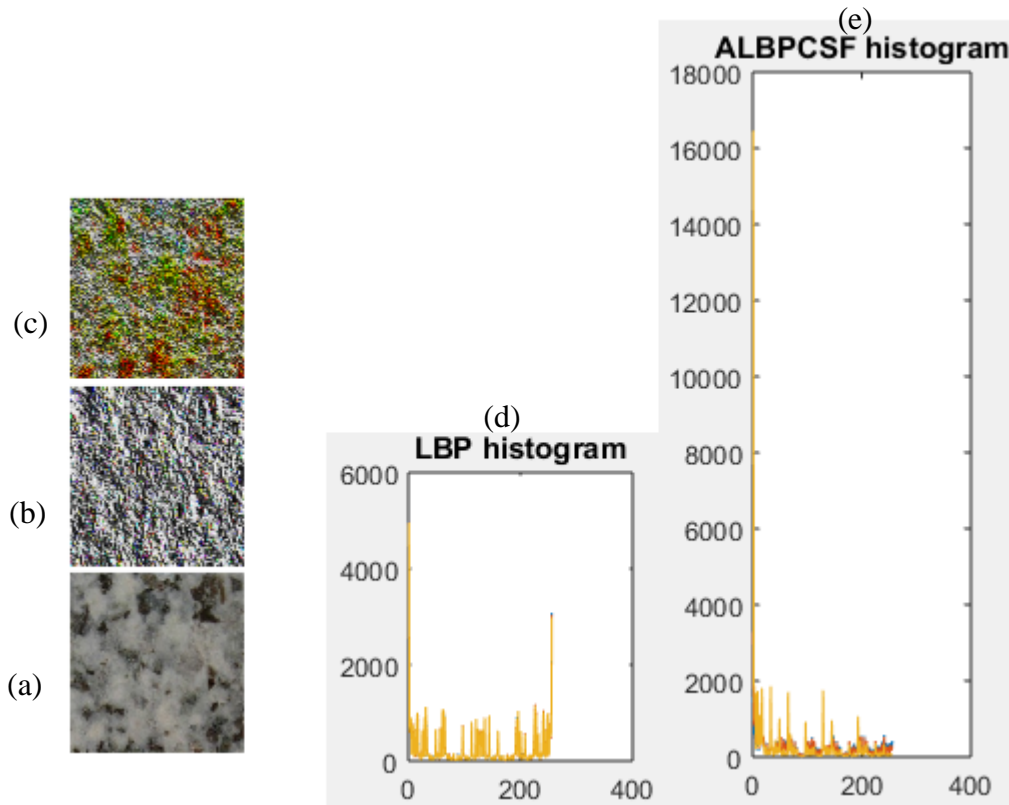


Figure 4-2: Un exemple d'image originale de granodiorite (a), son image LBP (b), son image ALBPCSF (c) (les 03 superposées), l'histogramme de l'image LBP(d) et l'histogramme ALBPCSF(e)

#### 4.2.2. Framework des techniques d'extraction des caractéristiques des roches

La figure 4-3 présente le principe des différentes techniques d'extraction des descripteurs de caractéristiques des roches.




Figure 4-3: Framework des techniques d'extraction des caractéristiques

#### 4.2.3. Nouvelle méthode d'extraction de caractéristiques des roches : G-ALBPCSF

Afin d'améliorer l'information dans les amplitudes, nous codons les valeurs des amplitudes de Gabor par l'opérateur ALBPCSF. Dans G-ALBPCSF, l'opérateur ALBPCSF est conduit sur les amplitudes produites par les filtres de Gabor multi-résolution et multi-échelle, plutôt que sur les intensités des images originales. L'opérateur LBP utilise la comparaison entre le pixel central et ses huit (8) voisins dans un voisinage  $3 \times 3$ . Leur combinaison avec les images de Gabor, exploitant ainsi les liens entre les pixels pour plusieurs résolutions et orientations, s'est révélée très robuste à l'illumination et aux changements d'échelle [165]. La figure 4-4 illustre bien cette combinaison. Elle montre l'application de ALBPCSF sur cinq (5) images d'amplitude de Gabor pour deux (2) différentes fréquences ( $\lambda=4$  pour les images de la première ligne et  $\lambda=8$  pour les images de la deuxième ligne) et cinq (5) orientations. La figure ci-dessous montre que les filtres de Gabor sont plus informatifs dans la direction diagonale ( $45^\circ$  et  $135^\circ$ ) et confirme ainsi la structure directionnelle de la roche étudiée.




Figure 4-4: Image G-ALBPCSF de l'image originale de Granite5E pour  $\lambda=4$  (en haut) et  $\lambda=8$  (en bas) et pour différentes orientations ( $0^\circ$  ;  $45^\circ$  ;  $90^\circ$  ;  $135^\circ$  ;  $180^\circ$ )

### 4.3. Combinaison ALBPCSF et la DCT pour l'extraction des caractéristiques

#### 4.3.1. Extraction de caractéristiques par la DCT

La DCT (Discrete Cosine Transform) est une technique populaire en imagerie et compression vidéo transformant les signaux de représentation spatiale en une représentation fréquentielle. Nous le savons, une quantité d'informations sur l'image originale est stockée dans un nombre relativement faible de coefficients (dans la partie supérieure gauche correspondant aux composants DCT à basse fréquence spatiale de l'image, où  $i$  et  $j$  sont tous deux petits), sur l'image centrale de la figure 4-5 ci-dessous. Cette région contient la plupart des informations, de l'énergie et des caractéristiques utiles, alors que la plupart des autres valeurs sont nulles.



Figure 4-5: image DCT (milieu) de l'image originale de granite5E (à gauche) et sa combinaison avec ALBPCSF (à droite)

Pour une image  $f(x, y)$  numérique de résolution  $M \times N$ , son DCT bidimensionnel est défini comme suit [166] :

$$A(i, j) = a(i)a(j) \sum_{x=0}^{M-1} \sum_{y=0}^{N-1} f(x, y) \times \cos \left[ \frac{(2x+1)i\pi}{2M} \right] \cos \left[ \frac{(2y+1)j\pi}{2N} \right] \quad (4.4)$$

$$i = 0, 1, 2, \dots, M-1; \quad j = 0, 1, 2, \dots, N-1;$$

où  $x$  et  $y$  sont les coordonnées spatiales des pixels de l'image ;  $i$  et  $j$  sont les coordonnées des coefficients DCT des pixels.  $A(i, j)$  est le résultat de la DCT c'est-à-dire le coefficient de DCT.

$a(i)$  et  $a(j)$  sont définies comme suit :

$$a(i) = \begin{cases} \sqrt{1/M} & , \text{ si } i = 0 \\ \sqrt{2/M} & , \text{ si } 1 \leq i \leq M-1 \end{cases} \quad a(j) = \begin{cases} \sqrt{1/N} & , \text{ si } j = 0 \\ \sqrt{2/N} & , \text{ si } 1 \leq j \leq N-1 \end{cases} \quad (4.5)$$

#### 4.3.2. Nouvelle méthode d'extraction de caractéristiques des roches : D-ALBPCSF

Les performances de la DCT ou de la LBP, prises indépendamment, ne sont pas totalement parfaites. Dans [165], la combinaison de DCT avec LGBPH, sur une base de données ORL, a donné de meilleurs résultats par rapport à LGBPH, appliqué seul. Dans cette section, nous proposons un nouvel algorithme de sélection des caractéristiques de textures de roches nommé D-ALBPCSF, en combinant la DCT et ALBPCSF afin de prendre en compte l'information couleur, en plus des avantages déjà mentionnés, plus haut. Tout d'abord, la DCT est effectuée sur des images de roches. Cela nous permet de sélectionner quelques coefficients DCT basse fréquence afin d'extraire les caractéristiques globales des images de textures de roches pouvant réduire les dimensions des images de roches. Ensuite, l'opérateur LBPcouleur (plus précisément ALBPCSF) est exécuté sur ces caractéristiques DCT de textures de roches pour maintenant extraire les caractéristiques locales avec de hautes fréquences (voir image à l'extrême droite dans la figure 4-5. L'analyse de l'existant a montré que le fait d'utiliser une combinaison de plusieurs classifieurs de types différents peut améliorer les performances de la classification [53]. Les descripteurs basés sur des caractéristiques globales sont susceptibles de contribuer à une capacité discriminante complémentaire aux descripteurs basés sur les caractéristiques locales, dans la reconnaissance des roches [142].

#### 4.4. Evaluation des méthodes et résultats expérimentaux

L'algorithme traduisant le principe des techniques d'extraction des caractéristiques est présenté par le pseudo code suivant :



**Algorithme** DCT\_Gabor\_ALBPCSF

---

**Entrée** : l'image ALBPCSF, l'image RGB

**Sortie** : une image

Début

1. Convertir l'image RGB en HSV
2. Déterminer une matrice HSV pour chaque canal de HSV
3. Extraire la composante V de la matrice de l'étape 2
4. Extraire les composantes R, G et B de l'image RGB
5. Appliquer la méthode DCT ou Gabor sur les composantes R, G, B de l'étape 4
6. Calculer les moments statistiques (moyenne, écart type, énergie)
7. Pour chaque composante DCT ou Gabor faire
8. Fusionner les composante DCT ou Gabor de l'étape 5 à la composante V de l'étape 3
9. Fin Pour
10. Déterminer l'image D\_ALBPCSF ou G\_ALBPCSF
11. Calculer les moments statistiques (moyenne, écart type, énergie)

Fin.

---

#### **4.4.1. Matériel utilisé**

Cette section présente les roches utilisées pour nos expérimentations. Les images de roches de vue directe choisies sont visibles à la figure 4-6, ci-dessous. Elles sont prises dans notre base de données conçues, contenant cent soixante (160) images de textures de roches magmatiques et métamorphiques. Les images ont été regroupées en huit (8) classes (de la classe 1 à la classe 8). Chacune de ces images de résolution 256x256, codées sur huit (8) bits par composante colorimétrique et présentant des textures non-homogènes, montre souvent des différences significatives en directionnalité, en granularité et en couleur au sein d'une même classe. Grâce à ces caractéristiques de textures et de couleur, les images originales ont été subjectivement regroupées en huit (8) classes par un expert géologue. Sur la figure 4-6, les différentes classes correspondent à différents types de roches : classe 1 : Granite ; classe 2 : Gabbro ; classe 3 : Granodiorite ; classe 4 : Schiste ; classe 5 : Eclogite ; classe 6 : Migmatite ; classe 7 : Cornéenne ; classe 8 : Cipolin.




Figure 4-6: Exemples des huit (8) différentes classes des images de roches

#### 4.4.2. Quelques moments statistiques utilisés

Dans cette section, à cause de la directionnalité contenue dans les textures de roches, les filtres de Gabor sont appliqués sur ces textures. Les caractéristiques statistiques de premier ordre (la moyenne) et de second ordre (l'écart type et l'énergie), sont calculées sur ces amplitudes de Gabor et des coefficients de DCT puis sur les coefficients G-ALBPCSF et D-ALBPCSF dans les différents canaux de couleur. En effet, la moyenne calculée caractérise l'intensité lumineuse des énergies dans l'image, tandis que l'écart type caractérise la variation de l'intensité moyenne de l'ensemble des pixels et correspond aux changements de contraste de l'image. Les résultats sont consignés dans les tableaux ci-dessous.

##### 4.4.2.1. Moyennes des coefficients des amplitudes de Gabor et G-ALBPCSF

Tableau 4-1: Moyenne des coefficients des amplitudes de Gabor

Moyennes des coefficients des amplitudes de Gabor calculées pour différentes roches, Lambda = 4, thêta =135°								
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	57,9142	46,945	55,5565	65,3018	44,8483	42,2141	57,9337	42,2962
(G,V)	57,9107	45,9711	55,5565	65,4266	44,7356	42,4674	57,9511	42,8727
(B,V)	57,9674	50,1033	55,5565	65,4139	44,7492	42,5286	57,9884	43,7508

Tableau 4-2: Moyennes des coefficients des amplitudes de G-ALBPCSF

	Moyennes des coefficients des amplitudes de G-ALBPCSF calculées pour différentes roches ( $\lambda = 4$ , $\theta = 135^\circ$ )							
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	15,4365	16,2430	21,4266	6,0078	7,1122	7,8196	6,0311	1,3431
(G,V)	15,4598	15,3746	21,4266	6,0249	7,0253	7,9517	6,0753	1,4434
(B,V)	15,5244	18,3144	21,4266	5,9887	6,9742	7,9593	6,0438	1,4487

#### 4.4.2.2. Moyennes des coefficients DCT et D-ALBPCSF

Tableau 4-3: Moyennes des coefficients DCT

	Moyennes des coefficients DCT calculées pour différentes roches							
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	8,5716	13,2398	10,7357	13,7518	8,8443	8,0340	6,7993	5,6949
(G,V)	8,5775	12,8244	10,7357	13,7803	8,7991	8,1157	6,8064	5,8441
(B,V)	8,6141	13,8325	10,7357	13,8325	8,8009	8,1050	6,8198	5,9921

Tableau 4-4: Moyennes des coefficients D-ALBPCSF

	Moyennes des coefficients DCT_LBP calculées pour différentes roches							
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	1,7970	7,2281	5,3610	0,6873	1,4901	1,1892	0,4790	0,3811
(G,V)	1,7917	6,7981	5,3610	0,6986	1,4537	1,2444	0,4772	0,4472
(B,V)	1,8362	7,3790	5,3610	0,7399	1,4636	1,2459	0,4808	0,5074

#### 4.4.2.3. Ecart types des coefficients des amplitudes de Gabor et G-ALBPCSF

Tableau 4-5: Ecart-type des coefficients des amplitudes de Gabor sur les images originales

	Moyenne des Ecart types des coefficients de Gabor calculés pour différentes roches, $\lambda = 4$ , $\theta = 135^\circ$							
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	35,0280	28,2244	33,5475	36,2668	27,5958	29,0953	34,2396	28,0670
(G,V)	35,0924	27,9218	33,5475	36,3339	27,6712	29,3490	34,2445	28,6090
(B,V)	35,0512	30,3900	33,5475	36,3649	27,6677	29,3802	34,2505	28,8726

Tableau 4-6: Ecart-type des coefficients des amplitudes G-ALBPCSF

Moyenne des Ecart types des coefficients de G-ALBPCSF calculés pour différentes roches, Lambda = 4, $\theta = 135^\circ$								
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	43,7388	44,4104	50,9072	27,7572	28,1538	31,2973	26,5383	12,9097
(G,V)	43,7826	43,1394	50,9072	27,7616	27,9202	31,5429	26,6805	13,3843
(B,V)	43,8905	46,5493	50,9072	27,6069	27,8314	31,4801	26,6287	13,3801

#### 4.4.2.4. Ecart types des coefficients DCT et D-ALBPCSF

Tableau 4-7: Ecart-type des coefficients DCT sur les images originales

Moyenne des Ecart types des coefficients DCT calculés pour différentes roches								
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	20,0985	27,2926	26,2376	21,8199	20,8450	19,4737	16,2005	15,5525
(G,V)	20,1102	25,7220	26,2376	21,8907	20,6854	19,8264	16,2257	16,3226
(B,V)	20,3104	26,5375	26,2376	22,1734	20,7362	19,7837	16,2660	17,0531

Tableau 4-8: Ecart-type des coefficients D-ALBPCSF

Moyenne des Ecart types des coefficients de D-ALBPCSF calculés pour différentes roches								
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	13,9308	28,0933	24,6956	7,9382	12,2155	11,0881	6,2382	5,9663
(G,V)	13,9060	27,1244	24,6956	8,0066	12,0336	11,3821	6,4121	6,6028
(B,V)	14,1372	28,2027	24,6956	8,2811	12,1098	11,3792	6,4332	7,0632

#### 4.4.2.5. Energies des coefficients des amplitudes de Gabor et G-ALBPCSF

Tableau 4-9: Energies des amplitudes de Gabor

Moyennes des énergies des coefficients des amplitudes de Gabor calculées pour différentes roches (exprimées en $10^6$ )								
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	3,9755	3,2225	3,8135	4.4826	3,0785	2,8977	3,9768	2,9172
(G,V)	3,9752	3,1556	3,8135	4.4912	3,0708	2,9151	3,9780	2,9571
(B,V)	3,9791	3,4393	3,8135	4.4903	3,0718	2,9193	3,9806	3,0176

Tableau 4-10 : Energies des amplitudes de G-ALBPCSF

Moyennes des énergies des coefficients des amplitudes G-ALBPCSF calculées pour différentes roches (exprimées $10^6$ )								
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	1,0117	1,0645	1,4042	0,3937	0,4661	0,5125	0,3953	0,0885
(G,V)	1,0132	1,0076	1,4042	0,3949	0,4644	0,5211	0,3980	0,0950
(B,V)	1,0174	1,2003	1,4042	0,3925	0,4570	0,5212	0,3961	0,0954

#### 4.4.2.6. Energies des coefficients DCT et D-ALBPCSF

Tableau 4-11: Energies des coefficients DCT

Moyennes des énergies des coefficients DCT calculées pour différentes roches (exprimées en $10^5$ )								
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	5,8839	9,0883	7,3695	9,4397	6,0711	5,5149	4,6673	3,9255
(G,V)	5,8804	8,8032	7,3695	9,4593	6,0400	5,5709	4,6721	4,0316
(B,V)	5,9131	9,1077	7,3695	9,4951	6,0413	5,5636	4,6814	4,7851

*Tableau 4-12: Energies des coefficients D-ALBPCSF*

	Moyennes des énergies des coefficients D-ALBPCSF calculées pour différentes roches (exprimées en 10 <sup>5</sup> )							
	Granite	Gabbro	Granodiorite	Schiste	Eclogite	Migmatite	Cornéenne	Cipolin
(R,V)	1,1777	4.7370	3,5134	0,3815	0,9766	0,7794	0,3139	0,2511
(G,V)	1,1742	4.4732	3,5134	0,4578	0,9527	0,8155	0,3127	0,2947
(B,V)	1,2029	4.8359	3,5134	0,4836	0,9592	0,8165	0,3151	0,3344

Les graphes des résultats numériques de ces différents tableaux sont représentés aux figures (4-7, 4-8 et 4-9) suivantes :




Figure 4-7: Moyennes des coefficients DCT, D-ALBPCSF, et des amplitudes de Gabor, G-ALBPCSF

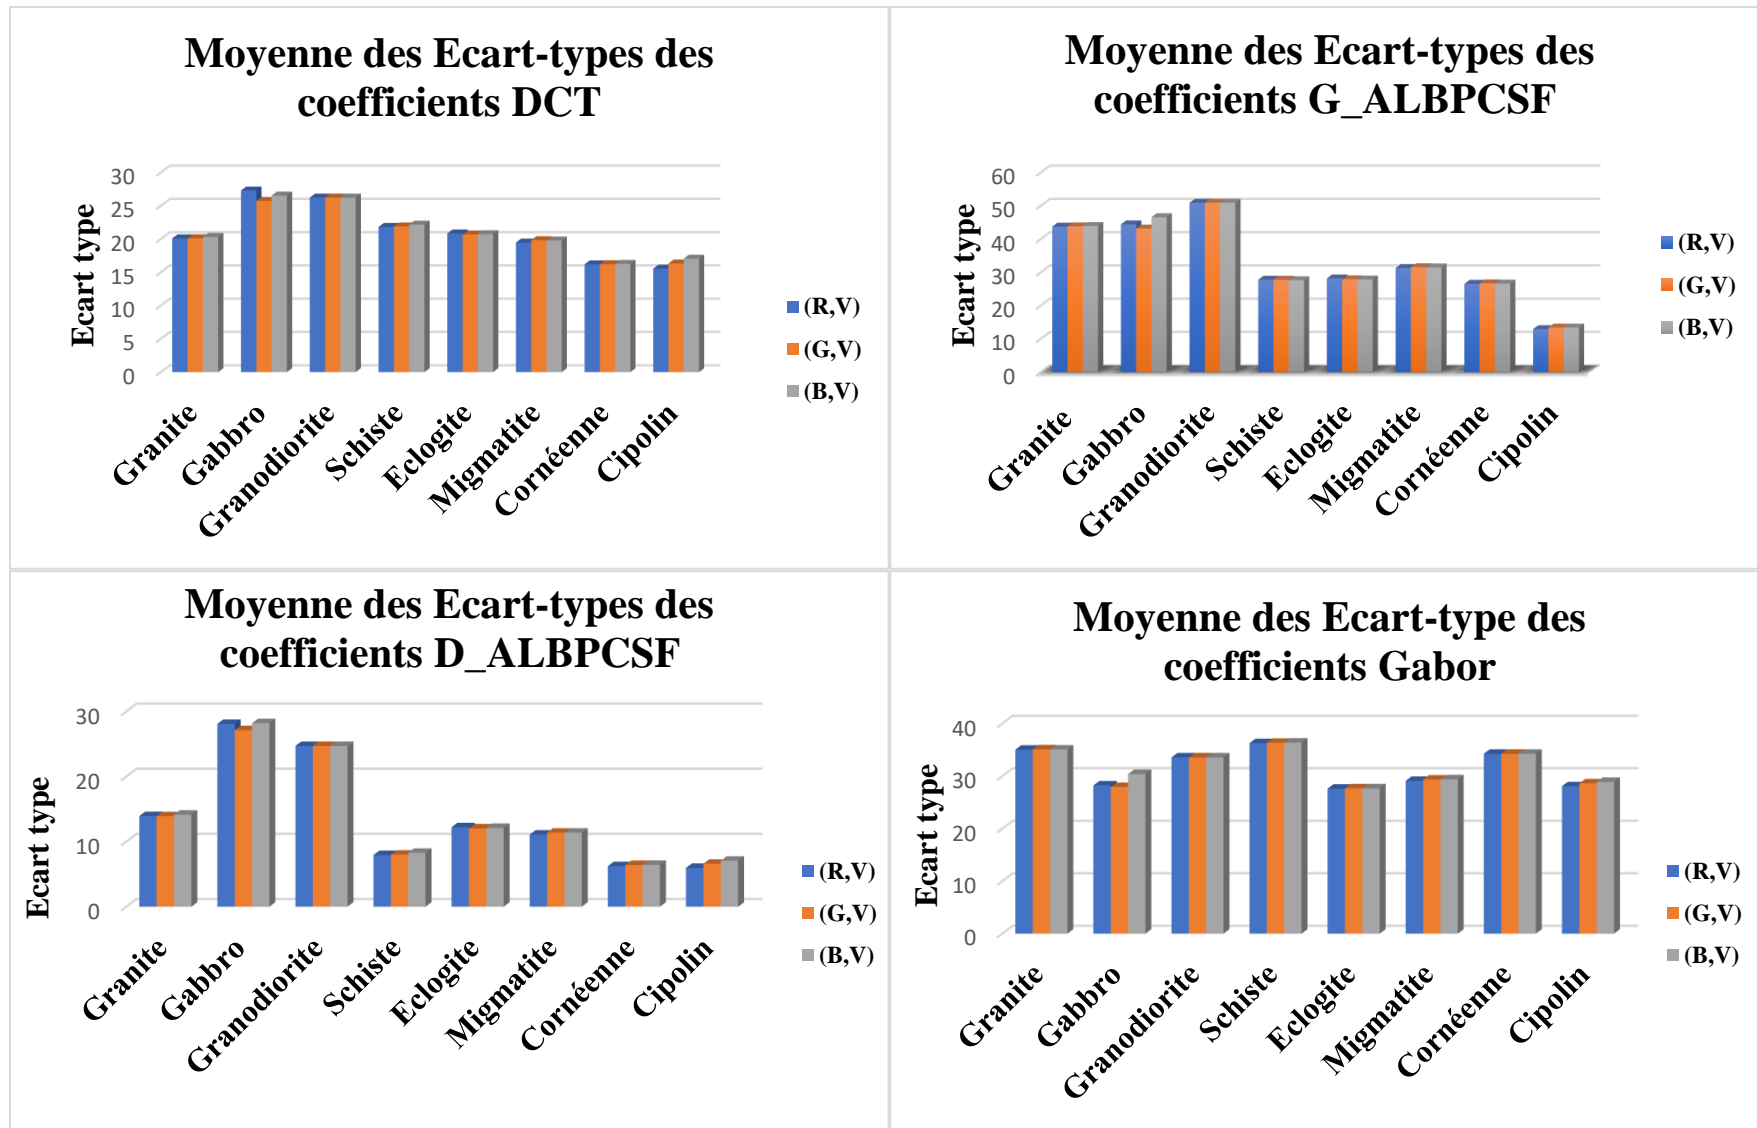


Figure 4-8 : Moyennes des écart-types des coefficients DCT, D-ALBPCSF, et des amplitudes de Gabor, G-ALBPCSF






