

الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université 20 Août 1955 -Skikda

Faculté des Sciences

Département d'Informatique

جامعة ٢٠ أوت ١٩٥٥ سكيكدة

كلية العلوم

قسم الإعلام الآلي



**Mémoire pour l'obtention du diplôme de Master**

**Spécialité : Informatique**

**Option : Systèmes d'Information Avancés et Applications (SIAA)**

**Thème :**

**Classification d'Images dans le contexte de l'Image  
Mining : Une étude comparative selon plusieurs  
critères**

**Présenté par :**

HARBI Wissal

NEDJAR Soumaya

**Encadré par :**

Pr. BOUCHEHAM Bachir

**Session : Juin 2024**

# Remerciements :

Nous remercions les responsables de notre université (l'Université de Skikda 20 Août 1955), la faculté des sciences ainsi que les responsable du département d'informatique pour nous avoir assuré l'environnement et les conditions favorables tout au long de notre cursus.

Nous voulons aussi exprimer toute notre gratitude à notre encadreur et directeur de notre Mémoire, le Pr. Bachir Boucheham, pour son expertise, sa grande disponibilité et ses précieux conseils. Il nous a donné l'occasion de découvrir le domaine du Data mining et plus spécifiquement l'image mining. Ce mémoire n'aurait pas été possible sans son soutien inconditionnel.

Nos meilleurs pensées vont a toutes les personnes précieuses à nos cœurs, pour leur soutien, leur amour, leurs conseils, leurs aides et pour leur présence à nos côtés.

Nous remercions, enfin, tous ceux qui nous ont soutenu de près ou de loin durant la réalisation de ce travail.

# Résumé :

Ce mémoire explore la tâche de classification de l'image dans le cadre de l'image mining. Cette dernière est un sous domaine du data mining. En effet, le Data mining se présente sous 3 formes : Le mining des données structurées, le mining du multimédia et enfin le Big Data. Le data mining (en français : fouille de données), est un processus d'extraction de connaissances utiles à partir de grandes quantités de données. Il vise à identifier des patterns, des tendances et des anomalies dans les données pour prendre des décisions éclairées. Dans le détail, il existe plusieurs types de Data mining : Le mining des données structurées dans les bases de données, le Mining du multimédia qui rassemble : Le mining de la vidéo, le mining du texte, le mining de l'audio, le mining du web, le mining des réseaux sociaux, le mining des times series, l'image mining et enfin, le Big Data.

Les objectifs essentiels de ce mémoire sont axés autour des concepts suivants :

Image Mining :

L'Image Mining, ou fouille de l'image, est un domaine du Data Mining qui s'intéresse à l'analyse et à l'extraction de connaissances à partir d'images numériques. Il utilise des techniques de traitement d'image, de caractérisation des images, des techniques d'appariement des images et d'apprentissage automatique pour identifier des objets, des textures, des formes et des relations spatiales dans les images.

Classification de l'image :

La classification de l'image est une tâche fondamentale de l'Image Mining qui consiste à assigner une classe ou une étiquette à une image donnée parmi un ensemble de classes prédéfinies. Cette tâche est réalisée grâce à un classifieur. Elle est utilisée dans de nombreuses applications, telles que la reconnaissance d'objets, la détection d'anomalies, la recherche d'images par le contenu et l'analyse médicale basée image.

Techniques de classification d'images :

Il existe de nombreuses techniques de classification d'images, chacune avec ses propres avantages et inconvénients. Parmi les techniques les plus populaires, nous avons : les ré-

seaux de neurones artificiels, les arbres de décision, les Support Vector Machines (SVM) et pour finiK-Nearest Neighborr, le classifieur K-Nearest Neighbors (KNN) qui classe une image x en fonction de la classe des k images les plus proches d'elle dans l'espace des caractéristiques.

Étude comparative des classifieurs d'images :

L'étude comparative, réalisée dans le cadre de ce mémoire, analyse les performances de plusieurs classifieurs (17 classifieurs) d'images populaires sur différentes organisations des deux dataset utilisées Kimia (base médicale) et Wang (base générale), en utilisant différentes distances, différents espaces de couleur, différents descripteurs de l'image pour le classifieur KNN (K-Nearest Neighbor). Nous avons également utilisé un classifieur qui relève du Deep Learning (Les réseaux de neurones convolutifs : CNN).

Les résultats essentiels tirés de cette étude sont :

1. Nous avons constaté que tous les paramètres utilisés ont une influence sur les résultats obtenus sur les deux Dataset : la distance, l'espace de couleur, L'attributs, le classifieur et arrangement des datasets utilisés.
2. Les résultats obtenus montrent que Les CNN sont beaucoup plus efficaces dans le cas d'images riches en concepts (base Wang) que dans les images pauvres en concepts (base Kimia).
3. Certaines images se prêtent beaucoup plus facilement à être classifiées que certaines sur la base de leur richesse et leur pauvreté en concepts.

