

THESE

En vue de l'obtention du : **DOCTORAT**

Structure de Recherche : Laboratoire de Recherche en Informatique et
Télécommunications

Discipline : Sciences de l'ingénieur

Spécialité : Informatique et Télécommunications

Présentée et soutenue le 17/09/2022 par :

Ibtissam AL SAIDI

**Machine Learning appliquée à l'analyse de données texturées en se basant
sur les motifs binaires locaux**

JURY

Mohammed EL HASSOUNI	PES, Université Mohammed V, Faculté des Lettres et des Sciences Humaines - Rabat	Président
Fatima GUEROUATE	PH, Université Mohammed V, Ecole Supérieur de Technologie - Salé	Rapporteur/examineur
Ghizlane ORHANO	PH, Université Mohammed V, Faculté des Sciences - Rabat	Rapporteur/examineur
El Houssaine ZIYATI	PES, Université Hassane II, Ecole Supérieur de Technologie - Casablanca	Rapporteur/examineur
Johan DEBAYLE	PES, Ecole des Mines de Saint-Etienne, SAINT-ETIENNE - France	Examineur
Mohammed RZIZA	PES, Université Mohammed V, Faculté des Sciences - Rabat	Directeur de Thèse

Année Universitaire : 2021-2022

*Au nom du dieu le clément et le miséricordieux
louange à ALLAH le tout puissant*

*Je dédie ce modeste travail en signe de respect,
reconnaissance et de remerciement :*

*A mes chers parents, qui m'ont
aidé de près et de loin.*

A mon cher frère Mohamed



REMERCIEMENT

En tout premier lieu, je remercie le bon Dieu, le Tout-Puissant, le plus grand de tous, dont nous dépendons en fin de compte pour notre subsistance et nos conseils, de m'avoir donné la force pour survivre, ainsi que l'audace pour dépasser toutes les difficultés

Les travaux présentés dans ce manuscrit ont été réalisés au sein du laboratoire de Recherche en Informatique et Télécommunications (LRIT) à la Faculté des Sciences de Rabat.

C'est avec la plus profonde gratitude que je souhaite adresser mes plus vifs remerciements à mon encadrant et directeur de thèse M. **Mohammed RZIZA**, professeur d'enseignement supérieur, à la Faculté des Sciences de Rabat. Je remercie ici sa très grande disponibilité, sa gentillesse, sa patience, ses nombreuses discussions et conseils toujours pertinents, le temps passé à m'avoir fait partager ses connaissances scientifiques et son expérience ainsi que la confiance qu'il m'a accordée tout au long de cette thèse.

Je tiens à remercier particulièrement M. **Johan DEBAYLE**, professeur d'enseignement supérieur, à l'École des Mines de Saint-Étienne, France, pour sa collaboration à tous mes travaux, pour le temps passé à m'avoir fait partager ses connaissances scientifiques et son expérience au cours de mes recherches ainsi que pour son humanité et sa gentillesse.

Je voudrais aussi remercier M. **Mohammed EL HASSOUNI**, professeur d'enseignement supérieur, à la Faculté des Lettres et des Sciences Humaines de Rabat, de m'avoir fait l'honneur de présider mon jury de thèse.

Je suis, également, particulièrement reconnaissante aux membres du jury pour l'intérêt qu'ils ont porté à ce travail. Mes sincères remerciements s'adressent à Mme **Fatima GUEROUATE**, professeur habilité à l'École Supérieur de Technologie de Salé. Je voudrais adresser mes plus vifs remerciements à M. **El Houssaine ZIYATI**, professeur habilité à l'École Supérieur de Technologie de Casablanca, et Mme **Ghizlane ORHANO**, professeur habilité à la Faculté des Sciences Rabat, pour avoir accepté la lourde tâche d'être les rapporteurs de ce mémoire.

Je voudrais aussi remercier les membres du laboratoire LRIT, c'était un immense plaisir de les côtoyer et de faire leur connaissance. Ma pensée se tourne également vers mes collègues et mes amis sans qui ces années de travail auraient été bien ternes.

Je garde le meilleur pour la fin. Mes plus profonds remerciements vont à mes très chers parents qui m'ont toujours encouragé et soutenu dans mes choix, rien au monde ne pourrait compenser tout ce qu'ils ont fait pour moi et nul mot ne saurait exprimer mes sentiments de gratitude, d'amour et de respect. À mon frère pour leur motivation inoxydable, leur humour et leur soutien essentiels.



RÉSUMÉ

La texture, en tant que caractéristique importante, peut représenter une large étendue de la surface d'un objet, et comprend la taille, l'éclairage, la forme et certaines autres caractéristiques physiques ou naturelles. Le principal inconvénient est que les textures dans le monde réel ne sont pas uniformes en raison de variations de direction, d'échelle ou d'apparence visuelle distincte. Le problème central de la classification des textures est de traiter les modifications de l'apparence des textures pour construire une représentation des textures robuste et discriminante. Local binary pattern (LBP) est devenu l'un des descripteurs de texture locale le plus remarquable et le plus largement examiné. La simplicité, la robustesse et la rapidité de ce calcul a attiré l'attention des chercheurs souhaitant créer leurs propres opérateurs locaux en développant d'autres variantes. Cependant, comme il n'utilise que des informations de signe dans la région locale, le LBP est inefficace pour capturer les caractéristiques discriminatoires.

La principale contribution de cette thèse est l'introduction de nouvelles variantes de LBP qui nous permettent de surmonter ses limitations initiales et d'obtenir plus de relations entre les voisins, les pixels centraux et les voisins avec les pixels centraux. La première extension nommée «*homogeneous LBP*» (HLBP), permet l'analyse de texture. Elle est générée en utilisant le critère d'homogénéité, qui permet de représenter une caractéristique significative fondée sur des relations entre pixels voisins. Une autre extension est proposée, nommée «*homogenous rotated*» LBP (HRLBP), qui vise à améliorer le côté invariant de rotation de HLBP en utilisant une variante robuste de LBP appelée *rotated LBP*» (RLBP). La troisième variante de LBP est une version améliorée du HLBP, destinée à la caractérisation de la texture dans le cadre de la classification par télédétection (*remote sensing* (RS)) et est connue sous le nom de «*completed HLBP*» (CHLBP). Les quatre et cinq variantes proposées de LBP sont connues respectivement sous le nom de «*circular parts LBP*» (CPLBP) et «*corner rhombus shape LBP*» (CRSLBP). CPLBP vise à améliorer LBP en étendant la zone de voisinage d'un à une région de voisins à l'aide de coordonnées polaires. Tandis que l'approche CRSLBP vise à traiter non seulement la relation entre les voisins et le centre des pixels, mais également la relation entre le centre et le voisin des pixels centraux du voisinage, en sélectionnant une région de bloc paire qui nous permet d'obtenir plus de pixels centraux. Nous évaluons les performances de nos descripteurs (HLBP, HRLBP, CHLBP CPLBP et CRSLBP) à l'aide de sept bases de données de texture complexes : *Outex TC10*, *Outex TC12*, *Brodatz*, *KTH-TIPSb2*, et *UMD*, *Gaofen Image Dataset* (GID), et *large-scale aerial* (AID). Diverses expériences approfondies ont été réalisées qui ont démontré l'efficacité et la robustesse de tous nos descripteurs par rapport à l'état de l'art disponible, contre l'état de bruit libre, et CHLBP est également contre l'état de bruit dans les ensembles de données RS de la scène publique.

Mots-clés : extraction des caractéristiques, *local binary pattern* (LBP), classification de la texture, la télédétection.



ABSTRACT

Texture, as an important characteristic, can represent a large extent of an object's surface, and includes size, lighting, shape, and some other physical or natural characteristics. The main drawback is that real-world textures are not uniform due to variations in direction, scale, or distinct visual appearance. The central problem of texture classification is to process changes in texture appearance to build a robust and discriminating texture representation. Local binary pattern (LBP) has become one of the most notable and widely examined local texture descriptors. The simplicity, robustness and speed of this computation has attracted the attention of researchers wishing to create their own local operators by developing other variants. However, since it only uses sign information in the local region, the LBP is inefficient in capturing discriminatory features.

The main contribution of this thesis is the introduction of new variants of LBP that allow us to overcome its initial limitations and to obtain more relations between neighbors, central pixels, and neighbors with central pixels. The first extension, named homogeneous LBP (HLBP), allows texture analysis. It is generated using the homogeneity criterion, which makes it possible to represent a significant characteristic based on relations between neighboring pixels. Another extension is proposed, named "homogenous rotated" LBP (HRLBP), which aims to improve the rotation invariant side of HLBP by using a robust variant of LBP called "rotated LBP" (RLBP). The third variant of LBP is an improved version of HLBP, intended for characterization of texture in the context of classification by remote sensing (RS) and is known as "completed HLBP" (CHLBP). The four and five proposed variants of LBP are known respectively as "circular parts LBP" (CPLBP) and "corner rhombus shape LBP" (CRSLBP). CPLBP aims to improve LBP by extending the neighborhood area from one to a region of neighbors using polar coordinates. While the CRSLBP approach aims to address not only the relationship between the neighbors and the center of the pixels but also the relationship between the center and the neighbor of the central pixels of the neighborhood, by selecting an even block region that allows us to get more central pixels. We evaluate the performance of our descriptors (HLBP, HRLBP, CHLBP, CPLBP, and CRSLBP) using several complex texture databases : Outex TC10 (HLBP, HRLBP, CHLBP, CPLBP, and CRSLBP), Outex TC12 (CHLBP, CPLBP, and CRSLBP), Brodatz (CRSLBP), KTH-TIPSB2 (CRSLBP), and UMD (CRSLBP), Gaofen Image Dataset (GID) (CHLBP), and large-scale aerial (AID) (CHLBP). Various extensive experiments were performed, which demonstrated the efficiency and robustness of all our descriptors against the available state of the art, against the free noise state, and CHLBP against the noise state in public scene RS datasets.

Keywords : feature extraction, local binary pattern (LBP), texture classification, remote sensing



TABLE DES MATIÈRES

AVANT-PROPOS	iii
Résumé	iv
Abstract	v
Liste des notations et abréviations	ix
Liste des figures	xiii
Liste des tableaux	1
Introduction générale	1
Chapitre 1 : Techniques d'analyse de la texture	8
1.1 Introduction	9
1.2 La notion de la texture	9
1.3 Problèmes d'analyse de texture et de ses applications	12
1.3.1 Classification de texture	15
1.3.2 Segmentation de la texture	17
1.3.3 Détermination d'une forme par la texture	19
1.3.4 Synthèse de texture	19
1.3.5 Récupération de textures	20
1.4 Les méthodes d'analyse de la texture	21
1.4.1 Approches statistiques	21
1.4.2 Approches structurelles ou géométriques	24
1.4.3 Approches Fréquentielles ou spectrales	24
1.4.4 Approches basées sur les modèles	26
1.4.5 Approches hybrides	27
1.5 Un brève historique sur les descripteurs locaux de la texture	27
1.6 Les bases de données d'images de la texture	31
1.6.1 <i>OUTEX</i>	32
1.6.2 <i>KTH-TIPS2-b</i>	33
1.6.3 <i>Brodatz</i>	34
1.6.4 <i>UMD</i>	35

1.6.5	<i>GID</i>	35
1.6.6	<i>AID</i>	35
1.7	Conclusion	36
Chapitre 2 : Les différentes méthodes de l'analyse de la texture par LBP . . .		38
2.1	Introduction	39
2.2	La méthode (LBP) de base	39
2.3	Mapping LBP	42
2.3.1	Modèle LBP uniforme $LBP_{R,P}^{u2}$	43
2.3.2	Modèle LBP invariant à la rotation $LBP_{R,P}^{ri}$	44
2.3.3	Modèle LBP uniforme et invariant à la rotation $LBP_{R,P}^{riu2}$	45
2.4	Multi-échelles LBP	47
2.5	Les variantes du LBP	47
2.5.1	topologie de voisinage et échantillonnage	48
2.5.2	seuillage	52
2.5.3	codage et regroupement	56
2.5.4	combinaison avec d'autres approches	59
2.6	Classification de la texture	62
2.6.1	k-Plus Proches Voisins	63
2.6.2	Machine à Vecteurs de Support	65
2.6.3	Réseaux de Neurones	67
2.6.4	Techniques d'évaluation de la performance d'un système de classification	68
2.6.4.1	Validation croisée	69
2.6.4.2	Validation croisée en k parties	69
2.6.4.3	Leave-one-out	71
2.6.4.4	Hold-out	71
2.6.4.5	Mesures Quantitatives	71
2.7	Conclusion	74
Chapitre 3 : les variantes de LBP en utilisant l'homogénéité		76
3.1	Introduction	77
3.2	<i>Homogeneous local binary pattern</i> (HLBP)	77
3.2.1	Le principe du descripteur HLBP	79
3.2.2	Résultats expérimentaux	80
3.2.2.1	Procédure expérimentale	80
3.2.2.2	Étude expérimentale 1 : performance sur l'invariance à la rotation et à l'échelle	81
3.2.2.3	Étude expérimentale 2 : amélioration HLBP en comparant avec LBP	81
3.2.3	Discussion	83
3.3	<i>Homogeneous rotated local binary pattern</i> (HRLBP)	84
3.3.1	Le principe du descripteur (HRLBP)	85
3.3.2	Résultats expérimentaux	87
3.3.2.1	Le choix des paramètres	87
3.3.2.2	Étude expérimentale 1 : évaluer la robustesse dans la variation de rotation	87

3.3.2.3	Étude expérimentale 2 : renforcer HRLBP en comparant avec LBP	89
3.3.3	Discussion	89
3.4	<i>Completed homogeneous</i> LBP (CHLBP) pour la classification des images de télé-détection	90
3.4.1	Le principe de la méthode CHLBP	91
3.4.2	Analyse expérimentale	93
3.4.2.1	Données et zone étudiée	93
3.4.2.2	Résultats expérimentaux sur la base de données <i>Outex</i>	94
3.4.2.3	Résultats expérimentaux sur la base de données <i>GID</i> et <i>AID</i> RS	96
3.4.3	Conclusion	98
Chapitre 4 : Circular Parts Local Binary Pattern (CPLBP)		100
4.1	Introduction	100
4.2	Le principe de la méthode CPLBP	101
4.3	Résultats expérimentaux	102
4.3.1	Procédure expérimentale	103
4.3.2	Étude expérimentale 1 : évaluation du CPLBP dans la variation du rayon R	103
4.3.3	Étude expérimentale 2 : évaluation la variation de l'angle du CPLBP	107
4.4	Conclusion	111
Chapitre 5 : Corner Rhombus Shape LBP (CRSLBP)		113
5.1	Introduction	113
5.2	Motivation de recherche pour l'approche CSRLBP	114
5.3	Le principe du CRSLBP	115
5.4	Résultats des expériences	121
5.4.1	Ensembles de données de texture	121
5.4.2	Résultats expérimentaux avec la base de données <i>Outex</i>	123
5.4.3	Résultats expérimentaux avec la base de données <i>KTH-TIPS2b</i>	124
5.4.4	Résultats expérimentaux avec la base de données <i>UMD</i>	125
5.4.5	Résultats expérimentaux avec la base de données <i>Brodatz</i>	126
5.5	Discussion	126
5.5.1	Résultats expérimentaux du CRSLBP avec MRELBP	127
5.6	Conclusion	128
Conclusion générale		129
Liste de publications		133
Bibliographie		134



LISTE DES NOTATIONS ET ABRÉVIATIONS

2D :	deux dimensions
3D :	trois dimensions
ACC :	Accuracy
ACPS :	adaptive center pixel selection
ACS-LBP :	Attractive Center-Symmetric Local Binary Patterns
AID :	large-scale aerial
ALBP :	adaptative LBP
ALG :	Average Local Gray Level
BRINT :	Binary Rotation Invariant and Noise Tolerant
CBIR :	Content-based image retrieval
CDF :	cumulative distribution function
CHLBP :	Completed Homogenous Local Binary Pattern
CLBP :	Completed Local Binary Pattern
CLSP :	Completed local shrinkage pattern
CoA-LBP :	Co-occurrence of Adjacent LBP
CPLBP :	Circular Parts Local Binary Pattern
CRSLBP :	Corner Rhombus Shape Local Binary Pattern
CURet :	Columbia-Utrecht Re?ectance and Texture
CV :	cross validation
DI-LBP :	Discriminative Robust Local Binary Pattern
DLBP :	Dominant Local Binary Pattern
DRLBP :	Dominant Rotated Local Binary Patterns
DTD :	Describable Textures Dataset
EBP :	Elliptical Binary Pattern
ELBP :	Extended LBP
FLBP :	Fuzzy LBP
FNR :	False Negative Rate
FPR :	False Positif Rate
GAN :	General Adaptative Neighborhood
GID :	Gaofen Image Dataset
GLCM :	Gray level co-occurence matrix
GLRLM :	Grey Level Run Length Matrix
GW :	Gabor wavelets
HEP :	histogramme de motifs équivalents
HRLBP :	Homogenous Rotated Local Binary Pattern
HLBP :	Homogenous Local Binary Pattern

HOG :	Histograms of oriented gradients
HRRS :	high spatial-resolution remote sensing
ILBP :	Improved Local Binary Patterns
ILTP :	Improved Local Ternary Pattern
KTH-TIPS2-b :	KTH-Textures under varying Illumination, Pose and Scale
LBP :	Local Binary Pattern
LBPV :	LBP variance
LDSMT :	local difference sign-magnitude transform
LDT :	local distribution transform
LTP :	Local Ternary Pattern
LSE :	least square estimation
MB-LBP :	Multiscale Block LBP
MBP :	Median Binary pattern
MLD-CBP :	Multi Level Directional Cross Binary Patterns
MLP :	Multi-Layer Perceptron
MRELBP :	Median Robust Extended LBP
MRF :	Markov Random Fields
NPV :	Negative Predictive Value
NRLBP :	Noise-Resistant Local Binary Pattern
OSLTP :	Orthogonal Symmetric LTP
PREC :	précision
RCS-LBP :	Repulsive Center-Symmetric Local Binary Patterns
R-LBP :	Robust local binary pattern
RLBP :	Rotated Local Binary Pattern
RMLBP :	Radial mean LBP
RN :	réseaux de neurones
RS :	Remote Sensing
SIFT :	scale invariant feature transformation
SILTP :	scale invariant LTP
SSELBP :	scale selective extended LBP
SVM :	Support Vector Machines
SURF :	Speeded Up Robust Features
TNR :	True Negative Rate
TN :	True Negative
TP :	True Positive
TPR :	True Positive Rate
TS :	Texture Spectrum
UIUC :	Université de Illinois dans Urbana-Champaign
UMD :	University of Maryland, College Park
UTGLBP :	Uniformly sampled Thresholds for General LBP
WLG :	Weighted Local Grey Level

TABLE DES FIGURES

1.1	Exemple des différents textures.	10
1.2	Deux images avec les mêmes statistiques de second ordre : (a) Le texture ne peut pas être différencié par l'œil humain, (b) les trois régions sont immédiatement discriminées par l'œil humain.	11
1.3	Le processus de base de la classification des textures.	13
1.4	Exemple de la classification des textures.	16
1.5	Exemple de la segmentation des textures.	18
1.6	Le problème de synthèse de texture : étant donné les textures cibles à gauche, la tâche consiste à synthétiser des images de sortie similaires, mais pas identiques, telles que celles de droite.	20
1.7	Revue globale sur les méthodes d'analyse de la texture.	22
1.8	Quelques exemples d'images de la base de données <i>Brodatz</i> et 24 échantillons de classe de la base de données <i>Outex</i>	33
1.9	Exemples de classes d'images de la base de données <i>KTH-TIPS2b</i> et 25 exemples de classes des bases de données <i>UMD</i>	34
1.10	Quelques exemples d'images de la base de données <i>GID</i> Tong et al. [2020].	36
1.11	Quelques exemples d'images de chaque classe de la base de données <i>AID</i>	36
2.1	Illustration du calcul des motifs LBP	40
2.2	La formulation circulaire du LBP	41
2.3	Textures particulières détectées par LBP^{u2} . Mäenpää and Pietikäinen [2005]	43
2.4	Le modèle LBP invariant à la rotation.	45
2.5	Les 10 modèles uniformes et invariants en rotation définis pour $P=8$. Les cercles noirs et les cercles blancs correspondent respectivement à la valeur binaire 0 et 1 dans le code LBP	46
2.6	Topologies de voisinage des variantes LBP Liu et al. [2017].	48
2.7	Illustration du CLBP.	50
2.8	Illustration du MB-LBP Zhang et al. [2007].	52
2.9	Illustration du TPLBP et FPLBP.	52
2.10	Illustration du ILBP.	53
2.11	Illustration du LTP.	55
2.12	Illustration du RLBP.	58
2.13	Exemple de fonctionnement du classifieur k-NN pour $k=6$ (a) et $k=14$ (b). Trois classes sont considérées et représentées respectivement en bleu ($y=1$), en noir ($y=2$) et en blanc ($y=3$).	64

2.14	Vecteurs de support et l'optimal hyperplan pour une classification binaire et des données linéairement séparables Do [2020].	65
2.15	Un exemple de SVM pour des données non linéairement séparables avec l'astuce du noyau ϕ	66
2.16	Structure d'un neurone artificiel.	68
2.17	Exemple de 5 fold validation croisée.	70
3.1	Exemple du HLBP de (P=8,R=1) et m=15.	80
3.2	Exemple d'images HLBP employant différents paramètres.	83
3.3	Exemple de HRLBP de (N=8,R=1) et h=20.	86
3.4	L'histogramme proposé de CHLBP utilisant la concaténation de quatre descripteurs d'histogramme.	94
3.5	Précision moyenne sous différents types et niveaux de bruit (a,b,c) et matrice de confusion (d) sur GID cinq catégories	99
4.1	Le principe du CPLBP (P=8,R=3).	103
4.2	La performance du CPLBP en fonction de la variation du rayon en utilisant (a) Outex_TC_0010 (b) Outex_TC_0012 t184 et l'horizon.	106
4.3	Les performances du CPLBP (selon la moyenne des différents rayons) par rapport aux méthodes de l'état de l'art.	108
4.4	La performance du CPLBP selon la variation θ en utilisant (a) <i>Outex_TC_10</i> (b) <i>Outex_TC_12 t184</i> et <i>horizon</i>	109
4.5	La performance du CPLBP selon la moyenne de la variation θ des méthodes de l'état de l'art	111
5.1	Un exemple de bloc 4×4 de CRSLBP.	116
5.2	(a) Les pixels voisins en forme de losange (b) Le pixel maximum de chaque seuil de nervure par le centre avec la même couleur. (c) Les quatre premiers codes binaires de CRSLBP.	116
5.3	(a) Les pixels voisins en forme de losange. (b) Pixel maximum de chaque nervure. (c) Calcul de la valeur C. (d) En soustrayant les valeurs maximales de pixel et de centre. (e) Le deuxième code à quatre binaires de CRSLBP.	117
5.4	(a) Les pixels voisins en forme de losange. (b) Rapport de tous les deux pixels. (c) Le troisième groupe de quatre codes binaires de CRSLBP.	117
5.5	Le bloc formel de CRSLBP.	118
5.6	(a) Le sous-bloc 4×4 de l'image. (b) Le traitement des coins. Le processus du premier (b), du deuxième (c) et du troisième (d) a généré le code CRSLBP.	118
5.7	L'histogramme de concaténation de tous les processus de CRSLBP.	121



LISTE DES TABLEAUX

1.1	Principaux attributs texturaux dérivés des matrices de co-occurrences	23
1.2	Principaux approximations informatiques des propriétés visuelles de la texture	25
2.1	Exemples de noyaux SVM appliqués aux points (x_i, y_i)	67
2.2	Matrice de confusion.	72
3.1	Taux de la classification (%) du descripteur HLBP et HLBP+LBP pour différentes valeurs de rayon R en utilisant <i>Outex-TC-10</i> comme base de données.	82
3.2	Taux de la classification (%) du descripteur HRLBP et HRLBP+RLBP pour différentes valeurs de rayon R et d'homogénéité h sur la base de données <i>Outex-TC-10</i>	88
3.3	TAUX DE CLASSIFICATION (%) DU CHLBP POUR DIFFÉRENTS RAYONS ET VOISINS SUR <i>Outex (TC10 et TC12)</i> ET LE CLASSIFICATEUR SVM.	95
3.4	TAUX DE CLASSIFICATION (%) DU CHLBP POUR DIFFÉRENTS RAYONS ET VOISINS SUR <i>Outex (TC10 ET TC12)</i> ET LE CLASSIFICATEUR KNN.	97
3.5	TAUX DE CLASSIFICATION MOYENNE (%) DU CHLBP POUR DIFFÉRENTS RAYONS ET VOISINS SUR GID (CLASSES 5 ET 15), AID ET CLASSIFICATEUR SVM.	98
4.1	Taux de classification (%) du descripteur CPLBP pour différentes valeurs du rayon R sur la base de données <i>TC10</i>	104
4.2	Taux de classification (%) du descripteur CPLBP pour différentes valeurs de rayon R sur la base de données <i>TC12</i>	105
4.3	Taux de classification (%) du descripteur CPLBP avec les méthodes de l'état de l'art pour les différentes valeurs de R sur les bases de données <i>outex_TC_10</i> et <i>12</i>	106
4.4	Taux de classification (%) du descripteur CPLBP pour différentes valeurs d'angle θ avec un rayon fixe R=6 sur les jeux de données <i>TC10</i> et <i>TC12</i>	109
4.5	Taux de classification (%) du descripteur CPLBP avec les méthodes de pointe pour différentes valeurs d'angle θ avec un rayon fixe R=6 sur les bases de données <i>TC10</i> et <i>TC12</i>	110
5.1	Résumé des caractéristiques des bases de données de texture utilisées dans nos expérimentations	122
5.2	Taux de classification (%) du CRSLBP pour différents R sur l'ensemble de données <i>Outex</i> et le classificateurs (SVM, NN).	123
5.3	Taux de classification (%) du CRSLBP pour différents R sur l'ensemble de données <i>KTH-TIPS2b</i> , <i>UMD</i> et <i>Brodatz</i> et le classificateur (SVM, NN).	125

5.4	Taux de la classification (%) de CRSLBP par rapport à MRELBP à l'aide d'un ensemble de classificateurs R et SVM	127
-----	---	-----



INTRODUCTION GÉNÉRALE

Notre environnement regorge de textures variées et complexes dérivées de diverses sources du monde réel. De telles textures peuvent être capturées afin d'être analysées par une variété de techniques d'imagerie. En général, la texture présente des apparences visuelles différentes selon les différents types d'images, tels que les surfaces d'objets dans les images naturelles (Shotton et al. [2009]), les motifs de tissu dans les images microscopiques (Kampouris et al. [2016]) et les structures géologiques dans les images sismiques (AlRegib et al. [2018]). L'apparence d'un objet est représentée par des informations visuelles sur la texture qui contiennent des informations latentes sur plusieurs caractéristiques matérielles clés telles que la douceur, la régularité ou la granularité, qui sont généralement déterminées par la taille, la forme et la disposition des micro-structures qui correspondent aux matériaux. Les micro-structures fondamentales des textures d'un matériau fournissent des repères importants à notre système visuel humain pré-attentif pour identifier des objets ou des régions locales en décrivant la disposition spatiale des constituants de base, des objets qui constituent une image ou une vidéo.

La vision par ordinateur est un vaste domaine de recherche qui traite l'extraction d'informations et la compréhension d'images et vidéos à l'aide d'algorithmes informatiques. Elle englobe divers problèmes dont la détection, la segmentation, la reconnaissance, la classification, l'estimation de mouvement et la restauration d'image. Les avancées technologiques et la quantité de données disponibles offrent une gamme d'applications de plus en plus large. L'analyse de la texture en vision par ordinateur vise à comprendre, modéliser et traiter la texture, ainsi qu'à simuler le processus d'apprentissage visuel humain. Elle est utilisée avec les algorithmes de classification dans de nombreuses applications de vision par ordinateur, notamment l'analyse d'images médicales (Rampun et al. [2017], Kaplan et al. [2020]), la récupération de formes spectrales (Biasotti et al. [2014], Biasotti et al. [2016]), la télédétection (Hajeb et al. [2020], Yang et al. [2019]), la reconnaissance faciale et d'objets (Tang et al. [2020], Xiao et al. [2017], Zhang et al. [2009]), la

récupération et reconnaissance vidéo (Song et al. [2018b], Wang et al. [2016], Wang et al. [2017]), l'automatisation industrielle (Kurka and Salazar [2019]), etc. Au cours des deux dernières décennies, la classification des textures apparaît comme l'un des problèmes majeurs dans l'analyse de texture. Elle s'est considérablement concentrée sur la reconnaissance des formes et le traitement d'images en utilisant diverses techniques mathématiques de catégorisation des échantillons de texture inconnus dans l'un des échantillons de texture prédéterminés ou d'évaluer la probabilité que l'échantillon inconnu corresponde à l'un des échantillons de texture prédéfinis.

Malgré les nombreuses applications de la classification des textures, les textures du monde réel sont souvent non uniformes en raison de variations d'orientation ou d'échelle, de la présence de bruit ou de tout autre élément visuel ayant une incidence sur l'efficacité des méthodes analytiques. De nombreux descripteurs ont été proposés, mais les progrès ont toujours été lents, car le problème devient plus complexe avec des images à grande échelle contenant de nombreux motifs de texture. De plus, plusieurs critères doivent être pris en compte lors de la conception des descripteurs de texture afin qu'ils soient pertinents et efficaces pour l'application envisagée. Ces facteurs incluent la taille du vecteur de caractéristiques généré par le descripteur, qui doit être suffisamment grand pour faire face au nombre croissant de photos dans la base de données, et la vitesse d'extraction des caractéristiques, qui doit être suffisamment rapide pour suivre la croissance du nombre d'images dans la base de données. Étant donné que de nombreux descripteurs ont été conçus pour extraire des informations de texture, de nouvelles recherches se concentrent sur la création de nouvelles approches locales afin d'effectuer une analyse de texture plus efficace et discriminante.

Le descripteur de texture *local binary pattern* (LBP) est un descripteur local fiable et efficace qui a été largement utilisé dans une variété d'applications au cours des deux dernières décennies. Ojala et al. [1996b, 2002c] ont d'abord proposé le descripteur en 1996, en s'appuyant sur les travaux de Harwood et al. [1995]. Il est considéré comme le fondement de l'opérateur LBP. Le LBP fonctionne avec des images en niveaux de gris et sa puissance découle de sa capacité à gérer la rotation que les motifs de texture peuvent subir. L'objectif principal de cette nouvelle méthode est de traiter l'image texturée à l'aide d'une fonction de noyau particulière, qui constitue la relation statistique entre les pixels voisins et le centre et permet de calculer la valeur de transformation en capturant le modèle structurel local. LBP est également évolutif, ce qui lui permet d'être étendu via une analyse multi-échelle ou complété par des informations supplémentaires à partir de l'image donnée. La simplicité, la robustesse et la rapidité de ce calcul ont attiré l'attention des chercheurs visant à créer leurs propres opérateurs locaux en développant d'autres variantes.

Objectifs

L'extraction des caractéristiques robustes et discriminantes est requise dans de nombreuses applications. Dans cette thèse, nous avons mis l'accent sur l'approche d'extraction des caractéristiques pour une classification efficace des textures. L'idée principale de cette approche est d'obtenir à la fois les informations de structure locales et globales d'une image afin de la représenter de manière invariante à la rotation, robuste aux changements d'échelle et d'éclairage, tout en étant capable de préserver le pouvoir discriminant.

L'objectif de cette recherche est « de proposer de nouvelles variantes de LBP qui améliorent la description de la texture d'une image et de les utiliser pour l'analyse d'images télédétection ». Les objectifs spécifiques de la recherche sont énumérés ci-dessous :

- étudier les variantes existantes du modèle binaire local et suggérer de nouvelles idées pour leur amélioration ;
- évaluer et comparer différentes variantes de LBP sur une base de données de texture populaire ;
- évaluer les améliorations suggérées aux variantes de LBP et combler les lacunes du descripteur ;
- automatiser la classification des images de télédétection d'une description spatiale très importante.

Contributions

La principale contribution de cette thèse réside dans la proposition de cinq nouvelles variantes de LBP :

La proposition d'une nouvelle variante de LBP, appelée *homogenous* LBP (HLBP), permettant d'améliorer les performances du descripteur LBP en se basant sur l'impact du critère de tolérance d'homogénéité provenant du descripteur *GAN-based Minkowski maps*. Dans (González-Castro et al. [2015]), ce dernier a été combiné avec le LBP pour classer les lésions cutanées, cependant, l'inconvénient majeur se manifeste sur le traitement global de l'image qui entraîne une perte d'information caractéristique des images et une sensibilité aux changements d'éclairage et de rotation. Afin de surmonter cet inconvénient, nous avons utilisé un seuillage par bloc fondé sur un critère choisi, tel que la luminance, le contraste, l'épaisseur, etc. Les valeurs des critères de pixel s'inscrivent dans une plage spécifiée de tolérance d'homogénéité qui permet de mieux

prendre en considération les relations entre les pixels voisins. Par conséquent, les voisinages des pixels correspondent d'avantage aux structures spatiales sous-jacentes, ce qui nous garantit des caractéristiques discriminantes robustes et puissantes avec une faible dimension.

La deuxième variante du LBP pour la classification de texture, nommée *homogenous rotated* LBP (HRLBP), qui vise à améliorer le côté invariant à la rotation du HLBP en utilisant une variante robuste du LBP intitulée *rotated* LBP (RLBP). Cette dernière traite l'invariant à la rotation en décalant les points circulairement par rapport à une direction dominante locale prise comme référence. Ainsi, les poids dépendent désormais du voisinage et non d'un arrangement pré-sélectionné. En conséquence, HRLBP augmente le pouvoir discriminant des caractéristiques extraites localement des images en rotation.

La troisième contribution fondée sur les deux premières HLBP et HRLBP : il s'agit d'une nouvelle variante de LBP destinée à la caractérisation de la texture dans le cadre de la classification des images de télédétection (*remote sensing* (RS) en anglais) en tolérance au bruit, connu sous le nom *completed homogeneous* LBP (CHLBP). En fait, CHLBP est une version améliorée des méthodes HLBP qui permet de bien modéliser les relations spatiales entre les régions exposées dans une image, telles que les limites, les distances et les orientations, en considérant l'impact de l'opérateur de tolérance d'homogénéité utilisé dans HLBP, et la distribution hybride (signe et magnitude) fournie par *completed* LBP (CLBP) avec l'ajout d'un paramètre δ qui permet de seuiliser les pixels centraux dans une plage spécifique avec la génération de signaux positifs et modèles locaux négatifs. Ainsi, ce nouveau codage est capable d'acquérir plus d'informations intrinsèques, ce qui permet d'obtenir une précision de classification significativement améliorée, notamment dans le cadre de RS.

La quatrième nouvelle, efficace et robuste extension du LBP pour la classification des textures nommée *circular parts* LBP (CPLBP). L'avantage du CPLBP est le substitut de la moyenne d'une région des pixels voisins au chaque voisinage d'un pixel centre (segment circulaire spécifié par rayon R et angle θ), qui permettent de conserver toutes les informations spatiales ce qui aide à réduire le bruit, et en conséquence, d'obtenir des informations puissantes, robustes et discriminantes pour les différents cas des coordonnées polaires : soit θ fixe et R variable et vice-versa. En outre, l'impact des coordonnées polaires (rayon R et angle θ), garantit une robustesse dans les propriétés importantes telles que l'invariance à la rotation et à l'échelle en comparant avec le LBP original.

La cinquième et la dernière contribution de cette thèse, une nouvelle variante du LBP nommée *corner rhombus shape* LBP (CRSLBP). La plupart des extensions LBP visent à exploiter la

relation entre pixels voisins avec un seul pixel central, alors que la relation entre pixels centraux qui peut nous fournir une information discriminante n'est pas prise en compte. D'autre part, l'interpolation bilinéaire utilisée par le descripteur LBP présente de nombreuses limitations, telles que la perte de netteté, l'imprécision de la valeur de gris et la complexité de calcul élevée. À partir de ces différentes observations, le CRSLBP est une version améliorée de la méthode LBP qui prend en considération le signe et la magnitude, avec l'ajout du bloc de choix pair, qui permet de seuiller quatre pixels centraux. Cela sert à obtenir des relations non seulement entre voisins, mais aussi entre les centres.

Une large gamme de bases de données de texture et de télédétection : (*Outex [TC10,TC12]*, *UMD*, *Brodatz*, *Kth-Tips2b*, *GID* et *AID*) sont utilisées afin d'évaluer les méthodes proposées. Nous avons entamé dans cette thèse une variété de problèmes liés à la reconnaissance de texture, à savoir : la présence de bruit , l'effet de l'éclairage, la rotation et le changement d'échelle, et l'influence du nombre d'images d'apprentissage. Les principaux avantages des approches proposées sont :

- la robustesse au bruit ;
- l'invariance à l'éclairage, à la rotation et à l'échelle ;
- les paramètres de textures très discriminatifs ;
- la faible dimension des paramètres ;
- la simplicité de mise en oeuvre ;
- le schéma de calcul rapide ;
- obtention de meilleur résultats quels que soient les paramètres choisis (l'échelle d'analyse ou la taille de la fenêtre de voisinage considérée).

Organisation du manuscrit

Le présent manuscrit s'articule autour de cinq chapitres. Outre le chapitre préliminaire faisant office d'introduction générale, les chapitres se présentent de la manière suivante :

Le **premier chapitre** expose une revue de la littérature sur la texture en mettant l'accent sur les problèmes de classification. Des études sur la perception humaine de la texture et les premières approches d'extraction de caractéristiques sont introduites comme bases sur lesquelles les tendances les plus récentes sont construites. Diverses méthodes d'extraction de caractéristiques de texture sont décrites, notamment des descripteurs structurels, statistiques, spectrales, et établis sur les modèles. L'utilisation de ces caractéristiques dans les analyses de texture est

décrite, en mettant l'accent sur la classification. On y trouve également une introduction sur les différentes bases de données de référence populaires pour les tâches de classification des textures qui seront utilisées pour réaliser des études expérimentales dans les chapitres suivants.

Le **deuxième chapitre** présente le descripteur *local binary pattern* (LBP), la relation entre le LBP et les méthodes de caractéristiques de texture antérieures, ainsi que ses variantes. Le chapitre commence par formuler la méthode de calcul de l'opérateur LBP d'origine (Ojala et al. [1996b]). Ensuite, les mesures pour traiter la rotation de l'image, la réduction de la dimensionnalité (LBP uniforme) et la mise à l'échelle de l'image sont présentées. Par la suite, nous résumons et classons les variantes de LBP en groupes pour comprendre facilement cette méthode qui est à la fois simple et efficace. À la fin du chapitre, nous exposerons les différents algorithmes de classification et les tests statistiques utilisés pour évaluer la pertinence des attributs extraits à partir de la texture.

Le **troisième chapitre** propose trois nouvelles variantes de LBP pour la classification de la texture. Les deux premières méthodes HLBP et HRLBP sont basées sur un critère d'homogénéité provenant d'une méthode d'analyse de la texture nommée *general adaptive neighborhood based minkowski maps* (Pinoli and Debayle [2009]). Bien que HLBP soit une contribution robuste, nous avons introduit l'approche HRLBP afin de renforcer le côté invariant à la rotation du descripteur HLBP. Par la suite, nous nous sommes intéressés à la caractérisation des images de télédétection en tolérance au bruit, et nous avons proposé notre troisième contribution CHLBP comme une version améliorée du HLBP qui prend en considération le signe et la magnitude fournis par CLBP avec l'ajout d'un paramètre δ qui permet de seuiliser les pixels centraux dans une plage spécifique avec la génération de signaux positifs et modèles locaux négatifs. Ensuite, par les études expérimentales, nous évaluerons nos descripteurs en utilisant les bases de données les plus populaires et les plus difficiles dans la classification des images de texture et de la télédétection à haute résolution spatiale (*Outex [TC10, TC12]*, *GID* et *AID*) et deux classifieurs (*support vector machine* (SVM) et *k nearest neighbors* (KNN)).

Le **quatrième chapitre** présente une autre variante du LBP pour la classification de la texture, nommée *circular part LBP* (CPLBP). Il se fonde sur l'impact des coordonnées polaires (rayon R et angle θ) qui permet d'extraire pour chaque pixel voisin un ensemble de pixels intégré dans la zone angulaire circulaire spécifiée par R et θ , en calculant sa moyenne, ce qui permet d'obtenir une information puissante et discriminante à partir des images. Nous testons et nous comparons les performances du descripteur de texture en utilisant les bases de données Outex (TC10, TC12) avec le classifieur SVM.

Le **cinquième chapitre** propose la dernière extension du LBP, connue sous le nom de

corner rhombus shape LBP (CRSLBP), qui vise à attirer l'attention sur les relations entre les pixels centre, différents de la plupart des variants qui mettent l'accent sur les pixels voisins. Pour atteindre cet objectif, dans cette contribution nous avons travaillé sur la taille du bloc qui nous a permis de capter quatre pixels centraux et de travailler sur cette relation. Nous évaluerons l'approche proposée par plusieurs études expérimentales utilisant une variété de bases de données (*Outex (TC10, TC12)*, *UMD*, *Brodatz*, *KTH-TIPS2b*) et classifieur (SVM et NN). Enfin, nous présenterons et discuterons les résultats expérimentaux à l'issue de nos études.

En dernier lieu, nous conclurons notre travail en synthétisant les points essentiels présentés dans cette thèse et en résumant les principaux résultats obtenus. Nous exposerons également les perspectives sous-jacentes de notre travail, aussi bien du point de vue théorique qu'applicatif.

TECHNIQUES D'ANALYSE DE LA TEXTURE
Sommaire

1.1	Introduction	9
1.2	La notion de la texture	9
1.3	Problèmes d'analyse de texture et de ses applications	12
1.3.1	Classification de texture	15
1.3.2	Segmentation de la texture	17
1.3.3	Détermination d'une forme par la texture	19
1.3.4	Synthèse de texture	19
1.3.5	Récupération de textures	20
1.4	Les méthodes d'analyse de la texture	21
1.4.1	Approches statistiques	21
1.4.2	Approches structurelles ou géométriques	24
1.4.3	Approches Fréquentielles ou spectrales	24
1.4.4	Approches basées sur les modèles	26
1.4.5	Approches hybrides	27
1.5	Un brève historique sur les descripteurs locaux de la texture	27
1.6	Les bases de données d'images de la texture	31
1.6.1	<i>OUTEX</i>	32
1.6.2	<i>KTH-TIPS2-b</i>	33
1.6.3	<i>Brodatz</i>	34
1.6.4	<i>UMD</i>	35
1.6.5	<i>GID</i>	35
1.6.6	<i>AID</i>	35
1.7	Conclusion	36

1.1 Introduction

L'analyse de la texture est un thème qui suscite beaucoup d'intérêt dans la communauté du traitement du signal et des images. Le but principal d'utiliser des techniques d'analyse de la texture est d'extraire des caractéristiques efficaces de la surface et de la structure interne d'un objet, telles que micro et macro-structure fondamentaux, des propriétés visuelles, des perceptions tactiles, des arrangements spatiaux qui fournissent des indices visuels importants ou des propriétés caractéristiques d'objets et de matériaux. Dans ce chapitre, avant d'aborder les différentes techniques d'analyse de la texture, il semble intéressant en premier de se pencher sur la notion de la texture. Ensuite, une revue bibliographique des différentes applications utilisant la méthode d'analyse de la texture, ainsi que l'évolution et les problèmes de la représentation des textures, depuis les techniques de représentation traditionnelles jusqu'aux approches les plus contemporaines basées sur l'apprentissage automatique.

1.2 La notion de la texture

Dans le monde naturel, la surface de tout objet visible est texturée à une certaine échelle. Les textures se manifestent par des assortis d'objets naturels et artificiels tels que ceux qui sont dans la peau des animaux, les plantes, le bois, etc. Généralement, le mot texture vient du mot latin *textura*, qui signifie tissu textile. Il se traduit par la structure physique, caractéristique donnée à un objet, à des matériaux, etc., qui sont communément déterminés par la taille, la forme, et l'arrangement. À la recherche du mot texture dans les dictionnaires, nombreuses définitions qui sont habituellement tactiles peuvent être associés à la texture telles que : grossière ou fine, régulière ou irrégulière, mate ou brillante, douce ou dure, etc. Néanmoins, la perception visuelle est la connaissance la plus prise en considération dans la vision par ordinateur puisqu'il tente de caractériser l'objet et les matériaux facilement. Cimpoi et al. [2014] utilisent une liste de 47 adjectifs pour décrire visuellement les textures. Par exemple, rayé, veiné et écailleux. Dans cette thèse, nous allons plutôt nous concentrer sur la texture visuelle. Quelques exemples de la texture naturelle et artificielle sont présentés dans les figures 1.1.

Bien que la texture soit un domaine de recherche important en vision par ordinateur, il n'y a pas de définition mathématique largement acceptée qui s'y rapporte, dû principalement à la représentation des propriétés des textures naturelles qui sont souvent discordantes mais contradictoires, telles que l'uniformité par rapport à la distorsion, la régularité par rapport au

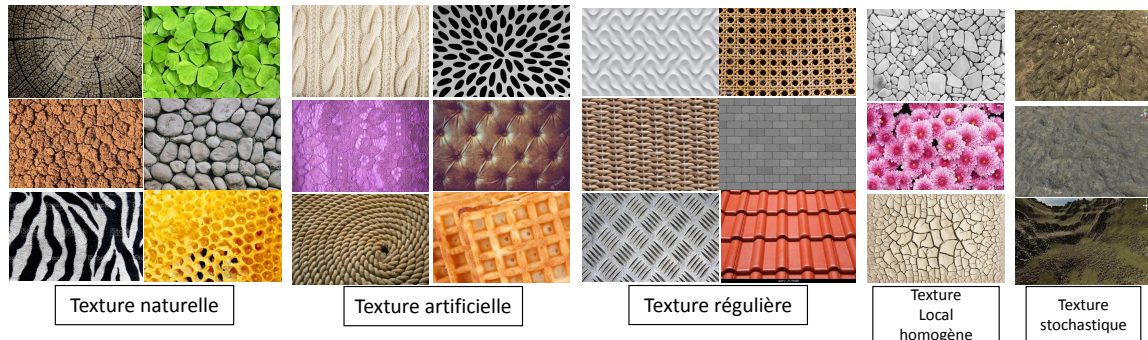


FIGURE 1.1 – Exemple des différents textures.

hasard, et qui peuvent difficilement être décrites de manière cohérente. Dans la littérature, de nombreuses études présentées tentent de définir la texture. La première hypothèse du Julesz [1962], si deux textures ayant les mêmes valeurs statistiques d'ordre un ou deux (basées sur des paires de valeurs de pixels), elles ne peuvent pas être distinguées par le système de texture de pré-attentif. L'exemple de la figure 1.2a démontre ce concept. Cette image représente deux régions texturées avec des statistiques de second ordre similaires. Toutefois, Julesz a rejeté la première conjonction, démontrée dans Julesz et al. [1978], que même si les textures comportent les mêmes ordres statistiques un et deux, leurs perceptions visuelles sont loin d'être les mêmes comme le montre la figure 1.2b, ce qui est confirmé par d'autres chercheurs, attendu que les textures visuelles sont des processus non-gaussien ce qui est le contraire pour les statistiques du deuxième ordre. Plus tard, Julesz [1981a,b] suggéré la théorie des textons à dans le but de donner un cadre formel à la problématique de la figure 1.2, dont il présume que la caractérisation des régions texturées se fait par la similarité/dissemblance des textons. Ces derniers sont désignés par des textures locales telles que les bords, les lignes d'extrémité et les fermetures. En se basant sur cette théorie des textons, Julesz a expliqué l'exemple de la figure comme suit : au niveau de la première image 1.2a l'information de la texture est incapable d'être distinguée par le système visuel à cause des taches allongées (segments de ligne) des textons ainsi que leurs terminaisons qui ont les mêmes nombres (densités). Tandis que, le système humain peut discriminer dans la figure 1.2b les différentes textures puisqu'il y a une différence entre le nombre de fin de lignes (termateurs) des textons. Haralick et al. [1973], Haralick [1979] présente un nouveau point de vue sur la texture. C'est un phénomène de zone organisée qui peut être décrit par des éléments de base ou "primitives" distinguées par des agencements spatiales précises. Cette définition est

déclarée aussi comme une approche structurelle, puisqu'il se base directement vers l'expérience visuelle humaine. La structure spatiale de ces primitives après ses organisations, elles indiquent des règles de placement spécifiques pour former un certain motif. D'autres présentations de la texture ont été proposées, dans Jain and Karu [1996] la texture ne concerne pas seulement la valeur de gris à un pixel, mais aussi les motifs avec ces voisinages. Une autre suggestion est proposée par Sklansky [1978] qui déclare qu'une région dans une image, contient une texture constante à condition que les statistiques locales ou d'autres propriétés locales soit constantes ou variantes lentement ou approximativement périodiques. Cimpoi et al. [2014] indique que la texture est un domaine bidimensionnel stochastique, éventuellement périodique. Cette définition peu être déclarée comme une approche stochastique, qui peut être présentée en tant qu'une des différentes approches informatique destinée a l'analyse de la texture.