Figure 4-9 : Moyennes des énergies des coefficients DCT, D-ALBPCSF, et des amplitudes de Gabor, G-ALBPCSF

## 4.5. Analyse et discussion

L'analyse des caractéristiques statistiques utilisées dans ce travail telles que la moyenne, l'écart type et l'énergie des coefficients (DCT, D-ALBPCSF) et des amplitudes de (Gabor, G-ALBPCSF) pour une orientation et une échelle ( $\lambda = 4$ ,  $\theta = 135^\circ$ ) renseignées dans les tableaux (4-1 à 4-12) montre que les roches magmatiques présentent des intensités plus élevées que celles des roches métamorphiques. Ces intensités élevées pourraient résulter d'une cristallisation à des températures et pressions plus élevées que celle des roches métamorphiques. Cependant, le schiste, l'éclogite et la cornéenne (roches métamorphiques), ont des intensités comparables à celles des roches magmatiques, lorsqu'on utilise individuellement les coefficients DCT et les amplitudes de Gabor. Ceci atteste une insuffisance de ces approches. Mais, l'analyse des moyennes, des écart types et des énergies des coefficients de G-ALBPCSF et D-ALBPCSF, calculées à partir des combinaisons des approches pour ces mêmes roches mettent en relief une bonne catégorisation des roches :

- Les roches magmatiques avec des intensités plus élevées.
- Les roches métamorphiques avec des intensités moins élevées que celles des roches magmatiques.

Ces analyses prouvent que les associations d'approches : D-ALBPCSF et G-ALBPCSF, permettent de mieux catégoriser les roches, contrairement aux informations avec Gabor et DCT prises individuellement. On note aussi que les moments statistiques (moyenne, écart type et énergie) calculés avec D-ALBPCSF pour le granite sont proches de ceux de la migmatite, confirmant ainsi la forte similarité entre ces deux (2) roches. La question est de savoir jusqu'à quelle valeur seuil on peut différencier les roches magmatiques des roches métamorphiques.

## 4.6. Classification des roches par analyse d'histogrammes

### 4.6.1. Mesures de similarité utilisées

Dans de nombreuses applications, il est utile de calculer une distance de similarité/dissimilarité entre histogrammes. Il y existe plusieurs métriques fréquemment utilisées de mesure de similarité entre deux (2) histogrammes pour la comparaison des caractéristiques. Ces métriques calculent la distance entre les vecteurs caractéristiques. On peut citer la distance de Bhattacharyya, le Chi2 [225], l'intersection des histogrammes de Ballard et Swain [103]. Dans le cadre de ce travail, nous utilisons l'intersection des histogrammes et la distance du Chi 2 entre deux (2) histogrammes  $h_1$  (1) et  $h_2$  (2), définies respectivement aux équations (4.6) et (4.7) ci-dessous et permettront de comparer l'efficacité des approches proposées.

$$HI(h_i(1), h_i(2)) = 1 - \frac{\sum_i \min(h_i(1), h_i(2))}{\sum_i h_i(2)} \quad (4.6)$$

$$\chi^2(h_i(1), h_i(2)) = \sum_i \frac{(h_i(1) - h_i(2))^2}{(h_i(1) + h_i(2))} \quad (4.7)$$

où  $h_i$  sont les histogrammes normalisés des échantillons des images des roches à comparer.

Des échantillons de roches peuvent être jugés similaires en appariant leurs histogrammes de caractéristiques (couleur et /ou texture). Plus la valeur est faible, meilleure est la similarité. Il en est de même pour le Chi2. Les deux (2) métriques présentent des résultats presque identiques. La similarité est parfaite lorsque la valeur de la métrique est nulle. Les tableaux 4-13 et 4-14 présentent les résultats des expérimentations réalisées où l'intersection des histogrammes et le Chi2 avec LBP, D-ALBPCSF et G-ALBPCSF donnent les meilleurs résultats.

Tableau 4-13: Valeurs moyennes des HI des différentes méthodes utilisées

	Valeurs moyennes des HI des différentes méthodes utilisées				
Roches	HI_ImagRGB	HI_LBP	HI_ALBPCSF	HI_D_ALBPCSF	HI_G_ALBPCSF
Schiste	0,4375	0,0977	0,2822	0,0122	0,2422
Granite	0,6737	0,2188	0,3847	0,0143	0,2665
Cipolin	0,6678	0,2663	0,3945	0,0077	0,5534
Eclogite	0,9283	0,3756	0,5696	0,0799	0,5673
Granodiorite	0,0635	0,0577	0,041	0,0359	0,0843
Migmatite	0,5690	0,2199	0,3805	0,0137	0,3492
Gabbro	0,7345	0,3358	0,4689	0,0764	0,6444
Cornéenne	0,5457	0,194	0,3680	0,0096	0,3918

Dans la suite de notre analyse, nous retenons la métrique intersection d'histogramme avec les approches LBP et D\_ALBPCSF vu qu'elle donne de bonnes performances attestées par les tableaux 4-13 et 4-14.

Tableau 4-14: Valeurs moyennes des  $\chi^2$  des différentes méthodes utilisées

Roches	Valeurs moyennes des $\chi^2$ des différentes méthodes utilisées				
	$\chi^2$ _ImagRGB	$\chi^2$ _LBP	$\chi^2$ _ALBPCSF	$\chi^2$ _D_ALBPCSF	$\chi^2$ _G_ALBPCSF
Schiste	25,25.10 <sup>-4</sup>	3,5972.10 <sup>-4</sup>	14,5.10 <sup>-4</sup>	0,62710 <sup>-4</sup>	10,278.10 <sup>-4</sup>
Granite	44.10 <sup>-4</sup>	7,75.10 <sup>-4</sup>	20,4.10 <sup>-4</sup>	0,62710 <sup>-4</sup>	11,5610 <sup>-4</sup>
Cipolin	53.10 <sup>-4</sup>	13.10 <sup>-4</sup>	14,25.10 <sup>-4</sup>	0,3229.10 <sup>-4</sup>	33.10 <sup>-4</sup>
Eclogite	71.10 <sup>-4</sup>	13,5.10 <sup>-4</sup>	36.10 <sup>-4</sup>	1,4872.10 <sup>-4</sup>	30,25.10 <sup>-4</sup>
Granodiorite	1,0245.10 <sup>-4</sup>	0,4488.10 <sup>-4</sup>	0,2207.10 <sup>-4</sup>	0,3971.10 <sup>-4</sup>	0,9283.10 <sup>-4</sup>
Migmatite	33,2.10 <sup>-4</sup>	9,014.10 <sup>-4</sup>	20,6.10 <sup>-4</sup>	0,4892.10 <sup>-4</sup>	17.10 <sup>-4</sup>
Gabbro	52,8.10 <sup>-4</sup>	19.10 <sup>-4</sup>	28,6.10 <sup>-4</sup>	2,7523.10 <sup>-4</sup>	44,8.10 <sup>-4</sup>
Cornéenne	31,6.10 <sup>-4</sup>	7,4783.10 <sup>-4</sup>	19,2.10 <sup>-4</sup>	0,3398.10 <sup>-4</sup>	20,8.10 <sup>-4</sup>

#### 4.6.2. Comparaison entre HI\_D-ALBPCSF et HI\_LBP

L'analyse de ces deux (2) méthodes met en relief que certaines roches métamorphiques (la migmatite, l'éclogite, la cornéenne, ...) sont similaires entre elles et à certaines roches magmatiques (le granite, le gabbro, ...). Ceci peut se justifier par le fait qu'elles ont des origines magmatiques depuis la genèse ; c'est le cas pour l'éclogite par exemple. Les résultats sont indiqués dans la figure 4-10 ci-dessous.




Figure 4-10 : Intersection des histogrammes des roches avec LBP et D\_ALBPCSF

La légende de la figure 4-10 doit être interprétée selon le formalisme suivant : GR-GR : Granite-Granite ; GRA-GRA : Granodiorite-Granodiorite ; GA-GA : Gabbro-Gabbro ; SH-SH : Schiste-Schiste ; CI-CI : Cipolin-Cipolin ; CO-CO : Cornéenne-Cornéenne ; MI-MI :

Migmatite-Migmatite ; EC-EC : Eclogite-Eclogite. La figure 4.10 montre une très bonne similarité entre les roches d'une même classe avec la méthode D\_ALBPCSF, prouvant la pertinence de notre méthode proposée par rapport à la méthode existante LBP.

#### 4.6.3. Matrice de confusion

Une matrice de confusion (voir tableau 4-15) a été réalisée avec la méthode D\_ALBPCSF discutée dans la section 4.3.2, pour montrer la pertinence de cette méthode. L'efficacité de cette dernière est évaluée avec la sélection de cinq (5) images de chaque classe de roches (8 classes), soit au total quarante (40) images pour une classification de trois cent vingt (320) croisements. Pour cette expérience, la sensibilité (rappel), la spécificité, l'exactitude et le taux d'erreurs dont les équations sont décrites ci-dessous et notées respectivement (4.8), (4.9), (4.10) et (4.11) sont des indicateurs de performance choisis pour démontrer l'efficacité de la méthode proposée, utilisés aussi par Vivek et Audithan en 2014 [141]. La sensibilité correspond à la qualité d'une classe. Elle indique la probabilité d'une roche d'appartenir à la classe sachant qu'elle est effectivement de la classe. Plus simplement, c'est le taux de vrais positifs. La spécificité indique, quant à elle, la probabilité qu'une roche n'appartienne pas à sa classe à juste titre, c'est le taux de vrais négatifs tandis que le taux d'erreurs correspond à la qualité générale du modèle.

$$\text{sensibilité} = FVP = \frac{VP}{VP + FN} \quad (4.8);$$

$$\text{spécificité} = FVN = \frac{VN}{VN + FP} \quad (4.9);$$

$$\text{précision} = \frac{VP}{VP + FP} = \frac{VN}{VN + FN} \quad (4.10);$$

$$\text{exactitude} = \frac{VP + VN}{VP + VN + FP + FN} \quad (4.11);$$

où VP : Vrai Positif, FP : Faux Positif ; VN : Vrai Négatif ; FN : Faux Négatif. Ici, les définitions des termes partent du principe qu'une roche est similaire à une autre si la valeur moyenne de l'intersection de leur histogramme est la plus faible. De ce fait, un vrai positif est une roche de la classe dont la valeur moyenne des intersections d'histogrammes est la plus petite. Le faux positif est une roche qui n'est pas de la classe mais ayant la valeur moyenne des intersections d'histogrammes la plus petite. Le faux négatif est une roche étant de la classe qui n'a pas la valeur la plus petite valeur moyenne des intersections d'histogramme. Le vrai négatif est une roche qui n'est pas de classe et n'a pas la valeur la plus petite des intersections d'histogramme.

Tableau 4-15: Matrice de confusion avec la méthode D\_ALBPCSF

		CLASSES PREDITES								TOTAL
		1	2	3	4	5	6	7	8	
CLASSES REELLES	1	4	0	0	0	1	0	0	0	5
	2	0	5	0	0	0	0	0	0	5
	3	0	0	5	0	0	0	0	0	5
	4	0	0	0	5	0	0	0	0	5
	5	0	0	0	0	5	0	0	0	5
	6	1	1	0	0	0	2	0	1	5
	7	0	0	0	0	0	0	4	1	5
	8	1	0	0	0	2	0	0	2	5
TOTAL		6	6	5	5	8	2	4	4	40

Tableau 4-16: Indicateurs de performance des deux (2) méthodes

Indicateurs d'évaluations		D_ALBPCSF	LBP
Images de textures de roche pour différentes classes	VP	32	32
	VN	272	272
	FP	8	8
	FN	8	8
	<b>Sensibilité</b>	<b>0,8=80%</b>	<b>0,8=80%</b>
	Spécificité	0,97=97%	0,97=97%
	Exactitude	0,95=95%	0,95=95%
	<b>Taux d'erreur</b>	<b>0,05 = 5%</b>	<b>0,05 = 5%</b>

Tableau 4-17: Comparaison des méthodes LBP et D\_ALBPCSF sur les différentes classes de roches

Méthodes	Indicateurs de performance	Granite	Granodiorite	Gabbro	Schiste	Cipolin	Eclogite	Migmatite	Cornéenne
LBP		VP=5 FN=0 VN=31 FP=4	VP=5 FN=0 VN=35 FP=0	VP=5 FN=0 VN=35 FP=0	VP=5 FN=0 VN=35 FP=0	VP=5 FN=0 VN=33 FP=2	VP=0 FN=5 VN=35 FP=0	VP=5 FN=0 VN=33 FP=2	VP=2 FN=3 VN=32 FP=3
	Exactitude par classe	90 %	100 %	100 %	100 %	95 %	87,5 %	95 %	85 %
	Précision des positifs	55,6 %	100 %	100 %	100 %	71,4 %	0%	71,4 %	40%
	Précision des négatifs	100 %	100%	100 %	100 %	100 %	87,5 %	100 %	94,1%
	Moyenne de l'exactitude	Roches magmatiques (96,7%)			Roches métamorphiques (92,5%)				
D_ALBPCSF		VP=5 FN=0 VN=34 FP=1	VP=5 FN=0 VN=35 FP=0	VP=5 FN=0 VN=35 FP=0	VP=4 FN=1 VN=33 FP=2	VP=5 FN=0 VN=32 FP=3	VP=2 FN=3 VN=35 FP=0	VP=4 FN=1 VN=35 FP=0	VP=2 FN=3 VN=32 FP=3
	Exactitude par classe	97,5 %	100 %	100 %	92,5 %	92,5 %	92,5 %	97,5 %	85 %
	Précision des positifs	83,3 %	100 %	100 %	66,7%	62,5 %	100 %	100 %	40 %
	Précision des négatifs	100 %	100 %	100 %	97,1%	100 %	92,1%	97,2%	94,1%
	Moyenne de l'exactitude	Roches magmatiques (99,2%)			Roches métamorphiques (92%)				

Les deux (2) méthodes donnent des performances similaires à première vue, à partir d'une analyse générale des indicateurs de performance tels que la sensibilité, la spécificité et l'exactitude. Cependant, avec un taux d'erreur de classification pratiquement égale à 8 % avec les deux méthodes LBP et D\_ALBPCSF pour les cinq (5) classes de roches métamorphiques, notre méthode proposée classifie mieux les roches magmatiques avec un taux d'erreur de 0,8 % contre 3,3 % pour la méthode LBP. Les résultats indiquent que la classification automatique des roches est meilleure avec les roches magmatiques. Ces résultats peuvent être dus à la dimension fractale ou à la moindre variabilité intra-classe dans les roches. Cependant, à l'observation des textures de roches magmatiques qui présente des textures presque similaires, ce résultat est dû à la moindre variabilité intra-classe dans ces roches. Ils révèlent également que notre méthode renvoie un nombre plus bas de classification incorrecte. Ces résultats mettent en évidence une performance légèrement meilleure de notre méthode à celle de LBP (voir figure

4-11). Cela est en accord avec l'observation visuelle qu'on peut faire de ces images de texture de roches. Pour les images de roches magmatiques, il est à noter que la texture et la couleur dans ces images sont quelque peu régulières dans leur représentation spatiale, contrairement à certaines roches métamorphiques où il y a absence d'homogénéité dans la représentation spatiale de la texture et de la couleur (exemples de l'éclogite et de la migmatite). L'association texture/couleur dans l'étude des roches a été bénéfique pour leur identification. De ce fait, les caractéristiques locales et globales, utilisées dans cette étude pour leur extraction, ont pleinement joué leur rôle.

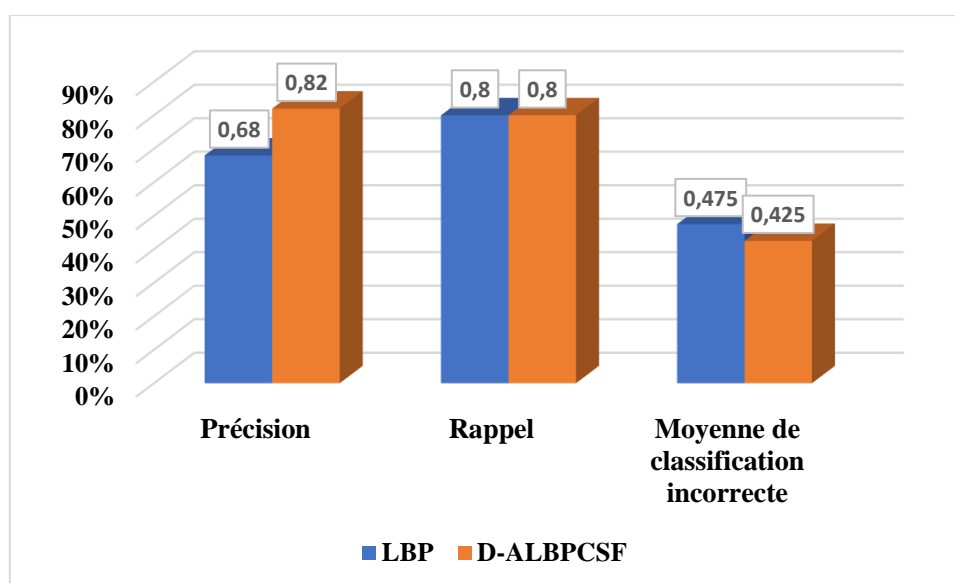


Figure 4-11 : Indicateur de performance de LBP et D\_ALBPCSF

#### 4.7. Conclusion partielle

Dans ce chapitre, nous avons proposé deux (2) nouvelles méthodes d'extraction de caractéristiques des images de roches. Ces méthodes sont obtenues en combinant les caractéristiques de Gabor à celles de ALBPCSF et les caractéristiques DCT à celles de ALBPCSF pour proposer deux (2) nouveaux descripteurs nommés G\_ALBPCSF et D\_ALBPCSF, dans le but de faire une meilleure indexation d'images de roches. Nous avons constaté que, même avec ces nouveaux descripteurs, la classification et la reconnaissance des roches sont une tâche très difficile à raison des différences fréquentes observées au sein même des échantillons de même type de roche. Les résultats expérimentaux réalisés sur notre base de données d'images de vue directe de roches montrent que les combinaisons G\_ALBPCSF et D\_ALBPCSF améliorent la performance de la reconnaissance par rapport à LBP original et ALBPCSF pris séparément. Dans l'ensemble, sur notre base d'apprentissage d'images, nous



avons obtenu un taux de bonne classification de 95%. Elles permettent de comprendre que les informations locales et globales sont à prendre en compte pour l'extraction des caractéristiques des roches.

## Chapitre 5 Nouvelle approche de classification des roches basée sur les représentations parcimonieuses

*Dans ce chapitre, nous présentons une nouvelle technique de classification des roches à partir des représentations parcimonieuses des signaux avec apprentissage de dictionnaire. Cette nouvelle technique apporte une solution à la redondance des données et à la dimension élevée des descripteurs. Les résultats obtenus à travers des matrices de confusion donnant le taux de classification de cette méthode sont promoteurs.*

### 5.1. Introduction

Traditionnellement, la classification et la caractérisation des roches, sujets inhérents à la géologie, sont des tâches exclusivement réservées aux géologues. Cependant, cette classification approximative, est sujette à des erreurs et subjective. La classification automatique apparaît alors comme une alternative, une solution conséquente [49, 142]. Plusieurs méthodes de classification automatique ont été développées pour atteindre cet objectif. Mais, aucune d'entre elles n'est considérablement assez parfaite pour faire la classification de toutes les roches. Comme introduit au paragraphe 2.14 du chapitre 2, bien que les avancées technologiques dans le domaine du traitement d'images aient permis la mise sur pied de plusieurs méthodes d'indexation des roches, le champ d'investigation reste toujours ouvert. L'idée sous-jacente est de trouver une méthode plus cohérente, précise et rapide pour classer les roches. La classification des roches est exigeante à cause de la variabilité de leurs propriétés et caractéristiques. La classification des roches par famille est difficile, même pour un expert. En effet, les experts individuels classifient souvent la même roche de différentes manières. Dans le souci de répondre à cette problématique, plusieurs classifieurs automatiques ont été proposés dans la littérature avec pour but de réduire considérablement la quantité de travail manuel, de maximiser le facteur temps et d'éliminer la nature subjective de cette classification. Dans ce chapitre, nous proposons une méthode de reconnaissance de roches basée sur le calcul de dictionnaire avec K-SVD appliquée à la combinaison de LBP couleur et les transformées fréquentielles, en considérant l'erreur de reconstruction comme le facteur discriminant. Cette considération est inspirée des travaux de thèse de Aghaei [11].