# Abstract :

This thesis explores the task of image classification within the framework of image mining, which is a subfield of data mining. In fact, data mining presents itself in three forms : structured data mining, multimedia mining, and finally, big data. Data mining is a process of extracting useful knowledge from large amounts of data. It aims to identify patterns, trends, and anomalies in the data to make informed decisions. In detail, there are several types of data mining : structured data mining in databases, multimedia mining, which includes video mining, audio mining, web mining, social network mining, text mining, time series mining, image mining, and finally, big data.

The most important objectives of this thesis are centered around the following concepts :

Image Mining :

Image mining, is a domain of data mining that focuses on the analysis and extraction of knowledge from digital images. It uses image processing techniques, image characterization, image matching techniques, and machine learning to identify objects, textures, shapes, and spatial relationships in images.

Image Classification :

Image classification is a fundamental task of image mining that involves assigning a class or label to a given image from a predefined set of classes. This task is accomplished using a classifier. It is used in numerous applications, such as object recognition, anomaly detection, content-based image retrieval, and medical image analysis.

Image Classification Techniques :

There are many image classification techniques, each with its own advantages and disadvantages. Among the most popular techniques are artificial neural networks, decision trees, support vector machines (SVM), and finally, the K-Nearest Neighbors (KNN) classifier, which classifies an image  $x$  based on the class of the  $k$  closest images to it in the feature space.

Comparative Study of Image Classifiers :

The comparative study conducted in this thesis analyzes the performance of several po-

pular image classifiers (17 classifiers) on different organizations of the two datasets used : Kimia (medical database) and Wang (general database), using different distances, different color spaces, and different image descriptors for the KNN classifier. We also used a classifier based on deep learning (CNN). The essential results drawn from this study are :

1. We found that all the parameters used have an influence on the results obtained on the two datasets : distance, color space, attribute, classifier, as well as the arrangement of the dataset used.
2. The results show that CNNs are much more effective in the case of images rich in concepts (here, the Wang database) than in the case of images poor in concepts (here, the Kimia database).
3. Some images lend themselves much more easily to classification than others based on their richness or poverty in concepts.

## الملخص :

تعالج هذه المذكرة مهمة التصنيف في إطار التنقيب عن الصور، وهو فرع من فروع استخراج البيانات. في الواقع، يأتي استخراج البيانات بثلاثة أشكال : استخراج البيانات المنظمة، واستخراج الوسائط المتعددة، وأخيراً البيانات الضخمة. استخراج البيانات هو عملية استخراج المعلومات من كميات كبيرة من البيانات. بهدف تحديد أنماط واتجاهات البيانات لاتخاذ قرارات مستنيرة.

هناك العديد من أنواع استخراج البيانات :

استخراج المعلومات المنظمة في قواعد البيانات والذي يشمل : استخراج الفيديو استخراج الصوت استخراج الويب استخراج الشبكات الاجتماعية استخراج السلاسل الزمنية استخراج الصور وأخيراً، البيانات الضخمة الأهداف الأساسية لهذه المذكرة تدور حول المفاهيم التالية :

تنقيب الصور :

التنقيب عن الصور، أو استكشاف الصور، هو مجال من مجالات استخراج البيانات يهتم بتحليل واستخراج المعرفة من الصور الرقمية. يستخدم تقنيات معالجة الصور، وخصائص الصور، وتقنيات مطابقة الصور، والتعلم الآلي لتحديد الأشياء والملمس والأشكال والعلاقات المكانية في الصور.

تصنيف الصور :

تصنيف الصور هو مهمة أساسية في التنقيب عن الصور، تتمثل في تعيين فئة أو ملصق لصورة معينة من بين مجموعة من الفئات المحددة مسبقاً. يتم تنفيذ هذه المهمة بواسطة مصنف. يتم استخدامه في العديد من التطبيقات، مثل التعرف على الكائنات، والكشف عن الشذوذ، والبحث عن الصور حسب المحتوى، والتحليل الطبيعي للصور.

تقنيات تصنيف الصور :

هناك العديد من تقنيات تصنيف الصور، ولكل منها مزايا وعيوب. من بين التقنيات الأكثر شيوعاً : الشبكات العصبية الاصطناعية، وأشجار القرار، وآلات دعم المتجهات وأخيراً، التصنيف الذي يصنف أي صورة بناءً على فئة الصور كالأقرب إليها في مساحة الميزات.

دراسة المقارنة لمصنفي الصور :

تقوم دراسة المقارنة، التي تم إجراؤها في إطار هذه المذكرة ، بتحليل أداء العديد من مصنفي الصور (١٧ مصنفاً) الشائعين على مختلف تنظيمات مجموعتي البيانات المستخدمة كيميما (قاعدة بيانات طبية) و (قاعدة بيانات عامة)، باستخدام مسافات مختلفة، وألوان مختلفة، مساحات، مميزات صور مختلفة لمصنف ك أقرب جار. هما استخدمنا مصنفاً ينتمي إلى التعلم العميق (الشبكات العصبية التلافيفية).