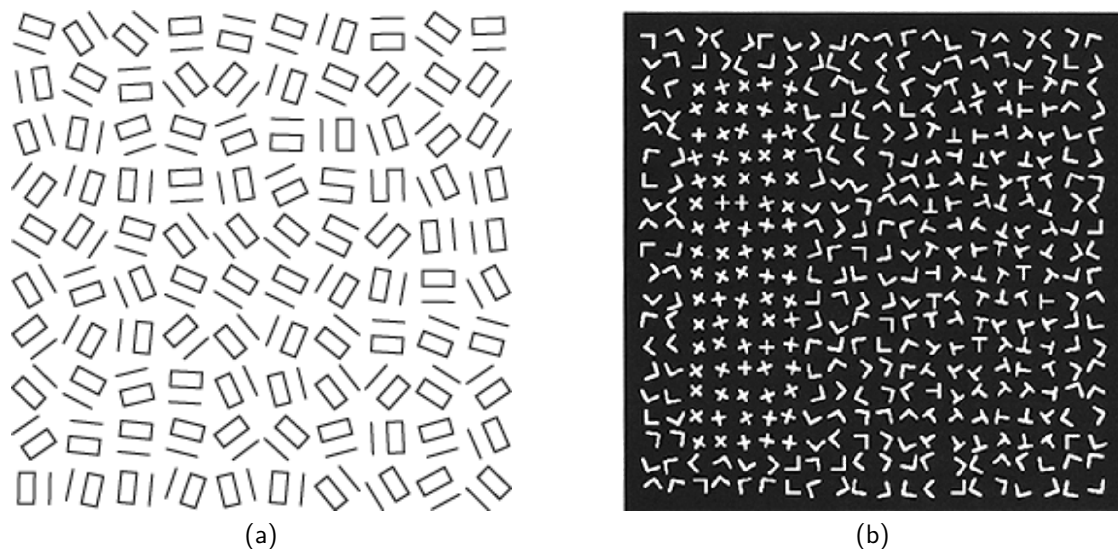


FIGURE 1.2 – Deux images avec les même statistiques de second-ordre : (a) Le texton ne peut pas être différencié par l'oeil humain, (b) les trois régions sont immédiatement discriminées par l'oeil humain.

Parmi les propriétés les plus importantes d'une texture est l'homogénéité spatiale. Au niveau statistique, cette dernière dénote la stationnarité statistique. Cette caractéristique concerne l'auto-similarité : une même statistique de signal peut représenter les motifs à différentes échelles, bien qu'il ne soient pas identiques. D'autre part, il existe aussi la non-homogénéité locale, c'est le fait de sortir d'une stricte homogénéité par une certaine expansion dans une région locale de l'image. Malgré la complexité et la diversité des textures, elles peuvent être classées en plusieurs

catégories. Telles que : primitive homogène (structure idéale répétitive), non-homogène (sans répétition d'un motif ni d'auto-similarité), faible homogène (variation spatiale locale des éléments de texture ou de leur disposition spatiale), texture régulière (éléments de petite taille facilement identifiables organisés en motifs périodiques forts), texture stochastique (éléments moins perceptibles et présentent des motifs plutôt aléatoires). Figure 1.1 présente des exemples de ces types de texture.

En résumé, l'analyse de texture est fortement influencée par la perception humaine de la texture. Diverses idées et définitions ont été explorées pour mieux comprendre comment les humains perçoivent la notion de la texture. Cela nous amène à l'hypothèse de Julesz. Par conséquent, de nombreuses méthodes analytiques sont utilisées afin de représenter la description de la texture par les paramètres mathématiques utilisés pour l'identifier. Les techniques statistiques d'analyse de la texture, qui utilisent des statistiques de caractéristiques pour décrire des images de la texture. Les techniques structurelles d'extraction des primitives de la texture en tant que caractéristiques locales sont basées sur la théorie des textures. Des modèles basés sur des banques de filtres ont été introduits dans la modélisation de texture informatique, ce qui a entraîné l'utilisation de filtres pour décomposer les images de texture et les transférer dans le domaine fréquentiel.

1.3 Problèmes d'analyse de texture et de ses applications

Dans la vision par ordinateur, l'analyse de la texture vise à comprendre, modéliser et traiter la texture, ainsi qu'à simuler le processus d'apprentissage visuel humain. La figure 1.3 illustre une structure commune d'analyse de la texture dans un système de vision par ordinateur se composant de plusieurs étapes ; une phase de pré-traitement, dont les images vont se traiter de telle sorte que de disposer du bruit, ou encore segmentées de manière plus sophistiquée en régions contiguës en fonction des propriétés de texture de chaque région ; une phase d'extraction de caractéristiques ou du descripteur de caractéristiques, cette phase a un concept, soit entraînable ou fixe, dont les importantes propriétés de l'image sont sélectionnées pour fournir des indices pour la classification des modèles ou l'identification des objets.

la texture apparaît dans un large intervalle de domaine d'application. Le développement des différentes méthodes d'analyse de la texture permet d'automatiser plusieurs tâches effectuées par des êtres humains en créant une description quantitative générale, efficace et compacte des textures afin que diverses opérations mathématiques puissent être utilisées pour modifier, comparer et transformer les textures. Par conséquence, la consommation du temps sera instantanément

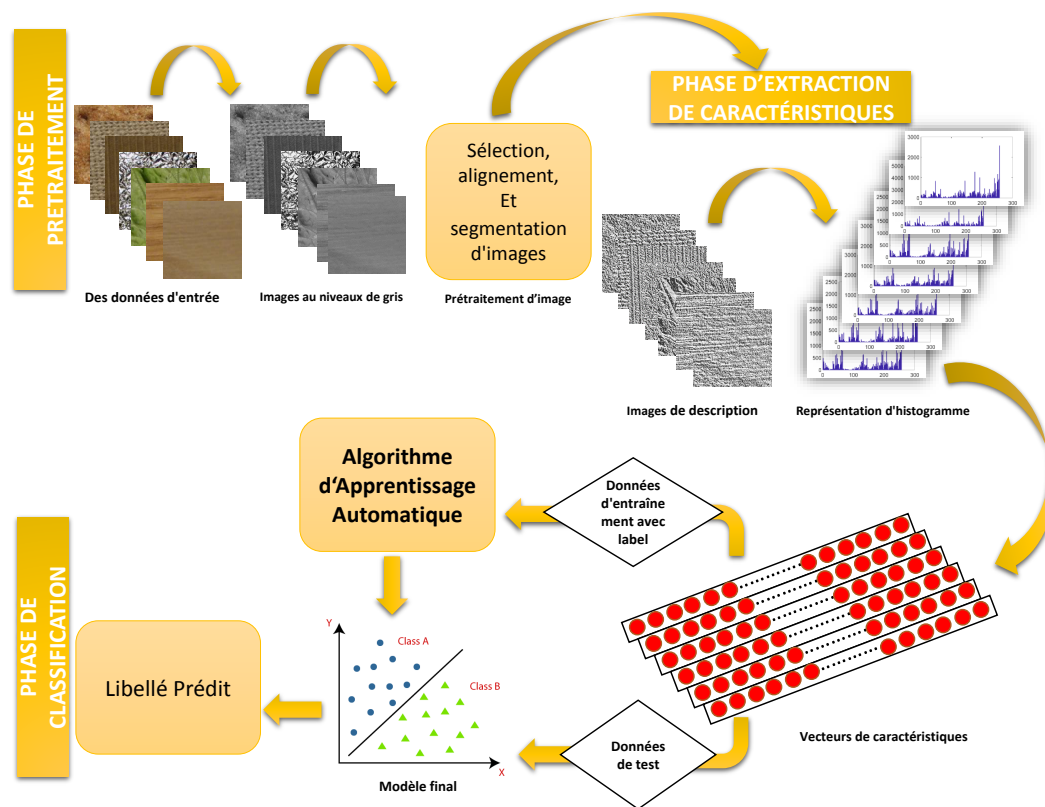


FIGURE 1.3 – Le processus de base de la classification des textures.

progressée avec un moindre besoin de ressource précisément dans les tâches fastidieuses.

La majorité des techniques d'analyse de texture impliquent l'extraction de caractéristiques de texture et la génération d'un schéma de codage d'image pour afficher ces données. Ces algorithmes peuvent changer, en fonction des caractéristiques de texture collectées ainsi que la manière dont elles sont présentées dans la description. Par exemple, une technique statistique, caractérise une texture à l'aide de statistiques de signal d'image, qui reflètent des propriétés non déterministes de la distribution spatiale du signal d'image. par contre, la technique structurale considère une texture comme une hiérarchie d'arrangements spatiaux de primitives de texture bien définies dont la technique spectrale se base au niveau de l'extraction sur le domaine spectral, ainsi le modèle probabiliste sur le processus stochastique sous-jacent. Plus de détails seront présentés dans la section 1.4

Les algorithmes d'analyse de la texture sont largement appliqués pour une variété des tâches, y compris le traitement des images médicales, la segmentation (séparer une image en plusieurs

régions, en fonction de leur similarité), la classification (mettre chaque texture d'une base de données dans une spécifique classe, ces classes sont prédéfinies selon certains critères de similarité), la récupération de texture, ou encore elles peuvent consister en un tremplin pour la synthèse de texture (c-à-d à base d'une texture donnée comme exemple en entrée, peut créer une texture synthétique et proche visuellement de celle d'entrée).

Dans la technologie d'imagerie médicale, les développeurs émergents signalent un besoin des approches et des outils innovants qui vont servir à analyser des données cliniques (Duncan and Ayache [2000]). En fonction de ces besoins qui sont signalés, des techniques d'analyses de texture sont employées pour assister les cliniciens à renforcer le diagnostic (Castellano et al. [2004]). En outre, l'analyse de la texture peut aussi aider à identifier et extraire les caractéristiques dans les images médicales liées à des objets anatomiques cibles. par ailleurs, la segmentation sera ensuite pratiquée par les cliniciens dans le but d'extraire divers statistiques, y compris la taille, la forme des tumeurs ou encore les structures anatomiques anormales. en trouvant d'autres usages de ces techniques d'analyses de la texture dans le domaine médicale comme l'analyse des tissus dans des taches, telle que la détection de lésions ou la discrimination entre les tissus normaux et pathologiques.

Au niveau de la télédétection, l'importance des approches d'analyses de la texture se situe dans l'extraction des informations de géométrie locale afin de caractériser l'organisation et la dynamique du terrain (Aptoula [2013], Regniers et al. [2016]). Ces informations extraites à l'aide des méthodes peuvent aussi être employées dans des évaluations statistiques significatives ou encore l'évaluation et la qualification de l'impact humain des activités humaines et des différents phénomènes naturels y compris des événements météorologiques graves. Ce domaine est riche et ses diversifié dans ces applications, telles que la classification des données de télédétection forestière et urbaine (Ruiz et al. [2004]), la classification des parcs à huîtres (Regniers et al. [2015]), la délimitation des parcelles de vigne dans les images de télédétection à très haute résolution (Da Costa et al. [2007]).

Les techniques d'analyse de la texture peuvent être utilisées également dans des processus qui sont liées au contrôle du qualité industriel afin de remplacer les systèmes d'inspection visuelle (qui est une tâche laborieuse puisqu'il est mis en place par l'homme) par d'autres qui sont automatisés. Cela va permettre une détection automatique des défauts en analysant les images texturées correspondantes aux surfaces de différents types de matériaux, tels que : métaux, céramiques, textiles (comme étant démontré dans [Tomczak et al. [2007]]).

Dans le domaine de l'infographie, des méthodes de synthèse de la texture peuvent être em-

ployés pour le défi permanent liées à l'invention d'une réalité virtuelle visuellement similaire aux scènes réelles du monde réel. Nombreuses solutions ont été suggérées dans la littérature (Efros and Leung [1999], Wei and Levoy [2000], Galerne et al. [2011], Urs [2013], Akl et al. [2015], Gatys et al. [2015])

Les méthodes d'analyse de la texture peuvent aussi être utilisées dans un autre domaine d'application des textures qui est le traitement de documents, de telle sorte d'identifier les régions d'intérêt d'image du document dans la phase de pré-traitement de segmentation, ces régions sont représentées soit par un code barre sur un document, ou par les blocs de texte dans un journal etc. (Jain et al. [1992]). Les données segmentées peuvent être utilisées à différents objectifs, y compris la reconnaissance d'adresses ou la restauration d'anciens textes.

La texture représente une caractéristique importante de l'apparence de toutes les surfaces naturelles, elle offre des indices fondamentaux pour identifier les matériaux et les objets, en particulier lorsque la forme n'est pas disponible.

Dans un environnement réel et selon les mesures exigées (comme déjà démontré dans les exemples des domaines d'applications proposés ci-dessus), l'application d'une analyse de texture peut conduire à rencontrer de nombreux sous-problèmes en raison de traiter, comprendre et simplifier les différents défis.

Quatre problèmes majeurs d'analyse de la texture ont été listés dans (Tuceryan and Jain [1993]), à savoir la classification de texture, la segmentation de texture, la synthèse de texture, et la détermination d'une forme par texture. Tandis que Petrou and Kamata [2021] ont proposés trois problèmes liés à l'analyse de la texture qui sont : la classification de texture, la segmentation de texture, et la détection des défauts par texture. Nous commençons par la classification des textures qui est la principale préoccupation de cette thèse.

1.3.1 Classification de texture

Dans la vision par ordinateur, la classification des textures apparaît comme l'un des domaines de recherche les plus importants qui s'est considérablement intéressé à la reconnaissance des formes et au traitement d'images en utilisant différentes techniques mathématiques permettant de prédire la catégorie ou la classe d'une donnée ou d'un échantillon inconnu. La raison principale de la classification, comme indiqué sur la Figure 1.4, est de classer ou de catégoriser des échantillons de texture inconnue dans l'un des échantillons de texture prédéfinis ou de déterminer la probabilité que l'échantillon inconnu corresponde à l'un des échantillons prédéfini (Liu




FIGURE 1.4 – Exemple de la classification des textures.

et al. [2019]).

Dans un système de classification des textures, deux étapes importantes sont requises et ils sont communs dans l'ensemble des publications existantes dans la littérature. La première et la primordiale étape consiste à extraire à partir de l'image, toutes les caractéristiques discriminantes, qui donnent la propriété de chaque classe de texture en termes de mesures de caractéristiques. Elle peut également être composée de 2 phases : (1) pré-traitement (2) extraction des caractéristiques. Généralement, il est important d'identifier et de sélectionner les caractéristiques distinctives afin qu'elles soient invariantes à la transformation non-pertinente des images, telles que la translation, la rotation et la mise à l'échelle. Tandis que la dernière étape dépend des caractéristiques extraites à partir de la première étape, en classifiant les données du test sous-jacentes au modèle d'apprentissage généré à partir des données d'apprentissage. Autrement dit, en se basant sur les mesures quantitatives obtenues des caractéristiques sélectionnées, les classificateurs sont entraînés à déterminer une étiquette pour chaque texture d'entrée (image test), selon la comparabilité des images (soit identique ou extrêmement proches soit différente). Par conséquent, un classificateur est une fonction qui prend les entités sélectionnées comme entrées et produit des étiquettes de classe de texture telles que « herbe », « bois » et « brique ». La classification peut également être binaire, telle que cancer « malin » vs « bénin » ou texture d'intérêt contre toutes les autres textures (c'est-à-dire spécialiste).

Cependant, la conception d'un extracteur de caractéristiques est généralement difficile à l'applicable, car les caractéristiques dépendent d'une situation spécifique, et nécessitent divers degrés de connaissance du domaine ou de données à partir desquelles on peut apprendre. Cela signifie qu'il y a peu d'extracteurs de caractéristiques qui distinguent bien toutes les catégories de textures. Par exemple, Le problème de la reconnaissance faciale est utilisé dans nombreuses travaux de classification, selon le travail récent de Rahim et al. [2013], un nouvel modèle suggéré

pour identifier le visage en utilisant l'une des techniques d'analyse de la texture, sauf le fait que sa robustesse s'élimine dans l'expression faciale, le vieillissement, l'illumination et l'alignement, ainsi il peut donner de faibles performances si la base contient, par exemple, la rotation.

Les méthodes d'analyse de texture basées sur la classification sont également largement utilisées dans l'analyse d'images médicales. Par exemple, les qualités texturales peuvent être dérivées d'une image, et la classification des tissus peut être effectuée sur la base des connaissances existantes. La classification des clichés radiographiques de maladies pulmonaires a été l'une des premières approches d'analyse de texture documentée dans la littérature (Sutton and Hall [1972]), la classification texturale est très utile pour l'identification de ces maladies car les zones affectées des poumons présentent des qualités texturales différentes. Généralement, les méthodes d'analyse de texture telles que la matrice de co-occurrence, la matrice de longueur de plage, l'histogramme et les ondelettes sont utilisées sur une variété d'images médicales avec la classification afin de faire ; soit le diagnostic de la dystrophie musculaire squelettique, la différenciation des tissus cérébraux, la détection de la sclérose en plaques ou encore la classification des lésions du col de l'utérus. (Sharma et al. [2015], Maani et al. [2016], Singh and Srivastava [2017], Sahoo and Chandra [2017]).

Les images de texture sont représentées numériquement dans des vecteurs de caractéristiques à l'aide d'un seul ou d'un mélange de descripteurs de texture, afin de former un classificateur, ensuite la sortie du classificateur est utilisée dans le sens de prévoir ou catégoriser la texture inconnue. Les classificateurs paramétriques et non paramétriques sont les deux types de classificateurs disponibles. La différence est que les classificateurs paramétriques, tels que les classificateurs bayésiens et Mahalanobis, font des hypothèses sur la distribution des caractéristiques. Tandis que, les classificateurs non paramétriques, tels que le classificateur k-NN, peuvent être utilisés avec n'importe quelle distribution de caractéristiques et sans faire d'hypothèses sur les formes des densités sous-jacentes (Bailey and Srinath [1996]). Les deux méthodes nécessitent certaines connaissances préalables, telles que des données de formation, et sont donc appelées procédures supervisées. Les techniques non supervisées ne nécessitent aucune connaissance préalable et reposent sur des techniques de clustering comme les cartes auto-organisatrices (Kohonen [1991]).

1.3.2 Segmentation de la texture

L'analyse de la texture peut également être utilisée pour segmenter des images en plusieurs régions discrètes, afin que chaque région soit homogène selon une caractéristique de texture




FIGURE 1.5 – Exemple de la segmentation des textures.

spécifique. La technique, nommée la segmentation de la texture, consiste à extraire des caractéristiques et à dériver des métriques pour séparer les textures. Les résultats de la segmentation peuvent être utilisés pour le traitement et l'analyse d'images, comme la reconnaissance d'objets. Des exemples d'images de la texture qui peuvent être segmentées sont illustrés à la figure 1.5, les caractéristiques texturales présentées dans la figure peuvent être utilisées pour partitionner le ciel, l'océan et les montagnes, qui peuvent ensuite être analysés à des fins spécifiques.

Selon la disponibilité des connaissances préalables de la classe d'image de texture, la segmentation peut être considérée comme étant une segmentation supervisée ou non supervisée. La segmentation supervisée utilise des informations préalables concernant l'homogénéité de l'objet et d'autres propriétés texturales ; elle fait l'identification et le partitionnement d'une ou plusieurs régions correspondant aux autres propriétés de texture présentées dans les textures d'apprentissage. Alors que la segmentation non supervisée n'a aucune connaissance préalable de l'objet ou de son homogénéité, elle doit d'abord récupérer différentes classes de texture d'une image avant de les séparer en régions. La segmentation non supervisée est plus adaptable aux applications du monde réel que la segmentation supervisée comme par exemple le pré-traitement d'images, bien qu'elle soit plus coûteuse en calcul, car elle ne nécessite pas l'effort de créer des données pour la formation, et encore il s'agit d'autres problèmes non résolus et intensément étudiés en vision par ordinateur (Unal et al. [2005]).

La segmentation de texture a une variété d'applications dans la reconnaissance de formes et l'apprentissage automatique. Afin de partitionner des images génériques, la texture peut également être combinée avec d'autres indices, tels que des informations de contour. Revenons à la figure 1.5, comme on peut le voir, la segmentation n'est pas nécessairement une opération bien définie, car une image peut contenir plusieurs segmentations correctes. En revanche, la segmentation peut être un outil utile intéressant menant à la classification et à la reconnaissance. La segmentation, par exemple, peut être utilisée comme une étape de pré-traitement pour détecter des individus humains et restaurer leur posture corporelle en reconnaissant les membres. De même, avant de classer les régions d'intérêt, de nombreuses applications de classification de texture décrites dans la section précédente utilisent des méthodes de segmentation pour les délimiter. Il existe de nombreuses autres applications permettant de segmenter la figure à partir du sol, y compris les applications graphiques, telles que la substitution d'arrière-plan et l'édition d'images.

1.3.3 Détermination d'une forme par la texture

La détermination d'une forme par la texture est un domaine de recherche qui consiste à estimer la forme de trois dimensions (3D) d'objets texturés en analysant les différents attributs de la texture à partir de leur image de deux dimensions (2D). Une faible homogénéité ou isotropie d'une texture peut fournir des indices de forme (Criminisi and Zisserman [2000]). À partir d'une projection en perspective, l'aspect visuel (comme une inclinaison) de la texture de surface fournit généralement des informations relatives au gradient de texture, qui sont utilisées pour déduire les paramètres liés à la forme, à la surface, ou à la transformation de perspective. Par conséquent, en mesurant correctement le gradient de texture, une carte de profondeur et des formes d'objets sont très probablement reconstruites (Leung and Malik [2001], Ojala et al. [2002c]). Il existe une variété d'application dans la détermination d'une forme par la texture. La distorsion de texture d'une image, par exemple, peut être utilisée pour calculer la ligne de fuite plane (Criminisi and Zisserman [2000]), qui est ensuite utilisée pour affiner la correction de l'image.

1.3.4 Synthèse de texture

La synthèse de la texture fait référence à une production d'images de texture qui a une cible spécifiée, à partir des petits échantillons de texture. Une texture synthétique doit être distincte de celle d'original, tout en ayant des propriétés de texture qui sont perceptuellement similaires. La synthèse de texture a l'avantage de pouvoir gérer naturellement les conditions des frontières




FIGURE 1.6 – Le problème de synthèse de texture : étant donné les textures cibles à gauche, la tâche consiste à synthétiser des images de sortie similaires, mais pas identiques, telles que celles de droite.

et d'éviter les répétitions texturales. La figure 1.6 illustre un exemple sur la problématique de la synthèse de la texture.

Parmi les applications fréquemment employée dans la synthèse de texture est l'infographie, soit en raison de rendre les surfaces réelles ou de manipuler des images (Jetchev et al. [2016]). Par contre, dans la compression des images on ne stocke qu'un échantillon d'une région de texture, en outre, dans la peinture d'images en remplissant des trous dans des images (Tuceryan and Jain [1993], Al-Kaff et al. [2018]).

1.3.5 Récupération de textures

Dans l'environnement médiatique numérique d'aujourd'hui, de grandes quantités d'informations sont disponibles gratuitement sur internet avec un accès rapide, et parmi ces informations, un volume colossal de données est présenté sous forme d'images. Toutefois, si les données ne pas bien organisées de manière à permettre une navigation, une recherche et une récupération efficaces, elle ne peuvent pas être accédées ou utilisées. Des recherche approfondies sur la récupération d'images sont en cours depuis longtemps en réponse à ce problème. Bien que la gestion de base de données soit une méthode, la vision par ordinateur peut également être utilisée en conjonction avec elle. Content-based image retrieval (CBIR) ou la recherche d'image par le contenu est une technique qui fait l'extraction des caractéristiques d'image qui décrivent la texture, la forme, la couleur et d'autres qualités, ensuite ces caractéristiques vont être combinées avec d'autres mesures de similarité pour permettre la recherche des images virtuellement comparables (Smeulders et al. [2000]). Veltkamp and Tanase [2002] ont examiné le système CBIR et ils ont découvert que pour 56 systèmes, 46 utilisent des caractéristiques de couleur, 38 utilisent des

caractéristiques de texture et 29 utilisent des caractéristiques de forme. Pour la récupération de texture, Lin et al. [1997] a utilisé avec succès des modèles de Markov cachés. Dans les applications de récupération d'images, les ondelettes, en particulier les ondelettes de Gabor Manjunath and Ma [1996], sont des descripteurs de texture populaire.

1.4 Les méthodes d'analyse de la texture

A partir des différentes études sur la notion de la texture et de la perception visuelle du système humain qui sont présentées dans la session 1.2, ont menées à signaler qu'il existe divers défis qu'un individu trouve pour capter, analyser, interpréter visuellement et fournir un diagnostic dans un domaine de la vision industrielle et du traitement d'image, d'ici d'où vient le rôle des principaux outils d'analyse de la texture utilisés couramment en traitement d'image. Nombreux travaux se sont dédiés à classifier ces outils. Initialement, les méthodes sont dévissées en deux classes. La première, dénommée l'approche statistique qui se base sur les propriétés statistiques des intensités et des positions des pixels pour décrire et traiter la formation d'une texture donnée. L'autre classe est connue sous le nom d'approche structurelle, elle décrit la texture qui a une structure complexe par des primitifs plus simples qui s'appellent des textons. La description des textures est basée sur le vocabulaire des textons et leur relation.

Tuceryan and Jain [1993] a suggéré une nouvelle manière de catégoriser les approches de la texture, qui sont mis en quatre classes : statistique, géométrique, basée sur un modèle et spectrale. Dans l'approche basée sur un modèle, l'idée est de construire un modèle qui peut être utilisé non seulement pour décrire la texture, mais aussi pour la synthétiser. Les paramètres du modèle capturent les qualités perçues essentielles de la texture. L'approche finale celle du spectral implique le filtrage des images puis l'analyse fréquentielle pour la description de la texture. La figure 1.7 illustre une revue globale sur les méthodes d'analyse de la texture existante dans la littérature.

1.4.1 Approches statistiques

Parmi les descripteurs de la texture, les approches statistiques sont les premières méthodes suggérées dans la littérature. Elles sont les qualités importantes extraites de la texture par des calculs mathématiques, et basées sur la stochastique de la distribution spatiale des valeurs d'intensité. Autrement dit, elles décrivent les relations entre les valeurs de pixel et leurs voisins et codent également la texture en fonction du variation d'intensité de niveau de gris. Les descrip-

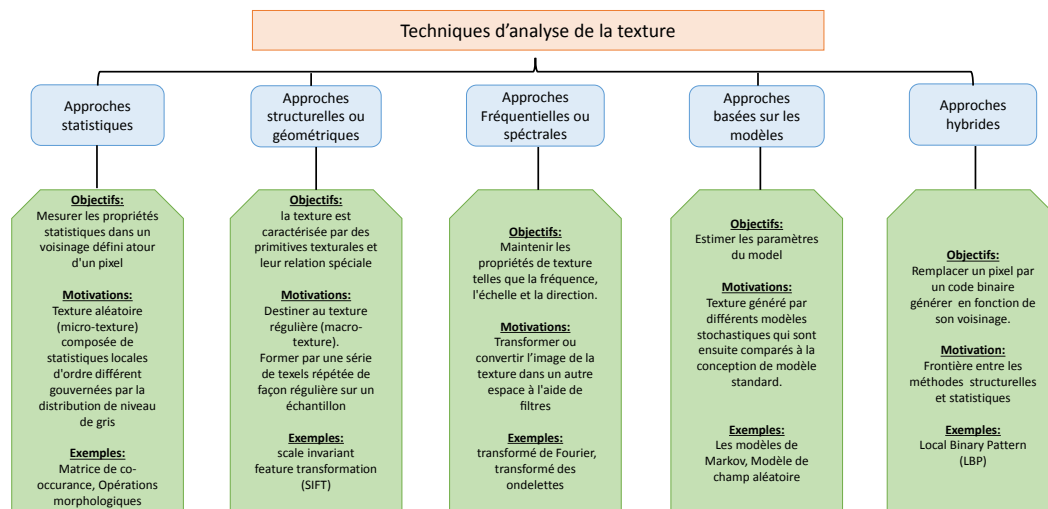


FIGURE 1.7 – Revue globale sur les méthodes d'analyse de la texture.

teurs statistiques sont destinés à tous type de texture, spécialement les textures fines et sans régularité apparente.

Généralement, les approches statistiques sont classées en trois classes : statistique du premier ordre, du deuxième ordre, et d'ordre supérieur. La distinction de ces classes est au niveau de l'ordre du paramètre statistique qui se dépend directement du type d'interaction spatiale entre les pixels considérés, plus l'ordre est élevé et plus le nombre de pixels mis en jeu est important. Par exemple, considérant l'histogramme des niveaux de gris de l'image qui est la plus simple propriété statistique de la texture, il n'intéresse qu'un pixel avec lui-même, par conséquent, il appartient aux familles des descripteurs du premier ordre. Par contre les matrices de co-occurrence sont des méthodes qui appartiennent à la famille du deuxième ordre puisqu'il considère des couples de pixels.

Dans les statistiques caractéristiques de premier ordre, seules les informations liées à la valeur des pixels sont pris en considération, et non les positions relatives des valeurs de pixel. Ceux-ci comportent la moyenne, l'asymétrie, la variance, et l'aplatissement.

Les statistiques de second ordre et d'ordre supérieur sont principalement extraite en utilisant des approches matricielles. Les statistiques du second ordre prennent en considération des paires de valeur de pixels qui ont été introduis dans la méthode Gray level co-occurrence matrix (GLCM) (Haralick [1979], Haralick et al. [1973]), Le GLCM vise à décrire les relations entre les intensités

TABLEAU 1.1 – Principaux attributs texturaux dérivés des matrices de co-occurrences

Attribut GLCM	Formule	Signification
Probabilité maximale	$P_{ij} = g_{ij}/n$	Donne une indication de la paire d'intensité la plus courante qui se produit dans l'image.
Corrélation	$\sum_{i=1}^k \sum_{j=1}^k \frac{(i-m_r)(j-m_c)}{\sigma_r \sigma_c} P_{ij}$	Mesure la similarité entre un pixel et son voisin, toujours compris entre -1 et 1, ce qui représente une relation parfaite négative à parfaite positive.
Contraste	$\sum_{i=1}^k \sum_{j=1}^k (i-j)^2 P_{ij}$	Mesure des variations locales d'intensité. Plus les variations sont élevées, la texture comporte une forte contraste. Caractérise la dispersion des valeurs de la matrice par rapport à sa diagonale principale.
Énergie	$\sum_{i=1}^k \sum_{j=1}^k P_{ij}^2$	Reflète le caractère régulier de la texture. Il vaut 1 pour l'image constante. Plus l'énergie augmente, plus la texture est régulière
Entropie	$\sum_{i=1}^k \sum_{j=1}^k P_{ij} \log_2 p_{i,j}$	Inverse de l'énergie, Mesure le caractère aléatoire du G.
Homogénéité	$\sum_{i=1}^k \sum_{j=1}^k \frac{P_{ij}}{1+ i-j }$	Mesure la proximité spatiale de la distribution des éléments en G à la diagonale. La plage de valeurs est [0,1].
Homogénéité	$\sum_{i=1}^k \sum_{j=1}^k \frac{P_{ij}}{1+ i-j }$	Mesure la proximité spatiale de la distribution des éléments en G à la diagonale. La plage de valeurs est [0,1].
Dissimilarité	$\sum_{i=1}^k \sum_{j=1}^k P_{ij} i-j $	Le poids des entrées des matrices augmente linéairement en s'éloignant de la diagonale plutôt que quadratiquement dans le cas du contraste.

de pixels voisins en analysant leur fonction de probabilité conjointe. Il résume l'occurrence de paires de pixels (horizontalement, verticalement ou en diagonale) dans une image, tandis que, les statistiques de l'ordre supérieur analysent la distribution conjointe de plus de deux pixels. Dans cet ordre, en remplaçant le GLCM par l'approche Grey Level Run Length Matrix (GLRLM) (Galloway [1974]) qui extrait l'occurrence des plages de pixels, ce qui signifie l'occurrence d'un pixel donnée dans une direction donnée.

Le tableau 1.1 illustre quelque attribut présenté par Haralick résumant l'information texturale contenue dans les matrices de co-occurrences. Soit Q un opérateur qui définit la position relative de deux pixels dans l'image I de L niveaux d'intensité possibles. Soit G une matrice dont les éléments g_{ij} sont le nombre de fois que des paires de pixels avec des intensités z_i et z_j se produisent dans I à la position spécifiée par Q. Une matrice formée de cette manière est appelée matrice de co-occurrence de niveau de gris et donnée mathématiquement comme

$$G_{\Delta x, \Delta y}(i, j) = \sum_{x=1}^n \sum_{y=1}^m \begin{cases} 1 & \text{if } I(x, y) = z_i \text{ et } I(x + \Delta x, y + \Delta y) = z_j \\ 0 & \text{otherwise} \end{cases}, \quad (1.1)$$

où $(\Delta x, \Delta y)$ sont définis par l'opérateur Q, I est une image de taille $n \times m$.

1.4.2 Approches structurelles ou géométriques

Dans les approches structurelle ou géométriques deux principales composantes peuvent introduire une texture : l'unité initiale et sa disposition selon certaines règles d'organisation spatiale. Les unités initiales peuvent être simplement un pixel, une région ou une ligne. Tandis que leurs règles de disposition spatiale sont arrangées ensembles en calculant des relations géométriques où en examinant leurs propriétés statistiques. Autrement dit, les approches structurelles sont caractérisées comme étant une combinaison d'éléments de base texturé nommés texels ou primitives ou encore éléments structurants. Le texel représente le plus petite élément qui offre une surface texturée. Une fois que les texels sont détectés, leurs propriétaires statistiques sont calculés pour caractériser les textures (Zhang and Tan [2002b]).

Le bénéfice significatif des approches structurelles est de fournir une description symbolique ; toutefois, cette caractérisation est plutôt utile pour des tâches synthétiques qu'analytiques (Marterka et al. [1998]). Généralement, ces types des méthodes sont invariants aux illuminations et spécialement conçus pour les textures régulières, mais ils ne sont pas vraiment optimaux pour celles qui ont des degrés d'aléation et de variabilité des primitives (microtexture et macrotexture) avec l'absence d'une différence claire entre ces deux derniers, à titre d'exemple : les textures naturelles. Par ailleurs, Julesz [1962] a justifié d'après des études psychophysiques que les humains peuvent fortement discriminer ces textures avec différents éléments primitives. Basant sur d'autres études psychophysiques similaires (Tamura et al. [1978]), six importantes approximations informatiques des propriétés visuelles de la texture ont été développées telles que la grossièreté, le contraste, la directionnalité, la ressemblance des lignes, la régularité et la rugosité, connu sous le nom en anglais "Tarama texture features". Le tableau 1.2 illustre ces approximations informatiques. Plus tard, Zhang and Tan [2002b] propose des propriétés structurelles des motifs de la texture qui ont été utilisés et appliqués par plusieurs auteurs, parmi ceux qui sont les plus utilisés : l'intensité moyenne des éléments, la zone, le périmètre, l'excentricité, l'orientation, l'allongement, l'ampleur, la compacité, le nombre d'Euler, les moments, etc (Zhang and Tan [2002b]). Plusieurs méthodes exploitent ces propriétés dans leurs calculs telles que l'histogramme invariant, les descripteurs de texture topologique ou la décomposition morphologique.

1.4.3 Approches Fréquentielles ou spectrales

Plusieurs chercheurs psychophysiques ont prouvés que le système visuel humain à la capacité d'analyser les images par des informations de fréquence d'intensité et c'est également une

TABLEAU 1.2 – Principaux approximations informatiques des propriétés visuelles de la texture

Approximations informatiques des propriétés visuelle	Formule	Signification
Grossièreté	$\frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N S_{best}(i, j)$ $S_{best}(i, j) = 2^k$	Mesure la granularité de la texture. k : (k_{best}) qui maximise les différences entre les paires de moyennes mobiles non superposées
Contraste	$\frac{\mu_4}{(\sigma_2)^2}$ $\alpha_4 = \frac{\mu_4}{\sigma^4}$	Mesure les variations de niveaux de gris dans l'image. α_4 : kurtosis (la forme de la distribution (le degré de planéité)) μ_4 : 4ème moment autour de la moyenne et σ : la variance.
Directionnalité	$\sum_p^{n_p} \sum_{\theta \in w_p} (\theta - \theta_p)^2 H_D(\theta)$	tient compte de la force du bord et de l'angle directionnel. Des pics forts dans l'histogramme indiquent que l'image est hautement directionnelle. H_D : histogramme; p : pic; n_p : le nombre totale des pics
Ressemblance aux lignes	$\frac{\sum_i \sum_j P_{Dd}(i, j) \cos[i-j \frac{2\pi}{n}]}{\sum_i \sum_j P_{Dd}(i, j)}$	Ne concerne que la forme de la texture. La co-occurrence dans la même direction est pondérée +1, et celles dans la direction perpendiculaire par -1. P_{Dd} : Matrice de co-occurrence de points dans la direction locale $n \times n$.
Régularité	$F_r e g = 1 - r(\sigma_{crs} + \sigma_{con} + \sigma_{dir} + \sigma_{lin})$	Fait le traitement de la régularité des motifs répétitifs. $\sigma_{crs}, \sigma_{con}, \sigma_{dir}, \sigma_{lin}$: écart type de respectivement grossièreté, contraste, directivité, et ressemblance de ligne
Rugosité	$F_r g h = \sigma_{crs} + \sigma_{con}$	La grossièreté et le contraste se rapprochent d'une mesure de rugosité

caractéristique importante des textures (Tuceryan and Jain [1993]). En outre, les expériences psychophysiques de Campbell and Robson [1968] qui ont été réalisées sur diverses grilles de motifs, ont également démontrés que l'image dans le système visuel est décomposée en images filtrées de différentes fréquences et orientations. Particulièrement, la texture est adaptée à ce type d'approche à cause de ses propriétés. En effet, dans les approches fréquentielles ou spectrales ou encore du traitement de signal, les réponses extraites après avoir employé des filtres à l'image, doivent être enregistrées sous forme de caractéristiques de texture. Autrement dit, l'analyse fréquentielle traite les textures comme étant des répétitions d'éléments avec une fréquence donnée.

Les approches fréquentielles comportent les transformées de Fourier, les ondelettes, et les bancs de filtres. Ces différentes approches interprètent le contenu fréquentiel (ou spatial-fréquentiel) des textures au niveau : soit du domaine spatial uniquement (par exemple, les filtres orientables, les caractéristiques de lois), soit du domaine fréquentiel (Par exemple, transformé de Fourier Bracewell and Bracewell [1986]), ou du domaine fréquentiel et spatial (par exemple, filtres de Gabor Gabor [1946] et transformées en ondelettes Morlet [1983], Mallat [1989]). Pourtant, les masques dans le domaine fréquentiel sont plus populaires et efficaces dans la description des textures.

Dans un domaine spatial, les méthodes spectrales font la convolution entre les images de texture et les filtres spatiaux, de telle sorte d'extraire des informations de fréquence en se basant sur les mesures des variations dans les voisinages locaux. Généralement, dans les approches fréquentielles, les statistiques des réponses des filtres sont utilisées pour caractériser la texture. Ce domaine inclut : des filtres basés sur les contours; Robert's ou Sobel's (Rosenfeld [1976]), tentent de décrire la grossièreté des textures en fonction de la densité des contours. Dans un

autre travail, pour extraire des réponses locales à des motifs significatifs, Laws [1980a] a introduit un ensemble de neuf filtres de $5 * 5$ qui sont calculés en utilisant le produit de paire de vecteurs, la réponse moyenne et la combinaison des filtres sont utilisées comme caractéristiques de texture.

Freeman et al. [1991] ont conçu les filtres orientables qui sont une collection des filtres sélectifs d'orientation destinés à la texture orientée et obtenue à travers une combinaison linéaire de filtres de base comme la dérivée de Gaussian à 0° et 90° .

Dans l'analyse du domaine fréquentiel et spatial, la transformée de Fourier est appliquée à l'image et les caractéristiques sont calculées, soit par exemple, du spectre de puissance (Weszka et al. [1976]), ou de la réponse des filtres de Gabor qui a été présenté dans la même approche (Gabor [1946]), ou encore Gabor wavelets (GW) qui a été proposé dans (Manjunath and Ma [1996]) parmi les mesures de texture les plus populaires.

1.4.4 Approches basées sur les modèles

Les approches basées sur un modèle comme leur nom l'indiquent, utilisent un modèle avec des paramètres estimables ou probabilistes pour capturer ou extraire les qualités fondamentales d'une texture. Ces paramètres peuvent être utilisés comme caractéristiques ou pour synthétiser des textures aux propriétés souhaitées. Autrement dit, ils considèrent la texture comme une réalisation d'un processus aléatoire régit par des lois de probabilités et donc modélisent les textures par un nombre de paramètres restreints. Parmi les approches les plus populaires dans les méthodes basées sur un modèle ; les modèles de Markov et les fractales.

Les modèles de Markov utilisent les propriétés de Markov qui présument que l'état futur d'un système ne dépend que de l'état actuel. Tant dit que dans le contexte de l'image, c'est des dépendances locales des intensités de pixels. Markov random fields (MRFs) présume qu'il y a une dépendance entre l'intensité de pixels et ses voisins, qui permet d'extraire les contraintes contextuelles locales au but de modéliser l'image (Cohen and Cooper [1987]). Un MRF est un modèle graphique qui fait l'extraction du caractère de la texture à partir des paramètres qui sont estimés dans le but de mieux s'adapter à l'image en se basant sur une méthode d'optimisation qui minimise une fonction énergétique. Ce modèle forme un graphe non orienté accompagné des pixels ou des super-pixels comme variables aléatoires et avec des contours uniquement entre les pixels et super-pixels voisins. Toutefois, il y a une difficulté à déterminer la fonction énergétique et la méthode d'optimisation.

1.4.5 Approches hybrides

Cette approche est produite à partir d'une combinaison de deux ou plusieurs approches précédemment citées. Prenant l'exemple de la méthode de filtre de Gabor qui a été appliquée à la segmentation des textures en regroupant avec les matrices de co-occurrence des attributs statistiques du deuxième ordre (Clausi and Deng [2005]). Nous citons également à cet effet l'approche Local Binary Pattern (LBP) qui a été introduite par Ojala et al. [1996b] en faisant la combinaison de deux approches statistique et structurelle, plus de détails sur cette méthode sera présenté dans le chapitre suivant.

1.5 Un brève historique sur les descripteurs locaux de la texture

Dans la littérature sur l'analyse de texture, de nombreuses façons de regrouper des modèles sont proposées et discutées. Bien que ces catégories soient exceptionnellement approfondies, en raison d'avoir des modèles qui ont des propriétés de plusieurs groupes, tandis que d'autres n'appartiennent à aucun groupe. Toutefois, l'utilités de ces regroupements existe toujours au but de faciliter la compréhension de la variation des différents modèles. Comme déjà discuté et expliqué dans la section 1.4, Tuceryan and Jain [1993] a divisé les modèles de texture en quatre groupes : approches statistiques, approches structurelles ou géométriques, approches fréquentielle ou spectrales, approches basée sur les modèles.

Comme mentionné précédemment, en utilisant les méthodes d'analyse de texture, la détection du motif concernant l'arrangement structurel des surfaces dans les images devient évidente, cela permet de travailler dans une variété de problèmes d'analyse de texture avec une utilisation efficace notamment l'analyse d'images médicales (Rampun et al. [2017], Kaplan et al. [2020]), récupération de formes spectrales (Biasotti et al. [2014], Biasotti et al. [2016]), télédétection (Hajeb et al. [2020]), reconnaissance faciale et d'objets (Tang et al. [2020], Xiao et al. [2017], Zhang et al. [2009]), récupération et reconnaissance vidéo (Song et al. [2018b], Wang et al. [2016], Wang et al. [2017]), automatisation industrielle (Kurka and Salazar [2019]), la segmentation de la texture (Jain and Farrokhnia [1991], Cimpoi et al. [2015]), la synthèse de la texture (Efros and Leung [1999]), et classification de texture (Xiao et al. [2017], Song et al. [2018c]). Ces dernières années, de nouveaux aspects des applications qui utilisent l'apprentissage en profondeur sont également apparus (Tabatabaei and Chalechale [2019], Song et al. [2018a]).

Généralement, les algorithmes de reconnaissance d'objets peuvent s'appuyer sur des attri-

but visuels globaux pour décrire une image dans son ensemble. Les fonctionnalités globales ont la capacité de généraliser un objet entier avec un seul vecteur. Par conséquent, leur utilisation par exemple dans les techniques de la classification standard est simple. Tandis que les attributs visuels locaux représentent des patches d'image, et ils sont calculés à plusieurs endroits de l'image, ce qui les rend plus résistants à l'occlusion et à l'encombrement. Toutefois, la gestion des cas avec un nombre variable des vecteurs des caractéristiques par image peut nécessiter l'utilisation d'algorithmes de classification spécialisés. On outre, les descripteurs globaux peuvent être appliqués sur chaque patch local de l'image dans les descripteurs locaux ou employer des descripteurs spécifiquement conçus pour les régions locales.

Dans la classification des textures, nous pouvons observer que le rôle du choix d'une méthode d'extraction de caractéristiques de texture appropriée est beaucoup plus important pour obtenir des performances intéressantes que le rôle du classificateur. Généralement, il est nécessaire d'avoir plus de détails sur le motif dans la base de données de la texture, comme l'uniformité, la propreté et la distribution pour prendre une décision pour les méthodes appropriées. Ainsi, de nombreuses méthodes sont proposées dans la littérature par les chercheurs; dont les premiers travaux sur l'analyse de la texture remontent aux années 1970 lorsque Haralick et al. [1973] à suggéré une nouvelle méthode d'analyse de la texture appartenant à la catégorie statistique nommée GLCM, qui est l'une des méthodes couramment utilisées pour examiner les statistiques de second ordre entre les paires de pixels. La technique des Lois (Laws [1979, 1980a,b]) est arrivée sur le devant de la scène à la fin des années 1970 (qui était auparavant dominée par l'approche matricielle des co-occurrences) et a conduit à l'approche des composantes principales (Ade [1983]), qui a été développée par Dewaele et al. [1988], Unser and Eden [1989, 1990], et d'autres. L'approche de Laws a été particulièrement utile, car elle a démontré comment l'analyse de texture pouvait être mise en oeuvre simplement et d'une manière compatible avec des applications en temps réel comme l'inspection. Julesz [1981a] a inventé le terme "texton" au début des années 1980 pour souligner le rôle des micro-structures (c'est-à-dire les bords, les coins et les points) dans la perception humaine pré-attentive et la discrimination des textures.

Depuis le début des années 2000, Leung and Malik [2001] ont utilisé la distribution des réponses de filtres locaux pour caractériser l'information texturale en introduisant des banques de filtres "prédéfinies" avec des tailles et des orientations variables selon les régions locales. Lowe [2004] suggère le descripteur scale invariant feature transformation (SIFT), comme son nom l'indique, les caractéristiques SIFT sont des caractéristiques invariantes d'échelle. Elles sont extraites en quatre étapes et seules les caractéristiques filtrées sont passées à l'étape suivante. Les

opérations coûteuses ne sont appliquées qu'aux endroits qui réussissent un test initial. Dalal and Triggs [2005] a proposé un autre descripteur nommé Histograms of oriented gradients (HOG), utilisé pour la détection humaine. L'idée générale est de diviser la fenêtre d'image en petites régions spatiales (cellules), au niveau de chacune un histogramme 1D de la direction du gradient est construit. Le regroupement de tous les histogrammes des cellules dans un seul histogramme sert à caractériser HOG. En outre, nombreux avantages peuvent être obtenus en combinant HOG et SIFT tel que : la capture de la structure locale du bord ou du gradient et la facilité d'atteindre un degré contrôlable d'invariance aux transformations géométriques et photométriques locales. Malgré que SIFT fournit des performances importantes, il souffre d'une lente vitesse, afin de traiter cette problématique Bay et al. [2008] introduit un nouveau descripteur qui s'inspire des fonctionnalités de SIFT nommé Speeded Up Robust Features (SURF). Les fonctions SURF utilisent LoG avec un filtre Box pour approximer les échelles. Ensuite, la détection des points d'intérêt se fait en appliquant une approximation matricielle hessienne très basique. L'invariance d'orientation est obtenue en extrayant les réponses d'ondelettes dans les directions horizontale et verticale. Enfin, l'extraction du descripteur se fait en deux étapes.

Généralement, GLCM a un problème de fonctionnalités de dimensionnalité énormes même s'il fournit des performances importantes. Fernández et al. [2013] a proposé un histogramme de motifs équivalents (HEP) qui permet de diviser l'espace des caractéristiques en relation avec la région de l'image de taille et de forme prédéfinies. Certaines autres méthodes les plus connues dans la catégorie des approches statistiques sont : le filtrage de Gabor (Wang et al. [2019]), la fonction d'autocorrélation (Alder and Wainwright [1970]), le modèle de champ aléatoire de Markov (Cross and Jain [1983]), le modèle binaire local (Ojala et al. [1996a, 2002b]). Dans les approches structurales, les méthodes structurelles les plus populaires sont les variations d'énergie (Fang et al. [2019]), les filtres morphologiques (Boato et al. [2020]), la variation de texture basée sur les bords (Sathish et al. [2017]), les primitives de squelette et les caractéristiques d'ondelettes (Han et al. [2017]). Pour les approches basées sur des modèles, les modèles les plus utilisés sont : le modèle de champ aléatoire de Markov (Wan et al. [2018]), les modèles autorégressifs (Peng et al. [2018]). Et en fin dans les approches fréquentielles, nous trouvons : la transformée de Fourier (Kanwal et al. [2019]), transformation de Gabor (Singh et al. [2020]), transformations en ondelettes (Yang and Yang [2016]) et transformation Curvelet (Ramana et al. [2018]).

Revenant en 2002, le modèle local est apparu par Ojala et al. [1996a, 2002b], en tant que nouvelle approche d'extraction de caractéristiques appelée modèle binaire local (LBP). par sa simplicité, sa robustesse et sa rapidité de calcul, LBP a de bonnes chances d'attirer l'attention des

universitaires qui souhaitent concevoir leurs propres opérateurs locaux ; Dominant LBP (DLBP) ont été proposés par Liao et al. [2009] qui suppriment les informations qui se produisent rarement. Pour éliminer le bruit et obtenir des fonctionnalités plus complexes, Tan and Triggs [2010] a étendu le LBP d'origine de deux à trois valeurs de code nommé local ternary pattern (LTP). Guo et al. [2010a] a suggéré que Completed LBP (CLBP) est l'association de la magnitude CLBP-Magnitude et du signe CLBP-Sign avec un ajout du CLBP-Center qui contient les mêmes informations que LBP. Pour surmonter la forte sensibilité de CLBP au bruit et à la dimensionnalité, Liu et al. [2014] a proposé BRINT qui a fusionné trois descripteurs BRINT S, BRINT M et BRINT C. Liu et al. [2016] a proposé Median Robust Extended LBP (MRELBP) qui utilise des médianes d'image régionales plutôt que des intensités d'image brutes. il combine trois descripteurs MRELBP NI, MRELBP RD et MRELBP CI. Basé sur ELBP Hu et al. [2017] a proposé scale selective extended LBP (SSELBP) qui est créé à l'aide d'un filtre gaussien qui permet de générer un histogramme avec toutes les échelles dans l'espace d'échelle. Ils ont également utilisé une stratégie de mise en commun maximale pour obtenir une fréquence de cooccurrence importante de modèles et des caractéristiques d'histogramme invariantes à l'échelle. Généralement, ils présentent deux inconvénients importants dans les textures non uniformes spécifiquement pour la structure de classification des récifs coralliens qui ont un temps d'exécution élevé avec une faible précision, c'est pourquoi Shakoore and Boostani [2018a] présentent une nouvelle méthode de cartographie pour obtenir un nombre inférieur de fonctionnalités puissantes en fusionnant certaines fonctionnalités dans d'autres. Radial mean LBP (RMLBP) est suggéré par Shakoore and Boostani [2018b] pour résoudre le problème de sensibilité au bruit en utilisant la moyenne des points sur chaque radial au lieu d'employer des points voisins angulaires.

