



République Algérienne Démocratique et Populaire



Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université M'Hamed Bougara de Boumerdes

Faculté de technologie

Département Génie Electrique

# Mémoire de fin d'études en Réseaux et Télécommunication

*Spécialité : Réseaux et Télécommunication*

## Thème

---

Suppression des échos du sol sur des images  
météorologique

---

Réalisé par

- ADJAOUD Redouane
- BENLALAM Samy

Soutenu le : 13/07/2024

Devant le jury composé de :

Mme Mahdi.I MCA : Présidente  
Mme Belaoura.W MCB : Examinatrice  
Mme Hedir.M MCB : Promotrice

2023/2024

# *Remerciements*

Tout d'abord, nous souhaitons exprimer notre profonde gratitude envers Dieu, le Tout-Puissant et Miséricordieux, qui nous a accordé la force et la patience nécessaires au cours de ces longues années d'études, ainsi que le courage d'accomplir ce modeste travail.

En second lieu, nous tenons à remercier chaleureusement notre encadrante, Mme M.Hedir, pour sa confiance malgré notre connaissance initialement limitée en programmation et en traitement d'image. Nous vous sommes reconnaissants de nous avoir guidés, encouragés et conseillés tout au long de ce projet, tant sur le plan scientifique que sur le plan humain. Votre disponibilité inégalée, votre gentillesse et votre patience à notre égard ont été d'une valeur inestimable.

Nous souhaitons également exprimer nos vifs remerciements aux membres du jury pour l'intérêt qu'ils ont porté à notre recherche en acceptant d'examiner notre travail et en nous enrichissant de leurs précieuses propositions.

Enfin, nous tenons à remercier toutes les personnes qui ont contribué de près ou de loin à la réalisation de ce travail. Votre soutien et votre collaboration ont été essentiels, et nous vous en sommes sincèrement reconnaissants.

# *Dédicaces*

A la femme de ma vie , mon premier amour , celle qui m'a toujours soutenu depuis mes premiers pats , ma **MAMAN** chérie.

A mon meilleur ami , mon guide , mon exemple et mon model , mon **PAPA**.

A mes grands frères **ADLANE** et **ISLEM** et à ma **SOEUR**. et dédicace a toute ma famille

Dédicace à **Anass** , **Anis** , **Bachir**

Dédicace à une personne chère, **Sabrine**

Enfin dédicace à tout mes camarades .

*Redouane.*

# *Dédicaces*

Il est difficile de trouver les mots justes pour exprimer toute la gratitude et l'amour que je ressens envers vous. Vous avez été mes piliers, mes guides et mes sources d'inspiration tout au long de ma vie. Votre soutien inconditionnel et votre présence constante m'ont donné la force et la confiance nécessaires pour atteindre mes rêves.

Maman, tu es ma source infinie de tendresse, de réconfort et de sagesse. Tu as toujours été là pour moi, m'encourageant à poursuivre mes passions et m'apprenant la valeur de l'empathie et de l'amour inconditionnel. Tes sacrifices et ton dévouement sans limites sont une source d'inspiration pour moi chaque jour.

Papa, tu es mon modèle de force, de persévérance et de détermination. Tu m'as montré l'importance du travail acharné, de la discipline et de l'intégrité. Ta présence bienveillante et ton soutien constant ont été mes repères, me guidant sur le chemin de la réussite.

À mes frères Rafik, Riad et Imad, Cette dédicace vous est offerte en reconnaissance de tout ce que vous avez fait pour moi. Votre amour, vos encouragements et votre soutien indéfectibles sont les plus beaux cadeaux que la vie m'a offerts. Je suis profondément reconnaissant de vous avoir dans ma vie et je vous chéris au-delà des mots Chacun de vous a apporté sa propre lumière à ma vie, enrichissant mon expérience et me rappelant la valeur des liens familiaux. Aux personnes qui m'ont toujours aidé et encouragé, qui étaient toujours à mes côtés et qui m'ont accompagné dans mon chemin . Mes chers amis, les moments durs, tristes ou heureux partagés, vos encouragements ont été très précieux et resteront à jamais gravés dans mon cœur.

Avec tout mon amour et ma reconnaissance éternelle.

*Samy.*

# TABLE DES MATIÈRES

<b>Table des matières</b>	<b>1</b>
<b>Table des figures</b>	<b>4</b>
<b>Liste des tableaux</b>	<b>6</b>
<b>Liste des abréviations</b>	<b>7</b>
<b>Introduction générale</b>	<b>9</b>
<b>1 Généralités sur les radars météorologique</b>	<b>12</b>
1.1 Les instruments de mesure . . . . .	13
1.1.1 Instrument de mesure de pluie au sol . . . . .	13
1.1.2 Instrument de mesure par télédétection . . . . .	14
1.2 Observation météorologique par satellite . . . . .	16
1.3 Type de télédétections . . . . .	16
1.3.1 Télédétection Passive . . . . .	16
1.3.2 Télédétection Active . . . . .	17
1.4 Différents orbites satellitaires . . . . .	17
1.4.1 Satellites géostationnaires . . . . .	17
1.4.2 Les satellites défilants (Polaire) . . . . .	18

1.5	Radar météorologique . . . . .	18
1.5.1	Principe de fonctionnement du radar météorologique . . . . .	18
1.5.2	Composants du radar . . . . .	18
1.5.3	Les Bandes d'émission . . . . .	19
1.5.4	Equation radar . . . . .	20
1.6	Formation des précipitations . . . . .	21
1.6.1	Effet Bergeron . . . . .	21
1.6.2	La coalescence . . . . .	22
1.7	Application . . . . .	23
1.8	Differents types d'échos radar . . . . .	23
1.9	Techniques d'élimination des échos du sol . . . . .	25
1.9.1	Méthode de masquage . . . . .	25
1.9.2	Méthodes statistiques . . . . .	25
1.10	Conclusion . . . . .	26
<b>2</b>	<b>Descripteurs de texture et Classification avec SVM</b>	<b>27</b>
2.1	Local Binary Pattern ( LBP ) . . . . .	28
2.1.1	Définition . . . . .	28
2.1.2	LBP basique . . . . .	28
2.1.3	LBP Multi-échelle . . . . .	29
2.1.4	LBP ( P,R ) . . . . .	30
2.1.5	Notions d'uniformité . . . . .	30
2.1.6	LBP invariant par rotation . . . . .	32
2.2	La Variance . . . . .	34
2.3	Completed Local Binary Pattern ( C-LBP ) . . . . .	35
2.4	Centre Symétrique de la configuration binaire locale (CS-LBP) . . . . .	36
2.4.1	Le Descripteur à base de Loi de Weber (Weber's Law Descriptor) . . . . .	38
2.5	La Classification . . . . .	41
2.5.1	La Classification Supervisée . . . . .	41
2.5.2	La Classification Non Supervisée . . . . .	41
2.6	Support Vecteurs Machine ( SVM ) . . . . .	42
2.6.1	Définition . . . . .	42
2.6.2	Types de SVM . . . . .	43

2.6.3	SVM linéaire . . . . .	43
2.6.4	SVM non linéaire . . . . .	45
2.6.5	RBF (Radial Basis Function) . . . . .	47
2.7	Conclusion . . . . .	48
<b>3</b>	<b>Méthodologie et résultats</b>	<b>49</b>
3.1	Introduction . . . . .	50
3.2	Base de données . . . . .	50
3.3	Critère d'évaluation . . . . .	51
3.4	Environnement d'application . . . . .	53
3.5	Structure d'un système de classification . . . . .	56
3.6	Structure du système de reconnaissance des échos radar . . . . .	58
3.7	Résultats et discussion . . . . .	62
3.8	Conclusion . . . . .	67
	<b>Conclusion générale</b>	<b>68</b>
	<b>Annexe 1</b>	<b>74</b>
.1	Langages fréquemment utilisée . . . . .	74
	<b>Annexe 2</b>	<b>76</b>

# TABLE DES FIGURES

1.1	Le réseau mondial des satellites météorologiques . . . . .	16
1.2	Deux mode de Télédétection . . . . .	17
1.3	Principe d'acquisition des images météosat . . . . .	17
1.4	Exemple du principe de fonctionnement d'un radar météorologique . . . . .	18
1.5	Exemple des composants d'un radar . . . . .	19
1.6	Principe de l'effet Bergeron . . . . .	22
1.7	Principe de la coalescence . . . . .	22
2.1	Illustration de calcul d'un LBP de base (8 voisins) . . . . .	29
2.2	Exemples de voisinages avec différentes valeurs de (P, R) . . . . .	30
2.3	Construction et uniformité d'un motif LBP. (a) le motif construit ici est non-uniforme. (b) et (c) Exemples de motifs respectivement uniformes et non-uniformes . . . . .	31
2.4	: Exemple d'application de l'opérateur $LBP_{P,R}^{u2}$ pour 3 échelles différentes.	32
2.5	Liste des 36 uniques motifs binaires locaux invariant en rotation possibles pour $LBP_{P,R}^{ri}$ . . . . .	33
2.6	:(a) un voisinage de 3x3; (b) la différence locale; (c) le signe (d) l'amplitude	35
2.7	CS-LBP caractéristique d'un quartier de 8 pixels . . . . .	37



2.8 Exemple de calcul du gradient d'orientation et la différence d'excitation pour une image . . . . .	39
2.9 Exemple de Support Vecteur Machin . . . . .	42
2.10 Optimisation de la séparation des classes par la recherche d'un hyperplan avec une marge maximale . . . . .	43
2.11 Le cas des données linéairement séparables . . . . .	44
2.12 Exemple d'une mauvaise classification. Les exemples x1 et x2 sont des exemples mal classés . . . . .	45
2.13 Représentation d'une possibilité de séparation avec un passage vers un espace de plus grande dimension ((a) étant l'espace d'entrée, (b)étant le nouvel espace) . . . . .	46
2.14 Présentation schématique d'un réseau RBF . . . . .	47
3.1 Image radar dans le cas séparable d'une dans la région de Bordeaux . . . .	50
3.2 Structure générale d'un système de classification . . . . .	56
3.3 image des deux sous ensembles séparée, l'image A contient les échos de précipitations, et l'image B les echos de sol . . . . .	57
3.4 Structure du système de filtrage à base des descripteurs proposés . . . . .	59
3.5 Organigramme du calcul des paramètres texturaux . . . . .	60
3.6 Image brut (A) et Images filtrées par LBP (B), CLBP(C), WLD(D) et (E) par LBP-CLBP . . . . .	65
3.7 Image brut (A) et Images filtrées par LBP (B), CLBP(C), WLD(D) et (E) par LBP-CLBP . . . . .	66

# LISTE DES TABLEAUX

1.1	Les gammes d'émission . . . . .	19
2.1	Exemple de voisinage 3x3 du pixel xc . . . . .	39
2.2	Exemples de noyaux . . . . .	47
3.1	Caractéristiques technique du radar de Bordeaux . . . . .	51
3.2	table de contingence . . . . .	51
3.4	Nombre de pixel pour la phase d'apprentissage et de test . . . . .	59
3.5	Paramètres des modelés obtenus avec l'apprentissage . . . . .	62
3.6	paramètres statiques obtenus après le test . . . . .	64

# LISTE DES ABRÉVIATIONS

- r : La distance sépare des gouttes
- c : Rétrodiffusion par les gouttes de pluie
- t : intervalle de temps qui sépare les instants d'émission et de réception de signal radar
- P : Puissance reçue par le radar
- $\gamma$  : Longueur d'onde d'émission
- $\eta$  : Réflectivité radar
- La : Facteur caractérisant l'atténuation de l'intensité du rayonnement dans l'atmosphère
- Lr : Affaiblissement causé par la bande passante du récepteur du radar
- A : Constante du radar
- V : Vocale de résolution
- PPI : Indicateur de plan de position
- RHI : Indicateur de hauteur de portée
- HTI : Indicateur de hauteur temporelle
- LBP : Motif binaire local
- CLBP : Motif binaire local complet
- CLBP-S : Dérivé du vecteur signe
- CLBP-M : Calculé à partir du vecteur d'amplitude
- CLBP-C : Valeur niveau de gris pixel central
- WLD : Descripteur à base de loi de weber

CSLBP : Motif binaire local centre symétrique

LBP-CLBP : Descripteur Local Binary Pattern + Motif binaire local complet

LBP-WLD : Descripteur Local Binary Pattern + Descripteur a base de loi de weber

LBP-CSLBP : Descripteur Local Binary + Motif binaire local centre symétrique

CLBP-WLD : Motif binaire local complet + Descripteur a base de loi de weber

CLBP-CSLBP : Motif binaire local complet + Motif binaire local centre symétrique

$\theta$  : Gradient d'orientation

CLBP\* : Motif binaire local complet code

SVM : Machine a vecteur de support

P : L'ordre du polinome

$\gamma$  : Parametre du noyau

$\eta$  : Borne supérieure de l'erreur d'apprentissage et bone inferieur du nombre de vecteur de support

RBF : Radial Basis Fonction

POD : Probabilité de bonne détection

FAR : Ratio de fausses alarmes

SR : Suces Ratio

CSI : Indice de réussite

CIA : Pourcentage de détection correcte

# INTRODUCTION GÉNÉRALE

La complexité de la structure de l'atmosphère et les différents échanges énergétiques qui s'y produisent font de l'atmosphère un domaine de recherche actuel pour la communauté scientifique, malgré les avancées technologiques. L'émergence de la télédétection a introduit une nouvelle technologie appelée radar, qui est une source précieuse pour la détection, le suivi et la classification des précipitations (pluie, neige, grêle, etc.). Pendant la Seconde Guerre mondiale, les opérateurs de radars ont remarqué des échos parasites provenant des précipitations, ce qui a conduit au développement de techniques pour filtrer ces échos indésirables. Cependant, les scientifiques ont rapidement reconnu le potentiel du radar en météorologie, et après la guerre, les radars militaires ont été utilisés pour la détection des précipitations. Aujourd'hui, les radars météorologiques sont largement utilisés par les services météorologiques nationaux, les aéroports et les départements de recherche universitaire en météorologie. Les données brutes de ces radars peuvent être utilisées pour générer des images ou être traitées par des logiciels spécialisés pour prévoir leur déplacement à court terme. De plus, ces données peuvent être intégrées dans des modèles numériques de prévision du temps pour améliorer les prévisions et l'analyse de la situation météorologique.

Les images radar présentent différents types d'échos, notamment ceux provenant des précipitations et ceux causés par la surface terrestre. Les échos provenant de la surface terrestre, appelés "clutters" ou échos du sol, perturbent considérablement la détection des

échos météorologiques et sont considérés comme des échos parasites. Ils réduisent les performances du radar et entraînent de grandes erreurs dans l'estimation des précipitations et l'identification des orages. Les échos du sol observés autour du radar sont causés par des obstacles fixes tels que les reliefs, les constructions proches du radar, les pylônes, les routes, etc. Ces échos sont permanents et localisés à des coordonnées précises. D'autres échos, appelés "anomalies de propagation" (AP ou Anaprops), sont présents dans les images radar pour des gradients d'indice de réfraction  $\frac{dn}{dh} \leq 157 \cdot 10^{-6}/km$ . Ces échos sont transmis par guidage atmosphérique et sont très intenses. Leur intensité et leur position dépendent des conditions météorologiques. L'objectif principal de notre étude est de proposer des techniques de traitement pour éliminer les échos indésirables, tels que les clutters, afin d'obtenir une estimation fiable des précipitations.

L'analyse de la texture des images en télédétection a été largement utilisée dans divers domaines tels que la géologie, la cartographie, la climatologie et l'environnement. Dans le domaine radar, elle a été principalement appliquée en agriculture, dans la différenciation des glaciers, en océanographie et en météorologie. C'est pourquoi nous envisageons d'utiliser l'analyse de texture pour la classification des échos radar météorologiques et l'élimination des échos du sol.

La texture est décrite par les propriétés statistiques des intensités et des positions des pixels. Des méthodes telles que les matrices de cooccurrence, les histogrammes de somme et de différence, ainsi que l'opérateur LBP (Local Binary Pattern), ont été utilisées pour mesurer la texture. Ces descripteurs texturaux ont été appliqués avec succès dans divers domaines, y compris la reconnaissance faciale et la classification de scènes. Dans le cadre de la météorologie, il est crucial de trouver une méthode efficace et automatique pour séparer les échos du sol des échos de précipitation. Dans notre mémoire, nous nous intéressons à l'élimination des échos indésirables en utilisant des descripteurs texturaux tels que le LBP, le CLBP (Completed Local Binary Pattern), CSLBP, WLD et d'autres, associés à des classificateurs de type SVM (Support Vector Machine).

Ce document est organisé comme suit :

Le chapitre I présente quelques généralités et rappels du fonctionnement des radars météorologiques ainsi que les différents types d'échos qu'ils peuvent détecter.

Le chapitre II expose les méthodes utilisées pour classer les échos radar, en mettant l'accent sur le choix des descripteurs les plus adaptés à notre application. De plus, la

théorie des Machines à Vecteurs de Support sera abordée.

Le chapitre III présente les différentes expériences que nous avons menées sur des données radar collectées à Bordeaux pour valider notre approche. Nous examinons également la performance et la puissance de la méthode à l'aide de plusieurs paramètres statistiques.

En conclusion, nous résumons les résultats obtenus et proposons des perspectives pour de futures recherches.