النتائج الأساسية المستخلصة من هذه الدراسة هي :

١- لاحظنا أن جميع المعلومات المستخدمة لها تأثير على النتائج التي تم الحصول عليها من مجموعتي

البيانات. من بين هذه المعلومات : المسافة، ومساحة اللون، والسمة، وكذلك ترتيب مجموعة البيانات المستخدمة.

٢- تُظهر نتائج الشبكة العصبية التلافيفية أنها أكثر كفاءة بكثير في حالة الصور الغنية بالمفاهيم مثل (قاعدة البيانات العامة) مقارنة بالصور الفقيرة بالمفاهيم مثل (قاعدة البيانات الطبية) .

٣- بعض الصور أسهل بكثير في التصنيف من غيرها بناءً على ثرائها أو فقرها في المعلومات.

**Mots-clés :** Data Mining, Image Mining, Espaces de couleur, Caractérisation de l'image, Classifieurs, Appariement d'images, KNN, CNN, Corel1K (Wang), Kimia path960.

# Table des matières

<b>1</b>	<b>Présentation générale du processus du Data Mining</b>	<b>28</b>
1.1	Introduction . . . . .	28
1.2	Concepts de base du Data Mining . . . . .	29
1.2.1	Définition du Data mining : . . . . .	29
1.2.2	Objectifs du Data mining : . . . . .	29
1.3	Définition du processus d'ECD (Extraction de Connaissances dans les Données) (KDD :Knowledge Discovery in Data ) : . . . . .	30
1.3.1	Les étapes du processus d'ECD [1] . . . . .	31
1.3.1.1	Sélection des données : . . . . .	31
1.3.1.2	Prétraitement des données : . . . . .	32
1.3.1.3	Réduction des données : . . . . .	32
1.3.1.4	Modélisation des données : . . . . .	32
1.3.1.5	Evaluation du modèle : . . . . .	32
1.3.1.6	Interprétation et déploiement : . . . . .	32
1.4	Les types du processus du Data Mining : . . . . .	33
1.4.1	Fouille de données structurées : . . . . .	33
1.4.1.1	Les étapes de la fouille de données structurées : . . . . .	33
1.4.1.1.1	1 - Préparation des données : . . . . .	33
1.4.1.1.2	2 - Exploration des données : . . . . .	33
1.4.1.1.3	3 - Modèles de construction : . . . . .	34
1.4.1.1.4	4- Evaluation des modèles : . . . . .	34
1.4.2	Fouille du multimédia . . . . .	34

1.4.2.1	Exemples d'applications de la fouille du multimédia : [45]	34
1.4.2.2	Mining du texte : . . . . .	36
1.4.2.2.1	Les applications du mining du texte : . . . . .	36
1.4.2.2.2	Exemples concret sur les applications du mining du texte : . . . . .	36
1.4.2.2.3	Exemples sur quelque techniques : . . . . .	37
1.4.2.3	Mining de la vidéo : . . . . .	37
1.4.2.3.1	Exemples sur les applications du mining de la vidéo : . . . . .	37
1.4.2.3.2	Techniques de mining de la vidéo couramment utilisées : . . . . .	38
1.4.2.4	Mining de l'image : . . . . .	39
1.4.2.5	Mining des réseaux sociaux : [68] . . . . .	40
1.4.2.5.1	Applications : . . . . .	40
1.4.2.5.2	Les techniques différentes pour fouiller les don- nées des réseaux sociaux : . . . . .	41
1.4.2.5.3	Les Avantages Du mining des réseaux sociaux : . . . . .	41
1.4.2.5.4	Les Risques du mining réseaux sociaux : . . . . .	42
1.4.2.6	Mining des times series : [52] . . . . .	43
1.4.2.6.1	Définition : . . . . .	43
1.4.2.6.2	Utilisation des connaissances : . . . . .	43
1.4.2.6.3	Les Techniques de fouille de séries temporelles : . . . . .	44
1.4.2.6.4	Applications de la fouille des séries temporelles : . . . . .	44
1.4.3	Le Big Data . . . . .	45

1.4.3.1	V1 : Le volume :	45
1.4.3.2	V2 : La vitesse :	45
1.4.3.3	V3 : La variété :	45
1.5	Les tâches du Data mining [53]	46
1.5.1	Recherche de motifs :	46
1.5.2	La classification :	46
1.5.3	Règles d'association :	47
1.5.4	Détection des valeurs aberrantes :	47
1.5.5	Regroupement :	47
1.5.6	Regression :	48
1.5.7	Prédiction :	48
1.6	Conclusion :	48
<b>2</b>	<b>Présentation du domaine de l'Image Mining</b>	<b>49</b>
2.1	Introduction :	49
2.2	Définition de l'image :	50
2.2.1	Fouille de l'image :	50
2.2.2	Définition d'image dans le contexte du mining :	50
2.3	Les espaces de couleurs de l'image :	50
2.3.1	Le modèle RGB :	51
2.3.2	HSV :	51
2.3.3	Comparaison entre le RGB et le HSV :	52
2.3.4	L'espace LAB :	52
2.3.5	CIE-LCH	54
2.3.5.1	Avantages du CIE-LCH :	55
2.3.5.2	Applications du CIE-LCH :	56
2.4	Les caractéristiques de l'image :	56
2.4.1	La couleur :	56
2.4.1.1	L'histogramme de couleur :	57
2.4.1.1.1	Fonctionnement :	57