Récemment, en 2019, Ruichek et al. [2019] a introduit un nouveau descripteur de texture nommé Attractive-and-Repulsive Center-Symmetric Local Binary Patterns (ACS-LBP et RCS-LBP) qui réserve la caractéristique de LBP uniforme et génère de bonnes caractéristiques à la fois de gradient et opérateurs de texture fondés sur des caractéristiques attractives et répulsives locales. En 2020, Kas et al. [2020] a proposé de nouvelles variantes LBP nommées Multi Level Directional Cross Binary Patterns (MLD-CBP) basées sur la combinaison de concepts de direction et de rayon qui fournissent des informations multi-radiales et multi-orientations et ajoutent la moyenne de niveau de gris locale, qui permet d'extraire des informations plus pertinentes et d'obtenir des performances supérieures. Completed local shrinkage pattern (CLSP) présenté par Xu et al. [2020] pour résoudre le problème de haute dimensionnalité avec des caractéristiques peu discriminantes exploitant une fonction de rétrécissement pour présenter le modèle de rétré-

cissement local concaténé avec le codage des pixels centraux. Dans Tekin et al. [2020] quatre descripteurs ont été proposés directement pour les images couleur référencées par des motifs binaires locaux de gauche à droite (LBP_{L2R}), des motifs binaires locaux de haut en bas (LBP_{T2D}), la surface du cube motif binaire local ($LBP_{Surfaces}$) et motif binaire local en diagonale de cube ($LBP_{Diagonal}$). En 2021, Pan et al. [2021] ont proposé une nouvelle qui est une sélection adaptative de pixels centraux (ACPS) essayant de surmonter la diminution des caractéristiques de texture à partir de motifs non uniformes. Il est basé sur l'utilisation de candidats de pixels centraux pour sélectionner plus d'informations de texture, d'informations de gradient pour acquérir une image de bord et d'un candidat de pixel central optimal pour prendre en compte les motifs non uniformes ignorés aux points de bord. En raison de la fixation de la fonction de distribution cumulative (CDF) qui était trop sensible au bruit. Shakoor and Boostani [2021] a suggéré une transformation de distribution locale (LDT). Pour chaque patch local dans une image, LDT tente d'approximer la CDF.

Plus de détail sur LBP et ces variantes seront représentés dans le chapitre 2.

1.6 Les bases de données d'images de la texture

Généralement, les chercheurs évaluent l'efficacité de leur algorithme proposé à l'aide des bases de données standard, y compris l'image de la texture. Ces images ont des caractéristiques appropriées pour évaluer les systèmes et les algorithmes proposés. Nombreuses base de données destinés à la texture ont été proposées dans la littérature telles que : *Outex* (Ojala et al. [2002a]), *Brodatz* (Brodatz [1966]), *Vistex* (Vis [2002]), *UIUC* (Lazebnik et al. [2005]), *DTD* (Cimpoi et al. [2014]), *CURet* (Dana et al. [1999]), etc.

Nous allons conclure ce chapitre en décrivant les six bases de données qui ont été utilisées dans cette thèse. La première base de données de la texture est celle de l'université d'Oulu (*OUTEX* Ojala et al. [2002a]) qui inclue une collection de surfaces et de scènes naturelles de la texture. La deuxième base de données est *KTH-TIPS* (Fritz et al. [2004], Mallikarjuna et al. [2006]) (Textures sous illumination, pose et échelle changeantes), *KTH* est l'abréviation d'une université, cette base de données d'images a été créée pour étendre le *Columbia-Utrecht Reflectance and Texture* (CURet). *CURet* (Dana et al. [1999]) est le *Columbia-Utrecht*, c'est une collection de 61 surfaces du monde réel avec un large éventail de caractéristiques géométriques et photométriques. La troisième base de données est Brodatz (Brodatz [1966]) est l'un des ensembles de données les plus populaires et polyvalents qui incluent la texture naturelle fournie par Brodatz via photographie

scannée après impression. La quatrième base de données est *University of Maryland, College Park* (UMD), c'est un ensemble de données de texture à haute résolution. La cinquième base de données est *Gaofen Image Dataset* (GID) (Tong et al. [2020]) est une base de données de télédétection à haute résolution spatiale (*high spatial-resolution remote sensing* (HRRS)) proposée pour classer les images HRRS non étiquetées à l'aide d'un modèle profond dérivé de la couverture terrestre de l'étiquette. La dernière base de données est *large-scale aerial* (AID) (Xia et al. [2017]) est un ensemble de données d'images aériennes à grande échelle. Ces différentes bases de données sont généralement utilisées pour tester la performance de nos algorithmes proposées dans les chapitres 3, 4, 5.

1.6.1 OUTEX

L'ensemble de données *Outex* parmi les ensembles les plus populaires et les plus volumineux, il a été proposé par Ojala et al. [2002a] de l'université d'Oulu en 2002. C'est une base qui contient une collection des images de texture de scène naturelle et de surface. Cependant, la collection de textures de surface est régulièrement élargie. Récemment, la base de données contient 320 textures de surface, macro et micro-textures.

Nombreuses textures dans *OUTEX* contiennent des variations au niveau du contenu de couleur local, ce qui entraîne des défis dans les variations des niveaux de gris local dans l'intensité des images. Certaines textures ont une grande dimension tactile, ce qui peut induire des distorsions locales considérables de niveau de gris.

Chaque texture utilise trois différents illuminants simulés fournis dans la source lumineuse : la lumière du soleil d'horizon 2300K connue par "*horizon*", la CIE A incandescente 2856K désignée par "*inca*" et enfin Fluorescent 4000K *TL84* dénoté par "*TL84*". Chaque texture est capturée en utilisant six résolutions spatiales (100, 120, 300, 360, 500 et 600 dpi) et neuf angles de rotation (0, 5, 10, 15, 30, 45, 60, 75 et 90). En générale, *OUTEX* inclut trois types basiques de suites de tests : la classification de texture ("*TC*"), la segmentation supervisée de texture ("*SS*") et la segmentation non supervisée de texture ("*US*"). Dans cette thèse, nous mentionnons uniquement les suites de tests destinés à la classification. Parmi les différentes suites de test pour la classification des textures, nous utilisons *Outex_TC_10*, et *Outex_TC_12*. Ces deux suites de tests contiennent les mêmes nombres et types de classes de texture qui sont 24 (voir la figure 1.8). Chaque classe de suite de test contient 180 images de texture capturée sous neuf angles de rotation (0, 5, 10, 15, 30, 45, 60, 75 et 90) avec une taille de 128×128 pour chacune. La

différence entre les deux types de base de données *OUTEX* est l'illumination de telle sorte la base *Outex_TC_10* est capturé sous "Inca", tandis que *Outex_TC_12* sous "Horizon" et "TL84"

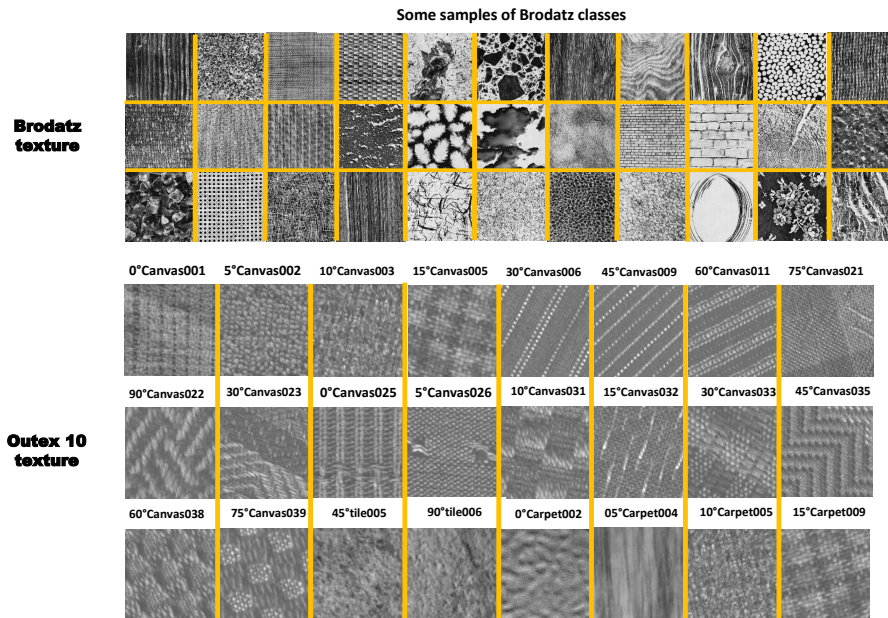


FIGURE 1.8 – Quelques exemples d'images de la base de données *Brodatz* et 24 échantillons de classe de la base de données *Outex*.

1.6.2 *KTH-TIPS2-b*

KTH-Textures under varying Illumination, Pose and Scale (*KTH-TIPS*) (Fritz et al. [2004]), avec *KTH* est l'abréviation de l'université. *KTH-TIPS* est une base qui a été créée pour étendre la base de données *CUReT* dans deux directions, en fournissant des variations d'échelle ainsi que de pose et d'éclairage, ainsi qu'en imageant d'autres échantillons d'un sous-ensemble de ses matériaux dans différents contextes. A partir de 61 images classes dans *CUReT*, *KTH-TIPS* inclue 10 images de classe de texture capturées à 9 échelles différentes et 9 conditions d'éclairage différentes, c'est-à-dire $9 * 9 = 81$ images par classe d'une taille 200×200 .

La base de données *KTH-TIPS2* (Mallikarjuna et al. [2006]) est une extension de la base *KTH-TIPS* qui considère quatre échantillons différents de 11 matériaux, chacun sous une pose, un éclairage et une échelle variables. Cette base de données inclut deux versions, *KTH-TIPS2-a* qui ne contient pas le même nombre d'images pour chaque échantillon (40 échantillons sur 44 comporte 108 images, tandis que 4 échantillons ne contiennent que 72 images). *KTH-TIPS2-b*

contient également ces images "manquantes".

kth-tips-2b (Hayman et al. [2004], Caputo et al. [2005]) est principalement conçue pour évaluer l'impact des conditions d'imagerie réelles sur la classification des matériaux. Le *KTH-TIPS2b* inclut 10 catégories issues de la base de données *CURET* et ajoute une nouvelle classe de changements de rotation et de directions d'éclairage. Ceux-ci contiennent quatre échantillons physiques de 11 matériaux différents. Chaque échantillon contient 108 images d'une taille 200×200 , en totale on a 4752 images, chacune avec 10 échelles, quatre illuminants, trois angles de vue. Quelques exemples de l'ensemble de données avec différentes échelles sont présentés dans la figure 1.9.

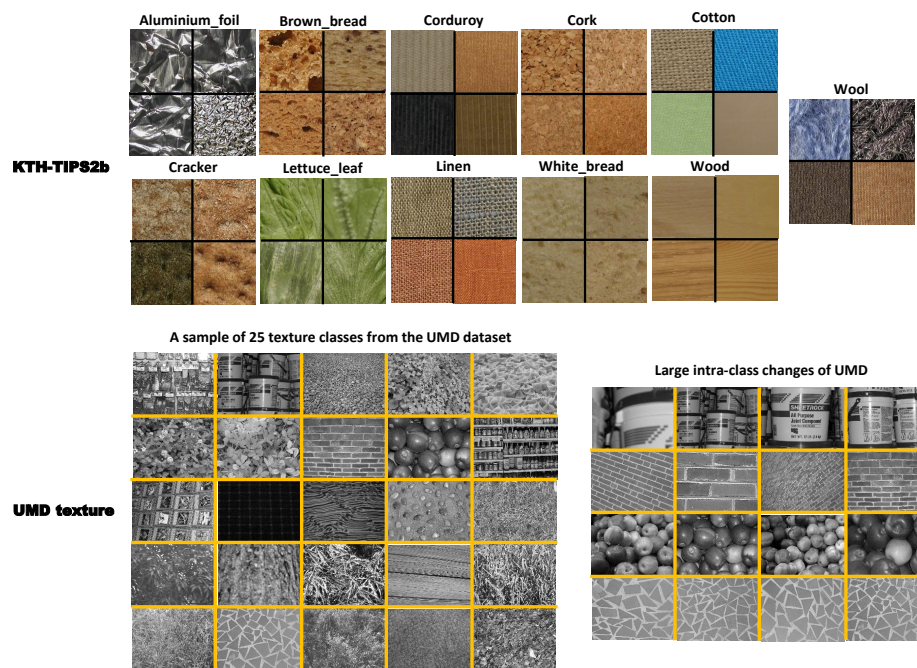


FIGURE 1.9 – Exemples de classes d'images de la base de données *KTH-TIPS2b* et 25 exemples de classes des bases de données *UMD*.

1.6.3 Brodatz

La base de données de texture *Brodatz* (Brodatz [1966]), bien que relativement ancienne et standard, elle est encore largement utilisée aujourd'hui. Les texture *Brodatz* sont populaires et largement utilisées dans la classification des textures. elle se composent de 112 classes d'images

de taille 512×512 , et chaque classe comprend une image de texture en niveaux de gris, qui est partitionnée en neuf sous-images non chevauchantes. *Brodatz* se caractérise par un éclairage et des directions de vision uniques. La figure 1.8 montre une poignée d'images de *Brodatz*.

1.6.4 UMD

University of Maryland, College Park (UMD) (Xu et al. [2006]) est une base de données de texture à haute résolution. Cette base de donnée à haute résolution se compose de 25 classes avec 40 images dans chaque classe, chacune avec une variété d'échelles, des rotations arbitraires et des changements de point de vue. Du fait de la haute résolution des images (1280×960), *UMD* est la base de données la plus exigeante. La figure 1.9 illustre un exemple de base de données de texture *UMD*.

1.6.5 GID

Les images satellites *GID* (Tong et al. [2020]) sont une base de données de télédétection à haute résolution spatiale (HRRS) proposées pour classer les images HRRS non étiquetées à l'aide d'un modèle profond dérivé de la couverture terrestre des étiquettes. Généralement, *GID* surpasse l'ensemble de données de couverture terrestre précédent en raison d'une couverture énorme, d'une large distribution et d'une résolution spatiale élevée. Les *GID* comprennent deux test Labeled : une classification à grande échelle et une classification fine d'occupation du sol. *GID* contient 30000 patchs d'images multi-échelles de taille $56 \times 56 \times 3$ pouvant être étiquetés à la fois pour la couverture terrestre fine et à grande échelle avec des données de formation et de validation de classification de 15 et 5 classes. La figure 1.10 présente des exemples d'images de *GID*.

1.6.6 AID

AID (Xia et al. [2017]) est un ensemble de données d'images aériennes à grande échelle. Il s'agit de l'un des nombreux ensembles de données de scènes en télédétection *-remote sensing* (RS)- collectées à partir d'images Google Earth. Leur résolution spatiale est inférieure à 1 mètre et tous les capteurs ont des bandes panchromatiques, tandis que la plupart ont des bandes proche infrarouge. Ils disposent de 10000 images de taille 600×600 . La figure 1.11 illustre des exemples d'images de *AID* au niveau de chaque classe.

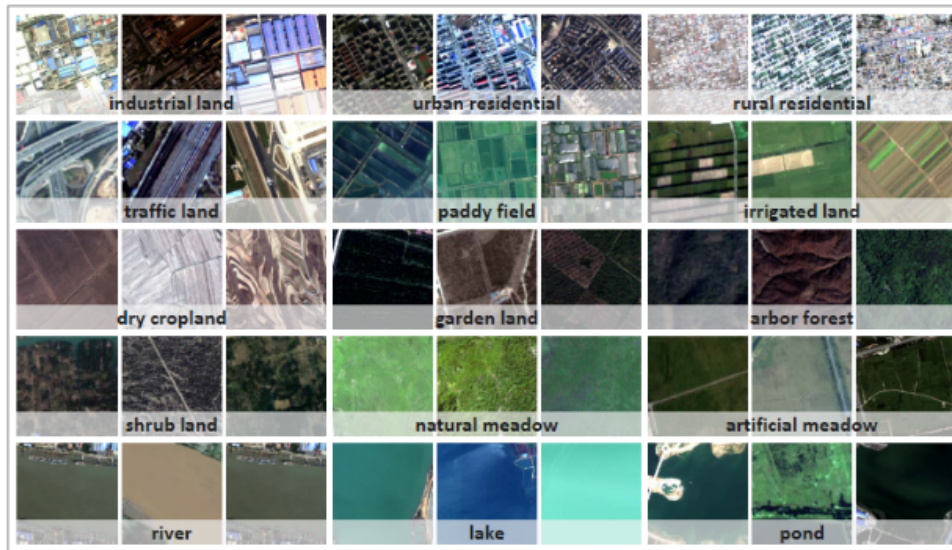


FIGURE 1.10 – Quelques exemples d’images de la base de données *GID* Tong et al. [2020].

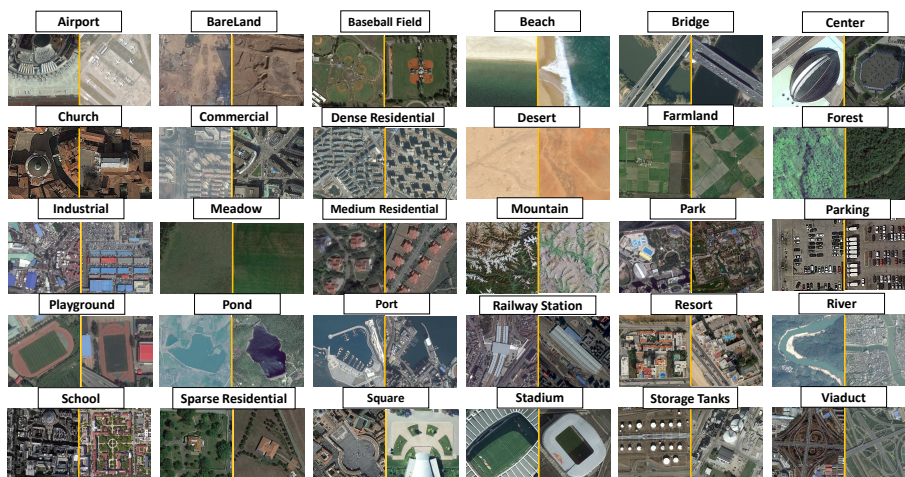


FIGURE 1.11 – Quelques exemples d’images de chaque classe de la base de données *AID*.

1.7 Conclusion

À travers ce chapitre, nous avons fourni un regard approfondi sur ce qui a été fait dans la littérature concernant l’analyse texturale des images : des notions de base sur la texture, les méthodes d’analyse de la texture, leurs domaines d’applications, etc. Nous avons constaté que malgré la diversité des méthodes d’analyse de la texture, aucune ne peut être considérée comme étant un modèle généralisé adapté à tout type de texture. Cela est dû principalement au fait

qu'il n'existe pas une définition précise et rigoureuse de la notion de texture. De plus, le choix des caractéristiques de texture est un point délicat, puisqu'il dépend de plusieurs facteurs.

Bien que plusieurs efforts aient été récemment déployés pour améliorer le descripteur de fonctionnalités de bas niveau, il reste encore un domaine de recherche ouvert. L'extraction des meilleures caractéristiques est une étape cruciale pour améliorer les performances de classification conduisant à un système robuste à ces défis (comme l'invariance à l'éclairage, à la rotation et à la résolution spatiale). L'extraction d'une caractéristique d'image peut être classée en deux catégories : les caractéristiques globales qui représentent les informations de texture, de couleur et de forme qui sont les plus populaires pour la représentation d'images. À la différence des caractéristiques globales, les caractéristiques locales visent à détecter les points d'intérêt (PI) dans une image et à les décrire par un ensemble de vecteurs.

Récemment, de nombreux chercheurs se sont concentrés sur l'extraction des caractéristiques PI, de texture et de couleur d'une image. Parmi les méthodes d'analyse proposées dans la littérature, l'approche LBP est un descripteur de texture simple et puissant qui décrit les attributs locaux de la texture combinant des propriétés statistiques et structurelles. LBP est très intéressante en raison de ses nombreux avantages, notamment la facilité de la mise en oeuvre, l'invariance aux changements d'éclairage monotones, l'invariance à la rotation et la faible complexité informatique. Sur des bases de données de textures typiques, des résultats de classification impressionnants sont obtenus.

Le succès significatif de LBP dans le domaine de vision par ordinateur et dans la reconnaissance des formes, a amené LBP à attirer l'attention des chercheurs désireux de créer leurs propres opérateurs locaux en développant d'autres variantes pour améliorer la capacité de discrimination ainsi que la robustesse au bruit de LBP. Dans cette thèse, nous proposons de nouvelles variantes de LBP. En conséquence, le chapitre suivant se concentrera sur les méthodologies LBP et leurs principales versions.

LES DIFFÉRENTES MÉTHODES DE L'ANALYSE DE LA TEXTURE PAR LBP

Sommaire

2.1	Introduction	39
2.2	La méthode (LBP) de base	39
2.3	Mapping LBP	42
2.3.1	Modèle LBP uniforme $LBP_{R,P}^{u2}$	43
2.3.2	Modèle LBP invariant à la rotation $LBP_{R,P}^{ri}$	44
2.3.3	Modèle LBP uniforme et invariant à la rotation $LBP_{R,P}^{riu2}$	45
2.4	Multi-échelles LBP	47
2.5	Les variantes du LBP	47
2.5.1	topologie de voisinage et échantillonnage	48
2.5.2	seuillage	52
2.5.3	codage et regroupement	56
2.5.4	combinaison avec d'autres approches	59
2.6	Classification de la texture	62
2.6.1	k-Plus Proches Voisins	63
2.6.2	Machine à Vecteurs de Support	65
2.6.3	Réseaux de Neurones	67
2.6.4	Techniques d'évaluation de la performance d'un système de classification	68
2.6.4.1	Validation croisée	69
2.6.4.2	Validation croisée en k parties	69
2.6.4.3	Leave-one-out	71
2.6.4.4	Hold-out	71
2.6.4.5	Mesures Quantitatives	71

2.1 Introduction

Dans le chapitre précédent, de nombreux types de descripteurs de texture ont été discutés. L'usage d'un descripteur de texture ou d'une combinaison de descripteurs a pour objectif de présenter la texture sous forme numérique, mettant l'accent sur les qualités distinctives de la texture. Toutefois, à cause des changements de direction, d'échelle, d'éclairage et d'autres considérations, les motifs de texture ne sont souvent pas uniformes. Pour cette raison, l'invariance de niveau de gris et l'invariance de rotation, ainsi que la complexité de calcul, sont des caractéristiques importantes pour que les descripteurs de texture réussissent.

Parmi divers descripteurs, la représentation binaire, également appelée descripteur de texture binaire local, est l'une des méthodes de représentation de texture les plus largement utilisées. Le descripteur de texture binaire local, qui est discriminant, invariant à l'éclairage et efficace en matière de calcul, traduit les différences d'intensité entre des paires de pixels voisins en valeurs binaires. Ces bénéfices des descripteurs binaires permettent des applications intéressantes, y compris la différenciation des types de texture avec LBP (Ojala et al. [2002c]), qui sont apparues comme l'une des classes de caractéristiques de texture les plus importantes et les plus étudiées, de telle sorte qu'un grand nombre de variantes de LBP a été présenté pour une gamme variée de problèmes, y compris la classification des textures.

L'originalité de l'opérateur LBP est exposée dans ce chapitre avec une explication détaillée du mécanisme de réduction de sa taille d'origine, en ajoutant d'autres extensions comme l'uniforme et l'invariant par rotation. Ensuite, un certain nombre de variations de l'opérateur de la texture LBP les plus courantes et les plus populaires sont examinées et décrites en détails. Enfin, le chapitre se clôt par l'exposition des différents classifieurs utilisés pour la classification des images.

2.2 La méthode (LBP) de base

Le LBP original a été proposé pour la première fois par Harwood et al. [1995] comme mesure complémentaire du contraste local de l'image en 1995, puis il est réapparu dans une étude comparative (Ojala et al. [1996b]). En 2002, l'introduction des descripteurs $LBP_{r,p}^{ri}$, $LBP_{r,p}^{u2}$ et $LBP_{r,p}^{riu2}$ (Ojala et al. [2002c]) remonte, et depuis cette année, le LBP a commencé à susciter un large intérêt de la part de la communauté des chercheurs et il a ainsi émergé avec les efforts




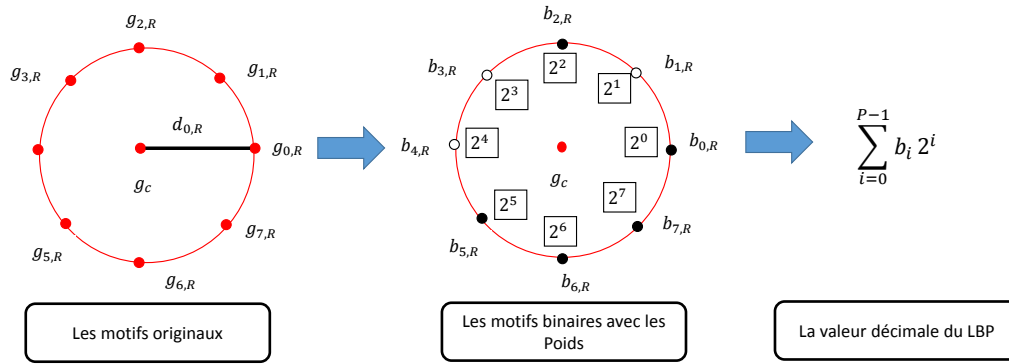

FIGURE 2.1 – Illustration du calcul des motifs LBP .

continus de développement d'un descripteur de caractéristiques locales expressives.

Généralement, le LBP est un descripteur non paramétrique, il combine les paramètres statistiques et structurels : il décrit la texture avec des micro-primitives et leurs règles statistiques de placement. Précisément, il traite l'image texturée à l'aide d'une fonction noyau particulière, qui constitue la relation statistique entre les voisins et le centre et permet de calculer la valeur de transformation en capturant des modèles structurels locaux en convertissant une image en label numérique (nombre décimal). La simplicité, la robustesse et la rapidité de ce calcul ont amené LBP à attirer l'attention des chercheurs à l'utiliser, testé et vérifié dans de nombreuses applications telles que l'analyse d'images de visage, la récupération d'images, la classification de texture.

L'approche LBP originale n'avait aucune étape de pré-traitement et la fonction LBP est extraite directement de l'image. La première incarnation de l'opérateur LBP fonctionnait avec les huit voisins d'un pixel pris dans un voisinage carré de 3×3 pixels, en utilisant la valeur du pixel central comme seuil, et en ne considérant que les informations du signe pour former le code binaire. Un code LBP pour un voisinage a été produit en multipliant les valeurs seuillées (valeurs binaires) par les poids donnés aux pixels correspondants, et en additionnant le résultat (figure 2.1). Ensuite, l'histogramme est généré à partir des codes LBP. Par conséquent, chaque image est présentée par un vecteur caractéristique. Cette méthode produit 256 motifs de texture.

Un pixel central c est le noyau de matière du LBP et c'est n'importe quel pixel de l'image. Cependant, le pixel sur la bordure de l'image n'est pas considéré comme un pixel central car il n'est pas complètement recouvert par un cercle de pixels (figure 2.2a). Dans la forme de cercle, les pixels voisins sont positionnés de telle sorte que ceux qui n'appartiennent pas au cercle du pixel centre g_c (initialement le bloc est carré) soient estimés par l'interpolation bilinéaire. En outre, un voisinage de différentes tailles (variations du rayon R et du nombre de pixels voisinage

(a) Un type de voisinage typique (R, P) utilisé pour dériver un opérateur de type LBP

(b) Trois voisinages de différent tailles du LBP. Mäenpää and Pietikäinen [2005]

FIGURE 2.2 – La formulation circulaire du LBP

P) a été introduit afin de calculer les caractéristiques LBP pour toute quantification de l'espace angulaire et pour toute résolution spatiale, qui permet d'inclure les informations de texture à différents échelles (figure2.2b).

Formellement, étant donné un pixel d'image c , le code LBP généré en c est calculé en comparant la valeur de niveaux de gris g_c du pixel avec les valeurs de gris g_i de ses p voisins g_0, \dots, g_{p-1} , l'équation mathématique qui décrit le code LBP est définis comme suit :

$$LBP_{R,P} = \sum_{i=0}^{P-1} s(g_i - g_c) 2^i, s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}, \quad (2.1)$$

d'où g_c et g_i représentent respectivement le pixel central et ses voisins ($i = 0, \dots, P-1$) qui sont équidistants sur un cercle de rayon R ($R > 0$), P est le nombre de voisins et $s()$ est

la fonction de signe qui garantit que le code LBP soit invariant contre toute transformation monotone de la luminosité de l'image. De plus, les coordonnées des voisins g_i sont données dans un image numérique par $x_c + R \cos(2\pi p/P)$, $y_c + R \sin(2\pi p/P)$ d'où (x_c, y_c) sont les coordonnées du pixel central. Étant donné que la corrélation entre les pixels diminue avec la distance, une grande partie des informations de texture d'une image peut être obtenue à partir des voisinages locaux.

Dans une image de texture I , chaque bloc de l'image est caractérisé par un motif binaire $LBP_{R,P}$, qui va être calculé pour chaque pixel c par l'équation 2.1. Le regroupement des motifs LBP va caractériser une image texturée, qui va être représentée par un vecteur d'histogramme h comme suit :

$$h(I) = \sum_{x,y} F(LBP(x,y) = I) \quad (2.2)$$

$$\text{Avec } I \in [0, \dots, 2^P - 1] \text{ et } I(\alpha) = \begin{cases} 1 & \text{si } \alpha \text{ est vrai} \\ 0 & \text{autrement} \end{cases},$$

Bien que les bénéfices distinctifs du LBP soient nombreux (tels que la faible complexité du calcul, l'invariant aux changements d'éclairage, et la facilité la mise en oeuvre), il existe des inconvénients significatifs qui sont associés au LBP d'origine, tels que : la longueur de l'histogramme qui est extrêmement volumineuse même pour les petits quartiers, ce qui implique une diminution du caractère distinctif et des besoins de stockage importants. La perte des informations liée à la structure texturale dans les grandes échelles est de capturer juste ceux qui sont très locaux. La perte d'information de texture locale à cause de l'utilisation de seulement les signes de différences de pixels voisins. La sensibilité à la rotation de l'image avec une importance sensibilité au bruit : un moindre changement des valeurs de pixels par rapport à celle du centre entraîne un contraste important. Pour remédier à ces limites, Ojala et al. [2002c] définissent trois premiers modèles : les modèles uniformes, les modèles invariants en rotation et les modèles uniformes invariants en rotation.

2.3 Mapping LBP

Ojala et al. [2002c] ont proposés trois applications de LBP : Uniforme, invariant à la rotation, et invariant à la rotation uniforme. Le "mapping" uniforme de LBP réduit la longueur des




FIGURE 2.3 – Textures particulières détectées par LBP^{u2} . Mäenpää and Pietikäinen [2005]

caractéristiques de LBP, tandis que "mapping invariant à la rotation est non seulement utile pour la réduction mais également pour les données de textures tournantes.

2.3.1 Modèle LBP uniforme $LBP_{R,P}^{u2}$

Les codes binaire créés par LBP représentent des motifs dans l'image. Généralement, Certains motifs binaires sont plus importants que d'autres, parce que ces motifs capturent des primitives plus importantes que d'autres. En outre, certains de ces motifs ne capturent aucune primitive et peuvent être produits par le bruit d'autres motifs, comme illustré à la figure 2.3.

Parmi les motifs binaires, nous trouvons ceux qui sont des propriétés fondamentales de la texture et qui peuvent parfois avoir une fréquence qui dépasse 90%, ces motifs sont dits uniformes. Cette catégorie des motifs est définie par une mesure d'uniformité qui correspond à une transition spatiale (c'est-à-dire le nombre de transitions d'un à zéro ou vice-versa, est inférieur ou égal à deux). Il existe une autre catégorie des motifs qui est le non-uniforme des motifs qui a l'indice d'uniformité supérieur à deux (c'est-à-dire les transitions sont plus de deux).

Généralement, la notion d'uniformité est importante dans la méthode LBP pour représenter les informations primitives structurelles comme les arêtes (coins) et les contours. Les motifs uniformes sont considérés comme étant plus influents que d'autres. Formellement, l'équation mathématique qui calcule le modèle uniforme du code LBP est indiquée comme suit :

$$U(LBP_{R,P}) = \sum_{i=1}^P |s(g_{\text{mod}(i,P)} - g_c) - s(g_{i-1} - g_c)|, \quad (2.3)$$

où la fonction $\text{mod}(i, N)$ est le modulo de i à N . A partir de cette équation, $U(LBP_{R,P}) > 2$ fait référence à des motifs non-uniformes, qui sont classés dans un seul groupe, ce qui entraîne une réduction significative de dimension, de 2^P motifs de LBP original à $P(P - 1) + 3$.

Ojala et al. [2002c] ont trouvé que seulement 58 des 256 motifs LBP sont uniformes puisque dans d'autres recherches il a été démontré que la plupart des motifs dans les images de la texture sont uniformes. Par conséquent, la dimension de l'histogramme peut être réduite de manière importante avec une perte d'information. C'est pour ça les 58 devienne 59 motifs de LBP, de telle sorte que les 58 premières catégories représentent le nombre d'occurrences de l'un des motifs uniformes, tandis que la dernière contiendra le nombre d'occurrences de tous les motifs non-uniformes, ce qui permet de réduire la dimension du descripteur et en même temps de garder la plupart des informations qu'en a besoin.

2.3.2 Modèle LBP invariant à la rotation $LBP_{R,P}^{ri}$

Parmi les modèles proposés dans Ojala et al. [2002c] est l'invariant par rotation qui a une caractéristique significative dans le modèle LBP. Dans le but d'obtenir l'invariante à la rotation, Les différents codes LBPs qui ont le même motifs avec un effet de rotation sont regroupés ensembles dans un seul groupe. Autrement dit, l'invariance à la rotation du LBP, $LBP_{P,R}^{ri}$ est facile à acquérir en tournant de manière circulaire le code binaire généré par LBP vers la droite jusqu'à ce qu'on obtient la valeur minimale des motifs binaires, ce fonctionnement est appelé un décalage au niveau du bit, c'est à dire en décalant la structure binaire de manière à aboutir à une séquence d'un nombre maximal de 0 au début. Par exemple, si le code binaire 11110100 est décalé en 11101001 puis en 00111101, c'est ce dernier code qui sera pris en considération puisqu'il contient la plus petite valeur de LBP.

Mathématiquement, les codes LBP invariant à la rotation sont générés en implémentant la fonction de décalage au niveau du bit comme indiqué dans l'équation suivante :

$$LBP_{R,P}^{ri} = \min\{ROR(LBP_{R,P}, i) | i = 0, 1, \dots, P - 1\} \quad (2.4)$$

où $ROR(x, i)$ est une fonction de décalage des bits, dont i décalages circulaires est effectué vers la droite au niveau du bit sur la chaîne binaire du motif x . En outre, dans l'utilisation de l'invariant à la rotation, le nombre des motifs produits sont réduits de 256 (LBP normal avec $P = 8$) à 36 motifs différents pour $P = 8$, où les motifs de la première rangée sont considérés comme des motifs uniformes comme illustré dans la Figure 2.4. Par exemple, la détection des tâches claire est faite par le motif "0", tandis que les tâches sombres et les surfaces monotones sont faites par le motif "8", le motif "3" les coins et le motif "4". les contours.

Dans $LBP_{R,P}^{ri}$, si la valeur du rayon renvoie 1, le $LBP_{R,P}^{ri}$ ressemble au descripteur LBP_{ROT} ,




FIGURE 2.4 – Le modèle LBP invariant à la rotation.

qui a été proposé par Pietikäinen et al. [2000], qui ont aussi déjà montré sa faiblesse d'obtenir de bonnes performances. La principale raison est que l'occurrence des fréquences de certains des 36 motifs possibles varie fortement (instabilité). Afin de régler cette limite, une mesure est effectuée sur les motifs afin de déterminer s'ils sont uniformes. Pour cette raison, une autre variante a été proposé dans le même papier qui regroupe l' uniforme avec l'invariante à la rotation.

2.3.3 Modèle LBP uniforme et invariant à la rotation $LBP_{R,P}^{riu2}$

Afin d'obtenir une version améliorée de l'invariance à la rotation avec une réduction de la dimensionnalité des caractéristiques, Ojala et al. [2002c] ont suggéré dans le même travail le modèle uniforme et invariant à la rotation $LBP_{R,P}^{riu2}$ qui se concentre sur la combinaison entre $LBP_{R,P}^{u2}$ et $LBP_{R,P}^i$ de telle sorte que tous les modèles binaires qui ont plus de 2 uniformités sont regroupés dans un seul groupe, ce qui implique dans le résultat final 10 groupes possibles, comme le montre la figure 2.5.

Formellement, le descripteur $LBP_{R,P}^{riu2}$ est défini comme suit :

$$LBP_{R,P}^{riu2} = \begin{cases} \sum_{i=0}^{P-1} s(g_i - g_c)2^i, & \text{if } U(LBP_{R,P}) \geq 2 \\ p + 1 & \text{otherwise} \end{cases}, \quad (2.5)$$

où U représente le modèle LBP uniforme qui est donné dans l'équation 2.3. Le $LBP_{R,P}^{riu2}$ classe tous les 2^p LBPs dans $p+2$ groupes distincts, ce qui permet d'obtenir une dimensionnalité des caractéristiques significativement plus faible.

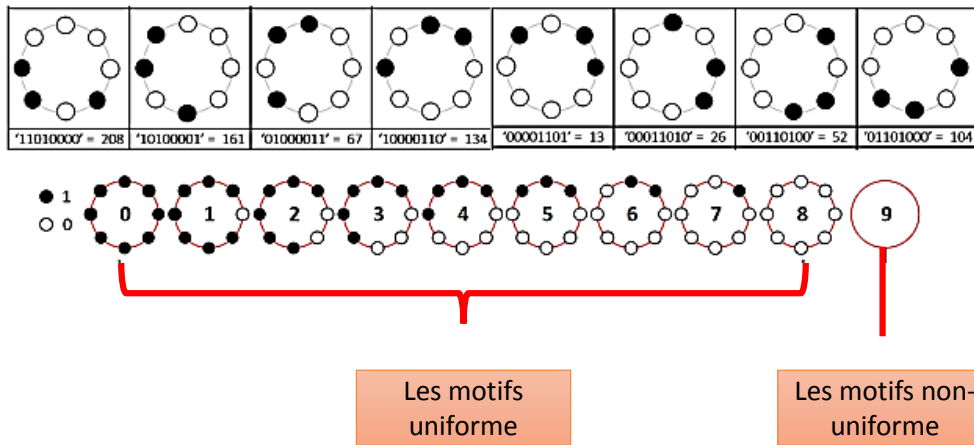


FIGURE 2.5 – Les 10 modèles uniformes et invariants en rotation définis pour $P=8$. Les cercles noirs et les cercles blancs correspondent respectivement à la valeur binaire 0 et 1 dans le code LBP

le modèle $LBP_{R,P}^{ri}$ a les mêmes limites que LBP normale ou originale, à l'exception d'un certain niveau d'invariance de rotation. Malheureusement, l'application du descripteur $LBP_{R,P}^{ri}$ dans le problème de la classification des images de texture a atteint des mauvaises performances (Pietikäinen et al. [2000], Ojala et al. [2002c]).

Comme déjà mentionné, la dimension des caractéristiques extraite par $LBP_{R,P}^{riu2}$ est beaucoup plus faible en comparant avec les autres modèles LBP soit l'original ou l'invariant à la rotation. Par exemple, pour le cas de huit voisins, il existe neuf codes LBP uniformes invariants par rotation, deux sans aucun changement de 0-1 et les sept autres sont les mêmes nombres de 1 à 7 présentés dans la figure 2.4. Alors que LBP génère 256 modèles pour 8 quartiers, $LBP_{R,P}^{ri}$ génère 36 modèles, LBP^{u2} génère 58 modèles uniformes et LBP^{riu2} donne 9 modèles pour le même quartier. Dans le cas de motifs uniformes et invariants en rotation, tous les motifs non uniformes sont résumés dans un seul bac pour la description de la texture.

Nombreuses extensions et modifications de LBP seront abordées dans les sections suivantes, s'appuyant sur la stratégie LBP fondamentale, cherchant à augmenter la robustesse, à améliorer le pouvoir discriminatif et à éviter les inconvénients des méthodes LBP traditionnelles.

2.4 Multi-échelles LBP

L'un des limites significatives de l'opérateur d'origine LBP est sa représentation par une petite zone de support spatial. Dans les types de voisinage local 3×3 du LBP, les caractéristiques calculées ne peuvent pas capturer les structures à grande échelle qui représentent des caractéristiques dominantes dans certaines textures. Cependant, les codes LBP adjacents ne sont pas totalement indépendants les uns des autres. En outre, chaque code LBP limite ainsi l'ensemble des codes possibles qui lui sont adjacents, ce qui rend la "zone effective" d'un seul code en fait légèrement supérieure à 3×3 pixels. Néanmoins, l'opérateur est peu robuste vis-à-vis des modifications locales de la texture, provoquées par exemple par des variations de points de vue ou de directions d'éclairage. Un opérateur avec une plus grande surface d'appui spatial est donc souvent nécessaire.

Un moyen simple d'élargir la zone de support spatial consiste à extraire plusieurs codes LBP de voisinages concentriques, en utilisant une variété de valeurs du voisinage P et du rayon R (figure 2.2b). Dans le cas de capturer la fonction LBP à différentes échelles, seul le rayon qui doit être varié. Pour chaque augmentation du nombre de rayon, le nombre des pixels voisins capturés augmente également, ce qui signifie une croissance dans les motifs LBP, et donc une augmentation dans la longueur des caractéristiques. Ainsi, les histogrammes LBP correspondant à différents rayons sont simplement concaténés et utilisés comme caractéristiques de texture.

2.5 Les variantes du LBP

Comme déjà mentionné dans la section 2.2, le LBP d'origine souffre de plusieurs limites, et en comparaison avec les autres descripteurs $LBP_{R,P}^{u2}$ et $LBP_{R,P}^{ri}$, nous évitons seulement l'inconvénient de la dimensionnalité élevée des caractéristiques. Bien que les motifs uniformes soient bénéfiques en pratique, leur utilisation reste heuristique : les LBP uniformes extraites de certaines images contenant des bords à forte courbure, traversant des frontières ou des coins ne sont pas nécessairement les modèles dominants.

Nombreuses variantes et modifications de LBP, seront discutées dans cette section, s'appuyant sur la stratégie LBP fondamentale, cherchant à augmenter la robustesse, à améliorer le pouvoir discriminatif et à éviter les inconvénients des méthodes LBP traditionnelles. Liu et al. [2017] ont proposés de classer les différentes variantes du LBP en 5 classes : (1) LBP original (section 2.2) (2) topologie de voisinage et échantillonnage, (3) seuillage, (4) codage et regroupe-

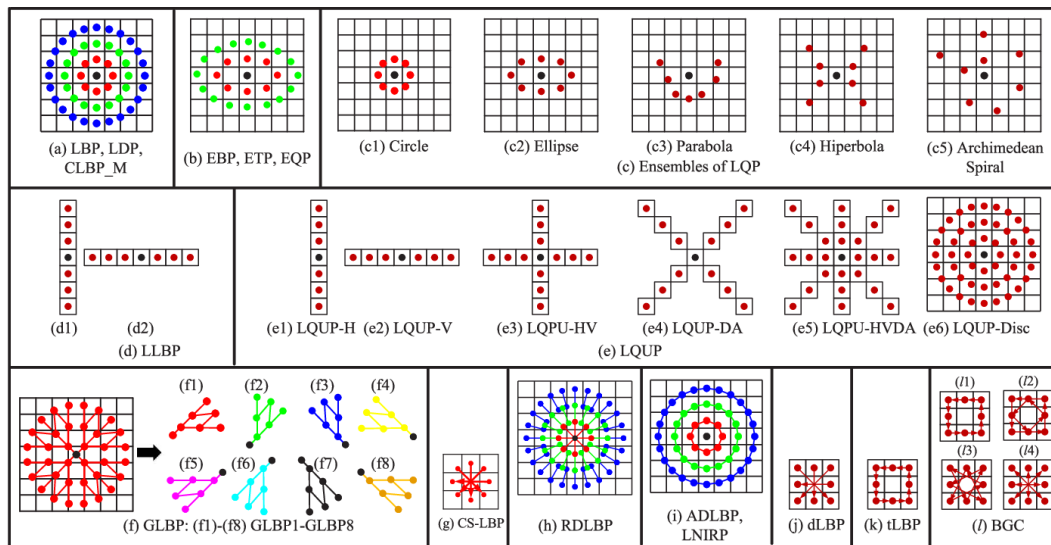


FIGURE 2.6 – Topologies de voisinage des variantes LBP Liu et al. [2017].

ment, (5) combinaison avec d'autres approches.

2.5.1 topologie de voisinage et échantillonnage

La topologie du voisinage à partir de laquelle les caractéristiques LBP sont calculées peut être modifiée en fonction des besoins de l'application donnée, ce qui est l'une des raisons essentielles qui rend la technique LBP polyvalente pour différents types de problèmes. Un voisinage est identifié par l'approche LBP classique comme un ensemble de pixels sur un anneau circulaire. Cependant, de nombreuses autres topologies de voisinage ont été établies, comme l'illustre la figure 2.6 et qui peuvent être divisés en trois sous-catégories :

Exploitation des informations anisotropes

Bien qu'un voisinage circulaire soit crucial pour l'invariance de rotation, il existe certaines applications où l'invariance de rotation n'est pas requise et des informations anisotropes peuvent être utiles, comme la reconnaissance faciale.

Dans l'originalité des topologies anisotropes, le type circulaire est le type le plus fondamentale, Liao and Chung [2007] a proposé le modèle EBP (Elliptical Binary Pattern) dont les pixels voisins sont elliptiques. Ensuite Nanni et al. [2010] a développé les topologies de voisinage paraboliques, hyperboliques et en spirale. Additionnellement, une très grande variation de topologie ont été introduites, telle que le descripteur Local Line Binary Pattern (LLBP) (Petpon and

Srisuk [2009]) qui se base sur des lignes dans les directions verticales et horizontales pour les calculs LBP, et le descripteur Local Quantized Pattern (LQP) (Triggs et al. [2012]) qui utilise la quantification vectorielle et les tables de recherche pour permettre de caractériser le modèle local.

Local différences or magnitudes

En générale, dans le codage LBP toutes les valeurs de pixels proches sont seuillées par rapport d'un unique pixel central. Ce seuillage encode un voisinage en fonction de sa valeur centrale, mais il supprime toutes les relations entre les pixels du voisinage. En conséquence, un ensemble d'approches pour générer des codes LBP basés sur des différences locales de base ou des grandeurs entre voisins a été développé. Guo et al. [2010a] propose le modèle complet CLBP (Completed Local Binary Pattern) qui utilise non seulement le signe du différence entre le pixel central et les pixels voisins mais un autre composant complémentaire qui est l'amplitude correspondant aux deux opérateurs : $CLBP_S$ et $CLBP_M$ respectivement. De plus, il existe un troisième opérateur $CLBP_C$ correspondant à la valeur du pixels central.

Formellement, si g_c est le pixel central et g_{i1} est l'un des pixels voisins, alors la différence $d_p = g_{i1} - g_c$ peut nous garantir l'extraction des deux opérateurs : le signe s_p et l'amplitude m_p . le *local difference sign-magnitude transform* (LDSMT) est utilisé pour calculer $CLBP_S$, $CLBP_M$, et $CLBP_C$ qui représentent les caractéristiques de la texture. Les équations mathématiques qui décrivent les deux composants sont définis comme suit :

$$CLBP_S_{R,P}(c) = \sum_{i=0}^{P-1} s(g_i - g_c)2^i, \quad s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & otherwise \end{cases}, \quad (2.6)$$

$$CLBP_M_{R,P}(c) = \sum_{i=0}^{P-1} t(m_i, c)2^i, \quad t(m_i, a) = \begin{cases} 1 & m_i \geq a \\ 0 & otherwise \end{cases}, \quad (2.7)$$

où g_i , g_c , P , R , $s()$ ont été présentés auparavant dans 2.1. $m_i = |g_i - g_c|$ représentant la composante de magnitude et c est la valeur moyenne de m_i dans toute l'image.

Comme déjà mentionné, un autre opérateur a été ajouté par Guo et al. [2010a] nommé $CLBP_{Centre}$ ($CLBP_C$) qui emploie la valeur du niveau de gris de chaque motif. $CLBP_C$ est généré par l'équation suivante :

$$CLBP_C_{R,P}(c) = t(g_c, a_I), \quad (2.8)$$




FIGURE 2.7 – Illustration du CLBP.

où a_I représente la moyenne du niveau de gris moyen de toute l'image. La figure 2.7, illustre le processus global de CLBP.