Ce chapitre s'organise ainsi : dans la deuxième section, nous estimons le dictionnaire des roches, la section 3 nous présente l'impact de la combinaison de méthodes d'extraction des caractéristiques sur l'estimation du dictionnaire, la section 4 montre la classification des roches en utilisant la méthode K-SVD et la distance euclidienne comme métrique de similarité. Une

matrice de confusion est mise en œuvre pour tester la performance de notre méthode de classification. Ce chapitre se termine par une conclusion.

## **5.2. Estimation du dictionnaire et de l'erreur de reconstruction des roches**

La construction d'un dictionnaire est la première étape d'une représentation parcimonieuse. L'apprentissage de dictionnaire est une étape primordiale afin d'obtenir un dictionnaire de qualité pour un type de données particulier. Le dictionnaire permet d'apprendre les motifs présents dans une image et avoir une base permettant de faire une décomposition parcimonieuse. Il permettra de regrouper les éléments caractéristiques d'une image de roche et en faire une base d'apprentissage. L'idée principale est que le dictionnaire fournisse une base dans laquelle la roche associée soit mieux représentée que les autres. La qualité d'un dictionnaire est liée ou est en relation avec l'erreur de reconstruction. Lors de la classification, on recherche le dictionnaire qui minimise l'erreur de reconstruction pour une contrainte de parcimonie imposée. En effet, plus l'erreur de reconstruction est faible, mieux le dictionnaire est adapté. Il existe dans la littérature de nombreuses méthodes utilisées pour la classification des roches avec l'aide d'un dictionnaire. Des méthodes usent des dictionnaires non appris, génériques comme par exemple une décomposition en série de Fourier ou une décomposition en ondelette [218] ou encore les décompositions géométriques multi-échelles (les curvelets par exemple). D'autres méthodes telles celles qui nous concerne font usage des techniques d'apprentissage automatique pour déduire le dictionnaire des données [195] et à notre connaissance n'ont jusque-là pas été utilisées dans l'étude des roches. Ces méthodes fournissent des dictionnaires adaptés aux données. Il a été démontré que les dictionnaires appris offrent une meilleure qualité de reconstruction que les dictionnaires prédéfinis [10]. Dans notre approche, les coefficients sont obtenus par décomposition du signal sur la base de signaux élémentaires appelés atomes qui sont de même nature que le signal disponible à décomposer en utilisant l'algorithme K-SVD. Un détail sur l'apprentissage de dictionnaire est donné à la section 1.2 issue des travaux de J. Aghaei [11].

### **5.2.1. Principe de la méthode de classification des roches proposée**

Le principe des approches proposées suit le même processus que celui présenté au chapitre 3. Nous partons d'une image originale  $I$  sur laquelle nous appliquons simultanément les filtres de Gabor et la DCT. L'on obtient respectivement Image Gabor et Image DCT. Sur ces dernières, est appliqué l'algorithme K-SVD, donnant lieu à un dictionnaire et une erreur de reconstruction pour chacune des images de roche. Nous appliquons ensuite l'algorithme ALBPCSF sur les Image Gabor et Image DCT obtenues précédemment, l'on obtient les images : G-ALBPCSF et

D-ALBPCSF. De même, à ces dernières, l'on applique l'algorithme K-SVD qui estime le dictionnaire et l'erreur de reconstruction de chacune des images. Un vecteur d'erreur de quatre (04) composantes représentant la signature de chaque roche est créé. Enfin, une analyse des vecteurs signatures des roches nous permet de discriminer les roches entre elles. Ce principe est résumé dans l'organigramme de la figure 5-1 ci-dessous.

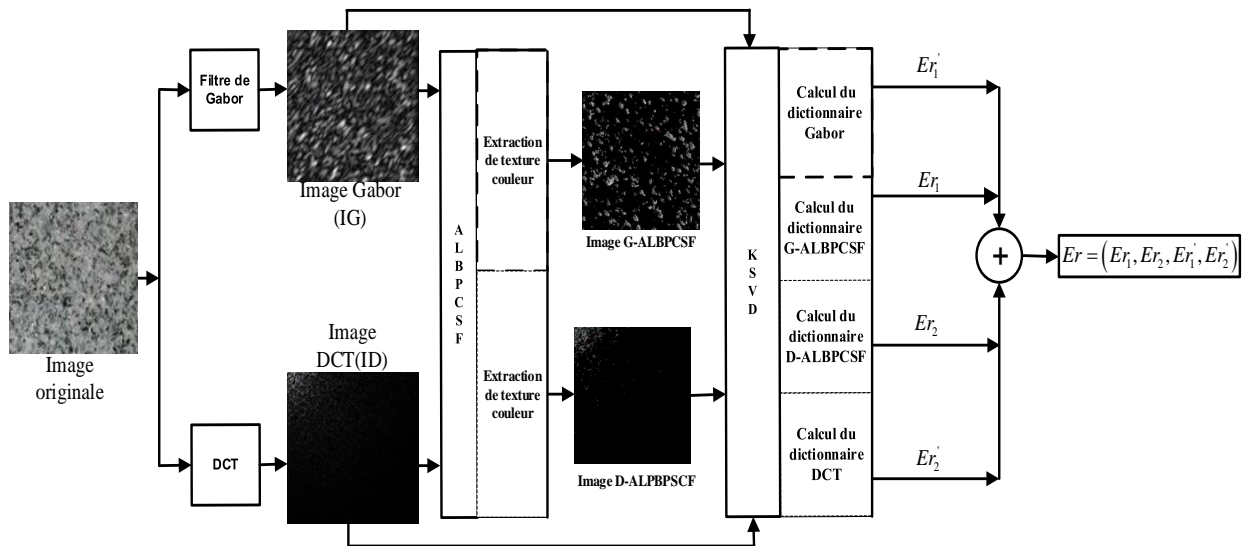


Figure 5-1: Organigramme de la méthode de classification de roches proposée

### 5.2.2. Algorithme de classification de la méthode proposée

L'algorithme ci-après traduit le principe de la méthode de classification présentée dans l'organigramme de la figure 5-1.

---

#### Algorithme KSVD\_DCT\_Gabor\_ALBPCSF

---

**Entrée :** l'image ALBPCSF, l'image RGB, l'image DCT, l'image Gabor

**Sortie :** Dictionnaires des images

Début

1. Appliquer l'Algorithme DCT\_Gabor\_ALBPCSF sur les images ALBPCSF et RGB
2. Créer la base de données d'images à partir des images DCT, Gabor et celles obtenus en 1.
3. Pour chaque image de la base de données d'image
4. Appliquer KSVD pour obtenir le dictionnaire et l'erreur de reconstruction
5. Sauvegarder l'erreur de reconstruction dans le vecteur Er
6. Fin Pour

Fin.

---

### 5.2.3. Apprentissage de dictionnaires avec Gabor et DCT

Les images de roches non homogènes présentent de grandes variabilités dues à la directionnalité et à l'orientation dans leurs textures. Pour prendre en compte ces différents

aspects de la texture des roches qui sont des textures naturelles, les auteurs utilisent les fonctions de base fréquentielles telles que la DCT et les filtres de Gabor [35]. De plus, ces méthodes copient les propriétés psycho-visuelles humaines et la prise en compte de ces propriétés permet de mieux analyser et traiter les roches. Dans cette section, nous nous intéressons aux dictionnaires Gabor et DCT qui sont calculés et puis appris en appliquant l'algorithme K-SVD sur les images des amplitudes de Gabor et des coefficients DCT pour faire des représentations parcimonieuses. Ces dernières images sont-elles mêmes obtenues par application des filtres de Gabor (spécialement pour une orientation de  $135^\circ$  et  $\lambda$  égale à 4) et de la DCT sur les images de vue directe de roches de notre base de données. Il est à noter que l'apprentissage de dictionnaire permet d'avoir des représentations adaptées aux données. Les erreurs de reconstructions de ces différents dictionnaires appris sont utilisées pour discriminer les roches puis faire leur classification.

#### **5.2.4. Apprentissage de dictionnaires avec G-ALBPCSF et D-ALBPCSF**

Pour améliorer la caractérisation des images de roches, nous avons combiné la LBP couleur aux transformées fréquentielles tels que les filtres de Gabor et la DCT afin d'obtenir respectivement les descripteurs G-ALBPCSF et D-ALBPCSF vus dans le chapitre 3. Le principe est le même que précédemment. Cependant, ici, les dictionnaires des différentes roches sont calculés et appris en appliquant K-SVD aux nouvelles images obtenues de ces combinaisons de descripteurs : les erreurs de reconstruction sont à nouveau utilisées comme facteur discriminant pour la classification.

### **5.3. Impact de la combinaison des caractéristiques sur les dictionnaires**

Pour améliorer la qualité du dictionnaire, l'apprentissage de dictionnaire est l'une des méthodes explorées. Une autre voie possible pour l'amélioration de la qualité du dictionnaire est la combinaison de caractéristiques. Cette combinaison permet de mieux représenter toute la diversité morphologique présente dans les images à traiter. Les résultats des expérimentations montrent que les combinaisons de méthodes donnent de meilleurs résultats que les méthodes dites simples.

### **5.4. Paramètres influençant l'apprentissage de dictionnaire**

L'apprentissage de dictionnaire ou Dictionary Learning (DL) en anglais, est l'une des étapes les plus importantes pour une représentation efficace des atomes de l'image. En effet, par une procédure d'optimisation alternée à chaque itération, les atomes du dictionnaire peuvent être estimés facilement par les méthodes de moindre carré ou de descente de gradient stochastique.

Ensuite, l'étape de codage parcimonieux qui est un problème NP-difficile, a été surmontée en utilisant les approches de poursuite de base avec la norme  $l_0$ , qui sont des heuristiques ou en remplaçant la norme  $l_0$  par la norme  $l_1$  avec une méthode de relaxation convexe. Toutefois, certains paramètres influencent cette optimisation du dictionnaire ; par exemple les critères d'arrêt qui peuvent être une erreur de représentation des vecteurs d'apprentissage à atteindre, un test sur la convergence de cette erreur, ou un nombre maximum d'itérations fixé.

#### **5.4.1. Critère d'arrêt : Nombre d'itérations**

Le critère d'arrêt que nous avons introduit pour estimer le dictionnaire afin de garantir une meilleure classification est le nombre d'itérations. Dans cette étude, nous avons fixé le nombre d'itérations à 500. L'algorithme s'arrête lorsque le nombre d'itération atteint 500 itérations. Cependant, ce nombre d'itération, lorsqu'il est pris égal à 1000 itérations, influence très peu l'erreur de reconstruction.

#### **5.4.2. La taille du dictionnaire**

L'augmentation ou la diminution de la taille du dictionnaire entraîne une détermination efficace du nombre d'atomes du dictionnaire. L'apprentissage d'un dictionnaire de taille adaptative en visant un compromis entre l'erreur de reconstruction et la parcimonie, a été proposé par la méthode de DLENE [226]. La taille du dictionnaire des roches influence l'estimation du dictionnaire.

### **5.5. Influence des paramètres sur l'estimation de l'erreur du dictionnaire**

Il existe plusieurs possibilités de choix des paramètres qui influencent l'estimation des dictionnaires. L'objectif, dans le choix des paramètres, est de parvenir à une meilleure représentation du dictionnaire de la roche de façon parcimonieuse. Ces paramètres peuvent influencer fortement la qualité du dictionnaire. La qualité du dictionnaire peut être liée à l'erreur de reconstruction : c'est le cas dans notre étude. Ainsi, pour une image de roche, plus l'erreur de reconstruction est faible, plus le dictionnaire est adapté à la roche et la représente mieux.

- Lorsque la taille ou les dimensions de l'image sont plus grandes, l'erreur de reconstruction est plus grande. Ces variations d'erreur dues à différentes tailles des images sont montrées au chapitre 3.
- Avec les méthodes KD-ALBPCSF, K-Gabor et KG-ALBPCSF, lorsque le nombre d'atomes  $K$  augmente ( $K=75$  atomes) tout en gardant la parcimonie (ou contrainte)  $L$  à 3 et avec un nombre d'itérations fixé à 500 itérations, l'erreur de reconstruction augmente et l'algorithme ne converge pas. En conséquence, il n'y a donc pas de stabilité

du dictionnaire. Cela est dû au nombre d'atomes choisis très grand devant la dimension de chaque donnée. Cependant, lorsqu'on diminue le paramètre  $K$  ( $K=25$  atomes par exemple) alors les algorithmes convergent et l'erreur de reconstruction est plus faible. Cela s'observe aussi bien au niveau des roches magmatiques que des roches métamorphiques.

- Avec la méthode K-DCT, le phénomène inverse se produit avec les deux (2) types de roches.

En somme, l'erreur de reconstruction dépend de la valeur de parcimonie. L'erreur augmente quand la taille du dictionnaire ou de l'image est grande. L'augmentation du nombre d'atomes du dictionnaire dans le but d'améliorer la qualité de représentation entraîne une augmentation du temps de codage.

### **5.6. Organigramme du principe de reconnaissance d'une roche**

La recherche d'images par le contenu visuel consiste à retrouver, dans une base de données d'images, des images visuellement similaires à une image requête. En général, le contenu des images (texture, forme et couleur) est caractérisé par un vecteur d'attributs ou signature qui représente les caractéristiques de chaque image de la base de données. Lors de la recherche, une signature de l'image requête est extraite puis comparée, suivant une mesure de similarité adoptée comme la distance euclidienne à l'ensemble des signatures stockées dans la base. Les images de la base qui produiront les plus grands scores de ressemblances, sont considérées comme les plus similaires.

L'organigramme de la méthode proposé est illustré par la figure 5-2.

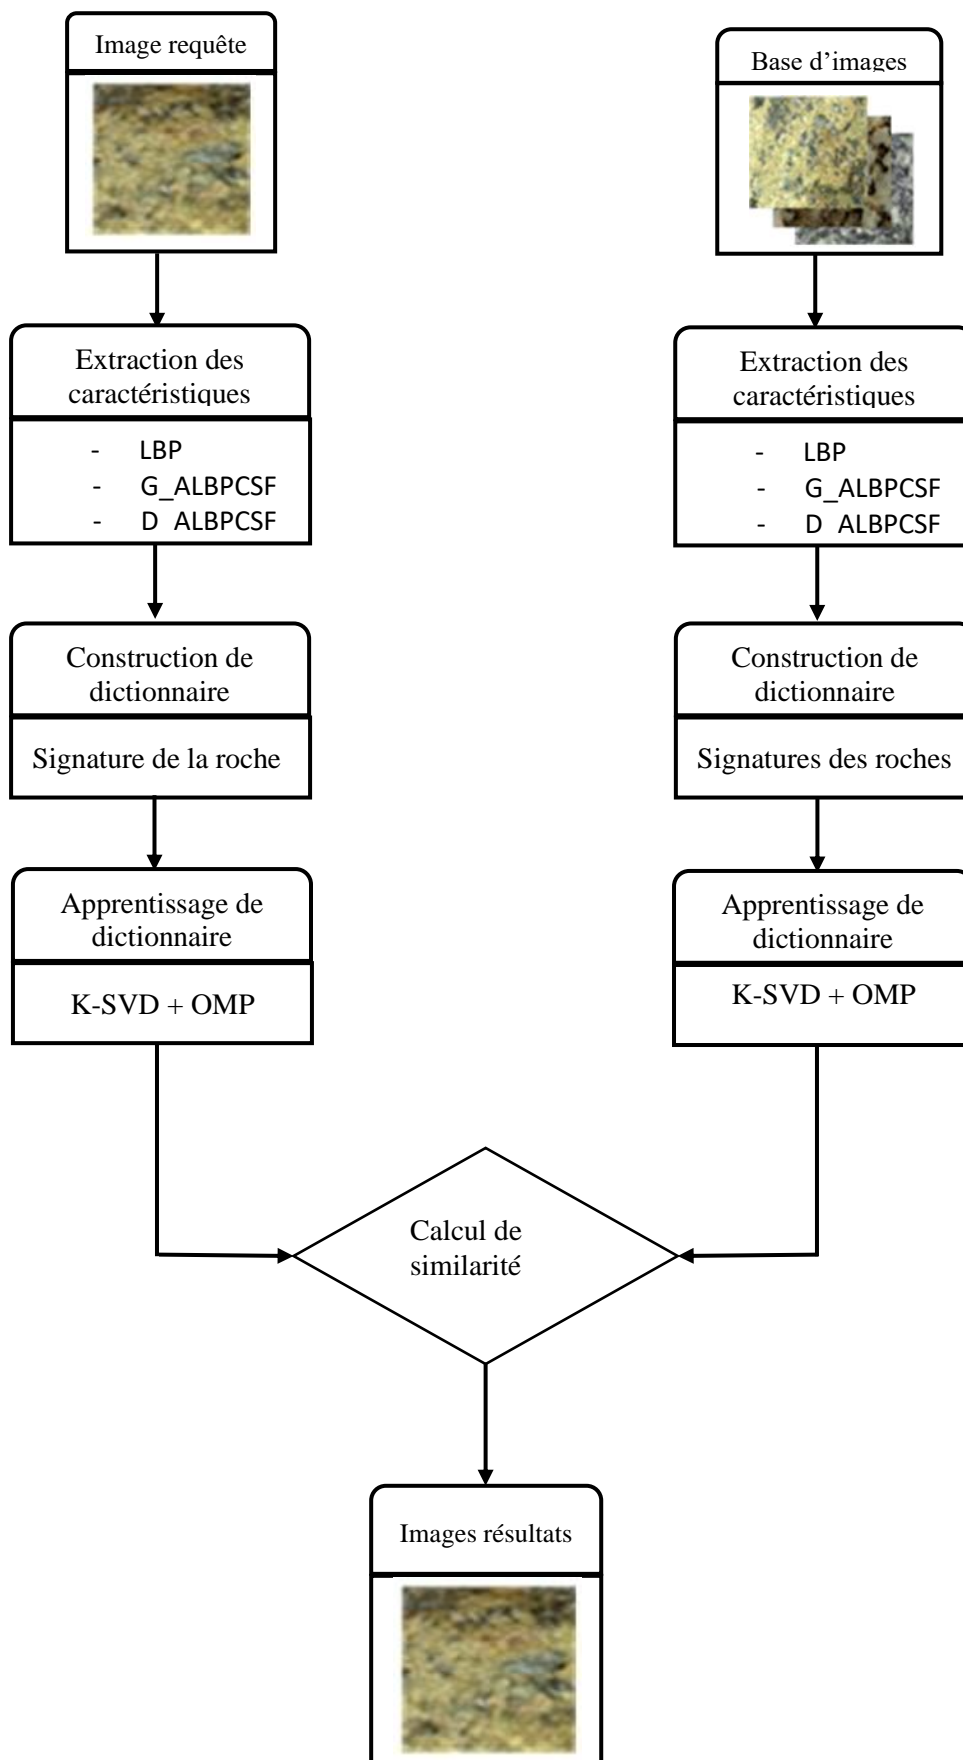


Figure 5-2: Organigramme du principe de reconnaissance



## 5.7. Expérimentations et résultats de la Classification des roches

Dans cette section, nous explorons la capacité et la performance de différentes combinaisons d'extraction de caractéristiques réalisées avec l'algorithme K-SVD, pour une meilleure classification. Les performances sont évaluées et comparées sous forme de taux de classification correcte, à partir des erreurs de reconstruction calculées lors de l'estimation des différents dictionnaires des différentes roches utilisées au chapitre précédent et qui sont appris. L'expérimentation a été réalisée avec le langage de programmation MATLAB sur un ordinateur HP Notebook et de processeur : Intel(R) Core(TM) i5-7200U CPU @ 2.50GHz, 2701 MHz, 2 cœur(s), 4 processeur(s) logique(s).

Dans le contexte de l'apprentissage, nous disposons d'un ensemble de quatre-vingt (80) images de roches de vue directe au total avec une résolution 256 x 256 chacune, dont 10 roches de chaque famille de roches : trente (30) de ces roches sont des roches magmatiques (10 granites, 10 granodiorites et 10 gabbros) et les cinquante (50) autres sont des roches métamorphiques (10 cipolins, 10 schistes, 10 migmatites, 10 éclogites et 10 cornéennes). Le test a été fait sur un ensemble de quarante (40) images de roches dont 5 images de chaque roche. Chaque roche a été classée géologiquement par un géologue expert dans chacune des deux (2) familles de roches citées plus haut. La méthode consiste à apprendre le modèle sur  $2n$  observations puis à valider le modèle sur les  $n$  observations ; l'opération est répétée  $n$  fois ou après  $n$  itérations. La classification des roches est obtenue par la recherche de proximité entre les erreurs de reconstruction avec la distance euclidienne (équation 5.1) que nous avons trouvée simple et meilleure dans notre cas face aux autres métriques de distance comme la distance Manhattan, la distance de Minkowski (pour un ordre supérieur ou égal à 3). Pour estimer la classe d'une image de roche  $I$  à classer, la méthode consiste à prendre en compte les erreurs de reconstruction des roches des différentes classes. La distance euclidienne permet de calculer la distance entre les signatures de  $X$  et de  $Y$ . Pour la classification, nous retenons la classe qui possède la distance minimale avec l'image  $I$ . Le tableau 5-1 présente les résultats de la classification des roches et donne le nombre d'échantillons attribués à chacune des huit (8) classes.