CHAPITRE

1

GÉNÉRALITÉS SUR LES RADARS  
MÉTÉOROLOGIQUE



## Introduction

La surveillance de l'atmosphère dans le but de détecter les précipitations et de les suivre est un domaine de recherche actuel. La prédiction des schémas d'échos et l'identification du type de précipitations (pluie, grêle, neige, etc.) sont devenues des préoccupations mondiales, étant donné la valeur de l'eau dans notre vie quotidienne et les catastrophes naturelles qui frappent le monde. La communauté scientifique dispose de deux moyens pour mener ces études : les stations au sol et les techniques de télédétection telles que le lidar, le radar météorologique et les satellites météorologiques. Dans ce chapitre, nous présentons les instruments de mesure au sol et à distance, ainsi que le principe de fonctionnement du radar météorologique en tant que source précieuse d'informations. Nous abordons également les différents types d'échos capturés par le radar météorologique.

### 1.1 Les instruments de mesure

On a classé les méthodes de mesures en deux catégories : la mesure directe et celle-ci consiste à regrouper l'eau de pluie dans un même endroit et mesurer la quantité recueillie pendant un intervalle de temps donné, la deuxième méthode de mesure appelée la mesure indirecte se base sur l'estimation des précipitations et sur la caractérisation des nuages en utilisant différents instruments de mesure que nous allons décrire

#### 1.1.1 Instrument de mesure de pluie au sol

Un instrument de mesure de pluie au sol est un outil utilisé pour mesurer la quantité de précipitations sur une zone donnée. Les instruments de mesure de pluie au sol sont souvent installés dans des endroits tels que les aéroports, les stations météorologiques et les terrains de recherche, Les instruments de mesure de pluie au sol sont importants pour la collecte de données météorologiques précises et la prévision des inondations. Ils peuvent également être utilisés pour étudier les modèles de précipitations et les changements climatiques.[1]

Il existe plusieurs types d'instruments de mesure de pluie au sol, chacun ayant ses propres caractéristiques et méthodes de mesure. Voici quelques exemples d'instruments de mesure de pluie au sol :

### **Pluviomètre standard**

Il s'agit d'un cylindre de mesure gradué qui recueille l'eau de pluie sur une surface plane. La hauteur d'eau recueillie dans le cylindre est ensuite mesurée et convertie en unités de mesure de pluie, généralement millimètres.[2]

### **Pluviomètre à augets**

Il s'agit d'un dispositif à deux ou plus augets basculants qui recueillent l'eau de pluie dans un récipient gradué. Chaque auget bascule lorsqu'il est rempli d'eau, et la quantité d'eau recueillie est mesurée par un capteur.[2]

### **Pluviomètre à bascule**

Il s'agit d'un dispositif à bascule unique qui recueille l'eau de pluie dans un récipient gradué. Le dispositif bascule lorsque le poids de l'eau recueillie dépasse un certain seuil, et la quantité d'eau recueillie est mesurée.[2]

### **Pluviographe**

Il s'agit d'un enregistreur automatique qui mesure la quantité de pluie en temps réel et enregistre les données pour une analyse ultérieure. Les pluviographes utilisent souvent des capteurs tels que des jauges de pression pour mesurer la hauteur de pluie.[3]

### **Jauge de tige flottante**

Il s'agit d'un dispositif qui utilise une tige flottante pour mesurer la hauteur de l'eau de pluie. La tige flottante est fixée à une tige graduée, et la hauteur de la pluie est mesurée en fonction de la position de la tige flottante.[4]

Ces instruments de mesure de pluie au sol sont utilisés pour collecter des données météorologiques précises sur les précipitations et sont importants pour la prévision des inondations et l'étude des modèles climatiques.

## **1.1.2 Instrument de mesure par télédétection**

La télédétection est l'ensemble des méthodes qui permettent de déterminer les propriétés des surfaces et de l'atmosphère terrestres à distance, en utilisant les rayonnements

qu'elles reflètent ou émettent dans différents domaines de longueurs d'onde

Le rayonnement se distingue par une onde électromagnétique qui se propage dans un milieu et interagit avec le spectre du rayonnement électromagnétique [5] Il existe plusieurs instruments de mesure de pluie par télédétection qui permettent de mesurer la pluie sans avoir à utiliser des instruments de mesure au sol. Voici quelques exemples d'instruments de mesure de pluie par télédétection :

### **Lidar**

Le Lidar (Light Detection and Ranging) est une technologie de télédétection qui utilise des lasers pour mesurer la distance entre le capteur et la surface de la Terre. Le Lidar peut être utilisé pour mesurer les précipitations en détectant les gouttes de pluie dans l'atmosphère. [6]

### **Radiomètre**

Les radiomètres peuvent mesurer les précipitations en mesurant la quantité de radiation électromagnétique réfléchiée par les gouttes de pluie. Les radiomètres peuvent être utilisés pour mesurer les précipitations à partir de la surface de la Terre ou depuis des avions.[5]

### **Radar météorologique**

Les radars météorologiques utilisent des ondes électromagnétiques pour détecter les précipitations et mesurer leur intensité. Les radars météorologiques peuvent couvrir de vastes zones et fournir des informations sur les précipitations en temps réel.[7]

### **Satellite météorologique**

Les satellites météorologiques peuvent observer les précipitations à partir de l'espace en utilisant des capteurs à bord des satellites. Les données recueillies par les satellites peuvent être utilisées pour fournir des images en temps réel des précipitations sur de vastes régions.[8]

Ces instruments de mesure de pluie par télédétection sont utilisés pour collecter des données sur les précipitations sur de vastes zones, .[9]

## 1.2 Observation météorologique par satellite

Un satellite météorologique est un satellite qui recueille des informations et données utiles à la prévision météorologique, il peut être géostationnaire c'est-à-dire en orbite dans le plan de l'équateur à 36 000 km d'altitude, ou défilant c'est-à-dire qu'il est placé à moins de 1000 km d'altitude et fait le tour de la terre en deux heures environ.[10]



FIGURE 1.1 – Le réseau mondial des satellites météorologiques

## 1.3 Type de télédétections

La télédétection peut être subdivisée en deux grandes classes comme le montre la figure 1.2

### 1.3.1 Télédétection Passive

Lorsque le satellite reçoit des données, il capture à la fois le rayonnement solaire réfléchi par la surface terrestre et l'atmosphère dans le domaine visible et infrarouge proche. En outre, il enregistre également le rayonnement émis par la Terre dans le domaine de l'infrarouge lointain.[11]

### 1.3.2 Télédétection Active

Lorsque la source de rayonnement fait partie du satellite, ce rayonnement est émis vers un objet, puis le rayon réfléchi est capté par le satellite [12]




FIGURE 1.2 – Deux mode de Télédétection

## 1.4 Différents orbites satellitaires

### 1.4.1 Satellites géostationnaires

L'orbite des satellites géostationnaires est sur le plan équatorial de la terre, ils tournent à la même vitesse angulaire que la terre, ainsi il sont fixe et observent toujours le même disque terrestre, cependant il fournissent de vastes plan de la surface terrestre et de l'atmosphère [13]




FIGURE 1.3 – Principe d'acquisition des images météosat

### 1.4.2 Les satellites défilants (Polaire)

Se sont des satellites en basse altitude, quasi polaire et héliosynchrone ils suivent le déplacement apparent du soleil autour de la terre, ce qui permet d'avoir des images à la même heure local de chaque région [8]

## 1.5 Radar météorologique

Le radar météorologique est spécialement conçu pour détecter les précipitations en météorologie, ainsi pour estimer leur trajectoire et leur nature (pluie, neige, grêle), grâce à sa structure 3D on peut déduire les mouvements des précipitations dans les nuages, et aussi la direction et la vitesse des vents si on utilise comme marqueurs les précipitations. [14]

### 1.5.1 Principe de fonctionnement du radar météorologique




FIGURE 1.4 – Exemple du principe de fonctionnement d'un radar météorologique

Le mécanisme du radar est fondé sur la réflexion des ondes électromagnétiques par des objets, ou cibles, il permet de mesurer la puissance rétrodiffusée par un ensemble de goutte de pluie. Le radar déduit l'intensité de précipitation grâce à la conversion réflectivité – intensité (la loi Z-R).[15]

### 1.5.2 Composants du radar




FIGURE 1.5 – Exemple des composants d’un radar

Le radar est composé de :

- 1 - Un émetteur qui génère une onde radio.
- 2 - Un guide d’onde qui amène l’onde vers l’antenne.
- 3 - Un duplexeur qui dirige l’onde vers l’antenne lors de l’émission, et le signal de l’antenne vers le récepteur quand il y’a réception.
- 4 - Une antenne qui diffuse l’onde électromagnétique.
- 5 - Un récepteur qui reçoit le signal.
- 6 - Un système de traitement de signal, qui traite le bruit pour extraire le signal utile.

[16]

### 1.5.3 Les Bandes d’émission

Pour que le radar soit efficace il existe trois types de fréquences, on parle de bande de fréquences [17] :

Bandes	S	C	X
Fréquences f	3 GHz	6 GHz	10.6 GHz
Longueur d’onde λ	3 GHz	6 GHz	10.6 GHz

TABLE 1.1 – Les gammes d’émission

Petit rappel :

$$\lambda = \frac{c}{f} \tag{1.1}$$

λ : longueur d’onde en m

$c$  : vitesse de propagation de la lumière en m

$f$  : fréquence en Hertz ( $s^{-1}$ )

### La bande X ( $\lambda - 2.5$ cm)

Utilisées sur les radars de nouvelle générations adapté aux mesures en montagnes, c'est un radar à faible cout, possède une portée d'environ 60km et le signal subit une forte atténuation si un nuage se situe derrière un autre, il ne sera pas détecté

### La bande C ( $\lambda - 5$ cm )

Adaptées pour les plaines pour détectés les précipitations stratiformes elle offre un bon compromis entre les deux bandes 2.5 et 10cm ainsi qu'un meilleur rapport qualité prix.

### La bande S( $\lambda - 10$ cm)

Adaptées sous les tropiques et la méditerranée elle permet la détection des averses, mais dispose de problème telle qu'un écho faible, un bruit important par rapport au signal rétrodiffusée,

## 1.5.4 Equation radar

L'équation du radar relie l'intensité moyenne du signal reçu à une puissance d'émission spécifique, en tenant compte des caractéristiques du volume diffusant situé à une distance  $r$ , ainsi que des conditions météorologiques. Cette équation est fonction des paramètres du radar tels que la puissance totale émise ( $P_T$ ), le gain maximum de l'antenne ( $G_M$ ), ainsi que les angles d'ouverture à 3 dB en site ( $\Theta_0$ ) et en azimut ( $\Phi_0$ ). Il a été démontré que la forme générale de l'équation du radar est la suivante :

$$\frac{P}{P_T} = \frac{G_M^2 \lambda^2 \Theta_0 \Phi_0 c \tau L_a^2 L_r}{1024 \pi^2 \ln 2} \cdot \frac{\eta}{r^2} \quad (1.2)$$

Avec :

$P$  : Puissance reçue par le radar

$\lambda$  : Longueur d'onde d'émission

$\eta$  : Réflectivité radar

$L_a$  : Facteur caractérisant l'atténuation de l'intensité du rayonnement dans l'atmosphère



$L_r$  : Affaiblissement causé par la bande passante du récepteur du radar.

En pratique, on peut ramener cette équation à une forme plus simple. Soit :

$$P = AL_a^2 \cdot \frac{\eta}{r^2} \quad (1.3)$$

Où A qui est la constante du radar considéré, est obtenue par la mesure des caractéristiques de ce dernier.

Pour une cible ayant un volume de résolution V, constituée d'un grand nombre d'éléments (i) avec des sections efficaces de rétrodiffusion  $\sigma_i$ , nous définissons la réflectivité radar comme la section efficace moyenne de la cible (par unité de volume). Cette réflectivité radar peut être exprimée par l'équation suivante :

$$\eta = \sum_{i=1}^n \frac{\sigma_i}{V} \quad (1.4)$$

$\eta$  est en  $m^2 m^{-3}$  mais couramment exprimée en  $cm^{-1}$ .

## 1.6 Formation des précipitations

Les précipitations sont les gouttes d'eau ou les cristaux de glacés, qui après s'être formés sous condensation et agglomération et sous leurs propres poids, deviennent trop lourd pour se maintenir dans les airs et tombent au sol, ils peuvent s'évaporer avant d'atteindre le sol.

Les nuages précipitants contiennent des particules liquide et solides en suspensions qui ne dépassent pas 50um, pour être emportées par la gravité et tomber, ils doivent faire au minimum 100um. Les particules grossissent sous l'effet Bergeron et la coalescence.[18]

### 1.6.1 Effet Bergeron

Les particules liquides en surfusion ont tendance à s'évaporer puis se condenser solidement autour de la glace et amène la taille du cristal a 100um. [19]



FIGURE 1.6 – Principe de l’effet Bergeron

### 1.6.2 La coalescence

C’est la formation de cristaux de glace plus gros lors de la collision de deux cristaux sous l’effet d’accrétion de l’eau surfondue.[20]

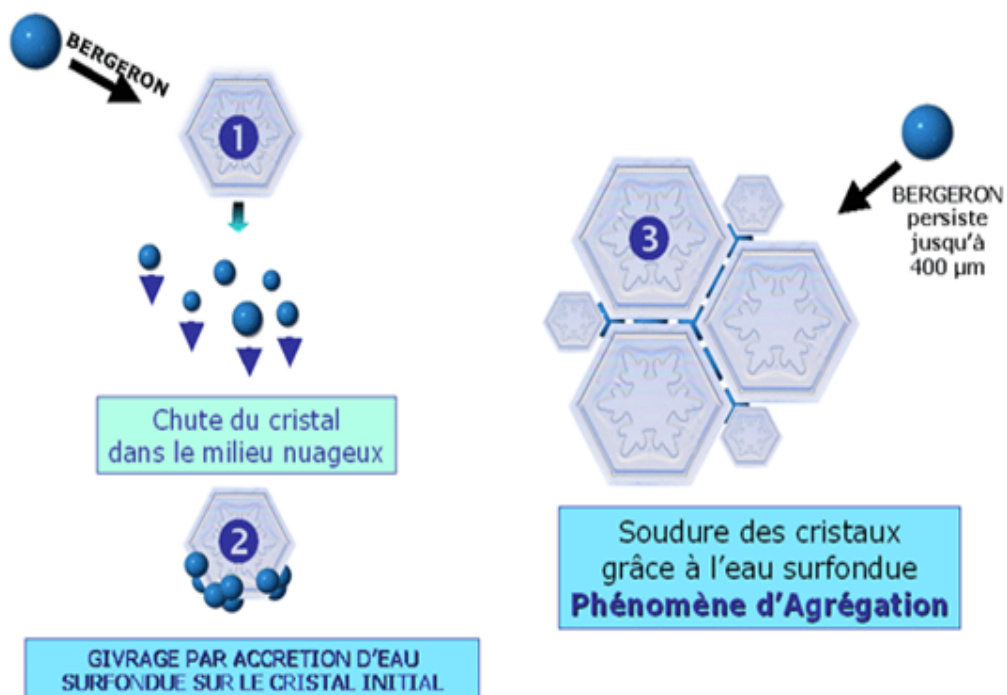


FIGURE 1.7 – Principe de la coalescence

## 1.7 Application

Les données météorologiques sont utilisées dans plusieurs applications, notamment [21] :

1. **Prévision météorologique** : Les données radars météorologiques sont utilisées pour prévoir les conditions météorologiques futures, telles que les précipitations, les orages et les tempêtes. Les modèles météorologiques utilisent ces données pour prédire l'évolution de la météo à court et à long terme.
2. **Gestion des ressources en eau** : Les données radars météorologiques sont utilisées pour surveiller les niveaux de précipitations dans les bassins versants et les rivières. Ces données peuvent aider à la gestion des ressources en eau, notamment pour la prévision des inondations et la gestion des réservoirs d'eau.
3. **Aviation** : Les données radars météorologiques sont utilisées pour fournir des informations sur les conditions météorologiques aux pilotes. Ces données peuvent aider les pilotes à éviter les zones de précipitations intenses, les turbulences et les conditions météorologiques dangereuses.
4. **Étude des changements climatiques** : Les données radars météorologiques sont utilisées pour étudier les modèles de précipitations et les tendances météorologiques au fil du temps. Ces données peuvent aider à comprendre les changements climatiques et leur impact sur l'environnement.

## 1.8 Différents types d'échos radar

Les ondes émises par un radar se réfléchissent sur toutes les surfaces qu'elles illuminent. Cela signifie que la rétrodiffusion radar est contaminée par divers échos indésirables pour l'utilisateur. Dans le cas d'un radar de contrôle aérien, les échos provenant des avions doivent être identifiés, tandis que tout le reste est considéré comme des échos indésirables. Pour un radar météorologique, les précipitations sont d'intérêt principal, tandis que le reste est considéré comme du "fouillis".