2.4.1.1.2	Interprétation :	57
2.4.1.1.3	Application :	57
2.4.1.1.4	L'équation de l'histogramme de couleur :	57
2.4.1.1.5	La représentation graphique de l'histogramme de couleur :	58
2.4.1.1.5.1	Les étapes générales pour créer une représentation graphique de l'histogramme de couleur pour une image donnée :	58
2.4.1.1.5.2	Un exemple de représentation graphique d'un histogramme de couleur pour une image RVB :	59
2.4.1.2	Les moments de couleur :	59
2.4.1.2.1	Quelques avantages de l'utilisation des moments de couleurs pour la classification d'images :	60
2.4.1.2.2	Combinaison de l'histogramme et des moments de couleur :	61
2.4.2	La texture :	61
2.4.2.1	Caractéristique de la texture :	62
2.4.2.1.1	Variabilité :	62
2.4.2.1.2	Rugosité :	62
2.4.2.1.3	Fréquence :	62
2.4.2.2	LBP :	63
2.4.2.2.1	Calcul du motif binaire local (LBP) :	63

2.4.2.2.2	Histogramme des motifs LBP :	63
	.....	
2.4.2.2.3	Représentation graphique du Motif Binaire Local (LBP) :	64
	.....	
2.4.2.2.4	Matrice d'image LBP :	64
	.....	
2.4.2.2.5	Illustration du Motif Binaire Local (LBP) :	65
	.....	
2.4.2.3	Matrice de cooccurrence Haralick :	66
2.4.2.3.1	Avantages de la Matrice de co-occurrence Haralick :	68
2.4.2.3.2	Inconvénients de la Matrice de co-occurrence Haralick :	68
2.4.3	La forme (Shape) :	69
2.4.3.1	Les Polynômes de Hu :	69
2.4.3.2	Les Polynôme de LEGENDRE :	69
2.4.3.3	Les Coefficients de Fourier :	70
2.4.3.3.1	Avantages de l'utilisation des polynômes de Legendre et des coefficients de Fourier pour la classification d'images :	70
2.4.3.3.1.1	Invariance à l'échelle et à la rotation :	70
	.....	
2.4.3.3.1.2	Robustesse au bruit :	71
	.....	
2.4.3.3.1.3	Efficacité computationnelle :	71
	.....	
2.4.3.3.2	Exemples d'applications :	71
2.4.3.3.2.1	- Reconnaissance d'objets :	71
	.....	

2.4.3.3.2.2	- Inspection d'images :	71
2.4.3.3.2.3	- Biométrie :	71
2.4.4	Les Motifs :	72
2.4.4.1	Définition : [31]	72
2.4.4.2	Les techniques d'extraction des motifs : [32]	72
2.4.4.2.1	Analyse de textures :	72
2.4.4.2.2	Analyse de formes et des contours :	73
2.4.4.2.3	Analyse de régions :	73
2.4.4.2.4	Caractéristiques locales et descripteurs :	73
2.4.4.2.5	Réseaux de neurones convolutionnels (CNN)	74
2.5	Les mesures de distances et les mesures de similarité	74
2.5.1	Les mesures de distance :	74
2.5.1.1	Distance Euclidienne :	74
2.5.1.2	Distance Manhattan :	74
2.5.1.3	Distance de Tchebyshev :	75
2.5.1.4	Distance de Canberra :[21]	75
2.5.2	Mesures de similarité :	76
2.5.2.1	Coefficient de corrélation :	76
2.5.2.2	Indice de Jaccard :	76
2.5.2.3	Coefficient de Dice :	77
2.5.2.4	Similarité Cosinus :	77
2.6	Les taches de l'image mining :	77