### 5.7.1. Mesure de similarité : distance euclidienne

L'évaluation de la qualité d'une méthode est une étape indispensable en classification et en traitement d'images. La mesure de similarité est l'un des moyens utilisés pour faire cette évaluation. En effet, le calcul de similarité entre deux (2) images  $I_1$  et  $I_2$  passe par une mesure de proximité entre signatures de  $I_1$  et de  $I_2$ . Dans ce contexte, toutes les mesures entre vecteurs

$x$  de  $\mathbb{R}^N$  sont possibles. Notons cependant, que le choix de la distance a un réel impact sur la classification. Différentes métriques [53] ont été testées et les meilleurs résultats de la classification ont été obtenus avec la distance euclidienne. En effet, La distance euclidienne entre deux (2) vecteurs signatures  $A$  et  $B_k$  de taille  $N$ , notée  $d(A, B_k)$ , où  $k$  décrit les classes de roches variant de 1 à 8. Cette distance est donnée par la formule suivante :

$$d(A, B_k) = \left( \sum_{i=1}^N (a_i - b_{ik})^2 \right)^{1/2} \quad (5.1)$$

$a_i$  représente les coordonnées de  $A$  (ou vecteur requête de la roche courante à identifier) et  $b_{ik}$  les coordonnées de  $B_k$  (vecteurs références des  $k$  classes de roches dans la base de données).

Soit  $X$  une matrice de vecteur qui regroupe sur chaque ligne les erreurs de reconstruction de chaque échantillon de roches obtenues sur dix (10) essais pour les quatre-vingt (80) échantillons de roches, soit au total huit cent (800) valeurs. On note que l'erreur de chaque essai est obtenue après cinq cent (500) itérations. Soit  $Y$  un vecteur qui regroupe la moyenne des erreurs de reconstruction de chaque échantillon après dix (10) essais sur chaque ligne (soit au total 80 valeurs moyennes ou référence de chaque classe de roches).  $Y = F_k$  représente la signature de chaque variante de K-SVD.  $Y_{ref}$  (correspondent aux  $b_{ik}$  d'une roche de classe  $k$ ) contient la signature de chaque classe de roche. On note que  $Y_{ref}$  a huit (8) valeurs au total (chaque élément de  $Y_{ref}$  est la moyenne des dix erreurs moyennes obtenues à partir de  $Y$ ).

### 5.7.2. Matrices de confusion

Les résultats des classifications avec les différentes méthodes utilisées sur les quatre-vingt (80) images de vue directe de roches en utilisant l'algorithme de classification supervisé et la règle de décision de distance minimale sous la forme de matrices de confusion sont présentés dans les tableaux 5-1 à 5-4. Les tableaux 5-1, 5-2, 5-3, 5-4 présentent respectivement les résultats de la classification utilisant la méthode KD-ALBPCSF, de la classification avec la méthode K-Gabor, de la classification utilisant la méthode K-DCT et enfin de la classification utilisant la méthode KG-ALBPCSF.

Les indicateurs de performance utilisés ici pour évaluer la performance de toutes ces méthodes ont été déjà définis au chapitre 4 (paragraphe 4.6.3). La sensibilité ou rappel, la spécificité, l'exactitude (accuracy) et la précision dont les équations sont décrites respectivement par les équations (4.8), (4.9), (4.10) et (4.11) sont les indicateurs de performance choisis pour prouver

l'efficacité des méthodes proposées et ont été aussi utilisés par Vivek et Audithan [141]. Notre expérimentation a porté sur 640 croisements des erreurs de reconstruction des roches.

Tableau 5-1 : Matrice de confusion réalisée pour la méthode KD-ALBPCSF

		CLASSES PREDITES								
Classes		1	2	3	4	5	6	7	8	TOTAL
CLASSES REELLES	1	<b>5</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>0</b>	<b>10</b>
	2	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>
	3	<b>0</b>	<b>1</b>	<b>9</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>
	4	<b>2</b>	<b>0</b>	<b>0</b>	<b>2</b>	<b>2</b>	<b>0</b>	<b>3</b>	<b>1</b>	<b>10</b>
	5	<b>1</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>3</b>	<b>1</b>	<b>4</b>	<b>0</b>	<b>10</b>
	6	<b>1</b>	<b>2</b>	<b>2</b>	<b>0</b>	<b>4</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>10</b>
	7	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>4</b>	<b>0</b>	<b>4</b>	<b>1</b>	<b>10</b>
	8	<b>0</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>5</b>	<b>1</b>	<b>10</b>
TOTAL		<b>9</b>	<b>14</b>	<b>11</b>	<b>4</b>	<b>17</b>	<b>6</b>	<b>16</b>	<b>3</b>	<b>80</b>

Tableau 5-2 : Matrice de confusion réalisée pour la méthode K-Gabor

		CLASSES PREDITES								
Classes		1	2	3	4	5	6	7	8	TOTAL
CLASSES REELLES	1	<b>4</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>3</b>	<b>10</b>
	2	<b>0</b>	<b>1</b>	<b>2</b>	<b>1</b>	<b>5</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>10</b>
	3	<b>0</b>	<b>1</b>	<b>7</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>
	4	<b>1</b>	<b>0</b>	<b>2</b>	<b>2</b>	<b>3</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>10</b>
	5	<b>5</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>1</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>10</b>
	6	<b>1</b>	<b>0</b>	<b>5</b>	<b>1</b>	<b>2</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>10</b>
	7	<b>3</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>1</b>	<b>4</b>	<b>10</b>
	8	<b>2</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>0</b>	<b>3</b>	<b>10</b>
TOTAL		<b>16</b>	<b>3</b>	<b>19</b>	<b>7</b>	<b>18</b>	<b>6</b>	<b>1</b>	<b>10</b>	<b>80</b>

Tableau 5-3 : Matrice de confusion réalisée pour la méthode K-DCT

		CLASSES PREDITES								
CLASSES REELLES	Classes	1	2	3	4	5	6	7	8	TOTAL
	1	<b>5</b>	<b>0</b>	<b>3</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>10</b>
	2	<b>2</b>	<b>5</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>10</b>
	3	<b>1</b>	<b>4</b>	<b>3</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>10</b>
	4	<b>2</b>	<b>0</b>	<b>2</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>3</b>	<b>1</b>	<b>10</b>
	5	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>7</b>	<b>10</b>
	6	<b>1</b>	<b>5</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>10</b>
	7	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>2</b>	<b>0</b>	<b>1</b>	<b>3</b>	<b>10</b>
	8	<b>0</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>2</b>	<b>0</b>	<b>2</b>	<b>4</b>	<b>10</b>
TOTAL		<b>12</b>	<b>15</b>	<b>11</b>	<b>8</b>	<b>5</b>	<b>5</b>	<b>8</b>	<b>16</b>	<b>80</b>

Tableau 5-4 : Matrice de confusion réalisée pour la méthode KG-ALBPCSF

		CLASSES PREDITES									
CLASSES REELLES	Classes	1	2	3	4	5	6	7	8	TOTAL	
	1	<b>9</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>10</b>
	2	<b>2</b>	<b>5</b>	<b>3</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	
	3	<b>0</b>	<b>5</b>	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>	
	4	<b>0</b>	<b>0</b>	<b>0</b>	<b>3</b>	<b>2</b>	<b>1</b>	<b>1</b>	<b>3</b>	<b>10</b>	
	5	<b>0</b>	<b>0</b>	<b>0</b>	<b>2</b>	<b>2</b>	<b>0</b>	<b>5</b>	<b>1</b>	<b>10</b>	
	6	<b>1</b>	<b>2</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>3</b>	<b>2</b>	<b>1</b>	<b>10</b>	
	7	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>6</b>	<b>2</b>	<b>10</b>	
	8	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>7</b>	<b>10</b>	
TOTAL		<b>12</b>	<b>12</b>	<b>9</b>	<b>6</b>	<b>7</b>	<b>6</b>	<b>14</b>	<b>14</b>	<b>80</b>	

Tableau 5-5 : Indicateurs de performance des quatre (4) méthodes

Indicateurs d'évaluation		Gabor	DCT	KD- ALBPCSF	KG- ALBPCSF
Images de textures de roche pour différentes classes	VP	20	23	33	40
	VN	500	503	513	520
	FP	60	57	47	40
	FN	60	57	47	40
	<b>Sensibilité</b>	<b>0,25</b>	<b>0,29</b>	<b>0,41</b>	<b>0,50</b>
	<b>Spécificité</b>	<b>0,89</b>	<b>0,90</b>	<b>0,92</b>	<b>0,93</b>
	<b>Exactitude</b>	<b>0,81</b>	<b>0,82</b>	<b>0,85</b>	<b>0,88</b>

Les définitions des termes partent du principe qu'une roche (classe de roches) est similaire à une autre si la distance euclidienne entre l'erreur de reconstruction d'une classe Y et la valeur référence Yref des erreurs de reconstruction de la classe est la plus faible et majorée par un seuil maximum à ne pas dépasser. Ce seuil dépend de la classe considérée lors de l'apprentissage. De ce fait, un vrai positif (VP) est une roche qui est de la classe et dont la distance euclidienne entre son erreur de reconstruction et celle de la référence de cette classe est la plus petite. Le faux positif (FP) est une roche qui n'est pas de la classe mais dont la distance, entre son erreur de reconstruction et celle de la référence d'une autre classe, est la plus petite. Le faux négatif (FN) est une roche qui est de la classe et qui n'a pas la valeur la plus petite valeur de la distance entre Y et Yref. Le vrai négatif (VN) est une roche qui n'est pas de classe et qui n'a pas la plus petite valeur de la distance entre les erreurs de reconstruction Y et Yref.

L'analyse des valeurs des différents tableaux montre que les quatre (4) variantes classifient mieux les roches magmatiques que les roches métamorphiques. Le tableau 5-4 révèle que l'approche KG-ALBPCSF classifie mieux deux (2) échantillons (classes 7 et 8) sur les cinq (5) échantillons chez les roches métamorphiques. Les approches KG-ALBPCSF et KD-ALBPCSF font de meilleures classifications des trois (3) roches magmatiques, contrairement aux deux (2) méthodes K-DCT et K-Gabor qui ne réussissent pas à les classer totalement. Les classes 2 et 1 (granite et granodiorite) sont difficiles à classifier par la méthode K-Gabor de même, la classe 3 reste difficile à classifier par K-DCT. L'information basse fréquence avec K-DCT est plus révélée avec les roches magmatiques. La figure 5-3 ci-dessous donne les proportions des échantillons de roches bien classés par méthode.

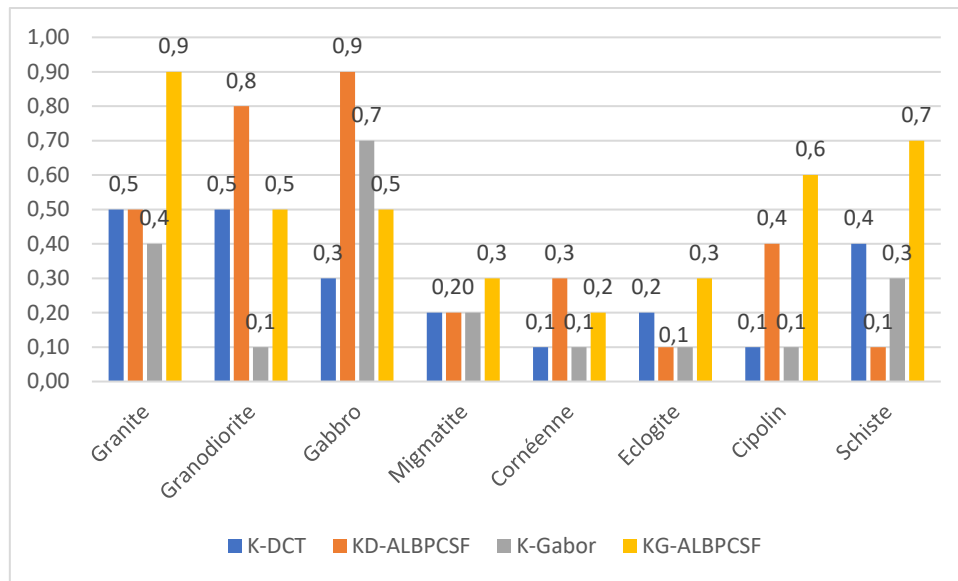


Figure 5-3: Pourcentages des échantillons bien classés par roche et pour les différentes méthodes de classification

Le tableau 5-6 et la figure 5-4 suivants présentent le taux de classification correcte pour chacune des quatre (4) méthodes de classification. Les résultats montrent que les méthodes avec les combinaisons de techniques d'extraction donnent les meilleurs résultats avec des taux de bonne classification évoluant jusqu'à 50 %.

Tableau 5-6 : Pourcentages de taux de bonne classification des différentes méthodes

Méthodes de classification	K-Gabor	K-DCT	KD-ALBPCSF	KG-ALBPCSF
Pourcentages de bonne classification	25 %	28,8 %	41,3 %	50 %




Figure 5-4: Pourcentages de taux moyen de bonne classification par méthode

Les résultats du tableau 5-7 et de la figure 5-5 montrent les pourcentages de taux de bonne classification des deux (2) familles de roches avec les quatre (4) méthodes. L'analyse atteste que les combinaisons de méthode KG-ALBPCSF et KD-ALBPCSF classifient mieux les roches magmatiques que les roches métamorphiques, avec des taux de bonne classification de 63,3% pour les roches métamorphiques et de 73,3 %, pour les roches magmatiques. La classification des roches métamorphiques reste toujours très faible, avec des taux de bonne classification inférieures à 50%.

Tableau 5-7 : Pourcentage de taux moyen de bonne classification par familles de roche

Méthodes	Pourcentages de bonne classification des différentes méthodes			
	K-DCT	K-Gabor	KD-ALBPCSF	KG-ALBPCSF
Roches magmatiques	43,3%	40%	73,3%	63,3%
Roches métamorphiques	20%	16%	22%	42%




Figure 5-5: Pourcentage de taux moyen de bonne classification par familles de roches

### 5.7.3. Discussion

Les résultats de l'activité expérimentale présentés dans la section 5.6.2 montrent que nos approches d'estimation de dictionnaire pour la classification des roches magmatiques et métamorphiques avec les combinaisons de méthodes c'est-à-dire KD-ALBPCSF et KG-ALBPCSF proposée, permettent d'améliorer les résultats obtenus avec la K-DCT et K-Gabor, pris individuellement. Ces résultats révèlent une fois de plus que la classification des roches est une tâche exigeante et très difficile. Dans la classification de ces roches, les informations hautes fréquences et basses fréquences ont été utiles. Ces résultats confirment donc ceux obtenus avec les moments statistiques calculés aux paragraphes 4.4.2.1 et 4.4.2.2 du chapitre 4. En outre, les combinaisons de méthodes proposées corrigent quelque peu le gap observé avec les résultats obtenus aux tableaux 5-2 et 5-3. Cela montre que, lorsque l'on prend en compte la répartition de l'intensité des textures couleur dans les images de roches avec les approches de combinaison, la classification est améliorée.

En somme, il faut noter que la classification des quatre (4) variantes testées une à une ne montre pas de bonnes performances. Cela s'explique par le caractère hétérogène et très varié des roches. Les classes d'images de roches se chevauchent également dans l'espace des caractéristiques. Pour apporter une solution aux problèmes posés, nous avons opté pour une concaténation des signatures des quatre (4) variantes.

## 5.8. Systèmes multi-algorithmes

La fusion des vecteurs caractéristiques peut se faire de plusieurs façons [57, 226]. Celle qui nous intéresse ici est la fusion multi-algorithme. C'est le type de système le plus classique utilisé



par de nombreuses approches. Les signatures sont extraites via différents algorithmes puis fusionnés pour donner un seul vecteur caractéristique, permettant de donner des précisions supérieures à celle d'un algorithme unique dans la classification des images de roches [53, 57].

## 5.9. Résultats de la fusion de caractéristiques

Afin de mieux discriminer les roches, nous avons concaténé les caractéristiques des roches à partir des différentes variantes utilisées pour les différentes expérimentations déjà menées sur cent vingt (120) images des bases d'apprentissage et de test.

### 5.9.1. Phase d'apprentissage

#### 5.9.1.1. Description

Dans l'étape d'apprentissage, on génère les signatures ou les paramètres caractéristiques des classes de roches dont quelques-unes sont présentées dans le tableau ci-dessous : X, F et Yref. X est la matrice des erreurs de reconstruction de l'ensemble des huit (8) classes des images de roches et pour les l'ensemble des quatre (4) variantes, on a : X1, X2, X3, X4. Chaque ligne de cette matrice contient les erreurs de reconstruction de chaque classe de roches ; chacune de ces dix (10) colonnes représente les erreurs de reconstruction à chaque essai de cinq cent (500) itérations. F = [F1, F2, F3, F4] représente la concaténation des paramètres caractéristiques de chaque roche à partir des quatre (4) variantes de K-SVD pour l'étape d'apprentissage où F1, F2, F3 et F4 représentent chacun, la moyenne des erreurs de reconstruction de chaque variante. Yref est la référence ou la signature de chaque classe de roche et  $X_k$  désigne la matrice de toutes les erreurs de reconstruction des huit (8) classes de roches pour chaque méthode. Ces différents paramètres sont présentés ci-dessous.

$$Y_{ref} = \begin{bmatrix} Y_{11} & Y_{21} & Y_{31} & Y_{41} \\ Y_{12} & Y_{22} & Y_{32} & Y_{42} \\ Y_{13} & Y_{23} & Y_{33} & Y_{43} \\ Y_{14} & Y_{24} & Y_{34} & Y_{44} \\ Y_{15} & Y_{25} & Y_{35} & Y_{45} \\ Y_{16} & Y_{26} & Y_{36} & Y_{46} \\ Y_{17} & Y_{27} & Y_{37} & Y_{47} \\ Y_{18} & Y_{28} & Y_{38} & Y_{48} \end{bmatrix} \begin{matrix} \rightarrow \text{Classe 1} \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ \cdot \\ \rightarrow \text{Classe 8} \end{matrix}$$

$$\begin{matrix} k = 1 : K - DCT(K - SVD + DCT) \\ k = 2 : KD - ALBPCSF(K - SVD + D - ALBPCSF) \\ k = 3 : K - Gabor(K - SVD + Gabor) \\ k = 4 : KG - ALBPCSF(K - SVD + G - ALBPCSF) \end{matrix}$$

$$\begin{matrix} \downarrow & \downarrow & \downarrow & \downarrow \\ k = 1 & k = 2 & k = 3 & k = 4 \end{matrix}$$

$$X_k = (x_{ij}^k) \text{ telle que } \begin{cases} i = 1, \dots, 10; \text{ où } i \text{ représente la colonne} \\ j = 1, \dots, 8; \text{ où } j \text{ représente la ligne} \\ k = 1, \dots, 4; \text{ où } k \text{ représente l'indice de la méthode} \end{cases}$$

Pour notre expérience, la matrice  $Y_{ref}$  contient huit (8) lignes, quatre (4) colonnes et se présente comme suit :

$$Y_{ref} = \begin{pmatrix} 5,0298 & 6,6733 & 1,9231 & 5,1948 \\ 6,2540 & 7,5880 & 1,6086 & 7,5937 \\ 5,4711 & 10,8690 & 1,4577 & 8,2089 \\ 4,7049 & 4,4742 & 1,5750 & 2,4970 \\ 3,8894 & 4,7743 & 1,6374 & 1,7804 \\ 6,1953 & 7,0282 & 1,4707 & 4,3798 \\ 4,4897 & 4,3354 & 1,9379 & 1,4806 \\ 3,8759 & 4,4458 & 1,9445 & 3,0411 \end{pmatrix}$$

Cependant, les matrices  $X_k$  sont des matrices de quatre-vingt (80) lignes et de dix (10) colonnes.

Un aperçu de ces matrices, dans les mêmes dimensions que la matrice  $Y_{ref}$ , pour l'exemple  $X_1$  correspondant à l'une des variantes de K-SVD, est défini comme suit :

$$X_1 = \begin{bmatrix} 5,0793 & 4,9441 & 4,885 & 4,9782 \\ 4,8398 & 5,0172 & 4,645 & 4,7675 \\ 5,6804 & 5,4445 & 5,4186 & 5,298 \\ 5,1769 & 5,5013 & 5,0159 & 5,1711 \\ 4,8112 & 4,9204 & 5,057 & 4,8567 \\ 5,5768 & 5,2558 & 5,2361 & 5,4207 \\ 4,6983 & 4,8746 & 4,9737 & 4,8881 \\ 5,0562 & 4,8155 & 4,8016 & 5,2816 \end{bmatrix}$$

### 5.9.1.2. Principe et résultats de la classification

L'expérience consiste à comparer l'erreur de reconstruction calculée pour une classe de roche donnée à toutes les  $Y_{ref}$  représentant les signatures des roches, et à retenir la plus petite valeur de distance à partir de la formule de la distance euclidienne ; ce qui indique la classe d'appartenance de la roche requête.

