



République Algérienne Démocratique et  
Populaire Ministère de l'enseignement supérieur et de la  
recherche scientifique



Université Larbi Tébessi - Tébessa  
Faculté des Sciences Exactes et des Sciences de la Nature et de la Vie  
Département : Mathématiques et Informatique

Mémoire de fin d'étude Pour l'obtention du diplôme de MASTER  
Domaine : Mathématiques et Informatique  
Filière : Informatique  
Option : Réseaux Et Sécurité Informatique

Thème

# ***Contribution à la reconnaissance de chiffres et mots manuscrits***

**Présenté Par :**  
Hadjer Boumaagouda

**Encadrer par :**  
Mr M. Aouine MAA Université Larbi Tébessa - Encadreur

**Devant le jury :**  
Mr C. Djeddi MCA Université Larbi Tébessa - Président  
Mr A. Zemar MAA Université Larbi Tébessa - Examineur

**Année 2020**

## Remerciements

*En tout premier lieu, je remercie le bon dieu tout puissant de m'avoir donné la force pour survivre, ainsi que l'audace pour dépasser toutes les difficultés.*

*Je tiens à remercier sincèrement Monsieur **Aouine Mohammed**, qui en tant qu'encadreur de ce mémoire, s'est toujours montré à l'écoute et très disponible tout au long de la réalisation de notre travail.*

*Egalement, je remercie tous les membres de jury : **Djeddi Chawki, Zemar Ammar**, pour l'honneur qu'ils m'ont fait en acceptant de juger mon travail.*

*Enfin, je adresse mon plus sincères remerciements à tous mon proches et amis, qui m'ont toujours soutenus et encouragés au cours de la réalisation de ce mémoire. Merci à tous et à toutes.*

## Dédicaces

*A mes chers parents, pour tous leurs sacrifices, leur amour, leur tendresse, leur soutien et leurs prières tout au long de mes études,*

*A mes chères sœurs **Akila, Imene** et **Asma** pour leurs encouragements permanents, et leur soutien moral,*

*A mes chers frères **Tarek** et **Mouhyieddine** pour leur appui et leur encouragement,*

*A mes chers nièces **Adam** et **Diala** pour apporter le sourire et la joie,*

*A mes meilleurs amis **Rayen Abdellaoui, Khedidja Kamach** et **Wafa Djelbani** pour leurs assistance et leurs encouragements,*

*A toute ma famille pour leur soutien tout au long de mon parcours universitaire,*

*Que ce travail soit l'accomplissement de vos vœux tant allégués, et le fruit de votre soutien infaillible,*

*Merci d'être toujours là pour moi.*

*Hadjer*

## Résumé

Un système de reconnaissance d'écriture et chiffres manuscrits est constitué de plusieurs étapes: acquisition, prétraitement, segmentation, extraction des caractéristiques, classification et post-traitement.

L'extraction des caractéristiques représentent un processus très important qui a un impact observable sur l'efficacité du système de reconnaissance. Donc il est nécessaire de définir les caractéristiques les plus pertinentes pour obtenir des performances de reconnaissance élevées.

Dans ce travail nous intéressons à la méthode d'extraction des caractéristiques LBP, ensuite pour valider et atteindre des bons résultats de reconnaissance on utilise le classifieur SVM.

**Mots-clés** : un système de reconnaissance des chiffres manuscrits, extraction des caractéristiques, classification, taux de reconnaissance, LBP, SVM, CVL.

## *Abstract*

A system of handwriting Words and digits recognition consists of several stages: acquisition, preprocessing, segmentation, feature extraction, classification and postprocessing.

The extraction of features is a very important process which has an observable impact on the efficiency of the recognition system. So it is necessary to define the most relevant features to obtain high recognition performance.

In this work we are interested in the method of extracting features which is LBP, then in order to validate and achieve good recognition results we use the SVM classifier.

**Keywords:** system for recognizing handwritten digits, extraction of characteristics, classification, recognition rate, LBP, SVM, CVL.

## ملخص

يتكون نظام التعرف على الكلمات والأرقام المكتوبة بخط اليد من عدة مراحل: الحصول عليها، المعالجة المسبقة، التجزئة، استخراج الميزات، التصنيف والمعالجة اللاحقة.

يعتبر استخراج الميزات عملية هامة للغاية لها تأثيرا ملحوظا على كفاءة نظام التعرف. لذلك من الضروري جدا تحديد الخصائص الأكثر دلالة للحصول على أداء تعرف عالي.

في هذا العمل، نهتم بطريقة استخراج الخصائص LBP ثم للتحقق للتحقق من صحة نتائج التعرف وجودتها نستخدم SVM كمصنف.

**الكلمات المفتاحية:** نظام التعرف على الأرقام المكتوبة بخط اليد، استخراج الخصائص، التصنيف، معدل التعرف, LBP, SVM, CVL.

## Table de matière

---

Introduction générale .....	11
<b>Chapitre 1 : La reconnaissance d'écriture manuscrite et des chiffres</b>	
1. Introduction .....	14
2. Différents aspects de reconnaissance .....	15
2.1. Reconnaissance en-ligne/hors-ligne .....	15
2.1.1. Reconnaissance en-ligne .....	15
2.1.2. Reconnaissance hors-ligne .....	16
2.2. Approches de reconnaissance hors ligne .....	16
2.2.1. Approche globale.....	17
2.2.2. Approche analytique.....	17
2.3. Processus générale d'un système de reconnaissance hors ligne :.....	17
2.3.1. Phase d'acquisition.....	18
2.3.2. Phase de prétraitement.....	18
2.3.2.1. La binarisation .....	18
2.3.2.1.1. Seuillage global .....	20
2.3.2.1.2. Seuillage adaptif .....	20
2.3.2.2.Élimination de bruit.....	20
2.3.2.3. Le lissage .....	21
2.3.2.4. La squelettisation(Thinning) .....	21
2.3.2.5. La normalisation.....	22
2.3.2.5.1. Normalisation de taille .....	22
2.3.2.5.2. La normalisation de l'inclinaison (Redressement).....	23
2.3.3. Phase de segmentation.....	23
2.3.3.1. Segmentation explicite .....	24
2.3.3.2. Segmentation implicite .....	24
2.3.4. Phase d'extraction des caractéristiques .....	25
2.3.5. Phase de classification.....	25
2.3.5.1. Classification supervisée .....	26
2.3.5.2. Classification non supervisée .....	26
2.3.5.2. Méthodes de classification de la reconnaissance.....	27

2.3.5.2.1. Approche statistique .....	27
2.3.5.2.2. Approche structurelle .....	28
2.3.5.2.3. Approche stochastique.....	28
2.3.5.2.4. Approche hybride .....	29
2.4. Méthodes de classification statistiques.....	29
2.4.1. Réseaux de neurones .....	29
2.4.2. Les Machines à Vecteur Support (SVM) .....	30
2.4.3. Le classifieur du K plus proches voisins .....	31
2.5. Post-traitements .....	32
3. Conclusion.....	33

## **Chapitre 2 : Extraction des caractéristiques**

1. Introduction .....	35
2. Caractéristiques d'une image numériques .....	36
2.1. Dimension.....	36
2.2. Résolution.....	36
2.3. Bruit.....	37
2.4. Histogramme .....	37
2.5. Luminance .....	38
2.6. Contraste.....	38
2.7. Bords.....	39
2.8. Coin .....	39
2.9. Blobs / régions d'intérêt .....	40
2.10. Couleur .....	40
3. Extraction des caractéristiques .....	40
3.1. Problème de sélection des caractéristiques.....	41
3.2. Types des caractéristiques .....	42
3.2.1. Caractéristiques topologiques ou métrique .....	42
3.2.2. Caractéristiques structurelles .....	42
3.2.3. Caractéristiques statistiques.....	43
3.2.4. Caractéristiques globales ou locales .....	43
3.2.5. Superposition des modèles et corrélation.....	43
3.3. Méthodes d'extractions des caractéristiques .....	43
3.3.1. Histogramme de gradient Orienté (HOG) .....	43

3.3.2. Filtre de Gabor.....	44
3.3.3. FAST (détecteur de coin) .....	45
3.3.4. Détecteur SURF.....	45
3.3.5. LBP (Local Binary Pattern).....	46
3.3.6. OBIF (Oriented Basic Image Feature) .....	46
4. Techniques d'extraction des caractéristiques :.....	48
5. Techniques déployées dans le système de reconnaissance des chiffres manuscrits.....	49
5.1. LBP (Local Binary Pattern).....	49
5.1.1. Principe de LBP.....	50
5.1.2. Méthodologie.....	51
5.1.3. Autres variantes de LBP .....	53
5.1.3.1. LBP amélioré (ILBP) .....	54
5.1.3.2. LBP invariant de rotation (RILBP) .....	54
5.1.3.3. Rotation invariante et uniforme LBP (RIULBP).....	55
5.1.3.4. LBP robuste et uniforme (RULBP).....	56
5.1.4. Avantages et inconvénients de LBP .....	57
5.2. Classification en SVM.....	58
5.2.1. Définition.....	58
5.2.2. Apprentissage statistique et SVM .....	59
5.2.3. Rôle d'apprentissage statistique en SVM .....	59
5.2.4. Le sur-apprentissage et le sous-apprentissage .....	60
5.2.4.1. Sur-apprentissage .....	60
5.2.4.2. Sous-apprentissage .....	61
5.2.5. Principe de SVM .....	61
5.2.6. Types de SVM.....	62
5.2.7. Fonctions noyaux (Kernel).....	63
5.2.8. Avantages et inconvénients des SVM .....	63
6. Travaux ultérieurs dans la reconnaissance des chiffres manuscrits .....	65
7. Conclusion.....	66
<b>Chapitre 3 : Conception et implémentation</b>	
1. Introduction .....	68
2. Présentation de notre technique .....	69
3. Schéma générale.....	70

4. Implémentation.....	71
4.1 Environnement de développement .....	71
4.1.1 Ressources matériels .....	71
4.1.2 Ressource logiciel.....	71
4.2 Base de données CVL .....	71
5. Résultats et discussions .....	72
6. Conclusion.....	74
Conclusion générale .....	76

## Liste des figures

---

Figure 1 : Exemple d'un système de reconnaissance en ligne cas du stylo numérique .....	15
Figure 2 : Exemple d'un système de reconnaissance hors ligne des chèques bancaires .....	16
Figure 3 : schéma général d'un système de reconnaissance d'écriture manuscrite et chiffres	17
Figure 4 : Effet de seuillage sur la qualité des caractères [5] .....	19
Figure 5 : Résultat de la binarisation de différentes images par le même seuil $s=120$ [5] .....	19
Figure 6 : Principe de la binarisation par seuillage global [5] .....	20
Figure 7 : Exemple d'élimination de bruit d'une image [8] .....	21
Figure 8 : Exemple de squelettisation [8] .....	22
Figure 9 : Exemple de redressement .....	23
Figure 10 : Exemple de segmentation .....	24
Figure 11 : Exemple d'une Classification par les réseaux de neurones convolutifs. ....	30
Figure 12 : Exemple Représentation en 3D d'une Classification de deux ensembles de points en SVM.....	31
Figure 13 : Exemple de dimension d'image numérique.....	36
Figure 14 : Exemple de résolution d'image, PPI signifie Pixel Per Inch et indique le nombre de pixels par pouce .....	37
Figure 15 : Exemple d'histogramme d'intensités de gris dans une image .....	38
Figure 16 : Exemple détection des bords dans une image.....	39
Figure 17 : Exemple de coin dans une image .....	40
Figure 18 : Exemple de Calcul de base du LBP .....	51
Figure 19 : Exemple Illustration du calcul du modèle binaire local (LBP) (a) exemple image, (b) patron binaire par seuillage et (c) matrice de poids .....	52
Figure 20 : Illustrations de pixels locaux voisins .....	52
Figure 21 : Illustration de la génération de valeur ILBP pour une fenêtre d'image grise $3 \times 3$ , où $P = 8$ , $R = 1$ et $\lfloor I \rfloor_{\text{mean}} = 94$ .....	54
Figure 22 : Illustration de la génération de valeur RILBP pour une fenêtre d'image grise $3 \times 3$ , où $P = 8$ et $R = 1$ .....	55
Figure 23 : Illustration de la génération de valeur RLBP pour une fenêtre d'image grise $3 \times 3$ , où $p = 8$ et $R = 1$ . Ici, la valeur de $th = 90$ .....	56
Figure 24 : Illustrations de LBP extraction de l'histogramme des caractéristiques dans un exemple de détermination du sexe de l'écrivain selon son écriture .....	56
Figure 25 : Exemple de classification de deux classes en SVM .....	59
Figure 26 : Exemple des cas d'apprentissage dans une SVM :(a)sous-apprentissage (b) le cas idéale (c)sur-apprentissage .....	61
Figure 27 : Les différents composants de base d'une SVM.....	62
Figure 28 : Schéma général du système de reconnaissance de chiffres manuscrits .....	70

## Liste des tableaux

---

Tableau 1 : Comparaison entre quelques techniques d'extraction des caractéristiques .....	49
Tableau 2 : Travaux ultérieurs dans la reconnaissance des chiffres .....	65
Tableau 3 : Résultats de classification pour LBP (P, R) .....	72
Tableau 4 : Résultats de classification pour LBP (P, R) .....	73

---

# **Introduction Générale**

---

## Introduction générale

L'écriture cursive est aujourd'hui le moyen le plus naturel pour la communication humaine et l'échange d'informations. Cependant, l'ère numérique demande des assistants numériques capables de traduire ou de transcrire automatiquement les textes en différentes langues parlés ou écrits sur différents supports tels que le papier ou l'encre électronique. La reconnaissance automatique de l'écriture manuscrite est une réponse à un tel besoin.

Alors, la reconnaissance de l'écriture manuscrite est un domaine de recherche très active dans le traitement d'image et de la reconnaissance des formes au cours de ces dernières années. Il contribue énormément à l'avancement du processus d'automatisation et peut améliorer l'interface entre l'homme et la machine dans de nombreuses applications.

Ce domaine a connu un grand succès dans le monde réel, allant du traitement automatique des chèques à l'extraction automatique d'information des formulaires, de registres, ou de courriers.

Plusieurs travaux de recherche se sont concentrés sur de nouvelles techniques et méthodes qui réduiraient le temps de traitement tout en offrant une précision de reconnaissance plus élevée.

Cependant, la reconnaissance de texte manuscrite sans contrainte reste un problème ouvert qui suscite un regain d'intérêt en tant que domaine de recherche actif en raison de la prolifération des Smartphones et des tablettes où se fait l'écriture avec doigt ou stylet est susceptible d'être un mode de saisie potentiellement pratique pour ces dispositifs de poche.

Dans ce mémoire, on s'intéresse à la reconnaissance d'écriture manuscrite et des chiffres hors-ligne qui reste un thème de recherche illimité. En effet, bien que le nombre de classes naturelles soit très large et à l'intérieur de chacune d'entre elles, se trouve une très grande variabilité de caractère, de plus, les conditions de la reconnaissance automatique sont souvent relativement précaires et la variabilité du matériel utilisé tendent à compliquer la reconnaissance.

Dans ce travail, on se concentre sur les méthodes d'extraction des caractéristiques, en particulier la méthode LBP, grâce à l'apparition des nouvelles techniques d'extraction des améliorations progressives sont toujours développés par combinaison de méthodes existantes.

Les contraintes de performance et la sélection de l'algorithme de classification approprié reste un problème pour la plupart du chercheurs, mais avec un bon choix elles fournissent des précisions satisfaisantes.

L'objet de ce mémoire est l'implémentation et l'amélioration de la méthode d'extraction des caractéristiques LBP afin d'augmenter le taux de reconnaissance et de réaliser des bons résultats pour la reconnaissance d'écriture et chiffres manuscrits.

Ce mémoire est organisé en trois chapitres :

- Le premier chapitre pour présenter les phases constituant le système de reconnaissance d'écritures manuscrites, ainsi nous abordons les différents types des classifieurs.
- Le deuxième chapitre un état de l'art sur la phase d'extraction des caractéristiques, en va définir les techniques et les méthodes d'extraction des caractéristiques les plus connus. Ensuite on détaille la méthode LBP et le classifieur SVM.
- Le dernier chapitre, va mettre l'accent sur notre conception de notre approche et les résultats obtenus.

---

# **Chapitre 1 :**

La reconnaissance  
d'écriture manuscrite et des  
chiffres

---

## 1. Introduction

La reconnaissance de l'écriture manuscrite et des chiffres fait toujours l'objet des recherches intensives, elle a attendu ces dernières années une grande évolution, et des accomplissements dans les différents domaines de la vie humaine et spécialement dans le champ industriel, elle présente un grand intérêt dans la réalisation de nombreuses et grandes applications dans divers secteurs d'activités parmi lesquelles on peut citer :

- La reconnaissance des montants littéraux et des montants numériques manuscrits pour l'authentification et la lecture de chèques bancaires.
- La lecture des formulaires et de documentation administratifs.
- La lecture des adresses postales et le tri du courrier automatique.
- l'échange de fichiers informatisés à distance pour les transactions de télécommunications.
- L'indexation et l'archivage automatique des documents.
- La reconnaissance de documents techniques comme : les schémas électronique, plans architecturaux.
- La transcription assistée par ordinateur utilisée dans la reconnaissance du manuscrit mono-scripteur.
- La reconnaissance de numéros minéralogiques pour la gestion et l'organisation routières.
- La recherche d'information dans une base de documents manuscrits.
- L'aide à la lecture pour les aveugles : Les systèmes de reconnaissance associés à des synthétiseurs vocaux permettent la compréhension de documents et livres pour non-voyants.

Dans ce chapitre nous présentons les différentes phases de reconnaissance d'écriture manuscrite et des chiffres.

## 2. Différents aspects de reconnaissance

La reconnaissance d'écriture est un traitement informatique qui permet de transformer un texte sous forme d'image en un fichier texte, c'est le processus inverse de la production en impliquant le passage de la forme manuscrite papier en forme logique.