Le "fouillis" est constitué d'échos parasites et de bruit de fond. Les échos parasites comprennent les rétrodiffusions provenant du sol, de la mer, des bâtiments, ainsi que des cibles biologiques telles que les oiseaux et les insectes, et autres. On peut résumer les types

d'échos comme suit :[22]

### 1. Echos atmosphériques

Sont désignées comme les précipitations, que ce soit sous forme liquide (brume, pluie, averse) ou sous forme solide (neige, grésil, grêle), ainsi que les précipitations déposées ou occultes (rosée, gelée blanche, givre, etc.). Ces précipitations sont généralement provoquées par des changements de température ou de pression.[23]

### 2. Echos du sol

Les échos observés autour du radar sont des échos permanents situés à des positions fixes. Ils sont causés par la présence d'obstacles environnants tels que des collines, des bâtiments, des forêts et des parcs éoliens. Ces éléments créent des rétrodiffusions qui sont détectées par le radar, générant ainsi des échos constants à ces emplacements spécifiques.[24]

### 3. Echos mobiles

Ces échos sont engendrés par les mouvements des arbres, les variations d'une impulsion radar à l'autre provoquant la formation de vagues, ainsi que par la présence d'oiseaux et de chauves-souris, en particulier lors des périodes de migration où ils se déplacent en groupes comprenant des milliers d'individus.[25]

### 4. Anomalies de propagation

Sous certaines conditions atmosphériques, l'indice de réfraction de l'air se dévie de la normale, ce qui entraîne une trajectoire anormale du faisceau radar, soit vers le bas, soit vers le haut. Ce phénomène est connu sous le nom de propagation anormale. En raison de la déviation du faisceau radar, les échos de retour sont mal positionnés par rapport à leur emplacement attendu. La forme la plus courante de propagation anormale se produit lorsqu'il y a une inversion de température à basse altitude, ce qui fait que le faisceau atteint le sol, renvoyant ainsi des échos intenses au radar.[26]

## 1.9 Techniques d'élimination des échos du sol

Les échos provenant du sol posent de nombreux problèmes aux opérateurs de radar car ils introduisent des erreurs dans l'identification et l'estimation des précipitations. Diverses méthodes d'élimination des échos fixes sont proposées. Les techniques les plus couramment utilisées sont les suivantes [27][28] :

- Filtrage Doppler
- Filtrage en peigne
- Filtrage par polarisation
- Circuits MTI ( Moving Target Indicator )
- Filtrage par seuillage
- Méthode de masquage
- Méthodes statistiques

Parmi ces techniques on cite à titre d'exemple :

### 1.9.1 Méthode de masquage

La méthode utilisée consiste à créer une image (ou un masque) qui est utilisée pour détecter et masquer les échos fixes présents sur les images radar. Cette image est obtenue en déterminant les niveaux de réflectivité les plus probables pour chaque pixel, en se basant sur des images en temps clair. Le filtrage est effectué en comparant directement pixel par pixel l'image à traiter avec le masque. Si la couleur du pixel correspond à celle du pixel du masque, la couleur noire est assignée à ce pixel dans l'image filtrée. Sinon, la couleur du pixel est maintenue. Cette approche a été utilisée par l'Office National de Météorologie pour traiter les échos fixes du sol sur le site de Sétif (lorsque le radar était opérationnel) [29]

### 1.9.2 Méthodes statistiques

Les méthodes statistiques sont des techniques utilisées dans le traitement des signaux radar. Elles impliquent l'échantillonnage du signal reçu, qui comprend à la fois les échos de précipitations et les échos provenant du sol, et la comparaison des différents échantillons . Ainsi, il est possible d'éliminer les échos indésirables en calculant les différences entre les valeurs moyennes et les valeurs maximales des propriétés du signal radar, et en rejetant les

signaux pour lesquels cette différence est faible. Une autre approche consiste à analyser la texture des images. Cette méthode repose sur des probabilités conditionnelles, des probabilités composées, des corrélations entre plusieurs pixels ou l'utilisation de réseaux de neurones [30] [31][32][33]. Par exemple, il est possible d'appliquer un filtre qui élimine les pixels ayant une faible corrélation avec leur voisinage[34].

## 1.10 Conclusion

Dans ce chapitre, nous avons d'abord présenté les différentes catégories d'instruments de mesure météorologiques, en mettant l'accent sur le radar météorologique et son fonctionnement. Ensuite, nous avons examiné les techniques les plus fréquemment utilisées dans le traitement des échos parasites provenant de la surface terrestre.

CHAPITRE

2

DESCRIPTEURS DE TEXTURE ET  
CLASSIFICATION AVEC SVM

## Introduction

Ce chapitre est dédié à l'explication des systèmes d'élimination du clutter. Dans notre étude, nous avons choisi d'utiliser des descripteurs texturaux qui ont démontré de bonnes performances dans diverses applications. Parmi ces descripteurs, nous avons utilisé les motifs binaires locaux (Local Binary Pattern LBP) ainsi que d'autres descripteurs dérivés. Ensuite, nous allons rappeler les principes fondamentaux du classifieur Support Vector Machines (SVM), qui sera utilisé pour générer un modèle permettant d'éliminer automatiquement les échos indésirables.

## 2.1 Local Binary Pattern ( LBP )

### 2.1.1 Définition

Le Local Binary Pattern (LBP), ou Modèle Binaire Local en français, est un descripteur largement utilisé en vision par ordinateur pour mesurer le contraste local d'une image monospectrale et analyser les textures. Il a été mentionné pour la première fois par Harwood en 1993, mais c'est Timo Ojala qui l'a réellement popularisé en 1996. Le LBP a démontré d'excellentes performances dans de nombreuses études comparatives, tant en termes de vitesse que de discrimination des différentes textures. Essentiellement, le LBP est une caractéristique utilisée en vision par ordinateur pour résumer la structure spatiale locale d'une image. Il permet de reconnaître des textures spécifiques ou de détecter des objets dans des images numériques. Grâce à sa simplicité et à son efficacité, le LBP est largement utilisé. Il est également invariant aux changements d'échelle et de luminosité, ce qui le rend robuste face à différentes variations d'images. En conclusion, le LBP est un descripteur puissant pour l'analyse des textures et la détection d'objets en vision par ordinateur. Il offre de bonnes performances en termes de vitesse de traitement et de capacité à discriminer différentes textures, ce qui en fait un outil précieux dans de nombreuses applications impliquant des images numériques.[35]

### 2.1.2 LBP basique

Le LBP repose sur le calcul d'un code binaire qui décrit la texture locale d'une région. Ce calcul est réalisé en seuillant un voisinage autour du pixel central en fonction de son



niveau de gris. Chaque voisin prendra la valeur 1 si son niveau de gris est supérieur ou égal à celui du pixel central, sinon il prendra la valeur 0. Ensuite, cette matrice binaire est multipliée par les poids LBP et la somme de tous les éléments donne la valeur LBP du pixel central. Le résultat de ce processus est une image où les pixels ont une intensité comprise entre 0 et 255, tout comme dans une image 8 bits classique. Cela permet de représenter de manière compacte la texture locale de l'image .[36]

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

Code binaire : 11110001 LBP=128+64+32+16+1=241

FIGURE 2.1 – Illustration de calcul d'un LBP de base (8 voisins)

### 2.1.3 LBP Multi-échelle

Le concept du LBP multi-échelle repose sur le choix d'un voisinage pour calculer un code LBP, ce qui permet de traiter les textures à différentes échelles. Le voisinage d'un pixel central est défini par un cercle et est construit en utilisant deux paramètres : le nombre de voisins "P" situés sur le cercle et le rayon "R" qui représente la distance entre le pixel central et ses voisins

Pour une texture donnée, notée  $T = t(g_c, g_0, \dots, g_{p-1})$ , où  $g_c$  représente la valeur de niveau de gris du pixel central et  $g_p$ , avec  $p = 0, \dots, P-1$ , correspond aux niveaux de gris des P pixels régulièrement espacés sur le cercle de rayon R. Si les coordonnées du pixel central  $g_c$  sont (0,0), alors les coordonnées des pixels  $g_p$  sont calculées selon l'équation suivante :

$$\begin{cases} g_p(x, y) = t(g_c(x + R \cos(\frac{2\pi p}{P}))) \\ g_c(y + R \sin(\frac{2\pi p}{P})) \end{cases} \quad (2.1)$$

Ainsi, chaque pixel dans le voisinage du pixel central est représenté par sa valeur de niveau de gris, et ces valeurs sont utilisées pour construire le code LBP multi-échelle. Ce

descripteur peut être utilisé pour caractériser les motifs locaux à différentes échelles dans une texture donnée. [37]

### 2.1.4 LBP ( P,R )

Initialement, les codes LBP étaient conçus pour des régions de taille fixe de 3 x 3. Ces codes étaient limités aux petites régions et ne pouvaient capturer que des micro-textures locales. Afin de remédier à cette limitation, le concept de LBP (P, R) a été introduit, permettant l'utilisation de voisinages de différentes tailles. Dans le cas de LBP (P, R), un cercle de rayon R est choisi autour du pixel central.

Les valeurs des P points échantillonnés sur le bord de ce cercle sont comparées à la valeur du pixel central. Pour obtenir les valeurs des P points échantillonnés dans le voisinage pour chaque rayon R, une interpolation est nécessaire.

Ainsi, la notation (P, R) définit le voisinage composé de P points échantillonnés sur un rayon R autour d'un pixel donné. Cette extension du LBP permet de prendre en compte des voisinages de tailles différentes et d'élargir la portée des caractéristiques texturales capturées. [35]




FIGURE 2.2 – Exemples de voisinages avec différentes valeurs de (P, R)

### 2.1.5 Notions d'uniformité

L'opérateur  $LBP_{P,R}^{u2}$  est calculé comme suit dans le cas du  $LBP_{P,R}$ . Généralement, le  $LBP_{P,R}$  génère  $2^P$  valeurs différentes, et parmi ces  $2^P$  valeurs, un motif binaire est considéré comme un motif binaire uniforme s'il contient un maximum de deux transitions entre 0 et 1, ou vice versa. L'uniformité  $U(x)$ , mesurée par le nombre de transitions entre 1

et 0, contient  $(P - 1)P + 2$  motifs binaires, tandis que les autres motifs, lorsque  $U(x) > 2$ , sont considérés comme des motifs binaires non uniformes.[38]

Voici comment l'opérateur  $LBP_{P,R}^{u2}$  est calculé :

$$LBP_{P,R}^{u2}(x, y) = \begin{cases} I(LBP_{P,R}(x, y)), & \text{si } U(LBP_{P,R}) \leq 2 \\ (P - 1)P + 2, & \end{cases} \quad (2.2)$$

La notion de motif binaire uniforme dans la méthode LBP fait référence à un motif qui présente exactement 0 ou 2 transitions (01 ou 10) dans un parcours circulaire. Cela signifie qu'un motif binaire est considéré comme uniforme s'il a une structure régulière d'alternance entre 0 et 1 sans interruption. Par exemple, un motif comme 10000001 ou 00011000 est considéré comme uniforme, tandis que 00101010 n'est pas un motif uniforme. Voir la figure 2.3

La notion d'uniformité est essentielle dans la méthode LBP car elle permet de représenter les informations relatives aux primitives structurales telles que les arêtes, les coins et les contours. Les motifs binaires uniformes captent ces structures régulières et fournissent des indications sur les variations locales dans une image.

Il convient de noter que les motifs binaires non uniformes, qui contiennent plus de deux transitions, peuvent également fournir des informations pertinentes sur d'autres aspects de l'image, mais ils sont considérés comme distincts des motifs uniformes en raison de leur structure différente. [37]




FIGURE 2.3 – Construction et uniformité d'un motif LBP. (a) le motif construit ici est non-uniforme. (b) et (c) Exemples de motifs respectivement uniformes et non-uniformes

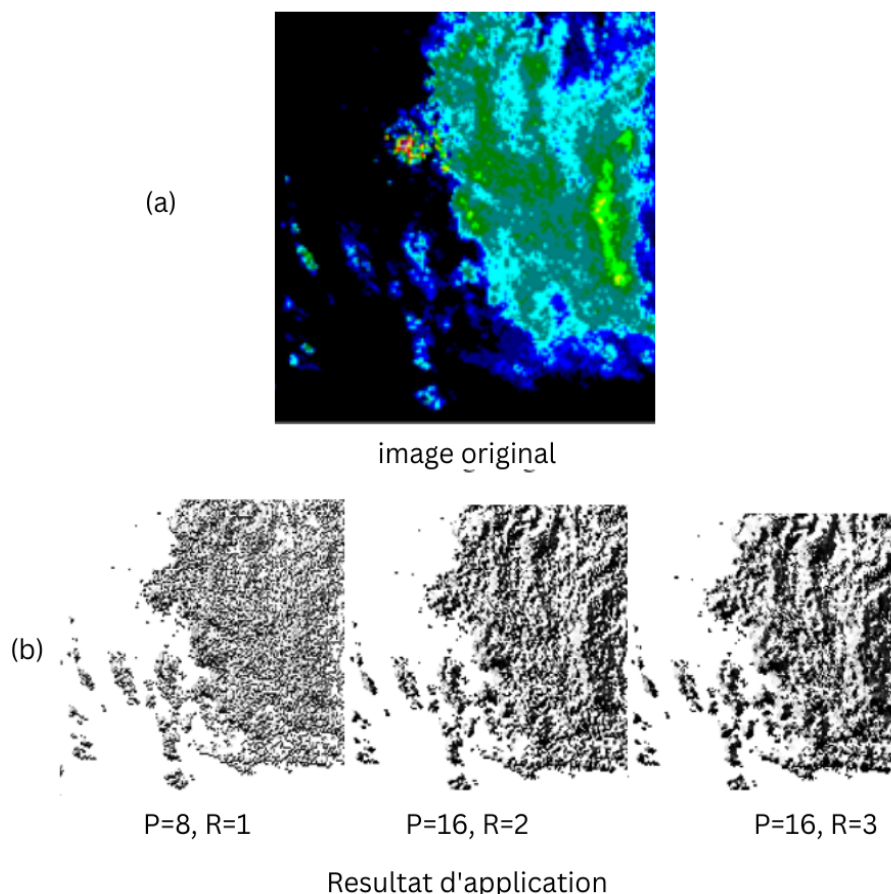


FIGURE 2.4 – : Exemple d'application de l'opérateur  $LBP_{P,R}^{u2}$  pour 3 échelles différentes.

Ojala (2002) a observé que seulement 58 des 256 motifs LBP sont uniformes, cependant, Ahonen et al. (2006) ont expérimentalement constaté que 90% des motifs rencontrés dans les images sont uniformes. Dans ce cas, la dimension de l'histogramme LBP peut être considérablement réduite en utilisant un histogramme de dimension 59. Les 58 premières catégories de l'histogramme représenteront le nombre d'occurrences des motifs uniformes individuels, tandis que la dernière catégorie représentera le nombre d'occurrences de tous les motifs non-uniformes. Ce regroupement permet de réduire la dimension du descripteur sans perdre trop d'information.[38] [35]

### 2.1.6 LBP invariant par rotation

La définition du motif binaire uniforme, qui repose sur la symétrie circulaire du voisinage, a conduit à la création d'un deuxième motif, appelé  $LBP_{P,R}^{ri}$ , qui est non seulement invariant par rapport aux transformations monotones de l'échelle des niveaux de gris, mais aussi invariant par rapport aux rotations de l'image. Pour chaque pixel  $(x, y)$ , le

calcul de ce motif est réalisé de la manière suivante :

$$LBP_{P,R}^{ri} = \min \{ROR(LBP_{P,R}(x, y), i) \mid i \in [0, P - 1]\} \quad (2.3)$$

Le terme  $ROR(a, i)$  représente le résultat obtenu après avoir effectué  $i$  décalages circulaires successifs vers la droite des bits du nombre  $a$ , codé sur  $P$  bits.

Le descripteur  $LBP_{P,R}^{ri}$  quantifie les statistiques d'occurrence de modèles individuels invariants en rotation qui correspondent à certaines micro-caractéristiques de l'image. La Figure 2.5 présente les 36 motifs binaires locaux uniques invariants en rotation possibles pour  $P = 8$ . Par exemple, le motif "0" permet de détecter les tâches claires, le motif "8" permet de détecter les tâches sombres et les surfaces monotones, le motif "3" permet de détecter les coins, et le motif "4" permet de détecter les contours.




FIGURE 2.5 – Liste des 36 uniques motifs binaires locaux invariant en rotation possibles pour  $LBP_{P,R}^{ri}$

Les points noirs et blancs dans la sortie sur 8 bits de l'opérateur ROR correspondent respectivement aux valeurs de bit 0 et 1.

Lorsque  $R = 1$ , l'opérateur " $LBP_{P,R}^{ri}$ " est équivalent à LBPROT proposé par Pietikäinen et al. en 2000. Cependant, il a été démontré que LBPROT ne donne pas de bonnes performances. La principale raison en est que l'occurrence des fréquences de certains des 36 motifs possibles varie considérablement, ce qui entraîne une instabilité.[39]

Pour résoudre ce problème, une mesure d'uniformité est effectuée sur les motifs afin de déterminer s'ils sont uniformes ou non. Si le nombre de transitions est supérieur à deux,

le motif est considéré comme non-uniforme. L'opérateur est appelé "LBP<sub>P,R</sub><sup>riu2</sup>" et est défini de la manière suivante :

$$\text{LBP}_{P,R}^{\text{riu2}} = \begin{cases} \sum_{p=0}^{P-1} u(g_p - g_c), & \text{si } U(\text{LBP}_{P,R}) \leq 2 \\ P + 1, & \end{cases} \quad (2.4)$$

autrement avec :

$$U(\text{LBP}_{P,R}) = |u(g_{p-1} - g_c) - u(g_0 - g_c)| + \sum_{p=1}^{P-1} |u(g_p - g_c) - u(g_{p-1} - g_c)| \quad (2.5)$$

## 2.2 La Variance

La variance est une mesure statistique qui quantifie la dispersion des valeurs d'un ensemble de données par rapport à leur moyenne. Elle permet de déterminer à quel point les données individuelles s'écartent de la valeur moyenne et fournit une indication sur la dispersion ou la variabilité des données. La variance est calculée en effectuant les étapes suivantes :

1. Calculer la moyenne des données.
2. Pour chaque valeur, soustraire la moyenne et élever le résultat au carré.
3. Calculer la moyenne des carrés obtenus à l'étape précédente.