2.6.1	La classification de l'image : . . . . .	77
2.6.2	clustering d'ensemble d'images : . . . . .	77
2.6.2.1	Applications du clustering d'ensemble d'images : . . . . .	78
2.6.3	Recherche d'images par le contenu : . . . . .	78
2.6.4	Détection d'anomalies : . . . . .	78
2.6.5	Recherche de l'image par le contenu visuel : . . . . .	79
2.7	Conclusion . . . . .	79
<b>3</b>	<b>La classification de l'image</b>	<b>81</b>
3.1	Introduction . . . . .	81
3.2	Définition de la classification d'image : . . . . .	81
3.2.1	Classification supervisée de l'image : . . . . .	82
3.2.1.1	Définition : . . . . .	82
3.2.1.2	Fonctionnement : . . . . .	82
3.2.1.2.1	Collecte d'un ensemble de données d'apprentis- sage : . . . . .	82
3.2.1.2.2	Extraction de caractéristiques : . . . . .	82
3.2.1.2.3	Sélection d'un algorithme de classification : . . . . .	82
3.2.1.2.4	Entraînement du modèle : . . . . .	82
3.2.1.2.5	Évaluation du modèle : . . . . .	83
3.2.1.3	Avantages : . . . . .	83
3.2.1.4	Inconvénients : . . . . .	83
3.2.2	Classification non supervisée de l'image : . . . . .	83
3.2.2.1	Définition : . . . . .	83
3.2.2.2	Fonctionnement : . . . . .	83
3.2.2.2.1	Collecte d'un ensemble de données non étiqueté : . . . . .	84
3.2.2.2.2	Extraction de caractéristiques : . . . . .	84
3.2.2.2.3	Sélection d'un algorithme de clustering : . . . . .	84
3.2.2.2.4	Apprentissage du modèle : . . . . .	84
3.2.2.2.5	Évaluation du modèle : . . . . .	84

3.2.2.3	Applications :	84
3.2.2.3.1	Détection d'anomalies :	84
3.2.2.3.2	Organisation d'images :	85
3.2.2.3.3	Recommandation d'images :	85
3.2.2.4	Avantages de ce genre de classification :	85
3.2.2.5	Inconvénients de ce genre de classification :	85
3.2.3	Processus de classification de l'images :	85
3.2.3.1	Acquisition d'images :	85
3.2.3.2	Prétraitement d'image :	86
3.2.3.3	Extraction de caractéristiques :	86
3.2.3.4	Apprentissage du modèle :	86
3.2.3.5	Classification des nouvelles images (données de teste) :	86
3.3	Exemples de classifieurs :	86
3.3.1	RNA (réseaux de neurones artificiels) :	87
3.3.1.1	Définition :	87
3.3.1.2	Structure d'un RNA :	87
3.3.1.3	Fonctionnement d'un RNA :	88
3.3.1.4	Types de RNA :	88
3.3.1.4.1	Les réseaux de neurones perceptron multicouche (MLP) :	88
3.3.1.4.2	Les réseaux de neurones convolutifs (CNN) :	89
3.3.1.4.3	Les réseaux de neurones récurrents (RNN) :	90
3.3.1.5	Avantages des RNA :	90
3.3.1.6	Inconvénients des RNA :	90
3.3.2	Arbres de décision :	91
3.3.2.1	Définition :	91
3.3.2.2	Fonctionnement :	91
3.3.2.3	Application :	92
3.3.3	Les SVM :	93

3.3.3.1	Définition :	93
3.3.3.2	Fonctionnement :	93
3.3.3.3	Application :	93
3.3.4	Classifieur Bayes naïf :	94
3.3.4.1	Définition :	94
3.3.4.2	Fonctionnement :	94
3.3.4.3	Application :	94
3.3.5	KNN : K Nearest Neighbors :	94
3.3.5.1	Définition :	94
3.3.5.2	Fonctionnement :	95
3.3.5.3	Application :	95
3.4	Les techniques avancées de la classification de l'image :	95
3.4.1	Combinaison de classifieurs :	95
3.4.1.1	Définition :	95
3.4.1.2	Avantages de la combinaison de classifieur :	95
3.4.1.2.1	Amélioration de la précision :	95
3.4.1.2.2	Robuste à l'erreur :	96
3.4.1.2.3	Réduction du sur-apprentissage :	96
3.4.2	Le Bagging et le boosting :	96
3.4.2.1	Le Baggin :	96
3.4.2.1.1	Définition :	96
3.4.2.1.2	Avantages du Bagging :	96
3.4.2.1.3	Exemple d'application :	96
3.4.2.2	Le Boosting :	96
3.4.2.2.1	Définition :	96
3.4.2.2.2	Types de Boosting :	97
3.4.2.2.2.1	AdaBoost :	97

3.4.2.2.2	Gradient Boosting :	97
3.4.2.2.3	Avantages du Boosting :	97
3.4.2.2.4	Exemple d'application :	97
3.4.3	Le deep Learning (CNN) . . . . .	97
3.4.3.1	Avantages des CNN :	97
3.4.3.2	Exemples d'application :	98
3.5	Conclusion . . . . .	98