Le processus se déroule en plusieurs étapes, l'initialisation est par l'acquisition du texte ou bien l'image qu'on va traiter.

Selon du type dispositifs d'acquisition et de données traitées et l'application visée. Il existe deux modes des systèmes de reconnaissance.

-La reconnaissance en ligne.

-La reconnaissance hors-ligne.

### 2.1. Reconnaissance en-ligne/hors-ligne

Les deux différents modes de reconnaissance, ayant des caractéristiques, un outillage spécifique et des algorithmes d'extraction tout dépend du la philosophie de l'application, le domaine et l'utilisation de chaque système.

#### 2.1.1. Reconnaissance en-ligne

C'est le cas notamment des applications stylo numériques, les agendas électroniques ou bien les tablettes tactiles. C'est une opération effectuée en temps réel et dite donc dynamique c'est-à-dire pendant le traçage des caractères [1].

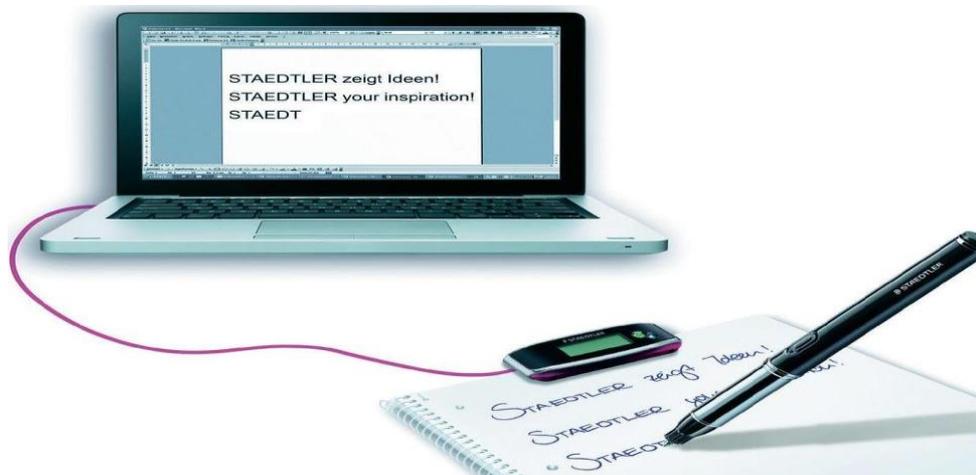


Figure 1 : Exemple d'un système de reconnaissance en ligne cas du stylo numérique

Le signal capté va constituer une suite de coordonnées de points correspondant à la position du stylo, il contient des informations absentes dans les signaux hors-ligne tel que l'ordre des caractères et leur sens de parcours.

Ce mode de reconnaissance est généralement plus efficace et fiable en termes de modification, correction des données saisies et il nécessite aussi un matériel coûteux, donc il possède le meilleur taux de reconnaissance.

### 2.1.2. Reconnaissance hors-ligne

Il s'agit de reconnaissance optique de caractères, elle s'appelle aussi la reconnaissance statique des données qui sont présentées sous forme des instants d'encre numérique, on parle là d'une image traitée comme un ensemble (somme) de pixels [1].

Ce mode est plus compliqué que la reconnaissance en ligne, il est favorisé pour les traitements asynchrones, comme la lecture de chèques bancaires ou le tri postal.



Figure 2 : Exemple d'un système de reconnaissance hors ligne des chèques bancaires

Le signal hors-ligne est une image en noir et blanc sous la forme des degrés de gris. Cette technique utilise des méthodes basées sur les modèles Markov cachés [2].

## 2.2. Approches de reconnaissance hors ligne

En reconnaissance hors-ligne des mots manuscrits et chiffres il existe deux approches :

-Une approche globale.

-Une approche analytique.

### 2.2.1. Approche globale

L'approche globale se base sur une seule description de l'image du mot, vue comme une entité indivisible. Contenant de beaucoup d'informations, en effet, la discrimination de mots proches est très difficile, et l'apprentissage des modèles demande un grand nombre d'échantillons qui est souvent difficile à réunir [3].

Cette approche est généralement utilisée pour la réduction des mots candidats dans une reconnaissance à vocabulaire réduit.

### 2.2.2. Approche analytique

L'approche analytique isole les caractères des mots pour segmenter l'image d'écriture manuscrite d'entrée en un ensemble de fragments morphologiques significatifs inférieur aux graphèmes. La reconnaissance des mots est basée sur la reconnaissance des entités segmentées, ce qui peut générer plusieurs types d'erreurs. Selon cette approche la reconnaissance est un processus de relaxation alternant des deux phases : la segmentation et l'identification des segments [3][4].

## 2.3. Processus générale d'un système de reconnaissance hors ligne :

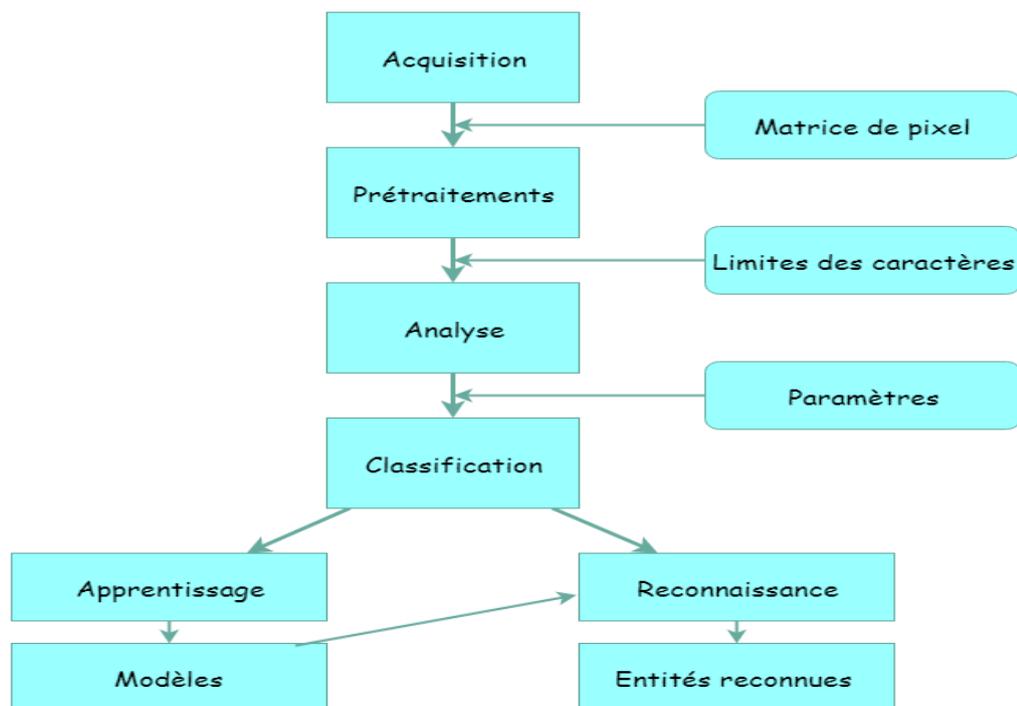


Figure 3 : schéma général d'un système de reconnaissance d'écriture manuscrite et chiffres

### 2.3.1. Phase d'acquisition

L'acquisition permettant la conversion du document papier sous la forme d'une image numérique (bitmap) [1].

Elle est basée sur les captures de l'image d'écriture manuscrite par des moyens et capteurs physiques comme les scanners et les caméras numériques, ensuite la conversion de l'image en des élévations numériques adaptés aux systèmes de traitement avec un taux de dégradation minimisé.

Le document numérisé est rangé dans un fichier des points appelés pixels, la taille du document dépend de type de résolution. La technicité des matériels d'acquisition a fait progrès ces dernières années [3].

Cette étape est importante car elle sert la préparation des documents, le choix et le paramétrage du matériel pour la saisie (scanner), ainsi que du format de stockage des images [1].

### 2.3.2. Phase de prétraitement

Juste après l'acquisition, la plupart des systèmes comporte une étape de prétraitement qui est pas confiné à la reconnaissance manuscrit, elle est généralement classique pour le traitement d'image.

Le prétraitement se base sur la préparation de l'image à la phase suivante, pour réduire le bruit superposé aux données et essayer d'extraire l'information significative.

Le bruit éliminé peut être a cause des conditions d'acquisition comme l'éclairage, mise incorrecte du document ou encore la qualité du document origine.

Parmi les opérations de prétraitement on peut citer : la binarisation, élimination de bruit, le lissage, la squelettisation et la normalisation.

#### 2.3.2.1. La binarisation

La plus simple façon pour réaliser une image binaire est de faire le choix d'une valeur seuil, puis de classer tous les pixels dont les valeurs sont au-dessus de ce seuil sont des pixels d'arrière plan, et tous les autres pixels sont des pixels de texte. Soit l'image  $K$  ( $M \times N$ ),

supposons que  $f(x, y)$  représente le niveau de gris du pixel aux coordonnées  $(x,y)$ ,  $0 \leq x \leq M$ ,  $0 \leq y \leq N$  et  $s$  est le seuil choisi. Alors, l'image binarisée  $g$  est déterminée par les pixels  $(x,y)$  dont la valeur est donnée par l'équation[5] :

$$g(x, y)=1 \text{ si } f(x, y) > s$$

$$g(x, y)=0 \text{ si } f(x, y) \leq s$$

Dans la pratique, cette situation idéale ne se rencontre que très rarement. Les niveaux de gris associés au fond et aux objets présents sur l'image sont supposés être suffisamment différents pour qu'une bonne discrimination puisse être faite. Par conséquent, un mauvais choix d'un seuil de binarisation peut détruire une grande part d'information utile contenue dans l'image en dégradant notamment la qualité des caractères à reconnaître par l'OCR, ces caractères peuvent ainsi être fragmentés ou fusionnés [5].

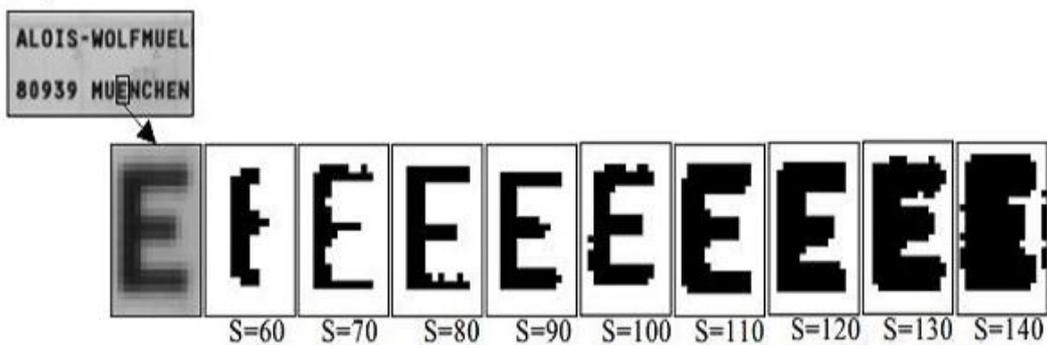


Figure 4 : Effet de seuillage sur la qualité des caractères [5]



Figure 5 : Résultat de la binarisation de différentes images par le même seuil  $s=120$  [5]

Selon la méthode de calcul du seuil de binarisation, on peut distinguer deux types : le seuillage globale et le seuillage adaptatif.

### 2.3.2.1.1. Seuillage global

Seuillage global Le seuillage global consiste à prendre un modifiable seuil, mais identique pour toute l'image. La méthode de seuillage globale consiste à calculer un seuil unique à partir d'une mesure globale sur toute l'image et la recherche de seuil s'effectue par l'analyse de l'histogramme des niveaux de gris et par la détermination d'un minimum local (voir figure ci-dessous). Il nous donner la possibilité de décider l'appartenance d'un pixel à l'objet ou au fond sur toute l'image. Tel que les pixels ayant un niveau de gris inférieur au seuil sont mis en noir et les autres en blanc.

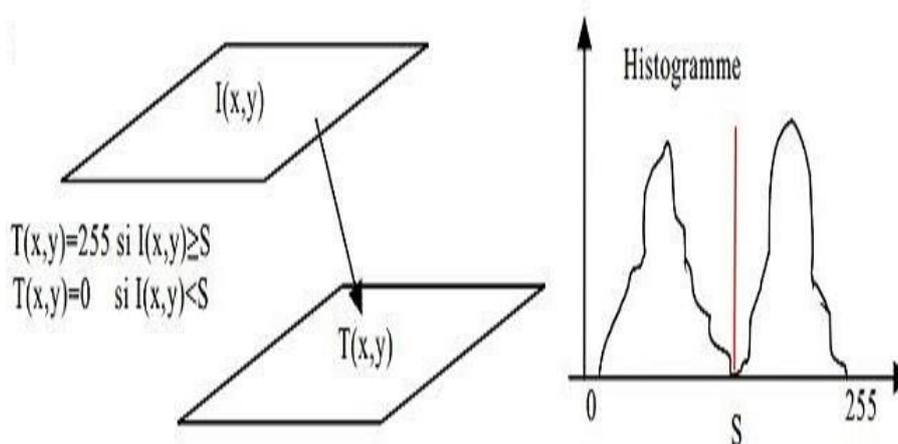


Figure 6 : Principe de la binarisation par seuillage global [5]

Cette méthode est fiable pour les documents simples et de bonne qualité (visuel).

Néanmoins, elle n'est plus applicable lorsque la qualité d'impression du texte n'est pas constante dans toute la page, des caractères peuvent être partiellement perdus [6].

### 2.3.2.1.2. Seuillage adaptif

Dans les documents dans lesquels l'intensité du fond et l'intensité de la forme sont variables au corps du document, un seuillage global est inadapté et non favorable. Il est nécessaire de choisir le seuil de binarisation d'une façon locale. On calcule un seuil de binarisation pour chaque pixel de l'image, en fonction de son voisinage [6].

### 2.3.2.2.Élimination de bruit

Le bruit est un problème très important et difficile à résoudre dans des cas comme le cas des feuilles ayant le fond complexe comme le papier couleur.

C'est une méthode simple qui consiste à faire la soustraction entre l'image d'entrée et l'image d'un papier couleur qui n'a pas d'écriture [7].

Les deux images doivent être alignées et les parties d'écriture vont être enlevées.

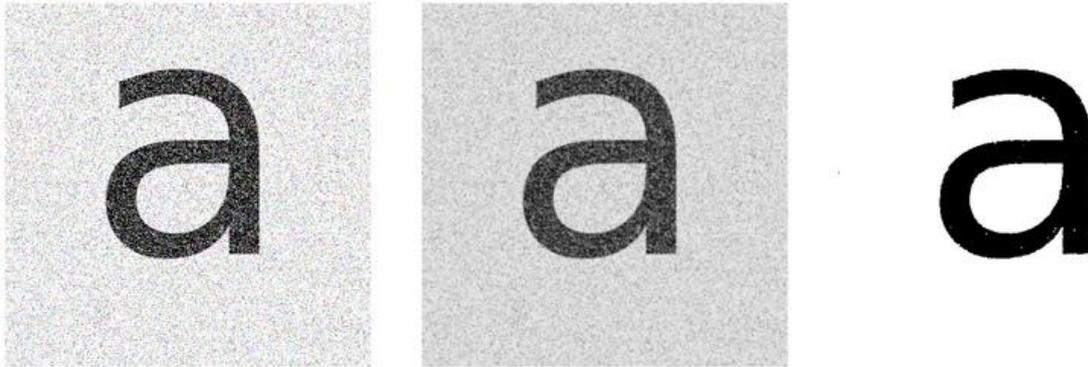


Figure 7 : Exemple d'élimination de bruit d'une image [8]

### 2.3.2.3. Le lissage

Les techniques de lissage permet de réduire au maximum les discontinuités de l'image par transformation et rétablissement de la régularité et la continuité du contour du mot ou de chiffre qu'elle contienne.

Les images à cause du bruit peuvent avoir des divers problèmes : des problèmes d'absence de point, surcharge de point. Pour résoudre ces derniers il existe des opérations locales comme le bouchage et le nettoyage [7].

### 2.3.2.4. La squelettisation(Thinning)

Le processus de squelettisation permet de réduire, compacter la taille de l'image en se trouvant un axe médian, qui représente l'ensemble de pixels S qui possèdent la même distance par rapport aux pixels de frontière. Le résultat de cette opération est un squelette de l'écriture manuscrite. Cette opération se fait à travers un ensemble de passes successives qui permet de déterminer si un pixel est essentiel pour le garder ou non dans la figure [4].

La représentation squelettique a les avantages suivants :

-Une très bonne représentation des relations structurelles entre les composants d'un échantillon.

-Très utilisée dans la plupart des systèmes de reconnaissance des chiffres et d'écriture manuscrits.

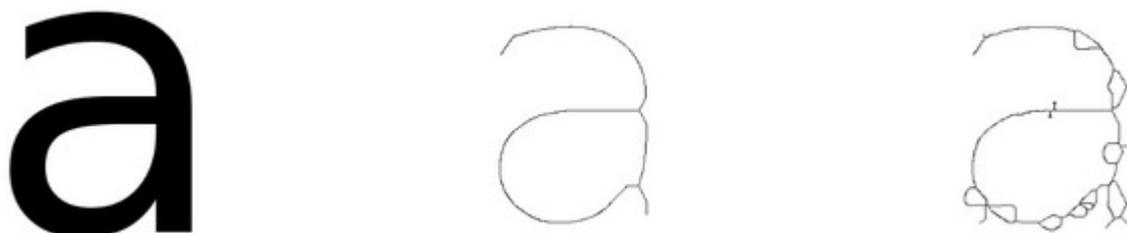


Figure 8 : Exemple de squelettisation [8]

### 2.3.2.5. La normalisation

Parmi les problèmes connus en reconnaissance des chiffres et écriture manuscrite est la taille d'image et l'inclinaison des lignes qui représente des difficultés pour la segmentation. Donc la normalisation est une étape importante pour chaque traitement d'image.