La variance est généralement représentée par le symbole  $\sigma^2$  pour une population entière ou  $s^2$  pour un échantillon. [40] [41]

Pour chaque motif binaire local, soustrayez la moyenne calculée à l'étape précédente et élevez le résultat au carré. Faites cela pour tous les motifs binaires locaux de la région. Ensuite, calculez la moyenne de ces carrés. Il convient de noter que différentes variantes du LBP peuvent avoir des variations dans la manière précise de calculer la variance. Les étapes mentionnées ci-dessus constituent une méthode générale pour calculer la variance dans le LBP. [38] [35]

## 2.3 Completed Local Binary Pattern ( C-LBP )

Nous introduisons ici le motif binaire local complet (Completed Local Binary Pattern - C-LBP), qui prend en compte non seulement le signe, mais aussi l'intensité du pixel lui-même ainsi que les amplitudes des différences. Pour un pixel donné  $g_c$  et ses  $P$  voisins notés  $g_p$ , nous calculons la différence  $d_p = g_p - g_c$ , ce qui est appelé la Transformée de Signe et Magnitude de la Différence Locale (Local Difference Sign Magnitude Transform - LDSMT). Selon l'équation

$$d_p = s_p \times m_p, \quad \begin{cases} s_p = \text{signe}(d_p), \\ m_p = |d_p|. \end{cases} \quad (2.6)$$

Le paramètre  $d_p$  peut être décomposé en deux composantes,  $s_p$  et  $m_p$ , qui sont organisées en deux vecteurs  $[s_0, \dots, s_{p-1}]$  et  $[m_0, \dots, m_{p-1}]$ , respectivement. Ces vecteurs sont appelés vecteurs de signe et vecteur d'amplitude. La Figure 2.6 illustre la manière de calculer  $d_p$ , ainsi que les deux vecteurs  $s_p$  et  $m_p$ .




FIGURE 2.6 – : (a) un voisinage de 3x3 ; (b) la différence locale ; (c) le signe (d) l'amplitude

Le C-LBP compte trois opérateurs pour chaque pixel :

1. le CLBP-S, dérivé du vecteur signe en utilisant l'équation (2.6) et correspond au LBP original

$$\text{CLBP-S}_{(P,R)} = \sum_{p=0}^{P-1} s(g_p - g_c) \cdot 2^p, \quad s(x) = \begin{cases} 1, & x \geq 0, \\ 0, & x < 0. \end{cases} \quad (2.7)$$

2. le CLBP-M, calculé à partir du vecteur d'amplitude, est donné par l'équation (2.3).

3. le CLBP-C correspond à la valeur du niveau de gris du pixel central.

$$\text{CLBP-M}_{(P,R)} = \sum_{p=0}^{P-1} t(m_p, c) \cdot 2^p, \quad (2.8)$$

où

$$t(x, c) = \begin{cases} 1, & \text{si } x \geq c, \\ 0, & \text{sinon.} \end{cases} \quad (2.9)$$

où  $c$  est un seuil déterminé de façon adaptative et  $x$  correspond à  $m_p$ . Le paramètre  $c$  est fixé comme étant la moyenne des niveaux de gris calculée à partir de chaque voisinage. Le niveau de gris central du voisinage est conservé et est noté CLBP-C. Les opérateurs CLBP-S, CLBP-M et CLBP-C sont combinés par concaténation dans un vecteur pour caractériser chaque pixel. [42]

## 2.4 Centre Symétrique de la configuration binaire locale (CS-LBP)

Le CS-LBP (Center-Symmetric Local Binary Pattern) est une variante modifiée du LBP (Local Binary Pattern) qui a été développée par Marko Heikkilä dans le cadre de la reconnaissance d'objets dans la base de données PASCAL.[?]

Le LBP initial, bien que largement utilisé et efficace dans de nombreuses applications, présentait certaines limitations. Parmi celles-ci, on compte sa sensibilité aux changements d'éclairage et sa performance moins satisfaisante sur des images présentant une structure plate. C'est dans ce contexte que le CS-LBP a été proposé pour améliorer les performances du LBP dans ces situations.

Dans le CS-LBP, au lieu de comparer la valeur de niveau de gris de chaque pixel avec celle du pixel central, on compare les valeurs des pixels symétriques par rapport au centre. Cela signifie que pour chaque pixel, on sélectionne un ensemble de pixels symétriques situés de part et d'autre du pixel central. Ensuite, on compare les valeurs de niveau de gris de



ces pixels symétriques avec celle du pixel central et on attribue une valeur binaire (1 ou 0) en fonction du résultat de la comparaison.

Les avantages du CS-LBP sont multiples. Tout d'abord, il présente une meilleure tolérance aux changements d'éclairage par rapport au LBP classique. En effet, en comparant les pixels symétriques, le CS-LBP tient compte de la structure globale de l'image plutôt que de la valeur absolue des pixels individuels. Cela lui permet de mieux résister aux variations de luminosité dans l'image.

De plus, le CS-LBP offre une meilleure robustesse dans les zones de l'image où la structure est plate. Dans de tels cas, le LBP classique peut avoir du mal à capturer des informations significatives, tandis que le CS-LBP est capable de détecter des motifs symétriques qui peuvent être caractéristiques de certains objets ou textures.

La formule pour calculer les caractéristiques CS-LBP dépend des paramètres choisis, tels que le rayon et le nombre de pixels symétriques à comparer.[43] Elle peut être exprimée comme suit :

$$CS\_LBP_{r,T} = \sum_{i=0}^{N/2-1} 2^i \left( [g_i - g_{i+N/2}] + \frac{T}{2} \right) \quad (2.10)$$

. avec :

$$S(x) = \begin{cases} 1, & \text{si } x \geq T \\ 0, & \end{cases} \quad (2.11)$$

$g_i$  et  $g_i + \frac{N}{2}$  correspondent au niveau de gris du centre-symétrique des paires des pixels (N au total) régulièrement espacés sur un cercle de rayon r. T est une valeur faible utilisée comme seuil.

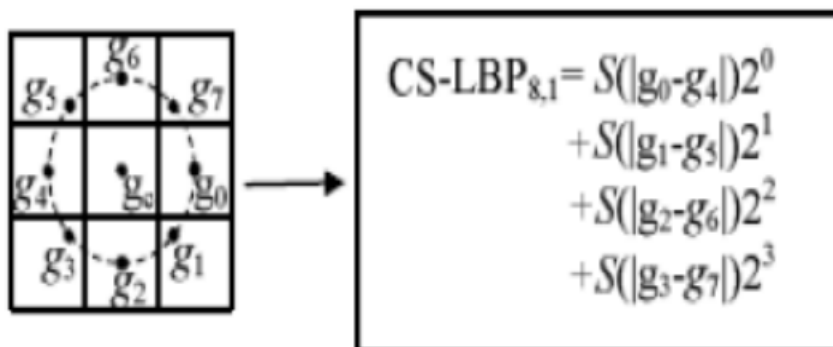


FIGURE 2.7 – CS-LBP caractéristique d'un quartier de 8 pixels

En conclusion, le CS-LBP est une amélioration du LBP qui permet de capturer des motifs centrés-symétriques et offre des avantages tels que la tolérance aux changements

d'éclairage, la robustesse dans les zones de l'image et l'efficacité de calcul. Il constitue un outil puissant pour l'analyse de textures et trouve des applications dans de nombreux domaines de la vision par ordinateur.

### 2.4.1 Le Descripteur à base de Loi de Weber (Weber's Law Descriptor)

Lorsqu'on se trouve dans une pièce vide et calme, même les chuchotements peuvent être clairement entendus, contrairement à une pièce où le niveau sonore est élevé, rendant difficile la distinction ou la perception des différents sons. Cette observation est basée sur le principe connu sous le nom de loi de Weber, formulée par le physiologue allemand E.H. Weber (1795-1878). Cette loi décrit la relation entre une sensation mentale et la grandeur physique d'un stimulus, telle que la relation entre la force perçue d'un son et la puissance de l'onde de pression correspondante dans l'air.

Une méthode récente qui est considérée comme un indicateur robuste utilise deux composantes : la différence d'excitation et le gradient d'orientation. Cette relation est communément appelée loi de Weber et peut être exprimée par la formule suivante :

$$\Delta I/I = K \quad (2.12)$$

Le rapport  $\Delta I/I$  est appelé loi de Weber,  $\Delta I$  représente le seuil d'incrément,  $I$  représente l'intensité du stimulus initial.

#### La différence d'excitation

La composante en question est représentée par  $\zeta(xc)$ , où  $xc$  est le pixel courant (dont l'intensité ne doit pas être nulle). Elle est modélisée par l'arc tangente de la somme des différences d'intensités entre le pixel courant et ses voisins, divisée par l'intensité du pixel courant (voir Table 2.1). Cette relation mathématique peut être exprimée par l'équation suivante

$$\zeta(xc) = \arctan \left( \frac{\sum_{i=0}^{P-1} (x_i - x_c)}{x_c} \right) \quad (2.13)$$

où  $x_i$  est le  $i$ -ème pixel voisin du pixel courant  $x_c$ .

Nous pouvons observer que l'intervalle de  $\zeta(xc)$  est  $[-\frac{\pi}{2}, \frac{\pi}{2}]$ . Lorsque la valeur de  $\zeta(xc)$  est positive, cela indique que le voisinage est plus lumineux que le pixel courant. En

revanche, si la valeur de  $\zeta(x_c)$  est négative, nous en déduisons que le voisinage est plus sombre que le pixel courant.

### Gradient d'orientation

Le calcul du gradient d'orientation concerne la mesure du rapport entre le changement dans la direction horizontale et la direction verticale d'une image. Les étapes détaillées de ce calcul sont résumées dans la figure 2.8. On peut exprimer ce calcul à l'aide de l'équation mathématique suivante :

$$\theta = \arctan \left( \frac{v_{10}}{v_{11}} \right) \tag{2.14}$$

où  $x_5, x_1, x_7$ , et  $x_3$  représentent les voisins du pixel courant  $x_c$  avec un voisinage 3x3, comme illustré dans la figure.

$x_0$	$x_1$	$x_2$
$x_7$	$x_c$	$x_3$
$x_6$	$x_5$	$x_4$

TABLE 2.1 – Exemple de voisinage 3x3 du pixel xc

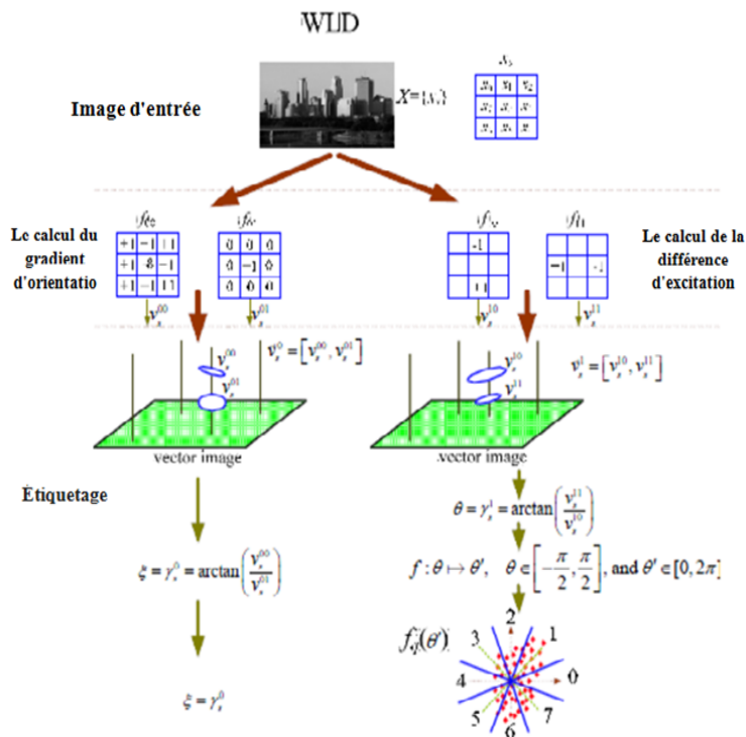


FIGURE 2.8 – Exemple de calcul du gradient d'orientation et la différence d'excitation pour une image

## Comparaison entre (LBP , C-LBP , CS-LBP , WLD)

Les méthodes LBP (Local Binary Patterns), C-LBP (Completed Local Binary Patterns), CS-LBP (Center-Symmetric Local Binary Patterns) et WLD (Weighted Local Descriptor) sont toutes des descripteurs locaux couramment utilisés pour l'analyse d'images. Voici une comparaison entre ces méthodes :

### LBP (Local Binary Patterns)

- C'est une méthode simple et efficace pour la description locale des textures.
- Elle consiste à comparer les niveaux de gris des pixels voisins par rapport à un pixel central et à les représenter sous forme de motifs binaires.
- LBP est invariant aux changements d'échelle et de luminosité, mais il peut être sensible aux variations de rotation et de perspective.

### C-LBP (Completed Local Binary Patterns)

- C-LBP étend la méthode LBP en considérant également les pixels diagonaux dans les comparaisons de motifs binaires.
- Cela permet de capturer plus d'informations de texture et de rendre le descripteur plus discriminant.
- C-LBP est également invariant aux changements d'échelle et de luminosité, mais il peut être sensible aux variations de rotation et de perspective comme LBP

### CS-LBP (Center-Symmetric Local Binary Patterns)

- CS-LBP est une extension de LBP qui utilise une opération de symétrie centrée pour comparer les niveaux de gris des pixels voisins.
- Cette méthode tente de capturer des caractéristiques locales plus discriminantes en tenant compte de la symétrie des motifs binaires.
- CS-LBP est également invariant aux changements d'échelle et de luminosité, mais il peut être sensible aux variations de rotation et de perspective.

### WLD (Weber's Law Descriptor)

- WLD est une méthode de descripteur local qui met l'accent sur les variations de luminosité et de texture.

- Il utilise des filtres pondérés pour capturer les informations sur les variations de gradients et de directions locales.

- WLD peut être plus robuste aux variations de luminosité et de contraste par rapport aux méthodes LBP, C-LBP et CS-LBP.

En résumé, LBP, C-LBP, CS-LBP et WLD sont des descripteurs locaux couramment utilisés dans l'analyse d'images. Chacune de ces méthodes présente des caractéristiques et des avantages spécifiques en termes de simplicité, d'invariance aux changements d'échelle et de luminosité, ainsi que de capacité à capturer des informations discriminantes. Le choix de la méthode dépendra des exigences spécifiques de l'application et des caractéristiques de l'image à analyser.

## 2.5 La Classification

### 2.5.1 La Classification Supervisée

La classification supervisée est une méthode de classification où les données d'entraînement sont étiquetées avec leurs classes respectives. L'objectif est d'apprendre un modèle à partir de ces données étiquetées afin de prédire la classe d'objets non étiquetés. Les étapes clés de la classification supervisée comprennent : Collecte des données d'entraînement avec des étiquettes de classe connues. Sélection des caractéristiques pertinentes pour la classification. Choix d'un algorithme de classification approprié, tel que les arbres de décision, les SVM, les réseaux neuronaux, etc. Entraînement du modèle à l'aide des données d'entraînement étiquetées. Évaluation du modèle à l'aide d'un ensemble de test distinct pour mesurer sa précision et sa performance. Utilisation du modèle entraîné pour prédire la classe de nouvelles données non étiquetées.

La classification supervisée est couramment utilisée dans des domaines tels que la reconnaissance d'images, la détection de fraudes, la classification de documents, etc.[44]

### 2.5.2 La Classification Non Supervisée

La classification non supervisée est une méthode de classification où les données d'entraînement ne sont pas étiquetées avec des classes. L'objectif est d'identifier des structures

ou des regroupements naturels dans les données sans aucune information préalable sur les classes. Les étapes principales de la classification non supervisée comprennent : Collecte des données sans étiquettes de classe. Sélection des caractéristiques appropriées. Choix d'un algorithme de regroupement (clustering) adapté, comme le k-means, la CAH, le DBSCAN, etc. Application de l'algorithme de regroupement pour découvrir les structures et les regroupements dans les données. Évaluation des résultats de la classification non supervisée en utilisant des mesures d'évaluation spécifiques, telles que l'indice de Davies-Bouldin, la silhouette, etc.