Pour caractériser la texture, les histogrammes des trois modèles $CLBP_S$, $CLBP_M$ et $CLBP_C$ sont regroupés. L'approche CLBP prend également en considération les différentes extensions du LBP : l'uniformité $CLBP^{u2}$, l'invariance à la rotation $CLBP^{ri}$ avec la combinaison des deux $CLBP^{riu2}$. Le regroupement des trois descripteurs $CLBP_M^{riu2}$, $CLBP_S^{riu2}$, et $CLBP_C^{riu2}$ apporte des meilleures performances et une importance discrimination que celle du LBP d'origine. l'un des inconvénients majeurs du CLBP et qui le rend difficilement exploitable spécifiquement sur des fenêtres de voisinage de grande dimension est le nombre important de paramètres utilisé.

Des méthodes LBP basées sur les patches

Les approches LBP traditionnelles et ses variantes (u2, ri, riu2), ont été critiquées parce qu'elles ne capturent que la micro-texture locale mais la macro-texture non-locale ne peut pas être capturée, même si, elle peut être dominante dans certaines circonstances. Les variantes LBP basées sur des patches sont conçues pour résoudre ce problème en s'intégrant sur une large région.

Dans cette catégorie, plusieurs méthodes avec une différentiation de mécanisme ont été suggérées pour introduire la non-localité, y compris : Multiscale Block LBP (MB-LBP) (Zhang

et al. [2007]), qui calcule les motifs des blocs ou des régions rectangulaires afin de capturer les macro-structures, qui permet de donner plus de détails sur la texture locale par rapport aux micro-structures du LBP d'origine. l'idée de MB-LBP est d'encoder des blocs rectangulaires par des opérateurs LBP. Toutefois, le concept a été étendu dans MB-LBP de telle sorte que l'intensité moyenne de la région centrale d'un bloc est comparée avec les intensités des sous-régions de voisinage qui peuvent être un rectangle ou un carré. Par la suite, lorsque la taille de bloc est égale à un, MB-LBP sera identique au LBP d'origine. Ainsi, le LBP d'origine est considéré comme un cas particulier du MB-LBP. La figure 2.8 illustre un exemple global du processus du MB-LBP. Plusieurs avantages du MB-LBP : la capacité de capturer des structures à grande échelle qui peuvent être des caractéristiques dominantes des images, l'insensibilité au bruit, la génération d'un ensemble de fonctionnalités plus petit par rapport au LBP d'origine, ainsi, moins de temps est nécessaire pour enregistrer, traiter et récupérer l'ensemble de fonctionnalités. Parmi les descripteurs de cette catégorie, on trouve Three Patch LBP (TPLBP) et Four Patch LBP (FPLBP) suggested by Wolf et al. [2010], comme son nom l'indique, TPLBP est produit en comparant les valeurs de trois patchs dans un seul anneau pour donner une valeur de bit unique dans le code attribué à chaque pixel, tandis que le FPLBP est produit en comparant deux patchs symétriques centraux dans l'anneau intérieur avec deux patchs symétriques centraux dans la bague ou l'anneau extérieur, les patchs sont positionnés le long du cercle (par exemple, dans le sens des aiguilles d'une montre). La figure 2.9 illustre le concept des deux descripteurs. Liu et al. [2014] a suggéré Binary Rotation Invariant and Noise Tolerant (BRINT) pour la classification de la texture afin de surmonter la forte sensibilité de CLBP au bruit ainsi que la dimensionnalité, en utilisant le même concept de CLBP tout en proposant une nouvelle stratégie pour étudier la multi-résolution. À chaque résolution, le vecteur des pixels voisins est transformé par moyenne locale ce qui apporte un nombre d'échantillons constant. Parmi les opérateurs les plus performants, nous trouvons Median Robust Extended LBP (MRELBP) proposé par Liu et al. [2016] qui utilise des médianes d'images régionales plutôt que des intensités d'images brutes.

Les différents descripteurs représentés sont liés à des variations, sur les formes des patchs (rectangulaire, carré ou arc de pixel), sur le filtrage (pixels bruts ou valeurs filtrées) et sur la nature de la comparaison centrale (pixel unique, patch moyen ou patch médian), si un ou plusieurs anneaux de patchs sont utilisés et si des informations directionnelles ou de gradient sont capturées.

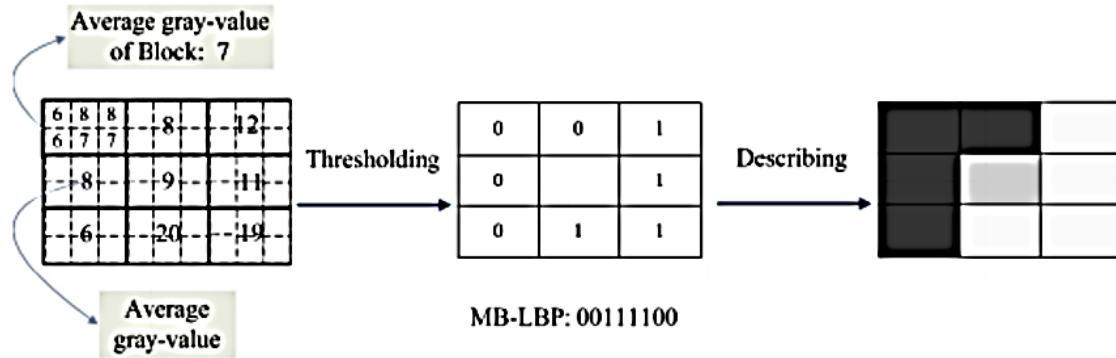



FIGURE 2.8 – Illustration du MB-LBP Zhang et al. [2007].



(a) Principe de TPLBP

(b) Principe de FPLBP

FIGURE 2.9 – Illustration du TPLBP et FPLBP.

2.5.2 seuillage

L'un des obstacles observé dans l'opérateur de base LBP est la sensibilité au bruit, qui se produit à cause de la comparaison directe de la valeur du pixel central avec ses voisins. Afin d'améliorer la robustesse du LBP au bruit et de collecter les discriminantes caractéristiques, les chercheurs ont proposés plusieurs variantes en modifiant les schémas du seuillage qui peuvent être partitionnés en trois catégories.

Changements au niveau du seuil

De nombreux seuils supplémentaires ont été envisagés pour ne pas utiliser seulement la valeur de niveau de gris du pixel central pour le seuillage.

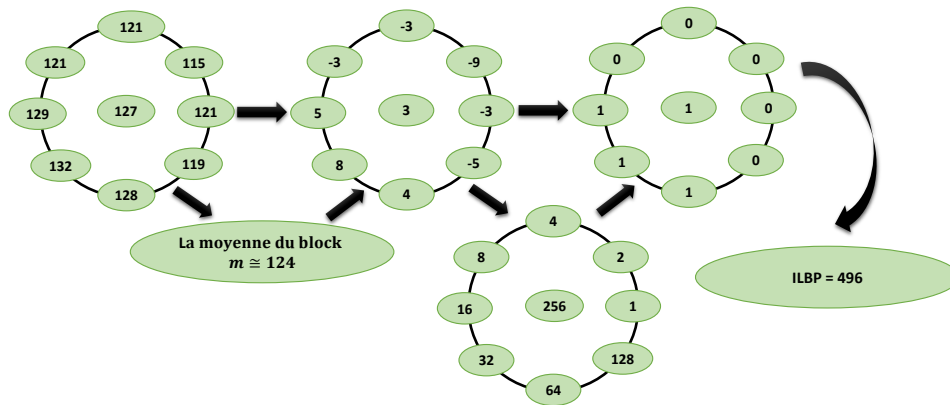


FIGURE 2.10 – Illustration du ILBP.

Jin et al. [2004] ont proposés un nouveau descripteur, nommé Improved Local Binary Patterns (ILBP), pour améliorer le LBP d'origine et augmenter sa capacité de discrimination. Dans ce descripteur, tous les pixels d'un bloc (y compris le pixel central) seront comparés par un seuil provenant de la moyenne de tous les pixels existants dans le bloc (figure 2.10).

Mathématiquement, ILBP est défini comme suit :

$$ILBP_{R,P}(c) = \sum_{i=0}^{P-1} s(g_i - m)2^i + s(g_c - m)2^i, \quad s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & otherwise \end{cases}, \quad (2.9)$$

où m représente la moyenne de tous les pixels existants dans le bloc et il peut être calculé par l'équation suivante :

$$m = \frac{1}{P+1} \left(\sum_{i=0}^{P-1} g_i + g_c \right) \quad (2.10)$$

L'idée de cette technique est basée sur l'observation de l'effet du pixel central, qui donne des informations supplémentaires plus que son pixel voisin. Le descripteur ILBP donne des résultats satisfaisants qui prouvent son pouvoir discriminant.

Hafiane et al. [2007] ont suggérés Median Binary pattern (MBP) destiné à la classification de la texture, de telle sorte que la valeur médiane du pixel central avec ses voisins soit calculée et prise en considération comme une valeur de seuillage. Formellement, l'équation mathématique

de cette méthode est représentée comme suit :

$$MBP_{R,P}(c) = \sum_{i=0}^{P-1} s(g_i - g_{med})2^i + s(g_c - g_{med})2^i, \quad s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & otherwise \end{cases}, \quad (2.11)$$

où $g_{med} = median(g_0, g_1, \dots, g_{i-1}, g_c)$.

Dans le descripteur MBP, la taille du code binaire a augmenté à cause de l'utilisation du pixel central dans le calcul qui fait l'ajout d'un bit supplémentaire et devient plus résistant au bruit que le LBP d'origine.

Dans la même catégorie on trouve d'autres opérateurs comme NILBP suggérée par Liu et al. [2012b] qui calcule la différence de chaque pixel de voisinage avec la moyenne du voisinage, au lieu de la valeur de gris du pixel central. Dans la même catégorie on trouve aussi Uniformly-sampled Thresholds for General LBP (UTGLBP) proposé par Ghahramani et al. [2013] qui fait la combinaison de nombreuses caractéristiques de TMLBP (Heikkila and Pietikainen [2006]) calculées avec différents seuils pour représenter une distribution de comportement, mais au prix d'une forte augmentation de la dimensionnalité des caractéristiques.

Modifications du nombre de niveaux de quantification

Précédemment au LBP, la Texture Spectrum (TS) a été introduite en 1990 par He and Wang [1990] comme une technique pionnière dans cette catégorie. Elle fait l'ajout d'un paramètre supplémentaire τ , qui définit un seuil de similarité entre différentes intensités de gris, permettant la résilience au bruit. Toutefois, TS a une dimensionnalité très élevée par rapport à LBP (TS $3^8 = 6561$ contre le LBP $2^8 = 256$). Motivé par les deux opérateurs, Tan and Triggs [2010] introduit Local Ternary pattern(LTP) en proposant une approche de codage fractionnée pour minimiser la dimensionnalité. La combinaison en paire de seuils offre un avantage significatif : LTP peut coder le bruit modulo de similitude de pixel en appliquant la règle de base selon laquelle deux pixels quelconques dans une certaine plage d'intensité sont similaires.

Contrairement au LBP qui encode les pixels par $\{0,1\}$, comme sortie de la fonction du seuil. LTP encode les pixels en utilisant trois valeurs de codages, à savoir : $\{-1,0,1\}$, comme indiqué




FIGURE 2.11 – Illustration du LTP.

dans l'équation 2.12.

$$LTP_{R,P}(c) = \sum_{i=0}^P S3(g_i, g_c, \tau) 2^i, \quad S3(g_i, g_c, \tau) = \begin{cases} 1 & g_i \geq g_c + \tau \\ 0 & g_c - \tau \leq g_i < g_c + \tau \\ -1 & \text{otherwise} \end{cases}, \quad (2.12)$$

où τ est une valeur de seuil qui va être définie par l'utilisateur, comme illustrée dans l'équation 2.12, si la valeur de différence est entre τ et $-\tau$, dans ce cas la sortie sera 0, tandis que s'elle est supérieure au seuil, alors ça retourne +1, et finalement ça retourne -1 dans le cas contraire. L'étape suivante est la génération des codes binaires à partir des codes ternaires, qui seront transformés vers des codes supérieur et inférieur comme illustré dans la figure 2.11.

En se basant sur le descripteur LTP (Tan and Triggs [2010]), plusieurs variantes ont été proposées dans la littérature y compris : scale invariant LTP (SILTP) proposé par Liao et al. [2010] pour modifier l'approche de la fonction du seuil fixe utilisé dans LTP, en incluant un opérateur de concaténation dans les chaînes binaires. Ainsi, SILTP est relativement robuste aux bruits d'image locaux dans une plage (comme les variations d'éclairage dans une zone ombragée). Huang et al. [2015] suggère Orthogonal Symmetric LTP (OSLTP) pour réduire la dimensionnalité des caractéristiques de l'histogramme LTP, en considérant moins de pixels voisins. Singh et al. [2022] propose une revue qui représente plus de variants du LTP. Dans une stratégie connexe,

certaines chercheurs ont proposé de coder d'abord la petite différence de pixel comme un bit incertain, puis de déterminer sa valeur en fonction des autres bits du code LBP, comme le Fuzzy LBP (FLBP) (Iakovidis et al. [2008]) et LBP résistant au bruit (NRLBP) (Ren et al. [2013]).

Conservation des informations supplémentaires

Huang et al. [2006, 2007] ont proposé une nouvelle extension du LBP nommé Extended LBP (ELBP), qui génère plusieurs codes LBP à une position de pixel de manière différente. En plus des informations de signe encodé par le descripteur ELBP entre le pixel central et ses voisins, il prend également les grandeurs en utilisant des unités binaires supplémentaires d'une manière intéressante. L'opérateur Improved Local Ternary Pattern (ILTP), prend aussi des suppléments d'informations, en combinant ILBP and LTP de telle sorte que le code LTP prenne ILBP comme une sortie positive et négative du code. Zhao et al. [2013] a introduit également une nouvelle approche qui se base sur des informations supplémentaires nommée Robust local binary pattern (R-LBP) pour résoudre la sensibilité du LBP traditionnel au bruit et aux variations d'éclairage. R-LBP est basée sur l'utilisation du Average Local Gray Level (ALG). Cependant, ALG ignore la valeur du pixel central, qui est nécessaire pour générer un descripteur robuste. Pour résoudre ce problème, Weighted Local Grey Level (WLG) est utilisé comme illustre l'équation suivante :

$$R - LBP_{R,P}(c) = \sum_{i=0}^{P-1} s(g_i - WLG)2^i, \quad s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & otherwise \end{cases}, \quad (2.13)$$

où $WLG = \sum_{i=1}^8 (g_i + \alpha g) / 8 + \alpha$.

Le paramètre α est défini par l'utilisateur, ALG est un cas particulier de WLG, alors que les deux sont identiques lorsque α est égal à un.

2.5.3 codage et regroupement

Généralement, L'opérateur LBP d'origine génère des histogrammes qui sont disproportionnellement énormes même pour les petits voisinages, ce qui entraîne une faible puissance discriminative et des besoins de stockage élevés. Il est évident que tous les motifs locaux ne sont pas utiles pour modéliser les caractéristiques des textures ou d'autres images. Les chercheurs ont donc tenté de trouver des caractéristiques plus discriminantes, résilientes et compactes en choisissant les groupes de motifs les plus informatifs en fonction des critères suivants : regroupements heuristiques, groupements de co-occurrence, et stratégies d'apprentissage.

Fondamentalement, l'invariance à la rotation dans le descripteur LBP est obtenue par une

étape circulaire de N codes binaires décalés N fois vers la droite au niveau du bit sur la chaîne binaire de motif. Cependant, les LBPs ignorent les informations de magnitude qui diminuent la robustesse de l'opérateur. Par conséquent, afin d'extraire des caractéristiques LBP discriminantes dans l'invariant à la rotation, Rotated Local Binary Pattern (RLBP) a été proposé par Mehta and Egiazarian [2013] comme une extension qui utilise la direction dominante (indice de différence maximale) qui repose sur l'exploitation de l'amplitude de la différence entre pixels du centre et du voisinage. La direction dominante (D) définie comme suit :

$$D = \arg \max_{n \in \{0,1,\dots,N-1\}} |g_n - g_c| \quad (2.14)$$

La rotation du voisinage est décalée en prenant l'indice de cette direction dominante D comme référence dans un voisinage circulaire en lui associant la valeur la plus faible du poids puis il est augmentée dans le sens anti-horaire. Par conséquent, le RLBP est calculé comme suit :

$$RLBP_{R,P}(x,y) = \sum_{n=0}^{P-1} s(g_n - g_c) 2^{\text{mod}(n-D,P)}, \quad (2.15)$$

$$s(g_n, g_c) = \begin{cases} 1 & g_n \geq g_c \\ 0 & g_n < g_c \end{cases}$$

où mod présente l'opération de modulo. Comme expliqué précédemment, le terme de pondération $2^{\text{mod}(n-D,P)}$ correspond au D . La charge de décalage a une invariance de rotation parce que le poids repose sur le voisinage et non sur un ordre pré-sélectionné. La figure 2.12 illustre un exemple de codage RLBP, nous avons un exemple de motif, le pixel centre est défini par 148 dans l'image originale et tournante. On peut remarquer que la direction dominante D pour les deux motifs ; original [01111100] et en rotation [11100011] correspondent au même pixel 210, qui va servir à décaler la rotation en utilisant le poids le plus faible correspondant à l'indice maximum des deux, en outre les autres poids sont circulairement mis en fonction de celui-ci. Par conséquent, nous obtenons le code RLBP similaire.

Contrairement au LBP uniforme traditionnel, qui analyse uniquement l'occurrence de modèles uniformes, Liao et al. [2009] ont développés l'approche Dominant Local Binary Pattern (DLBP) qui prend en compte l'occurrence de tous les modèles générés par l'algorithme LBP, afin de représenter les informations de texture dans DLBP. L'idée générale du DLBP est de trier en premier par ordre décroissant des valeurs bins, puis les premiers modèles (dominants) sont

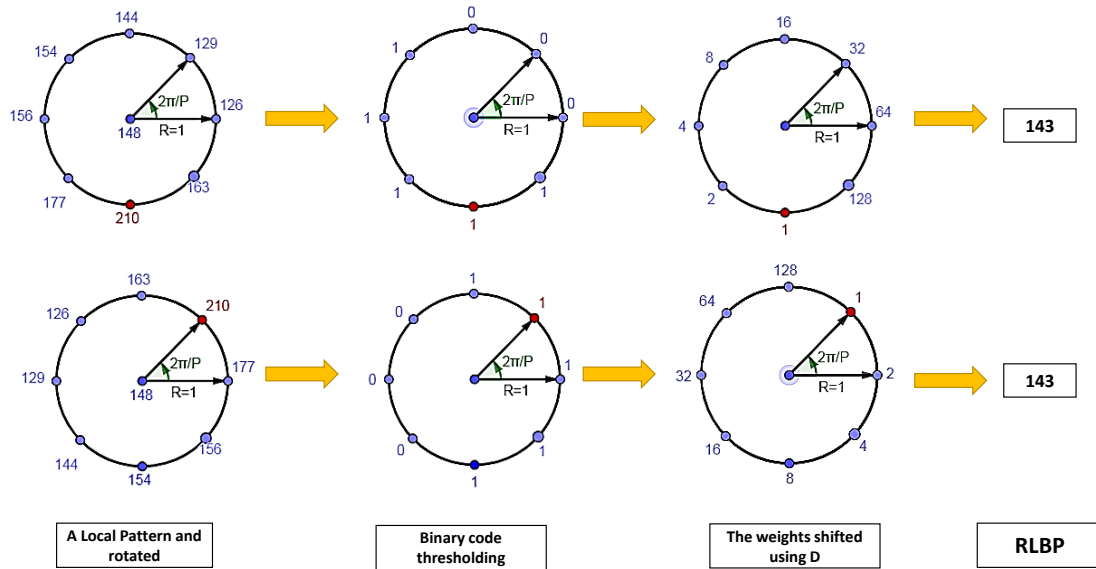


FIGURE 2.12 – Illustration du RLBP.

sélectionnés pour décrire les informations texturales.

En conséquence, les vecteurs de caractéristiques DLBP ne contiennent que des informations sur les fréquences d'occurrence des modèles LBP et non sur les types de modèles dominants. Pour cette raison, Liao et al. [2009] ont affirmés qu'il est pratiquement impossible d'avoir deux types de textures uniques avec les mêmes proportions de motifs dominants. Dans DLBP, les premiers groupes de l'histogramme triés, qui représentent 80% du nombre total d'occurrences, sont utilisés pour générer un certain nombre de premiers modèles :

$$k = \arg \min_k \left(\frac{\sum_{p=0}^{k-1} H(P)}{\sum_{p=0}^{2^P-1} H(P)} \geq 80\% \right) \quad (2.16)$$

Ce nombre est calculé pour tous les échantillons d'apprentissage, de plus, une valeur moyenne sera utilisée pour choisir les modèles les plus dominants parmi chacun d'eux. Cependant, DLBP présente de nombreux inconvénients importants, tels que le fait de ne pas se préoccuper des connexions de pixel

Nosaka et al. [2011] suggère Co-occurrence of Adjacent LBP (CoA-LBP) afin de préserver la relation spatiale entre les LBP adjacents. Généralement, le nombre de combinaisons potentielles

sera sensiblement plus grand dans CoA-LBP, par conséquent une matrice d'auto-corrélation sera utilisée pour déterminer la co-occurrence de LBP. Deux configurations sont présentées pour réduire le nombre de LBP : les motifs dérivés uniquement avec des pixels horizontaux et verticaux (LBP(+)) et les motifs dérivés uniquement avec des pixels diagonaux (LBP(-)). La matrice de corrélation est alors construite à l'aide de la matrice d'auto-corrélation N_p définie par l'équation ci-dessous.

$$H(q) = \sum_{r \in I} f(r)f(r+q)^T, \quad (2.17)$$

où q est le vecteur de déplacement du LBP à partir de la référence vers ces voisins. L'élément $H_{i,j}(q)$ indique le nombre de couples de LBP_i et LBP_j adjacents.

2.5.4 combinaison avec d'autres approches

En intégrant les points forts des descripteurs complémentaires, un certain nombre de nouveaux descripteurs locaux efficaces d'images et de vidéos ont été présentés. Le processus de ces méthodes peut être réalisé en utilisant trois classes : commencer par le pré-traitement de l'image d'entrée et ensuite extraire les caractéristiques de type LBP. La deuxième classe fait la combinaison entre deux ou plusieurs descripteurs de type LBP afin d'obtenir un autre plus puissant. La dernière classe est de faire l'extraction des caractéristiques de deux descripteurs en parallèle ; un qui appartient à la famille du LBP et l'autre non, ensuite fusionner les deux types de caractéristiques.

Mehta and Egiazarian [2016] introduisent une nouvelle méthode pour la classification des textures basée sur RLBP (Mehta and Egiazarian [2013]) et DLBP (Liao et al. [2009]) nommée Dominant Rotated Local Binary Patterns (DRLBP). L'idée générale est d'utiliser une stratégie d'invariance à la rotation dirigée par patch tout en utilisant la direction basée sur les références. Dans le cas de grands voisinages, il aborde le problème de la sélection de motifs discriminants. En supprimant les structures de caractéristiques superflues, l'approche réduit la dimensionnalité et améliore le pouvoir de discernement des caractéristiques. L'utilisation de la référence comme direction dominante présente des avantages supplémentaires, tels que le fait de rendre le calcul du RLBP très rapide et simple. En outre, étant donné que la direction dominante classique utilise le même processus de calcul que le LBP classique, il n'y a pas de différence dans la complexité de calcul. Le principal inconvénient du DRLBP est que seule une partie des données est enregistrée (juste la fréquence de l'occurrence de modèle dominant), tandis que les données du type de

modèle sont perdues. Pour remédier au défaut susmentionné, une nouvelle approche d'extraction de caractéristiques a été suggérée, qui apprend les caractéristiques les plus exigeantes et les plus robustes de l'image d'entrée brute.

Liu et al. [2012b] ont développés dans un premier temps une nouvelle méthode comme variante du descripteur LBP qui contient quatre descripteurs : LBP basée sur l'intensité centrale ($ELBP_{CI}$), LBP basée sur l'intensité du voisinage ($ELBP_{NI}$), LBP basée sur la différence radiale ($ELBP_{RD}$) et LBP basée sur la différence angulaire ($ELBP_{AD}$). Dans ce travail, il a pu démontrer que $ELBP_{CI}$, $ELBP_{NI}$ et $ELBP_{RD}$ (collectivement appelés E-LBP) produisaient de bonnes performances de classification de texture, mais avec les inconvénients de : (1) la sensibilité au flou et au bruit de l'image, (2) l'incapacité à capturer la macrostructure de la texture et (3) la dimensionnalité élevée. Dans le but de surmonter ces inconvénients, Liu et al. [2016] ont présenter une nouvelle méthode de haute qualité, efficace, et théoriquement simple nommée Robust Extended Local Binary Pattern (MRELBP). Le descripteur MRELBP remplace les intensités de pixel individuelles en un point par le représentant sur une région, précisément, les valeurs de pixel brutes sont remplacées par la médiane dérivée des correctifs locaux

Mathématiquement, Les trois descripteurs $MRELBP_{CI}$, $MRELBP_{RD}$, et $MRELBP_{NI}$ sont définis comme suit :

$$MRELBP_{CI}(g_c) = s(\phi(G_{c,w}) - \mu_w) \quad (2.18)$$

où $G_{c,w}$ désigne le patch local de taille $w \times w$ centré sur le pixel central g_c considéré, la fonction $\phi(x)$ est la valeur médiane sur x et μ_w est la moyenne de $\phi(G_{c,w})$ sur toute l'image.

$$MRELBP_{NI}_{R,P}(g_c) = \sum_{i=0}^{P-1} s(\phi(G_{R,P,w_R,i}) - \mu_{R,P,w_R})2^i, \quad (2.19)$$

$$\mu_{R,P,w_R} = \frac{1}{P} \sum_{i=0}^{P-1} \phi(G_{R,P,w_R,i})$$

Avec $G_{R,P,w_R,i}$ désigne le patch local de taille $w_R \times w_R$ centré sur les pixels voisins $G_{R,P,i}$

$$MRELBP_{RD}_{R,R-1,P,w_R,w_{R-1}}(g_c) = \sum_{i=0}^{P-1} s(\phi(G_{R,P,w_R,i}) - \phi(G_{R-1,P,w_{R-1},i}))2^i, \quad (2.20)$$

Avec $G_{R,P,w_R,i}$, et $G_{R,P,i}$ sont déjà définies, l'ajout ici est qu'ils sont les voisins circulairement et régulièrement espacés du pixel central g_c sur le rayon R .

Parmi les extensions du LBP qui font la combinaison avec d'autres approches, en trouvant le LBP variance (LBPV) proposé par Guo et al. [2010b]. Premièrement, Ojala et al. [2002c] ont proposés de combiner le descripteur LBP avec l'opérateur $VAR_{R,P}$ afin de générer une distribution conjointe $LBP_{P,R}/VAR_{P,R}$ qui donne un descripteur de texture puissant car il contient à la fois des informations sur le motif local et le contraste local. Mathématiquement, l'approche $VAR_{R,P}$ est définie comme suit :

$$VAR_{R,P} = \frac{1}{P} \sum_{n=0}^{P-1} s(g_p - \mu)^2, \quad \mu = \frac{1}{P} \sum_{n=0}^{P-1} g_p \quad (2.21)$$

En revanche, VAR a une valeur continue qui doit être quantifiée à l'aide de la distribution des caractéristiques de toutes les images d'entraînement. Il existe certains inconvénients, tels que la nécessité d'une étape d'apprentissage pour déterminer les valeurs de seuil pour chaque bin, la quantification étant dépendante d'échantillons d'apprentissage, et le nombre de bins devant être prédéterminé. Trop peu de bins donnent une discrimination insuffisante, alors que trop de bins entraînent d'énormes vecteurs de caractéristiques.

Une approche hybride, LBP variance (LBPV), qui donne des distributions conjointes et contrastes du LBP et utilise la variance $VAR_{P,R}$ comme un poids adaptatif pour moduler la contribution du code LBP dans le calcul de l'histogramme.

Formellement, l'histogramme de LBPV est calculé comme suit :

$$LBPV_{R,P}(x, y) = \sum_{i=1}^N \sum_{j=1}^M \nu(LBP_{R,P}(i, j), k), \quad k \in [0, K], \quad (2.22)$$

$$\nu(LBP_{R,P}(i, j), k) = \begin{cases} VAR_{R,P}(i, j) & \text{if } LBP_{R,P}(i, j) = k \\ 0 & \text{otherwise} \end{cases}$$

Arguant que la fonction de variance locale VAR est une mesure isotrope qui ne parvient pas à capturer les informations d'orientation dans les textures, Guo et al. [2010b] ont introduit *adaptive LBP* (ALBP) qui essaie d'incorporer la structure spatiale locale dans LBP. Afin de minimiser la différence directionnelle le long de différentes orientations, un nouveau paramètre de pondération est introduit w_p . La différence directionnelle globale $|g_c - w_p \times g_p|$ peut être minimisée par la fonction objective. En outre, Une technique least square estimation (LSE) est

utilisée pour l'optimisation de w_p , qui est calculée comme la fonction suivante :

$$w_p = \arg \max_w \left\{ \sum_{i=1}^N \sum_{j=1}^M |g_c(i, j) - w \cdot g_p(i, j)|^2 \right\}, \quad (2.23)$$

$$w_p = \bar{g}_p^T \bar{g}_c / \bar{g}_p^T \bar{g}_p$$

où \bar{g}_c et \bar{g}_p représentent respectivement un vecteur colonne qui contient toutes les valeurs de pixels centre et un vecteur correspondant pour toutes les valeurs. Chaque poids w_p est estimé selon une orientation $2\pi p/P$ de pixels g_p , ALBP est donc définie par :

$$ALBP = \sum_{i=0}^{P-1} s(g_p \times w_p - g_c) 2^i, \quad (2.24)$$

où P est la taille du vecteur poids w .

De la même manière que LBPV, Wang et al. [2009] ont combinés LBP avec Histogram of Gradients (HOG), destiné à la détection humaine avec une manipulation d'occlusion partielle. Discriminative Robust Local Binary Pattern (DI-LBP) proposé par Satpathy et al. [2014] fait la combinaison du LBP avec des données d'amplitude de gradient. Ce dernier permet d'attribuer un poids à chaque code, qui est ensuite voté dans la case appropriée. DR-LBP généré par la concaténation de deux histogrammes l'un qui est la différence absolue entre les bins d'un code LBP et son complément, tandis que l'autre est la somme des bins d'un code LBP et son homologue. DR-LBP surmonte la difficulté de discriminer un objet lumineux sur un fond sombre et vice versa, ce qui est un problème avec LBP. en trouvant également dans le même papier Satpathy et al. [2014] une autre combinaison entre deux familles du LBPs afin d'améliorer la discrimination.

2.6 Classification de la texture

En général dans le premier chapitre, nous avons abordé les différentes méthodes d'analyse de la texture, puis nous avons décrit dans les différentes sections de ce chapitre l'une des approches les plus populaires et efficaces : Le descripteur de base LBP avec ses variantes. Compte tenu de la variété de ces méthodologies, il est essentiel de pouvoir analyser quantitativement les nombreux descripteurs produits par ces méthodes. Dans la partie suivante, nous allons nous intéresser à

l'un des cadres applicatifs possibles pour explorer les attributs obtenus, celui de la classification.

L'algorithme de la classification vise à construire un modèle à partir d'une série d'images d'apprentissage, puis d'utiliser ce modèle pour classer certaines images qui ont des classes inconnues dans la classe correcte. Précisément, le processus de classification consiste à associer un attribut, également appelé descripteur ou vecteur caractéristique, en fonction des caractéristiques qu'il présente, à sa classe. Cette définition suggère qu'avant la classification, une étape d'extraction des caractéristiques doit être effectuée en utilisant les méthodes d'analyse de la texture décrites auparavant. Par conséquent, les algorithmes de classification peuvent utiliser les vecteurs de caractéristiques extraits comme entrée.

Dans la littérature, il existe deux types d'approches destinées à la classification : supervisée et non supervisée. Les procédures supervisées prennent en compte la connaissance à priori de la nature des images étudiées (vérité terrain), ce qui les rend préférables par rapport aux approches non supervisées qui catégorisent les images en fonction de leur proximité. Dans cette thèse, seule la classification supervisée sera considérée. Par conséquent, ceci nécessite une phase d'apprentissage initiale au cours de laquelle le système apprend les nombreuses fonctionnalités associées à chaque classe à partir d'une base de données d'apprentissage, en construisant un modèle de chaque classe de texture. Ensuite, il vient le rôle de la phase de reconnaissance, où les images de la texture vont être décrites par la même méthode d'analyse de texture, pour extraire les caractéristiques qui vont être par la suite comparées à celles des images d'apprentissage avec un algorithme de classification défini, l'échantillon est assigné à la classe de la meilleure correspondance.

Dans la classification de la texture une variété de techniques et de modèles ont été développées. Tous ces algorithmes ont le même objectif : effectuer une classification efficace sur la base de plusieurs critères d'évaluation tels que la précision, l'efficacité temporelle et l'efficacité spatiale. En conséquence, divers algorithmes de classification existent, notamment les algorithmes d'arbre de décision (Murthy [1998]), les algorithmes bayésiens (Cheeseman [1983]), les algorithmes de réseaux de neurones (Park et al. [2004]), les algorithmes *K-Nearest Neighbor* (Cover and Hart [1967]) et les algorithmes de la machine à vecteurs de support (Gunn et al. [1998]).

2.6.1 k-Plus Proches Voisins

Le classifieur k Nearest Neighbors (k-NN) (Cover and Hart [1967]) est connu dans le champ d'apprentissage automatique comme une méthode non paramétrique et basée sur le voisinage ; ceci signifie que l'algorithme permet de faire une classification sans faire l'hypothèse sur la fonc-

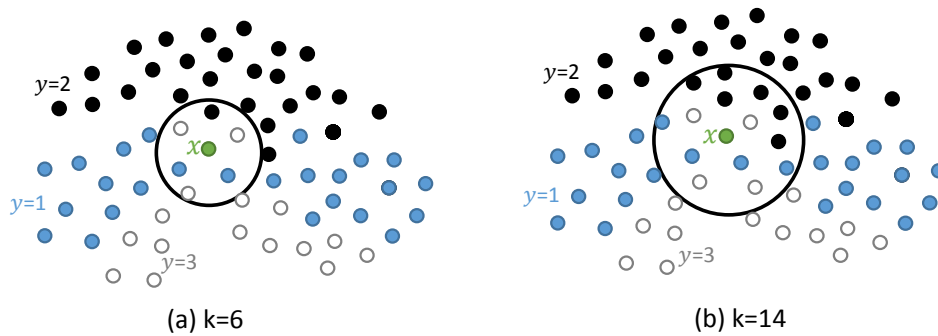


FIGURE 2.13 – Exemple de fonctionnement du classifieur k-NN pour $k=6$ (a) et $k=14$ (b). Trois classes sont considérées et représentées respectivement en bleu ($y=1$), en noir ($y=2$) et en blanc ($y=3$).

tion qui relie la variable dépendante aux variables indépendantes. Il est largement utilisé dans la littérature pour son approche intuitive simple et également au fait qu'il est facilement configurable; en outre, il permet de traiter des données non linéairement séparables.

L'algorithme K-NN se base sur le vote majoritaire de l'ensemble des k proches voisins (où k est un entier positif), en calculant la mesure de similarité entre un vecteur de caractéristique de texture qui doit être attribué à une classe et les autres vecteurs décrivant chacune des classes définies. Principalement, parmi les points d'apprentissage existants $Q(x)$, K-NN calcule l'ensemble des k plus proches voisins pour chaque nouvelle observation $x = (x_1, x_2, \dots, x_n)$. La classe affectée à x est déterminée en fonction de la classe majoritairement représentée par le choix de k voisins de l'observation x . La figure 2.13 illustre le mécanisme du classificateur K-NN. Généralement, le concept de similarité de texture est basé sur la métrique distance qui a été adaptée à l'approche utilisée pour caractériser la texture. La nature de donnée joue un rôle important sur le choix du paramètre k , si la valeur de k est faible cela amène à une forte probabilité de n'avoir que les échantillons qui appartiennent à la même classe que la région à classer. Contrairement à ce cas, une grande valeur de k permet au classificateur d'être moins sensible aux individus aberrants tout en réduisant la probabilité d'obtenir uniquement des échantillons de la même classe que la région à classer. De ce fait, la variation du paramètre k est très importante jusqu'à l'obtention




FIGURE 2.14 – Vecteurs de support et l’optimal hyperplan pour une classification binaire et des données linéairement séparables Do [2020].

de celle comprise entre ces deux risques d’erreurs de classification.

2.6.2 Machine à Vecteurs de Support

Les SVMs (Support Vector Machines) ont été introduites pour la première fois dans Boser et al. [1992] et améliorées par la suite dans Vapnik [1999]. Les SVMs ont été développées à l’origine pour classer les données linéaires, mais elles ont ensuite été étendues aux données non linéaires en les projetant par le biais sur un espace différent, appelé espace transformé, pour les rendre linéairement séparables, cette technique de noyau ou (Kernel) est la base des SVMs. D’une façon plus détaillée, Les SVMs a deux notions très importantes la notion de marge maximale et la notion du noyau. Ils ont commencé par les cas linéairement séparables comme la montre la figure 2.14, puisqu’ils sont plus simples et ils permettent de trouver facilement le classificateur linéaire. Afin d’obtenir une classification de deux classes séparables, la maximisation de la largeur de la zone vide (marge) entre les deux classes est requise. Les vecteurs du support sont les points de données les plus proches de la marge, qui sont utilisés pour former la fonction de discrimination.

Par la suite, afin de surmonter les inconvénients des cas non linéairement séparables, SVM a ajouté une extension dite astuce du noyau. L’idée est de transformer l’espace de caractéristiques d’origine (données non linéairement séparables) vers un espace de caractéristiques de dimension supérieure où la séparabilité linéaire des deux classes est plus facile à réaliser. Par exemple dans




FIGURE 2.15 – Un exemple de SVM pour des données non linéairement séparables avec l’astuce du noyau ϕ .

la figure 2.15, le cercle et les triangles représentent deux classes qui ne sont pas séparables à l’aide d’une fonction linéaire. Ainsi ces données sont projetées en dimension supérieure à l’aide d’une fonction noyau, où la séparation entre deux classes est possible. En pratique, quelques familles de fonctions noyau paramétrables sont connues et il revient à l’utilisateur de SVM d’effectuer des tests pour déterminer celle qui convient le mieux pour son application. Le tableau 2.1 illustre quelques exemples des noyaux fréquemment utilisés.

Généralement, Les SVM sont de plus en plus populaires dans une variété d’applications de classification pratiques en raison de leur capacité à accepter une large gamme de non-linéarités. Les SVM sont également bien connus pour leurs hautes performances lorsque le nombre d’échantillons dans la base d’apprentissage est faible, ce qui est une limitation courante dans de nombreux domaines. Les SVM sont également des outils de classification puissants et flexibles puisqu’ils vous permettent de choisir le noyau en fonction des caractéristiques des données.

Les expériences de cette thèse utilisent un SVM multi-classes "one-against-one" (Hsu and Lin [2002]) avec un noyau Gaussien (RBF) et une technique de validation croisée (Chang and Lin [2011]) pour optimiser les paramètres C et γ . Les données de formation sont séparées en données de formation et de test, pour chaque paramètre de coût la précision est enregistrée. Pour la génération finale de SVM, le meilleur paramètre de précision est défini. La construction d’un SVM pour chaque paire de classes est nécessaire dans la technique "one-against-one". En conséquence, un total de $N(N-1)/2$ SVM sont construits pour un problème de classification de classe N . Après cela, chaque SVM vote pour la classe gagnante lors de la classification, et l’échantillon inconnu est classé par la classe avec le plus de votes.

TABLEAU 2.1 – Exemples de noyaux SVM appliqués aux points (x_i, y_i) .

Noyau	Fonction
Linéaire	$\langle x_i, y_i \rangle$
Polynomial de degré d	$(\langle x_i, y_i \rangle + b)^d$
Gaussien (RBF)	$\exp\left(-\frac{\ x_i - y_i\ _2^2}{2\sigma^2}\right)$
Sigmoïde	$\tanh(\langle x_i, y_i \rangle + b)^d$
Laplacian	$\exp\left(-\frac{\ x_i - y_i\ _2}{\sigma}\right)$

2.6.3 Réseaux de Neurones

Les réseaux de neurones (RN) sont des modèles parallèles de réseaux distribués qui reflètent la physiologie du système nerveux biologique, ils sont constitués de pièces simples appelées neurones qui sont disposées en couches (Rojas [2013]). Des liaisons pondérées relient ces parties les unes aux autres (synapses). Les poids sont déterminés pour que chaque vecteur d'attribut sélectionné X_{ij} fourni en entrée du réseau soit corrélée à la classe Y^j à laquelle appartient le prototype correspondant ω_{ij} en sortie du réseau.

Pratiquement, grâce à des connexions synaptiques, chaque neurone reçoit des valeurs de neurones en amont et les traite à l'aide d'une fonction de combinaison. La fonction d'activation transforme le résultat de la combinaison pour générer sa sortie. Cette fonction permet de seuiller le résultat afin d'obtenir une sortie binaire. La construction d'un neurone artificiel est illustrée à la figure 2.16.

Chaque réseau comporte trois niveaux : une couche d'entrée, une couche de sortie et des couches intermédiaires qui sont entre l'entrée et la sortie du réseau. Ces couches sont également appelées couches cachées. Le rôle de ces couches est de modifier les données d'entrée afin d'en extraire les caractéristiques, que la couche de sortie pourra ensuite classer plus facilement. Grâce à l'intermédiaire des connexions pondérées, les informations se propagent de couche en couche dans les RNs, et parfois même au sein d'une couche. Généralement, les RNs comportent deux phases : une phase de conception qui consiste à choisir l'architecture et les paramètres du réseau, tels que le nombre de couches cachées et le nombre de neurones dans chacune de ces couches. Ensuite, une phase d'apprentissage commence et tout en long de cette phase les poids des connexions réseau

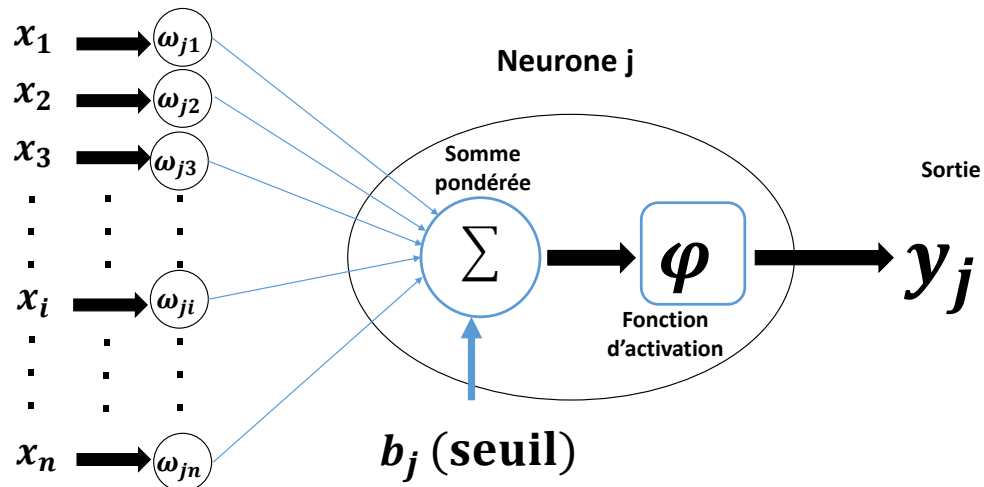


FIGURE 2.16 – Structure d'un neurone artificiel.

et le seuil de chaque neurone seront ajustés afin de s'adapter aux diverses situations d'entrée. Une fois que le réseau a été formé, il entre dans la phase d'utilisation et commence à effectuer la tâche pour laquelle il a été créé.

2.6.4 Techniques d'évaluation de la performance d'un système de classification

Une phase de validation est nécessaire dans le cas de l'apprentissage supervisé afin de vérifier quantitativement la qualité des descripteurs proposés d'une part, et les performances du modèle prédictif construit d'autre part. Il existe de nombreuses approches de validation qui diffèrent dans les proportions d'ensembles utilisés et, par conséquent, dans la manière dont le test est effectué.

Afin de valider les performances d'un schéma de classification, il existe plusieurs méthodes d'évaluation qui divisent un ensemble de données disponibles en ensembles d'apprentissage et de test : les méthodes de bootstrap, de resubstitution et de validation croisée telles que présentées dans (Jain et al. [2000]). Dans la validation croisée, nous pouvons distinguer trois types de techniques qui sont largement utilisées dans le cadre de la classification des textures tel que :

Holdout, Validation croisée en k parties (K-fold cross validation), et Leaving-one-out. Dans ce qui suit, nous dresserons une liste des critères les plus couramment utilisés y compris ces techniques de validation pour évaluer les performances des systèmes de classification, à la fois dans les cas binaires et en général pour les systèmes multi-classes.

2.6.4.1 Validation croisée

Bien que l'erreur empirique sur toutes les données d'apprentissage ne soit pas souvent un indicateur utile, puisqu'il y a un risque élevé de sur-apprentissage (overfitting en anglais), il est important de pouvoir mesurer la capacité de généralisation du modèle. Un meilleur modèle au sens prédictif n'est pas toujours celui qui correspond le mieux aux données (sur-apprentissage). Afin d'éviter le sur-apprentissage particulièrement lorsque la quantité de données disponibles est limitée, des approches de validation croisée peuvent être utilisées comme une méthode statistique permettant d'estimer (ou la précision) les performances globales du système de classification (un modèle d'apprentissage automatique) tout en utilisant l'ensemble de données complet (Kohavi et al. [1995], Stone [1977]).

Dans la validation croisée, un nombre défini des partitions des données est créé, l'analyse est effectuée sur chaque partition et l'estimation de l'erreur totale est moyennée. Généralement, dans la validation croisée l'ensemble des images initiales ϑ est divisé ou partitionné en trois sous ensembles distincts ϑ^α , ϑ^β , ϑ^γ au cours d'un apprentissage automatique, qui représente respectivement les bases de données d'apprentissage (qui est constitué des prototypes des classes), de test et de validation. La première base est utilisée pour créer la fonction de décision, tandis que la seconde est utilisée pour évaluer la capacité de généralisation de la fonction, et la base de validation est utilisée pour valider la fonction sélectionnée en utilisant des données qui n'ont pas été utilisées pendant le processus d'apprentissage. Il existe différentes approches de validation. Les approches les plus souvent utilisées en classification d'images de texture sont présentés ci-dessous

2.6.4.2 Validation croisée en k parties

L'algorithme de validation croisée (CV) à k parties consiste à segmenter aléatoirement la base de données initiale en k sous-ensembles distincts $\vartheta = \vartheta_1 \cup \vartheta_2 \dots \cup \vartheta_k$, numérotés de 1 à k , identiques (ou quasi-identiques si le nombre de d exemples n'est pas un multiple de k). Parmi les k sous ensembles, un est utilisé comme ensemble de test et les autres sont utilisés comme ensemble d'apprentissage. Autrement dit, afin de classer une image qui appartient à l'un des sous-ensembles

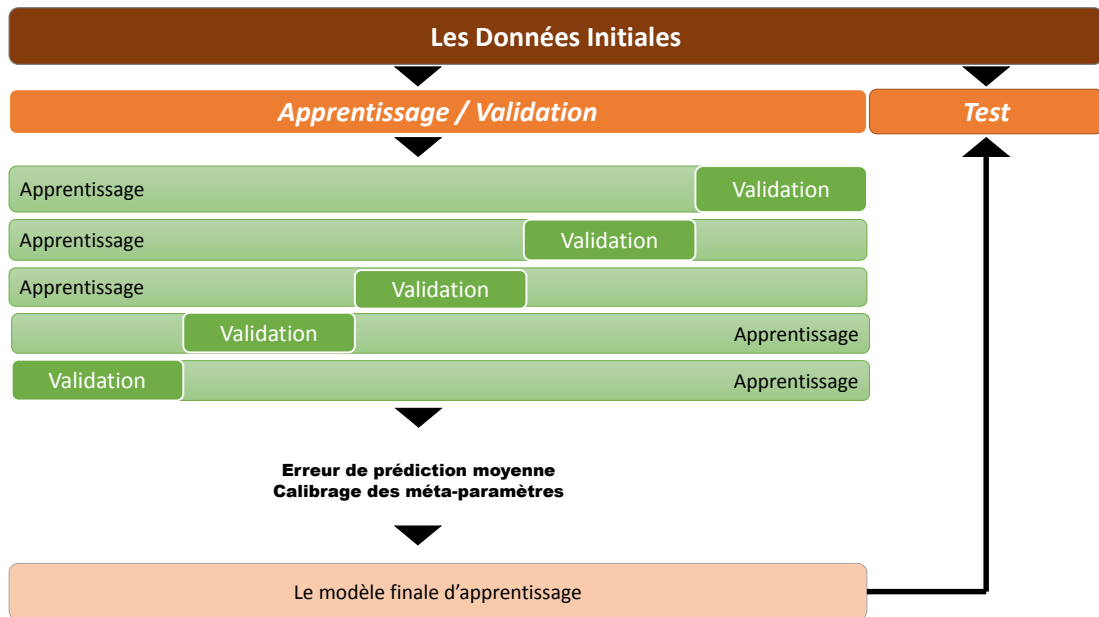


FIGURE 2.17 – Exemple de 5 fold validation croisée.

k , les $k-1$ sont réunis pour former l'ensemble d'apprentissage (Nakache and Confais [2003]). En général, il y a k phases d'entraînement, pour les bases d'entraînement, ϑ_i^α , et de test, ϑ_i^β , sont déterminées par $\vartheta_i^\alpha = \vartheta / \vartheta_i$, $\vartheta_i^\beta = \vartheta_i$, respectivement, à partir du ϑ_i . Par conséquent, la moyenne des erreurs réalisée sur l'ensemble des k bases de test est utilisée pour produire l'estimation de l'erreur réelle globale :

$$e_{relle} \approx e_{kVC} = \frac{1}{k} \sum_{i=1}^k e_{\vartheta_i^\beta}(D^{\vartheta_i^\alpha}) \quad (2.25)$$

Considérons la fonction de prise de décision de $D^{\vartheta_i^\alpha}$, qui est dérivée de la base d'entraînement de α . En pratique, k est fixé entre 3 et 10.