#### 4 Une étude comparative de plusieurs classifieurs d'images : Algorithmes,

	<b>Datasets, Distances :</b>	<b>100</b>
4.1	Introduction . . . . .	100
4.2	Les outils et langages utilisés :	101
4.2.1	Ordinateurs :	101
4.2.2	Le langage de programmation utilisé : Python . . . . .	101
4.2.3	Le langage Latex :	101
4.2.4	Application utilisé pour le codage :	102
4.2.5	DataSet D'images utilisée :	102
4.2.5.0.1	Corel 1K :	102
4.2.5.0.2	KIMIA path 960 :	103
4.2.5.0.3	Organisation des bases :	104
4.2.5.0.3.1	DatasetRouge :	104
4.2.5.0.3.2	DatasetVert :	105
4.2.5.0.3.3	DatasetBleu :	106

4.2.5.0.3.4	DatasetMini :	106
	.....	
4.2.5.0.3.5	DatasetHalf :	107
	.....	
4.2.6	Bibliothèques et méthodes utilisées :	107
4.2.7	Méthodes utilisées et comparaison :	108
4.2.7.1	Méthodes utilisées :	108
4.2.7.2	Résultat des expérimentations en utilisant la base de données Corel 1K :	112
4.2.7.2.1	Grpahique des résultats en utilisant la mesure Euclidienne :	112
	.....	
4.2.7.2.2	Grpahique des résultats en utilisant la mesure Canberra :	114
	.....	
4.2.7.2.3	Grpahique des résultats en utilisant la mesure Manhattan :	116
	.....	
4.2.7.2.4	Grpahique des résultats en utilisant la mesure DTW :	117
	.....	
4.2.7.2.5	Grpahique des résultats en utilisant les couleurs dominantes	120
	.....	
4.2.7.2.6	Grpahique des résultats en utilisant le CNN :	120
	.....	
4.2.7.3	Résultat des expérimentations en utilisant la base de données Kimia path 960 :	122
4.2.7.3.1	Grpahique des résultats en utilisant la mesure Euclidienne :	122
	.....	

4.2.7.3.2	Graphique des résultats en utilisant la mesure Canberra :	123
4.2.7.3.3	Graphique des résultats en utilisant la mesure Manhattan :	124
4.2.7.3.4	Graphique des résultats en utilisant la mesure DTW :	125
4.2.7.3.5	Graphique des résultats en utilisant le CNN :	126
4.3	Conclusion	126

# Table des figures

1.1	Schéma des étapes du processus d'ECD[54]	31
1.2	L'extraction des caractéristiques de la vidéo	38
2.1	Représentation de l'espace RGB[18]	51
2.2	Représentation de l'espace HSV[19]	52
2.3	Tableau de comparaison entre le RGB et le HSV	52
2.4	Représentation de l'espace LAB[66]	53
2.5	Représentation de l'espace CIE-LCH[15]	55
2.6	Représentation graphique de l'histogramme de couleur RGB[58]	59
2.7	Illustration d'une image (gauche) et de son image (droite) LBP	64
2.8	Exemple d'histogramme circulaire LBP	65
2.9	Exemple de matrice d'image LBP[42]	65
2.10	Domaine et application de la détection d'anomalie[2]	79
3.1	Figure illustrative d'une structure d'un RNA[67]	88
3.2	Figure illustrative d'un MLP[10]	89
3.3	Figure illustrative des réseaux de neurones convolutifs (CNN)[59]	89
3.4	Figure illustrative des réseaux de neurones récurrents (RNN)[36]	90
3.5	Figure illustrative d'un exemple d'arbres de décision[3]	92
3.6	Figure illustrative d'un support-vector-machine(SVM) [4]	93
4.1	La base Corel 1K	102
4.2	La base Kimia path 960	103
4.3	Tableau d'arrangement des bases	104

4.4	DatasetRouge . . . . .	105
4.5	DatasetRouge . . . . .	105
4.6	DatasetVert . . . . .	105
4.7	DatasetVert . . . . .	106
4.8	DatasetBleu . . . . .	106
4.9	DatasetBleu . . . . .	106
4.10	Bibliothèque utilisé . . . . .	107
4.11	Le dictionnaire des 50 couleurs dominantes extraites de la base Corel1k .	110
4.12	Figure illustrative d'un appariement en utilisant la distance usuel (eucledienne) ainsi que la distance DTW [9] . . . . .	111
4.13	Couches utilisé pour la classification . . . . .	111
4.14	Graphique représentant les résultats du Classifieur KNN – Euclidienne . K= 5 . . . . .	112
4.15	Détail par classe des résultats du meilleur classifieur, juque-là : Le Classifieur KNN – Euclidienne – Espace HSV complet. . . . .	113
4.16	Graphique représentant les résultats du Classifieur KNN – Canberra k =5	114
4.17	Détail par classe des résultats du meilleur classifieur, juque-là : Le Classifieur KNN – Canberra – Espace LAB complet . . . . .	115
4.18	Graphique représentant les résultats du Classifieur KNN – Manhattan K= 5	116
4.19	Détail par classe des résultats du meilleur classifieur, jusque-là : Le Classifieur KNN – Manhattan – Espace HSV complet. . . . .	117
4.20	Graphique représentant les résultats du Classifieur KNN DTW. K= 5 . .	118
4.21	Image originale test et son histogramme LBPBleu . . . . .	118
4.22	Image originale entrainement et son histogramme LBPBleu . . . . .	119
4.23	Résultats du classifieur KNN, Histogramme de couleurs dominantes . . .	120
4.24	Evolution des résultats du CNN : Précision de classification, en fonction du nombre d'itérations qui est de 10 . . . . .	121
4.25	Graphique représentant les résultats du Classifieur KNN – Euclidienne k =5	122
4.26	Graphique représentant les résultats du Classifieur KNN – Canberra k =5	123