La classification non supervisée est utilisée pour l'exploration de données, la segmentation d'images, la recommandation de produits, etc., lorsque les classes ne sont pas connues à l'avance ou lorsque l'objectif est d'identifier des structures intrinsèques dans les données. [45]

## 2.6 Support Vecteurs Machine ( SVM )

### 2.6.1 Définition

Les SVM (Support Vector Machines) sont une famille d'algorithmes d'apprentissage automatique utilisés pour résoudre des problèmes de classification, de régression et de détection d'anomalie. Ils sont réputés pour leurs solides garanties théoriques, leur grande flexibilité et leur facilité d'utilisation, même pour les utilisateurs n'ayant pas une grande connaissance en data mining.




FIGURE 2.9 – Exemple de Support Vecteur Machin

Les SVM ont été développés dans les années 1990. Leur principe est simple : ils visent à séparer les données en classes en utilisant une frontière aussi "simple" que possible, de manière à maximiser la distance entre les différents groupes de données et la frontière qui

les sépare. Les SVM sont ainsi appelés "séparateurs à vaste marge", et les "vecteurs de support" désignent les données les plus proches de la frontière. [?]

## 2.6.2 Types de SVM

Il existe plusieurs types de SVM (Support Vector Machines) en fonction de différentes variations et extensions apportées à l'algorithme de base. Voici deux types qui nous intéressent :

### 2.6.3 SVM linéaire

Les SVM utilisent un principe de projection des données d'un espace d'entrée  $X$  vers un espace de caractéristiques  $H$  de dimension supérieure. L'objectif est de trouver un hyperplan optimal dans l'espace de caractéristiques qui sépare les données appartenant à différentes classes. Cette séparation est effectuée de manière à maximiser la marge entre les exemples les plus proches de chaque classe, permettant ainsi une classification précise.

En résumé, les SVM cherchent à transformer l'espace d'entrée pour trouver un hyperplan optimal dans un espace de caractéristiques de dimension supérieure, afin de séparer les données des différentes classes de la manière la plus simple et précise possible. Lorsque

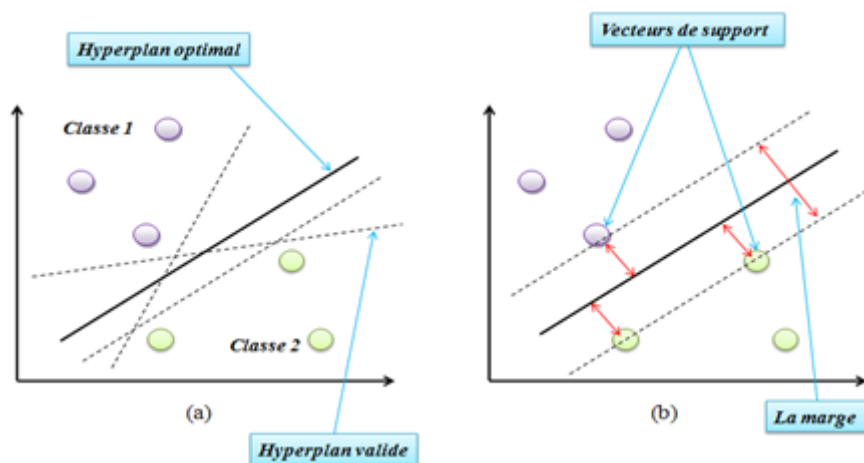


FIGURE 2.10 – Optimisation de la séparation des classes par la recherche d'un hyperplan avec une marge maximale

la fonction de décision peut être exprimée par une fonction linéaire, le classifieur est considéré comme "linéaire". Dans ce cas, il existe deux possibilités :

## Séparation à marge molle

L'ensemble des données d'apprentissage est défini par  $x_i y_i, i=1, \dots, N, x_i \in \mathbb{R}^d$  représente un vecteur caractéristique de dimension  $d$ , et  $y_i \in \{-1, +1\}$  indique l'appartenance à l'une des classes.  $N$  représente le nombre de données d'apprentissage. La séparation entre les deux classes distinctes est réalisée au moyen d'un hyperplan  $H$  de la forme :

$$\mathbf{x}_i \cdot \mathbf{w} + b = 0$$

où  $w$  est un vecteur de poids et  $b$  est un biais.

$x_i$  représente les données qui appartiennent à un espace  $H$ . Le vecteur  $w$  est le vecteur de pondération qui définit la normale à un hyperplan  $H$ , tandis que  $b$  est le biais. La distance perpendiculaire entre l'hyperplan  $H$  et l'origine est donnée par  $\frac{|b|}{\|w\|}$

Pour garantir une séparation optimale, il est nécessaire que l'hyperplan de séparation  $H$  permette une marge maximale, ce qui représente une condition d'optimisation de sa position. Cette condition peut être formulée de la manière suivante :

$$\mathbf{x}_i \cdot \mathbf{w} + b \geq +1$$

$$\mathbf{x}_i \cdot \mathbf{w} + b \leq -1$$

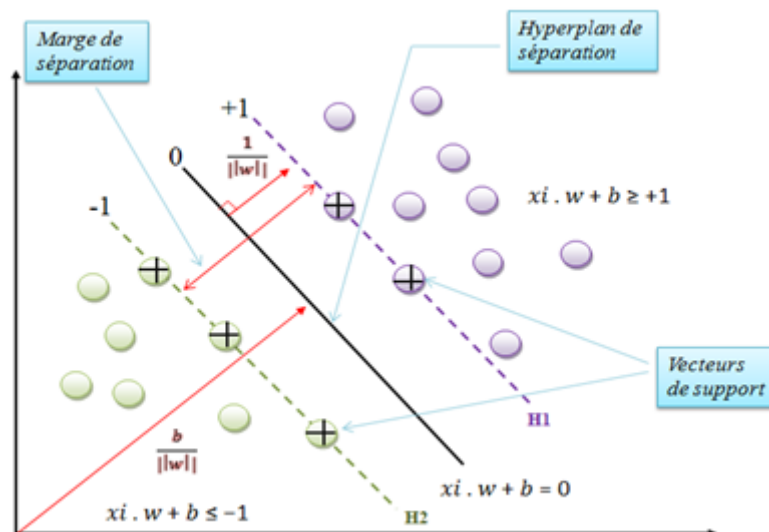


FIGURE 2.11 – Le cas des données linéairement séparables



## Séparation à marge dure

Dans le cas où la condition de séparabilité n'est pas garantie, il devient nécessaire d'accepter certaines erreurs d'apprentissage tout en les pénalisant à l'aide d'un paramètre de pénalisation. Ce paramètre permet de déterminer le compromis entre la maximisation de la marge et la minimisation de l'erreur de classification. Ainsi, ce scénario reflète la difficulté de séparer deux ensembles de données de manière parfaite et souligne la nécessité de trouver un équilibre entre la précision de la séparation et la capacité à généraliser les résultats.




FIGURE 2.12 – Exemple d'une mauvaise classification. Les exemples  $x_1$  et  $x_2$  sont des exemples mal classés

Pour traiter ce cas on utilise cette formule :

$$y_i \cdot (\mathbf{x}_i \cdot \mathbf{w} + b) \geq 1 - \xi_i, \quad \forall i \in \{1, \dots, N\}$$

### 2.6.4 SVM non linéaire

Dans le cas général, la fonction de transfert optimale est non linéaire. Pour prendre en compte les non-linéarités dans le modèle des SVM, des noyaux ou "kernels" non linéaires sont introduits. De manière surprenante, l'utilisation de noyaux ne modifie pas fondamentalement la nature des SVM (tant que l'on travaille dans le dual).

Cependant, la question la plus importante concerne la détermination de l'hyperplan de séparation dans le nouvel espace de représentation en utilisant la fonction noyau. Cette

approche consiste à remplacer le produit scalaire " $\mathbf{x}_i \cdot \mathbf{x}_j$ " dans l'espace de redescription par un noyau.

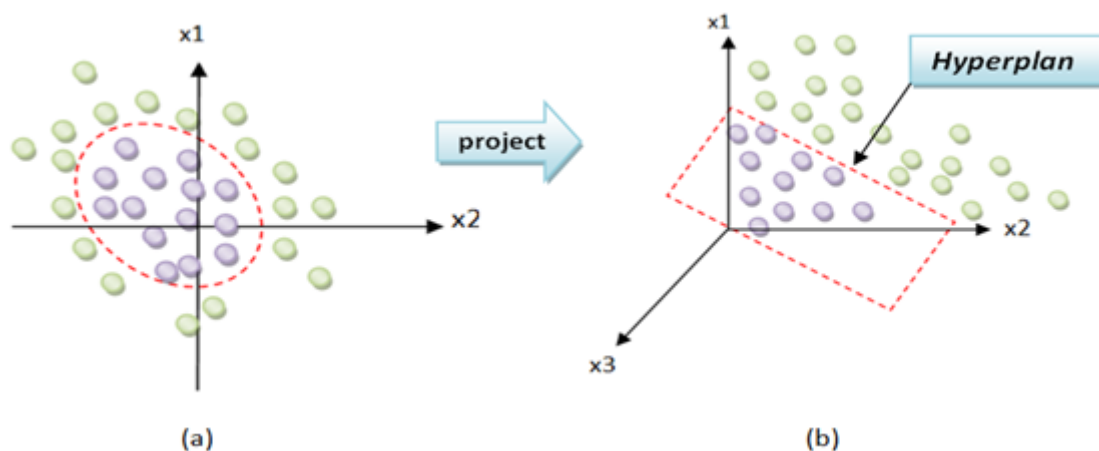


FIGURE 2.13 – Représentation d'une possibilité de séparation avec un passage vers un espace de plus grande dimension ((a) étant l'espace d'entrée, (b) étant le nouvel espace)

### Fonctions noyaux

La notion de fonction noyau est pertinente lorsque la séparation des données ne peut pas être réalisée de manière linéaire. En effet, pour mieux séparer les données qui se chevauchent, une solution consiste à les projeter dans un nouvel espace de dimension supérieure où une séparation linéaire peut être appliquée. Cette projection est représentée par la fonction  $\Phi$ . Selon le cas étudié précédemment, il devient nécessaire de calculer le produit scalaire ( $\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j)$ ) au lieu du produit scalaire ( $\mathbf{x}_i \cdot \mathbf{x}_j$ ) dans le nouvel espace de projection.

Suite à l'apparition de l'idée du noyau, la projection est effectuée de la manière suivante :

$$K(\mathbf{x}_i, \mathbf{x}_j) = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j))$$

où  $K$  représente le noyau. Cette équation exprime le fait que le noyau fournit les mêmes résultats que le produit scalaire lors de la projection des données dans un nouvel espace de représentation. Cette approche démontre que le noyau n'est pas une fonction arbitraire, mais est étroitement lié à la projection des données.

Le tableau suivant montre quelques noyaux et leurs paramètres :

Types de noyaux	Formules	Paramètres associés
Linéaire	$K(x_i, x_j) = x_i \cdot x_j$	-
Polynomial de degrés P	$K(x_i, x_j) = (1 + x_i \cdot x_j)^P$	P : L'ordre du polynôme
RBF (Radial Basis Function)	$K(x_i, x_j) = \exp(-\gamma \ x_i - x_j\ ^2)$	$\gamma$ : Paramètre du noyau

TABLE 2.2 – Exemples de noyaux

Le choix du noyau est souvent déterminé par les connaissances préalables du domaine d'application ainsi que par une série de tests et d'essais antérieurs.

### 2.6.5 RBF (Radial Basis Function)

RBF (Radial Basis Function) est une fonction noyau utilisée dans les machines à vecteurs de support (SVM) et d'autres algorithmes d'apprentissage automatique. Cette fonction noyau est couramment utilisée pour modéliser des relations non linéaires entre les données.

La fonction RBF est définie comme suit :

$$RBF(x, y) = \exp(-\gamma \|x - y\|^2)$$

où  $x$  et  $y$  représentent des vecteurs de données,  $\|x - y\|$  est la distance euclidienne entre les vecteurs  $x$  et  $y$ , et  $\gamma$  est un paramètre qui contrôle l'influence de la distance sur la similarité des données.

La fonction RBF attribue des valeurs plus élevées aux paires de points qui sont plus proches les uns des autres, ce qui permet de capturer les relations locales et non linéaires entre les données. Elle est largement utilisée dans des domaines tels que la classification, la régression et la reconnaissance de motifs. [46]




FIGURE 2.14 – Présentation schématique d'un réseau RBF

## 2.7 Conclusion

Dans ce chapitre, nous avons abordé la notion de texture ainsi que les différentes approches existantes pour analyser la texture. Nous avons d'abord examiné le descripteur LBP ainsi que d'autres variantes similaires, notamment le CLBP, WLD et le CSLBP, en rappelant les concepts fondamentaux de ces descripteurs. Par ailleurs, nous avons rappelé les principes de la méthode des Machines à Vecteurs de Support (SVM). Dans le prochain chapitre, nous présenterons une série d'expérimentations basées sur l'algorithme SVM et les descripteurs utilisés, puis nous discuterons des résultats obtenus.

CHAPITRE

3

MÉTHODOLOGIE ET RÉSULTATS

## 3.1 Introduction

Dans les chapitres précédents nous avons abordé les concepts en relation à la météorologie, les différentes méthodes d'extractions de caractéristiques à partir des images. Nous avons opté pour les techniques des motifs proposées (LBP, CLBP, WLD, et CSLBP). Dans ce présent chapitre nous parlerons des différentes étapes de création d'un système de classifications : de la génération des données jusqu'à la classification. Nous présenterons et évaluerons les résultats grâce des mesures statiques qui permettent de voir la robustesse des systèmes conçus.

## 3.2 Base de données

La ville de Bordeaux se trouve dans le Sud-Ouest de la France, à environ 50 km de l'océan Atlantique. La région présente principalement un relief plat et bénéficie d'un climat de type sub-océanique avec quelques influences méditerranéennes. Les hivers sont doux et pluvieux, tandis que les étés sont chauds et ensoleillés.

Le radar de Bordeaux est installé à l'aéroport de Bordeaux-Mérignac, à une altitude de 70 mètres. Ses coordonnées géographiques exactes sont 44°52' de latitude nord et 0°30' de longitude ouest. Les données radar sont collectées en continu, avec une période de 15 minutes. Toutes les images sont enregistrées selon le mode PPI (Plan Position Indicator). Elles sont représentées dans un format de 512x512 pixels, avec une résolution de 1 km par pixel. Chaque pixel de ces images est codé avec 64 niveaux de gris voir la figure 3.1




FIGURE 3.1 – Image radar dans le cas séparable d'une dans la région de Bordeaux

Il est à noter que les images radar de Bordeaux sont souvent perturbées par les échos du sol provenant de la zone industrielle de Bordeaux, dans un rayon d'environ 40 km.

Géré par Météo France et intégré au réseau opérationnel Français, le radar de Bordeaux fournit des informations météorologiques précieuses pour la région, malgré les perturbations causées par les échos du sol. Ces données sont essentielles pour surveiller les conditions météorologiques, prévoir le temps et soutenir la prise de décisions en matière de sécurité et de planification.

Le tableau 3.1 montre quelques spécifications techniques du radar de Bordeaux.

Fréquence d'émission	2,8 GHz
Puissance d'émission	700 KW crête
Gain de l'antenne	40 dB
Sensibilité à la réception	-105 dBm
Résolution spatiale	1 Km x 1Km
Durée de l'impulsion	2 $\mu$ s
Diamètre de l'antenne	4m
Ouverture du faisceau à 3dB	1.9°

TABLE 3.1 – Caractéristiques technique du radar de Bordeaux

### 3.3 Critère d'évaluation

Notre objectif est l'élimination des échos de sol tout en préservant les échos de précipitations, L'estimation de l'efficacité du classifieur est lié au calcul des statistiques, la table 3.2 affiche les paramètres utilisés

		Résultats	
		Précipitation	Echos du sol
Vérité terrain	Précipitation	A	B
	Echos du sol	C	D

TABLE 3.2 – table de contingence

- L'identification positive des échos de précipitation est désignée par a.
- L'identification négative des échos de précipitation est donnée par b.
- L'identifications positive des échos de sol est donnée par d.
- L'identifications négative des échos de sol est donnée par c.