Par exemple, pour une validation croisée quintuple, l'ensemble de données serait divisé en 5 groupes, et le modèle serait formé et testé 5 fois distinctes afin que chaque groupe ait une chance d'être l'ensemble de test. Cela peut être vu dans le graphique 2.17.

2.6.4.3 *Leave-one-out*

La validation croisée K-fold est poussée à son extrême logique avec une validation croisée *Leave-one-out*, avec $K = N$, le nombre de points de données dans l'ensemble. Cela signifie que N fois séparées, l'approximation de la fonction est entraînée sur toutes les données à l'exception d'un point et une prédiction est faite pour ce point. L'erreur moyenne est calculée et utilisée pour évaluer le modèle, comme précédemment. Cela rend l'évaluation fournie par l'erreur de validation croisée *leave-one-out* très coûteuse en temps de calcul, mais recommandée si l'ensemble ϑ est de petite taille (Sémani-Delmi [2004]). Par ailleurs, chaque base d'apprentissage correspond à la base d'exemples initiale à laquelle un exemple a été retiré. $\vartheta_i^\alpha = \vartheta / \vartheta_i$, avec un seul élément $\vartheta_i^\beta = \vartheta_i$ dans la base de test.

2.6.4.4 *Hold-out*

La validation *Hold-out* est le type de validation croisée le plus simple. La base de données initiale est divisé en deux parties distinctes : un ensemble d'apprentissage ou d'entraînement (2/3) et un ensemble de test (1/3). L'approximation de fonction utilise uniquement l'ensemble d'apprentissage pour ajuster une fonction. Ensuite, pour les données de l'ensemble de test, l'approximateur de fonction est invité à estimer les valeurs de sortie (il n'a jamais vu ces valeurs de sortie auparavant). Comme précédemment, les erreurs qu'il génère sont additionnées pour fournir l'erreur absolue moyenne de l'ensemble de test, qui est utilisée pour évaluer le modèle. Cette approche a l'avantage d'être généralement préférée à la méthode résiduelle et de ne pas prendre plus de temps à calculer. En revanche, son évaluation peut avoir une large gamme de résultats. Toutefois, l'exclusion présente un certain nombre d'inconvénients, dont le plus important est que ce type d'échantillonnage peut ne pas être représentatif ; sinon, les données utilisées pour la formation peuvent ne pas être suffisamment représentatives pour l'ensemble de la base de données. De plus, les données d'entraînement et de test sont fondamentalement différentes. Il est essentiel de noter, cependant, que pour exclure les résultats provenant du hasard, de nombreux *hold-out* (*hold-out* répétés) doivent être effectués et les résultats moyennés.

2.6.4.5 *Mesures Quantitatives*

Pour mieux analyser plus en détail la qualité des classes produites, on s'intéresse aux matrices de confusion, à partir desquelles on peut calculer de nombreuses métriques quantitatives. Ceux-ci sont utilisés pour exprimer à quel point le système construit peut fournir sur la classe d'un

TABLEAU 2.2 – Matrice de confusion.

		Prediction outcome		total
		p	n	
actual value	p'	True Positive	False Negative	P'
	n'	False Positive	True Negative	N'
total		P	N	

nouvel élément. Généralement, la matrice de confusion est construite comme suit : les colonnes représentent les classes des régions dans la vérité terrain et la répartition des régions dans le résultat de la classification selon leur classe. Les lignes indiquent à l'inverse les classes des zones dans la classification et incluent leur répartition dans la vérité terrain selon leur classe. Le nombre de bonnes classifications est représenté par la diagonale de la matrice, tandis que les erreurs de classification sont représentées par les entrées en dehors de la diagonale.

Dans le but de tester les différentes méthodes proposées dans cette thèse, nous avons effectué de nombreux tests en utilisant le rapport de classification afin d'afficher *precision*, *recall*, et *F1-score* du modèle

Avant d'expliquer ces termes, les symboles ci-dessous sont expliqués.

TP (Vrais Positifs) : la prédiction est positive et la valeur réelle est positive. TN (vrais négatifs) : la prédiction est négative et la valeur réelle est négative. FP (faux positifs) : la prédiction est positive tandis que la valeur réelle est négative. FN (faux négatifs) : la prédiction est négative tandis que la valeur réelle est positive.

La matrice 2.2 peut être utilisée pour définir une variété de métriques :

La précision (PREC) est représentée par le rapport entre le nombre total de vrais positifs correctement classés (TP) et le nombre total de vrais positifs et de faux positifs (TP+FP), elle est aussi appelée valeur prédictive positive (positive predictive value (PPV) en anglais), voir

l'équation 2.26. La meilleure précision est de 1,0, tandis que la pire est de 0,0.

$$Precision = \frac{(TP)}{(TP + FP)} \quad (2.26)$$

Negative Predictive Value (NPV) :

$$NPV = \frac{TN}{TN + FN} \quad (2.27)$$

Taux de faux positifs (FPR : False Positif Rate) :

$$FPR = \frac{FP}{FP + TN} = 1 - TNR \quad (2.28)$$

Taux de faux négatifs (FNR : False Negative Rate) :

$$FNR = \frac{FN}{FN + TP} = 1 - TPR \quad (2.29)$$

Sensibilité, Recall ou taux de vrais positifs (TPR : True Positive Rate en anglais) est le rapport du nombre total de vrais positifs correctement classés divisé par le nombre total de vrais positifs et de faux négatifs, voir l'équation 2.30.

$$Recall = \frac{(TP)}{(TP + FN)} \quad (2.30)$$

La spécificité ou taux de vrais négatifs (TNR : True Negative Rate en anglais) est le nombre de prédictions négatives correctes divisé par le nombre total de négatifs. La meilleure spécificité est de 1,0, alors que la pire est de 0,0.

$$TNR = \frac{(TN)}{(TN + FP)} \quad (2.31)$$

Le taux de faux positifs (False positive rate(FPR) en anglais) est le nombre de prédictions positives incorrectes divisé par le nombre total de négatifs. Le meilleur taux de faux positifs est de 0,0 alors que le pire est de 1,0. il peut également être représenté par $1 - \text{spécificité}$.

$$FPR = \frac{(FP)}{(FP + TN)} \quad (2.32)$$

Taux de bonne classification également appelé Accuracy (ACC) est un rapport de classifica-

tion de toutes les données correctement classées dans l'ensemble du test. Autrement dit, ACC est le nombre de toutes les prédictions correctes ($TP+TN$) divisé par le nombre total de l'ensemble de données ($TP+TN+FP+FN$), voir l'équation 2.33. La meilleure précision est de 1,0, tandis que la pire est de 0,0. Il peut aussi être calculé par $1 - ERR$.

$$Accuracy = \frac{(TP + TN)}{(TP + TN + FP + FN)} \quad (2.33)$$

F1-Score est une moyenne harmonique de précision ($PREC$) et de Sensibilité ($Recall$). un score proche de 1 indique un classificateur parfait, tandis qu'un score autour de 0 indique un mauvais classificateur, voir l'équation 2.34. Le F1-Score est également connu sous le nom de F-Measure. Le score F1 indique l'équilibre entre la précision et le rappel.

$$F1 - Score = \frac{(2 \times Recall \times PREC)}{(Recall + PREC)} \quad (2.34)$$

Le coefficient kappa mesure l'accord entre la classification et les valeurs de vérité. Une valeur kappa de 1 représente un accord parfait, tandis qu'une valeur de 0 représente aucun accord. Le coefficient kappa est calculé comme suit :

$$Kappa = \frac{Accuracy - RandomAccuracy}{1 - RandomAccuracy} \quad (2.35)$$

d'où $RandomAccuracy$ est définie comme la somme des produits de la vraisemblance de référence et de la vraisemblance du résultat pour chaque classe. Il peut s'écrire :

$$RandomAccuracy = \frac{(TN + FP) \times (TN + FN) + (FN + TP) \times (FP + TP)}{(TP + TN + FP + FN)^2} \quad (2.36)$$

2.7 Conclusion

Dans le premier chapitre, nous avons exposé les différentes méthodes d'analyse de la texture, et parmi elles nous avons mis l'accent dans ce chapitre sur le descripteur LBP, qui est l'un des descripteurs les plus performants et les plus utilisées pour la classification des textures.

Nous avons commencé par exposer les détails du LBP et ses dérivés ; le LBP original et ses premières variantes utilisant divers mappages comme uniforme et invariant à la rotation. Ensuite, nous avons examiné, décrit, analysé et résumé les différentes dérivations de la variante LBP

proposées par les chercheurs dans la littérature, qui sont souvent fondées sur des informations de voisinage, d'échelle ou d'intensité. Cette revue comprenait les avantages, les limites, les objectifs et l'efficacité des variations du LBP. Enfin, nous avons décrit le concept de la classification ainsi que les algorithmes de classification les plus utilisés pour la classification des textures, en rappelant vers la fin les techniques d'évaluation d'un système de classification.

Bien que Ojala et al. [1996b] aient proposé LBP, qui présente plusieurs avantages, tels que son faible coût de complexité de calcul, sa faible sensibilité à l'illumination et son invariant de rotation. Cependant, LBP souffre de plusieurs inconvénients, tels que son incapacité à résister au bruit et sa taille de descripteur, en particulier dans les grandes applications. En général, les approches existantes visent soit à augmenter les performances du LBP d'origine, soit à réduire sa taille. Chacune des publications discutées dans ce chapitre a atteint un certain objectif, mais comme indiqué, la littérature manque d'un descripteur qui combine le pouvoir discriminatif, l'augmentation des performances et la réduction de la taille des caractéristiques vectorielles. Il existe donc un besoin de proposer d'autres descripteurs avec de telles propriétés, qui sera l'objectif du chapitre suivant.

LES VARIANTES DE LBP EN UTILISANT L'HOMOGENÉITÉ

Sommaire

3.1	Introduction	77
3.2	<i>Homogeneous local binary pattern</i> (HLBP)	77
3.2.1	Le principe du descripteur HLBP	79
3.2.2	Résultats expérimentaux	80
3.2.2.1	Procédure expérimentale	80
3.2.2.2	Étude expérimentale 1 : performance sur l'invariance à la rotation et à l'échelle	81
3.2.2.3	Étude expérimentale 2 : amélioration HLBP en comparant avec LBP	81
3.2.3	Discussion	83
3.3	<i>Homogeneous rotated local binary pattern</i> (HRLBP)	84
3.3.1	Le principe du descripteur (HRLBP)	85
3.3.2	Résultats expérimentaux	87
3.3.2.1	Le choix des paramètres	87
3.3.2.2	Étude expérimentale 1 : évaluer la robustesse dans la variation de rotation	87
3.3.2.3	Étude expérimentale 2 : renforcer HRLBP en comparant avec LBP	89
3.3.3	Discussion	89
3.4	<i>Completed homogeneous LBP</i> (CHLBP) pour la classification des images de télédétection	90
3.4.1	Le principe de la méthode CHLBP	91
3.4.2	Analyse expérimentale	93

3.4.2.1	Données et zone étudiée	93
3.4.2.2	Résultats expérimentaux sur la base de données <i>Outex</i>	94
3.4.2.3	Résultats expérimentaux sur la base de données <i>GID</i> et <i>AID RS</i>	96
3.4.3	Conclusion	98

3.1 Introduction

En se fondant sur les conclusions tirées du deuxième chapitre 2, nous allons développer dans ce chapitre trois nouvelles approches de représentation binaire, qui seront des variantes de la méthode d'analyse de la texture LBP. Ce chapitre est organisé ainsi : nous commencerons par introduire le concept des deux premières contributions nommées «*homogeneous local binary pattern (HLBP)*» et «*homogeneous rotated local binary pattern (HRLBP)*» qui sont fondées sur un critère d'homogénéité provenant d'une méthode d'analyse de la texture appelée *general adaptive neighborhood (GAN)*. Ensuite, afin d'améliorer le descripteur HLBP et de surmonter les limites du descripteur LBP spécialement dans la caractérisation des images de télédétection de grande dimension avec un contenu sémantique complexe, nous présenterons notre troisième contribution destinée à la caractérisation de la texture dans le contexte de la classification par télédétection -*remote sensing (RS)* en anglais-, intitulée (completed homogeneous LBP (CHLBP)). Nous évaluerons les performances de nos descripteurs (HLBP, HRLBP, CHLBP) à l'aide de quatre bases de données de textures complexes : *Outex (TC10, TC12)*, *Gaofen Image Dataset (GID)* et *large-scale aerial (AID)*. Diverses expérimentations approfondies ont été réalisées et ont démontré l'efficacité et la robustesse de nos descripteurs, elles seront discutées dans ce chapitre

3.2 Homogeneous local binary pattern (HLBP)

L'analyse de texture est considérée unanimement comme l'un des problèmes les plus ardues et les plus difficiles de la reconnaissance des formes informatisées, en raison de la similitude des caractéristiques spectrales entre les différentes surfaces. Cependant, jusqu'à présent, elle était considérée comme la seule manière puissante pouvant présenter une discrimination fondamentale fondée sur diverses méthodes d'extraction de caractéristiques utilisées dans le traitement et la reconnaissance d'images.

Afin de permettre une classification efficace de la texture, deux étapes principales sont néces-

saires : la phase d'extraction des caractéristiques et celle de classification. Cette dernière permet de générer un modèle à partir de caractéristiques compactes et discriminantes extraites de la première phase. Pour extraire des caractéristiques, plusieurs approches ont été développées. Spécifiquement, le descripteur local binary patterns (LBP) (pour plus de détails, voir la section 2.2) a obtenu une attention importante en raison de sa robustesse et de ses performances face à l'illumination et à la variation d'échelle avec une complexité algorithmique minimale. Pour davantage de détails voir les deux premiers chapitres (1 et 2).

Récemment, Pinoli and Debayle [2009] ont proposés la méthode *GAN-based Minkowski maps* destinée à l'analyse de textures, comme étant une technique puissante qui a déjà prouvé son efficacité sur les images en niveaux de gris et en couleurs de manière locale, adaptative et multi-échelle. Puis, elle a été combinée avec le descripteur LBP pour classer les lésions cutanées dans (González-Castro et al. [2015]). L'idée est de réaliser l'extraction des caractéristiques géométriques pour chaque pixel de l'image de la texture en se fondant sur le GAN, avant de calculer le LBP pour les caractériser. Les inconvénients de cette approche sont : le traitement global de l'image, ce qui permet d'extraire des caractéristiques globales qui conduisent à perdre des informations discriminantes des images et sa sensibilité aux variations d'éclairage et de rotation.

Dans cette première contribution, pour obtenir de meilleurs détails de l'image, nous avons présenté une nouvelle méthode LBP fondée sur l'impact de la tolérance homogène utilisée dans la méthode *general adaptive neighborhood* (Pinoli and Debayle [2009], González-Castro et al. [2015]) nommée *homogeneous local binary pattern* HLBP. Celle-ci permet de surmonter l'inconvénient de l'approche initiale en utilisant un seuillage établi sur un critère choisi, tel que la luminance, le contraste, l'épaisseur, etc. Les valeurs des critères de pixel s'inscrivent dans une plage spécifiée de tolérance d'homogénéité qui permet de mieux prendre en considération les relations entre les pixels voisins. Par conséquent, les voisinages des pixels correspondent davantage aux structures spatiales sous-jacentes. Ainsi, le descripteur HLBP obtient plus de caractéristiques intrinsèques de l'image. Le descripteur proposé offre des caractéristiques discriminantes robustes et puissantes en basse dimension qui sont utilisées comme entrées du classificateur SVM.

Dans la suite de cette section, nous allons commencer par une explication approfondie de notre nouvelle approche HLBP. Nous présenterons ensuite les études expérimentales que nous avons conduites pour mettre en avant le descripteur HLBP en comparaison avec les méthodes de l'état de l'art.

3.2.1 Le principe du descripteur HLBP

Dans cette section, nous décrivons en détail notre nouvelle approche proposée HLBP, afin d'améliorer le LBP et d'obtenir des caractéristiques d'image plus intrinsèques.

Tout d'abord, nous avons observé que GAN est généralement une zone homogène qui utilise une tolérance d'homogénéité h avec une fonction de critère (luminance, contraste, etc.), qui le rend robuste par rapport aux autres méthodes d'analyse des images en niveaux de gris et en couleurs. Par conséquent, sur la base de cette observation, nous proposons le descripteur HLBP qui vise à améliorer l'approche LBP en utilisant la condition de critère d'homogénéité de ses pixels voisins g_i qui sont proches de celui du centre g_c . Formellement, le $HLBP_{P,R}$ est défini comme :

$$HLBP_{P,R,h}(x,y) = \sum_{i=0}^{P-1} s(g_i, g_c) 2^i, \quad (3.1)$$

$$s(g_i, g_c) = \begin{cases} 1 & \{|f(g_i) - f(g_c)| \leq h\} \\ 0 & otherwise \end{cases} \quad (3.2)$$

Comme le LBP, g_c est le centre du pixel, g_i présente les pixels voisins pour la position i^{th} , P et R sont respectivement le nombre de voisins et le rayon. $s()$ présente la fonction de signe avec un nouveau paramètre d'ajout pour HLBP qui est la tolérance d'homogénéité $h \in \mathbb{R}^+$ par rapport au critère (luminance, contraste, etc.) f qui aide à seuiller tous les pixels voisins dans un intervalle spécifique.

Afin de générer le code HLBP, nous devons suivre ces étapes :

1. Tout d'abord, nous devons spécifier la taille de la fenêtre en choisissant le rayon R et le nombre d'échantillons de pixels voisins P .
2. Deuxièmement, nous devons préciser la tolérance d'homogénéité h en considérant dans notre approche le critère de luminance $f \equiv N$ (N est l'intensité des pixels) pour obtenir les pixels adjacents à g_c par rapport au critère de mappage.
3. La phase finale est de calculer le code du LBP homogène. Dans cette étape, la valeur du centre est remplacée par le code binaire des voisins qui sont seuillés par rapport au pixel central $|f(g_i) - f(g_c)| \leq h$. Précisément, chaque pixel est seuillé par tolérance d'homogénéité h avec ses voisins en soustrayant la valeur du pixel central. Les valeurs résultantes qui respectent les seuils sont codées soit avec 1, soit avec 0. Ensuite, tous les

nombres binaires sont concaténés pour obtenir un code décimal qui étiquette le pixel.

Pour clarifier l'approche que nous proposons, nous illustrons dans la figure 3.1 la procédure complète du HLBP avec des paramètres spécifiques de R et P (8,1). Nous avons pris un exemple de motif local avec un centre $g_c = 190$, nous substituons tous les voisins $|g_c - g_i|$ puis nous les comparons avec la tolérance d'homogénéité que nous choisissons dans cet exemple par $h = 15$, qui va nous permettre par la suite de générer le code binaire «10001101».

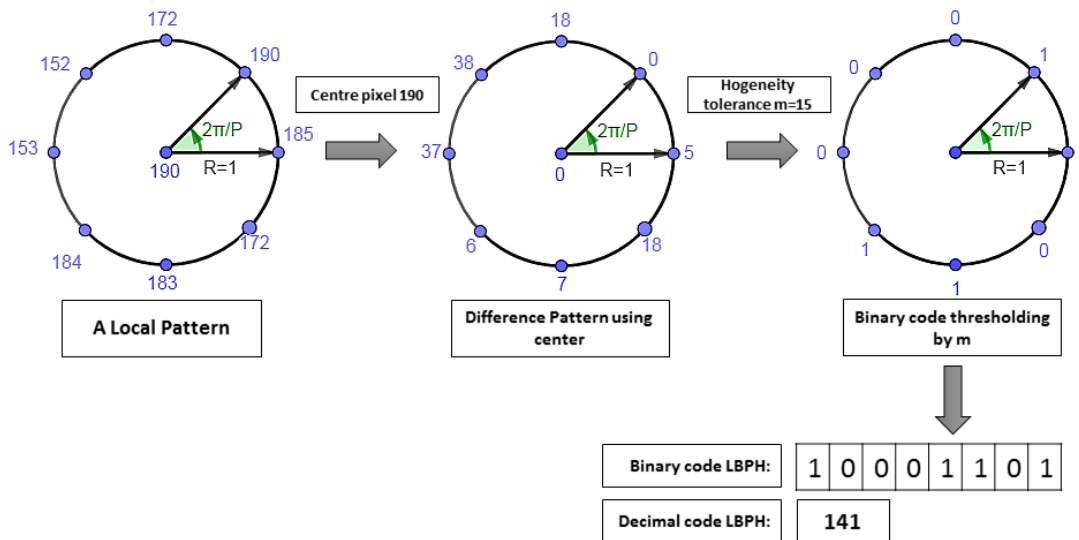


FIGURE 3.1 – Exemple du HLBP de ($P=8, R=1$) et $m=15$.

3.2.2 Résultats expérimentaux

L'objectif de cette section est de déterminer l'efficacité de HLBP dans la classification des textures.

3.2.2.1 Procédure expérimentale

Dans le cadre de l'étape de la classification, nous avons utilisé l'algorithme SVM. Les paramètres du SVM ont été calculés automatiquement à partir de la validation croisée par 10-fold. Étant donné que les différents vecteurs caractéristiques ont été calculés sur de nombreuses

échelles, une normalisation a été effectuée afin de ramener toutes les données numériques à une même échelle (Hsu and Lin [2002]).

Dans notre méthode proposée (HLBP), nous utilisons la variation de deux paramètres : rayon $R = 1, 2, 3, 4, 5, 6$ et la tolérance d'homogénéité $m = 5, 10, 15, 20, 30$. Cette variation permet d'extraire des HLBP en multi-échelles. Afin de réduire la dimension des caractéristiques et le temps de calcul, nous avons fixé P à 8 pixels voisins pour tout R . Dans le but d'évaluer les performances de notre descripteur, nous utilisons *Outex_TC_10* ; pour plus de détails, voir la section 1.6.1. Le tableau 3.1 illustre les résultats de l'expérience.

3.2.2.2 Étude expérimentale 1 : performance sur l'invariance à la rotation et à l'échelle

Dans la première étude expérimentale, nous comparons notre méthode (HLBP) avec le descripteur de texture fondé sur LBP «general adaptive neighborhood-Minkowski local binary pattern descriptor» présenté dans (González-Castro et al. [2015]).

Il est clairement remarquable que notre descripteur proposé (HLBP) offre un meilleur taux de classification par rapport à GANLBP. En effet, pour $h = 15$ nous avons obtenu comme taux de classification les valeurs 92,48 % , 98,40 % et 98,17 % pour $R = 1, 2$ et 3 respectivement. De plus, ils obtiennent également de bons résultats : 98,17 % , 98,66 % et 97,87 % dans les différents paramètres de la tolérance d'homogénéité $h = 15, h = 20$ et $h = 30$ respectivement. La figure 3.2 illustre des exemples de HLBP utilisant différentes tolérances d'homogénéité h et rayon R . De manière générale, notre approche HLBP donne de meilleures performances en capturant plus de caractéristiques intrinsèques de l'image grâce à l'utilisation d'un seuil de tolérance d'homogénéité h permettant de mieux prendre en compte les relations entre les pixels voisins .

3.2.2.3 Étude expérimentale 2 : amélioration HLBP en comparant avec LBP

Dans le tableau 3.1 pour la tolérance d'homogénéité $h = 15$, notre approche surpasse LBP pour la majeure partie du rayon. Cependant, nous ne sommes pas arrêtés là, nous voulions améliorer la robustesse de HLBP afin qu'il puisse surpasser le LBP dans n'importe quelle variation multi-échelle (rayon et tolérance à l'homogénéité), nous avons donc présenté cette deuxième expérience. L'idée est de fusionner les histogrammes HLBP et LBP.

Comme prévu, les performances des autres descripteurs tels que GANLBP + LBP et LBP

TABLEAU 3.1 – Taux de la classification (%) du descripteur HLBP et HLBP+LBP pour différentes valeurs de rayon R en utilisant *Outex-TC-10* comme base de données.

R	Approches	La tolérance d'homogénéité h				
		5	10	15	20	30
1	LBP original	96.26%				
	GANLBP	79.54%	85.51%	89.10%	90.16%	89.79%
	HLBP	95.69%	95.19%	92.48%	87.96%	69.19%
	GANLBP+LBP	97.80%	98.40%	98.52%	98.73%	98.47%
	HLBP+LBP	99.00%	98.35%	98.59%	99.05%	98.59%
2	LBP original	97.10%				
	GANLBP	82.55%	97.19%	88.73%	90.60%	92.48%
	HLBP	92.24%	98.38%	98.40%	97.73%	95.35%
	GANLBP+LBP	98.89%	97.25%	99.21%	99.12%	99.05%
	HLBP+LBP	99.31%	99.51%	99.54%	99.38%	99.35%
3	LBP original	97.94%				
	GANLBP	79.72%	81.44%	85.37%	88.10%	90.02%
	HLBP	87.01%	96.48%	98.17%	98.66%	97.87%
	GANLBP+LBP	98.68%	99.00%	99.42%	99.10%	99.03%
	HLBP+LBP	99.00%	99.38%	99.70%	99.51%	99.49%
4	LBP original	96.71%				
	GANLBP	78.45%	85.37%	85.51%	88.61%	90.46%
	HLBP	84.93%	94.31%	96.09%	96.00%	96.16%
	GANLBP+LBP	98.80%	99.03%	99.17%	99.00%	99.44%
	HLBP+LBP	99.05%	99.33%	99.54%	99.58%	99.61%
5	LBP original	94.00%				
	GANLBP	80.09	72.63%	80.30%	81.51%	82.78%
	HLBP	80.16%	90.79%	94.47%	94.58%	96.04%
	GANLBP+LBP	97.85%	98.08%	97.73%	97.73%	98.26%
	HLBP+LBP	97.41%	98.31%	98.91%	98.94%	98.80%
6	LBP original	94.12%				
	GANLBP	78.13%	80.42%	79.81%	79.68%	80.28%
	HLBP	79.38%	90.49%	94.42%	95.60%	95.51%
	GANLBP+LBP	97.36%	97.66%	97.94%	97.57%	97.25%
	HLBP+LBP	97.85%	98.66%	99.14%	99.07%	98.98%

diminuent pour cette base de données en raison de la perte d'informations structurelles, tandis que HLBP+LBP maintient ses performances devant les autres méthodes par une marge qui démontre sa robustesse avec les critères d'homogénéité h . Pour $h = 15$ nous obtenons 98.59 % 99.54 % 99.70 % 99.54 % 98.91 % 99.14 % dans $R = 1, 2, 3, 4, 5$ et 6 respectivement.

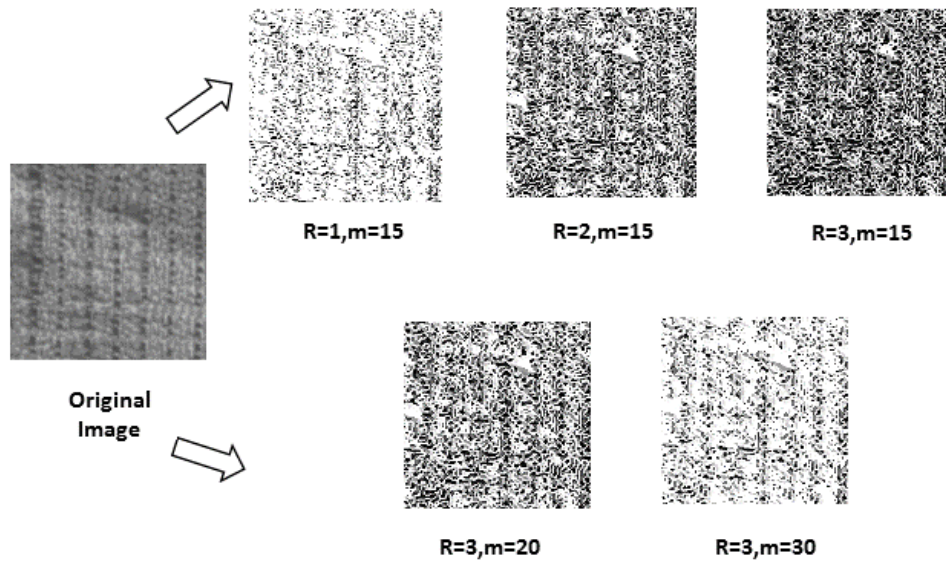


FIGURE 3.2 – Exemple d’images HLBP employant différents paramètres.

3.2.3 Discussion

Dans cette première partie du chapitre, nous avons proposé un nouveau descripteur de classification de texture HLBP qui permet une extraction d’informations discriminantes robustes à partir d’images de texture en utilisant un seuil de tolérance d’homogénéité h , ce qui amène à prendre en compte la relation entre les pixels voisins. En conséquence, les voisinages de pixels sont considérablement plus étroitement liés aux structures spatiales sous-jacentes. Différentes expériences ont été menées en utilisant l’une des bases de données de textures accessibles au public *Outex_TC_10* afin de démontrer les performances et la robustesse de notre technique. Dans la première étude expérimentale, nous avons montré la robustesse de notre descripteur HLBP à l’invariance à la rotation dans la plupart des variations multi-échelles (rayon et tolérance d’homogénéité) en comparaison avec les méthodes initiales dont nous nous sommes inspirées telles que LBP originale et GANLBP, comme présenté dans l’article (González-Castro et al. [2015]). Ensuite, nous avons entrepris une autre étude expérimentale qui vise à surpasser le LBP originale dans toutes les variations multi-échelles (rayon et tolérance d’homogénéité) en utilisant la concaténation ou la combinaison des deux descripteurs (HLBP+LBP). Comme prévu, HLBP obtient des résultats prometteurs sur la base de données *Outex* en comparant avec les descripteurs de l’état de l’art. À travers cette étude, nous avons introduit une nouvelle approche qui vise à renforcer la méthode HLBP afin de mieux prendre en compte les caractéristiques intrinsèques

des images en rotation changeante.

3.3 Homogeneous rotated local binary pattern (HRLBP)

Dans notre première contribution HLBP nous avons visé à améliorer la performance du descripteur LBP en utilisant un nouveau paramètre provenant du descripteur GAN-*based Minkowski maps* (González-Castro et al. [2015]). En nous fondant sur la discussion de la section précédente 3.2.3, nous allons développer dans cette section une autre nouvelle contribution visant à améliorer le côté invariant à la rotation du HLBP en utilisant une variante du LBP nommée *rotated LBP* (RLBP) (pour plus de détails, voir la section 2.5.3), qui traite l'invariant de rotation pour l'analyse de la texture en utilisant le décalage, ce qui entraîne une invariance de rotation car les poids dépendent du voisinage. En conséquence, les caractéristiques sont mieux capables de détecter les variations de rotation.

En générale, à base du descripteur GAN-*based Minkowski maps* qui a été combiné avec le descripteur LBP pour classer les lésions cutanées dans (González-Castro et al. [2015]), et du descripteur RLBP qui présente une technique puissante pour traiter l'invariant de rotation pour l'analyse de la texture, nous avons proposé une approche robuste et discriminante des invariants de rotation *homogeneous rotated local binary pattern* (HRLBP) dédiée à la réalisation de RLBP en utilisant l'influence de la tolérance d'homogénéité m dans le principe de GAN (González-Castro et al. [2015], Pinoli and Debayle [2009]).

L'idée principale de notre contribution dans cette section est : (1) exploiter la tolérance d'homogénéité h en utilisant un seuil établi sur un critère choisi, notamment la luminance, le contraste, l'épaisseur, etc. pour garder la même homogénéité du pixel même dans le cas d'une rotation ou d'un retournement sur la région, afin d'attirer plus d'attention sur la relation entre les pixels voisins qui correspondent davantage aux structures spatiales sous-jacentes. (2) en utilisant l'homogénéité dans le RLBP comme un descripteur robuste à l'invariance à la rotation, obtenu en décalant circulairement les poids en fonction de la direction dominante (indice de différence maximale entre le centre et les voisins). Fondé sur les influences réciproques de ces deux points, notre nouveau descripteur HRLBP augmente le pouvoir discriminant des caractéristiques extraites localement des images en rotation. Nous le démontrons en utilisant la base de données classique *Outex* pour l'analyse de la texture et le classificateur SVM. Les modifications suggérées peuvent fortement améliorer les performances du taux de classification.

Dans la suite de cette section, nous allons commencer par une explication approfondie de

notre nouvelle approche HRLBP. Nous présenterons ensuite les études expérimentales que nous avons conduites pour mettre en avant le descripteur HRLBP en comparaison avec les méthodes de l'état de l'art.

3.3.1 Le principe du descripteur (HRLBP)

Notre nouvelle proposition HRLBP, sera présentée en détail dans cette section. L'idée principale de cette approche est d'améliorer le descripteur RLBP en obtenant une information discriminante intrinsèque sur la texture locale au niveau des changements de rotation.

Parmi les méthodes d'analyse de la texture, nous avons remarqué que le GAN est un descripteur robuste par rapport aux approches existantes, en raison de son traitement d'image établi sur une région homogène utilisant la valeur de tolérance d'homogénéité h par rapport à la fonction de critère f comme : luminance, contraste, etc. Pour cette raison, nous pensons à proposer une nouvelle approche plus puissante nommée HRLBP qui vise à obtenir la caractéristique intrinsèque des images en changement de rotation. Pour cela, il faut considérer l'impact de la tolérance d'homogénéité h entre le centre g_c et ses pixels voisins g_n . Ces derniers permettent de garder la même homogénéité du pixel, même s'ils ont une rotation ou un retournement sur la région, grâce à sa capacité de capturer plus d'attention sur la relation entre les pixels voisins qui correspondent plus aux structures spatiales sous-jacentes.

Officiellement, le $HRLBP_{P,R,h}$ est défini comme :

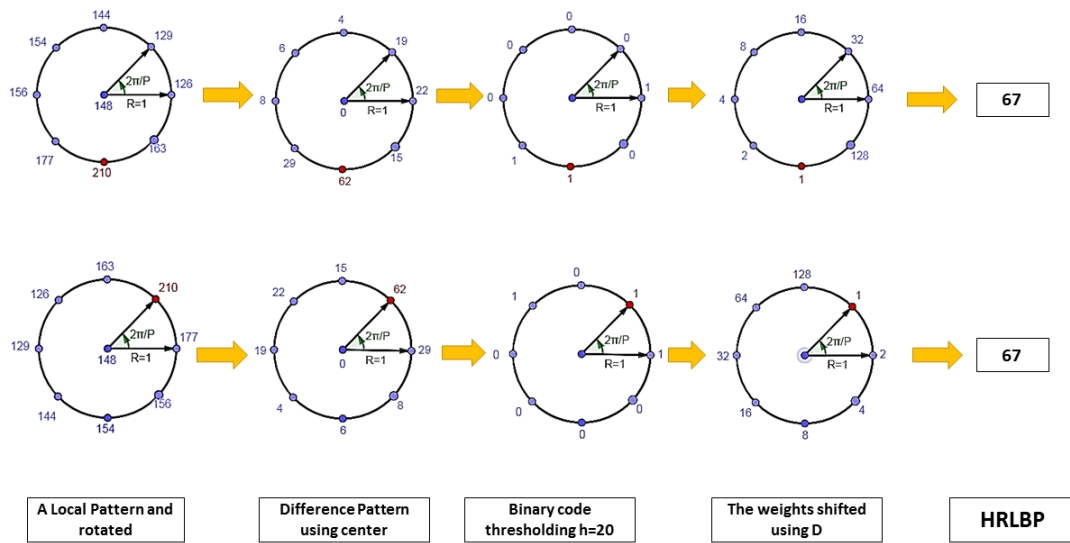
$$HRLBP_{P,R,h}(x, y) = \sum_{n=0}^{P-1} s(g_n - g_c) 2^{\text{mod}(n-D, P)}, \quad (3.3)$$

$$s(g_n, g_c) = \begin{cases} 1 & \{|f(g_n) - f(g_c)| \geq h\} \\ 0 & \text{otherwise} \end{cases} \quad (3.4)$$

où D est la direction dominante, $2^{\text{mod}(n-D, P)}$ présente le terme de pondération par rapport à D . P et R correspondent respectivement à un nombre d'échantillons (pixels voisins) et au rayon. Dans cette équation, nous avons ajouté un nouveau paramètre à la fonction de signe $s()$ qui aide à remplir tous les pixels voisins dans un intervalle spécifique nommé le critère de tolérance d'homogénéité h concernant la fonction critère (luminance, contraste, etc.) f .

Pour obtenir le code HRLBP, plusieurs étapes sont nécessaires :

— Après avoir choisi le nombre d'échantillons de pixels voisins P ainsi que le rayon R , nous

FIGURE 3.3 – Exemple de HRLBP de $(N=8, R=1)$ et $h=20$.

devons spécifier la tolérance d’homogénéité h par rapport au critère de luminosité $f \equiv N$ (N est l’intensité du pixel), qui aide à obtenir des pixels adjacents au centre g_c en relation avec le critère de mappage.

- Pour calculer le code de HRLBP il faut tout d’abord déterminer la direction dominante D . Ensuite, chaque pixel est seuillé avec ses voisins $|f(g_n) - f(g_c)| \geq h$ par le paramètre de la tolérance d’homogénéité h , en soustrayant la valeur du pixel central. Le résultat qui respecte les valeurs seuils est encodé soit avec 1, soit avec 0. Ensuite, selon la valeur de l’indice D , le poids le plus bas est indiqué et le code décimal HRLBP est obtenu.

La figure 3.3 représente un exemple de l’approche que nous proposons. Des paramètres spécifiques de P et R sont choisis $(8,1)$. Premièrement, la direction dominante est déterminée pour les images d’origine et de rotation. Dans cet exemple il est spécifié à 210. On substitue tous les voisins $|g_c - g_n|$ du centre $g_c = 148$ puis on le compare avec la tolérance d’homogénéité que nous avons fixé à $h = 20$. Pour composer le code binaire, les poids les plus bas sont circulaires à l’indice de D afin d’obtenir pour les deux $HRLBP = 67$.

3.3.2 Résultats expérimentaux

L'approche proposée est évaluée en deux étapes. Dans la première, nous avons estimé la robustesse de HRLBP dans la variation à la rotation par une variété de valeurs de rayon et d'homogénéité tolérance. Puis, nous avons évalué HRLBP en le comparant au descripteur original LBP.

3.3.2.1 Le choix des paramètres

Dans cette étape, l'algorithme SVM est employé avec les mêmes descriptions du paramètre que l'approche précédente HLBP. Comme mentionné précédemment, notre nouveau descripteur a trois paramètres tolérance d'homogénéité $h = (5, 10, 15, 20, 30)$, rayon $R = (1, 2, 3, 4, 5, 6)$ et $N = (8, 16, 24)$ nombre de voisins. Dans le but de réduire la dimension des caractéristiques et le temps de calcul, nous fixons N à 8 voisins et nous faisons varier h et R . Afin d'évaluer la qualité de notre nouvelle méthode au niveau de la rotation et de la variation multi-échelle, nous utilisons *Outex_TC_10* (plus de détail dans la section 1.6.1). Le tableau 3.2 présente les résultats des expériences.

3.3.2.2 Étude expérimentale 1 : évaluer la robustesse dans la variation de rotation

Dans cette première expérience, nous évaluons notre descripteur de texture HRLBP en comparant avec l'approche «GAN-Minkowski based LBP» issue de la combinaison des deux descripteurs GAN-Minkowski et LBP proposée par González-Castro et al. [2015].

En se fondant sur les résultats de cette expérience, nous avons fait les observations suivantes : pour la majorité des résultats, le taux de classification de notre approche unique HRLBP est meilleure que GANLBP ou RLBP classique, ce qui démontre que HRLBP maintient ses performances même en cas de rotation à plusieurs résolutions d'angle (0, 5, 10, 15, 30, 45, 60, 75 et 90) et multi-échelles (h, R) : par exemple, lorsque $h = 15$, nous avons trouvé 92,69 %, 98,31 % et 98,31 % pour $R = 1, 2$ et 3 respectivement. En outre, l'approche proposée atteint également les meilleures taux de classification en utilisant diverses tolérances d'homogénéité $h = 10, 15, 20, \text{ et } 30$: 96,46%, 98,31%, 98,66% et 97,69% respectivement.

TABLEAU 3.2 – Taux de la classification (%) du descripteur HRLBP et HRLBP+RLBP pour différentes valeurs de rayon R et d'homogénéité h sur la base de données *Outex-TC-10*.

R	Approches	La tolérance d'homogénéité h				
		5	10	15	20	30
1	RLBP classic	96.32%				
	GANLBP	79.54%	85.51%	89.10%	90.16%	89.79%
	HRLBP	95.51%	96.15%	92.69%	87.52%	69.42%
	GANLBP+LBP	97.80%	98.40%	98.52%	98.73%	98.47%
	HRLBP+RLBP	99.02%	98.84%	98.59%	98.91%	98.54%
2	RLBP classic	97.27%				
	GANLBP	82.55%	97.19%	88.73%	90.60%	92.48%
	HRLBP	92.22%	98.21%	98.31%	97.98%	95.19%
	GANLBP+LBP	98.89%	97.25%	99.21%	99.12%	99.05%
	HRLBP+RLBP	99.17%	99.49%	99.56%	99.28%	99.26%
3	RLBP classic	97.89%				
	GANLBP	79.72%	81.44%	85.37%	88.10%	90.02%
	HRLBP	87.04%	96.46%	98.31%	98.66%	97.69%
	GANLBP+LBP	98.68%	99.00%	99.42%	99.10%	99.03%
	HRLBP+RLBP	99.07%	99.51%	99.72%	99.63%	99.51%
4	RLBP classic	96.48%				
	GANLBP	78.45%	85.37%	85.51%	88.61%	90.46%
	HRLBP	84.56%	94.26%	96.09%	96.11%	96.23%
	GANLBP+LBP	98.80%	99.03%	99.17%	99.00%	99.44%
	HRLBP+RLBP	99.07%	99.26%	99.56%	99.56%	99.63%
5	RLBP classic	93.77%				
	GANLBP	80.09	72.63%	80.30%	81.51%	82.78%
	HRLBP	80.16%	91.04%	94.51%	94.49%	96.00%
	GANLBP+LBP	97.85%	98.08%	97.73%	97.73%	98.26%
	HRLBP+RLBP	97.18%	98.24%	98.63%	98.73%	98.77%
6	RLBP classic	93.68%				
	GANLBP	78.13%	80.42%	79.81%	79.68%	80.28%
	HRLBP	79.70%	90.37%	94.56%	95.58%	95.32%
	GANLBP+LBP	97.36%	97.66%	97.94%	97.57%	97.25%
	HRLBP+RLBP	97.55%	98.68%	99.18%	99.10%	98.91%

3.3.2.3 Étude expérimentale 2 : renforcer HRLBP en comparant avec LBP

Dans cette deuxième expérience, nous avons remarqué que notre descripteur HRLBP ne maintient pas ses performances pour un certain rayon, même s'il le fait pour la majorité de l'homogénéité h , telle que $h = 15$. Cependant, pour augmenter progressivement les performances du HRLBP en obtenant des caractéristiques plus discriminantes par rapport à toutes les tolérances d'homogénéité et de rayon en comparant avec RLBP. Nous avons combiné l'histogramme de HRLBP avec RLBP en comparant avec le GANLBP qui est combiné avec LBP.

Les résultats de cette expérience sont présentés dans le tableau 3.2 et, comme prévu, notre descripteur HRLBP offre de meilleures performances que GANLBP + LBP et RLBP. Cela est dû au fait que la variation de rotation de la base de données entraîne des difficultés aux descripteurs GANLBP + LBP et RLBP de récupérer toutes les informations d'image, contrairement au HRLBP+RLBP qui maintiennent leur performance avec une marge de taux de classification très intéressante spécialement dans la variation du critère d'homogénéité h . Pour $h = 20$ nous obtenons 98.91% 99.28% 99.63% 99.56% 98.73% 99.10% dans $R = (1, 2, 3, 4, 5 \text{ et } 6)$ respectivement.

3.3.3 Discussion

Cette section présente notre deuxième nouveau descripteur de classification de texture HRLBP qui fournit des informations discriminantes et robustes, établi sur deux facteurs : premièrement, l'impact de l'homogénéité, qui permet de considérer la relation entre les pixels voisins, qui correspond plus aux structures spatiales sous-jacentes et deuxièmement, l'impact de RLBP en utilisant le décalage, ce qui entraîne une invariance de rotation car les poids dépendent du voisinage. En conséquence, les caractéristiques sont mieux capables de détecter les variations de rotation. En outre, en utilisant le paramètre ou le critère de tolérance d'homogénéité h et le rayon R , une variation multi-échelle peut être obtenue. Diverses expériences sont menées pour démontrer la performance et la robustesse de notre approche HRLBP à la variation de rotation, en utilisant l'une des bases de données de textures accessibles au public, *Outex_TC_10*. Similaire à la première contribution HLBP, cette deuxième contribution HRLBP a également démontré sa performance, passant par deux études expérimentales. La première est destinée à montrer l'efficacité de l'approche devant l'invariant à la rotation. C'était d'ailleurs le cas dans la plupart des variations multi-échelles (rayon et tolérance d'homogénéité) en comparaison avec les méthodes initiales dont nous sommes inspirées telles que le RLBP original et le GANLBP, comme présenté dans l'article (González-Castro et al. [2015]). Par la suite, en utilisant la concaténa-

tion ou la combinaison des deux descripteurs (HRLBP + RLBP), nous avons réalisé la deuxième étude expérimentale qui visait à surpasser le LBP original dans toutes les variations multi-échelles (rayon et tolérance à l'homogénéité). Comme prévu, le descripteur HRLBP a obtenu des résultats prometteurs sur la base de données *Outex* par rapport aux descripteurs de l'état de l'art.

Après avoir présenté les deux premières contributions HLBP et HRLBP, nous nous sommes intéressés par la suite à la caractérisation des images de télédétection de grande dimension avec un contenu sémantique complexe. Cependant, même si le descripteur LBP est largement accepté dans de multiples applications de texture grâce à sa simplicité et son efficacité, il est faible dans ce type d'images à cause de son utilisation exclusive d'informations de signe dans la région locale. Dans la section suivante, nous allons proposer une nouvelle variante de LBP pour la caractérisation de la texture dans le contexte de la classification par télédétection -*remote sensing* (RS) en anglais-, connue sous le nom de *completed homogeneous* LBP (CHLBP).

3.4 Completed homogeneous LBP (CHLBP) pour la classification des images de télédétection

La classification de la couverture terrestre repose fortement sur des informations spatiales dérivées d'images de télédétection à haute résolution. Il peut s'agir de catégoriser une image multi-spectrale de télédétection en différentes couvertures terrestres telles que la terre, la végétation, l'eau, etc. La texture, la forme, la couleur, le contraste et d'autres caractéristiques de la couverture terrestre peuvent être trouvés. La texture d'image fournit une source d'informations alternative qui permet une description simple et efficace des informations structurelles de l'image, qui a été largement utilisée dans RS (Yang et al. [2019]), classification d'image (Cai and Wei [2020]), segmentation d'image (Li et al. [2020]), et d'autres domaines du traitement de l'information.

Dans la majorité des situations (Coburn and Roberts [2004]) et (Li et al. [2010]), la précision globale s'est considérablement améliorée. Pour extraire des informations de texture à partir d'images satellites à classer, de nombreux chercheurs ont utilisé divers algorithmes tels que la matrice de co-occurrence de niveaux de gris (GLCM)(Zheng et al. [2018]), la transformation fondée sur les ondelettes (Emimal and Kannan [2018]), etc. Cependant, ces stratégies ont montré un potentiel, mais comme la plupart d'entre elles sont coûteuses en calcul, elles sont rarement réalisables dans des contextes opérationnels. De plus, les zones appartenant à une classe spécifique peuvent ne pas toujours présenter des caractéristiques spectrales uniformes à haute résolution spatiale. Cela signifie que les pixels adjacents sont souvent très divers en matière de couleur ou

de luminosité.

Généralement, il existe un descripteur local efficace pour modéliser le contenu de l'image RS, mais les relations spatiales entre les régions exposées dans une image, comme les limites, les distances et les orientations, ne sont pas bien modélisées. L'objectif de cette section est de proposer une nouvelle variante de LBP destinée à la caractérisation de texture dans le cadre de données d'images de classification RS. Tout d'abord, comme prévu dans le CLBP, la distribution hybride de tous leurs opérateurs préserve plus de caractéristiques intrinsèques et démontre leurs performances dans la précision de la classification des textures. De plus, l'impact de l'opérateur de tolérance d'homogénéité utilisé dans le HLBP fournit leur robustesse pour détecter les discontinuités dans les images de texture qui représentent une caractéristique importante, telles que les frontières. Par conséquent, les caractéristiques sont plus robustes pour détecter la variation de rotation. Sur cette base, nous avons développé notre nouveau descripteur connu sous le nom de «*Completed homogeneous LBP*» (CHLBP), qui combine les descripteurs HLBP et CLBP avec l'ajout d'un nouveau seuillage pour améliorer HLBP et obtenir une relation de profondeur entre le centre et ses pixels voisins. Ainsi, ce nouveau codage est capable d'acquérir plus d'informations intrinsèques, ce qui permet d'obtenir une précision de classification significativement améliorée, notamment dans le cadre de RS.

Cette étude est structurée comme suit : la section suivante présente en détail le descripteur proposé CHLBP ; ensuite, nous discutons les performances de la méthode proposée en utilisant des classificateurs par rapport aux approches de l'état de l'art.

3.4.1 Le principe de la méthode CHLBP

Le descripteur HLBP a démontré sa robustesse dans la collecte des caractéristiques les plus intrinsèques à partir des images en rotation. Cela est dû à l'usage de l'incidence de la tolérance d'homogénéité h avec les changements multi-échelles qui viennent de la variation des paramètres du rayon R . D'autre part, le CLBP a prouvé ses performances pour la classification des textures en se fondant sur deux composantes clés, comme mentionné précédemment dans la section 2.5.1 : le signe et la magnitude, ainsi qu'un troisième opérateur relié au centre, qui nous permet de capturer des informations de texture.