Le principe de la normalisation est d'essayer de normaliser localement les différentes parties du mot, de manière à augmenter la ressemblance d'une image à une autre, cette opération introduit généralement de légères déformations sur les images. Cependant certains traits caractéristiques tels que la hampe dans les caractères (Ø Ù á Ç par exemple) peuvent être éliminés à la suite de la normalisation, ce qui peut entraîner à des confusions entre certains caractères [9].

#### 2.3.2.5.1. Normalisation de taille

Cette étape permet de ramener les images des chiffres et écriture manuscrits à des tailles standard. La normalisation introduit généralement de légères déformations sur les images mais elle reste indispensable pour certains types de systèmes et de méthodes de reconnaissance qui sont sensibles aux petites variations dans la taille et la position comme c'est le cas dans les templates matching et les méthodes de corrélation [6].

### 2.3.2.5.2. La normalisation de l'inclinaison (Redressement)

Le redressement est une technique pour corriger l'inclinaison afin de régler le défaut de positionnement du papier dans le scanner et aussi l'inclinaison interne des parties qui peuvent apparaître du document traité.

L'objectif de ce prétraitement est de transformer le mot de façon à ce que cet axe de direction principale devient vertical. Ceci permet une réduction considérablement de la variabilité de l'écriture et une amélioration de la qualité de la segmentation des mots en caractères [10] [11].

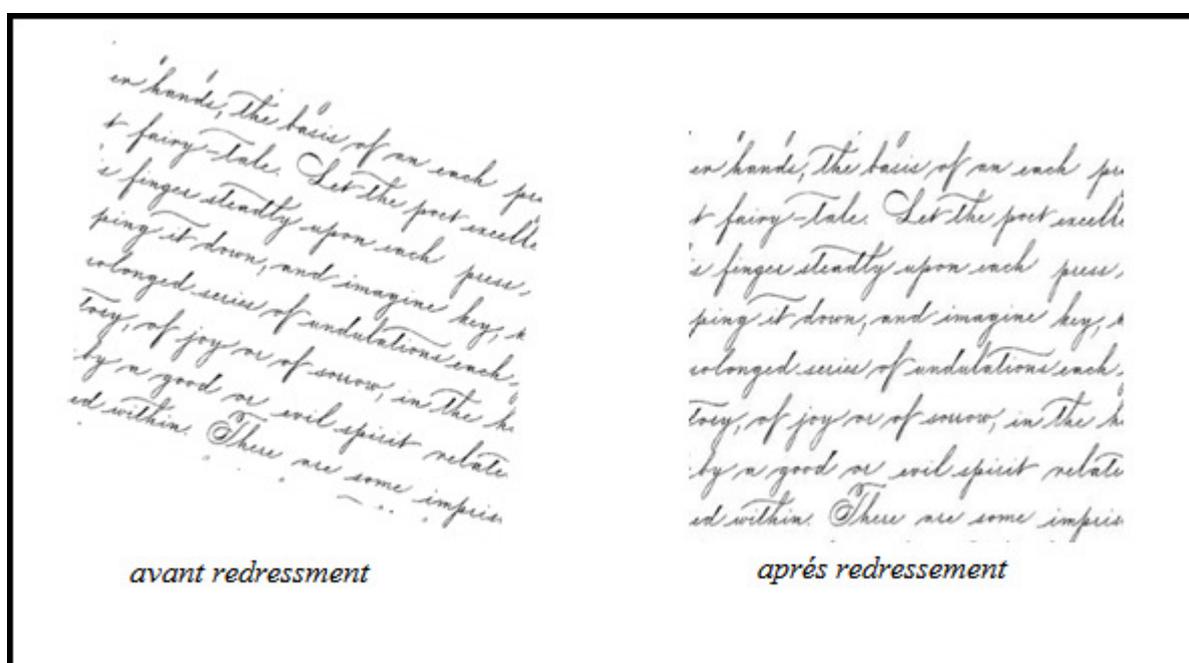


Figure 9 : Exemple de redressement

#### Remarque :

Selon la qualité du document à traiter, le type de l'écriture et la méthode d'analyse adoptée, une ou plusieurs techniques de prétraitement sont utilisées. Mais pas forcément toutes.

### 2.3.3. Phase de segmentation

Pour simplifier la tâche de reconnaissance, la segmentation consiste à découper l'image en différentes imagettes ou bien des régions de moindre taille [11]. Ces derniers peuvent être des graphèmes, lettres sous-mots ou des chiffres, et doivent être homogènes selon un certain critère, chaque région forme une matrice de pixel.

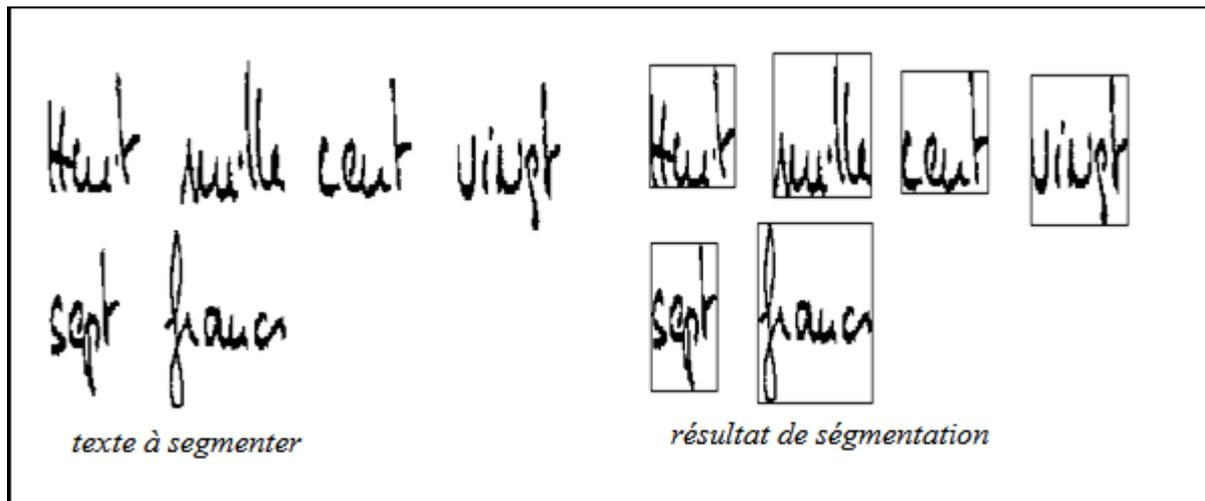


Figure 10 : Exemple de segmentation

Il existe deux techniques de segmentation : segmentation explicite et segmentation implicite.

### 2.3.3.1. Segmentation explicite

C'est une approche explicite ou discrète, consiste à choisir les plus probables points de segmentation, ensuite il faut séparer les composants de l'image selon un chemin à cause de liaisons multiples ou bien du contact prolongé. Une analyse est effectuée pour obtenir les chemins de segmentation, elle peut toucher des différents critères comme :

- Une analyse des contours de la forme du squelette.
- Une analyse d'un amincissement du fond.
- Une analyse à deux dimensions du tracé.
- Une combinaison d'analyse des contours et amincissement du fond.

L'avantage de cette segmentation c'est que l'information est localisée explicitement, puisque la séparation des lettres non pas d'après leur reconnaissance, mais d'après des critères topologiques ou morphologiques. Il n'existe pas de méthode de segmentation fiable à 100%, toute erreur de segmentation pénalise les performances de système[12].

### 2.3.3.2. Segmentation implicite

Afin de résoudre le problème du choix des points de segmentation, l'approche implicite considère tous les points de la figure comme des points de segmentation potentiels.

C'est une segmentation d'après des modèles des lettres et chiffres, elle consiste à découper a priori l'image en un ensemble d'intervalles de grandeurs fixés [12].

Cette technique est similaire à celle utilisée en reconnaissance de parole, elle s'effectue durant la reconnaissance. Le système cherche dans l'image traitée des composants ou des graphèmes qui correspondent à des classes particulières.

L'avantage de cette segmentation c'est que l'information est localisée par les modèles des lettres et la validation ce fait par ces modèles. Dans les approches à segmentation implicite, la tâche de segmentation est accomplie par le système, elle est soutenue simultanément par un processus de reconnaissance, en évitant la pré-segmentation d'un mot en lettre ou entités plus fines [12].

#### 2.3.4. Phase d'extraction des caractéristiques

C'est une phase critique pour la construction de tout système de reconnaissance [7].

Dans chaque système de reconnaissance, l'objectif principale d'extraction des caractéristiques est de garder les informations les plus pertinentes.

L'extraction c'est la transformation de l'image traitée en un vecteur de caractéristiques de taille fixe. Cette opération revient à changer l'espace de représentation des données, du niveau d'image vers un espace de  $n$  dimensions.

#### 2.3.5. Phase de classification

La classification dans un système de reconnaissance consiste à affecter une donnée à une classe prédéfinie, cette étape regroupe les deux tâches : l'apprentissage et la décision.

Elle tente d'attribuer une forme de donnée à un modèle de référence. Le résultat de l'apprentissage peut être la réorganisation ou le renforcement des modèles existants en prenant en considération l'apport d'une nouvelle forme soit par création d'un modèle ou l'apprentissage.

Le résultat de la décision est un « avis » sur l'appartenance ou non de la forme aux modèles d'apprentissage [13]. Un succès si la réponse est unique (un seul modèle répond à la description de la forme du caractère) [13].

Une confusion si la réponse est multiple (plusieurs modèles correspondent à la description)

Un rejet de la forme si aucun modèle ne correspond à sa description. Le type d'une méthode de classification se divise généralement en deux catégories : Le mode supervisé et le mode non supervisé.

### 2.3.5.1. Classification supervisée

Cette classification est guidée par un superviseur appelé professeur, son réalisation se fait dans la phase de reconnaissance par une introduction d'un grand nombre d'échantillons de référence. Le professeur indique le nom des échantillons. Le choix des primitives de référence est fait manuellement en fonction de système. Le nombre d'échantillons se varient de quelques unités à quelques dizaines, voire même quelques centaines par caractère [14].

Cette méthode est basée sur des échantillons qui sont déjà classés en un ensemble de classes prédéfinies et on veut classer un nouvel élément.

### 2.3.5.2. Classification non supervisée

Là le système lui-même doit décider les fonctionnalités et les règles qu'il utilisera pour regrouper les données en des classes de référence avec une assistance minimale. Les échantillons sont introduits par l'utilisateur sans indiquer leur classe.

Donc l'ensemble des échantillons n'est pas classés, et on veut les regrouper les éléments en classes.

La classification supervisée est très utile dans le cas de la reconnaissance des chiffres manuscrits car elle simplifie l'opération.

Pour évaluer la performance d'un classifieur, on suit deux phases élémentaires sont : l'apprentissage et reconnaissance.

**Étape d'apprentissage :** Elle consiste à utiliser des données d'apprentissage pour construire un classifieur qui peut reconnaître les formes inconnues et ensuite caractériser les classes.

**Étape de Reconnaissance et décision** : Elle cherche parmi les classes de référence en présence, ceux qui lui sont les plus proches. Le problème c'est comment affecter une forme inconnue à l'une des classes obtenues pendant l'apprentissage [15].

Le classifieur peut devenir incapable de reconnaître d'autres formes inconnues. C'est pourquoi il est très important d'avoir trois catégories de données pour améliorer la généralisation d'un classifieur : pour l'apprentissage, pour la validation, et le dernier pour le test.

Les données de validation sont utilisées pour accomplir le processus d'apprentissage jusqu'à ce que les performances sur l'ensemble de validation ne s'améliorent plus. En ce moment, l'apprentissage devrait être arrêté afin d'éviter le sur-apprentissage (over-training) du classifieur où sa capacité de généralisation commence à diminuer.

### 2.3.5.2. Méthodes de classification de la reconnaissance

Il existe trois approches fondamentales de classification et une approche dite hybride :

#### 2.3.5.2.1. Approche statistique

La méthode statistique ou géométrique permet de prendre une décision de classification d'un objet inconnue. Elle base sur une description extensive, plutôt que compréhensive, des classes [14].

Elle besoin un grand nombre d'exemple pour réaliser un apprentissage correcte des lois de calcul des probabilités des classes.

Elle est fondée sur l'étude statistique des mesures opérées sur les formes à reconnaître. L'étude de leur répartition dans un espace métrique et la caractérisation statistique des classes, aide à la prise d'une décision de reconnaissance du type « plus forte probabilité d'appartenance à une classe » [13].

Cette approche bénéficie des méthodes d'apprentissage automatique en se basant sur des théoriques fondés tel que :

Les méthodes paramétriques comme la règle de Bayes, les réseaux de neurones, les chaînes de Markov.

Les méthodes non paramétriques comme la plus connue méthode des k plus proches voisins.

Chaque méthode statistique comprend quatre étapes :

1. le choix des paramètres.
2. Une description statistique des classes.
3. Calcul de la distance d'une forme à chaque classe.
4. Choix de la classe la plus proche.

### 2.3.5.2.2. Approche structurelle

Les méthodes structurelles appuient sur la structure physique des caractères. Elles visent à trouver des éléments simples ou primitifs comme les graphèmes ou même les pixels de l'image et à décrire leurs relations [15].

La différence entre ces méthodes et les méthodes statistiques est que ces primitives sont de type topologique ou bien des formes élémentaires et non des mesures. Il existe plusieurs technique structurelle telles que : structures syntaxique, la comparaison des chaînes et la programmation dynamique.

### 2.3.5.2.3. Approche stochastique

Dans certaines de ces approches pour la reconnaissance de l'écriture, les images des mots sont segmentées. Puis ces segments sont transférés à un module qui fait le calcul de la probabilité d'apparition d'état selon laquelle chaque segment apparaît lorsque l'état correspondant de la chaîne de Markov est un certain état [16].

Cette approche utilise un modèle de la reconnaissance, prenant en considération la grande variabilité de la forme. La distance communément utilisée dans les techniques de comparaison dynamique est remplacée par des probabilités calculées de manière plus fine par apprentissage. La forme est considérée comme un signal continu observable dans le temps à différents endroits constituant des états « d'observations ». Le modèle représente ces états à l'aide de calcule probabilités de transitions d'états et de calcule de probabilités d'observation

par état. La comparaison consiste à trouver dans ce graphe d'états, le chemin de probabilité forte correspondant à une suite d'éléments observés dans la chaîne d'entrée [13].

Les méthodes les plus connues dans cette approche sont les méthodes utilisant les Modèles de Markov Cachés (MMC).

#### 2.3.5.2.4. Approche hybride

Pour améliorer les performances de reconnaissance, la tendance aujourd'hui est de mélanger différents types de caractéristiques, et qui combinent plusieurs classifieurs en couches dans un seul système. Pour surmonter les faiblesses de chaque approche et avoir des résultats plus précis plus meilleure que les résultats qui auraient été obtenus si la application de chaque approche séparément, comme les approche qui ont été fusionnés pour former celui intégré [16].

### 2.4. Méthodes de classification statistiques

L'approche statique a été conçu pour une reconnaissance des textes manuscrites et plus particulièrement la reconnaissance des chiffres sur des bases théoriques telle que les méthodes paramétriques, elles englobent plusieurs méthodes parmi ces dernières en peut citer :

#### 2.4.1. Réseaux de neurones

Est un ensemble de neurones formels interconnectés permettant la réalisation de plusieurs fonctions algébriques de ses entrées, par une composition des fonctions réalisées par chacun de ces compositions.

Donc il permet de résoudre des problèmes complexes tels que le traitement du langage naturel, la reconnaissance des formes et la reconnaissance d'écriture manuscrite, il s'inspire son fonctionnement des neurones biologiques et prend réalisation dans un ordinateur sous forme d'un algorithme. Le réseau neuronal peut se modifier lui-même selon les résultats de ses actions, ce qui permet l'apprentissage et la résolution de problèmes sans programmation classique.

Parmi les méthodes de classification des images on a le réseau neuronal convolutif qui il est basé sur l'idée que le modèle fonctionne correctement sur la base d'une

compréhension locale de l'image. Il utilise moins de paramètres par rapport à un réseau entièrement connecté en réutilisant plusieurs fois le même paramètre. Alors qu'un réseau entièrement connecté génère des poids à partir de chaque pixel de l'image, un réseau neuronal convolutif génère juste assez de poids pour balayer une petite zone de l'image à un moment donné. Lorsqu'un modèle CNN est formé pour classer une image, il recherche les entités à leur niveau de base et l'ordinateur recherche les courbures des limites de ces entités.

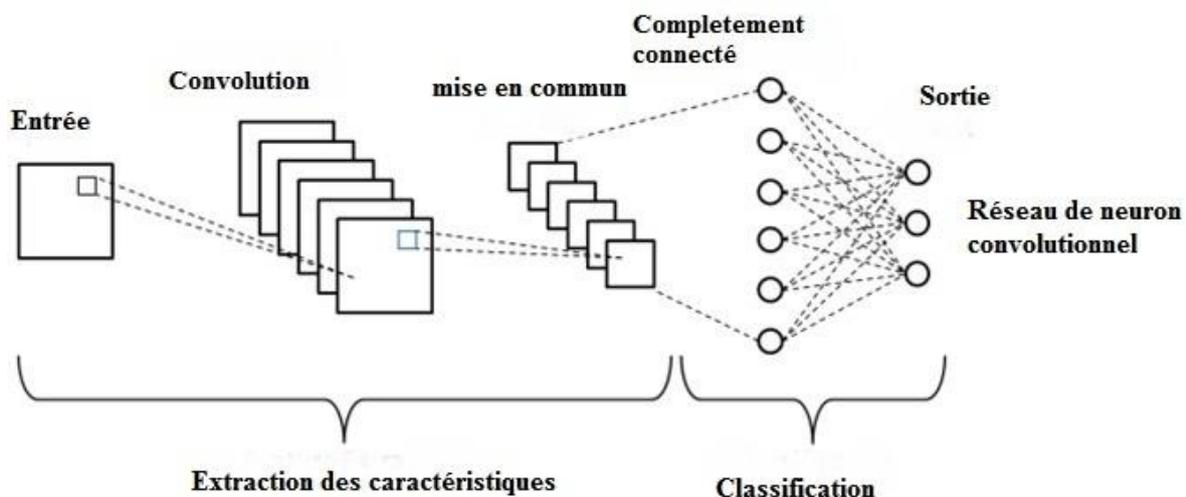


Figure 11 : Exemple d'une Classification par les réseaux de neurones convolutifs.