A partir des paramètres ci-dessus on peut déduire :

- La probabilité de bonne détection POD indique les pixels qui ont été correctement identifiés et elle est donnée par les expressions suivantes :

PODP pour les échos précipitation :

$$PODP = \frac{a}{(b + a)} \quad (3.1)$$

PODE pour les échos du sol :

$$PODE = \frac{d}{(c + d)} \quad (3.2)$$

- Le ratio de fausses alarmes (False Alarm Rate) des pixels qui sont mal classés est donné par :

FARP pour les précipitations :

$$FARP = \frac{c}{(c + a)} \quad (3.3)$$

FARE pour les échos du sol :

$$FARE = \frac{b}{(b + d)} \quad (3.4)$$

- Success Ratio (SR) définit les identifications positives des échos du sol parmi toutes les identifications :

$$SR = \frac{d}{(b + d)} \quad (3.5)$$

- L'indice de réussite CSI (Critical Success Index) indique le rapport entre les pixels correctement identifiés comme précipitant, et les pixels correctement identifiés comme précipitant et les pixels non correctement identifiés (précipitant et non précipitant). Il est exprimé par :

$$CSI = \frac{a}{(a + b + c)} \quad (3.6)$$

- Le pourcentage de détection correcte CIA, indique le rapport entre les pixels correctement identifiés (précipitant et échos du sol) et le nombre total de pixels. Il est donné par l'expression :



$$CIA = \frac{a + d}{(a + b + c + d)} \quad (3.7)$$

La valeur optimale de chaque paramètre statistique est donnée dans le tableau ci-dessous

	PODE/PODP	FARE/FARP	SR	CSI	CIA
Valeurs optimal	100	0	100	100	100

TABLE 3.3 – Valeur optimal pour chaque paramètre statistique

### 3.4 Environnement d'application

Notre application est développée dans l'environnement de programmation MATLAB R2022b. MATLAB est l'abréviation de "MATrix LABoratory". C'est un logiciel spécialement conçu pour résoudre des problèmes d'analyse numérique et de traitement du signal. Il offre des fonctionnalités permettant d'effectuer des calculs matriciels et de visualiser les résultats de manière graphique. La formulation des problèmes dans MATLAB est similaire à la formulation mathématique des problèmes à résoudre

#### La Bibliothèque SVM (libSVM)

La bibliothèque LIBSVM a été développée par Chih-Chung Chang et Chih-Jen Lin à l'Université nationale de Taiwan. Elle est distribuée gratuitement et est disponible pour plusieurs langages de programmation tels que C++, Java, Python et MATLAB. La bibliothèque LIBSVM (Support Vector Machines Library) est un outil puissant et largement utilisé pour la classification et la régression à l'aide des machines à vecteurs de support (SVM). Elle offre une implémentation efficace des SVM et fournit des fonctionnalités avancées pour la classification binaire, la classification multiclasse et des régressions. Les principales caractéristiques de la bibliothèque LIBSVM incluent la prise en charge de différents noyaux (linéaire, polynomial, gaussien, etc.), la possibilité de gérer des ensembles de données de grande taille et la prise en charge de l'optimisation des paramètres des SVM grâce à la validation croisée. Les auteurs du LIBSVM ont mis en place un site web dédié à la bibliothèque, offrant une documentation complète, des guides d'utilisation, des exécutable et des codes sources dans plusieurs langages, des jeux de données de test.[47] Site web LIBSVM : <https://www.csie.ntu.edu.tw/~cjlin/libsvm>.

## Fonctionnalités de la LIBSVM

La bibliothèque LIBSVM offre la possibilité de l'intégrer dans un code applicatif existant ou de l'utiliser directement en appelant les fichiers exécutables. Les utilisateurs peuvent accéder aux fonctionnalités de la bibliothèque en utilisant des commandes en ligne de commande. Voici un aperçu des commandes de base :

### — Entraînement d'un modèle SVM :

**svm-train** [options] fichier\_d'entrée modèle\_SVM Le SVM train consiste à entraîner un modèle SVM à partir de données d'entraînement étiquetées « fichier d'entrée », la qualité des résultats de prédiction dépend de la qualité des données d'entraînement et de la pertinence du modèle SVM choisi

### — Prédiction avec un modèle SVM :

**svm-predict** [options] fichier\_d'entrée fmodèle fichier\_de\_sortie Une fois le modèle « modèle » SVM entraîné, le SVM-predict permet de prédire les résultats sur de nouvelles données « fichier d'entrée ». La fonction permet de faire la prédiction sur le taux de reconnaissance.

Ces commandes basiques vous permettent d'entraîner des modèles SVM, de prédire des résultats, de réaliser des validations.

## Paramètres SVM pris en charge par la librairie

Pour commencer le processus d'apprentissage avec la LIBSVM, il est nécessaire de spécifier certains paramètres en fonction de notre objectif, qu'il s'agisse de classification, de régression ou autre. Le choix judicieux des paramètres est essentiel pour obtenir des résultats satisfaisants. Voici la liste complète des paramètres possibles de la LIBSVM. Il convient de noter que si ces paramètres ne sont pas renseignés, la bibliothèque utilisera les valeurs par défaut, indiquées ci-dessous également :

- **s svm\_type** : C'est le type de l'algorithme SVM à utiliser, il peut s'agir de l'une des fonctions : C\_SVC, NU\_SVC, ONE\_CLASS, EPSILON\_SVR, NU\_SVR.

Par défaut le type SVM utilisé est C\_SVC, et dans notre cas on a utilisé le SVM type Bi-Class = C\_SVC.

- **t kernel\_type** : Il existe différents types de fonctions noyau qui peuvent être utilisés, et ils peuvent être définis comme suit : LINEAR, POLY, RBF ou SIGMOID. Chaque type de fonction noyau correspond à une valeur spécifique :\*
  1. 0 : Fonction linéaire - Formule :  $= u' \cdot v$
  2. Fonction polynomiale - Formule :  $(\gamma * u' * v + \text{coef0})^{\text{degré}}$
  3. Fonction radiale - Formule :  $\tanh(\gamma * u' * v + \text{coef0})$
  4. Fonction sigmoïde - Formule :  $\tanh(\gamma * u' * v + \text{coef0})$
  5. Création d'un noyau dans le fichier de test (voir la documentation LIBSVM pour plus de détails)

Dans ces formules,  $u'$  représente la transposée du vecteur contenant les valeurs des attributs de l'ensemble d'apprentissage, et  $v$  est le vecteur des étiquettes (labels). Les paramètres gamma, degré et coef0 sont des valeurs que l'utilisateur spécifie.

Par défaut, la fonction noyau utilisée est RBF (fonction radiale). La documentation LIBSVM recommande l'utilisation de la fonction RBF pour plusieurs raisons, notamment parce qu'elle permet de gérer les cas où la relation entre les étiquettes et les attributs n'est pas linéaire.

### Paramètres des fonctions noyau

- **d degree** : Paramètre degré de la fonction noyau , par défaut 3
- **g gamma** : Paramètre gamma de la fonction noyau, par défaut 1
- **r coef0** : Paramètre coef0 de la fonction noyau, par défaut 0.

### Paramètres dépendants du type SVM choisi

- **c cost** : C'est le paramètre C (coût), qui représente la pénalité de l'erreur, à renseigner lors de l'utilisation du type SVM C-SVC, epsilon-SVR et nu-SVR, par défaut le coût est égal à 1
- **wi weight** : pour changer le paramètre C à  $\text{weight} * C$ , s'il n'est pas renseigné weight est égale à 1 sa valeur par défaut, et par conséquent neutre.
- **n nu** : Paramètre nu du type nu-SVC, One-class-SVM et nu-SVR, par défaut 0.5
- **p epsilon** : Paramètre epsilon de la fonction de perte (Loss Function) pour le type epsilon-SVR, par défaut égal à 0.1. [?]

### 3.5 Structure d'un système de classification

L'objectif de notre travail est de filtrer les échos parasites du radar, nous proposons une approche à partir de laquelle la reconnaissance des échos de l'image se fait de manière automatique. Pour cela nous développons un algorithme basé sur la classification par SVM. La structure du système est donnée par la figure 3.2 .

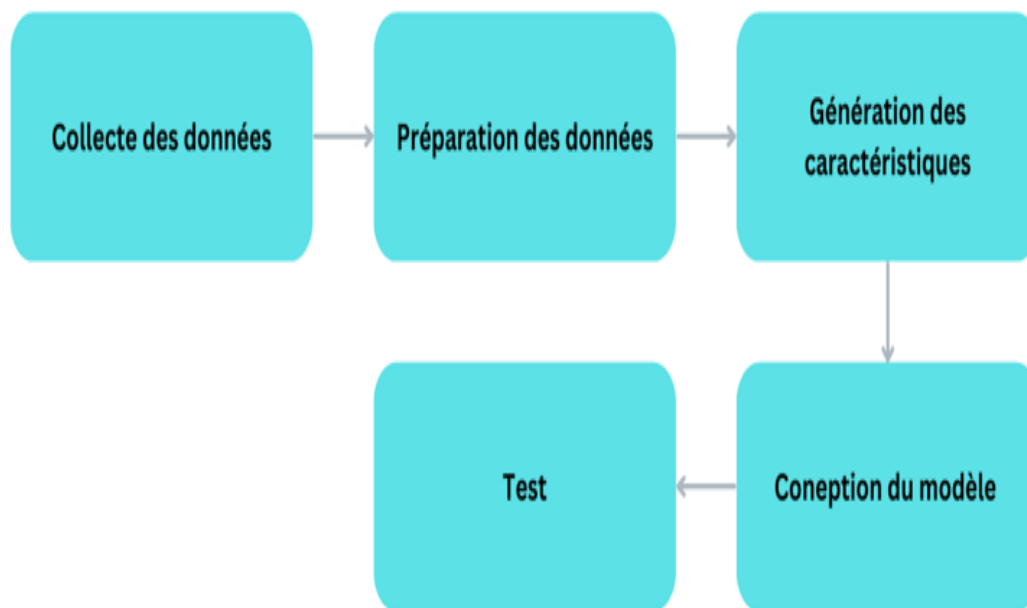


FIGURE 3.2 – Structure générale d'un système de classification

#### Collecte de données

Les images utilisées ont été enregistrées à l'aide d'un radar implanter à la région de Bordeaux. Une partie de cette base a été exploitées pour concevoir ce système.

#### Préparation de la base de données

La préparation des données consiste à créer deux ensembles l'un dédié à l'apprentissage et l'autre au test. Les données d'apprentissage sont réparties en deux sous-ensembles.

Le premier sous-ensemble comprend des images qui représentent exclusivement des échos de précipitations. Ces images sont sélectionnées parmi celles où il est facile de distinguer les échos du sol des échos de précipitations. Pour cela, nous utilisons des logiciels

de retouche d'images pour éliminer manuellement les échos parasites. La figure 3.3(a) représente les échos de précipitations.

Le second sous-ensemble regroupe des images prises en temps clair, c'est-à-dire en l'absence de précipitations. Ces images de référence sont utilisées ultérieurement pour identifier les paramètres discriminants entre les échos du sol et les échos de précipitations, et pour définir les conditions de suppression des échos indésirables. La figure 3.3(b) représente les échos de sol.

- **Lors de l'apprentissage ou conception du model :** Les données relatives aux précipitations sont étiquetées avec la valeur (1), tandis que celles correspondant aux échos du sol sont étiquetées avec la valeur (-1) en sortie du classifieur. La conception d'un modèle se déroule en réalité en deux étapes. Tout d'abord, nous effectuons l'apprentissage en observant de nombreux modèles avec de bons taux d'apprentissage, ce qui nécessite ensuite une deuxième étape pour choisir le modèle optimal, appelée phase de validation
- **Lors du test :** on utilise une nouvelle base de données appelée "données de test". Cette base de données est utilisée pour tester la robustesse du classifieur en utilisant des données qui n'ont jamais été utilisées précédemment. Cela permet de vérifier si le modèle est capable de généraliser et de produire des résultats cohérents et précis avec de nouvelles données.

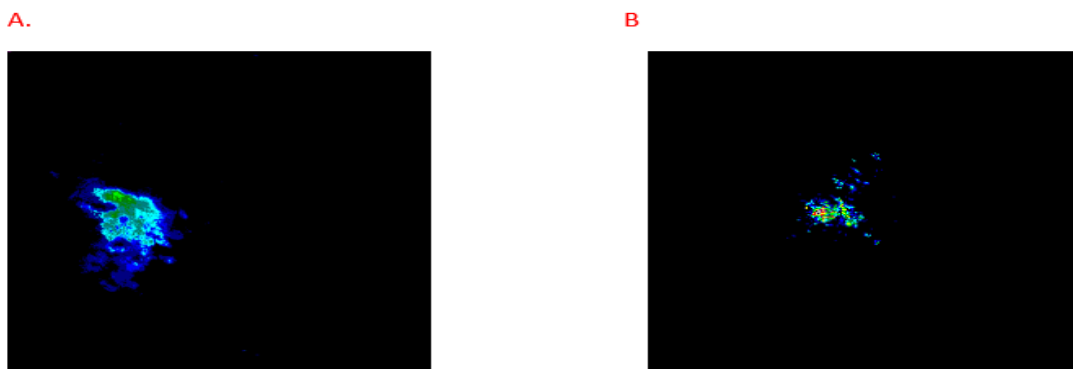


FIGURE 3.3 – image des deux sous ensembles séparée, l'image A contient les échos de précipitations, et l'image B les echos de sol

## 3.6 Structure du système de reconnaissance des échos radar

Une fois les deux bases créées comme expliqué précédemment (voir table 3.4). On travaille dans un premier temps avec la base d'apprentissage. Nous générons des caractéristiques pour tous les points de l'image qui appartiennent à l'écho de sol ou précipitations. Ces caractéristiques sont stockées dans des matrices puis sont injectées à l'entrée du SVM, elles serviront à entraîner ce dernier voir figure 3.4. La phase d'apprentissage a pour but de trouver les paramètres optimaux du SVM ( $C, \gamma$ ), offrant un bon taux de classification des données d'apprentissage. La validation d'un seul modèle est requise ce qui nécessite de partitionner les données d'apprentissage en deux portions : soit  $2/3$  pour l'entraînement et  $1/3$  pour la validation. La première portion est utilisée pour l'entraînement du modèle, tandis que la seconde est réservée à la validation afin de déterminer les performances et l'efficacité du modèle optimal.

Dans le cadre des SVM, les non-linéarités sont prises en compte en introduisant des noyaux non linéaires, également appelés "Kernel". La conception des modèles SVM non linéaires consiste principalement à choisir une famille de fonctions noyau appropriée et à ajuster les paramètres de ces fonctions, par exemple l'exposant pour les fonctions noyau polynomiales. Le choix du noyau utilisé est souvent lié à l'application, à la forme des fonctions de décision possibles et au type de contrôle des hypothèses réalisé. Par exemple, les fonctions noyau gaussiennes pénalisent les dérivées de tous les ordres et favorisent donc les solutions "régulières". Il est donc important de choisir soigneusement la famille de noyau utilisée afin de traduire au mieux les connaissances préalables sur le problème et les données.

En analysant les expériences présentées dans ce chapitre, on peut conclure que la mise en œuvre d'un algorithme SVM est généralement peu coûteuse en termes de temps, mais la recherche des meilleurs paramètres peut nécessiter des phases de tests assez longues. De plus, la phase d'apprentissage est un processus relativement lent en raison du nombre de SVM à construire. Dans cette approche, nous avons choisi d'utiliser le noyau RBF (fonctions radiales à base de noyau) en raison des tests et essais antérieurs qui ont donné des résultats satisfaisants dans la plupart des applications. [?] [?]

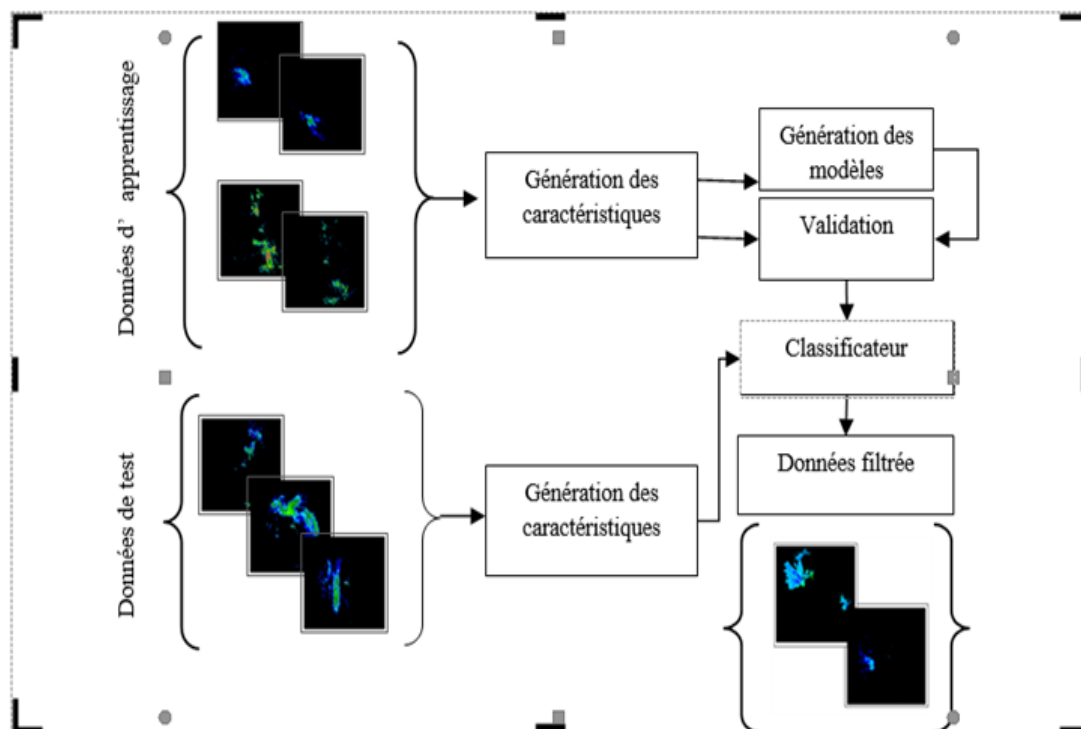


FIGURE 3.4 – Structure du système de filtrage à base des descripteurs proposés

Données d'apprentissage		Données de test	
Précipitations	Echos	Précipitations	Echos
11200	11200	1378267	92123