4.27	Graphique représentant les résultats du Classifieur KNN – Manhattan $k = 5$	124
4.28	Graphique représentant les résultats du Classifieur KNN – DTW $k = 5$ . . .	125
4.29	Evolution des résultats du CNN : Précision de classification, en fonction du nombre d'itérations qui est de 20 . . . . .	126

# Introduction générale

De nos jours, la technologie ne cesse d'évoluer, ouvrant et créant de nouveaux modèles et un nouveau monde où la recherche et l'analyse des données devient, de plus en plus, un objectif primordial. Notons que les données, autrefois simples, deviennent de plus en plus diversifiées et volumineuses, compliquant ainsi la manipulation et l'exploitation de ces données. De ce fait, le besoin d'exploitation de ces données a engendré la naissance d'une nouvelle discipline « un nouveau univers » qui s'intéresse spécifiquement aux données et aux difficultés qui leurs sont inhérentes. Ce nouveau domaine est le data mining, autrement appelé fouilles de données. Le data mining regroupe des méthodes anciennes et nouvelles, scientifiques et techniques pour collecter, analyser, explorer, visualiser et expliquer les données.

Dans le contexte du data mining, les données sont généralement regroupées en trois grandes classes dépendantes de leurs complexités : données structurées, données non structurées (multimédia) et le Big Data. Les données structurées sont ainsi appelées car elles sont organisées dans des bases de données. Autrement dit, ce sont des données qui possèdent des attributs qui les caractérisent. De ce fait, les données structurées sont immédiatement exploitables par le processus du data mining.

Par contre, les données non structurées, dites aussi données multimédia (images, vidéos, audios, textes et pages web) sont à la base des données non caractérisées et de ce fait, sont non immédiatement exploitables. Pour pouvoir, alors, exploiter ces données, il est nécessaire de les caractériser, d'abord. Du fait que l'opération de caractérisation de ces données n'est pas évidente et est plutôt très complexe, ce type de données est dit aussi « données complexes ».

D'un autre côté, le Big data fait référence à des données encore plus complexes et encore plus volumineuses, surtout. Par volumineuses, il faut comprendre des données de tailles gigantesque et même inimaginables, initialement. Cet aspect de grandeur se manifeste particulièrement dans les données des réseaux sociaux (facebook, instagram, twitter, etc.). Par rapport à l'aspect de la complexité, ces données sont soumises à des règles bien précises pour exprimer en même temps, la grandeur du volume, la grandeur de la vitesse de croissance des données, la variété des données, puisque ces données doivent être hétérogènes, ainsi que d'autres caractéristiques qui seront développées plus loin, dans ce mémoire. Dans ce projet, nous nous focalisons sur les données de type image. C'est-à-dire que nous nous intéressons exclusivement au sous domaine de L'image Mining (fouilles de l'image). Plus particulièrement encore, nous nous intéressons à une tâche spécifique : La classification de l'image.

La classification de l'image est une technique d'apprentissage automatique qui permet d'attribuer une étiquette à une image en fonction de son contenu visuel. Les classes d'appartenances des images sont alors de deux types : soit des classes préexistantes et nous parlons alors d'apprentissage supervisé ou extraites de façon automatique par une autre tâche du data mining : Le clustering (segmentation d'un ensemble d'images) et nous parlons alors d'apprentissage non supervisé.

Notons que d'autres tâches font partie du data mining, telles que, la recherche de l'image par le contenu visuel, la détection d'anomalies dans les images, l'indexation d'un ensemble d'images sur la base d'attributs bien choisis, la sélection d'attributs et bien d'autres tâches encore.

Notons aussi un point essentiel dans le cadre de la manipulation de l'image, celui des modèles de représentation de l'image. En effet, il est constaté et établi que, le modèle de représentation de l'image, dans le cadre du mining de l'image et d'autres domaines, a un effet significatif. Dans ce mémoire nous évoquons, alors, plusieurs modèles de représentation de l'image : le modèle RGB, le modèle HSV et le modèle CIE-LAB.

D'un autre côté, le mining de l'image est influencé par les attributs utilisés pour caractériser ces mêmes images. Dans ce cadre, nous recensons trois grandes classes d'attributs

pour l'image : attributs extraits du contenu couleur (i.e histogramme de couleurs), attributs extraits du contenu texture (i.e LBP : Local Binary Pattern) et attributs extraits du contenu shape (forme)(i.e les coefficients de Fourier).