Tableau 5-8 : Images de roches utilisées pour l'apprentissage

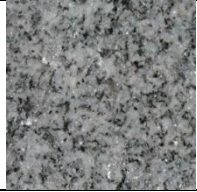
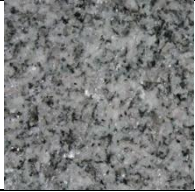
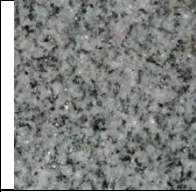
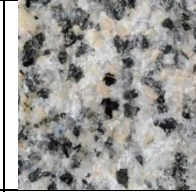
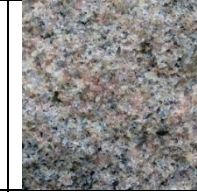


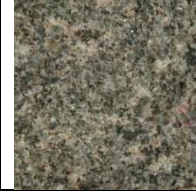


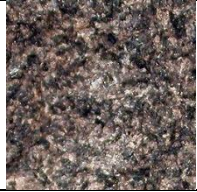

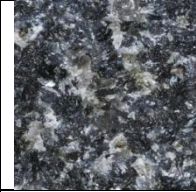
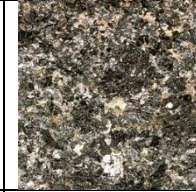
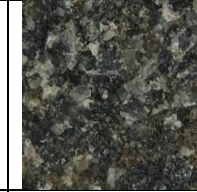










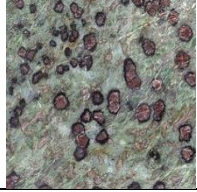
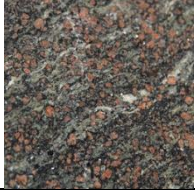

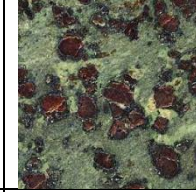
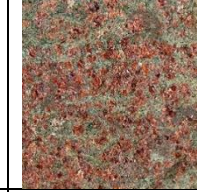

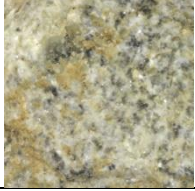

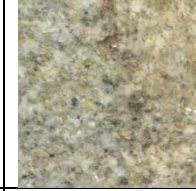
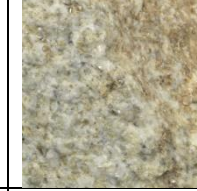





Granites					
	Granite_1(F)	Granite_2 (A20)	Granite_3(A21)	Granite_4(A16)	Granite_5(C)
Granodiorites					
	Grano_1(9)	Grano_2(11)	Grano_3(V)	Grano_4(X)	Grano_5(H)
Gabbros					
	Gabbro_1(3)	Gabbro_2(7)	Gabbro_3(4Z)	Gabbro_4(M)	Gabbro_5(T)
Migmatites					
	Mig_1(8)	Mig_2(12)	Mig_3(15)	Mig_4(20)	Mig_5(21)
Cornéennes					
	Corn_1(12)	Corn_2(13)	Corn_3(14)	Corn_4(15)	Corn_5(10)
Eclogites					
	Eclo_1(1)	Eclo_2(2)	Eclo_3(4)	Eclo_4(8)	Eclo_5(10)
Cipolins					
	Cip_1(3)	Cip_2(15)	Cip_3(16)	Cip_4(19)	Cip_5(21)
Schistes					
	Sch_1(5)	Sch_2(15)	Sch_3(16)	Sch_4(9)	Sch_5(11)

Tableau 5-9 : Matrice de confusion avec fusion des quatre (4) variantes

		CLASSES PREDITES								
Classes		1	2	3	4	5	6	7	8	TOTAL
CLASSES REELLES	1	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>
	2	<b>1</b>	<b>9</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>
	3	<b>0</b>	<b>0</b>	<b>10</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>10</b>
	4	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>10</b>
	5	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>10</b>
	6	<b>1</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>7</b>	<b>1</b>	<b>0</b>	<b>10</b>
	7	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>8</b>	<b>0</b>	<b>10</b>
	8	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>8</b>	<b>10</b>
TOTAL		<b>12</b>	<b>10</b>	<b>10</b>	<b>9</b>	<b>11</b>	<b>7</b>	<b>11</b>	<b>10</b>	<b>80</b>

Pour une analyse judicieuse combinatoire des quatre (4) variantes, une combinaison deux (2) à deux (2) ou trois (3) à trois (3) ou quatre (4) à quatre (4) ont été testées. Ce qui donne lieu à onze (11) possibilités de combinaisons. Cette étude montre que l'utilisation vectorielle simultanée des quatre (4) variantes et l'une des combinaisons de trois (3) variantes ([1 2 4]) donnent de meilleurs résultats (résultats identiques), contrairement aux autres possibilités combinatoires. Les résultats de cette combinaison de quatre (4) variantes sont consignés dans la matrice de confusion (voir tableau 5-9) ci-dessus.

Le tableau 5-10 donne les valeurs des indicateurs de performance calculés pour vérifier la performance de cette combinaison de variantes réalisée sur la phase d'apprentissage d'un ensemble de quatre-vingts (80) images de roches dont chacune des huit (8) classes contient dix (10) images de roches. Ces indicateurs sont calculés en suivant les mêmes formules présentées au paragraphe 4.6.3 du chapitre 4.

Le taux de classification pour l'ensemble des roches est de 96,25 %, où environ 99 % des roches magmatiques ont été bien classées, contre 95,4 % pour les roches métamorphiques. Quelques résultats de ces possibilités combinatoires des différentes variantes de K-SVD sont renseignés en annexe.

Tableau 5-10 : Indicateurs de performance de la combinaison des quatre (4) variantes de  
K-SVD

Indicateurs de performance	Combinaison des 4 variantes
VP	68
VN	548
FP	12
FN	12
Rappel	0,85 soit 85%
Précision	0,85 soit 85%
Exactitude	0,9625 soit 96,25%
<b>Taux d'erreur</b>	<b>0,0375 soit 3,75%</b>





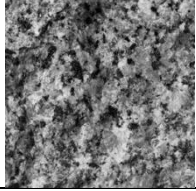




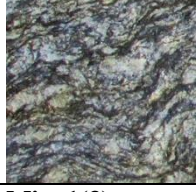





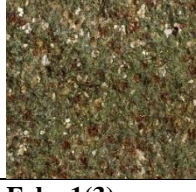



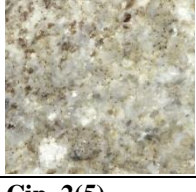
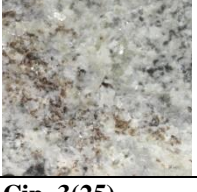



### 5.9.2. Classification sur la base de test d'apprentissage

En suivant le même principe que la phase d'apprentissage, nous calculons X ( $X_{11}$ ,  $X_{22}$ ,  $X_{33}$ ,  $X_{44}$ ) pour chaque roche requête et ces valeurs sont comparées aux valeurs de  $Y_{ref}$  qui représentent la signature des différentes classes de roches. Pour cette expérience de test, quarante (40) images de roches ont été utilisées dont cinq (5) de chacune des huit (8) classes. Ici, les matrices X contiennent quarante (40) lignes et dix (10) colonnes. Un aperçu d'une de ces matrices est présenté ci-dessous sous forme de  $X_{11}$  pour la première variante de K-SVD :

$$X_{11} = \begin{bmatrix} 5,0793 & 4,9441 & 4,885 & 4,9782 \\ 4,8112 & 4,9204 & 5,057 & 4,8567 \\ 4,6983 & 4,8746 & 4,9737 & 4,8881 \\ 5,1459 & 4,6852 & 4,6621 & 4,9534 \\ 4,9732 & 5,0503 & 4,8245 & 4,7057 \\ 6,5739 & 6,3625 & 6,5404 & 6,5875 \\ 6,4809 & 6,4807 & 6,6571 & 6,3076 \\ 7,1768 & 7,2457 & 7,3744 & 7,2229 \end{bmatrix}$$

Le tableau 5-11 donne quelques-unes des images de roches des différentes classes utilisées pour les tests. Pour les autres variantes, nous pouvons avoir par exemple comme matrice des caractéristiques des différentes autres variantes  $X_{22}$ ,  $X_{33}$  et  $X_{44}$  qui ne sont pas présentées ici.

Tableau 5-11 : Images de roches pour le test

Granites			
	<b>Granite_1(A12)</b>	<b>Granite_2(G)</b>	<b>Granite_3(N1)</b>
Granodiorites			
	<b>Grano_1(10)</b>	<b>Grano_2(2)</b>	<b>Grano_3(P)</b>
Gabbros			
	<b>Gabbro_1(6)</b>	<b>Gabbro_2(L)</b>	<b>Gabbro_3(O)</b>
Migmatites			
	<b>Mig_1(3)</b>	<b>Mig_2(2)</b>	<b>Mig_3(16)</b>
Cornéennes			
	<b>Corn_1(9)</b>	<b>Corn_2(3)</b>	<b>Corn_3(11)</b>
Eclogites			
	<b>Eclo_1(3)</b>	<b>Eclo_2(5)</b>	<b>Eclo_3(9)</b>
Cipolin			
	<b>Cip_1(1)</b>	<b>Cip_2(5)</b>	<b>Cip_3(25)</b>
Schistes			
	<b>Sch_1(18)</b>	<b>Sch_2(17)</b>	<b>Sch_3(14)</b>

### 5.9.3. Classification sur la base de test de validation de notre approche de classification

Pour valider notre approche, un test de validation permet d'évaluer la combinaison des quatre (4) variantes de K-SVD que nous proposons. Les résultats des paragraphes 7 et 8 nous permettent d'aboutir à une matrice de confusion pour cette évaluation. Cette matrice de confusion a été élaborée pour un ensemble de quarante (40) images de roches dont 5 de chaque classe (voir tableau 5-12 ci-dessous) et le tableau 5-13 donne les indicateurs de performance pour vérifier la pertinence de la méthode proposée.

Tableau 5-12 : Matrice de confusion avec notre méthode

		CLASSES PREDITES									
CLASSES RELLES	Classes	1	2	3	4	5	6	7	8	TOTAL	
	1	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>
	2	<b>0</b>	<b>4</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	
	3	<b>0</b>	<b>0</b>	<b>5</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>5</b>	
	4	<b>0</b>	<b>0</b>	<b>0</b>	<b>2</b>	<b>2</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>5</b>	
	5	<b>0</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>5</b>	
	6	<b>0</b>	<b>2</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>3</b>	<b>0</b>	<b>0</b>	<b>5</b>	
	7	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>0</b>	<b>0</b>	<b>4</b>	<b>0</b>	<b>5</b>	
	8	<b>1</b>	<b>0</b>	<b>0</b>	<b>0</b>	<b>1</b>	<b>1</b>	<b>0</b>	<b>2</b>	<b>5</b>	
<b>TOTAL</b>		<b>6</b>	<b>6</b>	<b>6</b>	<b>3</b>	<b>7</b>	<b>4</b>	<b>5</b>	<b>3</b>	<b>40</b>	

Les résultats du tableau 5.13 montrent que la méthode proposée donne de bonnes performances de classification, avec un taux de bonne classification de 93,13 % dans l'ensemble. Cependant, la méthode classe mieux les roches magmatiques avec un taux de 95,83 % contre 91,5 % pour les roches métamorphiques. La combinaison de méthodes vient combler le déficit constaté en prenant les méthodes individuellement. Le tableau 5-14 et la figure 5-6 présentent les différents indicateurs de performance réalisés.

Tableau 5-13 : Indicateurs de performance avec notre méthode

Indicateur de performance	Roches magmatiques			Roches métamorphiques				
	Granite	Granodiorite	Gabbro	Migmatite	Cornéenne	Eclogite	Cipolin	Schiste
VP	5	4	5	2	4	3	4	2
FN	0	1	0	3	1	2	1	3
FP	1	2	1	1	3	1	1	1
VN	34	33	34	34	32	34	34	34
<b>Rappel</b>	<b>1</b>	<b>0,8</b>	<b>1</b>	<b>0,4</b>	<b>0,8</b>	<b>0,6</b>	<b>0,8</b>	<b>0,4</b>
<b>Précision</b>	<b>0,833</b>	<b>0,667</b>	<b>0,833</b>	<b>0,667</b>	<b>0,571</b>	<b>0,75</b>	<b>0,8</b>	<b>0,667</b>
<b>Exactitude</b>	<b>0,975</b>	<b>0,925</b>	<b>0,975</b>	<b>0,9</b>	<b>0,9</b>	<b>0,925</b>	<b>0,95</b>	<b>0,9</b>
<b>Moyenne Exactitude</b>	<b>0,958</b>			<b>0,915</b>				

Tableau 5-14 : Indicateurs de performance

Indicateurs de performance	Roches magmatiques et métamorphiques	Roches magmatiques	Roches métamorphiques
Précision	0,725	0,778	0,691
Rappel	0,725	0,933	0,600
<b>Exactitude</b>	<b>0,931</b>	<b>0,958</b>	<b>0,915</b>




Figure 5-6: Indicateurs de performance de la combinaison de variante

## 5.10. Conclusion partielle

Nous avons proposé de nouvelles méthodes de classification lesquelles ont été utilisées dans le contexte de la classification automatique des roches magmatiques et métamorphiques. La



performance de ces méthodes a été évaluée à travers des matrices de confusion qui ont abouti à des taux de classification. Il faut noter que l'apprentissage de dictionnaire est un problème complexe. Les résultats des simulations montrent que les résultats ne sont pas toujours excellents. Il est difficile d'obtenir la même erreur après deux (2) essais. Cependant, les dictionnaires appris sont plus proches des données. Nos deux (2) approches améliorent tout de même le taux de bonne classification jusqu'à 50 % (41,3 % à 50 %). La concaténation des 4 variantes de K-SVD permet d'améliorer considérablement le taux de classification jusqu'à 93,13 % dans l'ensemble, avec des taux spécifiques de classification de 95,83 % pour les roches magmatiques, et 91,5% pour les roches métamorphiques.

---

## CONCLUSION GENERALE ET PERSPECTIVES

Ce travail est une contribution à l'identification automatique, simple et rapide, principalement de quelques roches magmatiques et métamorphiques, en vue de faire leur reconnaissance. Notre étude s'est focalisée sur les images photographiques multimodales et macroscopiques de vue directe de ces roches. La revue de la littérature, au chapitre 2, sur la classification des roches montre d'une part que les méthodes de classification des roches sont toujours associées, en amont, à des techniques de réduction des dimensions des descripteurs, introduisant souvent du bruit, d'autre part, elles sont associées à des techniques d'extraction de caractéristiques souvent non adaptées aux images.

Dans la même veine, la littérature nous révèle que, les représentations parcimonieuses avec l'apprentissage de dictionnaire appliquées sur les images satellitaires et sur les images faciales ont montré de belles performances, nous motivant à introduire les représentations parcimonieuses pour la construction et l'apprentissage de dictionnaires des roches avec K-SVD puis à opter pour la combinaison de techniques d'extraction des caractéristiques des roches. Dans cette étude, nos activités de recherche ont gravité autour de la recherche de méthodes d'agrégation de descripteurs pour une meilleure prise en compte des caractéristiques texturales et colorimétriques des roches, ensuite sur la classification des roches, à partir d'un dictionnaire adapté aux données présentes dans les images de roches.

Pour notre première contribution, nous avons fait une analyse de certains descripteurs tels que le descripteur de texture de Wang et le descripteur de texture LBP colorimétrique composite nommé « ALBPCSF », pour montrer l'influence de ces descripteurs sur des images de roches. Une autre analyse fut également réalisée par la représentation parcimonieuse des signaux avec K-SVD combinée aux spectres de textures des roches. Dans la première approche, nous avons d'abord appliqué K-SVD à des images de vue directe de roches et aux images obtenues à partir des textures de Wang ; conduisant à l'estimation respective de deux (2) dictionnaires  $D1$  et  $D2$ , ainsi que les matrices parcimonieuses associées  $X1$  et  $X2$  et leurs erreurs de reconstruction respectives  $Er1$  et  $Er2$ .

Dans la seconde analyse, l'approche précédente fut complétée par une combinaison de K-SVD avec le descripteur LBP couleur composite afin de prendre en compte l'aspect spectral de la couleur, permettant d'accentuer la similarité entre les roches ; Ce qui se justifie par une erreur relative plus faible.

Dans une seconde contribution, nous avons proposé une nouvelle méthode de classification basée sur les méthodes D-ALBPCSF et LBP par une mesure de similarité entre les histogrammes. Le taux de bonne classification de ces méthodes a été de 95 % avec une précision de plus de 80 % pour la méthode D-ALBPCSF.

Dans la dernière contribution, nous avons développé une deuxième méthode de classification basée sur K-SVD combinée à quatre (4) techniques d'extraction de caractéristiques : la DCT, les filtres de Gabor, la D-ALBPCSF et la G-ALBPCSF. Les mesures de performance réalisées nous ont permis d'obtenir un taux de bonne classification variant jusqu'à 50 %. Ces taux ont par la suite été améliorés en concaténant les quatre (4) variantes de K-SVD en une seule pour obtenir 93,13 % de taux de bonne classification des roches dans leur ensemble, avec 95,83 % en moyenne pour les roches magmatiques et 91,5 %, pour les roches métamorphiques.

En perspectives, nous prévoyons améliorer la performance de notre méthode de reconnaissance en utilisant comme caractéristiques des roches, les moments statistiques pour la classification. Nous envisageons ensuite créer un vecteur de caractéristiques qui sera la signature de chacune des roches en concaténant les dictionnaires obtenus avec les différentes méthodes proposées. Enfin, nous explorerons leur combinaison avec l'analyse spectrophotométrique et l'analyse microscopique d'images de roches.

## REFERENCES BIBLIOGRAPHIQUES

- [1]. A. Bitam, “**Analyse et segmentation d’images multispectrales : Application aux images MSG**”, Thèse de Doctorat de l’Université Mouloud MAMMERI de TIZI-OUZOU, 2013.
- [2]. L. Lepistö, Kunttu, I., Autio, J., Visa, A., “**Classification of non-homogeneous textures images combining classifiers**”, In: Proceedings of IEEE International Conference on Image Processing (ICIP 2003), Vol. 1, pp. 981-984, Barcelona, Spain, 2003.
- [3]. F. Bianconi, E. Gonzalez, A. Fernandez and S. A. Saetta “**Automatic Classification of granite tiles through colour and texture features**”, Expert Systems with Applications, vol. 39, no.12, pp. 11212-11218, 2012.
- [4]. S. Lefèvre, “**Approches multivariées et supervisées en morphologie mathématique et application en analyse d’image**”, Habilitation à diriger les travaux de recherche de l’Université de Strasbourg, 2009.
- [5]. L. Lepistö, L. Kunttu and A. Visa, “**Rock image classification using Color features in Gabor space**”, Journal of Electronic Image, Vol. 14, no. 4, pp. 1-3, 2005.
- [6]. Izadi, J. Sadri and M. Bayati, “**An intelligent system for mineral identification in thin sections based on a cascade approach**”, Computers & Geosciences, Vol. 99, pp. 37-49, 2017.
- [7]. M. Mlynarczuk, A. Gorszczyk, and B. Slipek, “**The application of pattern recognition in the automatic classification of microscopic rock images**”, Computers and Geosciences, Vol. 60, pp. 126-133, 2013.
- [8]. R. Marschallinger, “**Automatic Mineral Classification in the Macroscopic Scale**”, Computers & Geosciences, Elsevier Science, Vol. 23, no. 1, pp. 119-126, 1997.
- [9]. B. Olshausen and D. Field, “**Sparse coding with an overcomplete basis set: A strategy employed by v1?**”, Vis. Res. Vol. 37, no. 23, pp. 3311-3325, 1997.
- [10]. M. Aharon, M. Elad, and A. Bruckstein, “**K-SVD : An algorithm for Designing overcomplete dictionaries for sparse representation**”, IEEE Transactions on Signal Processing, Vol. 54, no. 11, pp. 4311-4322, 2006.
- [11]. J. M. Agahaei, “**Représentations parcimonieuses et apprentissage de dictionnaires pour la compression et la classification d’images satellites**”, Thèse de Doctorat de l’Université de Rennes1, Bretagne, 2015.
- [12]. J. Zepeda, C. Guillemot, and E. Kijak, “**Image Compression Using Sparse Representations and the Iteration-Tuned and Aligned Dictionary**”, IEEE Journal of Selected Topics in Signal Processing, Vol. 5, pp. 1061-1073, 2011.

- [13]. T. Ojala, M. Pietikainen, and D. Harwood, “**A comparative study of texture measures with classification based on feature distributions**”, Pattern Recognition, Vol. 29, pp. 51- 59, 1996.
- [14]. F. Bianconi, R. Harvey, P. Southam, and A. Fernández, “**Theoretical and experimental comparison of different approaches for color texture classification**”, Journal of Electronic Imaging, Vol. 20, no. 4, 2011.
- [15]. J. M. Aghaei, E. Vural, C. Labit, and C. Guillemot, “**Learning discriminative multilevel structured dictionaries for supervised image classification**”, arXiv: 1802.10497v1, 2018.
- [16]. Assas O., “**Classification floue des images**”. Thèse de Doctorat de l’Université de Batna, Algérie, 2013.
- [17]. M. Andre, “**Introduction aux techniques de traitement d’images**”, Eyrolles 1987
- [19]. K. F. Adles, “**Contribution à la morphologie mathématique : nouveaux ordres vectoriels et nouvelle méthode de classification vectorielle de pixels d’images multicomposantes**”, Thèse de Doctorat de l’Institut National Polytechnique Houphouët Boigny, Yamoussoukro, 2018.
- [20]. Rafael C. Gonzalez Richard E. Woods, “**Digital image processing**”, Vol. 3<sup>rd</sup>, 2009.
- [21]. Young, T., “**Bakerian Lecture: On the Theory of Light and Colours**”. Phil. Trans. R. Soc. Lond. 92: pp.12-48, 1802
- [23]. Lambert P., Macaire L. “**Filtering and Segmentation: The Specificity of color images**”, Proceeding of the 1st International Conference on Color in Graphics and Image Processing, Saint-Etienne, France, pp. 57-71, 2000.
- [24]. S. Ouattara, “**Stratégie de segmentation d’images multicomposantes par analyse d’histogrammes multidimensionnels : Application à des images couleur de coupes histologiques**”. Thèse de Doctorat de l’Université d’Angers, France, 2009.
- [25]. N. Vendenbroucke, “**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 de l’Université de Lille 1, France, 2000.
- [26]. N. Vandenbroucke, L. Busin, and L. Macaire. “**Unsupervised color-image segmentation by multicolor space iterative pixel classification**”, Journal of Electronic Imaging, Vol. 24, no. 2, 2015.
- [27]. O. Lezoray “**Segmentation d’image couleur par morphologie mathématique et classification de données par réseaux de neurones : application à la classification de cellules en cytologie des séreuses**”. Thèse à l’Université de Caen, France, 2000.