TABLE 3.4 – Nombre de pixel pour la phase d'apprentissage et de test

### Génération des paramètres

Rappelons que notre application consiste à classer chaque pixel de l'image dans une classe « Echo de sol, ou Précipitation » en calculant chaque descripteur cité dans le chapitre précédent, puis concevoir un model SVM. Nous traiterons que les pixels porteurs d'informations différent du fond noir. Dans le calcul des paramètres texturaux la taille de la fenêtre qui va balayer et analyser toute l'image influe sur la valeur affectée à chaque pixel, ainsi pour le LBP nous avons choisi différentes tailles de fenêtre avec un Rayon « R » et son voisinage « N » adéquat, Taille choisie :

-3x3 : R=1 et N=8

-5x5 : R=2 et N=16

-7x7 : R=3 et N=24

Les vecteurs résultats sont obtenus par la composante d'invariance par rotation et d'uniformité « RIU<sup>2</sup> ». Pour le calcul des descripteurs restant nous avons continué avec la taille 3x3 et  $R = 1$  et  $N=8$ ,

- - Pour le CLBP on prend l'intensité du pixel, et on calcule de son voisinage les variables CLBP-S et CLBP-M en utilisant les équations (2.7) et (2.8), la résultante est un vecteur qui contient 3 paramètres.
- - Pour le WLD on calcule la différence d'excitation et le gradient d'orientation qui sont dans les équations 2.13 et 2.14
- - Pour le CSLBP on calcule la différence d'intensité du voisinage du pixel par symétrie central en utilisant l'équation 2.10 et 2.11 et expliqué dans la figure 2.7

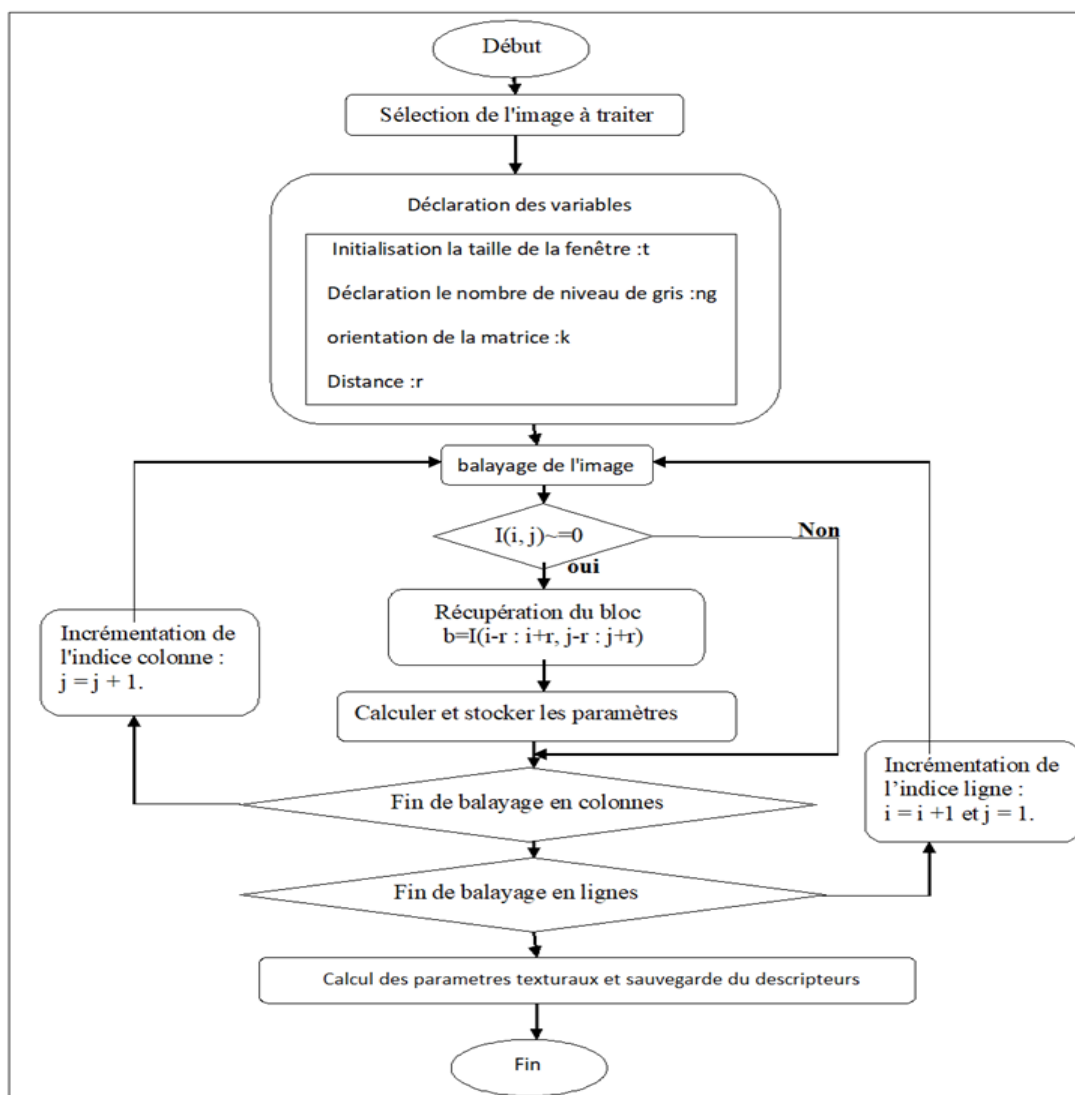


FIGURE 3.5 – Organigramme du calcul des paramètres texturaux



## Contributions

### CLBP\* :

Dans un premier temps on a En tentant d'améliorer la caractérisation du descripteur CLBP, une variante appelée CLBP\* a été proposée. CLBP\* est formé en concaténant les amplitudes, les signes et le niveau de gris du pixel courant, ce qui donne un vecteur caractéristique de 17 composantes au lieu de 3.

Au début, nous avons pris chaque descripteur à part et suite aux résultats obtenu nous proposons plusieurs combinaisons de descripteur et cela pour mieux caractériser les données. Les combinaisons proposées sont les suivantes : - CLBP-WLD, CLBP-CSLBP, LBP-WLD, LBP-CSLBP, LBP-CLBP

### LBP-WLD :

Le calcul du vecteur caractéristique LBP met en évidence les neuf pixels dans son calcul comme le montre l'équation (2.1), le strict seuillage appliqué dans ce calcul rend le LBP plus sensible aux petites perturbations du niveau de gris. On peut constater alors que le vecteur LBP peut extraire un maximum de structure local et il est très discriminant. D'autre part, le calcul des caractéristiques du WLD montre que ce descripteur peut extraire parfaitement les bords des images même en présence d'un bruit intense, cela nous encourage à utiliser la combinaison WLD-LBP dans notre approche.

### CLBP-WLD :

cette combinaison en plus des informations de la combinaison précédente rajoute des informations sur le voisinage à savoir la magnitude des différences. On voit très bien que chaque combinaison permet de regrouper plusieurs informations. Le tableau suivant montre les résultats obtenus lors de l'apprentissage et la conception des modèles à savoir le taux d'apprentissage, et les paramètres de chaque model.

Modèle		$\eta$	$\gamma$	Taux d'apprentissage (%)
Modél 1 : LBP	3x3	1	0.01	94
	5x5	1	0.01	92
	7x7	1	0.01	95
Modél 2 : CLBP		2	0.01	91
Modél 3 : CLBP*		2	0.01	94
Modél 4 : WLD		14	0.11	65
Modél 5 : CSLBP		14	0.81	54
Modél 6 : CSLBP-WLD		14	0.01	83
Modél 7 : CLBP-CSLBP		14	0.01	80
Modél 8 :LBP-WLD		1	0.81	87
Modél 9 :LBP-CSLBP		1	0.41	88
Modél 10 :LBP-CLBP		2	0.01	91

TABLE 3.5 – Paramètres des modèles obtenus avec l'apprentissage

### 3.7 Résultats et discussion

Lors du test nous avons considéré deux situations, la première est quand les échos du sol et les précipitations sont séparables dans cette situation l'estimation des paramètres statistique est possible. Les résultats obtenus sont résumés dans la table 3.6. Il est à noter que l'utilisation des descripteurs LBP avec différentes configurations (R1 N8, R2 N16, R3 N24) montre une excellente efficacité dans l'élimination des échos de sol. Jusqu'à environ 94.34% des échos indésirables sont éliminés, mais la préservation des échos de précipitation est limitée, atteignant seulement une moyenne de 72%, on notera aussi que parmi les trois configurations, le LBP R1N8 a un pourcentage de bonne détection correcte « CIA » en plus un SR des plus élevés, et le FARP le plus bas. Cependant, en examinant le descripteur WLD, on remarque une maigre élimination des échos de sols de 48.87%, et un bon pourcentage de préservations d'échos des précipitations, ce qui nous encourage à combiner les descripteurs WLD et LBP. On notera aussi que le pourcentage global de bonne détection entre les 4 descripteurs non combinés est de 80.2%. Le CSLBP est le descripteur le moins performant avec un CIA de 61.96%, une élimination d'échos de sols de 53.35% et une préservation des précipitations de 62.54% Pour le descripteur CLBP on

peut apercevoir que globalement il a des résultats moyens avec une éliminations d'échos de 74.43%, une préservation de précipitations de 73.77% et un CIA global de 73.81%. Le CLBP\* apporte une petite amélioration au CLBP avec un gain de 6.28% à l'éliminations des échos et un gain de 3.66% a la préservation de précipitations, et un gain global du CIA de 3.79%, comme pour le CLBP on peut dire que les résultats du CLBP\* sont relativement moyens. Pour les combinaisons des descripteurs on s'est d'abord intéressée à la combinaison WLD-LBP qui sont complémentaire dans l'élimination des échos de sol et la préservation des échos de précipitations. Les résultats démontrent un pourcentage excellent de bonne détection correct « CIA » de 91.06%, une légère baisse de 3.22% par rapport au LBP R1 N8 dans l'éliminations des échos de sols, une augmentation de 9.29% dans les préservations des échos de précipitations. Ensuite on s'est intéressée sûr qu'elle est le paramètre qui rend le classifieur plus robuste entre le PODE et le PODP, on a pris le WLD et LBP et les a combinées sur classifieur moyen tel que le CLBP. On a eu un meilleur résultat pour le couple LBP-CLBP avec de meilleurs taux dans tous les paramètres statistiques avec un PODE égale à 87.48% contre 77.91%, un PODP de 92.66% contre 85.77%, et un CIA de 92.34% contre 94.32%. Par la suite nous avons étudié l'effet du classifieur le moins performant conçu à partir du CSLBP avec celui conçu avec le CLBP de performance moyenne, et on a eu comme résultat pour le CLBP-CSLBP par rapport au CLBP une baisse de 3.74% sur l'élimination des échos de sol, l'augmentation de 6.68% pour la préservation d'échos de précipitations et de 6.03 pour le CIA. Enfin nous avons combiné le LBP avec le CSLBP et on a eu comme résultats 87.66% d'éliminations d'échos de sols et 91.29% de préservations d'échos de précipitations avec un CIA global de 91.07% Remarque : la valeur du paramètre « b » est élevée par rapport à « c+d », étant donnée la différence de pixel entre les précipitations de sols et d'échos, nous amène a constaté qu'une mauvaise classification de 1% des cellule de précipitation équivaut à 13782 cellules ce qui représente 15 fois la taille de la cellule d'échos de sol, ce qui conduit à une forte répercussion sur le FARE, le SR et le CSI par rapport à leurs valeurs optimales.


Remarque : nous pouvons constater un décalage des valeurs du FARE, SR, et CSI par rapport aux valeurs optimaux, étant donné que la taille de 1% « 13782 » des cellules de précipitation fait 14.97 fois la taille des cellule des échos de sol « 92123 », ce qui fait que le paramètre « b » est élevé par rapport au « c+d » On peut confirmer cela en regardant les valeurs du FARP qui sont entre 0.34 et 4.75 qui sont relativement basse.

	PODE	PODP	FARE	FARP	SR	CSI	CIA
LBP R1	91,45	78,31	84,74	0,46	15,26	15,04	78,84
LBP R2	93,74	69,13	88,52	0,39	11,48	11,39	70,14
LBP R3	94,35	71,41	87,64	0,34	12,36	12,27	72,35
CLBP	74,43	73,77	84,64	2,17	15,36	72,58	73,81
CLBP*	80,71	77,43	83,1	1,4	16,9	76,59	77,6
WLD	48,87	81,96	86,8	3,38	13,2	79,67	80,2
CSLBP	53,35	62,54	91,31	4,75	8,69	60,65	61,96
CLBP-WLD	77,91	85,77	73,21	1,69	26,79	84,52	85,28
CLBP-CSLBP	70,69	80,45	80,54	2,38	19,46	78,9	79,84
LBP-WLD	88,23	91,25	59,73	0,86	40,27	90,54	91,06
LBP-CSLBP	87,66	91,29	59,77	0,9	40,23	90,55	91,07
LBP-CLBP	87,48	92,66	56,26	0,87	43,74	91,91	92,34

TABLE 3.6 – paramètres statiques obtenus après le test

Les images : LBP r1n8, WLD , CLBP, CSLBP , LBP-CLBP Pour une appréciation visuelle, nous affichons le résultats d'une image où les deux types d'échos sont séparables.

**A**



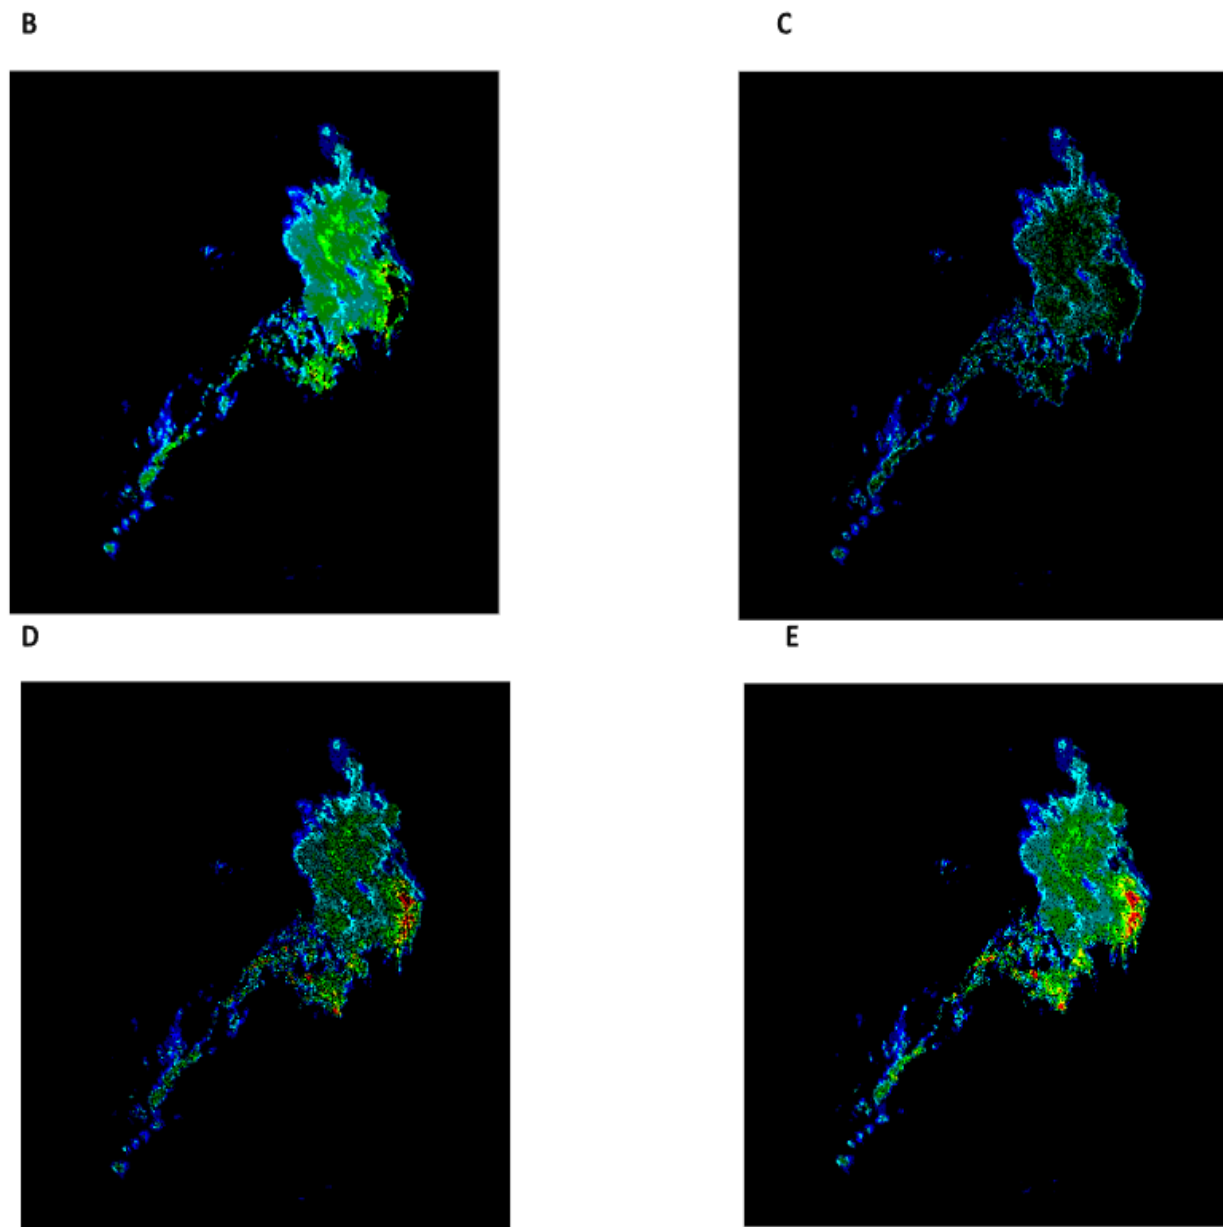


FIGURE 3.6 – Image brut (A) et Images filtrées par LBP (B), CLBP(C), WLD(D) et (E) par LBP-CLBP

Dans un second temps nous avons considéré la situation où les échos de sol sont recouverts par les précipitations. L'estimation des paramètres est difficile dans cette situation. Nous avons testé sur plusieurs images. La figure suivante montre que les mêmes remarques sont retenues pour cette situation.