La motivation derrière la proposition de cette nouvelle méthode est d'augmenter la robustesse de la représentation des caractéristiques de HLBP en incorporant des informations locales supplémentaires provenant de CLBP, dans le but d'en extraire un autre plus robuste pour la

caractérisation de la texture dans le contexte RS.

Généralement, la nouvelle approche que nous proposons, notée *completed homogeneous* LBP (CHLBP), est générée en combinant quatre descripteurs CHLBP_S_INF, CHLBP_M_INF, CHLBP_S_SUP, et CHLBP_M_SUP. CHLBP est défini par les équations mathématiques suivantes : 3.5, 3.6, 3.7 et 3.8.

Tout d'abord, la fonction de signe a deux nouveaux paramètres ajoutés. La première est la tolérance d'homogénéité h , fournie par HLBP qui aide à remplir tous les pixels voisins dans un intervalle spécifique concernant la fonction critère (luminance, contraste, etc.) f ; l'autre critère est δ , qui permet de diviser les modèles en positifs et négatifs. Les équations mathématiques de CHLBP_S sont décrites comme suit :

$$CHLBP_S_INF_{R,P}(c) = \sum_{i=0}^{P-1} s_{inf}(g_i, g_c)2^i, \quad (3.5)$$

$$\text{where } s_{inf}(g_i, g_c) = \begin{cases} 1 & \{|f(g_i) - f(g_c) - \delta| \leq h\} \\ 0 & \text{otherwise} \end{cases},$$

$$CHLBP_S_SUP_{R,P}(c) = \sum_{i=0}^{P-1} s_{sup}(g_i, g_c)2^i, \quad (3.6)$$

$$\text{where } s_{sup}(g_i, g_c) = \begin{cases} 1 & \{|f(g_i) - f(g_c) + \delta| \leq h\} \\ 0 & \text{otherwise} \end{cases},$$

g_c , g_i , P et R définis comme l'équation 3.1. $s_{inf}()$ et $s_{sup}()$ sont deux fonctions de signe présentes, les informations inférieure et supérieure avec une tolérance d'homogénéité $h \in \mathbb{R}^+$ qui permettent d'obtenir le signe des voisins dans la plage spécifique concernant la fonction critère $f()$.

Comme la composante de signe, la composante de magnitude de CHLBP est obtenue par la fusion des deux descripteurs de concept CLBP_M et HLBP avec un nouvel ajout de paramètre δ qui nous donne la possibilité de diviser la composante en motifs positifs et négatifs. Formellement, la caractéristique de code CHLBP_M est générée par les équations suivantes :

$$CHLBP_M_INF_{R,P}(c) = \sum_{i=0}^{P-1} t(m_inf_i, c)2^i, \quad (3.7)$$

$$\text{where } t(m_inf_i, a) = \begin{cases} 1 & m_inf_i \geq a \\ 0 & \text{otherwise} \end{cases},$$

$$\text{and } m_inf_i = |f(g_c) - f(g_i) - \delta - h| + |f(g_c) - f(g_i) - \delta + h|$$

$$CHLBP_M_SUP_{R,P}(c) = \sum_{i=0}^{P-1} t(m_sup_i, c)2^i, \quad (3.8)$$

$$\text{where } t(m_sup_i, a) = \begin{cases} 1 & m_sup_i \geq a \\ 0 & \text{otherwise} \end{cases},$$

$$\text{and } m_sup_i = |f(g_i) - f(g_c) - \delta + h| + |f(g_i) - f(g_c) - \delta - h|$$

$g_i, g_c, P, R,$ et $s()$ ont été mentionnés précédemment dans l'équation 3.1 et 3.2 respectivement, avec la nouvelle intégration de l'opérateur de tolérance d'homogénéité h .

Enfin, comme CLBP, un dernier opérateur a été ajouté également dans CHLBP, nommé CHLBP_Center qui est généré par :

$$CHLBP_C_{R,P}(c) = t(g_c, a_I), \quad (3.9)$$

où a_I indique le niveau de gris moyen de toute l'image, et comme mentionné précédemment, tous les paramètres ont été expliqués dans l'équation 3.1. La figure 3.4 montre les caractéristiques de texture après avoir été extraites par CHLBP.

3.4.2 Analyse expérimentale

Dans cette section, nous menons une série d'études expérimentales avec différentes bases de données pour évaluer les performances de la stratégie CHLBP.

3.4.2.1 Données et zone étudiée

Les bases de données de *Outex* (Ojala et al. [2002a]), *Gaofen Image Dataset* (GID) (Tong et al. [2020]) et *Aerial Image Dataset* (AID) (Xia et al. [2017]) représentent les ensembles de données qui sont utilisés dans nos expériences. Pour plus de détails, voir les sections 1.6.1, 1.6.5, et 1.6.6.

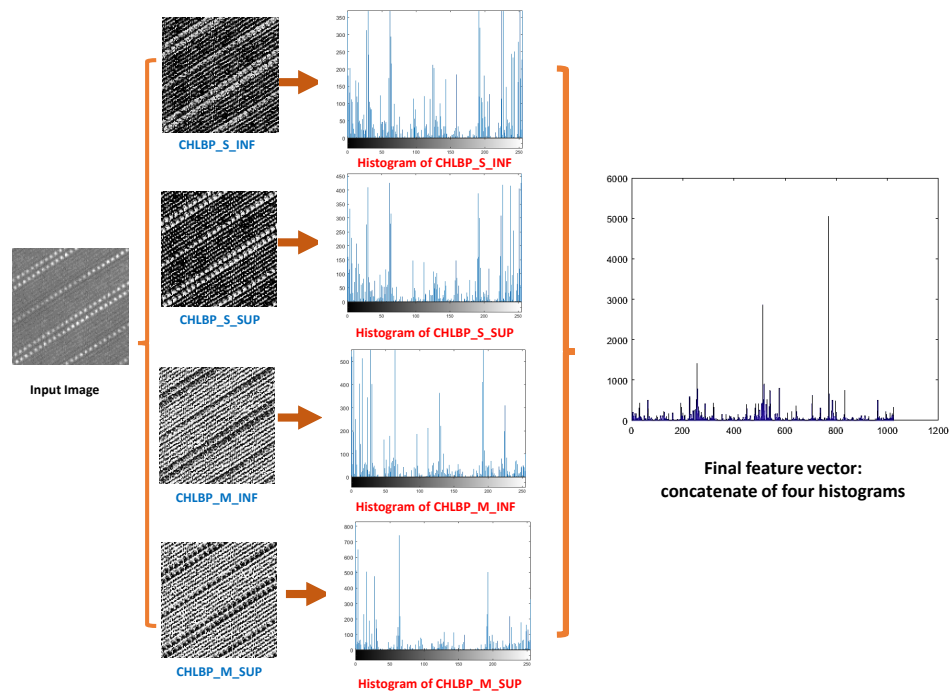


FIGURE 3.4 – L’histogramme proposé de CHLBP utilisant la concaténation de quatre descripteurs d’histogramme.

3.4.2.2 Résultats expérimentaux sur la base de données Outex

Résultats expérimentaux pour une expérience sans bruit avec SVM

Dans cette première expérience, nous évaluons les performances de notre descripteur proposé CHLBP face aux méthodes classiques LBP, CLBP, HLBP, HRLBP qui sont directement liées à celle que nous avons créée. Le tableau 3.3 affiche les taux de classification pour les bases de données *Outex TC10* et *TC12* à l’aide du classificateur SVM avec une variété de rayons et de pixels voisins (1,8), (2,16), (3,24). On peut voir que les diverses combinaisons de *CHLBP* dans l’état de bruit libre ont un taux de classification significativement plus élevée que les autres descripteurs d’origine -LBP (Ojala et al. [2002b]), HLBP (Al Saidi et al. [2020]), HRLBP (Al Saidi et al. [2021]), CLBP (Guo et al. [2010a]), il est compris entre 0,5% et 7,17% pour la base de données *TC10*, et entre 2,44% et 15,52% d’une part, et entre 1,23% et 13,13% d’autre part, pour *TC12* avec respectivement les éclaircissements *T184* et *horizon*.

On peut remarquer que les résultats obtenus indiquent que CHLBP est efficace, robuste et très performant face aux défis de la rotation et des changements d’éclairage dans l’état de bruit

TABLEAU 3.3 – TAUX DE CLASSIFICATION (%) DU CHLBP POUR DIFFÉRENTS RAYONS ET VOISINS SUR *Outex (TC10 et TC12)* ET LE CLASSIFICATEUR SVM.

Descripteurs	TC10			TC12					
	Inca			T184			horizon		
	R1(1,8,10)	R2(2,16,18)	R3(3,24,26)	R1(1,8,10)	R2(2,16,18)	R3(3,24,26)	R1(1,8,10)	R2(2,16,18)	R3(3,24,26)
LBP Classic	96.26	99.05	99.38	77.83	80.10	76.88	81.98	83.15	79.29
HLBP	92.48	98.77	98.96	72.52	78.60	75.48	76.17	77.71	76.17
HRLBP	92.69	98.77	98.91	73.52	78.46	75.98	75.08	78.15	76.23
CLBP /S/	96.08	98.98	99.35	77.92	80.27	76.42	81.48	78.88	78.17
CLBP /M/	94.40	98.52	99.14	73.10	77.75	76.21	77.54	77.27	77.04
CLBP /S/M/	98.70	99.61	99.79	85.60	84.21	81.69	86.98	81.90	81.85
Proposed <i>CHLBP(S_INF)</i>	97.55	99.17	99.05	80.60	80.52	77.63	83.46	82.54	79.08
Proposed <i>CHLBP(S_SUP)</i>	97.68	98.82	98.91	80.35	80.15	77.15	82.54	80.37	76.58
Proposed <i>CHLBP(M_INF)</i>	95.30	98.47	99.58	78.75	78.75	76.58	80.79	80.23	79.06
Proposed <i>CHLBP(M_SUP)</i>	96.92	99.35	98.63	77.46	80.08	77.58	79.98	81.00	78.73
Proposed <i>CHLBP(S_INF_S_SUP)</i>	99.05	99.72	99.77	85.08	84.04	80.83	86.43	85.65	83.33
Proposed <i>CHLBP(S_INF_M_INF)</i>	98.89	99.56	99.79	85.33	83.96	80.83	85.94	85.10	83.15
Proposed <i>CHLBP(S_INF_M_SUP)</i>	99.64	99.79	99.75	85.27	85.33	81.68	86.33	85.98	83.29
Proposed <i>CHLBP(S_SUP_M_INF)</i>	99.31	99.70	99.70	85.92	83.23	79.83	86.17	84.41	81.52
Proposed <i>CHLBP(S_SUP_M_SUP)</i>	99.08	99.47	99.63	84.58	83.06	79.5	85.87	84.12	80.12
Proposed <i>CHLBP(M_INF_M_SUP)</i>	98.52	99.70	99.86	83.75	84.08	80.83	84.46	84.19	81.54
Proposed <i>CHLBP(S_INF_M_INF_S_SUP_M_SUP)</i>	99.65	99.75	99.84	88.04	87.08	83.5	88.21	86.81	84.52

libre. La principale raison de ce succès est l'ajout de deux nouveaux paramètres. Le premier est la tolérance d'homogénéité qui correspond beaucoup plus aux structures spatiales sous-jacentes, et qui permettent de générer une caractéristique invariante très distinctive fondée sur les relations entre les pixels voisins. Le second, est le paramètre δ , qui nous donne un avantage à construire pour chaque opérateur (signe et grandeur) fourni par CLBP deux autres présentant les pixels positifs et négatifs. Par conséquent, ces informations additives génèrent un puissant motif binaire robuste aux changements d'échelle, de rotation et d'éclairage.

Résultats expérimentaux Pour une expérience sans bruit et avec bruit avec (KNN)

Dans cette étude expérimentale, nous voulons prouver l'efficacité de notre approche proposée CHLBP dans le bruit additif avec classificateur KNN en utilisant les bases de données *Outex TC10* et *TC12*. Nous nous sommes appuyés sur la même évaluation et les résultats obtenus sur l'article suivant (Tabatabaei and Chalechale [2019]) pour tester les performances de notre méthode CHLBP. La configuration expérimentale était la suivante : le test a été réalisé en utilisant trois bruits additifs, le premier est un bruit gaussien blanc. Des images ont été générées en utilisant quatre SNR différents (SNR = 20, 30, 40, 50), le second est le bruit sel et poivre avec quatre densités différentes ($\rho = 1, 2, 5, 10$), et le dernier est un bruit de flou gaussien avec quatre écarts-types ($\sigma = 0,5, 0,75, 1, 1,25$). L'état de bruit et l'état de bruit libre ont été classifiés par (KNN) avec le même principe que (Guo et al. [2010a]). Le tableau 3.4 présente les résultats de taux de classification obtenus par le CHLBP avec les bases de données *Outex (TC10 et TC12)* et

le classificateur KNN comme mentionné précédemment. Il peut être remarqué que les résultats de toutes les méthodes de pointe ont été obtenus à partir de (Tabatabaei and Chalechale [2019]) avec le même paramètre de configuration utilisé dans notre approche.

Nous avons principalement examiné CHLBP dans un état de bruit libre par rapport aux approches *state of the art* (SOTA) et, comme il est observé dans les résultats, notre approche proposée $CHLBP_{M_INF\&M_SUP}$ a obtenu la plus grande précision : 98,70% pour $h = 15$ et $\delta = 13$, ce qui démontre sa robustesse. Comme mentionné précédemment, les paramètres de CHLBP ont été modifiés en fonction du type de bruit utilisé, pour δ entre 13 et 20, et h entre 10 et 20. Le CHLBP offre un meilleur taux de classification que les approches SOTA dans les différents SNR lorsqu'un bruit gaussien blanc est appliqué aux images de test ; même dans le cas de $SNR > 30dB$, CHLBP surpasse toutes les approches en matière de taux de classification en raison de sa plus grande robustesse. $DTLBP_S/M/C$ a un taux de classification plus élevé par rapport aux autres méthodes, à 28,75%, mais nous avons obtenu le taux le plus élevé 29,35% dans $CHLBP_{S_INF\&S_SUP\&M_INF}$. Sur le bruit sel et poivre, la meilleure précision pour chaque densité dans le résultat SOTA est obtenue par $DTLBP_S/M/C$ pour les densités 1,2,5 et $CLBP_S/M/C$ pour la densité 10, avec un score classement de 94,27, 77,78, 42,18 et 17,39 respectivement. Cependant, le nôtre fournit les résultats les plus précis à différentes valeurs de densité 95,91%, 86,19%, 46,67% et 35,65%, obtenus par $CHLBP_{M_INF-M_SUP\&C}$, $CHLBP_{S_INF\&S_SUP\&M_INF}$, et $CHLBP_{M_INF\&M_SUP\&C}$. Sur le bruit flou gaussien, comme les autres types de bruit, notre CHLBP suggéré démontre également la robustesse et la haute performance par rapport à toutes les bases de données SOTA. En matière de taux de classification, les figures 3.5a, 3.5b, 3.5c démontrent la fiabilité du descripteur CHLBP proposé pour la caractérisation des images de texture avec les critères de changement d'éclairage et de rotation, ainsi que l'ajout d'une variété de bruits (*white Gaussian*, *salt and paper*, et *Gaussian blur*). Notons que le dernier cas de CHLBP qui intègre tous les types d'images produites par l'approche sera pris en compte dans les expériences futures puisqu'il a démontré son efficacité dans les différentes études expérimentales.

3.4.2.3 Résultats expérimentaux sur la base de données GID et AID RS

Dans cette deuxième expérience, nous évaluons les performances de CHLBP en utilisant l'apprentissage des données GID labeled avec respectivement 5 et 15 classes, et AID avec 30 classes. Comme indiqué dans le tableau 3.5, les résultats de chaque base de données (taux de classification, score F1 et kappa) ont été présentés par la moyenne de différents rayons ($R=\{1,2,3\},N$

TABLEAU 3.4 – TAUX DE CLASSIFICATION (%) DU CHLBP POUR DIFFÉRENTS RAYONS ET VOISINS SUR *Outex* (TC10 ET TC12) ET LE CLASSIFICATEUR KNN.

Descripteurs	Taux de classification (%)												
	État sans bruit	État du bruit											
		Bruit White Gaussian (SNR(dB))					Bruit Salt and Paper				Bruit Gaussian (Rat Standard deviation (σ))		
		50	40	30	20	1	2	5	10	0.5	0.75	1	1.25
CSLBP(t=2.5)	40.6	39.18	37.97	19.30	4.17	28.35	20.13	7.63	5.10	35.02	26.17	19.79	12.57
LDNP	43.85	40.13	37.65	22.68	8.93	43.35	40.36	27.50	16.69	34.73	20.96	19.79	12.10
GLTP	48.09	48.33	47.86	33.15	11.92	43.88	38.90	16.09	9.55	42.81	26.87	16.87	9.86
LDTP	49.55	48.33	47.63	24.24	4.16	36.38	26.09	11.17	7.65	41.32	20.20	11.61	8.15
MTP	55.39	55.28	57.89	45.20	16.58	52.29	42.50	21.56	12.23	50.44	31.95	19.08	7.99
ILBP	62.55	54.74	38.70	15.55	4.17	21.17	12.08	7.03	4.47	39.50	21.19	14.06	10.46
MBP	62.99	55.03	38.65	15.50	4.17	21.17	11.97	7.42	4.76	39.76	20.80	13.43	9.94
ILTP(t=5)	78.7	77.56	64.12	18.03	4.17	39.32	25.46	8.67	6.58	64.92	21.30	11.56	9.14
CLBP _M	81.74	80.53	67.64	21.91	7.22	20.65	11.77	4.16	4.16	56.71	30.80	14.81	11.69
RLBP(t=2)	82.34	28.42	26.62	10.81	8.31	73.9	59.37	33.72	13.80	34.11	13.09	8.85	6.40
AECLBP _S	82.34	81.72	77.53	37.32	4.30	26.40	18.12	8.85	7.68	51.71	12.52	5.15	4.16
DTLBP _S	83.56	81.07	80.28	53.03	13.23	68.64	45.46	17.03	8.46	53.20	14.92	7.65	4.86
AECLBP _M	83.62	83.07	82.06	49.72	9.98	27.16	11.69	4.01	4.16	69.42	39.34	23.75	14.71
CLBP _S	84.82	34.48	30.27	13.55	12.45	73.82	54.76	25.62	11.97	25.78	13.28	13.07	11.06
LTP(t=5)	88.05	86.23	76.52	21.25	4.17	76.25	59.53	15.13	4.29	70.23	29.01	21.56	15.72
DTLBP _M	88.31	87.52	87.13	70.84	16.65	45.44	24.63	9.55	4.16	80.18	55.88	42.47	29.97
LQP	88.39	79.82	68.70	19.33	4.17	65.07	46.90	24.86	10.62	64.45	25.93	22.10	14.63
CLBP _M §	90.36	90.24	85.81	31.62	4.77	37.73	16.01	9.89	9.58	82.55	61.22	42.05	31.90
AELTP(t=5)	92.73	92.61	91.39	48.49	4.17	51.25	29.84	14.81	7.05	74.40	38.41	17.16	9.45
AECLBP _{M/C}	92.87	92.69	92.37	70.34	11.88	58.20	28.30	10.98	7.86	85.23	57.78	41.66	34.92
AECLBP _S (M/C)	94.35	93.69	93.47	60.71	5.94	71.06	40.93	17.16	13.20	82.08	47.36	21.82	13.17
CLBP _S (M/C)	94.53	85.21	81.28	27.35	8.34	57.63	29.37	16.71	13.02	64.97	41.45	21.79	16.95
CLBP _{S/M}	94.66	82.95	80.50	25.37	4.20	50.41	27.52	10.93	10.02	63.09	35.00	19.03	15.28
DTLTP(t=5)	94.76	93.94	93.34	64.76	12.1	89.45	71.17	28.30	14.11	87.78	47.18	28.15	13.77
DTLBP _{M/C}	94.79	94.03	93.77	85.14	16.91	76.53	40.83	18.80	4.16	93.22	77.57	59.06	45.62
AECLBP _{S/M}	95.49	94.50	93.72	61.52	6.20	71.56	40.13	13.02	4.19	86.25	53.22	35.31	14.68
CLBP _{S/M/C}	96.56	92.24	90.42	32.50	8.34	70.80	38.59	17.50	17.39	74.01	48.54	31.32	22.89
DTLBP _S M/C	96.69	96.57	96.28	82.35	22.14	89.68	61.25	26.66	4.89	91.95	55.67	37.63	21.19
DTLBP _{S/M}	97.45	96.48	95.40	89.28	25.60	89.71	64.40	19.94	7.26	93.28	61.43	40.28	16.82
AECLBP _{S/M/C}	97.58	96.56	95.98	76.52	15.16	86.19	58.64	23.98	4.29	91.53	60.78	40.93	22.52
DTLBP _{S/M/C}	98.31	97.34	96.36	94.54	28.75	94.27	77.78	42.18	4.32	96.95	68.51	41.38	24.34
Proposed CHLBP _{S_INF}	89.53	90.39	89.53	70.39	23.20	70.44	44.00	24.35	18.28	83.70	34.14	17.94	12.48
Proposed CHLBP _{M_INF}	94.66	94.69	94.06	79.69	14.92	75.07	60.76	12.14	8.10	88.05	54.22	24.64	14.43
Proposed CHLBP _{S_SUP}	88.96	89.14	88.83	76.80	21.80	74.06	45.44	25.81	12.24	81.56	46.22	26.43	12.19
Proposed CHLBP _{M_SUP}	90.05	90.23	88.83	75.89	19.35	74.40	50.65	11.04	4.24	86.07	55.10	27.60	14.35
Proposed CHLBP _{S_INF&S_SUP}	97.32	97.83	97.71	89.35	24.66	87.60	51.67	36.74	22.32	95.62	72.55	38.78	19.14
Proposed CHLBP _{S_SUP&M_INF}	98.33	98.39	98.41	93.54	20.29	84.64	60.21	23.33	8.18	96.17	75.00	41.82	24.40
Proposed CHLBP _{M_INF&M_SUP}	98.70	98.72	98.54	94.71	21.54	84.48	51.64	21.59	10.29	96.77	76.85	43.02	27.42
Proposed CHLBP _{M_SUP&C}	94.95	95.03	93.96	85.29	19.30	91.27	72.99	20.44	13.21	91.43	66.72	35.39	23.20
Proposed CHLBP _{S_INF} S_SUP&M_INF	98.35	98.62	98.65	94.06	20.68	85.96	60.16	25.76	7.94	96.12	72.27	37.81	18.12
Proposed CHLBP _{S_SUP} M_INF&M_SUP	98.49	98.49	98.33	92.58	20.44	85.73	56.15	19.24	7.06	96.32	75.70	42.03	23.59
Proposed CHLBP _{M_INF} M_SUP&C	97.71	97.63	96.98	87.06	20.99	95.13	86.19	31.72	17.60	94.61	67.11	38.83	24.53
Proposed CHLBP _{S_INF&S_SUP&M_INF}	97.63	98.15	98.12	91.80	29.35	92.73	59.43	46.67	35.65	96.22	77.86	43.49	20.68
Proposed CHLBP _{M_INF&M_SUP&C}	98.57	98.46	97.68	94.01	22.60	95.91	69.69	21.25	11.85	97.08	80.29	51.56	27.47

=8).

Comme on peut l'observer, le CHLBP a atteint des taux de classification hautement comparables de 89,97% et 77,66% sur GID pour les deux catégories (5 et 15 classes). Un exemple de matrice de confusion (R=2,N=8) est illustré dans la figure 3.5d. D'autre part, nous essayons

TABLEAU 3.5 – TAUX DE CLASSIFICATION MOYENNE (%) DU CHLBP POUR DIFFÉRENTS RAYONS ET VOISINS SUR GID (CLASSES 5 ET 15), AID ET CLASSIFICATEUR SVM.

Descripteurs	Taux de classification % (SVM)								
	GID dataset (5 classes)			GID dataset (15 classes)			AID dataset (30 classes)		
	Acc(%)	F1-Score	Kappa	Acc(%)	F1-Score	Kappa	Acc(%)	F1-Score	Kappa
LBP Classic	78.83	0.7788	0.3386	61.73	0.6131	0.6728	46.70	0.4559	0.8789
LTP	87.17	0.8609	0.5961	72.80	0.7256	0.5417	60.97	0.6013	0.8349
CLBP /S/	79.41	0.7832	0.3567	46.60	0.4557	0.8792	46.60	0.4557	0.8792
CLBP /M/	78.77	0.7726	0.3367	56.31	0.5538	0.7148	47.21	0.4586	0.8778
CLBP S/M/	86.08	0.8515	0.5651	72.34	0.7217	0.5478	62.13	0.6129	0.8297
RLBP	79.35	0.7824	0.3547	62.62	0.6220	0.6648	46.51	0.4541	0.8794
Proposed CHLBP	89.97	0.8115	0.6865	77.66	0.7752	0.4424	66.85	0.6619	0.8055

d'augmenter le défi avec les données AID qui contiennent 30 catégories, parmi lesquelles des classes d'objets au sol difficiles et similaires. CHLBP est efficace, montrant une haute performance face à tous ces défis. La principale raison de ce succès est l'ajout de deux nouveaux paramètres. Le premier est la tolérance d'homogénéité, qui correspond beaucoup plus aux structures spatiales sous-jacentes et nous permet de créer une caractéristique invariante très identifiable fondée sur les interactions de pixels voisins. Le second est le paramètre δ , qui nous permet de construire pour chacun des opérateurs de CLBP (signe et magnitude), deux autres opérateurs affichent des pixels positifs et négatifs. Ainsi, cette information additive génère un motif binaire puissant avec des caractéristiques discriminantes.

3.4.3 Conclusion

Une nouvelle approche appropriée pour la classification des images de texture avec des bases de données RS en tolérance au bruit est proposée dans cette section, nommée «*completed homogeneous LBP*» (CHLBP). En fait, CHLBP est une version améliorée des méthodes HLBP qui prend en considération le signe et la magnitude fournis par CLBP avec l'ajout d'un paramètre δ qui permet de seuiller les pixels centraux dans une plage spécifique avec la génération de signaux positifs et modèles locaux négatifs. Par conséquent, ce nouveau descripteur génère quatre images à partir desquelles l'histogramme de chacune est extrait et concaténé, ce qui permet de générer un modèle local de caractéristiques robustes, efficaces et discriminantes pour détecter la tolérance au bruit.

Différentes études expérimentales ont été menées pour évaluer CHLBP en utilisant les bases de données les plus populaires et les plus difficiles dans la classification des images de texture

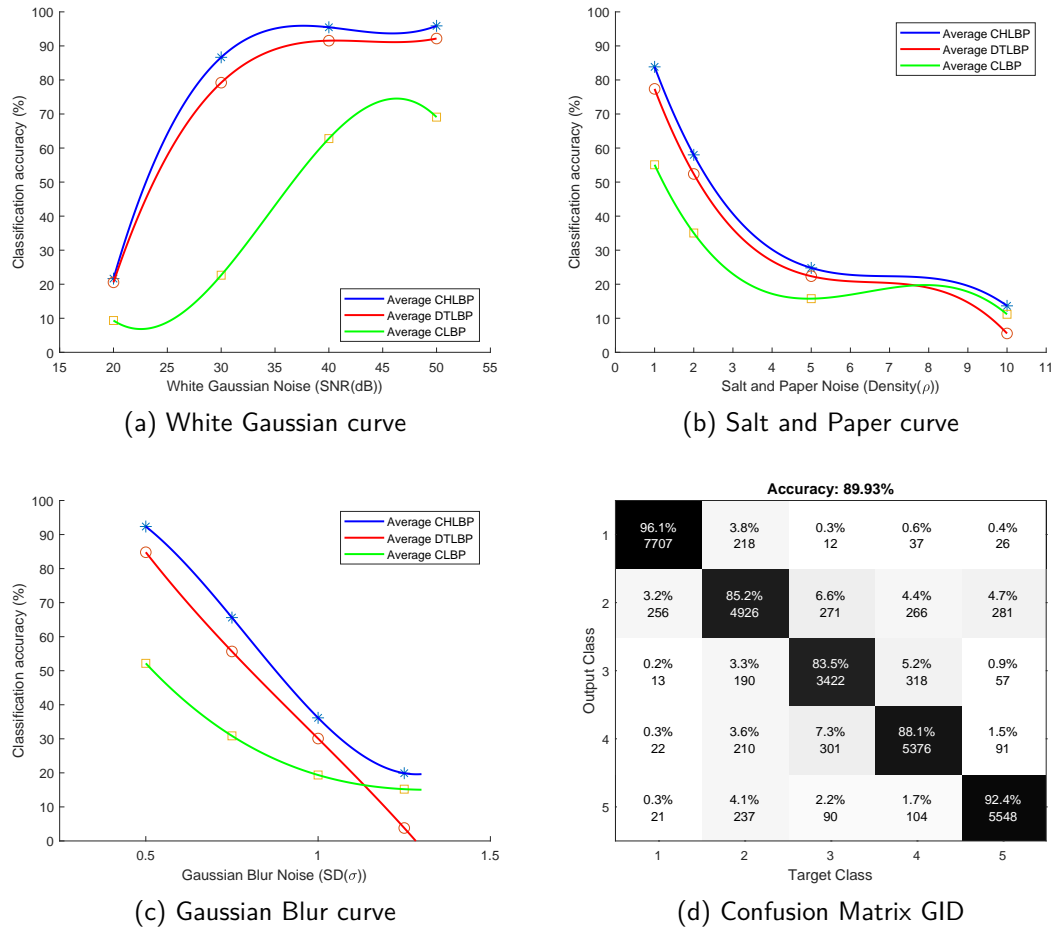


FIGURE 3.5 – Précision moyenne sous différents types et niveaux de bruit (a,b,c) et matrice de confusion (d) sur GID cinq catégories

et de la télédétection à haute résolution spatiale (*Outex [TC10, TC12]*, *GID* et *AID*) et deux classificateur (SVM et KNN). Les résultats montrent que notre approche CHLBP a obtenu un taux de classification supérieure avec les différents rayons R et voisins P dans le bruit libre et le bruit additif (blanc gaussien, sel et poivre et flou gaussien). Nous avons comparé CHLBP avec les variantes dont nous nous sommes inspirés, ainsi qu’avec les approches SOTA, et généralement, les résultats montrent que CHLBP surpasse largement ces méthodes en matière de taux de classification.

CIRCULAR PARTS LOCAL BINARY PATTERN (CPLBP)

Sommaire

4.1	Introduction	100
4.2	Le principe de la méthode CPLBP	101
4.3	Résultats expérimentaux	102
4.3.1	Procédure expérimentale	103
4.3.2	Étude expérimentale 1 : évaluation du CPLBP dans la variation du rayon R	103
4.3.3	Étude expérimentale 2 : évaluation la variation de l'angle du CPLBP	107
4.4	Conclusion	111

4.1 Introduction

L'analyse de texture est destinée à comprendre et à interpréter les modèles visuels du monde réel. La classification de la texture présente l'un des problèmes les plus ardues et les plus difficiles de l'analyse de la texture, elle a fait l'objet d'une attention significative au cours de plusieurs décennies et a démontré une forte amélioration. Par conséquent, le problème de l'extraction des caractéristiques efficaces et discriminantes afin de caractériser et distinguer plusieurs textures a été considéré jusqu'à présent comme un défi considérable.

Afin d'extraire une classification efficace et robuste du traitement des images de texture, différents algorithmes ont été proposés ; parmi eux, LBP a retenu l'attention des chercheurs comme l'une des fonctionnalités puissantes extraites en raison de sa robustesse et sa complexité algorithmique minimale. Fondées sur la LBP, de nombreuses variantes ont été définies et étudiées dans la littérature pour répondre à ses limites ; pour plus de détails, voir les sections 2.2, 2.3, 2.4 et 2.5.

Dans l'analyse de la texture, nous avons remarqué que la majorité des méthodes LBP utilisent un nombre limité de pixels voisins, ce qui cause la perte de l'information de la texture locale. Afin d'améliorer les performances du LBP pour la classification des textures, nous avons proposé dans ce chapitre une nouvelle extension efficace et plus robuste que celle du LBP originale, nommée *circular parts* LBP (CPLBP). Premièrement, le CPLBP substitue la moyenne d'une région de pixels voisins au chaque voisinage d'un pixel central (parties circulaires spécifiées par un angle et un rayon), qui permettent de conserver toutes les informations spatiales. Ensuite, chaque centre est seüllé avec la moyenne de chaque région circulaire. Établies sur l'impact des coordonnées polaires (rayon R et angle θ), les propriétés importantes telles que l'invariance à la rotation et à l'échelle sont plus robustes que le LBP original. De plus, le calcul de la moyenne de chaque partie du cercle permet de capter plus d'informations que les pixels voisins tous seuls, ce qui aide à réduire le bruit. Dans ce chapitre, plusieurs études expérimentales ont été réalisées afin d'évaluer l'approche proposée, plusieurs tests portant sur la classification des textures sont effectués en utilisant deux bases de données, à savoir : *Outex (TC10, TC12)* (voir 1.6). La méthode proposée est comparée à des variantes de l'approche LBP ainsi qu'avec d'autres méthodes d'analyse de textures.

Dans la suite de ce chapitre, nous allons commencer par une explication approfondie de notre nouvelle approche CPLBP. Nous présenterons ensuite les études expérimentales que nous avons conduites pour mettre en avant le descripteur CPLBP en comparaison avec les méthodes de l'état de l'art.

4.2 Le principe de la méthode CPLBP

Étant donné que la stratégie de codage traditionnelle LBP utilise un nombre fixe de voisins, même avec des variations du rayon, cela entraîne une perte significative d'informations. Notre méthode suggérée CPLBP cherche à conserver toutes les informations provenant des voisins en calculant la moyenne de toutes les valeurs de pixels de chaque partie ou segment du cercle spécifié par les valeurs d'angle et de rayon (en utilisant le système de coordonnées polaires). En conséquence, le CPLBP est discriminant et robuste par rapport au LBP du fait qu'il est conçu pour contenir plus d'informations spatiales. Formellement, le $CPLBP_{P,R}$ est défini par :

$$CPLBP_{R,P}(c) = \sum_{p=0}^{P-1} s(gM_p - g_c)2^p, s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (4.1)$$

Comme le LBP, g_c est le centre du pixel, $s()$ présente la fonction de signe. $R = r_1 + r_2 + r_3 + \dots + r_n$ est le rayon, P est un segment du cercle (partie) et gM_p est l'intensité moyenne des pixels qui appartiennent au segment du cercle P . Puisque nous travaillons dans le cercle d'échantillonnage en tant que LBP, si nous supposons que $(0, 0)$ sont les coordonnées du pixel central g_c , alors les coordonnées des voisins qui sont inclus dans la partie du cercle sont calculées comme suit : $(-R \sin(2\pi n/P), R \cos(2\pi n/P))$ où $R = r_1 + r_2 + r_3 + \dots + r_n$.

Afin de générer le code CPLBP, nous devons suivre les étapes suivantes :


1. **Diviser le cercle en parties.** Choisir le rayon R et l'angle θ du segment circulaire. Ces paramètres (R, θ) permettent de scinder le cercle de tous les pixels voisins en parties. Chaque partie est une région de pixels voisins. Le nombre de pièces dépend du choix de l'angle θ . Par exemple, si $\theta = 30$ le cercle sera divisé en 12 parties.
2. **Calcul de la valeur de gM_p .** Chaque partie du cercle en fonction de son rayon et de son angle comprend une région de pixels voisins, qui sont regroupés en calculant la valeur moyenne de la partie du cercle.
3. **Calcul du motif binaire local.** Dans cette étape, la valeur du pixel central g_c est comparée à la valeur moyenne de chaque partie du cercle gM_p pour former le code CPLBP.

Afin de clarifier notre approche, la figure 4.1 illustre la procédure complète du CPLBP. Dans l'exemple, les paramètres choisis de P et R sont $(8, 3)$, $R = r_1 + r_2 + r_3 = 3$ désigne le rayon du cercle centré au pixel $g_c = 161$. Nous avons choisi $\theta = 45^\circ$ ce qui permet de diviser le cercle en 8 parties. Chaque partie ou segment du cercle contient exactement 6 voisins. La valeur moyenne de chacun des six pixels voisins est calculée (dans l'exemple $\langle gM_1 = 160.33 \rangle$) puis comparée au centre $g_c = 161$ pour former le code binaire local $\langle 01110100 \rangle$.

Notons que les trois propriétés *uniform*, *rotation invariant* et *rotation invariant uniform* sont applicables pour le CPLBP.

4.3 Résultats expérimentaux

L'objectif de cette section est de déterminer l'efficacité du CPLBP dans la classification des textures.

FIGURE 4.1 – Le principe du CPLBP ($P=8, R=3$).

4.3.1 Procédure expérimentale

Les bases de données de *Outex* (*TC10* et *TC12*) constituent les deux bases de données utilisées dans nos études expérimentales. Pour plus de détails, voir la section 1.6.1.

Dans le cadre de l'étape de la classification, nous avons utilisé l'algorithme SVM. Les paramètres du SVM ont été calculé automatiquement à partir de la validation croisée. Afin d'estimer la fiabilité globale du système de classification construit, une validation croisée par 10-fold a été réalisée.

Compte tenu de cette nouvelle méthode proposée CPLBP, plusieurs études expérimentales approfondies sont utilisées pour démontrer la performance de notre méthode par rapport à celles de la littérature.

4.3.2 Étude expérimentale 1 : évaluation du CPLBP dans la variation du rayon R

Cette première étude expérimentale est réalisée afin d'évaluer l'effet du seuillage de pixel central avec la région moyenne des pixels circulaires voisins dans la variations du rayon R. Dans cette expérience, nous comparons CPLBP avec LBP en utilisant les deux bases de données *Outex_TC_10* et *Outex_TC_12* avec différentes valeurs de rayon (1,2,3,4,5,6,7,8,9 et 10) et une

TABLEAU 4.1 – Taux de classification (%) du descripteur CPLBP pour différentes valeurs du rayon R sur la base de données *TC10*.

	Taux de classification % Outex_TC10										Average
	R = 1	R = 2	R = 3	R = 4	R = 5	R = 6	R = 7	R = 8	R = 9	R = 10	
LBP classic	99.83	99.86	99.88	99.53	99.10	98.99	99.26	98.56	97.48	96.11	98.86
CPLBP	99.86	99.88	99.90	99.86	99.95	99.95	99.84	99.88	99.79	99.65	99.86
LBP u2	99.86	99.84	99.56	99.30	98.77	98.36	96.76	94.88	92.43	90.07	96.98
CPLBP u2	99.88	99.67	99.77	99.79	99.70	99.72	99.75	99.63	99.51	99.05	99.65
LBP riu2	96.26	97.10	97.94	96.71	94.00	94.12	91.60	88.40	84.58	81.62	92.23
CPLBP riu2	95.30	96.06	98.01	98.91	99.26	98.77	98.36	98.31	98.05	98.24	97.93

valeur fixe d'angle $\theta = 45^\circ$ afin de tester le pouvoir de l'approche CPLBP dans la condition du changement de rayon, ainsi que réduire la dimension des caractéristiques et le temps d'exécution.

Étude expérimentale 1-1 : Évaluation du CPLBP dans la variation du rayon R

Sur la base de données Outex_TC_10

Le tableau 4.1 présente des résultats comparatifs des taux de classification de l'approche CPLBP avec les différentes versions du LBP -classique, uniforme (u2), uniforme invariant à la rotation (riu2)- en utilisant la base de donnée *Outex_TC_10*. Nous pouvons remarquer que les résultats obtenus indiquent l'efficacité, la robustesse et la meilleure performance de notre approche suggérée CPLBP face aux défis des changements de la rotation et de l'éclairage. En matière de taux de classification, CPLBP atteint les meilleurs résultats par rapport aux différentes versions du LBP : par exemple, dans le rayon $R = 10$, nous obtenons 99.65 %, 99.05 % et 98.24 %, pour respectivement CPLBP, $CPLBP^{u2}$, et $CPLBP^{riu2}$, contrairement aux LBP originaux qui perdent progressivement leurs performances 96,11, 90,07 et 81,62 respectivement pour LBP classique, LBP^{u2} , et LBP^{riu2} . Cela est principalement dû au fait de capturer des informations beaucoup plus discriminantes grâce à des pixels voisins locaux qui existent dans chaque secteur du cercle spécifié par un angle égal à θ et ensuite représenté avec la valeur moyenne ; par conséquent, le descripteur CPLBP conserve sa résilience, particulièrement lorsque le rayon augmente.

Sur la base de données Outex_TC_12

Le tableau 4.2 illustre les résultats comparatifs de CPLBP avec LBP classique en utilisant deux conditions d'illumination différentes *Outex_TC_12* «t184" et «horizon» avec des change-

TABLEAU 4.2 – Taux de classification (%) du descripteur CPLBP pour différentes valeurs de rayon R sur la base de données TC12.

	Taux de classification % Outex_TC12										Average
	R = 1	R = 2	R = 3	R = 4	R = 5	R = 6	R = 7	R = 8	R = 9	R = 10	
	Outex_TC12 T184										
LBP classic	94.08	95.44	94.73	94.23	94.15	93.42	91.50	90.88	88.79	86.54	92.38
CPLBP	95.33	95.43	95.25	95.54	95.08	94.90	94.94	93.52	93.29	92.83	94.61
	Outex_TC12 horizon										
LBP classic	94.84	95.48	95.75	94.90	94.25	93.42	92.29	91.63	90.02	87.48	93.01
CPLBP	97.30	96.90	96.38	96.25	95.40	94.92	94.56	93.88	93.65	92.75	95.20

ments de rotation. Comme nous pouvons observer, notre approche fournit également des performances supérieures en matière de moyenne des rayons : 94,61 et 95,20 *Outex_TC_12* («*horizon*», et «*t184*») respectivement, contrairement aux LBP originaux qui perdent progressivement leurs performances 92.38, 93.01 respectivement. Surtout lorsque le rayon augmente, par exemple avec $R = 10$ nous avons obtenu des précisions de 92,83 et 92,75 pour «T184 et «*horizon*» respectivement. Comme mentionné précédemment, cette haute performance est due à plusieurs facteurs. Premièrement, l'impact du système de coordonnées polaires qui aide à obtenir une nouvelle extension plus robuste que LBP eu égard aux changements de rotation. Deuxièmement, sur la région locale, les pixels voisins capturés dans des θ précis apportent plus d'informations spatiales qu'un seul pixel voisin de LBP.

La figure 4.2 établit la comparaison des taux de LBP classique et CPLBP des deux bases de données *outex_TC_0010* et *0012* avec dix rayons différents de 1 à 10. Notre descripteur surpasse toujours le LBP classique, il garde une bonne précision même avec un rayon élevé.

Expérience 1-2 : Comparatif entre CPLBP et SOTA dans la variation du rayon R.

Afin d'examiner la robustesse, la performance et les autres avantages de notre approche CPLBP dans la classification des textures, nous avons sélectionné à partir de l'état de l'art quatre variantes du LBP destinées à la classification : LTP, RLBP, DRLBP, et CLBP. Pour davantage de détails sur les variantes, voir la section 2.5.

Le tableau 4.3 montre les résultats comparatifs des taux de classification (%) pour *outex_TC_10* et *12* (*t184* et *horizon*). À partir des résultats expérimentaux, nous avons fait les observations suivantes.

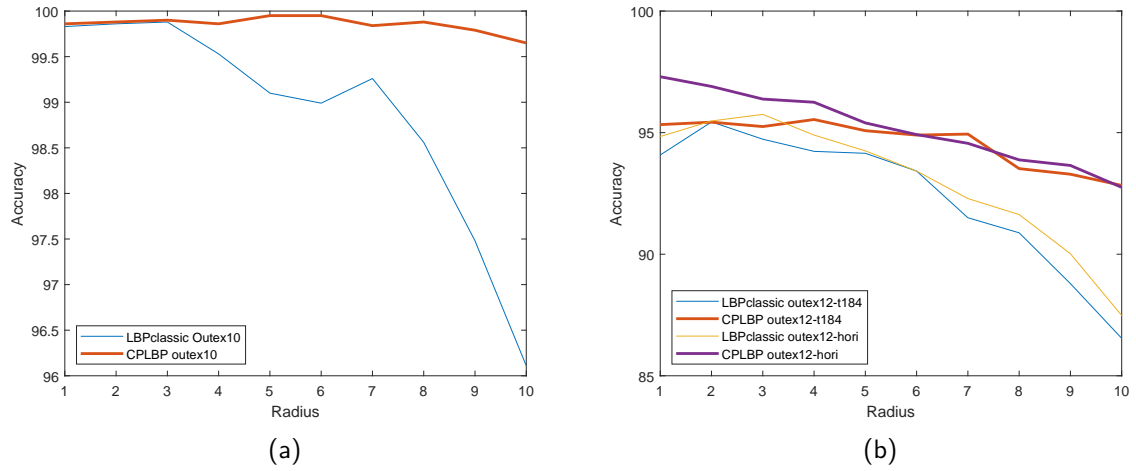


FIGURE 4.2 – La performance du CPLBP en fonction de la variation du rayon en utilisant (a) Outex_TC_0010 (b) Outex_TC_0012 t184 et l'horizon.

TABLEAU 4.3 – Taux de classification (%) du descripteur CPLBP avec les méthodes de l'état de l'art pour les différentes valeurs de R sur les bases de données *outex_TC_10* et *12*.

Taux de Classification % Outex_TC 10 and 12											
	R = 1	R = 2	R = 3	R = 4	R = 5	R = 6	R = 7	R = 8	R = 9	R = 10	Average
Outex_TC10											
LBP classic	99.83	99.86	99.88	99.53	99.10	98.99	99.26	98.56	97.48	96.11	98.86
LTP	99.84	99.93	99.95	99.91	99.88	99.88	99.68	99.00	98.77	97.92	99.48
RLBP	99.35	99.81	99.84	99.95	99.86	99.93	99.51	98.40	98.63	97.69	99.40
DRLBP	98.58	98.05	99.86	99.93	99.88	99.93	99.65	99.31	98.59	97.99	99.17
CLBP M	98.94	99.58	99.81	99.72	99.75	99.49	99.03	98.13	97.82	96.94	98.92
CLBP S	99.79	99.93	99.98	99.81	99.70	99.70	99.31	98.56	97.48	96.32	99.06
CPLBP	99.86	99.88	99.90	99.86	99.95	99.95	99.84	99.88	99.79	99.65	99.86
Outex_TC12 T184											
LBP classic	94.08	95.44	94.73	94.23	94.15	93.42	91.50	90.88	88.79	86.54	92.38
LTP	95.58	95.69	95.60	95.10	94.68	93.47	92.88	92.75	92.25	91.69	93.87
RLBP	90.27	92.46	92.45	88.50	88.00	86.19	83.73	84.65	82.83	80.88	87.00
DRLBP	90.11	90.81	94.41	90.19	89.00	87.15	85.10	85.47	83.44	82.80	87.85
CLBP M	92.40	94.23	94.25	93.73	93.15	92.81	91.77	91.27	90.33	89.79	92.37
CLBP S	96.52	96.35	96.29	96.10	95.47	94.50	93.60	92.13	91.73	90.00	94.27
CPLBP	95.33	95.43	95.25	95.54	95.08	94.90	94.94	93.52	93.29	92.83	94.61
Outex_TC12 horizon											
LBP classic	94.84	95.48	95.75	94.90	94.25	93.42	92.29	91.63	90.02	87.48	93.01
LTP	96.33	95.73	95.88	95.15	94.79	94.42	93.38	93.77	93.10	92.06	94.46
RLBP	92.88	93.44	91.83	88.58	88.48	86.04	86.31	86.19	84.31	82.31	88.04
DRLBP	93.01	93.50	91.96	88.60	87.92	85.52	84.96	85.75	83.90	81.02	87.61
CLBP M	94.25	95.29	95.06	94.19	94.00	93.67	91.94	91.42	90.56	89.38	92.98
CLBP S	97.50	97.52	96.75	96.23	95.85	94.65	93.85	93.56	92.77	91.65	95.03
CPLBP	97.30	96.90	96.38	96.25	95.40	94.92	94.56	93.88	93.65	92.75	95.20

En matière de taux de classification moyenne, RLBP et DRLBP sont meilleurs que LBP. En

effet, le décalage RLBP et DRLBP entraîne une invariance de rotation, car les poids dépendent du voisinage, ce qui les rend plus robustes pour détecter la variation de rotation. CLBP_S et CLBP_M obtiennent respectivement les caractéristiques de signe et de magnitude. Le LTP est généralement supérieur au LBP car il prend en compte les relations arborescentes entre le pixel central et ses voisins «supérieur à», «égal à» et «inférieur à». Au contraire, LBP ne peut en prendre que deux «supérieur à» et «inférieur à». Enfin, comme on peut le voir dans le tableau, le descripteur CPLBP que nous proposons atteint une meilleure performance que les autres méthodes dans les changements d'illumination et de rotation spécifiquement lorsque le rayon est élevé grâce à plusieurs facteurs. Premièrement, l'utilisation d'un système de coordonnées polaires qui permet d'exploiter l'invariance d'échelle et de rotation propriétés pour une approche beaucoup plus robuste que les autres approches. Deuxièmement, l'extension de la zone de voisinage de un à une région de pixels voisins locaux en employant des paramètres de rayon et d'angle et représentés avec la valeur moyenne augmente l'efficacité d'extraction des caractéristiques sans augmenter la dimensionnalité.

La figure 4.3 illustre le taux de classification moyenne de dix rayons différents $R = \{1, 2, 3, 4, 5, 6, 7, 8, 9, 10\}$ de notre approche CPLBP et diverses méthodes de l'état de l'art. Nous pouvons observer que notre descripteur atteint les meilleures précisions pour toutes les bases de données. Il peut atteindre jusqu'à 99,86% comme taux moyen de la base *Outex_TC_10*.