- [28]. G. Wyszecki and W. S. Stiles. “**Color Science: concepts and methods, quantitative data and formulae**”, John Wiley & Sons, Inc., New York, second edition, 1982.
- [29]. A. Clement, “**Algorithmes et outils informatiques pour l’analyse d’images couleur : Application à l’étude de coupes histologiques de baies de raisins en microscopie optique**”, Thèse de Doctorat de l’Université d’Angers, France, 2002.
- [30]. **Internationale Beleuchtungs commission**, editor. Colorimetry. Number 15 in Technical Report / CIE. CIE, Central Bureau, Vienna, 3. ed edition, 2004. OCLC: 255699746.
- [31]. D. T. Berry. “**Colour recognition using spectral signatures**”, Pattern Recognition Letters, Vol. 6, no. 1, pp. 69–75, 1987.
- [32]. Healey C.G., Enns J.T., “**A perceptual color Segmentation Algorithm**”, UBC CS Technical Repport, 1996.
- [33]. Zhiming Liu, Chengjun Liu, “**Fusion of color, local spatial and global frequency information for face recognition**”, Pattern Recognition, Vol. 43, pp. 2882–2890, 2010.
- [34]. J. B. Ditya, A. K. Gupta and F. A. Khan, “**Comparing the performance of L\*a\*b\* and HSV color spaces with respect to color image segmentation**”, International Journal of Emerging Technology and Advanced Engineering (IJETA), Vol. 5, pp. 192-203, 2015.
- [35]. Y. I. Ohta, T. Kanade, et T. Sakai. “**Color information for region segmentation**”. Computer Graphics and Image Processing, Vol. 13, pp. 222–241, 1980.
- [36]. Vinh TRUONG HOANG, “**Multi color space LBP-based feature selection for texture classification**”, Thèse de Doctorat de l’Université du Littoral Côte d’Opale, 2018.
- [37]. E. Cernadas, M. F. Delgado, E. G. Rufino and P. Carrion, “**Influence of normalization and color space to color texture classification**”, Pattern Recognition, Vol. 61, pp. 120-138, 2017.
- [38]. H. D. Cheng, X. H. Jiang, Y. Sun and J. Wang, “**Color image segmentation: advances and prospects**”. Pattern Recognition, vol. 34, pp. 2259-2281, 2001.
- [39]. N. Vandenbroucke, L. Macaire, J. G. Postaire, “**Color image segmentation by pixel classification in adapted hybrid color space. Application to soccer image segmentation**”. Computer Vision and Image Understanding, Vol. 90, no. 2, pp.190-216, 2003.
- [40]. I. Lissner and P. Urban, “**Toward a unified color space for perception-based image processing**”, IEEE Trans. Image Process., Vol. 21, no. 3, pp. 1153-1168, 2012.
- [41]. S. Handour, “**Segmentation d’images couleurs par morphologie mathématique : application aux images microscopiques**”, Thèse de Doctorat de l’Université de Toulouse. France, 2010.

- [42]. Duda R. O., Hartt P. E. and Stork D. G., “**Pattern classification**”, 2<sup>nd</sup> edition, John Wiley & Sons, 2001.
- [44]. P. Shivhare, V. Gupta, “**Review of image segmentation techniques including pre & post processing operation**”, international journal of engineering and advance technology, vol. 4, issue 3, Feb. 2015.
- [45]. A. K. Thakur and Madhusudan, “**Image Segmentation: A Comparative Study**”, International Journal of Advances in Computer Science and Technology, Vol. 5, no. 6, pp.64-71, 2016.
- [46]. Sujata S. and Komal A., “**A study analysis on the different image segmentation Techniques**” International Journal of Information & Computation Technology, Vol. 4, no 14, pp. 1445-1452, 2014.
- [47]. N. Otsu, “**A Threshold Selection Method from Grey-Level Histograms**”. IEEE Transactions on System, Man, and Cybernetics, Vol. 9, no. 1, pp. 62-66, 1979.
- [48]. J. Autio, L. Lepistö, and A. Visa, “**Image analysis and data mining in rock material research**”, Materia, Vol. 4, pp. 36-40, 2004.
- [49]. M. Mlynarczuk, M. Skiba, “**The Application of Artificial Intelligence for the Identification of the Maceral Groups and Mineral Components of Coal**”, Computers and Geosciences, Vol. 103, pp. 133-141, 2017.
- [50]. M. Ladniak and M. Mlynarczuk, “**Search of visually similar microscopic rock images,**” In comput. GEOSCI, Vol. 19, pp. 127-136, 2014.
- [51]. C. Shang an D. Barnes, “**Support vector machine-based classification of rock texture images aided by efficient feature selection**”, IEEE World Congress on Computational Intelligence (WCCI), pp. 10-15, 2012.
- [52]. A. Fernandez, O. Ghita, E. Gonzalez, F. Bianconi and P. F. Whelan, “**Evaluation of robustness against rotation of LBP, CCR and ILBP features in granite texture classification**”, Machine Vision and Application, Springer, no. 22, pp. 913-926, 2011.
- [53]. L. Lepistö, L. Kunttu and A. Visa, “**Rock image classification based on k-Nearest Neighbor (K-NN) voting**”, IEE Proceedings Vision, Image and Signal Processing, Vol. 153, no. 4, pp. 475-482, 2006.
- [54]. T. Harinie, I. J. Chellam, S. B. Sathya Bama, S. Raju, and V. Abhaikumar “**Classification of Rock textures**”, Proceedings of the InConINDIA, AISC 132, pp. 887-895, 2012.
- [55]. N. Singh, T. N. Singh, A. Tiway and K. M. Sarkar, “**Textural identification of basaltic rock mass using image processing and neural network**”, Computer and Geosciences, Vol. 14, pp. 301- 310, 2010.

- [56]. S. Chatterjee “**Vision-based rock-type classification of limestone using multiclass support vector machine**”, Applied Intelligence Vol. 39, pp. 14-27, 2013.
- [57]. L. Lepistö, Kunttu, I., Autio, J., Visa, A., “**Classification of non-homogeneous textures images combining classifiers**”, In: Proceedings of IEEE International Conference on Image Processing (ICIP 2003), Vol. 1, pp. 981-984, Barcelona, Spain, 2003.
- [58]. L. Lepistö, “**Colour and Texture Based Classification of Rock Images Using Classifier Combinations**”, Thesis for the degree Doctor of technology, at Tampere University of technology, on the 7th of April 2006.
- [59]. G. E. Ehlers, and Blatt, H.: “**Petrology, Igneous sedimentary and metamorphic**”. CBS publishers and distribution.4596/1-A new delhi-11000, India, 1997.
- [60]. P. A. Sabine, Harrison, R. K., & Lawson, R. I., “**Classification of volcanic rocks of the British Isles on the total alkali oxide-silica diagram, and the significance of alteration**”, British Geological Survey Report, Vol. 17, no. 4, 1985.
- [61]. Streckeisen, A., “**Classification and nomenclature of plutonic rocks**”, recommendations N. Jb. Miner. MonatJg., pp. 149-164, 1973.
- [62]. Streckeisen, A., “**Classification of the common igneous rocks by means of their chemical composition: a provisional attempt**”, JV. Jb. Miner. Mh. Jg., pp. 1-15, 1976.
- [63]. H. Williams, T. J. Francis, G.M. Charles, “**Petrography: An Introduction to the study of rocks in thin section**”, 2<sup>nd</sup> ed. San Francisco, US, 1982.
- [66]. Van Gool, L., Dewaele, P., Oosterlinck, A., “**Survey texture analysis Anno 1983**”, Computer Vision, Graphics, and Image Processing, Vol. 29, pp. 336-357, 1985.
- [67]. R. M. Haralick, “**Statistical and Structural approach to texture,**” Proceeding of the IEEE, Vol. 67, no. 5, May 1979.
- [68]. B. Julesz. “**Textons, the elements of texture perception, and their interactions**”, Nature, Vol. 290, pp. 91–97, March 1981.
- [69]. P. Brodatz, “**Texture: A photographic album for Artistic and Designers**”, Reinhold, New York, 1968.
- [70]. Nour-Eddine Lasmar : **Modélisation stochastique pour l’analyse d’images texturées : Approches Bayésiennes pour la caractérisation dans le domaine des transformées**, Thèse de Doctorat réalisé à l’Université Sciences et Technologie-Bordeaux 1, France, 2013.
- [71]. R. M. Haralick, K. Shanmugam, and I. Dinstein, “**Textural features for image classification**”, IEEE Trans. SMC, Vol. 3, no. 6, pp. 610–621, November 1973.



- [72]. A. Drimbarean and P. F. Whelan, “**Experiments in colour texture analysis**”, Pattern Recognition Letters, Vol. 22, no. 10, pp. 1161–1167, 2001.
- [73]. H. Tamura, S. Mori, and T. Yamawaki, “**Textural features corresponding to visual perception**”, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 8, no. 6, pp. 460-473, 1978.
- [74]. J. Malik, S. B., T. Leung, J. Shi, “**Contour and texture analysis for image segmentation**”, International Journal of Computer Vision, 2001.
- [75]. K. A. Nugraha, W.H., N.A. Haryono, “**Analysis Tekstur Pada Citra Motif Batik Untuk Klasifikasi Menggunakan K-NN**”, Jurnal Informatika, 2014.
- [76]. D. Han et al., “**Classification of levee slides from airborne synthetic aperture radar images with efficient spatial feature extraction**”, Journal of Applied Remote Sensing, Vol. 9, no. 1, p. 097294, 2015.
- [77]. Rao, A. R., Lohse G. L., “**Towards a texture naming System: Identifying relevant dimensions of texture**”, Proceedings of IEEE Conference on Visualization, USA, pp. 220-227, 1993.
- [78]. F. Liu and R W. Picard. Periodicity, directionality and randomness, “**Wold features for image modelling and retrieval**”, Vol. 18, no. 7, pp. 722–733, 1996.
- [79]. B. Julesz, E. N. Glibert, and J. D. Victor, “**Visual discrimination of textures with Identical third-order statistic**”, Biol. Cybernetics, Vol. 31, pp. 137-140, 1978.
- [80]. Dounia Awad. **Vers un système perceptuel de reconnaissance d’objets. Vision par ordinateur et reconnaissance de formes**. Thèse de Doctorat réalisé à l’Université de la Rochelle, au Laboratoire Informatique, Image, Interaction Pole Sciences et Technologies, 2014.
- [81]. A. Rosenfeld & M. Thurston, “**Edge and Curve Detection for Visual Scene Analysis**”, Computers, IEEE Transactions on, vol. C-20, no. 5, pages 562–569, 1971.
- [82]. C. Gasquet & P. Witomski. “**Analyse de Fourier et applications**”, Université de Grenoble I, Dunod, 1996.
- [83]. S. Theodoridis & K. Koutroumbas. “**Pattern recognition**”, third edition. Academic Press, Inc., Orlando, FL, USA, 2006.
- [84]. L. Lepistö, I. Kunttu, J. Autio, J. A. Visa, “**Rock image classification using non-homogenous textures and spectral imaging**”, WSCG Short papers proceedings, plzen, Czech Republic, pp. 82-86, 2003.
- [85]. L. Lepistö, I. Kunttu, J. Autio, J. A. Visa, “**Rock image Retrieval and classification based on Granularity**”, Proceedings of 5th International Workshop on Image Analysis for Multimedia Interactive Services, Lisbon, Portugal, 2004.

- [86]. C. Palm and T. M. Lehmann, “**Classification of color textures by Gabor filtering**”, *Machine Graphics & Vision International Journal*, Vol. 11, no. 2-3, pp.195–219, September 2002.
- [87]. T. Mäenpää and M. Pietikäinen, “**Classification with color and texture: jointly or separately?**”, *Pattern Recognition*, Vol. 37, no. 8, pp. 1629–1640, August 2004.
- [88]. S. Banerji, A. Verma, and C. Liu, “**LBP and color descriptors for image classification**” In *Cross Disciplinary Biometric Systems*, Springer, pp. 205–225, 2012.
- [89]. R. Khan, J. van de Weijer, F. S. Khan, D. Muselet, C. Ducottet, and C. Barat, “**Discriminative color descriptors**”, In *Proceedings of 23th IEEE International Conference on Computer Vision and Pattern Recognition*, pages 2866–2873, June 2013.
- [90]. F. S. Khan, J. Van de Weijer, S. Ali, and M. Felsberg, “**Evaluating the impact of color on texture recognition**”, In *International Conference on Computer Analysis of Images and Patterns*, pp.154–162. Springer, 2013.
- [91]. R. G. Gonzalez and R. E. Woods: “**Digital image processing**”, Addison-Wesley Publishing Company, 1993.
- [92]. M. Seul, O’Gorman, L., & Sammon, M. J., “**Practical algorithms for image analysis**”, Cambridge: Cambridge University Press, 2000.
- [93]. A. Del Dimbo, “**Visual Information Retrieval**”, Morgan Kaufmann Publishers, San Francisco, California, 1999.
- [94]. C. Boukovalas, J. Kittler, R. Marik, and M. Petrou, “**Color grading of randomly textured ceramic tiles using color histograms**”, *IEEE. Transactions on Industrial Electronics*, Vol. 46, no. 1, pp. 219-226, 1999.
- [95]. J. W. Vangah, S. Ouattara, A. Clement and G. Ouattara, “**Combination of dictionary learning by K-SVD and a colorimetric texture descriptor for improved identification of geological structures: case of rocks**”, *International Journal of Innovation and Applied Studies (IJIAS)*, Vol. 24, no. 3, pp. 1193-1208, 2018.
- [96]. Jun-Kai G., Chia-Chi S. and C. Heng-Hua, “**Restoration of underwater vision using a two-phase regularization mechanism**”, *The 7th International Congress on Image and Signal Processing*, pp. 243-247, 2014.
- [97]. C. Cusano, P. Napoletano, and R. Schettini, “**Combining local binary patterns and local color contrast for texture classification under varying illumination**”, *Journal of the Optical Society of America A*, Vol. 31, no. 7, pp. 1453, July 2014.
- [98]. H. Permuter, J. Francos, and I. Jermyn, “**A study of Gaussian mixture models of color and texture features for image classification and segmentation**”, *Pattern Recognition*, Vol. 39, no. 4, pp. 695–706, 2006.

- [99]. O. J. Hernandez, J. Cook, M. Griffin, C. De Rama, and M. McGovern, “**Classification of color textures with random field models and neural networks**”, *Journal of Computer Science & Technology*, 5, 2005.
- [100]. M. Tuceryan and A. K. Jain and others, “**Texture analysis**”, In the *Handbook of Pattern Recognition and Computer Vision* (2nd Edition), Vol. 2, pp. 207–248, 1993.
- [101]. Li Wang, “**Automatic Identification of Rocks in thin sections using texture analysis**”, *Mathematical Geology*, Vol. 27, no.7, 1995.
- [102]. M. Stricker and M. Orengo, “**Similarity of Color Images**”, *Proceedings of SIPE Storage and Retrieval for Image and Video Databases III*, Vol. 2420., 1995.
- [103]. M. Swain and M. Ballard, “**Color indexing**”, *International Journal of Computer Vision*, Vol. 7, no. 1, pp. 11-32, 1991.
- [104]. J. Huang, S. R. Kumar, M. Mitra and W. J. Zhu, “**Image indexing using color correlograms**”, *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Juan, Puerto Rico, pp. 762-768, 1997.
- [105]. F. Bianconi and A. Fernández. An appendix to “**Texture databases – A comprehensive survey**”, *Pattern Recognition Letters*, Vol. 45, pp. 33–38, August 2014.
- [106]. K. Sande, T. Gevers, and C. Snoek, “**Evaluating color descriptors for object and scene recognition**”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 32, no. 9, pp. 1582–1596, September 2010.
- [107] N. Vandembroucke, O. Alata, C. Lecomte, A. Porebski, and Imtnan-UI-H. Qazi. “**Color texture attributes**”, In *Digital Color Imaging*, ISTE – Wiley, pp. 193–240, May 2012.
- [108] C. Zheng, Da-W. Sun, and L. Zheng, “**A new region-primitive method for classification of colour meat image texture based on size, orientation, and contrast**”, *Meat Science*, Vol. 76, no. 4, pp. 620–627, August 2007.
- [109]. A. Koschan, “**A comparative study on color edge detection**”, In *Proceedings of the 2nd Asian Conference on Computer Vision*, pp. 574–578, 1995.
- [110]. A. Sinha, S. Banerji, and C. Liu, “**Novel color Gabor-LBP-PHOG (GLP) descriptors for object and scene image classification**”, In *Proceedings of the Eighth Indian Conference on Computer Vision, Graphics and Image Processing*, page 58. ACM, 2012.
- [111]. B. Thai et G. Hailey, “**Optimal Spatial Filter Selection for illumination -invariant color texture discrimination**”, *IEEE Transactions on System, Man, and Cybernetics-Part B*, Vol. 30, no. 4, pp. 610-616, 2000.

- [112]. G. Pachos, “**Perceptually Uniform Color Spaces for Color Texture Analysis: An Empirical Evaluation**”, IEEE Transactions on Image Processing, Vol. 10, no. 6, pp. 932-937, 2001.
- [113]. G. Van de Wouwer, P. Scheunders, S. Livens, and D. Van Dyck, “**Wavelet correlation signatures for color texture characterization**”, Pattern recognition, Vol. 32, no. 3, pp. 443–451, 1999.
- [114]. Q. Xu, J. Yang, and S. Ding, “**Color texture analysis using the wavelet-based hidden Markov model**”, Pattern Recognition Letters, Vol. 26, no. 11, pp. 1710–1719, August 2005.
- [115]. P. S. Hiremath, S. Shivashankar, and J. Pujari, “**Wavelet based features for color texture classification with application to CBIR**”, International Journal of Computer Science and Network Security, Vol. 6, no. 9A, pp. 124–133, 2006
- [116]. D. Iakovidis, D. Maroulis, and S. Karkanis, “**A comparative study of color-texture image features**”, In Proceedings of IEEE International Workshop on Systems, Signal and Image Processing, pp. 205–209, 2005.
- [117]. M. Pietikäinen, T. Mäenpää, and J. Viertola, “**Color texture classification with color histograms and local binary patterns**”, In Workshop on Texture Analysis in Machine Vision, pp. 109–112, 2002.
- [118]. A. Rosenfeld, “**Multispectral texture**”, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 12, no. 1, pp. 79–84, January 1982.
- [119]. R. Pydipati, T. F. Burks, and W. S. Lee, “**Identification of citrus disease using color texture features and discriminant analysis**”, Computers and Electronics in Agriculture, Vol. 52, no. 1-2, pp. 49–59, June 2006.
- [120]. R. Lakmann and L. Priese, “**A reduced covariance color texture model for micro-textures**”, In Proceedings of 10th Scandinavian Conference on Image Analysis, Lappeenranta, Finland, 1997.
- [121]. S. O. Shim, T. S. Choi, “**Image indexing by modified color co-occurrence matrix**”, Proceedings of International Conference on Image Processing Barcelona, Spain, Vol. 3, pp. 493-496, 2003.
- [122]. J. Martinez-Alajarin, J. D. Luis-Delgado, and L. M. Tomas-Balibrea, “**Automatic system for quality-based classification of marble textures**”, IEEE Transactions on Systems, Man, and Cybernetics, Vol. 35, no. 4, pp. 488–497, November 2005.
- [123]. A. Ledoux, O. Losson, and L. Macaire, “**Color local binary patterns: compact descriptors for texture classification**”, Journal of Electronic Imaging, Vol. 25, no. 6, pp. 061404, 2016.

- [124]. C. Münzenmayer, H. Volk, C. Küblbeck, K. Spinnler, and T. Wittenberg, “**Multispectral texture analysis using interplane sum- and difference -histograms**”, In Proceedings of the 24th DAGM Symposium on Pattern Recognition, pp. 42–49, 2002.
- [125]. T. Mäenpää, M. Pietikainen, and J. Viertola, “**Separating color and pattern information for color texture discrimination**”, In Proceedings of the 16th IEEE International Conference on Pattern Recognition, volume 1, pp. 668–671, 2002.
- [126]. S. H. Lee, J. Y. Choi, Y. M. Ro, and Konstantinos N. Plataniotis, “**Local color vector binary patterns from multichannel face images for face recognition**”, IEEE Transactions on Image Processing, Vol. 21, no. 4, pp. 2347–2353, April 2012.
- [127]. P. Vácha, M. Haindl, and T. Suk, “**Colour and rotation invariant textural features based on Markov random fields**”, Pattern Recognition Letters, Vol. 32, no. 6, pp. 771–779, 2011.
- [128]. A. Bosch, A. Zisserman, and X. Muñoz, “**Scene classification via pLSA**”, In European conference on computer vision, pp. 517–530. Springer, 2006.
- [129]. Y. Ke & R. Sukthankar, “**PCA-SIFT: A More Distinctive Representation for Local Image Descriptors**”, In Proceedings Computer Society Conference on Computer Vision and Pattern Recognition (CVPR), IEEE Computer Society, pp. 506–513, USA, 2004.
- [130]. H. Bay, A. Ess, T. Tuytelaars & L. Van Gool, “**Speeded-Up Robust Features (SURF)**”, Comput. Vis. Image Underst., vol. 110, no. 3, pages 346–359, June 2008.
- [131]. K. Mikolajczyk & C. Schmid, “**A Performance Evaluation of Local Descriptors**”, IEEE Trans. Pattern Anal. Mach. Intell., vol. 27, no. 10, pp. 1615–1630, October 2005.
- [132]. A. Sinha, S. Banerji, and C. Liu, “**New color GPHOG descriptors for object and scene image classification**”, Machine Vision and Applications, Vol. 25, no. 2, pp. 361–375, Feb. 2014.
- [133]. F. Sandid and A. Douik, “**Robust color texture descriptor for material recognition**”, Pattern Recognition Letters, Vol. 80, pp. 15–23, September 2016.
- [134]. F. Peng, L. Qin and M. Long, “**CCoLBP: Chromatic Co-occurrence of Local Binary Pattern for face presentation attack detection**”, 27th International Conference on Computer Communication and Networks (ICCCN), 2018.
- [135]. L. Liu, P. Fieguth, Y. Guo, X. Wang, and M. Pietikäinen, “**Local binary features for texture classification: Taxonomy and experimental study**”. Pattern Recognition, Vol. 62, pp. 135–160, February 2017.