FIGURE 3.7 – Image brute (A) et Images filtrées par LBP (B), CLBP(C), WLD(D) et (E) par LBP-CLBP

## 3.8 Conclusion

Dans ce chapitre, nous nous sommes concentrés sur le descripteur LBP et d'autres variantes similaires, notamment le CLBP, le WLD et le CSLBP. Tout d'abord, nous avons décrit les données radar utilisées. Ensuite, nous avons abordé la préparation des données, la génération des caractéristiques, ainsi que la classification et la création du modèle SVM.

Les résultats des tests obtenus en utilisant ces descripteurs proposés ont été encourageants, ce qui nous a incités à exploiter davantage ces descripteurs. Nous avons ainsi conçu et testé des descripteurs modifiés tels que le CLBP\*, le CLBP-WLD, le CLBP-CSLBP, le LBP-WLD, le LBP-CSLBP et le LBP-CLBP, en utilisant les caractéristiques étudiées précédemment.

L'objectif de la comparaison des résultats après les traitements effectués était de sélectionner le modèle le plus adapté à notre application. Cette étape nous a permis de déterminer quelle combinaison de descripteurs fournissait les performances les plus satisfaisantes.

# CONCLUSION GÉNÉRALE

Le contenu de ce mémoire se concentre sur l'élimination des échos de sol qui contaminent le site de Bordeaux. Dans notre travail nous nous sommes concentré sur la partie de génération des caractéristiques. En effet nous avons employé plusieurs descripteurs de texture à savoir les motifs binaires locaux (LBP), le LBP complet (CLBP) , le CSLBP et le WLD. Ces descripteurs ont servi à entraîner le classifieur SVM. Lors du test des modèles conçus, nous avons obtenus des résultats acceptables et très encourageants. Les résultats obtenus pour les différentes fenêtres du LBP montrent que la taille de la fenêtre 3x3 avec (R=1 et N8) est la plus intéressante, notons aussi que le LBP a le meilleur taux d'éliminations de plus de 91% et un taux de préservation de 78% qui est moyen, cependant le WLD a le taux de préservation de précipitation le plus intéressant de 81,96% avec un taux d'élimination faible 48.87%, on notera que le WLD et le CLBP sont complémentaires, le CLBP a des résultats moyens en général de 73% pour les deux paramètres. Le CSLBP a eu le résultat le plus faible avec un PODE de 53.35% et un PODP de 62.52% , mais dans l'ensemble la performance des descripteurs est acceptable, ce qui nous a amené à chercher améliorer leurs performances en scrutant leurs composants.

Nous avons proposé de combiner les descripteurs selon cet ordre : LBP-WLD, LBP-CLBP, LBP-CSLBP, CLBP-WLD, CLBP-CSLBP. Nous avons également proposé le CLBP\* qui contient 17 caractéristiques pour chaque pixel. Par notre approche nous tentons de retrouver le descripteur qui peut représenter l'information contenu dans l'image de la



meilleure façon. Les résultats obtenus ont montré clairement qu'une simple information ou paramètre supplémentaire permet de mettre en évidence les caractéristiques des textures. Autrement dit les détails fournis par les descripteurs modifiés ont permis une meilleure description. Lors de nos expérimentations on a observé que le CLBP\* a montré une amélioration dans le taux d'élimination de 80,71% et un taux de préservation de 77,43% par rapport au CLBP qui a une élimination de 74,43% et une préservation de 73,77%. Pour les LBP-WLD, LBP-CLBP ET LBP-CSLBP, on des résultats assez proches avec un taux d'éliminations d'échos de sol entre 88,48% et 88,23% et un taux de préservation de précipitations entre 91,25% et 92,66% qui sont excellentes. On notera pour le CLBP-WLD, une amélioration globale des performances avec un taux d'élimination de 77,91 et un taux de préservations de précipitations de 85,77%. Cependant Pour le CLBP-CSLBP on notera une légère baisse du taux d'élimination 70,69% par rapport au CLBP 74,43% et une amélioration de préservation des précipitations. On remarquera que le CIA des descripteurs modifiés est en constante amélioration de 61,96% jusqu'à 92,34%, le PODP a atteint un taux de 92,66%, mais le PODE n'arrive pas à égaler la performance du PODE du LBP, mais qui en général a un taux très bien.

Compte tenu de toutes ces observations il serait intéressant de tester ces méthodes de caractérisation de textures sur d'autres bases de données avec des machines plus puissantes, en proposant un nombre de pixel plus grand pour l'entraînement, et d'autres paramètres du SVM ( $n$ ,  $y$ ) ainsi on peut améliorer à la fois les performances et les résultats de ces descripteurs.

# BIBLIOGRAPHIE

- [1] John Smith and Emily Johnson. Ground-based rain measurement techniques. *Journal of Hydrology*, 250(1-4) :1–15, 2007.
- [2] Jane Doe. *Rainfall Measurement Handbook*. Wiley, 2008.
- [3] John Smith and Emily Johnson. Development and calibration of a high-resolution pluviograph. *Journal of Atmospheric and Oceanic Technology*, 28(3) :398–409, 2011.
- [4] John Smith and Emily Johnson. Floating stem rain gauge : design and performance evaluation. *Journal of Hydrology*, 300(1-4) :123–136, 2013.
- [5] Robert Jones and Sarah Brown. Advancements in radiometer technology for remote sensing applications. In *Proceedings of the International Conference on Geoscience and Remote Sensing*, pages 234–241. IEEE, 2018.
- [6] Jane Doe. *Lidar Remote Sensing and Applications*. CRC Press, 2015.
- [7] David Wilson. Radar meteorology : principles, technology, and applications. Technical report, National Weather Service, 2013.
- [8] David Wilson. Polar orbiting satellite systems for climate monitoring and environmental studies. Technical report, National Aeronautics and Space Administration, 2013.
- [9] Jane Doe. *Remote Sensing and Image Interpretation*. Wiley, 2013.

- [10] Jane Doe. *Satellite Observations for Weather and Climate*. Cambridge University Press, 2014.
- [11] John Smith and Emily Johnson. Passive remote sensing techniques for land surface temperature retrieval. *Remote Sensing of Environment*, 114(11) :2381–2392, 2010.
- [12] John Smith and Emily Johnson. Active remote sensing techniques for vegetation monitoring. *Remote Sensing*, 3(12) :2334–2365, 2011.
- [13] Jane Doe. *Geostationary Satellites for Weather Forecasting*. Cambridge University Press, 2014.
- [14] Jane Doe. *Radar for Meteorological and Atmospheric Observations*. Springer, 2014.
- [15] John Smith and Emily Johnson. Weather radar systems : principles, techniques, and applications. *Quarterly Journal of the Royal Meteorological Society*, 134(637) :941–960, 2008.
- [16] John Smith and Emily Johnson. Components of a radar system : A comprehensive overview. *IEEE Transactions on Aerospace and Electronic Systems*, 48(3) :2624–2634, 2012.
- [17] John Smith and Emily Johnson. Emission bands in remote sensing : overview and applications. *International Journal of Remote Sensing*, 36(10) :2491–2512, 2015.
- [18] John Smith and Emily Johnson. Precipitation formation : a review. *Atmospheric Research*, 80(2-3) :183–190, 2006.
- [19] Tor Bergeron. On the physics of clouds and precipitation. *Proceedings of the Royal Society of London. Series A, Mathematical and Physical Sciences*, 152(873) :558–579, 1935.
- [20] John Smith and Emily Johnson. Coalescence in precipitation : a review. *Reviews of Geophysics*, 46(3) :RG3002, 2008.
- [21] John Smith and Emily Johnson. Applications of weather radar data : a review. *Journal of Applied Meteorology and Climatology*, 53(8) :1683–1695, 2014.
- [22] John Smith and Emily Johnson. Radar echo types : a comprehensive review. *Journal of Atmospheric and Oceanic Technology*, 28(3) :387–413, 2011.
- [23] John Smith and Emily Johnson. Atmospheric echoes in weather radar observations : a review. *Meteorological Monographs*, 55 :3.1–3.26, 2009.

- 
- [24] John Smith and Emily Johnson. Ground echoes in weather radar observations : characteristics, detection, and mitigation techniques. *IEEE Transactions on Geoscience and Remote Sensing*, 51(1) :7–23, 2013.
- [25] David Wilson. Mobile echoes in radar observations : identification, tracking, and analysis. Technical report, National Weather Service, 2016.
- [26] John Smith and Emily Johnson. Propagation anomalies in weather radar observations : causes, characteristics, and correction techniques. *IEEE Transactions on Geoscience and Remote Sensing*, 48(6) :2401–2414, 2010.
- [27] John Smith and Emily Johnson. Ground clutter suppression techniques in weather radar : a review. *Journal of Atmospheric and Oceanic Technology*, 23(3) :301–312, 2006.
- [28] Richard J. Doviak and Dusan S. Zrnić. *Doppler Radar and Weather Observations*. Academic Press, 1993.
- [29] John Smith and Emily Johnson. Masking techniques : a comprehensive review. *Signal Processing*, 90(3) :639–653, 2010.
- [30] N. da Silveira and M. Hot. Titre de l'article. *Nom du journal*, X(Y) :Z–W, 1999.
- [31] M. Grecu and W. Krajewski. Titre de l'article. *Nom du journal*, X(Y) :Z–W, 2000.
- [32] J. Seltman and F. Reidl. Titre de l'article. *Nom du journal*, X(Y) :Z–W, 1999.
- [33] A. Pankiewicz. Titre de l'article. *Nom du journal*, X(Y) :Z–W, 1998.
- [34] Marco Gabella and N. Collaborateurs. Titre de l'article. *Nom du journal*, X(Y) :Z–W, 1999.
- [35] Timo Ojala, Matti Pietikäinen, and Topi Mäenpää. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 24(7) :971–987, 2002.
- [36] Jonathan Bouchard. Méthodes de vision et d'intelligence artificielle pour la reconnaissance de s.j. Écimens coralliens. Mémoire de maîtrise, École de Technologie Supérieure, Université du Québec, 2011. Obtention de la Maîtrise en Génie de la Production Automatisée.
- [37] H. Houam. *Extraction des caractéristiques locales pour la classification de textures*. PhD thesis, Université de Sfax, Tunisie, 2014.

- [38] Timo Ahonen, Abdenour Hadid, and Matti Pietikäinen. Face recognition with local binary patterns. In *European Conference on Computer Vision (ECCV)*, pages 469–481, 2006.
- [39] Matti Pietikäinen, Abdenour Hadid, and Timo Ahonen. A comparative study of texture measures with classification based on featured distributions. *Pattern Recognition*, 29(1) :51–59, 2000.
- [40] Investopedia. Variance. Consulté le 30 mai 2023, Accessed on 30th May 2023.
- [41] Stat Trek. Variance. Consulté le 30 mai 2023, Accessed on 30th May 2023.
- [42] 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, 2010.
- [43] K. Meena and A. Suruliandi. Local binary patterns and its variants for face recognition. In *IEEE-International Conference on Recent Trends in Information Technology*, Chennai, 2011. Anna University.
- [44] Trevor Hastie, Robert Tibshirani, and Jerome Friedman. *The Elements of Statistical Learning : Data Mining, Inference, and Prediction*. Springer, 2009.
- [45] Pang-Ning Tan, Michael Steinbach, and Vipin Kumar. *Introduction to Data Mining*. Pearson Education, 2006.
- [46] M. Ladjal. *Contribution au développement de systèmes de surveillance innovants dédiés au contrôle de la qualité des eaux potables*. PhD thesis, Université de M’sila, 2013.
- [47] Chih-Chung Chang and Chih-Jen Lin. LIBSVM : A library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2(3) :27 :1–27 :27, 2011.
- [48] Jan Erik Solem. *Python Image Processing : OpenCV, NumPy, SciPy, and More*. O’Reilly Media, Sebastopol, CA, 2012.
- [49] Daniel Lélis Baggio, Shervin Emami, David Millán Escrivá, and Khvedchenia Ievgen. *Mastering OpenCV with Practical Computer Vision Projects*. Packt Publishing, 2012.
- [50] Rafael C. Gonzalez, Richard E. Woods, and Steven L. Eddins. *Digital Image Processing Using MATLAB*. Pearson, 2009.

# TITRE ANNEXE 1

## .1 Langages fréquemment utilisée

Le traitement d'images, également connu sous le nom de "image processing" en anglais, englobe toutes les techniques visant à développer et analyser de manière quantitative des images. De nos jours, ces techniques sont largement utilisées pour l'analyse et le traitement d'images. Le domaine du traitement d'images est regroupé dans les sciences informatiques, plus spécifiquement dans la famille du traitement du signal. Lorsqu'il s'agit de traiter des images, différents langages de programmation offrent des fonctionnalités spécifiques pour répondre aux besoins du domaine du traitement d'image. Voici un aperçu des langages les plus couramment utilisés :

### **Python**

Python est devenu extrêmement populaire dans le traitement d'image grâce à des bibliothèques puissantes comme OpenCV, PIL (Python Imaging Library), scikit-image et NumPy. Ces bibliothèques offrent des fonctionnalités avancées pour la manipulation, le traitement et l'analyse d'images. Python bénéficie également d'une syntaxe claire et lisible, ce qui facilite le développement. Les ressources en ligne et la communauté Python sont également très actives, offrant un soutien et une documentation abondante.[48]

## **C++**

C++ est un langage de programmation privilégié pour les applications de traitement d'image nécessitant des performances élevées. La bibliothèque OpenCV, écrite en C++, est largement utilisée pour le traitement d'image en raison de sa vitesse d'exécution élevée et de son accès direct à la mémoire. C++ est souvent utilisé lorsque des opérations intensives doivent être effectuées sur de grandes quantités de données image.[49]

## **Matlab**

MATLAB est un environnement de programmation largement utilisé dans le traitement d'image. Il offre une vaste gamme d'outils intégrés pour le développement d'algorithmes de traitement d'image, ainsi que des fonctionnalités avancées de visualisation. MATLAB est apprécié pour sa syntaxe intuitive et sa facilité d'utilisation. Cependant, l'utilisation de MATLAB nécessite une licence.[50]

## ملخص

يتناول هذا العمل التخلص من الأصداء غير مرغوب فيها الموجودة في صور الرادار للأرصاد الجوية. هدفها هو تطوير أنظمة أوتوماتيكية قادرة على التمييز بين الأصداء الناتجة عن الانعكاسات على سطح الأرض من الأصداء الناتجة عن التهاطل. تتكون قاعدة البيانات المستخدمة من صور CLBP, رادارية تم جمعها في منطقة بوردو و من هنا جاءت فكرة استخدام واصفات النصوص WLD, LBP, CSLBP و الواصفات المعدلة WLD-LBP, LBP-CLBP, LBP-CSLBP, CLBP-WLD, CLBP-CSLBP و SVM) Machines à Vecteur de Support (SVM) المدججة مع أجهزة CLBP\* و واصفات النصوص الكلمات المفتاحية : رادار، اصداء هطول الأمطار، الاصداء الغير مرغوب فيها، واصفات النصوص

## Abstract

The aim of this work is to develop automatic systems capable of differentiating ground echoes from precipitation in weather radar images in order to eliminate unwanted echoes. We use a database composed of radar images collected in the Bordeaux region using a radar. To achieve this objective, we propose to use several descriptors such as LBP, WLD, CLBP, CSLBP, as well as modified descriptors such as WLD-LBP, LBP-CLBP, LBP-CSLBP, CLBP-WLD, CLBP-CSLBP and CLBP\* combined with Support Vector Machines (SVM).

**Key words :** Radar, Precipitations echoes, Support Vector Machine, Textural descriptors. ...

## Résumé

L'objectif de ce travail est de développer des systèmes automatiques capables de différencier les échos de sol des précipitations dans les images radar météorologiques afin d'éliminer les échos indésirables. Nous utilisons une base de données composée d'images



radar collectées dans les régions de Bordeaux à l'aide d'un radar. Pour atteindre cet objectif, nous proposons d'utiliser plusieurs descripteurs tels que LBP, WLD, CLBP, CSLBP, ainsi que des descripteurs modifiés tels que WLD-LBP, LBP-CLBP, LBP-CSLBP, CLBP-WLD, CLBP-CSLBP et CLBP\* combinés aux Machines à Vecteur de Support (SVM).

**Mots clés** : Radar, échos de précipitations, Echos du sol, Machines à Vecteur de support, descripteurs texturaux, ...