### 2.4.2. Les Machines à Vecteur Support (SVM)

Les réseaux de neurones ont des difficultés à examiner les données de très haute dimension, de plus, ils possèdent un grand nombre de paramètres d'apprentissage. Pour résoudre ce problème, on procède souvent le choix d'une partie des attributs des données pour réduire la dimension d'espace de l'entrée. Mais dans ce cas, on aura besoin d'utiliser des hypothèses pour simplifier les choses qui ne sont pas toujours vérifiées en pratique. Par ailleurs, une méthode de formulation pour la théorie de l'apprentissage statistique qui apparaît à l'ouvrage de Vapnik en 1995 intitulé « the nature of learning theory » surpasse cette difficulté en exigeant une liaison linéaire entre le nombre de paramètres et de données d'apprentissage. Cette méthode est appelée Support Vector Machines(SVM) ou bien machines à vecteurs de support. [17].

Ils sont une famille d'algorithmes d'apprentissage automatique qui permettent de résoudre des problèmes tant de classification que de régression ou de détection

d'anomalies. Ils sont solides en termes de garanties théoriques, flexible et simple en utilisation [18].

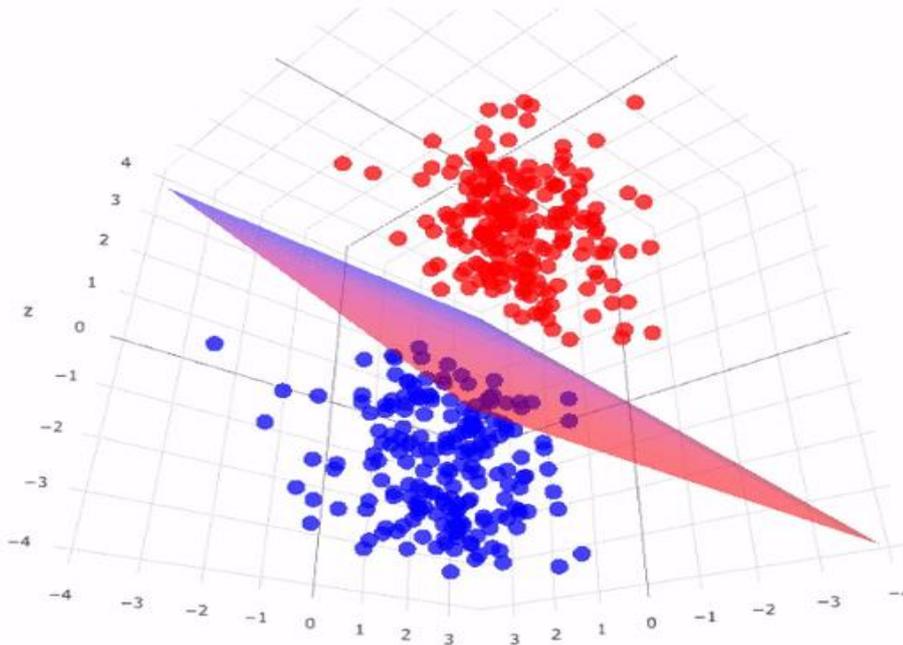


Figure 12 : Exemple Représentation en 3D d'une Classification de deux ensembles de points en SVM

### 2.4.3. Le classifieur du K plus proches voisins

La méthode des "k plus proches voisins" fait partie des méthodes les plus simples d'apprentissage supervisé pouvant être utilisée pour les cas de régression et de classification [19].

Les 'k plus proches voisins' ou k-nearest neighbors en anglais (d'où l'appellation KNN) est une méthode qui n'a pas des paramètres dont le modèle sauvegarde les observations du groupe d'apprentissage pour la classification des données de groupe de test [20].

En effet, cet algorithme est qualifié comme paresseux (Lazy Learning) car il n'apprend pas pendant l'étape d'entraînement. Pour prédire la classe d'une nouvelle donnée d'entrée, il va chercher ses K voisins les plus près (en utilisant la distance euclidienne, ou autre) et sélectionnera la classe des voisins majoritaires [19].

Cette technique se résume dans les étapes suivantes :

- Fixer un nombre de voisins k.

- Détecter les  $k$ -voisins les plus proches des nouvelles données d'entrée que l'on souhaite classer.
- Attribuer les classes correspondantes par élection majoritaire.
- Et pour choisir le paramètre  $k$  lors de l'implémentation de l'algorithme on doit :
- Faire différer  $k$
- Pour chaque valeur de  $k$ , on estime le taux d'erreur de l'ensemble de test on stocke le paramètre  $k$  qui minimise le taux d'erreur test.

## 2.5. Post-traitements

Le post-traitement est un traitement ultérieur de la classification, Son objectif principal est d'augmenter le taux de reconnaissance en appliquant des modifications possibles et des corrections des erreurs de l'étape précédente.

Le principal objectif de la phase de post-traitement au niveau lexicale est de déterminer quel est le meilleur choix possible pouvant correspondre aux hypothèses de reconnaissance. et il vérifie aussi si la réponse est correcte en à la base des données indisponible au classifieur.

### 3. Conclusion

Dans ce chapitre, nous avons présenté les différents concepts élémentaires dans les systèmes de reconnaissance d'écriture manuscrite et des chiffres.

Dans le chapitre suivant nous présentons les techniques et les méthodes d'extraction des caractéristiques les plus connus. Ensuite on va détailler la méthode LBP et le classifieur SVM.

---

**Chapitre 2 :**  
Extraction des  
caractéristiques

---

---

## 1. Introduction

Lorsque le prétraitement et le niveau de segmentation souhaité (ligne, mot, caractère ou symbole) ont été atteints, nous appliquons des techniques d'extraction de caractéristiques aux segments pour obtenir des caractéristiques, qui sont suivies par l'application de techniques de classification et de post-traitement. Il est essentiel de se concentrer sur la phase d'extraction des caractéristiques car elle a un impact observable sur l'efficacité du système de reconnaissance. Donc la sélection d'une méthode d'extraction des caractéristiques est le facteur le plus important pour obtenir des performances de reconnaissance élevées.

Ce chapitre est destiné à la présentation des différentes méthodes d'extraction des caractéristiques. Une partie traite les caractéristiques d'image et expose les méthodes utilisées dans l'extraction puis une petite comparaison entre autres méthodes connues associées par leurs avantages et inconvénients, la deuxième partie présente la méthode d'extraction des caractéristiques choisie, ensuite on va présenter en détail les notions d'apprentissage et le classifieur sélectionné pour traiter les données.

## 2. Caractéristiques d'une image numériques

Une image numérique est une représentation d'image réelle sous la forme d'un ensemble de pixels structurés (éléments d'image) et qui sont caractérisés par les paramètres suivants :

### 2.1. Dimension

C'est la taille de l'image numérique, elle est représentée sous la forme d'une matrice dont ces éléments sont les valeurs numériques des intensités lumineuses (pixels). La multiplication de nombre de lignes et de colonnes de cette matrice nous donne le nombre total de pixels de l'image

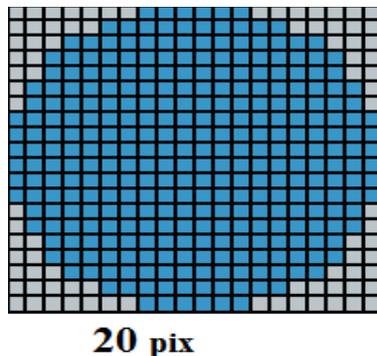


Figure 13 : Exemple de dimension d'image numérique

### 2.2. Résolution

C'est le degré de clarté et finesse de détails réalisée par moniteur ou imprimante dans la production d'image numérique, elle s'exprime en le nombre de pixel par unité de longueur, par exemple le nombre de pixel par pouce ou Inch (1 pouce = 2,54 cm) et est exprimé en DPI (= point par pouce). Plus le nombre de pixels est élevée, plus la quantité d'informations ou la précision de l'image est élevée.

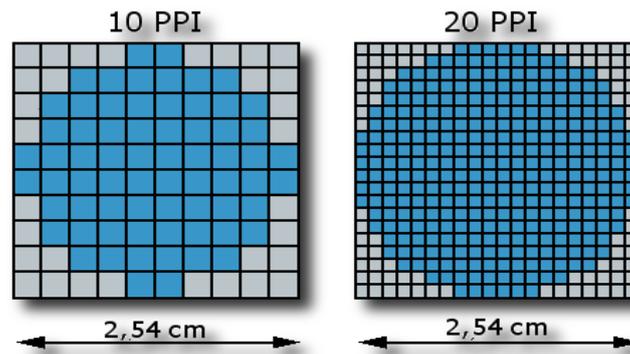


Figure 14 : Exemple de résolution d'image, PPI signifie Pixel Per Inch et indique le nombre de pixels par pouce

### 2.3. Bruit

Le bruit (parasite) est un phénomène de variation brusque d'intensité d'un pixel par rapport aux autres pixels d'image. Il peut être produit par capteur d'image ou bien les circuits du scanner ou d'appareil photo numérique, le bruit de l'image peut également provenir du grain du film et du bruit de tir inévitable d'un détecteur de photons idéal. Il est un sous-produit indésirable de la capture d'image qui masque les informations souhaitées et qui peut endommager une image en altérant sa qualité.

### 2.4. Histogramme

Peut être défini par une fonction discrète qui donne la fréquence d'apparition de chaque niveau de gris (Couleur) et la distribution d'intensité de l'image, Elle représente aussi le nombre de pixels en fonction du niveau de gris. Lorsque cette fonction est entre 0 et 1 pour chaque niveau de gris, on peut la voir comme une densité de probabilité qui donne la probabilité de trouver un certain niveau de gris de l'image.

La détermination d'histogramme est réalisée en dénombrant les pixels d'intensité de l'image. On exécute parfois des quantifications, qui englobent des différentes valeurs d'intensité dans la même classe, ce qui peut permettre d'augmenter la visualisation de distribution des intensités de l'image.

L'histogramme peut être utilisé pour améliorer la qualité d'image en effectuant quelques modifications pour pouvoir extraire les informations utiles.

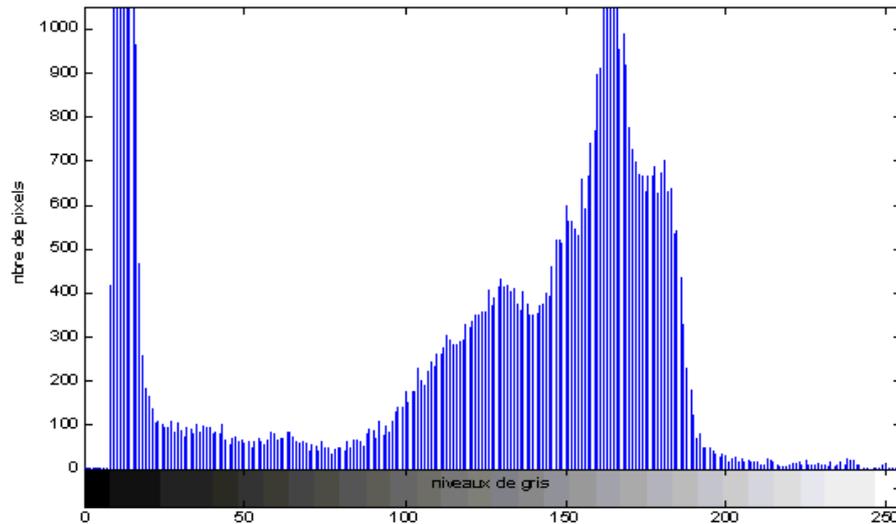


Figure 15 : Exemple d'histogramme d'intensités de gris dans une image

## 2.5. Luminance

Représente les degrés de luminosité des points d'image, elle est considérée comme étant la quantité de lumière de la couleur dans une surface. Dans certains cas, nous pouvons facilement dire que l'image est lumineuse, et dans certains cas, ce n'est pas facile à percevoir[21].

Une bonne luminance se caractérise par :

- Des images lumineuses
- Un bon contraste
- L'absence de bruit

## 2.6. Contraste

C'est l'écart entre les intensités (miniums et maximums)des pixels d'image, il est donc l'opposition marqué entre les régions sombres et claires des images.

Le contraste est calculé en fonction des luminances de deux régions d'images. Si  $L1$  et  $L2$  sont les degrés de luminosité de deux régions voisines d'une image, le contraste  $C$  est défini par la formule suivante :

$$C = \frac{L1 - L2}{L1 + L2}$$

## 2.7. Bords

Les bords sont des points qui se situent à la limite de deux zones d'image et sont détectés par le calcul de changement de luminosité. Ces bords correspondent à des régions de l'image où les valeurs des pixels se transforment rapidement. Nous pouvons également dire que les changements soudains de discontinuités dans une image sont appelés bords. Les transitions significatives dans une image sont appelées bords.

En général, les bords sont de trois types:

- Bords horizontaux
- Bords verticaux
- Bords diagonaux

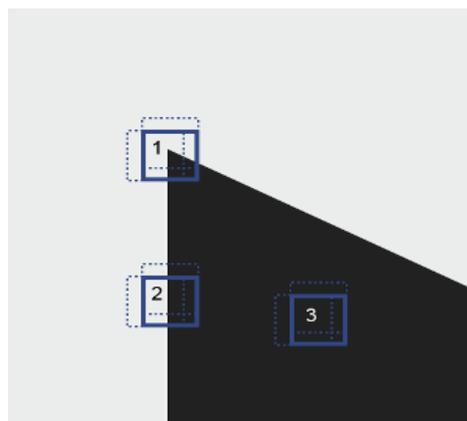


Figure 16 : Exemple détection des bords dans une image

## 2.8. Coin

Un coin est le point de l'intersection de deux bords d'image et il représente un point d'intérêt comme une petite région dans l'image (fenêtre) pour lequel, peu importe dans quelle direction voisine on regarde il y a une forte variation de luminosité. Les coins permettent de définir les points de l'image même si elle est redimensionnée tournée, la luminosité change ou l'image a été prise à partir d'un point de vue légèrement différent [22].

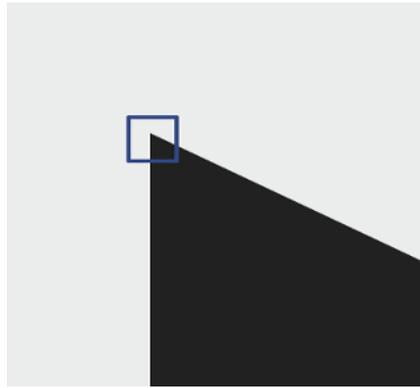


Figure 17 : Exemple de coin dans une image

## 2.9. Blobs / régions d'intérêt

Les gouttes, ou régions d'intérêt, sont des régions où la luminosité ou la couleur des points changent très peu, de sorte qu'ils peuvent être considérés dans un certain sens comme étant similaires les uns aux autres.

## 2.10. Couleur

La couleur d'une image numérique est montrée par un modèle de couleur. Il existe différents modèles qui peuvent décrire les couleurs, les plus utilisés sont RGB (rouge, vert, bleu), HSV (teinte, saturation, valeur) et Y, Cb, Cr (luminance et chrominance). Ainsi, le contenu de couleur est caractérisé par 3 canaux à partir d'un modèle de couleur.

## 3. Extraction des caractéristiques

Une caractéristique d'image est un terme général, mais il signifie généralement une partie d'une image ou une propriété mesurable qui contient des informations. En traitement d'image plus particulièrement en reconnaissance de l'écriture manuscrite et chiffres, l'extraction de caractéristiques est une forme spéciale de réduction de la dimensionnalité c'est-à-dire son objectif principal consiste à obtenir les informations les plus pertinentes à partir des données d'origine et représenter ces informations dans un espace de dimensionnalité inférieure. Lorsque les données d'entrée d'un algorithme est trop volumineux pour être traité et il est soupçonné d'être redondant (beaucoup de données, mais pas beaucoup informations) puis les données d'entrée seront transformées en un ensemble de représentation réduit de fonctionnalités (également vecteur de caractéristiques nommées).

L'objectif majeur de la fonctionnalité d'extraction consiste à extraire un ensemble des éléments des caractéristiques, qui maximise le taux de reconnaissance avec le moins de montant d'éléments et pour générer un ensemble de fonctionnalités similaires pour variété d'instances du même symbole.

### 3.1. Problème de sélection des caractéristiques

La sélection des caractéristiques les plus significatives est très importante étape dans le processus de classification extractions des caractéristiques en particulier aux systèmes de reconnaissance manuscrite parce que:

- Il est nécessaire pour trouver tous les sous-ensembles de caractéristiques possibles qui peuvent être formés à partir de l'ensemble initial, ce qui prend du temps.
- Chaque caractéristique est significative pour au moins certains des discriminations
- Variations intra-classe et entre inter-classe n'est pas trop élevé. Au-delà d'un certain point, l'inclusion de fonctionnalités supplémentaires conduit à une performance pire plutôt que meilleure.

La sélection des caractéristiques est donc dite critique car elle influe nettement les résultats, ces caractéristiques doivent avoir ces propriétés [23] :

- La discrimination : pour une bonne différenciation entre les classes des caractères à reconnaître.
- Nombre de dimensions limite : pour éviter le phénomène de la dimensionnalité il faut maintenir un nombre très limité de dimensions
- L'invariante : les caractéristiques doivent être stable par translation, rotation et changement d'échelle, en générale indépendantes de la distorsion et du bruit.