4.3.3 Étude expérimentale 2 : évaluation la variation de l'angle du CPLBP

Cette deuxième étude expérimentale vise à évaluer la robustesse de notre approche en utilisant une variété d'angles qui peuvent diminuer ou augmenter le nombre de segments de pixels locaux voisins dans le cercle. Dans cette étude, nous adoptons la version invariante de rotation uniforme de LBP pour minimiser la dimension du vecteur de caractéristiques et le temps d'exécution lorsque 12 et 16 voisins sont utilisés. De plus, chaque angle spécifique de notre méthode équivaut à un nombre exact de voisins sur LBP. Dans cette configuration, nous avons fixé le rayon $R = 6$ et nous avons fait varier l'angle sur cinq valeurs $\theta = \{\pi/8, \pi/6, \pi/4, \pi/3, \pi/2\}$.

Expérience 2-1 : Évaluation de l'angle du CPLBP avec la version LBP sur *Outex_TC_10* et *12*




FIGURE 4.3 – Les performances du CPLBP (selon la moyenne des différents rayons) par rapport aux méthodes de l'état de l'art.

Le tableau 4.4 montre les résultats du taux de classification sur les bases de données *Outex TC10* et *TC12* (*t184* et *horizon*). Comme nous pouvons le voir, le taux de classification le plus élevé de 99,14 est révélé par CPLBP (*Outex 10*) lorsque $\theta = \pi/6$. De plus, pour toutes les bases de données et sur chaque valeur d'angle, le meilleur résultat est obtenu par notre nouveau descripteur CPLBP qui démontre une forte performance et efficacité dans les changements d'illumination, de rotation, et d'échelle, en gardant la même dimension que l'approche LBP. Généralement, l'utilisation de la valeur moyenne des pixels voisins qui appartiennent à des régions ou des segments locaux identifiés par θ dans le seuillage au lieu d'un seul pixel voisin dans le LBP est plus discriminante, ce qui donne de bons résultats de classification.

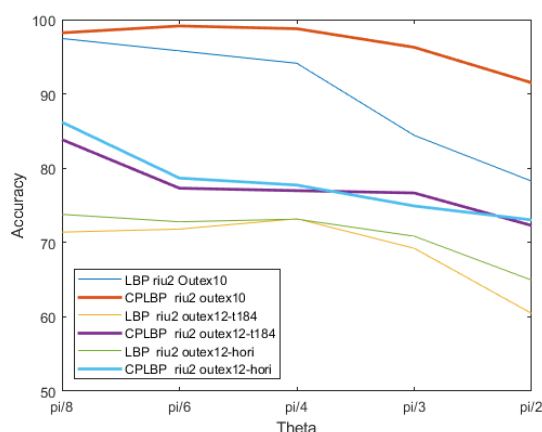
Le taux de classification de CPLBP peut également être observé sur la figure 4.4 après avoir fixé le rayon à 6 et réalisé une variation sur θ pour cinq angles $\{\pi/8, \pi/6, \pi/4, \pi/3, \pi/2\}$. On peut observer que CPLBP conserve une stabilité et une efficacité élevées pour diverses valeurs de θ par rapport à la méthode originale LBP.

Expérience 2-2 : Étude comparative entre CPLBP et SOTA au niveau de l'angle

Une étude comparative présentée dans le tableau 4.5 compare les performances de notre

TABLEAU 4.4 – Taux de classification (%) du descripteur CPLBP pour différentes valeurs d'angle θ avec un rayon fixe $R=6$ sur les jeux de données *TC10* et *TC12*.

Taux de Classification % Outex_TC10 and 12						
LBP	N=16	N=12	N=8	N=6	N=4	Average
CPLBP	$\theta = \pi/8$	$\theta = \pi/6$	$\theta = \pi/4$	$\theta = \pi/3$	$\theta = \pi/2$	
Outex_TC10						
LBP riu2	97.45	95.79	94.12	84.42	78.26	90.01
CPLBP riu2	98.22	99.14	98.77	96.27	91.50	96.78
Outex_TC12 T184						
LBP riu2	71.40	71.81	73.20	69.23	60.46	69.22
CPLBP riu2	83.85	77.31	76.98	76.67	72.29	77.42
Outex_TC12 horizon						
LBP riu2	73.79	72.79	73.15	70.85	64.94	71.11
CPLBP riu2	86.19	78.67	77.73	74.92	73.04	78.11

FIGURE 4.4 – La performance du CPLBP selon la variation θ en utilisant (a) *Outex_TC_10* (b) *Outex_TC_12 t184* et *horizon*.

nouveau descripteur avec les approches de l'état de l'art (LTP, RLBP, et CLBP. Plus de détails sur les variantes du LBP sont exposés à la section 2.5), en utilisant des bases de données plus populaires et difficiles à caractériser *Outex_TC_10* et *12 (t184 et horizon)*. Une amélioration significative des résultats des taux de classification sont marqués par notre nouveau descripteur CPLBP (riu2) en particulier lors de l'augmentation de θ comme $\pi/3$ et $\pi/2$ du fait que les autres descripteurs perdent beaucoup d'informations provenant des voisins et ne prennent qu'un nombre limité de pixels voisins ce qui diminue leur robustesse contrairement au CPLBP (riu2) qui conserve toutes les informations détaillées provenant des pixels voisins.

La figure 4.5 trace les résultats des taux moyens de classification en fonction des valeurs θ

TABLEAU 4.5 – Taux de classification (%) du descripteur CPLBP avec les méthodes de pointe pour différentes valeurs d'angle θ avec un rayon fixe $R=6$ sur les bases de données *TC10* et *TC12*.

Classification accuracy % Outex_TC10 and 12						
Others descriptors	N=16	N=12	N=8	N=6	N=4	Average
CPLBP	$\theta = \pi/8$	$\theta = \pi/6$	$\theta = \pi/4$	$\theta = \pi/3$	$\theta = \pi/2$	
Outex_TC10						
LBP riu2	97.45	95.79	94.12	84.42	78.26	90.01
LTP riu2	99.51	99.44	99.14	95.72	91.81	97.12
RLBP riu2	97.52	95.74	94.03	89.98	78.66	91.19
CLBP M riu2	97.48	97.64	94.40	85.12	70.32	88.99
CLBP S riu2	97.31	95.39	93.96	83.66	78.31	89.73
CPLBP riu2	98.22	99.14	98.77	96.27	91.50	96.78
Outex_TC12 T184						
LBP riu2	71.40	71.81	73.20	69.23	60.46	69.22
LTP riu2	77.21	76.23	78.60	78.73	73.02	76.76
RLBP riu2	71.54	71.92	73.19	69.02	61.83	69.50
CLBP M riu2	72.23	72.13	72.13	64.54	54.50	67.11
CLBP S riu2	71.67	71.25	73.02	68.90	61.58	69.28
CPLBP riu2	83.85	77.31	76.98	76.67	72.29	77.42
Outex_TC12 horizon						
LBP riu2	73.79	72.79	73.15	70.85	64.94	71.11
LTP riu2	78.67	77.00	79.79	78.81	75.50	77.95
RLBP riu2	73.92	72.88	73.48	70.63	65.35	71.25
CLBP M riu2	72.85	73.44	72.42	64.94	54.44	67.62
CLBP S riu2	73.71	73.50	73.31	70.60	64.60	71.14
CPLBP riu2	86.19	78.67	77.73	74.92	73.04	78.11

pour toutes les bases de données : 4.5a *Outex_TC_10*, 4.5b *Outex_TC_12 t184* et *horizon*. Comme illustré sur la figure 4.5, CPLBP fournit les meilleurs résultats et une haute performance même s'ils ont une légère diminution pour CPLBP par rapport à la méthode LTP sur *Outex_TC_12*. Comme il le soutient auparavant, cette diminution est due au seuillage de LTP qui prend trois relations «supérieur à», «égal à» et «inférieur à».

Une dernière remarque concerne le temps d'exécution de notre nouvelle approche CPLBP. Pour les images d'une grandeur de 128×128 pixels comme *Outex_TC_10* et dans cette condition expérimentale : MATLAB R2018a, système Windows, processeur Intel Pentium(R) Core(TM) i7-4500U 2,39 GHz et 8 Go de mémoire, le temps d'exécution avec CPLBP est de 15 secondes pour chaque image en fonction de la variation de (Rayon, θ) qui est dix fois plus grande que les autres méthodes qui ne prennent environ que 0,10 seconde. Ce temps est causé par le calcul des valeurs moyennes dans chaque région locale et peut être considéré comme une limite de




FIGURE 4.5 – La performance du CPLBP selon la moyenne de la variation θ des méthodes de l'état de l'art

l'approche proposée. Bien que la consommation de temps du CPLBP augmente, les performances sont considérablement améliorées.

4.4 Conclusion

Dans ce chapitre, nous avons présenté une nouvelle et robuste extension du LBP pour la classification des textures. Notre approche CPLBP utilise la moyenne d'un ensemble de pixels voisins dans la zone angulaire circulaire au lieu d'un voisin dans le LBP d'origine, ce qui permet d'obtenir une information puissante et discriminante à partir des images pour plusieurs cas : θ fixe et R variable dans les coordonnées polaires et inversement. Sur les bases de données *Outex*, les résultats expérimentaux démontrent que l'approche proposée est plus performante que l'originale vis-à-vis des changements d'illumination, d'échelle et de rotation. De plus, la comparaison de notre méthode avec les méthodes de l'état de l'art montre de très bons taux de classification.

Notre contribution dans ce chapitre est une extension du LBP qui vise à attirer l'attention sur la relation entre les pixels voisins et à exploiter toutes les informations provenant de ces pixels, même dans le cas d'une augmentation importante de rayon. Les questions qui se posent sont les suivantes : où se trouve la relation entre les pixels centraux ? Pourrions-nous travailler avec plusieurs pixels centraux en même temps, et exploiter cette relation pour offrir une meilleure

représentation nous permettant d'atteindre de meilleurs résultats? La réponse à ces questions constitue notre nouvelle contribution, qui va être présentée dans le chapitre suivant.

CORNER RHOMBUS SHAPE LBP (CRSLBP)

Sommaire

5.1	Introduction	113
5.2	Motivation de recherche pour l'approche CSRLBP	114
5.3	Le principe du CRSLBP	115
5.4	Résultats des expériences	121
5.4.1	Ensembles de données de texture	121
5.4.2	Résultats expérimentaux avec la base de données <i>Outex</i>	123
5.4.3	Résultats expérimentaux avec la base de données <i>KTH-TIPS2b</i>	124
5.4.4	Résultats expérimentaux avec la base de données <i>UMD</i>	125
5.4.5	Résultats expérimentaux avec la base de données <i>Brodatz</i>	126
5.5	Discussion	126
5.5.1	Résultats expérimentaux du CRSLBP avec MRELBP	127
5.6	Conclusion	128

5.1 Introduction

En se fondant sur les conclusions du chapitre 4, nous allons présenter dans ce chapitre une nouvelle variante du LBP nommée *corner rhombus shape* LBP (CRSLBP) qui va permettre de répondre à toutes les questions proposées.

Dans la classification des textures, de nombreux descripteurs et extensions de LBP utilisent un seul centre comme référence pour seuiller les pixels voisins. Par conséquent, la relation entre les pixels centraux est ignorée. De plus, LBP utilise l'interpolation bilinéaire, qui présente de nombreuses limitations, telles que la perte de netteté, l'imprécision de la valeur de gris et la

complexité de calcul élevée. Une nouvelle version de LBP est proposée dans ce chapitre pour pallier ces faiblesses, connue sous le nom de CRSLBP. Premièrement, pour obtenir plus d'un centre, des blocs de 4×4 sont utilisés pour sélectionner quatre pixels centraux en même temps. De cette manière, nous pouvons déterminer la relation entre les pixels centraux et entre les pixels centraux et voisins des pixels centraux voisins. Deuxièmement, l'interpolation bilinéaire est éliminée et toutes les informations fournies par le bloc sont exploitées à l'aide de diverses méthodes de seuillage calculées de manière adaptative en examinant les structures locales et leurs propriétés. Les résultats expérimentaux démontrent que l'extension LBP suggérée peut améliorer les performances en matière de précision de classification.

Cette étude est structurée comme suit : la section 5.3 présente le descripteur d'analyse de texture proposé CRSLBP. Les résultats des études expérimentales de plusieurs bases de données sont présentées dans la section 5.4. La section 5.5 discute des performances de la méthode proposée en utilisant des classificateurs par rapport aux approches SOTA. Et enfin, le chapitre est conclu dans la section 5.6.

5.2 Motivation de recherche pour l'approche CSRLBP

En récupérant les publications des variantes LBP cette année, nous avons découvert que la plupart des approches utilisaient un centre comme référence pour seuiller tous les voisins et le remplaçaient par des codes LBP. Par conséquent, la relation entre les centres est relâchée. En revanche, l'interpolation bilinéaire (est la méthode la plus simple pour estimer la valeur prise par une fonction continue entre deux points déterminés) utilisée par LBP permet de calculer la valeur qui est censée être placée à la même distance du pixel central (cercle gris). Cependant, elle présente de nombreuses faiblesses, comme la perte de netteté, l'imprécision de la valeur de gris, des informations de texture imprécises et une grande complexité de calcul.

Afin d'éviter les problèmes et les limitations, cet article crée une nouvelle variante de LBP avec de grandes différences dans la forme et le code du modèle local extrait. Les problèmes sont résolus en mappant le code LBP avec des blocs pairs, contrairement à la plupart des variantes LBP qui utilisent des blocs impairs pour sélectionner un centre avec ses voisins. De cette façon, nous nous donnons la chance de travailler avec quatre centres en même temps, ce qui nous permet non seulement d'obtenir l'interconnexion entre les pixels centraux, mais aussi celle de chaque pixel central avec ses voisins. De plus, chaque pixel central acquiert une relation avec les

pixels voisins des pixels de voisinage centraux. En outre, le nouveau descripteur proposé élimine l'interpolation bilinéaire et exploite toutes les informations fournies par les pixels voisins dans le bloc en utilisant plusieurs seuils, qui sont calculés de manière adaptative en examinant différentes structures locales et leurs propriétés.


D'autre part, nous essayons d'extraire des informations de la relation entre voisins en fonction des pixels centraux. Comme prévu dans CLBP, et pour préserver des caractéristiques plus intrinsèques, deux vecteurs importants sont extraits de l'image ; le signe et la grandeur. Cependant, parmi les deux, le signe est le plus influant. Sur la base de cette idée, nous essayons d'extraire le signe des pixels des nervures des pixels voisins en forme de losange. Aussi, pour obtenir une relation de profondeur entre le centre et ses voisins, chaque centre de pixel est seuillé avec les voisins du centre voisin.

Sur la base de tout cela, ce nouvel encodage est suffisamment utile pour acquérir plus d'informations intrinsèques, ce qui permet une amélioration significative du taux de classification.

5.3 Le principe du CRSLBP

Dans cette section, nous présentons notre nouvelle variante LBP pour la classification des textures afin de résoudre les faiblesses du LBP original et d'obtenir des fonctionnalités plus robustes avec une faible complexité. En général, le CRSLBP est construit via les étapes principales suivantes. Contrairement à LBP et à la plupart de ses variantes, nos données d'entrée sont divisées en blocs pairs de 4 pixels, ce qui permet de sélectionner quatre pixels centraux au milieu de chaque bloc (voir Figure 5.1, le bloc vert), et d'exploiter la relation entre quatre centres et leurs pixels voisins. D'autre part, les pixels voisins du bloc sont divisés en deux : les pixels d'angle et les pixels voisins en forme de losange sont respectivement marqués par des cercles roses et orange, comme le montre la figure 5.1. Après avoir extrait tous les pixels requis, nous commençons la construction du code CRSLBP comme suit :

- **Étape 1** : Les quatre pixels de coin sélectionnés sont comparés par la moyenne de tous les pixels centraux, ce qui donne quatre motifs binaires (figure 5.6b).
- **Étape 2** : Comme le montre la (figure 5.2a), chaque nervure spécifique du losange contient deux pixels. Tout d'abord, nous prenons le maximum des deux pixels et le comparons

FIGURE 5.1 – Un exemple de bloc 4×4 de CRSLBP.

avec la commutation horizontale des pixels centraux (figure 5.2b). Cela nous donne quatre nouveaux motifs binaires (figure 5.2c).




FIGURE 5.2 – (a) Les pixels voisins en forme de losange (b) Le pixel maximum de chaque seuil de nervure par le centre avec la même couleur. (c) Les quatre premiers codes binaires de CRSLBP.

- **Étape 3 :** Nous extrayons les nombres minimum et maximum de chaque nervure spécifique de pixels de losange par rapport à la commutation horizontale des pixels centraux, ce qui crée une relation entre chaque centre et ses voisins éloignés. Ensuite, nous calculons la valeur C (figure 5.3c), qui est utilisée pour seuiller les voisins en soustrayant la moyenne de tous les nombres maximaux avec la moyenne de tous les nombres minimaux. Nous soustrayons ensuite les nombres maximaux de chaque nervure de losange spécifique (figure 5.3d) de la commutation horizontale des pixels centraux (figure 5.3b) et les comparons à la valeur C pour générer également quatre autres binaires motifs codés (figure 5.3e).




FIGURE 5.3 – (a) Les pixels voisins en forme de losange. (b) Pixel maximum de chaque nervure. (c) Calcul de la valeur C. (d) En soustrayant les valeurs maximales de pixel et de centre. (e) Le deuxième code à quatre binaires de CRSLBP.




FIGURE 5.4 – (a) Les pixels voisins en forme de losange. (b) Rapport de tous les deux pixels. (c) Le troisième groupe de quatre codes binaires de CRSLBP.

- **Étape 4** : Pour chaque nervure spécifique de pixels de losange suivant une direction particulière comme présenté dans la (figure5.4a), le rapport de tous les deux pixels est calculé (figure5.4b), et la valeur entière est capturée pour extraire quatre modèles binaires supplémentaires (figure5.4c).
- **Étape 5** : Après avoir extrait tous les motifs binaires, nous formons trois codes décimaux par la concaténation de quatre motifs binaires (deux codes binaires) pixel par pixel, comme suit :
 1. L'étape 1 avec L'étape 2
 2. L'étape 1 avec L'étape 3
 3. L'étape 1 avec L'étape 4

Formellement, étant donné le sous-bloc de 4×4 pixels comme le montre la figure 5.5, $h_{corner}(i)$ et $h_{rhombus}(j)$ présentent le coin et la forme de losanges voisins pixels, et $h_{center}(i)$ est le pixel central du bloc. Les descripteurs CRSLBP sont définis comme suit :

- 1) Les pixels voisins du coin du bloc $h_{corner}(i)$ sont donnés par l'équation suivante :




FIGURE 5.5 – Le bloc formel de CRSLBP.

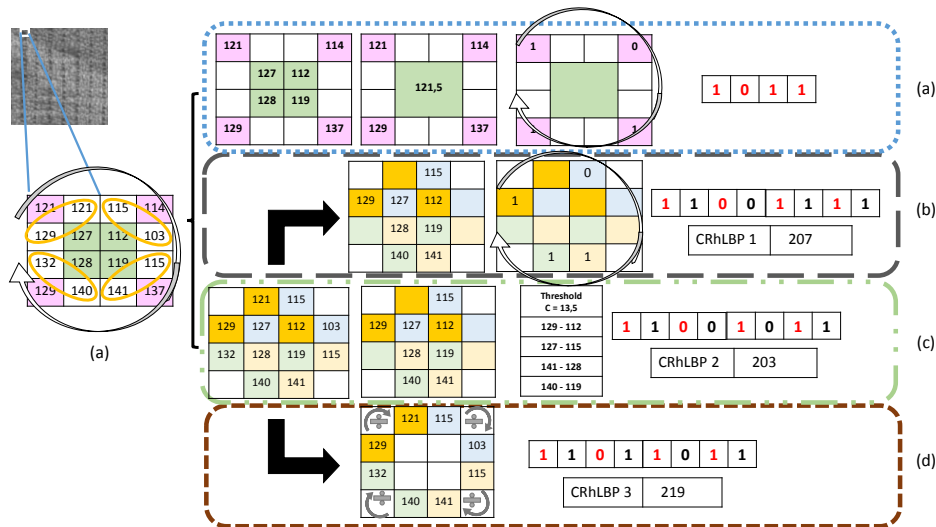


FIGURE 5.6 – (a) Le sous-bloc 4×4 de l'image. (b) Le traitement des coins. Le processus du premier (b), du deuxième (c) et du troisième (d) a g n r  le code CRSLBP.

$$CRSLBP_{corner}^{riu2}(r, N) = \sum_{i=0}^{N-1} s(h_{corner}(i) - h_{Mcenter}), s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (5.1)$$

o  $h_{Mcenter}$ repr sente la moyenne de tous les pixels centraux et $s()$ est la fonction de signe.

2) Les pixels voisins en forme de losange du bloc $h_{losange}(j)$ sont trait s par trois  quations,

comme suit :

La première équation utilise la valeur maximale de chaque nervure de pixels voisins en forme de losange :

$$CRSLBP_{rhombus1}^{riu2}(r, N) = \sum_{j=0}^{(N*2)-1} s(\max(h_{rhombus}(2j+1), h_{rhombus}(2j+2)) - h_{center}),$$

$$s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad (5.2)$$

La deuxième équation utilise la valeur C pour couvrir la valeur maximale de chaque nervure de pixels voisins en forme de losange :

$$CRSLBP_{rhombus2}^{riu2}(r, N) = \sum_{j=0}^{(N*2)-1} B(\max(h_{rhombus}(2j+1), h_{rhombus}(2j+2)) - h_{center}),$$

$$B(x) = \begin{cases} 1 & x \geq C \\ 0 & x < C \end{cases} \quad (5.3)$$

Où $B(x)$ est la fonction de signe fondée sur la valeur de contraste. Dans l'équation ci-dessus, la valeur C est utilisée pour seuiller les voisins et est calculée, de la manière suivante :

$$C = 1/N \left(\sum_{j=0}^{(N*2)-1} \max(h_{rhombus}(2j+1), h_{rhombus}(2j+2)) - \sum_{j=0}^{(N*2)-1} \min(h_{rhombus}(2j+1), h_{rhombus}(2j+2)) \right) \quad (5.4)$$

En utilisant la valeur C, nous essayons d'améliorer la qualité de l'image en nous fondant sur des opérations telles que l'amélioration du contraste et la réduction ou la suppression du bruit.

La dernière équation utilise le rapport entre les deux pixels de chaque nervure de pixels voisins en forme de losange :

$$CRSLBP_{rhombus3}^{riu2}(r, N) = \sum_{j=0}^{(N*2)-1} s(h_{rhombus}(2j+1)/h_{rhombus}(2j+2)),$$

$$s(x) = \begin{cases} 1 & x \geq 1 \\ 0 & x < 1 \end{cases} \quad (5.5)$$

Dans les équations 5.2 et 5.3, le centre h_{center} (présenté sur la figure 5.5) pour le seuillage de chaque pixel voisin en forme de losange nervuré est organisé comme suit :

$h_{center} = \{h_{center2}, h_{center1}, h_{center4}, h_{center3}\}$. Les équations 5.1, 5.2, 5.3 et 5.5 génèrent quatre motifs binaires. Le modèle de caractéristique final de CRSLBP est donné comme suit :

1) L'étape 1 avec L'étape 2

$$CRSLBP1^{riu2}(r, N) = \sum_{i=0}^{(N-1)} \sum_{j=2i+1}^{(N-1)} (CRSLBP_{corner}^{riu2}(i)2^{(j-1)} + CRSLBP_{rhombus1(r,N)}^{riu2}(i))2^j \quad (5.6)$$

2) L'étape 1 avec L'étape 3

$$CRSLBP2^{riu2}(r, N) = \sum_{i=0}^{(N-1)} \sum_{j=2i+1}^{(N-1)} (CRSLBP_{corner}^{riu2}(i)2^{(j-1)} + CRSLBP_{rhombus2}^{riu2}(i))2^j \quad (5.7)$$

3) L'étape 1 avec L'étape 4

$$CRSLBP3^{riu2}(r, N) = \sum_{i=0}^{(N-1)} \sum_{j=2i+1}^{(N-1)} (CRSLBP_{corner}^{riu2}(i)2^{(j-1)} + CRSLBP_{rhombus3}^{riu2}(i))2^j \quad (5.8)$$

Le processus total de CRSLBP expliqué ci-dessus est illustré dans la figure 5.6. Pour augmenter la discrimination et l'efficacité de la représentation des caractéristiques, les trois processus de modèle codés CRSLBP 1–3, donnés dans les équations 5.6, 5.7 et 5.8 sont regroupés dans une distribution hybride nommée CRSLBP équation 5.9, qui nous permet de créer un modèle robuste avec une sensibilité au bruit réduite et une efficacité améliorée. De plus, en utilisant une combinaison linéaire de plusieurs caractéristiques générées à partir de différents processus de codage de motifs, une approche multi-échelle pourrait être utilisée pour capturer des informations

grossières et fines. Le CRSLBP se présente comme suit :

$$CRSLBP^{riu2}(r, N) = \langle CRSLBP1^{riu2}(r, N), CRSLBP2^{riu2}(r, N), CRSLBP3^{riu2}(r, N) \rangle \quad (5.9)$$

La figure 5.7 montre les caractéristiques de texture après avoir été extraites par CRSLBP. De plus, Algorithm 1 résume le cadre général du vecteur de caractéristiques CRSLBP.

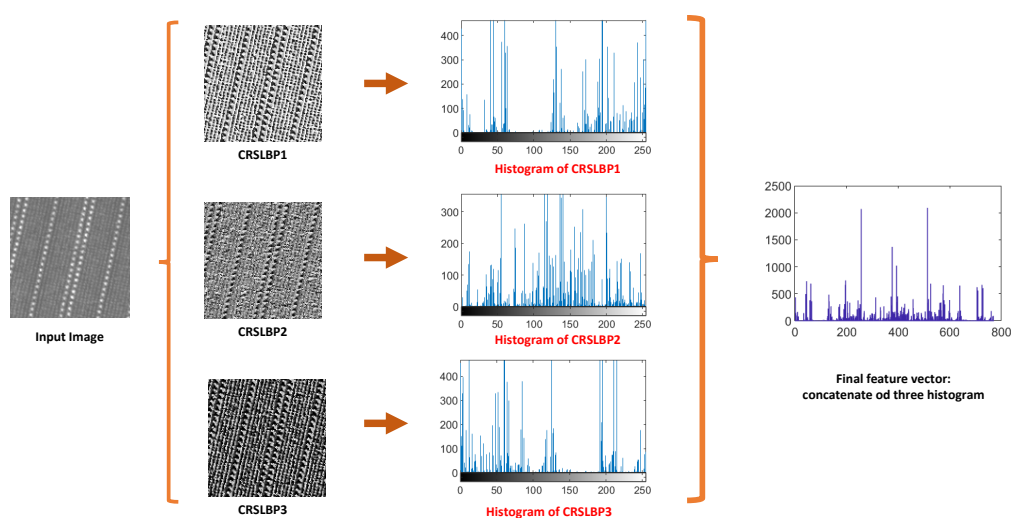


FIGURE 5.7 – L’histogramme de concaténation de tous les processus de CRSLBP.

5.4 Résultats des expériences

Dans cette section, nous menons une série d’études expérimentales avec différentes bases de données pour vérifier l’efficacité de la stratégie du CRSLBP.

5.4.1 Ensembles de données de texture

Les bases de données *Outex*, *KTH-TIPS2b*, *UMD* et *Brodatz* ont été utilisées dans nos études expérimentales pour évaluer la robustesse et l’efficacité de l’approche proposée CRSLBP (pour davantage de détails, voir la section 1.6). Le tableau 5.1 résume les informations de chaque type

Input: Image IMG ;

Output: calculer l'histogramme $hist = CRSLBP(IMG)$;

Charger les images d'entrée IMG à partir d'une base de données ;

Convertir IMG en images en niveaux de gris ;

Fonction :

Divisez l'IMG en matrice de blocs de 4×4 pixels ;

foreach bloc do

Identifiez les coins et les pixels voisins en forme de losange et extrayez l'ensemble des quatre pixels centraux ;

Calculer la moyenne des pixels centraux $h_{MCenter}$ et réorganisez les pixels centraux $h_{center} = \{h_{center2}, h_{center1}, h_{center4}, h_{center3}\}$;

Extraire le maximum de chaque voisin de pixel en forme de losange nervuré comparé par le centre $h_{MaxRhom}(i)$;

Calculez la valeur C ;

Calculez la différence locale entre : $h_{MCenter}$ et $h_{Corner}(i)$ & $h_{MaxRhom}$ et h_{center} & $h_{MaxRhom}$, h_{center} et C ;

Calculez le rapport local entre le premier pixel et le deuxième pixel de chaque forme de losange de nervure ;

Calculez les deux motifs values pixel par pixel entre coin et trois types de losanges (max, valeur C, rapport) chaque valeur du processus à trois losanges ;

end

return S^* ; Calculez chaque histogramme ;

Former le vecteur caractéristique par la combinaison des trois histogrammes ;

Fin de la Fonction

Algorithm 1: Algorithme de CRSLBP

de base de données. La méthode proposée est comparée à d'autres approches de variantes de LBP, dont certaines sont classées dans la même catégorie que notre méthode.

TABLEAU 5.1 – Résumé des caractéristiques des bases de données de texture utilisées dans nos expérimentations

Number	Name	Classes	Samples per class	Total samples	Sample resolution (pixels)	Image format (Monochrome)	Challenges
1	Brodatz	112	9	1008	512×512	JPG	Various texture types
2	KTH-TIPS2b	11	4×108	4752	200×200	BMP	illumination, scale, pose changes pose changes
3	OuTeX_TC_00010	24	180	4320	128×128	RAS	Rotation changes (0°) for training and other degrees for test
4	OuTeX_TC_00012	24	200	4800	128×128	RAS	Rotation and illumination(Tl84, horizon) ('Tl84', 'horizon')changes
5	UMD	25	40	1000	1280×960	PNG	Small illumination changes, strong scale, rotation and viewpoint changes

Dans les études expérimentales de cette méthode, tous les descripteurs sont considérés comme des paramètres assis sur la rotation invariante et l'uniforme (riu2) avec des caractéristiques normalisées pour diminuer le nombre de caractéristiques, réduire le temps de traitement et fournir des caractéristiques discriminantes. La méthode proposée est testée à l'aide de deux classifications, SVM et NN (voir la section 2.6), et elle est comparée à d'autres approches de variantes de

LBP.

5.4.2 Résultats expérimentaux avec la base de données *Outex*

Les résultats de classification de cette expérience sont illustrés dans le tableau 5.2.

TABLEAU 5.2 – Taux de classification (%) du CRSLBP pour différents R sur l'ensemble de données *Outex* et le classificateurs (SVM, NN).

	Classification accuracy (%) <i>Outex</i> (SVM)												Classification accuracy (%) (NN)			
	<i>Outex_TC10</i>				<i>Outex_TC12</i>								<i>Outex_TC10</i>			
	Inca				T184				horizon				Inca			
	R = 1	R = 2	R = 3	Average	R = 1	R = 2	R = 3	Average	R = 1	R = 2	R = 3	Average	R = 1	R = 2	R = 3	Average
LBP classic	96.26	97.10	97.94	97.1	77.83	79.25	78.83	78.64	81.98	82.50	78.69	81.06	96.91	97.38	98.76	97.68
HLBP	92.48	98.40	98.17	96.35	72.52	78.37	74.81	75.23	76.17	79.21	76.02	77.13	93.06	99.23	98.15	96.81
HRLBP	92.69	98.31	98.31	96.43	73.52	78.46	74.58	75.52	75.08	79.42	75.92	76.80	94.60	99.23	98.76	97.53
HLBP+LBP	98.59	99.54	99.70	99.27	84.60	84.50	82.50	83.86	86.65	85.06	82.67	84.79	99.08	99.54	99.69	99.43
HRLBP+RLBP	98.59	99.56	99.72	99.29	85.29	84.60	82.42	84.10	86.83	85.21	82.62	84.88	98.92	100	100	99.64
CPLBP	95.30	96.06	98.01	96.45	76.31	78.04	77.52	77.29	79.94	78.52	79.29	79.25	—	—	—	—
LTP	99.21	99.56	99.42	99.40	85.71	83.92	83.42	84.35	85.92	85.23	82.21	84.45	99.53	99.69	99.84	99.69
CLBP S/M	98.70	99.40	99.49	99.20	85.60	85.62	83.27	84.83	86.98	85.77	82.67	85.14	99.22	99.84	99.69	99.58
CLBP S	96.08	97.13	97.99	97.07	77.92	79.85	78.56	78.78	81.48	82.75	78.35	80.86	95.98	97.99	98.77	97.58
CLBP M	94.40	97.08	98.14	96.54	73.10	76.50	75.00	74.87	77.54	77.58	76.10	77.07	95.37	97.99	98.61	97.32
CLDP	96.23	77.10	71.06	81.46	78.40	59.85	53.40	63.88	81.79	64.81	56.00	67.53	96.23	77.10	71.06	81.46
RLBP	96.32	97.27	97.89	97.16	78.40	78.94	78.40	78.58	81.73	82.60	78.75	81.03	95.98	97.68	98.30	97.32
LBPV	78.75	90.72	93.56	87.67	63.69	78.79	82.96	75.15	70.67	83.42	84.42	79.50	81.01	90.12	92.28	87.80
CRSLBP	99.65	99.84	99.79	99.76	94.23	94.50	93.17	93.97	95.42	94.45	93.87	94.58	99.69	99.84	99.84	99.79
MRELBP		99.90		99.90			87.02	87.02			87.04	87.04		100		100

Tout d'abord, nous avons comparé notre descripteur avec la méthode LBP originale. Remarquablement, les performances de CRSLBP sont bien supérieures à celles de LBP pour toutes les résolutions à savoir divers *Outex* (*TC10* et *TC12*), les classificateurs (SVM, réseau de neurones (NN)) et le rayon. Le taux de classification moyenne est de 99,76% et 99,79% pour *Outex TC10* SVM et NN, respectivement. En outre, nous avons trouvé une précision SVM de 93,97% et 94,58% pour *Outex TC12* avec T184 et éclairage d'horizon, respectivement. De plus, nous avons comparé la CRSLBP avec la LBP homogène (HLBP) et la LBP homogène en rotation (HRLBP), qui ont été présentées par Al Saidi et al. [2020, 2021]. Comme on peut le voir, la méthode que nous proposons améliore à la fois les descripteurs HLBP et HRLBP et donne de très bons résultats pour chaque résolution proposée (classificateur, bases de données *Outex*, rayon et tolérance d'homogénéité). De plus, nous avons obtenu les meilleurs résultats même si HLBP+LBP et HRLBP+RLBP étaient concaténés, démontrant la robustesse et la haute performance de notre méthode. D'autre part, nous avons comparé CRSLBP avec CPLBP, qui a été introduit par Al Saidi et al. [2021]. Comme on peut le voir, notre méthode a amélioré CPLBP, avec des taux de classification plus élevés dans diverses illuminations d'*Outex* (*Inca*, *T184* et *horizon*) et cela vient, d'une part, des quatre pixels centraux extraits du bloc et, d'autre part, de la relation dérivée de chaque centre et voisin des pixels centraux. Enfin, nous avons comparé

notre approche avec les approches de l'état de l'art (SOTA). Comme le montre le tableau, les performances moyennes de CRSLBP avec SVM et le classificateur MLP de réseau de neurones artificiels pour tous les types d'*Outex* (*TC10*, *TC12*) étaient supérieures à celles de SOTA, à l'exception de MRELBP. La raison de cette petite diminution est probablement l'utilisation d'un ensemble de rayons (quatre rayons) pour générer l'approche MRELBP.

5.4.3 Résultats expérimentaux avec la base de données *KTH-TIPS2b*

La base de données *KTH-TIPS2b* 1.6.2 est principalement conçue pour évaluer l'impact des conditions d'imagerie réelles sur la classification des matériaux. Le Tableau 5.3 affiche les taux de classification pour la base de données *KTH-TIPS2b* en utilisant le classificateur SVM et NN pour évaluer les performances de notre descripteur.

On peut voir que CRSLBP surpasse le LBP d'origine avec diverses valeurs de rayon et classificateurs de plus de 8,87 % pour SVM et 10 % pour NN. De même, CRSLBP a un taux de classification moyenne significativement plus élevé, entre 5 % et 10 % supérieure à celui présenté par Al Saidi et al. [2020, 2021] pour HLBP et HRLBP ainsi que leur concaténation avec LBP et RLBP, respectivement. Pour évaluer davantage les performances du CRSLBP, nous avons effectué une autre comparaison avec certaines méthodes SOTA, comme indiqué dans le tableau. CRSLBP a obtenu des précisions de classification bien meilleures que LBP : 96,89 %, 96,76 % et 97,19 % pour le classificateur SVM et 94,81 %, 95,37 % et 95,65 % pour le classificateur NN. Avec la base de données *KTH-TIPS2b*, CRSLBP n'a pas pu obtenir de meilleurs résultats que MRELBP car l'ensemble de valeurs de rayon fixées dans la méthode permet d'obtenir plusieurs échelles en même temps.

TABLEAU 5.3 – Taux de classification (%) du CRSLBP pour différents R sur l'ensemble de données *KTH-TIPS2b*, *UMD* et *Brodatz* et le classificateur (SVM,NN).

	Taux de classification (%) <i>Outex</i> (SVM)											
	KTH-TIPS2b				UMD				Brodatz			
	R = 1	R = 2	R = 3	Average	R = 1	R = 2	R = 3	Average	R = 1	R = 2	R = 3	Average
LBP classic	89.67	88.62	85.94	88.07	97.7	97.6	96.1	97.13	90.77	92.16	91.27	91.40
HLBP	89.41	90.51	89.29	89.74	94.90	95.20	95.30	95.13	84.23	84.33	84.72	84.43
HRLBP	89.44	91.35	89.26	90.02	94.50	94.80	95.00	94.77	83.43	85.02	84.73	84.39
HLBP+LBP	96.00	96.76	96.27	96.34	98.70	99.00	98.60	98.77	93.55	94.35	93.95	93.95
HRLBP+RLBP	96.11	96.55	96.06	96.24	99.00	98.70	98.20	98.63	93.45	94.25	93.75	93.81
LTP	95.73	96.46	95.75	95.98	98.9	98.2	98.3	98.47	93.65	94.84	94.94	94.47
CLBP S/M	94.93	96.14	95.18	95.42	98.8	98.2	98.00	98.33	93.65	94.84	94.94	94.47
CLBP S	89.14	89.27	85.69	80.03	97.60	97.00	96.30	94.20	90.67	93.65	91.47	91.93
CLBP M	85.69	88.15	85.65	86.50	94.70	94.50	93.40	94.20	81.65	84.42	83.63	83.23
CLDP	96.23	77.10	71.06	81.46	97.60	87.10	80.10	88.27	91.07	69.35	56.45	72.29
RLBP	89.58	89.16	85.69	88.14	97.50	97.90	96.60	97.33	91.07	93.06	91.67	91.93
LBPV	78.24	83.12	84.41	81.92	88.40	92.70	92	91.03	64.48	76.49	75.00	71.99
CRSLBP	96.89	96.76	97.19	96.94	98.50	98.40	98.80	98.56	94.15	95.54	95.44	95.04
MRELBP		98.55		98.55		99.60		99.60		97.02		97.02

(a) Using SVM classifier

	Taux de classification (%) <i>Outex</i> (NN)											
	KTH-TIPS2b				UMD				Brodatz			
	R = 1	R = 2	R = 3	Average	R = 1	R = 2	R = 3	Average	R = 1	R = 2	R = 3	Average
LBP classic	87.08	84.85	83.59	85.17	96.00	92.67	94.00	94.22	87.42	90.07	90.73	89.40
HLBP	81.77	89.34	89.29	86.8	96.67	95.33	92.66	94.89	87.42	86.09	83.44	85.65
HRLBP	81.62	86.26	89.26	85.71	94.64	94.00	96.67	95.10	84.11	84.11	90.07	86.10
HLBP+LBP	94.25	95.79	96.27	95.44	98.00	99.33	100	99.11	95.37	96.03	94.04	95.15
HRLBP+RLBP	95.23	94.53	96.06	95.23	98.64	99.33	99.33	99.1	93.38	95.37	92.05	93.6
LTP	93.68	94.68	92.70	93.69	98.00	98.66	97.33	98.00	94.04	93.38	94.04	93.82
CLBP S/M	92.15	93.40	91.72	92.42	97.33	98.00	98.00	97.78	92.05	92.71	94.04	92.93
CLBP S	85.97	85.41	81.90	84.43	95.33	96.66	91.33	94.44	89.40	93.38	92.72	91.83
CLBP M	82.60	82.18	82.32	82.37	89.33	92.66	86.66	89.55	84.77	83.44	87.42	85.21
CLDP	96.23	77.10	71.06	81.46	96.66	83.33	75.33	85.11	85.43	60.26	58.94	68.21
RLBP	87.79	83.59	80.78	84.05	94.66	92.66	93.33	93.55	93.38	92.72	90.06	92.05
LBPV	71.39	79.95	72.37	74.57	65.33	84.00	87.33	78.88	59.60	78.15	74.83	70.86
CRSLBP	94.81	95.37	95.65	95.28	99.33	100	98.67	99.33	95.37	98.68	100	98.01
MRELBP		96.49		96.49		100		100		97.35		97.35

(b) Using NN classifier

5.4.4 Résultats expérimentaux avec la base de données *UMD*

UMD est la base de données la plus exigeante parce qu'elle est composée d'images de haute résolution (1280×960). Les résultats expérimentaux avec l'ensemble des données de *UMD* sont répertoriés dans le tableau.5.3 pour les classificateurs SVM et NN.

Nous avons principalement examiné la CRSLBP en comparaison avec la LBP originale. Malgré la haute résolution, la rotation arbitraire, les grands changements de point de vue et les différentes échelles au sein du jeu de données *UMD*, l'approche proposée a obtenu la plus grande

précision : 100 % pour $radius = 2$ avec NN. Pour les deux classificateurs, CRSLBP est beaucoup plus robuste que LBP. Notre deuxième étude expérimentale a testé CRSLBP par rapport à HLBP et HRLBP. Comme illustré dans le tableau 5.3, le CRSLBP a affiché une plus grande précision de classification : 98,5 %, 98,4 % et 98,80 % avec SVM et 99,33 %, 100 % et 98,67 % avec NN (rayon $R = 1$, $R = 2$ et $R = 3$ respectivement). De plus, CRSLBP a démontré sa robustesse par rapport à HLBP renforcé par LBP et HRLBP renforcé par RLBP. La dernière expérience a montré le potentiel de CRSLBP par rapport aux approches SOTA. Comme nous pouvons le voir, le taux de classification moyenne de notre descripteur est beaucoup plus élevé que les autres à travers différentes résolutions (rayon et classificateur), à l'exception de MRELBP, comme expliqué précédemment.

5.4.5 Résultats expérimentaux avec la base de données *Brodatz*

La base de données *Brodatz*, bien qu'elle soit relativement ancienne, est encore largement utilisée aujourd'hui. Les résultats de l'expérience avec l'ensemble de données de *Brodatz* sont présentés dans le tableau.5.3. En utilisant le CRSLBP, nous avons obtenu des taux de classification moyenne de 95,04 % et 98,01 %, surpassant le LBP d'origine, qui avait une précision de classification de 91,40 % et 89,40 % avec SVM et NN, respectivement, ce qui démontre les performances du CRSLBP. D'autre part, nous avons évalué la robustesse du CRSLBP par rapport à HLBP, HRLBP, HLBP+LBP et HRLBP+HRLBP. Comme le montrent les tableaux, les précisions les plus élevées ont été obtenues par le CRSLBP, et les méthodes SOTA ont donné des taux de classification inférieurs au nôtre à l'exception du MRELBP.

5.5 Discussion

Après avoir terminé nos études expérimentales, nous avons fait les observations suivantes : dans ce travail, nous avons proposé une nouvelle approche de classification des textures appelée CRSLBP. Le taux de reconnaissance de CRSLBP a été évalué par rapport aux approches largement utilisées pour la classification des textures, à savoir LBP, HLBP, HRLBP, HLBP+LBP, HRLBP+RLBP, LTP, CLBP S/M, CLBP S, CLBP M, CLDP, RLBP, LBP Variance (LBPV) et MRELBP. De plus, CRSLBP a été testé à l'aide de bases de données de textures accessibles au public, telles que : *Outex (TC10, TC12)*, *Kth-Tips2b*, *UMD* et *Brodatz*. Les résultats obtenus avec toutes les bases de données démontrent que le descripteur proposé CRSLBP est efficace, robuste et performant quels que soient les enjeux de la base de données. La principale raison de

ce succès est l'exploitation simultanée de la relation entre quatre pixels centraux et de chaque pixel central en profitant des voisins provenant des voisins des pixels centraux, nous permettant de collecter des caractéristiques plus discriminantes. D'autre part, en éliminant l'interpolation bilinéaire, nous pouvons profiter de chaque pixel voisin dans le bloc, même si l'échelle augmente, nous permettant de capturer toutes les informations de l'image. De plus, toutes les informations de texture locale ont été extraites immédiatement en utilisant diverses manières de seuillage à partir des pixels voisins en forme de coin et de losange. Cela fusionne les informations de signe et de magnitude, nous permettant d'examiner différents types d'informations et de générer un puissant motif binaire robuste aux changements d'échelle, de rotation et d'éclairage.

5.5.1 Résultats expérimentaux du CRSLBP avec MRELBP

Quant au faible taux de classification de notre descripteur par rapport à la méthode MRELBP, il est normal d'obtenir de petites différences de précision de classification entre les deux approches en raison de l'ensemble des quatre valeurs de rayon utilisées dans MRELBP pour générer un code qui permet plusieurs échelles à la fois. Pour éviter cette irrégularité entre CRSLBP et MRELBP, nous avons réalisé une autre expérience avec des paramètres réglementaires. Pour les deux descripteurs, les paramètres de sélection étaient un ensemble de valeurs de rayon (2, 4, 6, 8) avec un classificateur SVM. Le tableau 5.4 montre les résultats de cette expérience.

TABLEAU 5.4 – Taux de la classification (%) de CRSLBP par rapport à MRELBP à l'aide d'un ensemble de classificateurs R et SVM

	<i>Outex(TC10,TC12)</i>			<i>KTH-TIPS2b</i>	<i>UMD</i>	<i>Brodatz</i>
	<i>inca</i>	<i>T184</i>	<i>horizon</i>			
MRELBP	99.9%	87.02%	87.04%	98.55%	99.6%	97.02%
CRSLBP	99.88%	94.77%	95.56%	99.22%	99.1%	95.84%

Sur la base de l'analyse du tableau, notre méthode a obtenu de meilleurs résultats que MRELBP, avec des précisions de classification plus élevées pour la plupart des ensembles de données (*Outex TC12* et *KTH-TIPS2b*). De plus, la différence de résultats avec les autres bases de données est très faible si l'on considère la grande différence de dimension de vecteur de caractéristique entre les deux : 120 et 800 pour le CRSLBP et le MRELBP.

5.6 Conclusion

Une nouvelle approche appropriée pour les images de classification de texture est proposée dans ce chapitre, nommée «*corner rhombus shape LBP*» (CRSLBP). En fait, CRSLBP est une version améliorée de la méthode LBP qui prend en considération le signe et la magnitude, avec l'ajout du bloc de choix pair, qui nous permet de seuiller quatre pixels centraux. Cela sert à obtenir des relations non seulement entre voisins, mais aussi avec le centre. Différentes expériences ont été menées pour évaluer le CRSLBP en utilisant les bases de données les plus populaires et les plus difficiles en classification de texture (*Outex [TC10, TC12]*, *Brodatz*, *UMD* et *KTH-TIPsb2*) et deux classificateurs (SVM et NN). Les résultats montrent que notre approche de CHLBP surpasse les très grandes méthodes SOTA en matière de précision de classification lors de l'utilisation de différents rayons et voisins.



CONCLUSION GÉNÉRALE

Ce chapitre résume les idées essentielles proposées dans les chapitres précédents, tire des conclusions et met en évidence les contributions importantes apportées par la recherche présentée dans cette thèse. Il donne également un aperçu des possibilités de recherche futures potentielles, en particulier dans le but d'améliorer encore la fonctionnalité et l'efficacité des algorithmes présentés.

L'impulsion fondamentale de la recherche est un travail sur les descripteurs de texture *local binary pattern* (LBP) présenté dans (Ojala et al. [2002c]). Le LBP est un descripteur de texture basique mais puissant, dont diverses variantes ont été publiées dans la littérature. Dans cette thèse, des nouvelles variantes du descripteur LBP sont proposées afin de surmonter certains problème ou défis du descripteur original qui vont nous permettre de mieux analyser et caractériser la texture, spécialement les images de télédétection. Généralement, les deux premières variantes proposées (HLBP et HRLBP) utilisent un nouveau critère de tolérance d'homogénéité qui permet de mieux prendre en considération les relations entre les pixels voisins. Par conséquent, les voisinages des pixels correspondent davantage aux structures spatiales sous-jacentes. Non seulement les HLBP et HRLBP sont proposés, mais le concept est également étendu pour la caractérisation de la texture dans le contexte de la classification par télédétection, en proposant le CHLBP qui prend en considération trois paramètres, celui du HLBP (tolérance d'homogénéité), du CLBP (signe et amplitude) et un nouveau paramètre δ qui permet de seuiller les pixels centraux dans une plage spécifique avec la génération de signaux positifs et modèles locaux négatifs. Une quatrième variante a été proposée qui se fonde sur l'impact des coordonnées polaire pour améliorer la performance surtout, du côté du changement de rotation. En outre, la dernière proposition de cette thèse CRSLBP a porté sur l'amélioration du LBP en se fondant sur l'impact des relations entre les centre qui sont négligeables dans la plupart des variantes du LBP de l'état de l'art. Les performances des deux descripteurs sont impressionnantes et surpassent la plupart des variantes

de LBP discutées dans cette thèse. Les performances des descripteurs suggérés sont examinées sur quatre bases de données de classification de la texture et deux bases de données de télédétection pour démontrer leur efficacité. Les résultats montrent que les descripteurs ont assez bien surpassé leurs équivalents originaux.