- [136]. J. E. Lindqvist and U. Akesson, “**Image analysis applied to engineering geology, a literature review**”, Bulletin of Engineering Geology and the Environment, Vol. 60, no. 2, pp. 117-122, 2001.
- [137]. M. Singh, A. Javadi and S. Singh, “**A comparison of texture features for the classification of rock images**”, Proceedings of 5th International Conference on Intelligent Data Engineering and Automated Learning, LNCS 3177, Exeter, UK, pp. 179-184, 2004.
- [138]. P. Paclik, S. Verzakov, R. P. W. Duin, “**Improving the maximum-likelihood co-occurrence classifier: a study on classification of inhomogeneous rock images**”, Proceedings of 4th Scandinavian Conference on Image Analysis, Joensuu, Finland, pp. 998-1008, 2005.
- [139]. M. T. Duarte, J. M. R. Fernlund, “**Analysis of meso textures of geomaterials through Haralick parameters**”, Proceedings of the 2<sup>nd</sup> Iberian Conference on Pattern Recognition and Image Analysis, Portugal, pp. 713-719, 2005.
- [140]. R. A. Salinas, U. Raff, C. Farfan, “**Automated estimation of rock fragment distributions using computer vision and its application in mining**”, IEEE proceedings on Vision Image, and Signal Processing Vol. 152, no. 1, 20050810, 2005.
- [141]. C. Vivek and S. Audithan, “**Robust analysis of the rock texture image based on the boosting classifier with Gabor wavelet features**”, Journal of Theoretical and Applied Information Technology, Vol. 69, no. 3, pp. 562-570, 2014.
- [142]. F. J. Galdames, C. A. Perez, P. A. Estévez and M. Adams, “**Rock Lithological Classification by Laser Range 3D and Color Images**”, International Journal of Mineral Processing, 2017.
- [143]. X. Tan and B. Triggs, “**Enhanced local texture feature sets for face recognition under difficult lighting conditions**”, In International Workshop on Analysis and Modeling of Faces and Gestures, pp. 168–182. Springer, 2007.
- [144]. M. Heikkilä, M. Pietikäinen, and C. Schmid, “**Description of interest regions with local binary patterns**”, Pattern Recognition, Vol. 42, no. 3, pp. 425–436, March 2009.
- [145]. K. Wang, Charles-E. Bichot, Chao Z., and L. Bailin, “**Pixel to patch sampling structure and local neighboring intensity relationship patterns for texture classification**”, IEEE Signal Processing Letters, Vol. 20, no. 9, pp. 853–856, September 2013.
- [146]. M. Calonder, V. Lepetit, M. Ozuysal, T. Trzcinski, C. Strecha, and P. Fua, “**BRIEF: Computing a local binary descriptor very fast**”, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 34, no. 7, pp. 1281–1298, 2012.
- [147]. L. Li, L. Yunli, P. W. Fieguth, L. Songyang, and Z. Guoying, “**BRINT: Binary Rotation**

- Invariant and Noise Tolerant Texture classification**”, IEEE Transactions on Image Processing, Vol. 23, no. 7, pp. 3071–3084, July 2014.
- [148]. L. Liu, L. Zhao, Y. Long, G. Kuang, and P. Fieguth, “**Extended local binary patterns for texture classification**”, Image and Vision Computing, Vol. 30, no. 2, pp. 86–99, February 2012.
- [149]. Z. Baochang, G. Yongsheng, Z. Sanqiang, and L. Jianzhuang, “**Local derivative pattern versus local binary pattern: face recognition with high-order local pattern descriptor**”, IEEE Transactions on Image Processing, Vol. 19, no. 2, pp. 533–544, February 2010.
- [150]. L. Liu, S. Lao, P. W. Fieguth, Y. Guo, X. Wang, and M. Pietikainen, “**Median robust extended Local Binary Pattern for texture classification**”, IEEE Transactions on Image Processing, Vol. 25, no. 3, pp. 1368–1381, March 2016.
- [151]. N. S Vu, H. M. Dee, and A. Caplier, “**Face recognition using the POEM descriptor**”, Pattern Recognition, Vol. 45, no. 7, pp. 2478–2488, July 2012.
- [152]. G. Zhao, T. Ahonen, and J. Matas, “**Rotation-Invariant Image and Video Description with Local Binary Pattern Features**”, IEEE Transactions on Image Processing, Vol. 21, no. 4, pp. 1465–1477, April 2012.
- [153]. J. Kannala and E. Rahtu, “**BSIF: Binarized Statistical Image Features**”, In Proceedings of the 21th IEEE International Conference on Pattern Recognition, pages 1363–1366, 2012.
- [154]. T. Ojala, M. Pietikainen and T. Maenpaa, “**Multiresolution gray-scale and rotation invariant texture classification with local binary patterns**”, IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 24, no. 7, pp. 971-987, 2002.
- [155]. D. Huang, C. Shang, M. Ardabilian, Y. Wang and L. Chen, “**Local Binary Patterns and its application to facial image analysis: A survey**”, IEEE Transactions on systems, MAN and Cybernetics-Part C: Applications and reviews, Vol. 41, no.6, pp. 765-781, 2011.
- [156]. S. Brahmam, L. C. Jain, L. Nanni, and A. Lumini, “**Local Binary Patterns: New variants and applications**”, volume 506 of Studies in Computational Intelligence. Springer Berlin Heidelberg, Berlin, Heidelberg, 2014.
- [157]. M. Pietikäinen, T. Ojala, and Z. Xu, “**Rotation-invariant texture classification using feature distributions**”, Pattern Recognition, Vol. 33, no. 1, pp. 43–52, 2000.
- [158]. S. Liao and A. C. Chung, “**Face recognition by using elongated local binary patterns with average maximum distance gradient magnitude**”, In Proceedings of the Asian Conference on Computer Vision, pp. 672–679. Springer, 2007.

- [159]. L. Nanni, A. Lumini, and S. Brahmam. “**Local binary patterns variants as texture descriptors for medical image analysis**”, *Artificial Intelligence in Medicine*, Vol. 49, no. 2, pp. 117–125, June 2010.
- [160]. T. Mäenpää and M. Pietikäinen, “**Multi-scale binary patterns for texture analysis**”, In *Proceedings of the 13th Scandinavian Conference on Image Analysis*, pp. 885–892. Springer Berlin Heidelberg, 2003.
- [161]. L. Zhang, R. Chu, S. Xiang, S. Liao, and Stan Z. Li, “**Face detection based on multi block LBP representation**”, In *Proceedings of the 2007 International Conference on Advances in Biometrics*, pp. 11–18. Springer-Verlag, 2007.
- [162]. H. Jin, Q. Liu, H. Lu, and X. Tong, “**Face detection using improved LBP under Bayesian framework**”, In *Proceedings of the Third International Conference on Image and Graphics*, pp. 306–309, December 2004.
- [163]. A. Hafiane, G. Seetharaman, and B. Zavidovique, “**Median binary pattern for textures classification**”, In *Proceedings of the 4th International Conference on Image Analysis and Recognition*, pp. 387–398. Springer Berlin Heidelberg, 2007.
- [164]. S. Liao, M. W. K. Law, and A. C. S. Chung, “**Dominant Local Binary Patterns for texture classification**”, *IEEE Transactions on Image Processing*, 1Vol. 8, no. 5, pp. 1107–1118, 2009.
- [165]. W. Zhang, S. Shan, W. Gao, X. Chen, and H. Zhang, “**Local Gabor binary pattern histogram sequence (LGBPHS): a novel non-statistical model for face representation and recognition**”, In *Proceedings of the 10th IEEE International Conference on Computer Vision*, Vol. 1, pp.786–791, October 2005.
- [166]. X. Wang, Tony X. Han, and S. Yan, “**An HOG-LBP human detector with partial occlusion handling**”, In *Proceedings of the 12th IEEE International Conference on Computer Vision*, pp. 32–39, 2009.
- [167]. S. U. Hussain and W. Triggs, “**Feature sets and dimensionality reduction for visual object detection**”, In *Proceedings of the British Machine Vision Conference*, pp. 112.1- 112.10, 2010.
- [168]. B. F. Klare and A. K. Jain, “**Heterogeneous face recognition using kernel prototype similarities**”, *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol. 35, no. 6, pp.1410–1422, June 2013.
- [169]. A. Roy and S. Marcel, “**Haar Local Binary Pattern Feature for Fast Illumination Invariant Face Detection**”, In *Proceedings of the The British Machine Vision Conference*, pp.19.1–19.12, 2009.



- [170]. T. Ahonen, J. Matas, C. He, and M. Pietikäinen, “**Rotation invariant image description with local binary pattern histogram Fourier features**”, In Proceedings of the 16th Scandinavian Conference on Image Analysis, pp. 61–70. Springer Berlin Heidelberg, 2009.
- [171]. V. T. Hoang, A. Porebski, N. Vandenbroucke, and D. Hamad, “**LBP parameter tuning for texture analysis of lace images**”, In Proceedings of the Second IEEE International Conference on International Image Processing, Applications and Systems, pp. 1–6, 2016.
- [172]. J. Ning, L. Zhang, D. Zhang, and C. Wu, “**Robust object tracking using joint color-texture histogram**”, International Journal of Pattern Recognition and Artificial Intelligence, Vol. 23, no. 07, pp. 1245–1263, 2009.
- [173]. M. Kalakech, A. Porebski, N. Vandenbroucke, and D. Hamad, “**A new LBP histogram selection score for color texture classification**”, In Proceedings of the 5th IEEE International Conference on Image Processing Theory, Tools and Applications, pp. 242–247, Nov. 2015.
- [174]. F. Z. Chelali and A. Djeradi, “**CSLBP and OCLBP local descriptors for speaker identification from video sequences**”, In Proceedings of IEEE International Conference on Complex Systems, pp. 1–7, 2015.
- [175]. S. Wang, D. Huang, H. Jia, D. Liu and B. B. Dickson, “**Adjacent Local Binary Patterns Based on Color Space Fusion for Color Image Classification**”, Journal of Fiber Bioengineering and Informatics, vol. 8, no. 4, pp. 783-790, 2015.
- [176]. A. K. Jain, R. P. W. Duin, and J. Mao, “**Statistical pattern recognition: A review**”, IEEE Transactions on Pattern Analysis and Machine Intelligence, Vol. 22, no. 1, pp. 4–37, 2000.
- [177]. O. Baklanova and O. Shvets, “**Methods and Algorithms of Cluster Analysis in the Mining Industry-Solution of Tasks for Mineral Rocks Recognition**”, In Proceedings of the 11th International Conf. on Signal Processing and Multimedia Applications, pp. 165-171, 2014.
- [178]. M. J. Álvarez, E. González, F. Bianconi, J. Armesto and A. Fernández “**Colour and texture features for image retrieval in granite industry**”, Dyna, year 77, no. 161, pp. 121-130, 2010.
- [179]. B. S. Manjunath and W. Y. Ma, “**Texture features for browsing and retrieval of image data**”, IEEE Trans. Pattern Anal. Mach. Intell., Vol. 18, pp. 837–842, August 1996.
- [180]. B. S. Manjunath, P. Salembier and T. Sikora, “**Introduction to MPEG-7 Multimedia content description interface**”, John Wiley & Sons, Uk, 2002.
- [181]. J. Wright, A. Y. Yang, A. Ganesh, S. S. Sastry, Y. Ma, “**Robust face recognition via sparse representation**”, Pattern Anal. Mach. Intell. IEEE Trans. Vol. 31, no. 2, pp. 210–227, 2009.

- [182]. J. Mairal, F. Bach, J. Ponce, “**Sparse modeling for image and vision processing**”, *Found. Trends. Comput. Graph. Vis.* Vol. 8, no. 2–3, pp. 85–283, 2014.
- [183]. G. Davis, S. Mallat, and M. Avellaneda, “**Adaptive greedy approximation, Constructive Approximation**”, Vol. 13, no. 1, pp. 57–98, 1997.
- [184]. S. Mallat, Z. Zhang, “**Matching Pursuit with Time-Frequency Dictionaries**”, *IEEE Transactions on Signal Processing*, Vol. 41, pp. 3397–3415, 1993.
- [185]. Y. C. Pati, R. Rezaifar, P. S. Krishnaprasad, “**Orthogonal Matching Pursuit: Recursive Function Approximation with Applications to Wavelet Decomposition**”, In *Proc. of the 27 th Annual Asilomar Conference on Signals, Systems, and Computers*, pp. 40–44, 1993.
- [186]. D. L. Donoho, Y. Tsaig, I. Drori, and J. L. Starck, “**Sparse Solution of Underdetermined Systems of Linear Equations by Stagewise Orthogonal Matching Pursuit**”, *IEEE Transactions on Information Theory*, Vol. 58, no. 2, pp. 1094–1121, 2012.
- [187]. W. Dai, and O. Milenkovic, “**Subspace Pursuit for Compressive Sensing signal reconstruction**”, *IEEE Trans. On Information Theory*, Vol. 55, pp. 2230–2249, 2009.
- [188]. L. Rebollo-Veira and Lowe, “**Optimized orthogonal matching pursuit approach**”, *IEEE Signal Processing Letters*, Vol. 9, no. 4, pp. 137–140, 2002.
- [189]. G. Rath and C. Guillemot, “**A complementary matching pursuit algorithm for sparse approximation**”, In *Proc. European Signal Processing Conference (EUSIPCO)*, Vol. 164, 2008.
- [190]. T. Blumensath and M. E. Davies, “**Iterative thresholding for sparse approximations**”, *Journal of Fourier Analysis and Applications*, Vol. 14, no. 5–6, pp. 629–654, 2008.
- [191]. J. A. Tropp, and S. J. Wrigh, “**Computational Methods for Sparse Solution of Linear Inverse Problems**”, *Proceedings of the IEEE*, Vol. 98, no. 6, pp. 948–958, 2010.
- [192]. S. Chen, D. L. Donoho, A. M. Saunders, “**Atomic Decomposition by Basis Pursuit**”, *SIAM Journal on Scientific Computing*, Vol. 20, no. 1, pp. 33–61, 1998.
- [193]. I. F. Gorodnitsky, B. D. Rao, “**Sparse signal reconstruction from limited data using FOCUSS: a re-weighted minimum norm algorithm**”, *Signal Processing, IEEE*, Vol. 45, no. 3, pp. 600–616 (March), 1997.
- [194]. C. Herzet, A. Drémeau, “**Bayesian Pursuit Algorithms**”, In *Proc. European Signal Processing Conference (EUSIPCO)*, Aalborg, Denmark, August 2010.
- [195]. R. Rubinstein, A. Bruckstein et M. Elad. “**Dictionaries for Sparse Representation Modeling**”. In *IEEE Proceedings. T.* Vol. 98, no. 6, pp. 1045–1057, 2010.

- [196]. R. Rubinstein, T. Peleg et M. Elad. “**Analysis K-SVD: A Dictionary-Learning Algorithm for the Analysis Sparse Model**”, In IEEE Transactions on Signal Processing. T. Vol. 61, No. 3, pp. 661–677, 2013
- [197]. M. Sadeghi, M. Babaie-Zadeh et C. Jutten, “**Dictionary Learning for Sparse representation: A Novel Approach**”, In IEEE Signal Processing Letters. T. Vol. 20, no 12, pp. 1195–1198, 2013.
- [198]. J. Mairal, F. Bach, J. Ponce, and G. Sapiro and A. Zisserman, “**Discriminative learned dictionaries for local image analysis**”, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1-8, 2008.
- [199]. C. Bao et al. “**Dictionary learning for sparse coding: algorithms and convergence analysis**”, In IEEE transactions on pattern analysis and machine intelligence Vol. 38, no.7, pp. 1356–1369, 2016.
- [200]. R. Rubinstein, M. Zibulevsky, and M. Elad, “**Double sparsity, Learning sparse dictionaries for sparse signal approximation**”, IEEE Transactions on Signal Processing, Vol. 58, no. 3, pp. 1553-1564, 2010.
- [201]. J. Mairal, F. Bach, J. Ponce, and G. Sapiro, “**Online learning for matrix factorization and sparse coding**”, The journal of machine learning Research, Vol. 11, pp. 19-60, 2010.
- [202]. M. Aharon and M. Elad, “**Sparse and redundant modeling of image content using an image signature dictionary**”, SIAM Journal on Imaging Sciences, Vol. 1, no. 3, pp. 228-247, 2008.
- [203]. S. Chan Wai Tim, “**Apprentissage supervisé d’une représentation multicouches à base de dictionnaires pour la classification d’images et de vidéos**”, Traitement du signal et de l’image. Université Grenoble Alpes, France, 2016.
- [204]. K. Skretting et K. Engan, “**Recursive least squares dictionary learning algorithm**”, IEEE Trans. on Signal Processing, Vol. 58, pp. 2121–2130, 2010.
- [205]. B. Efron, T. Hastie, I. Johnstone, R. Tibshirani and others, “**Least angle regression**”, The Annals of Statistics. Vol. 32, no. 2, pp. 407–499, 2004.
- [206]. K. Engan, S.O. Aase et J.H. Husøy, “**Multi-frame compression: theory and design**”, Signal Process., Vol. 80, pp. 2121–2140, 2000.
- [207]. K. Engan, K. Skretting et J.H. Husøy, “**Family of iterative LS-based dictionary learning algorithms, ILS-DLA, for sparse signal representation**”, Digit. Signal Process., Vol. 17, pp. 32–49, 2007.
- [208]. O. Bryt and M. Elad, “**Compression of facial images using the K-SVD algorithm**”, Journal of Visual Communication and Image Representation, Vol. 19, no. 4, pp. 270-282, 2008.



- [209]. Z. Jiang, Z. Lin, and L. S. Davies, “**Learning a discriminative dictionary for sparse coding via label consistent K-SVD**”, IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 1697-1704, 2011.
- [210]. J. Zepeda Salvatierra, “**Nouvelles méthodes de représentations parcimonieuses : Application à la compression et l’indexation d’images**”, Thèse de Doctorat de l’Université de Rennes 1, Bretagne Atlantique, 2010.
- [211]. J. Zepeda, C. Guillemot, E. Kijak, et al. “**The iteration tuned dictionary for sparse representations**”, In Proc. Of the IEEE International Workshop on MMSP, 2010.
- [212]. Y. Yankelevsky and M. Elad, “**Structure-aware classification using supervised dictionary learning**”, IEEE International Conference on Acoustic, Speech and Signal Processing, pp. 4421-4425, 2017.
- [213]. Q. Zhang and B. Li, “**Discriminative K-SVD for dictionary learning in face recognition**”, in IEEE Conference on Computer Vision and Pattern Recognition, pp. 2691-2698, 2010.
- [214]. Zhihua Xie, “**Single Sample Face Recognition Based on DCT and Local Gabor Binary Pattern Histogram**”, Springer, ICIC 2013, pp.435- 442, 2013.
- [215]. S. Shan, W. Zhang, Y. Su, X. Chen and W. Gao, “**Ensemble of Piecewise FDA Based on Spatial Histograms of Local (Gabor) Binary Pattern for Face Recognition**”, IEEE 2006, The 18th International Conference on Pattern Recognition (ICPR’06), 2006.
- [216]. L. Jacques, L. Duval, C. Chaux et G. Peyre, “**A panorama on multiscale geometric representations, intertwining spatial, directional and frequency selectivity**”, Signal Process., Vol. 91, pp. 2699–2730, 2011.
- [217]. S. Mallat, “**A Wavelet Tour of signal processing**”, 3rd edition, New-York: Academic, 2009.
- [218]. Wang, Z., Bovik, A. C., Sheikh, H. R., and Simoncelli, E. P., “**Image quality assessment: from error visibility to structural similarity**”, IEEE Transactions on Image Processing, Vol. 13, no. 4, pp. 600–612, 2004.
- [219]. W. Khedr, R. Ali, F. Ismail, “**Image Denoising using K-SVD Algorithm based on Gabor Wavelet Dictionary**”, International Journal of Computer Applications (0975 – 8887), Vol. 59, no. 2, pp. 30-34, December 2012.
- [220]. E. J. Candes, L. Demanet, D. L. Donoho, and L. Ying, “**Fast discrete curvelet transforms**”, Multiscale Modeling & Simulation, vol. 5, pp. 861–899, 2006.
- [221]. N. Ahmed, T. Natarajan, and K. R. Rao, “**Discrete cosine transform**”, IEEE Trans. Comput., vol. 23, no. 1, pp. 90-93, 1974.




- [222]. J. Cooley and J. Tukey, “**An algorithm for the machine calculation of complex Fourier series**”, Mathematics of computation, Vol. 19, no. 90, pp. 297-301, 1965.
- [223]. R. Gribonval, R. Jenatton, F. Bach, M. Kleinstauber, and M. Seibert, “**Sample Complexity of Dictionary Learning and Other Matrix Factorizations**”, IEEE Trans. Inf. Theor., Vol. 61, no. 6, pp. 3469–3486, 2015.
- [224]. G. Zhang, H. Sun, Z. Ji, G. Xia, L. Feng and Q. Sun, “**Kernel dictionary learning based discriminant analysis**”, In J. Vis. Commun. Image R., Vol. 40, pp. 470-484, 2016.
- [225]. N. A. Thacker, F. J. Aherne, P. I. Rockett, “**The bhattacharyya metric as an absolute similarity measure for frequency coded data**”, 1998.
- [226]. M. Marsousi, K. Abhari, P. Babyn et J. Alirezaie. “**An Adaptive Approach to Learn Overcomplete Dictionaries with Efficient Numbers of Elements**”, IEEE Transactions on Signal Processing, Vol. 62, pp. 3272–3283, 2014.
- [227]. P. Buysens, “**Fusion de différents modes de capture pour la reconnaissance du visage appliquée aux e\_transactions**”, Thèse de Doctorat de l’Université de Caen, 2011.