Cette phase d'extraction des caractéristiques peut poser un problème de perte d'information à cause des techniques utilisées, il faut prendre en considération la qualité et la quantité des données.

Pour cela on réduit le nombre de caractéristiques qui a les avantages suivants :

- Améliorer la visualisation et la compréhension des informations.
- Réduire les temps d'apprentissage et la classification des systèmes de reconnaissance.
- Enrichir les performances en classification.

- Minimiser la taille des bases d'apprentissage.

## 3.2. Types des caractéristiques

Il existe cinq catégories principales de caractéristiques [24]:

- Caractéristiques topologiques
- Caractéristiques statistiques
- Caractéristiques structurelles
- Globales ou locales
- Superposition des modèles et corrélation.

### 3.2.1. Caractéristiques topologiques ou métrique

Cette catégorie de caractéristiques est basée sur des densités de pixels. Dans cette faction de caractéristiques, elle comporte également les profils et histogrammes. Pour améliorer un vecteur de caractéristiques de dimension fixe, on divise l'image traitée en un nombre fixe de bandes horizontales et verticales. Les moyennes des valeurs sur ces bandes sont les caractéristiques [25].

Elles consistent à compter dans une forme plusieurs mesures comme :

- Calculer le nombre de trous
- Traiter les concavités et les orientations
- Mesurer les pentes et autres paramètres de courbures, aussi les surfaces
- Mesurer la longueur et l'épaisseur des traits
- Détecter les croisements et les jonctions des traits.

### 3.2.2. Caractéristiques structurelles

Elles ressemblent beaucoup aux caractéristiques topologiques. La différence est qu'elles sont dérivées à partir du squelette ou du contour de l'image ou bien de la forme pour donner ses caractéristiques globales et locales. Ainsi, on ne parle plus de trous, mais de boucles ou de cycles dans une représentation structurelle de l'objet.

Parmi ces caractéristiques on peut citer:

- Les lignes et les anses avec des différentes directions et tailles.

- Les points terminaux.
- La hauteur et largeur de la primitive
- Les pentes et les arcs
- Les points d'intersections, Les boucles...etc.

### 3.2.3. Caractéristiques statistiques

Les caractéristiques statistiques représentent une forme en termes d'un ensemble de mesures extraites.

### 3.2.4. Caractéristiques globales ou locales

L'objectif des caractéristiques globales est de représenter au mieux la forme générale d'un objet, ils sont calculées sur des images relativement grandes (ex: Couleur dans l'histogramme, la cohérence spatiale au histogramme de connexité, texture et forme..). Les primitives locales sont calculées durant les parcours des pixels de l'image avec un pas d'analyse qui dépend de la modélisation, du type de caractéristique et de la taille de l'image traitée [25].

### 3.2.5. Superposition des modèles et corrélation

La méthode de « template matching » est appliquée à une image binaire (en niveaux de gris ou squelettes), consiste à utiliser l'image de d'objet comme un vecteur de caractéristiques pour être comparé à un modèle (template) pixel par pixel dans la phase de reconnaissance, ensuite en calcule une mesure de similarité [26].

## 3.3. Méthodes d'extractions des caractéristiques

Dans le domaine de traitement d'image il existe multiplicité de techniques d'extractions des caractéristiques, en ce qui suit on va introduire quelques méthodes.

### 3.3.1. Histogramme de gradient Orienté (HOG)

Histogramme de gradient orienté (HOG) a été fondé en 2005 pour la première fois par Dalal et Triggs [27] est appliqué dans divers contextes comme détection du corps humain et dans les vidéos, il est maintenant l'un des descripteurs utilisés avec succès et répandues dans vision par ordinateur et reconnaissance de formes et surtout dans la reconnaissance des lettres

et chiffres manuscrits. HOG compte le nombre d'occurrences des orientations de dégradés dans une région d'une image, il s'agit donc d'un descripteur d'apparence. HOG divise l'image d'entrée en petites cellules carrées (selon les critères du système utilisé) puis calcule l'histogramme des directions de gradient ou des directions de bord basé sur les différences centrales. Pour les pixels dans chaque cellule, un histogramme des directions de gradient est compilé. Le descripteur est la concaténation de ces histogrammes. Pour une précision améliorée, les histogrammes locaux peuvent être normalisés par contraste en calculant une mesure de l'intensité sur une plus grande région de l'image, appelée bloc, puis en utilise cette valeur afin de normaliser les cellules du bloc. Cette normalisation se traduit par une meilleure invariance aux changements d'éclairage et d'ombrage. C'est la raison pour laquelle HOG est stable sur la variation d'éclairage.

C'est un descripteur rapide par rapport au quelques autres méthodes tel que SIFT et au LBP en raison de calculs simples, il a également été montré que HOG les fonctionnalités sont un descripteur réussi pour la détection [28].

### 3.3.2. Filtre de Gabor

Un filtre Gabor (dans le traitement d'image) est l'une des textures les plus établies descripteurs introduits en 1946 nommé d'après Dennis Gabor, est un filtre linéaire utilisé pour l'analyse de texture et pour la détection de bord, ce qui signifie qu'il analyse essentiellement s'il y a un contenu de fréquence spécifique dans l'image dans des directions spécifiques dans une région localisée autour du point ou région d'analyse. De nombreux scientifiques de la vision contemporaine prétendent que les représentations de fréquence et d'orientation des filtres de Gabor sont similaires à celles du système visuel humain, bien qu'il n'y ait aucune preuve empirique ni aucune justification fonctionnelle pour soutenir l'idée [29].

Ils se sont avérés être particulièrement appropriés pour la représentation et la discrimination de texture. Dans le domaine spatial, un filtre de Gabor 2D est une fonction noyau gaussienne qui a un module sous la forme d'une onde plane sinusoïdale.

Certains auteurs affirment que de simples cellules du cortex visuel des cerveaux de mammifères peuvent être modélisées par des fonctions de Gabor. Ainsi, le traitement d'image avec des filtres de Gabor est considérée comme similaire à la perception dans le système visuel humain.

L'utilisation des filtres Gabor 2-D dans le traitement d'images:

- Pour la reconnaissance des images dans les documents, les fonctionnalités de Gabor sont idéales pour identifier le script d'un mot dans un document multilingue.
- Des filtres de Gabor avec différentes fréquences et avec des orientations dans différentes directions ont été utilisés pour localiser et extraire les régions de texte à partir d'images de documents complexes (gris et couleur).
- Il a été appliqué pour la reconnaissance des expressions faciales, la reconnaissance de l'iris et la reconnaissance des empreintes digitales.
- Les filtres Gabor ont été largement utilisés dans les applications d'analyse de motifs.
- L'espace Gabor est très utile dans les applications de traitement d'image telles que la reconnaissance optique des caractères, Les relations entre les activations pour un emplacement spatial sont très distinctives entre les objets d'une image.

### 3.3.3. FAST (détecteur de coin)

FAST (Features from Accelerated Segment Test) caractéristiques issues des tests accélérés de segments, est une technique d'extraction des caractéristiques utilisé dans la reconnaissance des images et objets présenté par des chercheurs de l'université de Cambridge, basé sur le critère de coin SUSAN (Smallest Univalued Segment Assimilating Nucleus) [30] Pour la détection des caractéristiques, SUSAN place un masque circulaire sur le pixel à tester (le noyau). La région du masque est  $M$  et un pixel de ce masque est représenté par  $m$  et chaque pixel est comparé au noyau en utilisant une fonction de comparaison.

Avec FAST, la détection des coins a été priorisée par rapport aux bords, car ils ont affirmé que les coins sont l'un des types les plus intuitifs de caractéristiques qui montrent un fort changement d'intensité bidimensionnel et sont donc bien distingués des points voisins. Selon une étude comparative des détecteurs d'angle existants basée sur les critères ci-dessus (cohérence, précision et vitesse), il a été constaté que la plupart de ces détecteurs satisfaisaient à l'un des critères mais échouaient dans les autres.

### 3.3.4. Détecteur SURF

La méthode SURF (Speeded Up Robust Features) est un algorithme rapide qui assure une vitesse élevée dans trois des étapes de détection des caractéristiques: détection, description et correspondance sans sacrifier la qualité des points détectés et robuste pour la

représentation locale et invariante de similarité et la comparaison d'images. L'intérêt principal de l'approche SURF réside dans son calcul rapide des opérateurs à l'aide des boîtes des filtres, permettant ainsi des applications temps réel telles que le suivi et la reconnaissance d'objets.

SURF est composé de deux étapes qui sont l'extraction de caractéristiques qui se base sur une approche de détection des points d'intérêt en utilisant une approximation matricielle de Hesse très basique, et la deuxième étape c'est la description des fonctions

La méthode SURF utilise des techniques de détection des caractéristiques, il crée une «pile» sans sous-échantillonnage pour les niveaux supérieurs de la pyramide d'image traitée, ce qui donne des images de même résolution. Dans l'étape de correspondance des points clés, le voisin le plus proche est défini comme le point clé avec une distance euclidienne minimale pour le vecteur descripteur invariant [31].

### 3.3.5. LBP (Local Binary Pattern)

Local binary pattern (LBP) est un descripteur de texture simple mais robuste [32]. Il est utilisé pour décrire le modèle de texture local et pour la classification des textures et dans l'extraction des caractéristiques des images numériques. Un des critères les plus significatives de LBP sont sa robustesse à la monotonie aux changements d'échelle de gris causés par des conditions d'éclairage variables traités lors les deux phases d'extraction et de classification. Une autre propriété importante est sa simplicité de calcul, ce qui le rend adapté aux applications en temps réel. Par conséquent, LBP a été utilisé avec succès dans une grande variété applications visuelles des ordinateurs comme compris la reconnaissance des visages humains, la détection humain, la détection d'objets en mouvement, l'analyse des images médicaux et plus d'autres diverses utilisations.

### 3.3.6. OBIF (Oriented Basic Image Feature)

Les descripteurs de type OBIF, sont des descripteurs de la texture d'image et utilisés dans l'extraction des caractéristiques notamment dans les documents et les images numériques.

Il se base sur la notion de l'emplacement des images en formulant un schéma d'histogramme de colonne d'OBIF, et par conséquence un vecteur des caractéristiques extrait de l'image traitée.

---

La méthode d'OBIF est très appliquée dans les domaines de reconnaissance des formes comme celle d'écriture manuscrite et notamment les chiffres grâce à leur efficacité et qui résultent des bons résultats quel que soit la taille, la forme ou l'inclinaison.

#### 4. Techniques d'extraction des caractéristiques :

Tech	Avantages	Inconvénients
<b>SIFT</b> (Scale Invariant Feature Transform)	<ul style="list-style-type: none"> <li>- <u>Localité</u>: les caractéristiques sont locales, donc résistantes à l'occlusion et à l'encombrement (pas de segmentation préalable).</li> <li>- <u>Caractère distinctif</u>: les caractéristiques individuelles peuvent être associées à une grande base de données d'objets.</li> <li>- <u>Quantité</u>: de nombreuses fonctionnalités peuvent être générées même pour les petits objets.</li> <li>- <u>Efficacité</u>: proche des performances en temps réel.</li> <li>- <u>Extensibilité</u>: peut facilement être étendue à un large éventail de types de fonctionnalités différents, chacun ajoutant de la robustesse.</li> </ul>	<ul style="list-style-type: none"> <li>- Toujours assez lent car il est mathématiquement compliqué et lourd en calcul.</li> <li>- Ne fonctionne généralement pas bien avec les changements d'éclairage et le flou.</li> <li>- SIFT est basé sur l'histogramme des dégradés.</li> <li>- Il n'est pas efficace pour les appareils de faible puissance.</li> </ul>
<b>BRIEF</b> (Binary robust independent elementary feature)	<ul style="list-style-type: none"> <li>- BRIEF se base sur un nombre relativement restreint de tests de différence d'intensité pour représenter un patch d'image sous forme de chaîne binaire.</li> <li>- BRIEF est très rapide à construire et à assortir.</li> <li>- BRIEF surpasse facilement les autres descripteurs rapides en termes de vitesse et de taux de reconnaissance dans de nombreux cas.</li> </ul>	<ul style="list-style-type: none"> <li>- Sensible au changement des conditions d'images.</li> <li>- Nombre d'application de ce descripteur est limité par rapport aux autres méthodes d'extraction.</li> </ul>

## ORB (Oriented FAST and Rotated BRIEF)

- Bonnes performances et faible coût.
- L'ajout d'un composant d'orientation rapide et précis à FAST
- Le calcul efficace des fonctionnalités BRIEF orientées
- Analyse de variance et corrélation des fonctionnalités BRIEF orientées
- Une méthode d'apprentissage pour améliorer les fonctionnalités BRIEF sous invariance de rotation, conduisant à de meilleures performances dans les applications du plus proche voisin.

Sensible est plus robuste aux changements d'échelle malgré que l'ORB utilise des pyramides d'images pour l'invariance d'échelle et le centre de gravité d'intensité pour l'invariance de rotation il reste faible dans le changement des conditions et niveaux d'image

Tableau 1 : Comparaison entre quelques techniques d'extraction des caractéristiques

## 5. Techniques déployées dans le système de reconnaissance des chiffres manuscrits

En ce qui suit on va détailler le principe et le fonctionnement des méthodes d'extraction des caractéristiques et le classifieur utilisé dans notre système qui concerne seulement la reconnaissance des chiffres manuscrits.

### 5.1. LBP (Local Binary Pattern)

Le LBP est une bonne et rapide méthode utilisée dans l'analyse de texture introduite pour la première fois par Ojala et al [33]. Cette technique a été largement popularisée en 2002 en tant qu'ensemble de caractéristiques de texture extrait directement sur les images en niveaux de gris. Comme l'a démontré Ojala, l'histogramme de certains modèles binaires spécifiques est un très important jeu de fonctionnalités. Les LBP sont intrinsèquement des caractéristiques de texture au début mais elles ont été utilisées dans un très large éventail d'applications en informatique dont beaucoup dépassent la reconnaissance de texture typique Tâches comme :

- En 2004, Ahonen et al, utilisé avec succès LBP pour la reconnaissance faciale [34].

- En 2007, Zhao et al, a étendu l'opérateur comme une version 2D plus temps voxel de LBP, appelé VLBP, et les a utilisés avec succès pour la reconnaissance des gestes faciaux [35].
- Dans 2009, Whang et al. Fonctions LBP combinées avec HOG pour résoudre le problème des occlusions partielles dans le problème de détection humaine. Plus récemment, LBP a gagné l'attention de l'analyse d'image de document [36].
- En 2010 Luft et al, utilisé LBP sur les diacritiques de l'écriture arabe pour améliorer l'identification des écrivains [37].
- Du et al. Proposer LBP extraction sur le domaine des ondelettes pour l'identification de l'auteur [38].
- En 2013, Ferrer et al, utilisé LBP orienté sur différents bandes horizontales dans une ligne de texte pour détecter le script [39].
- En 2013, LBP est appliqué avec succès dans la tâche d'identification d'écrivain [40].

Dans ce travail nous nous intéressons au rôle de LBP à l'extraction des caractéristiques dans les chiffres manuscrits.

### 5.1.1. Principe de LBP

LBP fonctionne en principe par la division de l'image en cellules des niveaux de gris. Pour chaque pixel de la cellule, on doit comparer le pixel aux pixels voisins, si les valeurs du pixel central sont supérieures à la valeur du voisin on écrit 1 sinon 0. Il donne un nombre binaire à 8 chiffres. Après avoir obtenu ce chiffre, on le convertisse en nombre décimal correspondant. Puis on Calcule l'histogramme de chaque cellule, de la fréquence de chaque nombre, dont l'histogramme est un vecteur de caractéristiques à 256 dimensions. Enfin, la normalisation d'histogramme.

L'histogramme normalisé de chaque cellule donne le vecteur caractéristique de l'image en niveaux de gris donnée. Une extension de LBP est un motif uniforme, qui réduit la taille du vecteur d'entité. Dans un motif uniforme, la longueur de la fonction vecteur pour une seule cellule condensée de 256 à 59.

LBP utilise des voisins de 8 pixels avec 1 pixel central pour fonctionner comme valeur de seuil. La valeur de chaque pixel voisin sera comparée au pixel central, ensuite tous les

pixels voisins seront combinés de gauche à droite on obtiendra des nombres binaires qui peuvent être convertis en décimaux aussi appelés LBP [41].comme dans l'exemple suivant :

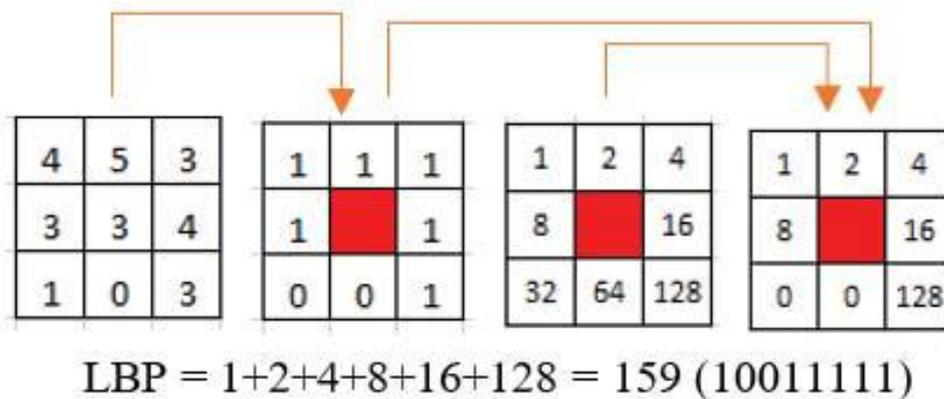


Figure 18 : Exemple de Calcul de base du LBP

En se qui suit on va détailler les calculs du LBP, pour mieux comprendre les phases principaux dans cette technique locale de détection et de d'extraction des caractéristiques d'image.