Nous avons brièvement résumé notre contribution dans ce qui suit : au cours du premier chapitre, nous avons exposé une revue de la littérature sur la texture et les techniques d'analyse de celle-ci en mettant l'accent sur les problèmes de classification. Des études sur la perception humaine de la texture et les premières méthodologies d'extraction de caractéristiques sont présentées comme la base sur laquelle les tendances et les nouvelles sont développées. Les méthodes d'extraction de caractéristiques de texture sont discutées, en mettant l'accent sur la classification. En outre, nous avons introduit les différentes bases de données que nous avons utilisées pour l'évaluation de nos approches.

Dans le deuxième chapitre, avant d'entamer les différents algorithmes de classification et les tests statistiques utilisés pour évaluer la pertinence des attributs extraits à partir de la texture, nous avons particulièrement mis l'accent d'une façon détaillée sur le descripteur LBP et ses variantes, y compris les mappages, comme étant une approche de texture invariante en échelle de gris simple mais puissante ; et de même, il s'agit de la base de nos approches proposées dans cette thèse.

Dans le troisième chapitre, nous avons proposé trois nouvelles extensions du LBP (HLBP, HRLBP et CHLBP). Premièrement, nous avons exploité l'impact de la tolérance d'homogénéité provenant du GAN *based Miskowski maps* (González-Castro et al. [2015]) pour la création du HLBP, afin d'améliorer la performance du descripteur LBP et de surmonter le problème de traitement global de l'image par GAN, en utilisant un seuillage établi sur un critère choisi, tel que la luminance, le contraste, l'épaisseur, etc. Les valeurs des critères de pixel s'inscrivent dans une plage spécifiée de tolérance d'homogénéité qui permet de mieux prendre en considération les relations entre les pixels voisins. Ensuite, nous avons renforcé le HLBP en utilisant le RLBP dans notre deuxième contribution HRLBP. Par la suite, nous nous sommes intéressé à la classification des images de télédétection en tolérance au bruit, et nous avons proposé le troisième descripteur CHLBP comme une version améliorée de HLBP en considérant l'impact de la tolérance d'homogénéité et la distribution hybride (signe et magnitude) fournie par CLBP avec l'ajout d'un paramètre δ qui permet de seuiller les pixels centraux dans une plage spécifique avec la génération de signaux positifs et de modèles locaux négatifs. Les résultats obtenus montrent la robustesse, l'efficacité et la performance d'approches que nous avons proposées (HLBP, HRLBP et CHLBP)

en utilisant une variété de bases de données populaires telles que *Outex (TC10, TC12)*, *GID* et *AID* avec des classifieurs (SVM et KNN) pour la caractérisation de la texture, et spécialement le CHLBP qui caractérise à la fois la texture avec les critères de changement d'éclairage et de rotation et les images de télédétection en présence de bruit (*white Gaussian, salt and paper*, et *Gaussian blur*).

Notre contribution CPLBP a fait l'objet du quatrième chapitre. Nous avons exploité l'impact des coordonnées polaires (rayon R et angle θ) afin d'extraire des caractéristiques d'un segment de pixels au lieu d'un seul voisin de LBP, ce qui permet de conserver toutes les informations spatiales afin de réduire le bruit, et en conséquence, d'obtenir des informations puissantes, robustes et discriminantes. Par la suite, nous avons remarqué que la plupart des extensions de LBP travaillent sur l'amélioration de la méthode en utilisant des relations spatiales provenant des pixels voisins, tandis que ceux des pixels centraux sont relâchés, ce qui nous a conduit à présenter notre cinquième contribution CRSLBP dans le dernier chapitre. L'idée est de changer la dimension du bloc afin d'obtenir plus qu'un pixel central. De cette manière, nous pouvons déterminer la relation entre les pixels centraux et entre les pixels centraux et voisins des pixels centraux voisins. Différentes études expérimentales ont été menées pour évaluer le CPLBP et le CRSLBP en utilisant les bases de données les plus populaires et les plus difficiles en classification de texture (*Outex [TC10, TC12]*, *Brodatz*, *UMD* et *KTH-TIPSB2*) et deux classificateurs (SVM et NN). Les résultats expérimentaux démontrent que les extensions LBP suggérées surpassent les très grandes méthodes SOTA en matière de précision de classification.

Perspectives

Peu importe le nombre de fois que l'analyse comparative sera effectuée, elle n'atteindra jamais le sommet et couvrira toutes les variétés de LBP, d'autant plus que de nouvelles variantes émergent constamment. En conséquence, le *benchmarking* sera mis à jour régulièrement. De plus, il y aura toujours une certaine variation entre les données du monde réel et les données synthétisées. Ce vide sera comblé en comparant les versions de LBP sur des ensembles de données du monde réel. Étant donné que les tendances actuelles de la vision par ordinateur dépendent des données 3D, il sera difficile d'évaluer les performances de LBP sur des ensembles de données présentant un certain degré de variance 3D. Des ensembles de données fournissent des photos faciales dans diverses poses, ce qui peut nous conduire à une conclusion différente de celle énoncée dans cette thèse.

Parmi les descripteurs proposés dans cette thèse, il y a ceux qui génèrent plus qu'une image à la fois. Afin de réduire la longueur des caractéristiques de ces descripteurs, tout en gardant

la même performance, voire en l'augmentant, la méthode principale est le *component analysis* (PCA).

Les méthodes que nous proposons peuvent s'appliquer à d'autres domaines, y compris ceux du médical, de la reconnaissance faciale ou du biomédical. Selon le degré de la problématique, ces approches peuvent être combinées à d'autres, comme filtre de Gabor, l'ondelette, etc., afin de consolider les résultats et de garantir une meilleure performance.

La catégorie du LBP «Combinaison avec des fonctionnalités complémentaires», ouvre la voie vers diverses perspectives liées à la combinaison des descripteurs que nous avons proposés avec des approches de *deep learning*, telles que la combinaison de CHLBP avec la méthode ScatNet qui se sont avérés robustes au bruit. Cependant, cela nécessite des expériences et des tests sur des données de bruit.



LISTE DE PUBLICATIONS

Revues internationales

Al Saidi, Ibtissam, Mohammed Rziza, and Johan Debayle. "A New LBP Variant : Corner Rhombus Shape LBP (CRSLBP)." *Journal of Imaging* 8, no. 7 (2022) : 200. doi : 10.3390/ji-maging8070200

Al Saidi, I., Rziza, M., & Debayle, J. (2021). A novel texture descriptor : circular parts local binary pattern. *Image Analysis & Stereology*, 40(2), 105-114, doi :10.5566/ias.2580

Conférences internationales

Al Saidi, I., Rziza, M., & Debayle, J. (2021, April). A novel texture descriptor : Homogeneous Rotated Local Binary Pattern (HRLBP). *In 2020 10th International Symposium on Signal, Image, Video and Communications (ISIVC)* (pp. 1-5). *IEEE*, doi :10.1109/ISIVC49222.2021.9487538

Al Saidi, I., Rziza, M., & Debayle, J. (2020, June). A new texture descriptor : the Homogeneous Local Binary Pattern (HLBP). *In International Conference on Image and Signal Processing* (pp. 308-316). *Springer*, Cham, doi :10.1007/978-3-030-51935-3_33

Articles soumis

Al Saidi, I., Rziza, M., & Debayle, J. Completed Homogeneous LBP For Remote Sensing Image Classification. *International Journal of Remote Sensing*.



BIBLIOGRAPHIE

- Vistex. <http://vismod.media.mit.edu/vismod/imagery/VisionTexture/>, 2002.
- Frank Ade. Characterization of textures by 'eigenfilters'. *Signal Processing*, 5(5) :451–457, 1983.
- Adib Akl, Charles Yaacoub, Marc Donias, Jean-Pierre Da Costa, and Christian Germain. Texture synthesis using the structure tensor. *IEEE Transactions on Image Processing*, 24(11) :4082–4095, 2015.
- Abdulla Al-Kaff, David Martin, Fernando Garcia, Arturo de la Escalera, and José María Armingol. Survey of computer vision algorithms and applications for unmanned aerial vehicles. *Expert Systems with Applications*, 92 :447–463, 2018.
- Ibtissam Al Saidi, Mohammed Rziza, and Johan Debayle. A new texture descriptor : the homogeneous local binary pattern (hlbp). In *International Conference on Image and Signal Processing*, pages 308–316. Springer, 2020.
- Ibtissam Al Saidi, Mohammed Rziza, and Johan Debayle. A novel texture descriptor : Homogeneous rotated local binary pattern (hrlbp). In *2020 10th International Symposium on Signal, Image, Video and Communications (ISIVC)*, pages 1–5. IEEE, 2021.
- BJ Alder and TE Wainwright. Decay of the velocity autocorrelation function. *Physical review A*, 1(1) :18, 1970.
- Ghassan AlRegib, Mohamed Deriche, Zhiling Long, Haibin Di, Zhen Wang, Yazeed Alaudah, Muhammad Amir Shafiq, and Motaz Alfarraj. Subsurface structure analysis using computational interpretation and learning : A visual signal processing perspective. *IEEE Signal Processing Magazine*, 35(2) :82–98, 2018.

- Erchan Aptoula. Remote sensing image retrieval with global morphological texture descriptors. *IEEE transactions on geoscience and remote sensing*, 52(5) :3023–3034, 2013.
- Robert R Bailey and Mandyam Srinath. Orthogonal moment features for use with parametric and non-parametric classifiers. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(4) :389–399, 1996.
- Herbert Bay, Andreas Ess, Tinne Tuytelaars, and Luc Van Gool. Speeded-up robust features (surf). *Computer vision and image understanding*, 110(3) :346–359, 2008.
- Silvia Biasotti, Andrea Cerri, Mostafa Abdelrahman, Masaki Aono, A Ben Hamza, Moumen El-Melegy, Aly Farag, Valeria Garro, Andrea Giachetti, Daniela Giorgi, et al. Shrec'14 track : Retrieval and classification on textured 3d models. In *Proceedings of the Eurographics workshop on 3d object retrieval*, pages 111–120, 2014.
- Silvia Biasotti, Andrea Cerri, Masaki Aono, A Ben Hamza, Valeria Garro, Andrea Giachetti, Daniela Giorgi, Afzal Godil, C Li, Chika Sanada, et al. Retrieval and classification methods for textured 3d models : a comparative study. *The visual computer*, 32(2) :217–241, 2016.
- Giulia Boato, Duc-Tien Dang-Nguyen, and Francesco GB De Natale. Morphological filter detector for image forensics applications. *IEEE Access*, 8 :13549–13560, 2020.
- Bernhard E Boser, Isabelle M Guyon, and Vladimir N Vapnik. A training algorithm for optimal margin classifiers. In *Proceedings of the fifth annual workshop on Computational learning theory*, pages 144–152, 1992.
- Ronald Newbold Bracewell and Ronald N Bracewell. *The Fourier transform and its applications*, volume 31999. McGraw-Hill New York, 1986.
- Phil Brodatz. *Textures : a photographic album for artists and designers*. New York : Dover Pub., 1966.
- Weiwei Cai and Zhanguo Wei. Remote sensing image classification based on a cross-attention mechanism and graph convolution. *IEEE Geoscience and Remote Sensing Letters*, 2020.
- Fergus W Campbell and John G Robson. Application of fourier analysis to the visibility of gratings. *The Journal of physiology*, 197(3) :551, 1968.

- Barbara Caputo, Eric Hayman, and P Mallikarjuna. Class-specific material categorisation. In *Tenth IEEE International Conference on Computer Vision (ICCV'05) Volume 1*, volume 2, pages 1597–1604. IEEE, 2005.
- Gabriella Castellano, Leonardo Bonilha, LM Li, and Fernando Cendes. Texture analysis of medical images. *Clinical radiology*, 59(12) :1061–1069, 2004.
- Chih-Chung Chang and Chih-Jen Lin. Libsvm : a library for support vector machines. *ACM transactions on intelligent systems and technology (TIST)*, 2(3) :1–27, 2011.
- Jocelyn Chanussot, Patrick Bas, and Lionel Bombrun. Airborne remote sensing of vineyards for the detection of dead vine trees. In *Proceedings. 2005 IEEE International Geoscience and Remote Sensing Symposium, 2005. IGARSS'05.*, volume 5, pages 3090–3093. Citeseer, 2005.
- Peter Cheeseman. A method of computing generalized bayesian probability values for expert systems. In *Proceedings of the Eighth international joint conference on Artificial intelligence-Volume 1*, pages 198–202, 1983.
- Mircea Cimpoi, Subhransu Maji, Iasonas Kokkinos, Sammy Mohamed, and Andrea Vedaldi. Describing textures in the wild. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pages 3606–3613, 2014.
- Mircea Cimpoi, Subhransu Maji, and Andrea Vedaldi. Deep filter banks for texture recognition and segmentation. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 3828–3836, 2015.
- David A Clausi and Huang Deng. Design-based texture feature fusion using gabor filters and co-occurrence probabilities. *IEEE transactions on image processing*, 14(7) :925–936, 2005.
- CA Coburn and Arthur CB Roberts. A multiscale texture analysis procedure for improved forest stand classification. *International journal of remote sensing*, 25(20) :4287–4308, 2004.
- Fernand S Cohen and David B Cooper. Simple parallel hierarchical and relaxation algorithms for segmenting noncausal markovian random fields. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (2) :195–219, 1987.
- Thomas Cover and Peter Hart. Nearest neighbor pattern classification. *IEEE transactions on information theory*, 13(1) :21–27, 1967.

- Antonio Criminisi and Andrew Zisserman. Shape from texture : Homogeneity revisited. In *BMVC*, volume 1, page 2, 2000.
- George R Cross and Anil K Jain. Markov random field texture models. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, (1) :25–39, 1983.
- Jean Pierre Da Costa, Franck Michelet, Christian Germain, Olivier Lavialle, and Gilbert Grenier. Delineation of vine parcels by segmentation of high resolution remote sensed images. *Precision Agriculture*, 8(1) :95–110, 2007.
- Navneet Dalal and Bill Triggs. Histograms of oriented gradients for human detection. In *2005 IEEE computer society conference on computer vision and pattern recognition (CVPR'05)*, volume 1, pages 886–893. Ieee, 2005.
- Kristin J Dana, Bram Van Ginneken, Shree K Nayar, and Jan J Koenderink. Reflectance and texture of real-world surfaces. *ACM Transactions On Graphics (TOG)*, 18(1) :1–34, 1999.
- Piet Dewaele, Luc Van Gool, A Wambacq, and André Oosterlinck. Texture inspection with self-adaptive convolution filters. In *9th International Conference on Pattern Recognition*, pages 56–57. IEEE Computer Society, 1988.
- Thanh-Nghi Do. Automatic learning algorithms for local support vector machines. *SN Computer Science*, 1(1) :1–11, 2020.
- James S Duncan and Nicholas Ayache. Medical image analysis : Progress over two decades and the challenges ahead. *IEEE transactions on pattern analysis and machine intelligence*, 22(1) : 85–106, 2000.
- Alexei A Efros and Thomas K Leung. Texture synthesis by non-parametric sampling. In *Proceedings of the seventh IEEE international conference on computer vision*, volume 2, pages 1033–1038. IEEE, 1999.
- M Emimal and P Kannan. Classification of remote sensing images using wavelet based contourlet transform and accuracy analysis of classified images. *International Journal of Advanced Networking and Applications*, 9(5) :3601–3605, 2018.
- Yuming Fang, Jiaying Liu, Yabin Zhang, Weisi Lin, and Zongming Guo. Reduced-reference quality assessment of image super-resolution by energy change and texture variation. *Journal of Visual Communication and Image Representation*, 60 :140–148, 2019.

- Antonio Fernández, Marcos X Álvarez, and Francesco Bianconi. Texture description through histograms of equivalent patterns. *Journal of mathematical imaging and vision*, 45(1) :76–102, 2013.
- William T Freeman, Edward H Adelson, et al. The design and use of steerable filters. *IEEE Transactions on Pattern analysis and machine intelligence*, 13(9) :891–906, 1991.
- Mario Fritz, Eric Hayman, Barbara Caputo, and Jan-Olof Eklundh. The kth-tips database. 2004.
- Dennis Gabor. Theory of communication. part 1 : The analysis of information. *Journal of the Institution of Electrical Engineers-Part III : Radio and Communication Engineering*, 93(26) : 429–441, 1946.
- Bruno Galerne, Yann Gousseau, and Jean-Michel Morel. Micro-texture synthesis by phase randomization. *Image processing on line*, 1 :213–237, 2011.
- Mary M Galloway. Texture analysis using grey level run lengths. *NASA STI/Recon Technical Report N*, 75 :18555, 1974.
- Leon Gatys, Alexander S Ecker, and Matthias Bethge. Texture synthesis using convolutional neural networks. *Advances in neural information processing systems*, 28, 2015.
- Mohammad Ghahramani, Guoying Zhao, and Matti Pietikäinen. Incorporating texture intensity information into lbp-based operators. In *Scandinavian Conference on Image Analysis*, pages 66–75. Springer, 2013.
- Víctor González-Castro, Johan Debayle, Yanal Wazaefi, Mehdi Rahim, Caroline Gaudy-Marqueste, Jean-Jacques Grob, and Bernard Fertil. Texture descriptors based on adaptive neighborhoods for classification of pigmented skin lesions. *Journal of Electronic Imaging*, 24(6) :061104, 2015.
- Steve R Gunn et al. Support vector machines for classification and regression. *ISIS technical report*, 14(1) :5–16, 1998.
- Zhenhua Guo, Lei Zhang, and David Zhang. A completed modeling of local binary pattern operator for texture classification. *IEEE transactions on image processing*, 19(6) :1657–1663, 2010a.
- Zhenhua Guo, Lei Zhang, and David Zhang. Rotation invariant texture classification using lbp variance (lbpv) with global matching. *Pattern recognition*, 43(3) :706–719, 2010b.

- Zhenhua Guo, Xingzheng Wang, Jie Zhou, and Jane You. Robust texture image representation by scale selective local binary patterns. *IEEE Transactions on Image Processing*, 25(2) :687–699, 2015.
- Adel Hafiane, Guna Seetharaman, and Bertrand Zavidovique. Median binary pattern for textures classification. In *International Conference Image Analysis and Recognition*, pages 387–398. Springer, 2007.
- Masoud Hajeb, Sadra Karimzadeh, and Abdolhossein Fallahi. Seismic damage assessment in sarpole-zahab town (iran) using synthetic aperture radar (sar) images and texture analysis. *Natural Hazards*, 103 :347–366, 2020.
- Fei Han, Brian Reily, William Hoff, and Hao Zhang. Space-time representation of people based on 3d skeletal data : A review. *Computer Vision and Image Understanding*, 158 :85–105, 2017.
- Robert M Haralick. Statistical and structural approaches to texture. *Proceedings of the IEEE*, 67(5) :786–804, 1979.
- Robert M Haralick, Karthikeyan Shanmugam, and Its' Hak Dinstein. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, (6) :610–621, 1973.
- David Harwood, Timo Ojala, Matti Pietikäinen, Shalom Kelman, and Larry Davis. Texture classification by center-symmetric auto-correlation, using kullback discrimination of distributions. *Pattern Recognition Letters*, 16(1) :1–10, 1995.
- Eric Hayman, Barbara Caputo, Mario Fritz, and Jan-Olof Eklundh. On the significance of real-world conditions for material classification. In *European conference on computer vision*, pages 253–266. Springer, 2004.
- Dong-Chen He and Li Wang. Texture unit, texture spectrum, and texture analysis. *IEEE transactions on Geoscience and Remote Sensing*, 28(4) :509–512, 1990.
- Marko Heikkila and Matti Pietikainen. A texture-based method for modeling the background and detecting moving objects. *IEEE transactions on pattern analysis and machine intelligence*, 28(4) :657–662, 2006.
- Chih-Wei Hsu and Chih-Jen Lin. A comparison of methods for multiclass support vector machines. *IEEE transactions on Neural Networks*, 13(2) :415–425, 2002.

- Yuting Hu, Zhiling Long, and Ghassan AlRegib. Scale selective extended local binary pattern for texture classification. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 1413–1417. IEEE, 2017.
- Di Huang, Yunhong Wang, and Yiding Wang. A robust method for near infrared face recognition based on extended local binary pattern. In *International Symposium on Visual Computing*, pages 437–446. Springer, 2007.
- Mingming Huang, Zhichun Mu, Hui Zeng, and Shuai Huang. Local image region description using orthogonal symmetric local ternary pattern. *Pattern Recognition Letters*, 54 :56–62, 2015.
- Yonggang Huang, Yunhong Wang, and Tieniu Tan. Combining statistics of geometrical and correlative features for 3d face recognition. In *BMVC*, pages 879–888. Citeseer, 2006.
- Dimitris K Iakovidis, Eystratios G Keramidas, and Dimitris Maroulis. Fuzzy local binary patterns for ultrasound texture characterization. In *International conference image analysis and recognition*, pages 750–759. Springer, 2008.
- Anil K Jain and Farshid Farrokhnia. Unsupervised texture segmentation using gabor filters. *Pattern recognition*, 24(12) :1167–1186, 1991.
- Anil K. Jain and Kalle Karu. Learning texture discrimination masks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 18(2) :195–205, 1996.
- Anil K Jain, Sushil K Bhattacharjee, and Yao Chen. On texture in document images. In *CVPR*, pages 677–680. Citeseer, 1992.
- Anil K Jain, Robert P. W. Duin, and Jianchang Mao. Statistical pattern recognition : A review. *IEEE Transactions on pattern analysis and machine intelligence*, 22(1) :4–37, 2000.
- Nikolay Jetchev, Urs Bergmann, and Roland Vollgraf. Texture synthesis with spatial generative adversarial networks. *arXiv preprint arXiv :1611.08207*, 2016.
- Hongliang Jin, Qingshan Liu, Hanqing Lu, and Xiaofeng Tong. Face detection using improved lbp under bayesian framework. In *Third International Conference on Image and Graphics (ICIG'04)*, pages 306–309. IEEE, 2004.
- Bela Julesz. Visual pattern discrimination. *IRE transactions on Information Theory*, 8(2) : 84–92, 1962.

- Bela Julesz. Textons, the elements of texture perception, and their interactions. *Nature*, 290 (5802) :91–97, 1981a.
- Bela Julesz. A theory of preattentive texture discrimination based on first-order statistics of textons. *Biological Cybernetics*, 41(2) :131–138, 1981b.
- Bela Julesz, Edgar N Gilbert, and Jonathan D Victor. Visual discrimination of textures with identical third-order statistics. *Biological Cybernetics*, 31(3) :137–140, 1978.
- Christos Kampouris, Stefanos Zafeiriou, Abhijeet Ghosh, and Sotiris Malassiotis. Fine-grained material classification using micro-geometry and reflectance. In *European Conference on Computer Vision*, pages 778–792. Springer, 2016.
- Navdeep Kanwal, Akshay Girdhar, Lakhwinder Kaur, and Jaskaran Singh Bhullar. Detection of digital image forgery using fast fourier transform and local features. In *2019 International Conference on Automation, Computational and Technology Management (ICACTM)*, pages 262–267. IEEE, 2019.
- Kaplan Kaplan, Yılmaz Kaya, Melih Kuncan, and H Metin Ertunç. Brain tumor classification using modified local binary patterns (lbp) feature extraction methods. *Medical hypotheses*, 139 :109696, 2020.
- Mohamed Kas, Y Ruichek, R Messoussi, et al. Multi level directional cross binary patterns : New handcrafted descriptor for svm-based texture classification. *Engineering Applications of Artificial Intelligence*, 94 :103743, 2020.
- Brendan F Klare and Anil K Jain. Heterogeneous face recognition using kernel prototype similarities. *IEEE transactions on pattern analysis and machine intelligence*, 35(6) :1410–1422, 2012.
- Ron Kohavi et al. A study of cross-validation and bootstrap for accuracy estimation and model selection. In *Ijcai*, volume 14, pages 1137–1145. Montreal, Canada, 1995.
- Teuvo Kohonen. Self-organizing maps : optimization approaches. In *Artificial neural networks*, pages 981–990. Elsevier, 1991.
- Paulo Roberto Gardel Kurka and Aldo André Díaz Salazar. Applications of image processing in robotics and instrumentation. *Mechanical Systems and Signal Processing*, 124 :142–169, 2019.

- Daniel T Larose and Chantal D Larose. K-nearest neighbor algorithm. *Discovering knowledge in data : An introduction to data mining*, 90 :106, 2005.
- Kenneth I Laws. Rapid texture identification. In *Image processing for missile guidance*, volume 238, pages 376–381. SPIE, 1980a.
- Kenneth I Laws. Textured image segmentation. Technical report, University of Southern California Los Angeles Image Processing INST, 1980b.
- Kenneth Ivan Laws. Texture energy measures. In *Proc. Image understanding workshop*, pages 47–51. Los Angeles, CA : Sci. Appl, 1979.
- Svetlana Lazebnik, Cordelia Schmid, and Jean Ponce. A sparse texture representation using local affine regions. *IEEE transactions on pattern analysis and machine intelligence*, 27(8) : 1265–1278, 2005.
- Thomas Leung and Jitendra Malik. Representing and recognizing the visual appearance of materials using three-dimensional textons. *International journal of computer vision*, 43(1) : 29–44, 2001.
- Haifeng Li, Kaijian Qiu, Li Chen, Xiaoming Mei, Liang Hong, and Chao Tao. Scattnet : Semantic segmentation network with spatial and channel attention mechanism for high-resolution remote sensing images. *IEEE Geoscience and Remote Sensing Letters*, 18(5) :905–909, 2020.
- Haitao Li, Haiyan Gu, Yanshun Han, and Jinghui Yang. Object-oriented classification of high-resolution remote sensing imagery based on an improved colour structure code and a support vector machine. *International journal of remote sensing*, 31(6) :1453–1470, 2010.
- Shengcai Liao, Guoying Zhao, Vili Kellokumpu, Matti Pietikäinen, and Stan Z Li. Modeling pixel process with scale invariant local patterns for background subtraction in complex scenes. In *2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, pages 1301–1306. IEEE, 2010.
- Shu Liao and Albert Chung. Face recognition by using elongated local binary patterns with average maximum distance gradient magnitude. In *Asian conference on computer vision*, pages 672–679. Springer, 2007.
- Shu Liao, Max WK Law, and Albert CS Chung. Dominant local binary patterns for texture classification. *IEEE transactions on image processing*, 18(5) :1107–1118, 2009.

- Hsin-Chih Lin, Ling-Ling Wang, and Shi-Nine Yang. Color image retrieval based on hidden markov models. *IEEE Transactions on Image Processing*, 6(2) :332–339, 1997.
- Jinping Liu, Jiezhou He, Wuxia Zhang, Zhaohui Tang, Pengfei Xu, and Weiha Gui. Texture pattern classification based on probability density function estimation of the image spatial structure feature with symmetrical weibull distribution model. *Multimedia Tools and Applications*, 78(9) :12251–12279, 2019.
- Li Liu, Lingjun Zhao, Yunli Long, Gangyao Kuang, and Paul Fieguth. Extended local binary patterns for texture classification. *Image and Vision Computing*, 30(2) :86–99, 2012a.
- Li Liu, Lingjun Zhao, Yunli Long, Gangyao Kuang, and Paul Fieguth. Extended local binary patterns for texture classification. *Image and Vision Computing*, 30(2) :86–99, 2012b.
- Li Liu, Yunli Long, Paul W Fieguth, Songyang Lao, and Guoying Zhao. Brint : binary rotation invariant and noise tolerant texture classification. *IEEE transactions on Image Processing*, 23(7) :3071–3084, 2014.
- Li Liu, Songyang Lao, Paul W Fieguth, Yulan Guo, Xiaogang Wang, and Matti Pietikäinen. Median robust extended local binary pattern for texture classification. *IEEE Transactions on Image Processing*, 25(3) :1368–1381, 2016.
- Li Liu, Paul Fieguth, Yulan Guo, Xiaogang Wang, and Matti Pietikäinen. Local binary features for texture classification : Taxonomy and experimental study. *Pattern Recognition*, 62 :135–160, 2017.
- David G Lowe. Distinctive image features from scale-invariant keypoints. *International journal of computer vision*, 60(2) :91–110, 2004.
- Rouzbeh Maani, Sanjay Kalra, and Yee-Hong Yang. A review of texture classification methods and their applications in medical image analysis of the brain. *Handbook of Pattern Recognition and Computer Vision*, pages 351–369, 2016.
- Topi Mäenpää and Matti Pietikäinen. Texture analysis with local binary patterns. In *Handbook of pattern recognition and computer vision*, pages 197–216. World Scientific, 2005.
- Stephane G Mallat. Multifrequency channel decompositions of images and wavelet models. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 37(12) :2091–2110, 1989.

- P Mallikarjuna, Alireza Tavakoli Targhi, Mario Fritz, Eric Hayman, Barbara Caputo, and Jan-Olof Eklundh. The kth-tips2 database. *Computational Vision and Active Perception Laboratory, Stockholm, Sweden*, 11, 2006.
- Bangalore S Manjunath and Wei-Ying Ma. Texture features for browsing and retrieval of image data. *IEEE Transactions on pattern analysis and machine intelligence*, 18(8) :837–842, 1996.
- Andrzej Materka, Michal Strzelecki, et al. Texture analysis methods—a review. *Technical university of lodz, institute of electronics, COST B11 report, Brussels*, 10(1.97) :4968, 1998.
- Rakesh Mehta and Karen Egiazarian. Rotated local binary pattern (rlbp) : rotation invariant texture descriptor. In *2nd International Conference on Pattern Recognition Applications and Methods, ICPRAM 2013, Barcelona, Spain, 15.-18.2. 2013*, pages 497–502, 2013.
- Rakesh Mehta and Karen Egiazarian. Dominant rotated local binary patterns (drlbp) for texture classification. *Pattern Recognition Letters*, 71 :16–22, 2016.
- Jean Morlet. Sampling theory and wave propagation. In *Issues in acoustic Signal image processing and recognition*, pages 233–261. Springer, 1983.
- Sreerama K Murthy. Automatic construction of decision trees from data : A multi-disciplinary survey. *Data mining and knowledge discovery*, 2(4) :345–389, 1998.
- Jean-Pierre Nakache and Josiane Confais. *Statistique explicative appliquée : analyse discriminante, modèle logistique, segmentation par arbre*. Editions Technip, 2003.
- Loris Nanni, Alessandra Lumini, and Sheryl Brahnam. Local binary patterns variants as texture descriptors for medical image analysis. *Artificial intelligence in medicine*, 49(2) :117–125, 2010.
- Ryusuke Nosaka, Yasuhiro Ohkawa, and Kazuhiro Fukui. Feature extraction based on co-occurrence of adjacent local binary patterns. In *Pacific-rim symposium on image and video technology*, pages 82–91. Springer, 2011.
- Timo Ojala, Matti Pietikäinen, and David Harwood. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29(1) :51–59, 1996a.
- Timo Ojala, Matti Pietikäinen, and David Harwood. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29(1) :51–59, 1996b.

- Timo Ojala, Topi Maenpaa, Matti Pietikainen, Jaakko Viertola, Juha Kyllonen, and Sami Huovinen. Outex-new framework for empirical evaluation of texture analysis algorithms. In *Object recognition supported by user interaction for service robots*, volume 1, pages 701–706. IEEE, 2002a.
- Timo Ojala, Matti Pietikainen, and Topi Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on pattern analysis and machine intelligence*, 24(7) :971–987, 2002b.
- Timo Ojala, Matti Pietikainen, and Topi Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on pattern analysis and machine intelligence*, 24(7) :971–987, 2002c.
- Zhibin Pan, Hongcheng Fan, and Li Zhang. Texture classification using local pattern based on vector quantization. *IEEE Transactions on Image Processing*, 24(12) :5379–5388, 2015.
- Zhibin Pan, Shiqi Hu, Xiuquan Wu, and Ping Wang. Adaptive center pixel selection strategy to local binary pattern for texture classification. *Expert Systems with Applications*, page 115123, 2021.
- Soo Beom Park, Jae Won Lee, and Sang Kyoong Kim. Content-based image classification using a neural network. *Pattern Recognition Letters*, 25(3) :287–300, 2004.
- Anjie Peng, Gao Yu, and Hui Zeng. Blind median filtering detection using auto-regressive model and markov chain. *Int J Robotics Control*, 1(1) :32–40, 2018.
- Amnart Petpon and Sanun Srisuk. Face recognition with local line binary pattern. In *2009 Fifth International Conference on Image and Graphics*, pages 533–539. IEEE, 2009.
- Maria MP Petrou and Sei-ichiro Kamata. *Image processing : dealing with texture*. John Wiley & Sons, 2021.
- Matti Pietikäinen, Timo Ojala, and Zelin Xu. Rotation-invariant texture classification using feature distributions. *Pattern recognition*, 33(1) :43–52, 2000.
- Jean-Charles Pinoli and Johan Debayle. General adaptive neighborhood mathematical morphology. In *2009 16th IEEE International Conference on Image Processing (ICIP)*, pages 2249–2252. IEEE, 2009.

- Md Abdur Rahim, Md Shafiul Azam, Nazmul Hossain, and Md Rashedul Islam. Face recognition using local binary patterns (lbp). *Global Journal of Computer Science and Technology*, 2013.
- M Venkata Ramana, E Sreenivasa Reddy, and CH Satayanarayana. Curvelet transform for efficient static texture classification and image fusion. *International Journal of Image, Graphics & Signal Processing*, 10(5), 2018.
- Andrik Rampun, Philip Morrow, Bryan Scotney, and John Winder. Breast density classification using multiresolution local quinary patterns in mammograms. In *Annual Conference on Medical Image Understanding and Analysis*, pages 365–376. Springer, 2017.
- Olivier Regniers, Lionel Bombrun, Ioana Ilea, Virginie Lafon, and Christian Germain. Classification of oyster habitats by combining wavelet-based texture features and polarimetric sar descriptors. In *2015 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, pages 3890–3893. IEEE, 2015.
- Olivier Regniers, Lionel Bombrun, Virginie Lafon, and Christian Germain. Supervised classification of very high resolution optical images using wavelet-based textural features. *IEEE Transactions on Geoscience and Remote Sensing*, 54(6) :3722–3735, 2016.
- Jianfeng Ren, Xudong Jiang, and Junsong Yuan. Noise-resistant local binary pattern with an embedded error-correction mechanism. *IEEE Transactions on Image Processing*, 22(10) :4049–4060, 2013.
- Raúl Rojas. *Neural networks : a systematic introduction*. Springer Science & Business Media, 2013.
- Azriel Rosenfeld. *Digital picture processing*. Academic press, 1976.
- Y Ruichek et al. Attractive-and-repulsive center-symmetric local binary patterns for texture classification. *Engineering Applications of Artificial Intelligence*, 78 :158–172, 2019.
- LA Ruiz, A Fdez-Sarría, and JA Recio. Texture feature extraction for classification of remote sensing data using wavelet decomposition : A comparative study. In *20th ISPRS Congress*, volume 35, pages 1109–1114. Citeseer, 2004.
- Anita Sahoo and Satish Chandra. Multi-objective grey wolf optimizer for improved cervix lesion classification. *Applied Soft Computing*, 52 :64–80, 2017.

- Dayakshini Sathish, Surekha Kamath, Keerthana Prasad, Rajagopal Kadavigere, and Roshan J Martis. Asymmetry analysis of breast thermograms using automated segmentation and texture features. *Signal, Image and Video Processing*, 11(4) :745–752, 2017.
- Amit Satpathy, Xudong Jiang, and How-Lung Eng. Lbp-based edge-texture features for object recognition. *IEEE Transactions on image Processing*, 23(5) :1953–1964, 2014.
- Dahbia Sémani-Delmi. *Une méthode supervisée de sélection et de discrimination avec rejet : application au projet Aqu@ thèque*. PhD thesis, La Rochelle, 2004.
- Mohammad Hossein Shakoor and Reza Boostani. A novel advanced local binary pattern for image-based coral reef classification. *Multimedia Tools and Applications*, 77(2) :2561–2591, 2018a.
- Mohammad Hossein Shakoor and Reza Boostani. Radial mean local binary pattern for noisy texture classification. *Multimedia Tools and Applications*, 77(16) :21481–21508, 2018b.
- Mohammad Hossein Shakoor and Reza Boostani. Noise robust and rotation invariant texture classification based on local distribution transform. *Multimedia Tools and Applications*, 80(6) : 8639–8666, 2021.
- Aditya M Sharma, Ajay Gupta, P Krishna Kumar, Jeny Rajan, Luca Saba, Ikeda Nobutaka, John R Laird, Andrew Nicolades, and Jasjit S Suri. A review on carotid ultrasound atherosclerotic tissue characterization and stroke risk stratification in machine learning framework. *Current atherosclerosis reports*, 17(9) :1–13, 2015.
- Jamie Shotton, John Winn, Carsten Rother, and Antonio Criminisi. Textonboost for image understanding : Multi-class object recognition and segmentation by jointly modeling texture, layout, and context. *International journal of computer vision*, 81(1) :2–23, 2009.
- Aditya Singh, Ramesh K Sunkaria, and Anterpreet Kaur. A review on local binary pattern variants. In *Proceedings of First International Conference on Computational Electronics for Wireless Communications*, pages 545–552. Springer, 2022.
- Amit Kr Singh, Rajesh Singla, et al. Different approaches of classification of brain tumor in mri using gabor filters for feature extraction. In *Soft Computing : Theories and Applications*, pages 1175–1188. Springer, 2020.

- Vibhav Prakash Singh and Rajeev Srivastava. Content-based mammogram retrieval using wavelet based complete-lbp and k-means clustering for the diagnosis of breast cancer. *International Journal of Hybrid Intelligent Systems*, 14(1-2) :31–39, 2017.
- Jack Sklansky. Image segmentation and feature extraction. *IEEE Transactions on Systems, Man, and Cybernetics*, 8(4) :237–247, 1978.
- Arnold WM Smeulders, Marcel Worring, Simone Santini, Amarnath Gupta, and Ramesh Jain. Content-based image retrieval at the end of the early years. *IEEE Transactions on pattern analysis and machine intelligence*, 22(12) :1349–1380, 2000.
- Jingkuan Song, Yuyu Guo, Lianli Gao, Xuelong Li, Alan Hanjalic, and Heng Tao Shen. From deterministic to generative : Multimodal stochastic rnns for video captioning. *IEEE transactions on neural networks and learning systems*, 30(10) :3047–3058, 2018a.
- Jingkuan Song, Hanwang Zhang, Xiangpeng Li, Lianli Gao, Meng Wang, and Richang Hong. Self-supervised video hashing with hierarchical binary auto-encoder. *IEEE Transactions on Image Processing*, 27(7) :3210–3221, 2018b.
- Wei Song, Yubing Zhang, Fei Liu, Zhilei Chai, Feng Ding, Xuezhong Qian, and Soon Cheol Park. Taking advantage of multi-regions-based diagonal texture structure descriptor for image retrieval. *Expert Systems with Applications*, 96 :347–357, 2018c.
- Mervyn Stone. An asymptotic equivalence of choice of model by cross-validation and akaike’s criterion. *Journal of the Royal Statistical Society : Series B (Methodological)*, 39(1) :44–47, 1977.
- Richard N Sutton and Ernest Lenard Hall. Texture measures for automatic classification of pulmonary disease. *IEEE Transactions on Computers*, 100(7) :667–676, 1972.
- Sayed Mohamad Tabatabaei and Abdollah Chalechale. Noise-tolerant texture feature extraction through directional thresholded local binary pattern. *The Visual Computer*, pages 1–21, 2019.
- Hideyuki Tamura, Shunji Mori, and Takashi Yamawaki. Textural features corresponding to visual perception. *IEEE Transactions on Systems, man, and cybernetics*, 8(6) :460–473, 1978.
- Xiaoyang Tan and Bill Triggs. Enhanced local texture feature sets for face recognition under difficult lighting conditions. *IEEE transactions on image processing*, 19(6) :1635–1650, 2010.

- Jialin Tang, Qinglang Su, Binghua Su, Simon Fong, Wei Cao, and Xueyuan Gong. Parallel ensemble learning of convolutional neural networks and local binary patterns for face recognition. *Computer Methods and Programs in Biomedicine*, 197 :105622, 2020.
- Ramazan Tekin, Ömer Faruk Ertuğrul, and Yılmaz Kaya. New local binary pattern approaches based on color channels in texture classification. *Multimedia Tools and Applications*, 79(43) : 32541–32561, 2020.
- L Tomczak, V Mosorov, D Sankowski, and J Nowakowski. Image defect detection methods for visual inspection systems. In *2007 9th International Conference-The Experience of Designing and Applications of CAD Systems in Microelectronics*, pages 454–456. IEEE, 2007.
- Fumiaki Tomita and Saburo Tsuji. *Computer analysis of visual textures*, volume 102. Springer Science & Business Media, 2013.
- Xin-Yi Tong, Gui-Song Xia, Qikai Lu, Huanfeng Shen, Shengyang Li, Shucheng You, and Liangpei Zhang. Land-cover classification with high-resolution remote sensing images using transferable deep models. *Remote Sensing of Environment*, 237 :111322, 2020.
- Bill Triggs et al. Visual recognition using local quantized patterns. In *European conference on computer vision*, pages 716–729. Springer, 2012.
- Mihran Tuceryan and Anil K Jain. Texture analysis. *Handbook of pattern recognition and computer vision*, pages 235–276, 1993.
- Gozde Unal, Anthony Yezzi, and Hamid Krim. Information-theoretic active polygons for unsupervised texture segmentation. *International Journal of Computer Vision*, 62(3) :199–220, 2005.
- Michael Unser and Murray Eden. Multiresolution feature extraction and selection for texture segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7) :717–728, 1989.
- Michael Unser and Murray Eden. Nonlinear operators for improving texture segmentation based on features extracted by spatial filtering. *IEEE Transactions on Systems, Man, and Cybernetics*, 20(4) :804–815, 1990.
- Radu Dragos Urs. *Non-parametric synthesis of volumetric textures from a 2D sample*. PhD thesis, Université Sciences et Technologies-Bordeaux I, 2013.

- Vladimir Vapnik. *The nature of statistical learning theory*. Springer science & business media, 1999.
- Remco C Veltkamp and Mirela Tanase. Content-based image retrieval systems : A survey. *Department of Computing Science, Utrecht University*, pages 1–62, 2002.
- Luoma Wan, Hongsheng Zhang, Ting Wang, Gang Li, and Hui Lin. Mangrove species discrimination from very high resolution imagery using gaussian markov random field model. *Wetlands*, 38(5) :861–874, 2018.
- Junmin Wang, Yangyu Fan, Zuhe Li, and Tao Lei. Texture classification using multi-resolution global and local gabor features in pyramid space. *Signal, Image and Video Processing*, 13(1) : 163–170, 2019.
- Xiaoyu Wang, Tony X Han, and Shuicheng Yan. An hog-lbp human detector with partial occlusion handling. In *2009 IEEE 12th international conference on computer vision*, pages 32–39. IEEE, 2009.
- Xuanhan Wang, Lianli Gao, Jingkuan Song, and Hengtao Shen. Beyond frame-level cnn : saliency-aware 3-d cnn with lstm for video action recognition. *IEEE Signal Processing Letters*, 24(4) :510–514, 2016.
- Xuanhan Wang, Lianli Gao, Peng Wang, Xiaoshuai Sun, and Xianglong Liu. Two-stream 3-d convnet fusion for action recognition in videos with arbitrary size and length. *IEEE Transactions on Multimedia*, 20(3) :634–644, 2017.
- Li-Yi Wei and Marc Levoy. Fast texture synthesis using tree-structured vector quantization. In *Proceedings of the 27th annual conference on Computer graphics and interactive techniques*, pages 479–488, 2000.
- Joan S Weszka, Charles R Dyer, and Azriel Rosenfeld. A comparative study of texture measures for terrain classification. *IEEE transactions on Systems, Man, and Cybernetics*, (4) :269–285, 1976.
- Lior Wolf, Tal Hassner, and Yaniv Taigman. Descriptor based methods in the wild. In *Workshop on faces in 'real-life' images : Detection, alignment, and recognition*, 2008.

- Lior Wolf, Tal Hassner, and Yaniv Taigman. Effective unconstrained face recognition by combining multiple descriptors and learned background statistics. *IEEE transactions on pattern analysis and machine intelligence*, 33(10) :1978–1990, 2010.
- Gui-Song Xia, Jingwen Hu, Fan Hu, Baoguang Shi, Xiang Bai, Yanfei Zhong, Liangpei Zhang, and Xiaoqiang Lu. Aid : A benchmark data set for performance evaluation of aerial scene classification. *IEEE Transactions on Geoscience and Remote Sensing*, 55(7) :3965–3981, 2017.
- Yang Xiao, Zhiguo Cao, Li Wang, and Tao Li. Local phase quantization plus : A principled method for embedding local phase quantization into fisher vector for blurred image recognition. *Information Sciences*, 420 :77–95, 2017.
- Xiaochun Xu, Yibing Li, and QM Jonathan Wu. A completed local shrinkage pattern for texture classification. *Applied Soft Computing*, 97 :106830, 2020.
- Yong Xu, Hui Ji, and Cornelia Fermuller. A projective invariant for textures. In *2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR'06)*, volume 2, pages 1932–1939. IEEE, 2006.
- Peng Yang and Guowei Yang. Feature extraction using dual-tree complex wavelet transform and gray level co-occurrence matrix. *Neurocomputing*, 197 :212–220, 2016.
- Rui Yang, Xin Xu, Zhaozhuo Xu, Hao Dong, Rong Gui, and Fangling Pu. Dynamic fractal texture analysis for polsar land cover classification. *IEEE Transactions on Geoscience and Remote Sensing*, 57(8) :5991–6002, 2019.
- Baochang Zhang, Yongsheng Gao, Sanqiang Zhao, and Jianzhuang Liu. Local derivative pattern versus local binary pattern : face recognition with high-order local pattern descriptor. *IEEE transactions on image processing*, 19(2) :533–544, 2009.
- Jianguo Zhang and Tieniu Tan. Affine invariant texture analysis based on structural properties. In *Proceedings of the Fifth Asian Conference on Computer Vision (ACCV 2002)*, pages 216–221, 2002a.
- Jianguo Zhang and Tieniu Tan. Brief review of invariant texture analysis methods. *Pattern recognition*, 35(3) :735–747, 2002b.

Lun Zhang, Rufeng Chu, Shiming Xiang, Shengcai Liao, and Stan Z Li. Face detection based on multi-block lbp representation. In *International conference on biometrics*, pages 11–18. Springer, 2007.

Yang Zhao, Wei Jia, Rong-Xiang Hu, and Hai Min. Completed robust local binary pattern for texture classification. *Neurocomputing*, 106 :68–76, 2013.

Gang Zheng, Xiaofeng Li, Lizhang Zhou, Jingsong Yang, Lin Ren, Peng Chen, Huaguo Zhang, and Xiulin Lou. Development of a gray-level co-occurrence matrix-based texture orientation estimation method and its application in sea surface wind direction retrieval from sar imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 56(9) :5244–5260, 2018.

Résumé

La texture est la caractéristique de base qui apparaît dans chaque surface naturelle. Étant donné que l'analyse et la classification des textures sont importantes dans de nombreuses applications de vision par ordinateur, de nombreuses recherches ont été consacrées au développement de descripteurs de texture efficaces. LBP et leurs dérivés sont des descriptions de texture simples mais efficaces. Cependant, comme il n'utilise que des informations de signe dans la région locale, le LBP est inefficace pour capturer les caractéristiques discriminatoires. La principale contribution de cette thèse est l'introduction de nouvelles variantes de LBP qui nous permettent de surmonter ses limitations initiales et d'obtenir plus de relations entre les voisins, les pixels centraux et les voisins avec les pixels centraux. La première extension nommée «homogeneous LBP» (HLBP). Elle est générée en utilisant le critère d'homogénéité. Une autre extension est proposée, nommée «homogenous rotated LBP» (HRLBP), qui vise à améliorer le côté invariant de rotation de HLBP en utilisant une variante robuste de LBP appelée rotated LBP. La troisième variante de LBP est destinée à la caractérisation de la texture dans le cadre de la classification par télédétection et est connue sous le nom de «completed HLBP» (CHLBP). Les deux dernières variantes proposées de LBP sont connues respectivement sous le nom de «circular parts LBP» (CPLBP) et «corner rhombus shape LBP» (CRSLBP). CPLBP vise à améliorer LBP en étendant la zone de voisinage d'un à une région de voisins à l'aide de coordonnées polaires. Tandis que l'approche CRSLBP vise à traiter non seulement la relation entre les voisins et le centre des pixels, mais également la relation entre le centre et le voisin des pixels centraux du voisinage. Diverses expériences approfondies ont été réalisées qui ont démontré l'efficacité et la robustesse de notre descripteur par rapport à l'état de l'art disponible.

Mots-clefs : extraction des caractéristiques, local binary pattern (LBP), classification de la texture, la télédétection.

Abstract

Texture is the basic characteristic that appears on every natural surface. Since texture analysis and classification are important in many computer vision applications, much research has been devoted to the development of effective texture descriptors. LBP and their derivatives are simple but effective texture descriptions. However, since it only uses sign information in the local region, the LBP is inefficient in capturing discriminatory features. The main contribution of this thesis is the introduction of new variants of LBP that allow us to overcome its initial limitations and to obtain more relations between neighbors, central pixels, and neighbors with central pixels. The first extension is named "homogeneous LBP" (HLBP). It is generated using the homogeneity criterion. Another extension is proposed, named "homogenous rotated LBP" (HRLBP), which aims to improve the rotation invariant side of HLBP by using a robust variant of LBP called rotated LBP. The third variant of LBP is intended for characterization of texture in the context of classification by remote sensing and is known as "completed HLBP" (CHLBP). The last two proposed variants of LBP are known respectively as "circular parts LBP" (CPLBP) and "corner rhombus shape LBP" (CRSLBP). CPLBP aims to improve LBP by extending the neighborhood area from one to a region of neighbors using polar coordinates, whereas the CRSLBP approach aims to address not only the relationship between the neighbors and the center of the pixels, but also the relationship between the center and the neighbors of the central pixels of the neighborhood. Various in-depth experiments have been performed which demonstrate the efficiency and robustness of our descriptor compared to the available state of the art.

Key Words: feature extraction, local binary pattern (LBP), texture classification, remote sensing.