## REFERENCES WEBOGRAPHIQUES

- [18]. <http://www.map.toulouse.archi.fr/works/panoformation/imagenum/imagenum.html>, 8 March 2017.
- [22]. Gabriel Peyré, <http://images.math.cnrs.fr/Le-traitement-numerique-des-images.html>, 11 November 2011.
- [43]. **Socialcompare**.com/fr/comparison /image-file formats, 24 May 2019.
- [64]. [www.crpq.cnrs-nancy.fr/Science/Collection/Magmatique/métamorphique.html](http://www.crpq.cnrs-nancy.fr/Science/Collection/Magmatique/métamorphique.html), Feb. 2016.
- [65]. [www.groupe.polymtl.ca/glq1100/roches/granite/granitehtml](http://www.groupe.polymtl.ca/glq1100/roches/granite/granitehtml), Feb. 2016

**ANNEXE A :  
GRAPHES DES CROISEMENTS ENTRE DES ROCHES (MAGMATIQUES ET  
METAMORPHIQUES)**







## ANNEXE B :

**TABLEAU 1 : EXPERIMENTATION DE COMBINAISON AVEC HI D\_ALBPCSF POUR LES DIFFERENTES ROCHES  
(MAGMATIQUES ET METAMORPHIQUES)**

Combinaison de roche											Moy ± écartype	[Min Max]
Combinaison de Schistes	14_15	14_16	14_17	14_18	15_16	15_17	15_18	16_17	16_18	17_18	0,0118±0,0047	[0,0044 0,0192]
	0,0152	0,0070	0,0072	0,0192	0,0123	0,0114	0,0096	0,0044	0,0159	0,0154		
Combinaison de Cipolin	1_2	1_3	1_5	1_6	2_3	2_5	2_6	3_5	3_6	5_6	0,0093±0,0042	[0,0050 0,0155]
	0,0139	0,0066	0,0051	0,0063	0,0155	0,0132	0,0137	0,0063	0,0071	0,0050		
Combinaison de Granite	5E_F	5E_6F	5E_A20	5E_A21	F_6F	F_A20	F_A21	6F_A20	6F_A21	A20_A21	0,0128±0,0026	[0,0087 0,0155]
	0,0150	0,0152	0,0129	0,0155	0,0092	0,0130	0,0087	0,0147	0,0097	0,0141		
Combinaison de Gabbro	3_4	3_5	3_6	3_7	4_5	4_6	4_7	5_6	5_7	6_7	0,0980±0,0521	[0,0388 0,1750]
	0,0388	0,0687	0,0627	0,1705	0,0743	0,0686	0,1750	0,0442	0,1368	0,1402		
Combinaison de Cornéenne	7_8	7_9	7_10	7_11	8_9	8_10	8_11	9_10	9_11	10_11	0,0104±0,00521	[0,0062 0,0176]
	0,0062	0,0091	0,0176	0,0073	0,0077	0,0156	0,0063	0,0135	0,0064	0,0151		
Combinaison de Granodiorite	1_2	1_3	1_4	1_5	2_3	2_4	2_5	3_4	3_5	4_5	0,0275±0,0133	[0,0086 0,0175]
	0,0175	0,0341	0,0448	0,0473	0,0223	0,0328	0,0357	0,0144	0,0172	0,0086		
Combinaison de Migmatite	15_16	15_17	15_18	15_19	16_17	16_18	16_19	17_18	17_19	18_19	0,0150±0,0051	[0,0081 0,0240]
	0,0126	0,0102	0,0226	0,0122	0,0141	0,0168	0,0081	0,0240	0,0133	0,0166		
Combinaison de Eclogite	5_6	5_9	5_11	5_12	6_9	6_11	6_12	9_11	9_12	11_12	0,0561±0,0388	[0,0198 0,1154]
	0,0198	0,0203	0,0945	0,0335	0,0241	0,0896	0,0368	0,1011	0,0256	0,1154		

**TABLEAU 2 : EXPERIMENTATION DE COMBINAISON AVEC HI\_LBP POUR LES DIFFERENTES ROCHES (MAGMATIQUES ET METAMORPHIQUES)**

Combinaison de roche											Moy ± écart type	[Min Max]
Combinaison de Schistes	14_15	14_16	14_17	14_18	15_16	15_17	15_18	16_17	16_18	17_18	0,0953±0,0325	[0,0242 0,1331]
	0,1160	0,0977	0,0950	0,0822	0,1331	0,1294	0,1200	0,0242	0,0813	0,0738		
Combinaison de Cipolin	1_2	1_3	1_5	1_6	2_3	2_5	2_6	3_5	3_6	5_6	0,2639±0,0398	[0,2016 0,3314]
	0,3314	0,2596	0,2444	0,2468	0,3003	0,2996	0,2893	0,2365	0,2300	0,2016		
Combinaison de Granite	5E_F	5E_6F	5E_A20	5E_A21	F_6F	F_A20	F_A21	6F_A20	6F_A21	A20_A21	0,1785±0,0708	[0,0550 0,2283]
	0,2200	0,1885	0,2226	0,2283	0,2222	0,0550	0,0827	0,2270	0,2402	0,0988		
Combinaison de Gabbro	3_4	3_5	3_6	3_7	4_5	4_6	4_7	5_6	5_7	6_7	0,3276±0,0362	[0,2745 0,4049]
	0,3245	0,3163	0,3159	0,4049	0,3063	0,2965	0,3597	0,2745	0,3351	0,3418		
Combinaison de Cornéenne	7_8	7_9	7_10	7_11	8_9	8_10	8_11	9_10	9_11	10_11	0,1913±0,0590	[0,1071 0,2735]
	0,1700	0,1648	0,1816	0,2091	0,1071	0,1435	0,2735	0,1359	0,2605	0,2675		
Combinaison de Granodiorite	1_2	1_3	1_4	1_5	2_3	2_4	2_5	3_4	3_5	4_5	0,0433±0,0146	[0,0250 0,0697]
	0,0579	0,0582	0,0449	0,0697	0,0250	0,0339	0,0306	0,0338	0,0301	0,0437		
Combinaison de Migmatite	15_16	15_17	15_18	15_19	16_17	16_18	16_19	17_18	17_19	18_19	0,1917±0,0288	[0,1631 0,2383]
	0,2383	0,2343	0,2214	0,1924	0,1684	0,1809	0,1757	0,1734	0,1631	0,1692		
Combinaison de Eclogite	5_6	5_9	5_11	5_12	6_9	6_11	6_12	9_11	9_12	11_12	0,3062±0,0486	[0,2365 0,4000]
	0,2365	0,2974	0,2835	0,2971	0,3367	0,2681	0,2720	0,4000	0,3644	0,3063		

**TABLEAU 3 : EXPERIMENTATION DES COMBINAISONS ENTRE ROCHES DE MEME CLASSE :**

Croisement interclasses	Valeurs des moyennes des croisements inter classes magmatiques avec HI_LBP										(moy ± écart-type)
Granite-granite	0,2200	0,1885	0,2226	0,2283	0,2222	0,0550	0,0827	0,2270	0,2402	0,0988	(0,1785±0,0708)
Granodiorite-granodiorite	0,0579	0,0582	0,0449	0,0697	0,0250	0,0339	0,0306	0,0338	0,0301	0,0437	(0,0428±0,0148)
Gabbro-gabbro	0,3245	0,3136	0,3159	0,3776	0,3063	0,2965	0,3009	0,2745	0,2701	0,2759	(0,3056±0,0315)

Croisement interclasses	Valeurs des moyennes des croisements inter classes métamorphiques avec HI_LBP										(moy± écart-type)
Schiste-schiste	0,1160	0,0977	0,0950	0,0822	0,1331	0,1294	0,1200	0,0242	0,0813	0,0738	(0,0953±0,0325)
Cipolin-cipolin	0,2596	0,2444	0,2468	0,2491	0,2365	0,2300	0,2296	0,2016	0,2197	0,2160	(0,2333±0,0175)
Cornéenne-cornéenne	0,1700	0,1648	0,1816	0,2091	0,1071	0,1435	0,2735	0,1359	0,2605	0,2675	(0,1913±0,0590)
Migmatite-migmatite	0,2383	0,2343	0,2214	0,1924	0,1684	0,1809	0,1757	0,1734	0,1631	0,1692	(0,1917±0,0288)
Eclogite-éclogite	0,2365	0,2974	0,2971	0,3247	0,3367	0,2720	0,3004	0,3644	0,4136	0,2450	(0,3088±0,0538)

Croisement interclasses	Valeurs des moyennes des croisements inter classes magmatiques avec HI_D_ALBPCSF										
Granite-granite	0,0150	0,0152	0,0129	0,0155	0,0092	0,0130	0,0087	0,0147	0,0097	0,0141	(0,0128±0,0026)

Granodiorite-granodiorite	0,0175	0,0341	0,0448	0,0473	0,0223	0,0328	0,0357	0,0114	0,0172	0,0086	(0,0272±0,0137)
Gabbro-gabbro	0,0388	0,0687	0,0627	0,0413	0,0743	0,0686	0,0455	0,0442	0,0553	0,0507	(0,0550±0,0128)

Croisement intra classes	Valeurs des moyennes des croisements inter classes métamorphiques avec HI_D_ALBPCSF										
Schiste-schiste	0,0152	0,0070	0,0072	0,0192	0,0123	0,0114	0,0096	0,0044	0,0159	0,0154	(0,0118±0,0047)
Cipolin-cipolin	0,0066	0,0051	0,0063	0,0065	0,0063	0,0071	0,0068	0,0050	0,0045	0,0062	(0,0060±0,0009)
Cornéenne-cornéenne	0,0062	0,0091	0,0176	0,0073	0,0077	0,0156	0,0063	0,0135	0,0064	0,0151	(0,0105±0,0045)
Migmatite-migmatite	0,0126	0,0102	0,0226	0,0122	0,0141	0,0168	0,0081	0,0240	0,0133	0,0166	(0,0150±0,0051)
Eclogite-éclogite	0,0198	0,0203	0,0335	0,0347	0,0241	0,0368	0,0388	0,0256	0,0281	0,0095	(0,0262±0,0103)

**TABLEAU 4 : Moyenne des croisements : Références de chaque classe de roches pour les méthodes HI\_LBP et HI\_D\_ALBPCSF**

Croisement intra classes	Moyenne HI_LBP	Moyenne HI_D_ALBPCSF
Granite-granite	0,1785	0,0128
Granodiorite-granodiorite	0,0433	0,0275
Gabbro-gabbro	0,3056	0,0550
Schiste-schiste	0,0953	0,0118
Cipolin-cipolin	0,2333	0,0062
Cornéenne-cornéenne	0,1913	0,0105
Migmatite-migmatite	0,1917	0,0150
Eclogite-éclogite	0,3088	0,0262

## ANNEXE C :

TABLEAU : CROISEMENT INTER-ROCHES MAGMATIQUES ET METAMORPHIQUES (avec Khi 2)

Roches	Schiste14	Granite5E	Cipolin1	Eclogite5	Granodiorite1	Migmatite15	Gabbro3	Cornéenne7	Méthodes
Schiste14	0	0,0075	0,0055	0,0072	0,0078	0,0055	0,0076	0,0078	$\chi^2$ ImagRGB
	0	0,0014	0,0032	0,0024	0,0015	0,0012	0,0033	0,0021	$\chi^2$ LBP
	0	0,0042	0,0052	0,0047	0,0059	0,0020	0,0048	0,0059	$\chi^2$ ALBPCSF
	0	$1,0578 \cdot 10^{-4}$	$0,3601 \cdot 10^{-4}$	$1,3227 \cdot 10^{-4}$	$4,5382 \cdot 10^{-4}$	$0,7310 \cdot 10^{-4}$	$5,1891 \cdot 10^{-4}$	$0,3009 \cdot 10^{-4}$	$\chi^2$ D_ALBPCSF
	0	0,0013	0,0056	0,0046	0,0060	0,0030	0,0058	0,0032	$\chi^2$ G_ALBPCSF
Granite5E	0,0075	0	0,0076	0,0075	0,0067	0,0066	0,0071	0,0055	$\chi^2$ ImagRGB
	0,0014	0	0,0019	0,0013	0,0013	$9,8761 \cdot 10^{-4}$	0,0022	$9,8765 \cdot 10^{-4}$	$\chi^2$ LBP
	0,0042	0	0,0067	0,0054	0,0035	0,0041	0,0048	0,0029	$\chi^2$ ALBPCSF
	$1,0578 \cdot 10^{-4}$	0	$1,1878 \cdot 10^{-4}$	$1,0516 \cdot 10^{-4}$	$3,1672 \cdot 10^{-4}$	$0,6239 \cdot 10^{-4}$	$3,5249 \cdot 10^{-4}$	$1,1802 \cdot 10^{-4}$	$\chi^2$ D_ALBPCSF
	0,0013	0	0,0054	0,0045	0,0060	0,0026	0,0052	0,0032	$\chi^2$ G_ALBPCSF
Cipolin1	0,0055	0,0076	0	0,0075	0,0078	0,0041	0,0077	0,0077	$\chi^2$ ImagRGB
	0,0032	0,0019	0	0,0017	0,0029	0,0018	0,0021	0,0016	$\chi^2$ LBP
	0,0052	0,0067	0	0,0048	0,0077	0,0042	0,0059	0,0075	$\chi^2$ ALBPCSF
	$0,3601 \cdot 10^{-4}$	$1,1878 \cdot 10^{-4}$	0	$1,4023 \cdot 10^{-4}$	$4,9517 \cdot 10^{-4}$	$0,8955 \cdot 10^{-4}$	$5,3469 \cdot 10^{-4}$	$0,3076 \cdot 10^{-4}$	$\chi^2$ D_ALBPCSF
	0,0056	0,0054	0	0,0039	0,0080	0,0040	0,0040	0,0041	$\chi^2$ G_ALBPCSF
Eclogite5	0,0072	0,0075	0,0075	0	0,0078	0,0075	0,0074	0,0078	$\chi^2$ ImagRGB
	0,0024	0,0013	0,0017	0	0,0023	0,0015	0,0019	0,0014	$\chi^2$ LBP
	0,0047	0,0054	0,0048	0	0,0071	0,0044	0,0041	0,0066	$\chi^2$ ALBPCSF
	$1,327 \cdot 10^{-4}$	$1,0516 \cdot 10^{-4}$	$1,4023 \cdot 10^{-4}$	0	$4,2990 \cdot 10^{-4}$	$1,0300 \cdot 10^{-4}$	$3,4420 \cdot 10^{-4}$	$1,4412 \cdot 10^{-4}$	$\chi^2$ D_ALBPCSF
	0,0046	0,0045	0,0039	0	0,0079	0,0031	0,0043	0,0032	$\chi^2$ G_ALBPCSF
Granodiorite1	0,0078	0,0067	0,0078	0,0078	0	0,0078	0,0078	0,0073	$\chi^2$ ImagRGB
	0,0015	0,0013	0,0029	0,0023	0	0,0014	0,0035	0,0013	$\chi^2$ LBP
	0,0059	0,0035	0,0077	0,0071	0	0,0059	0,0065	0,0041	$\chi^2$ ALBPCSF
	$4,5382 \cdot 10^{-4}$	$3,1672 \cdot 10^{-4}$	$4,9517 \cdot 10^{-4}$	$4,2990 \cdot 10^{-4}$	0	$3,2426 \cdot 10^{-4}$	$4,4300 \cdot 10^{-4}$	$4,8631 \cdot 10^{-4}$	$\chi^2$ D_ALBPCSF
	0,0060	0,0060	0,0080	0,0079	0	0,0077	0,0080	0,0076	$\chi^2$ G_ALBPCSF
Migmatite15	0,0055	0,0066	0,0041	0,0075	0,0078	0	0,0072	0,0074	$\chi^2$ ImagRGB

	0,0012	9,876110 <sup>-4</sup>	0,0018	0,0015	0,0014	0	0,0023	0,0011	$\chi^2$ LBP
	0,0020	0,0041	0,0042	0,0044	0,0059	0	0,0051	0,0057	$\chi^2$ _ALBPCSF
	0,7310.10 <sup>-4</sup>	0,6239.10 <sup>-4</sup>	0,8955.10 <sup>-4</sup>	1,0300.10 <sup>-4</sup>	3,2426.10 <sup>-4</sup>	0	3,8955.10 <sup>-4</sup>	0,8798.10 <sup>-4</sup>	$\chi^2$ _D_ALBPCSF
	0,0030	0,0026	0,0040	0,0031	0,0077	0	0,0041	0,0024	$\chi^2$ _G_ALBPCSF
Gabbro3	0,0076	0,0071	0,0077	0,0074	0,0078	0,0072	0	0,0078	$\chi^2$ ImagRGB
	0,0033	0,0022	0,0021	0,0019	0,0035	0,0023	0	0,0021	$\chi^2$ _LBP
	0,0048	0,0048	0,0059	0,0041	0,0065	0,0051	0	0,0059	$\chi^2$ _ALBPCSF
	5,1891.10 <sup>-4</sup>	3,5249.10 <sup>-4</sup>	5,3469.10 <sup>-4</sup>	3,4420.10 <sup>-4</sup>	4,4300.10 <sup>-4</sup>	3,8955.10 <sup>-4</sup>	0	5,3979.10 <sup>-4</sup>	$\chi^2$ _D_ALBPCSF
	0,0058	0,0052	0,0040	0,0043	0,0080	0,0041	0	0,0047	$\chi^2$ _G_ALBPCSF
Cornéenne7	0,0078	0,0055	0,0077	0,0078	0,0073	0,0074	0,0078	0	$\chi^2$ ImagRGB
	0,0021	9,8765.10 <sup>-4</sup>	0,0016	0,0014	0,0013	0,0011	0,0021	0	$\chi^2$ _LBP
	0,0059	0,0029	0,0075	0,0066	0,0041	0,0057	0,0059	0	$\chi^2$ _ALBPCSF
	0,3087.10 <sup>-4</sup>	1,1802.10 <sup>-4</sup>	0,3076.10 <sup>-4</sup>	1,4412.10 <sup>-4</sup>	4,8631.10 <sup>-4</sup>	0,8798.10 <sup>-4</sup>	5,3979.10 <sup>-4</sup>	0	$\chi^2$ _D_ALBPCSF
	0,0032	0,0032	0,0041	0,0032	0,0076	0,0024	0,0047	0	$\chi^2$ _G_ALBPCSF

**TABLEAU : CROISEMENT INTER-ROCHES MAGMATIQUES ET METAMORPHIQUES (avec HI)**

Roches	Schiste14	Granite5E	Cipolin1	Eclogite5	Granodiorite1	Migmatite15	Gabbro3	Cornéenne7	Méthodes
Schiste14	0	0,9643	0,7937	0,9379	0,9999	0,7918	0,9814	0,9944	HI_ImagRGB
	0	0,3444	0,5765	0,4838	0,3653	0,3150	0,5800	0,4555	HI_LBP
	0	0,6550	0,7589	0,7056	0,8379	0,3911	0,7135	0,8222	HI_ALBPCSF
	0	0,0348	0,0069	0,0409	0,1211	0,0246	0,1395	0,0079	HI_D_ALBPCSF

	0	0,2939	0,7814	0,6904	0,8552	0,5228	0,8010	0,5442	HI_G_ALBPCSF
Granite5E	0,9643	0	0,9797	0,9660	0,9184	0,8883	0,9254	0,7881	HI_ImagRGB
	0,3444	0	0,3970	0,2931	0,2873	0,2431	0,4386	0,2570	HI_LBP
	0,6550	0	0,9042	0,7721	0,6019	0,6566	0,7237	0,4900	HI_ALBPCSF
	0,0348	0	0,0364	0,0219	0,0989	0,0176	0,1114	0,0377	HI_D_ALBPCSF
	0,2939	0	0,7643	0,6779	0,8482	0,4849	0,7495	0,5429	HI_G_ALBPCSF
Cipolin1	0,7937	0,9797	0	0,9732	1	0,6301	0,9874	0,9924	HI_ImagRGB
	0,5765	0,3970	0	0,3312	0,5254	0,3858	0,3833	0,3419	HI_LBP
	0,7589	0,9042	0	0,7227	0,9851	0,6574	0,8238	0,9718	HI_ALBPCSF
	0,0069	0,0364	0	0,0413	0,1248	0,0275	0,1400	0,0073	HI_D_ALBPCSF
	0,7814	0,7643	0	0,5773	0,9947	0,6150	0,5951	0,6205	HI_G_ALBPCSF
Eclogite5	0,9379	0,9660	0,9732	0	0,9999	0,9717	0,9527	0,9961	HI_ImagRGB
	0,4838	0,2931	0,3312	0	0,4476	0,3138	0,3606	0,2964	HI_LBP
	0,7056	0,7721	0,7227	0	0,9474	0,6811	0,6226	0,8944	HI_ALBPCSF
	0,0409	0,0219	0,0413	0	0,1080	0,0249	0,1095	0,0439	HI_D_ALBPCSF
	0,6904	0,6779	0,5773	0	0,9897	0,5230	0,6340	0,5197	HI_G_ALBPCSF
Granodiorite 1	0,9999	0,9184	1	0,9999	0	1	0,9972	0,9960	HI_ImagRGB
	0,3653	0,2873	0,5254	0,4476	0	0,3062	0,6116	0,2719	HI_LBP
	0,8379	0,6019	0,9851	0,9474	0	0,8519	0,9020	0,6619	HI_ALBPCSF
	0,1211	0,0989	0,1248	0,1080	0	0,1035	0,0872	0,1250	HI_D_ALBPCSF

	0,8552	0,8482	0,9947	0,9897	0	0,9743	0,9938	0,9713	HI_G_ALBPCSF
Migmatite15	0,7918	0,8883	0,6301	0,9717	1	0	0,9437	0,9669	HI_ImagRGB
	0,3150	0,2431	0,3858	0,3138	0,3062	0	0,4414	0,2824	HI_LBP
	0,3911	0,6566	0,6574	0,6811	0,8519	0	0,7397	0,8065	HI_ALBPCSF
	0,0246	0,0176	0,0275	0,0249	0,1035	0	0,1190	0,0286	HI_D_ALBPCSF
	0,5228	0,4849	0,6150	0,5230	0,9743	0	0,6256	0,4313	HI_G_ALBPCSF
Gabbro3	0,9814	0,9254	0,9874	0,9527	0,9972	0,9437	0	0,9950	HI_ImagRGB
	0,5800	0,4386	0,3833	0,3606	0,6116	0,4414	0	0,4239	HI_LBP
	0,7135	0,7237	0,8238	0,6226	0,9020	0,7397	0	0,8343	HI_ALBPCSF
	0,1395	0,1114	0,1400	0,1095	0,0872	0,1190	0	0,1429	HI_D_ALBPCSF
	0,8010	0,7495	0,5951	0,6340	0,9938	0,6256	0	0,6828	HI_G_ALBPCSF
Cornéenne7	0,9944	0,7881	0,9924	0,9961	0,9960	0,9669	0,9950	0	HI_ImagRGB
	0,4555	0,2570	0,3419	0,2964	0,2719	0,2824	0,4239	0	HI_LBP
	0,8222	0,4900	0,9718	0,8944	0,6619	0,8065	0,8343	0	HI_ALBPCSF
	0,0079	0,0377	0,0073	0,0439	0,1250	0,0286	0,1429	0	HI_D_ALBPCSF
	0,5442	0,5429	0,6205	0,5197	0,9713	0,4313	0,6828	0	HI_G_ALBPCSF