### 5.1.2. Méthodologie

LBP opère sur chaque pixel en seillant ses voisins pixels avec la valeur du pixel central lui-même. Il en résulte des valeurs binaires, 0 et 1, où 0 indique que le la valeur d'échelle de gris du pixel voisin est inférieure à celle du pixel central, tandis que 1 indique le contraire. Il faut concaténer le flux binaire de tous les voisins est ensuite converti en décimal et est défini comme la valeur LBP du pixel central. Ce processus est expliqué avec les mathématiques suivantes expressions:

$$S(x) = \begin{cases} 1 & \text{if } x \geq 0 \\ 0 & \text{if } x < 0 \end{cases}$$

$$LBP = \sum_{p=0}^{p-1} s(g_p - g_c) 2^p$$

Où  $s(x)$  est la fonction de seuil, et  $g_c$  et  $g_p$  représentent la valeur d'échelle de gris du pixel central et le  $p$ -ème voisin respectivement. Par conséquent, la valeur binaire du  $p$ -ème voisin est multipliée par son poids correspondant  $2^p$ . LBP est calculé en additionnant ces valeurs binaires pondérées. C'est illustré sur la figure 18 qui montre que le motif binaire 01110101 est converti en  $LBP = 1 + 4 + 16 + 32 + 64 = 117$ .

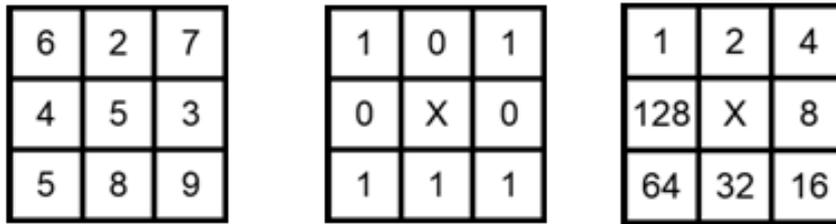


Figure 19 : Exemple Illustration du calcul du modèle binaire local (LBP) (a) exemple image, (b) patron binaire par seuillage et (c) matrice de poids

Le LBP de base a une limitation qui est la taille de 3x3 pixels voisins afin qu'il ne puisse pas capturer le domaine de texture propriétés à plus grande échelle donc pour surmonter la texture à grande échelle, LBP est développé en utilisant les plus grand locaux pixels voisins [41].

La première étape qui peut être effectuée en développant une taille de pixel locale consiste à définir la texture  $T$  dans l'environnement voisin de l'image en niveaux de gris  $P + 1$  ( $P > 0$ ) comme dans la formule suivante :

$$T = t(r_c, r_0, \dots, r_{p-1})$$

Où  $r_c$  est la valeur centrale des pixels locaux voisins.  $r_p$  ( $P=0, \dots, P-1$ ) est la valeur en pixels de l'échelle de gris  $P$  avec un espace ou une distance égale au rayon du cercle  $R$  ( $R > 0$ ) formera un voisin symétrique circulaire voisin.

La figure 19 : illustrations de pixels locaux voisins où les valeurs  $P$  et  $R$  varient ( $P, R$ ), montre la valeur du pixel voisin  $P$  avec un rayon de tir de  $R$  valeur. La valeur d'un pixel voisin incorrect tombant sur le pixel sera calculée en utilisant une interpolation bilinéaire.

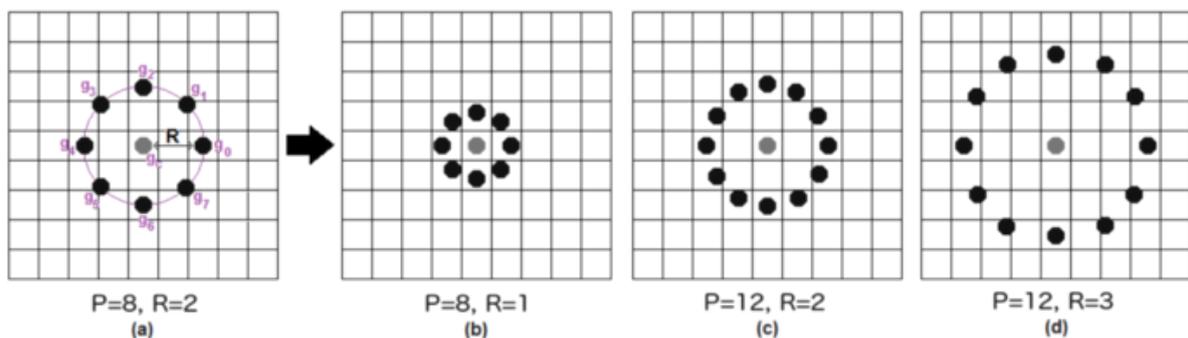


Figure 20 : Illustrations de pixels locaux voisins

Selon la position ou bien la distance par rapport au pixel centrale (ou rayon) et la distance orientation des points d'échantillonnage (voisins), des différentes formes de modèles binaires locaux peuvent être réalisées. Dans ce qui suit sections, nous décrivons trois des variations les plus populaires de LBP: LBP de base, LBP uniforme et LBP simplifié.

### **LBP de base**

C'est le modèle le plus couramment utilisé pour LBP. En base LBP, un quartier  $3 \times 3$  est envisagé autour du pixel central, LBP est calculé en utilisant les huit pixels voisins. Par conséquent, le LBP de base peut représenter  $2^8 = 256$  modèles uniques.

### **LBP uniforme**

Il s'agit d'une version étendue du LBP de base. L'uniforme LBP place tous les modèles binaires avec plus de deux transitions de 0 à 1 et de 1 à 0 dans une seule catégorie, appelée LBP non uniforme. En revanche, chaque modèle binaire qui a deux transitions ou moins est appelé le modèle uniforme, il est affecté à une valeur LBP unique. Par exemple, le motif binaire 00110100 a quatre transitions, donc c'est un non uniforme modèle. D'un autre côté, le modèle binaire 00110000 à deux transitions, c'est donc un motif uniforme. L'idée derrière LBP uniforme est que les motifs non uniformes se produisent si rarement que leur probabilité ne peut être estimée correctement. Par conséquent, les motifs non uniformes doivent être éliminés comme caractéristique utile. LBP uniforme offre une réduction importante des fonctionnalités et peut améliorer les performances du classifieur.

### **LBP simplifié**

Le LBP ou S-LBP simplifié est introduit par Lui et al [42]. S-LBP utilise seulement trois points d'échantillonnage. Cependant, la position de ces points est déterminée empiriquement. S-LBP a démontré des résultats prometteurs.

### **5.1.3. Autres variantes de LBP**

Afin d'extraire efficacement les caractéristiques de texture de diverses complexités, l'opérateur LBP d'origine a été modifié pour générer un certain nombre de variantes.

### 5.1.3.1. LBP amélioré (ILBP)

La principale différence entre ILBP [43] et LBP simple est que, au lieu de l'intensité du pixel central, la valeur d'intensité moyenne de tous les pixels, y compris le pixel central, est utilisée pour trouver la différence d'intensité pendant le calcul du motif. En plus de cela, lors du calcul de l'ILBP, l'intensité du pixel central est également comparée à l'intensité moyenne. ILBP est formellement défini comme suit:

$I_{cen}$  et  $I_p$  représentent les valeurs de gris du pixel central et du pixel voisin, respectivement.

$$ILBP_{(P,R)}(x_{cen}, y_{cen}) = \sum_{n=0}^{P-1} f(I_n - I_{mean}) \times 2^n + f(I_{cen} - I_{mean}) \times 2^P,$$

$$I_{min} = \frac{(\sum_{n=0}^{P-1} I_n)}{P + 1}$$

Comme ILBP considère en plus le centre du pixel, ainsi la valeur d'ILBP ( $M, P$ ) ( $x_{cen}, y_{cen}$ ) peut varier de 1 à 511 (voir la Figure suivante).

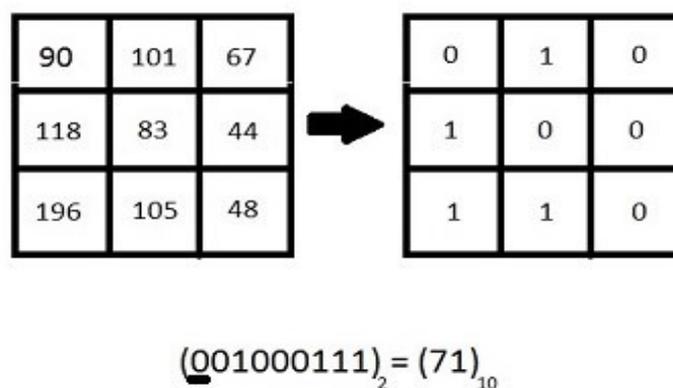


Figure 21 : Illustration de la génération de valeur ILBP pour une fenêtre d'image grise  $3 \times 3$ , où  $P = 8$ ,  $R = 1$  et  $[I]_{mean} = 94$

Le bit représentant le pixel central a été souligné dans la représentation binaire de la valeur LBP.

### 5.1.3.2. LBP invariant de rotation (RILBP)

RILBP [44] est obtenu par rotation bit par bit (circulaire) des motifs binaires puis par sélection de la valeur minimale. Ceci est fait pour annuler l'effet de rotation sur une texture, ce

qui change le LBP, bien que la texture considérée soit essentiellement la même. Le RILBP peut être formellement défini comme suit:

$$RILBP_{(P,R)}(x_{cen}, y_{cen}) = \min\{Rot(LBP_{(P,R)}, i, 0 \leq i \ll P - 1)\}.$$

Ici,  $Rot(A, i)$  est une fonction qui prend un motif binaire de M bits «A» et effectue une opération de décalage à droite circulaire bit par bit sur «A». L'ensemble du processus est illustré à la figure :

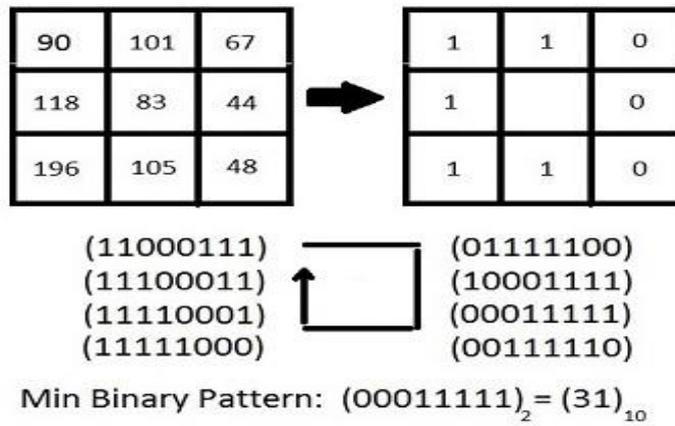


Figure 22 : Illustration de la génération de valeur RILBP pour une fenêtre d'image grise  $3 \times 3$ , où  $P = 8$  et  $R = 1$

### 5.1.3.3. Rotation invariante et uniforme LBP (RIULBP)

Dans RIULBP [44], les motifs sont choisis de telle sorte qu'ils soient à la fois invariants et uniformes en rotation. Semblable à l'ULBP, ici aussi tous les modèles invariants de rotation non uniformes sont placés dans un bac séparé. Cette variante de LBP peut être formulée comme :

$$RIULBP_{(P,R)}(x_{cen}, y_{cen}) = \begin{cases} \sum_{n=1}^P f(I_n - I_{cen}), \\ \text{si } U(RILBP_{(P,R)}(x_{cen}, y_{cen})) \geq 2, P + 1 \\ \text{sinon} \end{cases}$$

$$U(RIULBP_{(P,R)}) = \left( \sum_{n=2}^P |f(I_n - I_{cen}) - f(I_{n-1} - I_{cen})| + |f(I_P - I_{cen}) - f(I_1 - I_{cen})| \right)$$

### 5.1.3.4. LBP robuste et uniforme (RULBP)

C'est une modification mineure mais significative de LBP robuste (RLBP) pour développer RULBP. Dans RLBP, l'argument de la fonction  $f(x)$  la valeur de  $I_n$  doit être supérieure à la valeur de gris du pixel central  $I_{cen}$  d'une quantité  $th$  pour produire un 1 [45]. Ce descripteur est conçu avec l'idée d'augmenter la robustesse à des changements négligeables de la valeur de gris. Par conséquent, le RLBP peut être formellement défini comme suit:

$$RLBP_{(P,R)} = \sum_{n=1}^P f(I_n - I_{cen} - th) \times 2^{n-1}$$

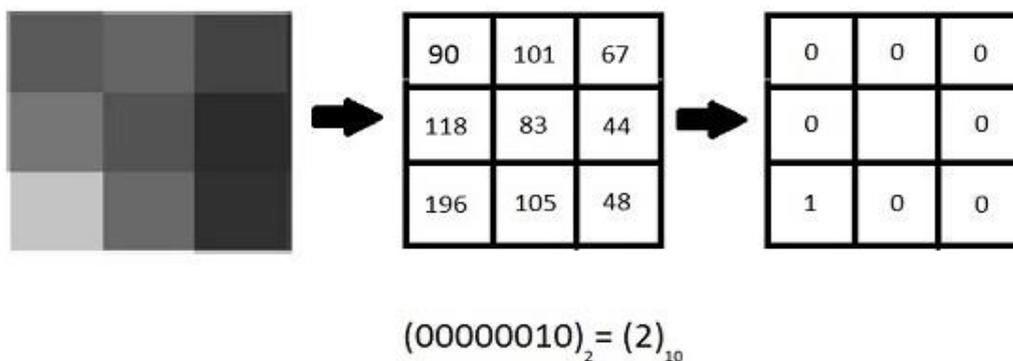


Figure 23 : Illustration de la génération de valeur RLBP pour une fenêtre d'image grise  $3 \times 3$ , où  $p = 8$  et  $R = 1$ . Ici, la valeur de  $th = 90$

Une fois le motif binaire local calculé pour tous les pixels, l'image convertie LBP est divisée en plusieurs zones ou blocs. L'histogramme local de chaque bloc est ensuite calculé séparément. Enfin, ces histogrammes locaux sont concaténés et exploités comme caractéristiques pour la classification des images. Ce processus est illustré dans la figure 15.

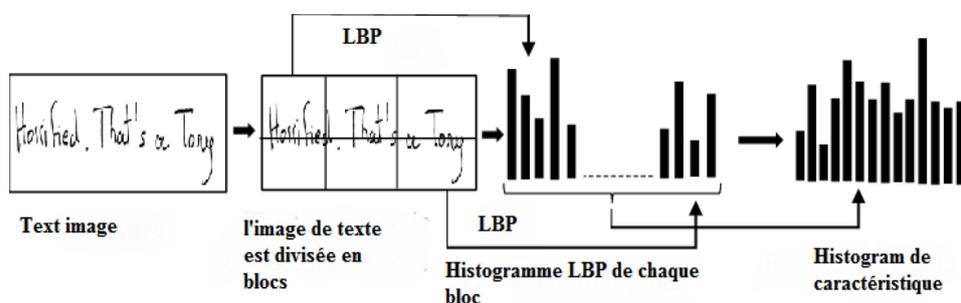


Figure 24 : Illustrations de LBP extraction de l'histogramme des caractéristiques dans un exemple de détermination du sexe de l'écrivain selon son écriture

Ensuite l'opération de normalisation l'histogramme qui est optionnelle. Cette Concaténation (normalisation) histogrammes de toutes les cellules donne un vecteur caractéristique pour la fenêtre de l'image traité.

Le vecteur de fonction peut maintenant être traité à l'aide de la machine à vecteur de support, ou un autre algorithme d'apprentissage pour classer les images. Ces classifieurs peuvent être utilisés pour la reconnaissance d'écriture manuscrite ou d'autres types qu'on a déjà abordés. Une extension de l'opérateur d'origine comme d'un modèle uniforme est appelée, et utilisée pour la réduction de la longueur du vecteur caractéristique et mettre en œuvre une simple rotation des descripteurs invariants. Cette idée est le résultat du fait que certains modèles binaires se produisent plus fréquemment dans les images que d'autres. Un modèle binaire local est appelé uniforme si le patron binaire contient au maximum deux 0-1 ou 1-0 transitions. Par exemple, 00010000 (2 transitions) est un patron uniforme, 01010100 (6 transitions) est pas. Dans le calcul de l'histogramme de LBP, l'histogramme a un bac séparé pour chaque patron uniforme, et tous les modèles non uniformes sont affectés à un seul bac. Utilisation de patrons uniformes, la longueur du vecteur de caractéristique pour une cellule unique réduit de 256 à 59. Les 58 motifs binaires uniformes correspondent aux nombres entiers suivants :

0, 1, 2, 3, 4, 6, 7, 8, 12, 14, 15, 16, 24, 28, 30, 31, 32, 48, 56, 60, 62, 63, 64, 96, 112, 120, 124, 126, 127, 128, 129, 131, 135, 143, 159, 191, 192, 193, 195, 199, 207, 223, 224, 225, 227, 231, 239, 240, 241, 243, 247, 248, 249, 251, 252, 253, 254 et 255.

#### 5.1.4. Avantages et inconvénients de LBP

La propriété la plus importante pour LBP opérateur dans l'application du monde réel est que l'opérateur LBP est invariant à la variance monotone au niveau de gris, tels que la variance du niveau d'éclairage [46]. L'autre importante chose est la simplicité du calcul, qui permet d'analyser l'image sur la modification des paramètres en temps réel [47].

Les inconvénients de LBP:

- Inefficace en cas de région bruyante.
- Sur-ajustement en cas d'images basses résolution.
- L'opérateur LBP produit de longs histogrammes sensibles à rotation de l'image.
- Le LBP a un petit support spatial; dans sa forme de base, l'opérateur LBP ne peut pas détecter correctement les structures texturales à grande échelle.

- LBP perd des informations texturales locales, car seuls les signes de différences des pixels voisins sont utilisés.
- LBP est très sensible au bruit. La moindre fluctuation au-dessus ou en dessous de la valeur du pixel central est traité comme équivalent à un contraste important entre le pixel central et son environnement.

## 5.2. Classification en SVM

### 5.2.1. Définition

Support vector machine en anglais appelé également «maximum margin classifieur» (séparateur à marge maximale), sans aucun doute est l'une des plus réussis et populaire forme de modèle d'apprentissage automatique supervisé grâce à leur succès dans le domaine de reconnaissance d'écriture manuscrite et des chiffres. En apprenant des exemples fournis- les données d'apprentissage - le modèle trouve une fonction qui attribue les données d'entrée à la sortie correcte. La sortie des nouvelles données peut ensuite être prédite en appliquant la fonction extraite. SVM est souvent utilisé pour problèmes de classification pour lesquels la sortie correcte est la classe à laquelle les données appartiennent aussi la régression, détection des valeurs aberrantes et dans les problèmes de clustering. Le modèle fonctionne en créant un hyperplan qui sépare les points de données d'une classe de ceux de l'autre classe, avec une marge aussi élevée que possible. La marge est la largeur maximale de la dalle parallèle à l'hyperplan qui n'a pas de points de données intérieurs. Les vecteurs supports qui donnent son nom au modèle sont les points de données les plus proches de l'hyperplan et déterminent donc la marge. Les SVM sont généralement basé sur la théorie de l'apprentissage statistique [48] et vérifiant la théorie de la minimisation de risque, c'est-à-dire trouver le séparateur qui minimise la somme de l'erreur de l'apprentissage [49], ils se reposent sur les notions : une fonction Kernel et marge maximale.

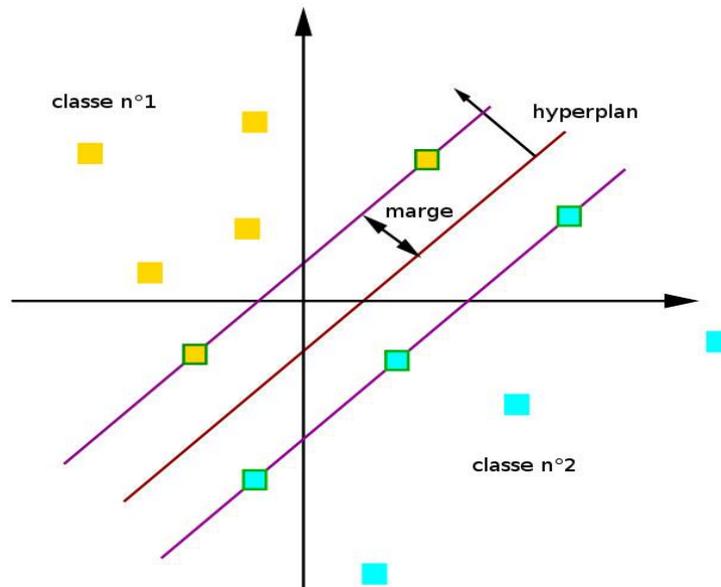


Figure 25 : Exemple de classification de deux classes en SVM

### 5.2.2. Apprentissage statistique et SVM

La notion d'apprentissage est un concept fondamental dans les SVM, il sert à réaliser des résultats par des traitements et exemples particuliers qui sont composés d'un ensemble de couples entrée/sortie.

L'apprentissage se divise en deux types : supervisé et non supervisé, le cas qui considère les SVM c'est l'apprentissage supervisé, dont le plus important objectif est de regrouper des méthodes capables de traiter et analyser les données d'apprentissage, déduire des règles permettant de prédire le comportement ou d'identifier la classe à laquelle une donnée appartient. Ces méthodes sont souvent sous la forme d'une fonction qui correspond aux exemples vus et qui permet de prédire les sorties pour les entrées qui n'ont pas été traitées, les entrées représentent souvent les descriptions d'objets (Data) et la sortie est la classe à laquelle appartient les objets d'entrée (Label).

### 5.2.3. Rôle d'apprentissage statistique en SVM

Pour mieux comprendre le rôle de la théorie d'apprentissage statistique dans SVM coté mathématique, on prend comme exemple de la classification Bi-classe (de deux classes) qui se base sur l'estimation d'une fonction d'apprentissage  $f: x \rightarrow \{+1, -1\}$  [44]

L'ensemble d'apprentissage peut prendre les couples  $(x_i, y_i)$ , selon une distribution de probabilité  $(x, y)$  inconnue, tel que :

$$(x_i, y_i) \in X \times Y \text{ où } i=1, \dots, N \text{ et } y = \{+1, -1\}$$

De sorte à ce que  $f$  classe correctement des exemples inconnus  $(x_i)$ . Prenant le cas où on peut affecter  $x_k$  à la classe (+1) si  $(x_k) \geq 0$ , sinon à la classe (-1).

L'ensemble des exemples inconnus suivent la même distribution  $P(x, y)$  comme dans l'ensemble d'apprentissage. Pour obtenir la fonction optimale  $f$  en doit minimiser le risque par cette fonction:

$$R[f] = \int L[f(x), y] dP(x, y).$$

Où  $L$  est une fonction de coût, par exemple :

$$L[f(x), y] = (f(x) - y)^2.$$

## 5.2.4. Le sur-apprentissage et le sous-apprentissage

### 5.2.4.1. Sur-apprentissage

Le sur-apprentissage (overfitting en anglais) survient quand le modèle statistique est entraîné avec beaucoup de données. Lorsqu'un modèle est formé avec une grande masse de données, il apprend du bruit et des entrées de données inexactes dans l'ensemble de données. Ensuite, le modèle ne catégorise pas correctement les données, en raison de trop de détails et de bruit [50].

Les raisons du sur-apprentissage sont les méthodes non paramétrées et non linéaires, et dans les algorithmes d'apprentissage automatique ont beaucoup de liberté dans la construction du modèle fondé à partir de l'ensemble de données et peuvent donc vraiment construire des modèles irréalistes.

Techniques pour réduire le sur-apprentissage:

1. Augmentez les données d'entraînement.
2. Réduisez la complexité du modèle.
3. Arrêt prématuré pendant la phase d'entraînement.

### 5.2.4.2. Sous-apprentissage

Le sous-apprentissage (underfitting en anglais), On dit qu'un modèle statistique ou un algorithme d'apprentissage automatique est dans le cas du sous-apprentissage lorsqu'il ne peut pas capturer la tendance sous-jacente des données [50]. Un sous-ajustement détruit la précision du modèle d'apprentissage automatique. Son occurrence signifie simplement que le modèle ou l'algorithme ne correspond pas assez bien aux données. Cela se produit généralement lorsqu'il y a un problème de manque des données pour construire un modèle précis et également de la construction d'un modèle linéaire avec des données non linéaires.

Techniques pour réduire le sous-apprentissage :

1. Augmenter la complexité du modèle
2. Augmenter le nombre de fonctionnalités, effectuer l'ingénierie des fonctionnalités
3. Supprimez le bruit des données.
4. Augmentez le nombre d'époques ou augmentez la durée de la formation pour obtenir de meilleurs résultats.

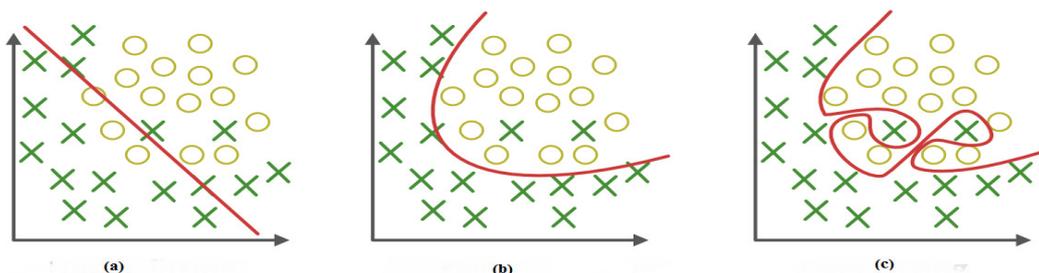


Figure 26 : Exemple des cas d'apprentissage dans une SVM : (a) sous-apprentissage (b) le cas idéal (c) sur-apprentissage

### 5.2.5. Principe de SVM

Leur principe est simple : ils ont pour objectif de distinguer entre les données en classes à l'aide d'une borne simple, de telle façon que la distance entre les différents groupes de données et la borne qui les sépare soit maximale. Cette distance est appelée marge et les SVM sont ainsi compétent comme séparateurs à vaste marge, les vecteurs de support étant les données les plus proches de la borne [51].

L'objectif principal est de séparer le jeu de données donné de la meilleure façon possible. La distance entre les points les plus proches est appelée la marge. L'objectif est de sélectionner un hyperplan avec la marge maximale possible entre les vecteurs de support

dans l'ensemble de données donné pour mieux classer les nouveaux exemples. SVM recherche l'hyperplan marginal maximal dans les étapes suivantes:

- Générez des hyperplans qui séparent les classes de la meilleure façon. Figure de gauche montrant trois hyperplans noir, bleu et orange. Ici, le bleu et l'orange ont des erreurs de classification plus élevées, mais le noir sépare correctement les deux classes.
- Sélectionnez l'hyperplan droit avec la séparation maximale des points de données les plus proches.

Un hyperplan est un plan de décision qui sépare un ensemble d'objets ayant différentes appartenances à une classe. La dimension de l'hyperplan est directement proportionnelle au nombre d'entités. En général, la classification d'un nouvel exemple inconnu pour le modèle est donnée par sa position par rapport à l'hyperplan optimal.

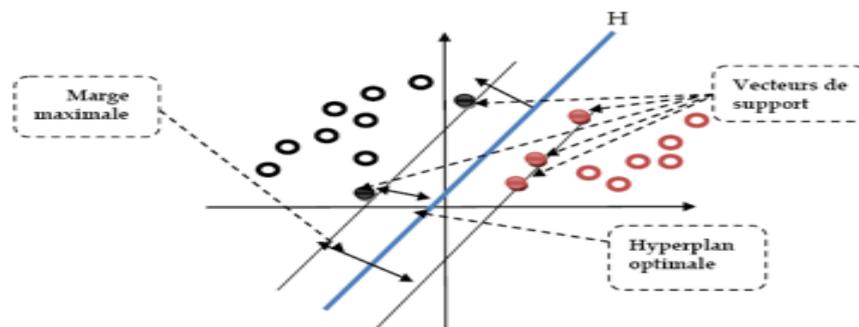


Figure 27 : Les différents composants de base d'une SVM

Selon les données, la performance des SVM est en général de même ordre voire supérieure à celle d'un réseau de neurones ou d'un modèle de mélanges gaussiens, à l'exception de certains cas notables comme la classification d'images. Il a aussi été montré que la performance des SVM est en général la même ou plus à celle d'un réseau de neurones ou d'un modèle de mélanges gaussiens, à l'exception des cas comme la classification d'images. Les SVM évoluent comme un « approximateur universel » c'est à dire qu'avec un grand nombre de données, l'algorithme peut toujours trouver la meilleure borne possible pour séparer deux classes (à condition qu'elle existe) [51].

### 5.2.6. Types de SVM

SVM peut être de deux types:

**SVM linéaire:** ce type de SVM est spécifié pour les données linéairement séparables, ce qui signifie que si un ensemble de données peut être classé en deux classes à l'aide d'une seule ligne droite, ces données sont appelées données linéairement séparables et le classificateur est appelé classifieur SVM linéaire.

**SVM non linéaire:** SVM non linéaire est utilisé pour les données séparées non linéairement, ce qui signifie que si un ensemble de données ne peut pas être classé en utilisant une ligne droite, ces données sont appelées données non linéaires et le classifieur utilisé est appelé non- classifieur SVM linéaire, la solution dans ce cas est de changer l'espace de représentation des données par exemple en 3D à l'aide d'une fonction noyau ce qui augmente la probabilité de trouver un hyperplan[52].

### 5.2.7. Fonctions noyaux (Kernel)

Les algorithmes SVM utilisent un ensemble de fonctions mathématiques définies comme le noyau. Le rôle principal de cette fonction du noyau est de prendre des données en entrée et de les transformer dans la forme requise. Différents algorithmes SVM utilisent différents types de fonctions du noyau. Il existe plusieurs types des fonctions noyaux, par exemple, linéaire, non linéaire, polynomiale, fonction de base radiale (RBF) et sigmoïde.

Ils renvoient le produit interne entre deux points dans un espace de fonctionnalités approprié. Ainsi en définissant une notion de similarité, avec peu de coût de calcul même dans des espaces de très grande dimension.

### 5.2.8. Avantages et inconvénients des SVM

Les avantages des machines vectorielles de support sont:

- Efficace dans un espace de grande dimension. Toujours efficient dans les cas où le nombre de dimensions est supérieur au nombre d'échantillons.
- Optimisation garantie: En raison de la nature de l'optimisation convexe, la solution sera toujours un minimum global, pas un minimum local.
- L'abondance des implémentations: nous pouvons y accéder facilement, que ce soit depuis Python ou Matlab.

- SVM peut être utilisé pour des données séparables linéairement Séparables ou non. Les données linéairement séparables constituent la marge ferme, tandis que les données non linéairement séparables constituent une marge souple.
- Les SVM assurent la conformité aux modèles d'apprentissage semi-supervisé. Il peut être utilisé dans les zones où les données sont étiquetées ou non. Il ne nécessite qu'une condition au problème de minimisation.
- Utilise un sous-ensemble de points d'apprentissage dans la fonction de décision (appelés vecteurs de support), donc il est également bon en terme mémoire.
- Des différentes fonctions du noyau peuvent être spécifiées pour la fonction de décision.

Les inconvénients des machines vectorielles de support incluent:

- Pour un ensemble de données plus volumineux, le traitement demande beaucoup de temps.
- Les SVM ne fournissent pas directement d'estimations de probabilité comme résultat, celles-ci sont calculées à l'aide d'une validation croisée coûteuse en cinq fois.
- SVM n'offre pas les meilleures performances pour la gestion des structures de texte par rapport aux autres algorithmes utilisés pour gérer les données de texte. Cela entraîne une perte d'informations séquentielles et, par conséquent, une dégradation des performances.
- Le choix du noyau est peut-être la plus grande limitation de la machine vectorielle de support. Compte tenu du nombre de noyaux présents, il devient difficile de choisir le bon pour les données.

## 6. Travaux ultérieurs dans la reconnaissance des chiffres manuscrits

Éditeur	Taux	Techniques d'extraction et classification utilisées.
Gorgevik et Cakmakov	97.27%	SVM pour les chiffres romains manuscrits.
Chen et al	98.76%	Infrastructure de pseudoprobabilités postérieures max-min pour la reconnaissance de chiffres manuscrits romains.
Labusch et al	99.41%	Méthode d'extraction de caractéristiques basée sur le codage épars avec SVM comme classificateur sur MNIST (NIST modifié).
Mane et Ragha	94.91%	SVM
Cruz et al	99.68%	Méthodes d'extraction de caractéristiques multiples et réseaux de classifieur neuraux
Yang et al	98.71%	Méthode de factorisation matricielle améliorée utilisée directement comme classificateur multi classe
Akhtar et H	97.04%	SVM and $k$ -Nearest Neighbor ( $k$ -NN)
Dan and C	77.67%	Le réseau neuronal utilisant l'algorithme de Backpropagation (BP)
AlKhateeb and Alseid	85.26%	Système de reconnaissance des chiffres manuscrits en arabe utilisant le réseau bayésien dynamique
Gil et al	99%	Classifieurs binaires SVM et arbres de décision déséquilibrés
El Qacimy et al	98.76%	SVM
AL-Mansoori	99.32%	Classificateur MLP pour reconnaître et prédire les chiffres manuscrits
Ebrahimzadeh et Jampour	97.25%	SVM+HOG

Tableau 2 : Travaux ultérieurs dans la reconnaissance des chiffres

---

## 7. Conclusion

Dans ce chapitre nous avons présenté quelques caractéristiques de l'image numériques puis les méthodes utilisées dans l'extraction des caractéristiques.

Ensuite une comparaison entre quelques techniques d'extraction des caractéristiques en termes d'avantage et inconvénient,

Enfin une étude détaillée sur les versions de méthodes LBP qui est l'objet de notre travail le classifieur SVM est choisi pour valider notre travail.

Le chapitre suivant sera consacré à la conception et l'implémentation du notre système et les résultats.

---

# **Chapitre 3 :**

## Conception et Implémentation

---

## 1. Introduction

Ce chapitre est consacré à la conception et la réalisation de notre système. La première partie de ce chapitre est la conception de notre approche de reconnaissance par LBP. Tandis que la seconde partie c'est l'implémentation de ce système.

Nous commencerons d'abord par détailler le principe de la méthode LBP, puis nous représenterons la base de données dans lesquelles les tests ont été effectués.

Ensuite on va présenter les expériences effectuées et résultats obtenus dans le cadre d'extraction des caractéristiques et classification d'image des chiffres manuscrits.

## 2. Présentation de notre technique

L'application de la méthode LBP dans la reconnaissance de chiffres manuscrits convertit les images des chiffres en modèles binaires locaux ('local binary patterns'), et détermine l'histogramme.

1. La valeur LBP est calculée pour chaque pixel par le seuillage de ses voisins avec un seuil dont la valeur est le niveau de gris du pixel en question. Tous les voisins prendront alors une valeur 1 si leur valeur est supérieure ou égale au pixel courant et 0 si leur valeur est inférieure. Le code LBP du pixel courant est alors produit en concaténant ces valeurs pour former un code binaire qui sera ensuite transformé en décimal. On obtient donc, comme pour une image à niveaux de gris, une image des valeurs LBP. On calcule l'histogramme de chaque image
2. Les opérations précédentes sont répétées pour chaque image de la base de donnée le résultat est enregistré dans une matrice et un vecteur tel que chaque ligne de la matrice représente l'histogramme concaténé d'une image, et le vecteur représente l'étiquette de chaque ligne de la matrice.
3. Dans la phase de classification on cherche le meilleur taux de reconnaissance, en utilisant le classifieur SVM ( $c=10$ ,  $\sigma=1...100$ ), Après l'étape d'extraction des caractéristiques, nous procédons à la classification des images en se basant sur les différents descripteurs. Dans ce travail, la méthode de classification *SVM* a été considérée vu son efficacité et sa flexibilité au niveau des protocoles d'expérimentation. Dans la phase de classification on cherche le meilleur taux de reconnaissance, en utilisant le classifieur SVM ( $c=10$ ,  $\sigma=1...20$ ), quelle peut fournir sur la base CVL, avec les descripteurs (P, R).

### 3. Schéma générale

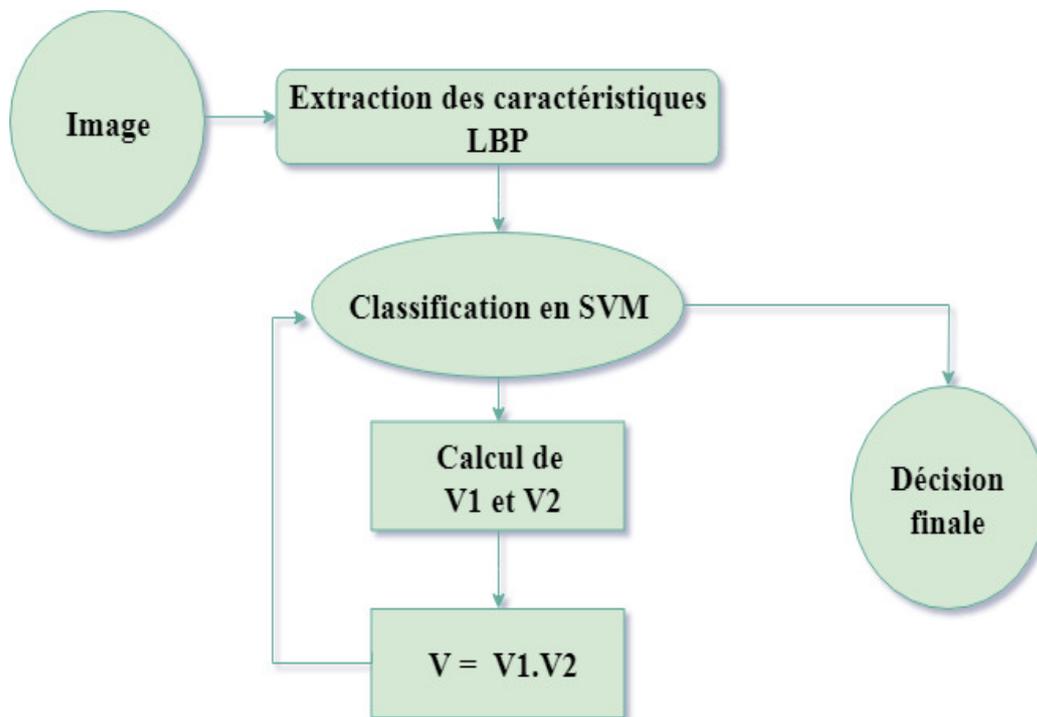


Figure 28 : Schéma général du système de reconnaissance de chiffres manuscrits

Pour les couples (P, R) on cherche les deux couples (P, R1), (P, R2) qui donne les meilleurs taux de reconnaissance.

- V1 vecteur de caractéristiques pour LBP  $(P1, R1)$
- V2 vecteur de caractéristiques pour LBP  $(P2, R2)$
- $V=V1.V2$
- Classification SVM (V,  $\sigma=1...20$ , C=10)

## 4. Implémentation

### 4.1 Environnement de développement

Dans cette partie on présente l'environnement déployé pour réaliser ce travail.

#### 4.1.1 Ressources matériels

Un ordinateur DELL avec les caractéristiques suivantes :

- Processeur Intel ® Core™ i5-2520 M, d'une fréquence de 2.50 GHz
- Une mémoire vive d'une capacité de 4,00 Go.
- Une carte graphique Intel® HD Graphics 3000.

#### 4.1.2 Ressource logiciel

##### - Langage MATLAB :

(MATrix LABoratory) est un logiciel de calcul de calcul scientifique avec une base matriciel, une syntaxe simple et une grande variété des fonctions spécialisées dans divers spécialités. Grâce à la vaste bibliothèque de boîtes à outils prédéfinies, on peut commencer directement par les algorithmes essentiels à pour chaque domaine. Les outils et les fonctions du MATLAB sont tous testés rigoureusement. Ils sont conçus pour fonctionner conjointement. Il est aussi interactif avec les autres langages tels que C, C++, Java, Fortran.

### 4.2 Base de données CVL

La base de données CVL (Computer Vision Lab) a été utilisée dans la reconnaissance de chiffres manuscrits, elle est composée de 7000 chiffres uniques pour l'apprentissage (700 chiffres par classe) et 21000 chiffres uniques pour le test (2100 chiffres par classe) écrits par environ 60 rédacteurs différents.

## 5. Résultats et discussions

<b>R</b>	<b>P</b>	<b>Taux</b>	<b><math>\delta</math></b>	<b>C</b>
4	1	53,26	5	10
4	2	<b>60.10</b>	4	10
4	4	<b>72.43</b>	3	10
8	1	67,90	10	10
8	2	<b>81,19</b>	7	10
8	4	<b>85,65</b>	8	10
8	8	70,35	3	10
16	1	68,60	19	10
16	2	<b>82,99</b>	16	10
16	4	<b>87,50</b>	18	10
16	8	75,63	7	10
16	16	58.24	11	10

Tableau 3 : Résultats de classification pour LBP (P, R)

### Taux de classification :

Le taux de classification calcule le rapport entre le nombre d'échantillons correctement classifiés et le nombre total d'échantillons considérés.

Ensuite pour chaque LBP (P, R) on calcule les deux vecteurs :

- V1 vecteur de caractéristiques pour (P1, R1)
- V2 vecteur de caractéristiques pour (P2, R2)
- Concaténation :  $V=V1.V2$
- Classification SVM (V,  $\sigma=1...20$ , C=10)

**Résultats obtenu :**

<b>(R, P)</b>	<b>Taux</b>	<b><math>\delta</math></b>	<b>C</b>
(4,2) (4,4)	73.14	9	10
(8,2) (8,4)	<b>88.74</b>	14	10
(16,2) (16,4)	<b>90.13</b>	17	10

*Tableau 4 : Résultats de classification pour LBP (P, R)*

D'après les résultats obtenus, l'amélioration appliquée à la méthode d'extraction des caractéristiques multiscale-LBP (Local Binary Pattern) permet d'augmenter effectivement le taux de reconnaissance des chiffres manuscrits non normalisés.

## 6. Conclusion

On a présenté dans ce chapitre notre technique proposée, où on a utilisé la méthode LBP multiscale pour l'extraction des caractéristiques.

Ensuite on a évalué la méthode d'extraction des caractéristiques par en utilisant le classifieur SVM qui est l'une des plus réussis modèle d'apprentissage.

---

# **Conclusion Générale**

---

## Conclusion générale

La reconnaissance automatique d'écriture et chiffres manuscrits présente toujours un domaine de recherche intéressant et bien exploré à cause de ces différentes applications industrielles dans des divers domaines, malgré les grands efforts et l'énorme nombre des travaux dans ce domaine aucun système de reconnaissance d'écriture et chiffres manuscrit n'est totalement fiable, mais il y a des progrès et les chercheurs essayent d'améliorer les résultats de reconnaissance ce qui introduise beaucoup d'utilité et facilite les activités de l'être humain.

L'objectif de notre travail est l'application de la méthode LBP multiscale pour la reconnaissance des chiffres manuscrits en utilisant le classifieur SVM.

Nos expérimentations ont été effectuées sur la base CVL qui contient des chiffres non-normalisés de 0 à 9, on a utilisé pour valider notre travail le classifieur SVM.

On peut envisager plusieurs perspectives possibles :

- Combiner la méthode d'extraction des caractéristiques LBP avec des autres méthodes.
- Utiliser un autre classifieur comme Kmeans, HMM et CNN.
- Appliquer notre approche aux mots manuscrits.

## Références bibliographiques

- [1] S.Haitaamar : " segmentation de texte en caractère pour la reconnaissance optique de l'écriture arabe". Université EL-HADJ LAKHDHAR Batna, Juillet 2007.
- [2] Bernsen. Dynamic thresholding of gray-level images. Proc. 8th Int. Conf. Pattern Recognition Paris, pages 1251–1255, 1986.
- [3] B.Riadh, «Système de reconnaissance hors-ligne des mots manuscrits arabe pour multi-scripteurs»; Thèse de Master, FSJEGJ Jendouba, 2006.
- [4] R.Azizi, «Une approche Hybride pour la reconnaissance d'écriture arabe manuscrite» Université de constantine, Constantine, 2007.
- [5] D.GACEB Contributions Au Tri Automatique De Documents Et De Courrier d'entreprises, INSA De Lyon, Thèse, 2009.
- [6] N. Otsu. A threshold selection method from gray-level histograms. In IEEE Trans.
- [7] Shubair A et al: " Off-line Arabic handwritten word segmentation using rotational invariant segments features ". The international Arab journal of information technology, Vol. 5, No. 2, April 2008.
- [8] R.Ensiwiki, «projet de reconnaissance hors-ligne des images dans les documents» Université de Paris, 2016.
- [9] T. Steinherz, E. Rivlin, N. Intrator: «Off-line cursive word recognition: a survey ». International journal on document analysis and recognition, 2(2), pp. 90-110, 1999.
- [10] M. Bozinovic, S. N. Srihari. Off-line Cursive Script Word Recognition. IEEE trans. On Pattern Analysis and Machine Intelligence, vol. 11, no. 1; 1989.
- [11] F. Grandidier. Un nouvel algorithme de sélection de caractéristiques – application la lecture automatique de l'écriture manuscrite. PhD thesis, Univ du Québec, 2003.
- [12] F.Biadsy, SEI-Sana, N.Habash, "Online Arabic handwriting recognition using Hidden Markov Models", Proceeding of IWFHR'06, 10th International Workshop on Frontiers in Handwriting Recognition, pp. 85-90, La Baule, France 2006.
- [13] A. Belaid, et Y. Brlaid, « Reconnaissance des formes. Méthodes et application »; P : 14 – 17, 1992.

- [14] P.M Lallican, C. Viarp-Gaudin and S. Knerr, « From off-line to on-line handwriting recognition ». Proc. 7th workshop on frontiers in handwriting recognition, pp. 303-312, Amsterdam, 2000.
- [15] N.Benamara, «Utilisation des modèles de Markov cachés planaires en reconnaissance de l'écriture arabe imprimée,» Thèse de doctorat, Université des Sciences, des Techniques et de Médecine de Tunis II, Tunisie, 1999.
- [16] G.Abdeldjalil, «Segmentation automatique pour la reconnaissance numérique des chèques bancaires Algériens » ; Thèse de MAGISTER, centre Universitaire de Khanchela, 2011.
- [17] V.Vapnik, 1995 .the nature of statistical learning thory. springer\_verlag, V. K. Govindan, 1990. « Character recognition - A review » ; Department of Electrical communication engineering, India; CNED'94; P 671-672, New\_York, USA, 1995.
- [18] Wang, J., Chen, Q., & Chen, YRBF kernel based support vector machine with universal approximation and its application. In *International Symposium on Neural Networks* (pp. 512-517). Springer, Berlin, Heidelberg. . (2004, August).
- [19] P. Mahé, L. Ait-Ali : « Projet d'apprentissage statistique SVM pour l'apprentissage non supervisé», DEA MVA, Février 2003
- [20] G. K. H. B. T.M. Ha, «"Text localization and handwriting recognition,» Technical report,university of Berne, 1996.
- [21] Cocquerez J-P., Philippe S., (1995). Analyse d'images : filtrage et segmentation. Edition Masson, Paris, France.
- [22] Ryszard S. Choras, < Image Feature Extraction Techniques and Their Applications for CBIR and Biometrics Systems>.
- [23] Ivind Due Trier, Anil K. Jain and Torfinn Taxt , "Feature Extraction Methods for Character Recognition-a Survey", Pattern Recognition Vol.29, No.4, p.p.641-662 (1996)
- [24] Dargenton, «Contribution à la segmentation et la reconnaissance de l'écriture manuscrite» ; Thèse de Doctorat. Institut National des Sciences Appliquées de Lyon, 174 pages. 1994
- [25] S. Chevalier et al : « Étude de primitives spectrales pour la reconnaissance de caractères manuscrits dans le cadre d'une approche markovienne 2D », DGA/Centre d'Expertise Parisien, France, Novembre 2005.

- [26] Mohammed Cheriet, Nawwaf Kharma, Cheng Lin Liu, and Ching Suen. *Character Recognition Systems: A Guide for Students and Practitioners*. Wiley-Interscience, 2007.
- [27] N. Dalal and B. Triggs. Histograms of oriented gradients for human detection. In *CVPR*, 2005
- [28] C.W. CHONG, P. RAVEENDRAN et R. MUKUNDAN: A comparative analysis of algorithms for fast computation of zernike moments. *Pattern Recognition*, 36(3):731–742, mars 2003
- [29] J. Y. Tou, Y. H. Tay, and P. Y. Lau, “Gabor Filters and Grey-level Cooccurrence Matrices in Texture Classification,” *MMU International Symposium on Information and Communications Technologies*, 1-5 2007.
- [30] E. Rosten, R. Porter, T. Drummond *FASTER and better: a machine learning approach to corner detection* *IEEE Trans Pattern Anal Mach Intel*, 32 (2010), pp. 105-119
- [31] Yang zhan-long, Guo bao-long. Image mosaic based on SIFT. In: *International conference on intelligent information hiding and multimedia, Signal Processing*; 2009. p 1422–5.
- [32] M. Pietikainen, A. Hadid, G. Zhao, and T. Ahonen, *Computer vision using local binary patterns*. Springer, 2011, vol. 40.
- [33] Ojala, T., Pietikäinen, M. et Harwood, D. (1996). Étude comparative des mesures de texture avec une classification basée sur les distributions de caractéristiques. *Pattern Recognition*, 29, 51–59.
- [34] T. Ahonen, A. Hadid, and M. Pietikäinen, “Face recognition with local binary patterns,” in *Computer Vision-ECCV 2004*. Springer, 2004, pp.469–481.
- [35] G. Zhao and M. Pietikainen, “Dynamic texture recognition using local binary patterns with an application to facial expressions,” *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, vol. 29, no. 6, pp. 915–928, 2007.
- [36] X. Wang, T. X. Han, and S. Yan, “An hog-lbp human detector with partial occlusion handling,” in *Computer Vision, 2009 IEEE 12th International Conference on*. IEEE, 2009, pp.32–39.

- [37] M. Lutf, X. You, and H. Li, "Offline arabic handwriting identification using language diacritics," in Pattern Recognition (ICPR), 2010 20th International Conference on. IEEE, 2010, pp. 1912–1915.
- [38] L. Du, X. You, H. Xu, Z. Gao, and Y. Tang, "Wavelet domain local binary pattern features for writer identification," in Pattern Recognition (ICPR), 2010 20th International Conference on. IEEE, 2010, pp. 3691–3694.
- [39] M. Ferrer, A., A. Morales, and U. Pal, "Towards explainable writer verification and identification using vantage writers," in Document Analysis and Recognition, 2013. ICDAR 2013. Twelfth International Conference on, vol. 1. IEEE, 2013, pp. 369–373.
- [40] A. Nicolaou, M. Liwicki, and R. Ingold, "Oriented local binary patterns for writer identification," in Proceedings of the 2nd ICDAR International Workshop on Automated Forensic Handwriting Analysis, 2013.
- [41] M. Pietikäinen, A. Hadid, M. Pietikäinen and A. Hadid, Computer Vision Using Local Binary Patterns, New York: Matti Pietikäinen Abdenour Hadid, 2011.
- [42] L. Liu, H. Zhang, A. Feng, X. Wan, and J. Guo, "Simplified local binary pattern descriptor for character recognition of vehicle license plate," in Computer Graphics, Imaging and Visualization (CGIV), 2010 Seventh International Conference on. IEEE, 2010, pp. 157–161.
- [43] Jin, H.; Liu, Q.; Lu, H.; Tong, X. Face detection using improved LBP under Bayesian framework. In Proceedings of the Third International Conference on Image and Graphics (ICIG), Hong Kong, China, 18–20 December 2004; pp. 306–309.
- [44] Mohamadally .H, Fomani.B :« SVM machine à vecteurs de support ou séparateur à vaste marge », BD Web, ISTY3, Versailles St Quentin, France, janvier 2006.
- [45] Vojislav Kecman, "Learning and Soft Computing Support Vector Machines, Neural[46] Hsu C. and Lin C., "A Comparison Of Methods For Multiclass Support Vector Machines," IEEE Transactions on Neural Networks, vol. 13, no. 2, pp. 415-425, 2002 Networks, and Fuzzy Logic Models", the MIT Press 2001.
- [47] S. Hajri, F. Kallel, and A. B. Hamida, "Contrast enhancement and feature extraction algorithms of finger knucle print image for personal recognition," in Advanced Technologies for Signal and Image Processing (ATSIP), Sousse, 2018.

- [48] Bernhard Scholkopf, Alexander J. Smola “Learning with Kernels, Support Vector Machines, Regularization, Optimization, and Beyond”, the MIT Press 2002.
- [49] Vojislav Kecman, “Learning and Soft Computing Support Vector Machines, Neural Networks, and Fuzzy Logic Models”, the MIT Press 2001
- [50] Underfitting and overfitting in machine learning, online site geeks for geeks 2020a available on: <https://www.geeksforgeeks.org/underfitting-and-overfitting-in-machine-learning/>
- [51] P. Mahé, L. Ait-Ali : « Projet d’apprentissage statistique SVM pour l’apprentissage non supervisé», DEA MVA, Février 2003.
- [52] Ojala, T.; Pietikainen, M.; Maenpaa, T. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. IEEE Trans. Pattern Anal. Mach. Intell. **2002**, 24, 971–987.