Un autre point essentiel dans le cadre du mining de l'image est la notion de mesures de distance et de mesures de similarité pour établir les degrés de proximité (mesures de distance) ou bien de similarité (mesures de similarité) entre images. Parmi les distances les plus célèbres et les plus utilisées dans le cadre du data mining, nous recensons, entre autres, la distance Euclidienne et la distance de Manhattan. Pour les mesures de similarité, nous recensons la mesure de Canberra et la mesure DTW (Dynamic Time Warpping). L'objectif principal de ce travail de mémoire est d'effectuer une étude comparative de plusieurs classifieurs de l'image. La diversification des classifieurs est réalisée par le recours à plusieurs modèles de couleurs, plusieurs attributs de l'image, plusieurs mesures de distance et mesures de similarité. Nous avons choisi comme modèle de classification le classifieur KNN (K Nearest Neighbours), en français KPPV (K Plus Proches Voisins). Ce modèle, bien que simple, est de très bonne qualité.

Ce classifieur a été exploité selon plusieurs scénarios en combinant différents paramétrages des critères suivants :

1. Espace de couleurs
2. Mesures de distances et mesures de similarité
3. Les attributs
4. L'arrangement des bases de données utilisées

De plus, nous avons utilisé un autre modèle qui relève du deep learning, en l'occurrence, le modèle de type CNN (Convolutional Network), en français, Réseau neuronal convolutif.

Pour les données, nous avons utilisé la base d'images bien connue COREL 1k (base Wang). Cette base est constituée de 10 classes préexistantes incluant une diversité de contenus (fleurs, éléphants, plages, aliments, etc.). Ainsi qu'une autre base connue sous le nom de Kimia qui est une base qui regroupe une collection d'images histopathologiques, contenant 960 images divisé en 20 classes.

Ainsi ce mémoire est alors découpé en 4 chapitres : Chapitre 1 : Dans ce chapitre, nous présentons de façon assez brève le domaine général du data mining.

Chapitre 2 : Dans ce chapitre nous présentons de façon assez brève le sous domaine du mining de l'image.

Chapitre 3 : Dans ce chapitre, nous présentons de façon assez brève la tâche spécifique de classification de l'image.

Chapitre 4 : Dans ce chapitre nous exposons les différentes méthodes et algorithmes de classification que nous avons considérés et les résultats comparatifs obtenus, en termes de précision de la classification sur la base de Wang et la base Kimia.

Conclusion générale : Dans cette section, nous présentons nos conclusions découlent de l'étude des résultats obtenus suite à l'ensemble des études théoriques et expérimentales effectuées dans le cadre de ce mémoire de Master.

# Chapitre 1

## Présentation générale du processus du Data Mining

### 1.1 Introduction

Au fil des années, les données n'ont pas cessé d'évoluer pour devenir de plus en plus gigantesques, volumineuses et très pesantes. Ce fait a contribué à la complication de la manipulation et l'exploitation de ces données. Afin de prendre en charge, entre autres, ces complications, un nouveau domaine fit son apparition : le data mining.

Cette nouvelle discipline est un processus d'exploration et d'analyse de données qui vise à identifier les modèles, les tendances, ainsi que des relations, pas immédiatement apparentes. C'est-à-dire, le data mining a pour but essentiel d'extraire des connaissances à partir des données, en combinant des techniques des domaines de pattern recognition, bases de données, analyse des données, recherche de l'information, statistiques, intelligence artificielle et recherche opérationnelle, entre autres.

Au début (année 1990 et plus), le processus du data mining s'est centré sur les données organisées dans les BDDs, d'où l'appellation : Fouille des données structurées, pour désigner le data mining initial.

Par la suite, particulièrement après l'avènement de l'internet, il y'a eu un intérêt croissant au mining des données, autres que les enregistrements des BDDs, telles que, le texte,

l'image, la vidéo, les pages web, et les times series.

Dans ce chapitre, nous développons alors avec plus ou moins de détails les concepts, les objectifs, les outils, les techniques et les applications du domaine du data mining.

## 1.2 Concepts de base du Data Mining

### 1.2.1 Définition du Data mining :

Le Data Mining, aussi appelé fouille de données, exploration de données ou forage de données, est un processus d'extraction de connaissances à partir de grandes quantités de données. En effet, le data mining repose sur un nouveau paradigme, non connu auparavant, qui stipule que, dans les données, il y a de la connaissance. Autrement dit, le processus du data mining ne fonctionne pas forcément selon le paradigme initial de l'informatique : Données + Traitement = Résultat. Il fonctionne, plutôt, selon la relation : Données + Data Mining = Connaissances. De ce point de vue, il est clair que les connaissances extraites par le processus du data mining sont beaucoup plus profondes, d'où l'appellation Mining. Aussi, le processus du data mining est centré, essentiellement, autour des données, là où le paradigme initial de l'informatique est centré autour de la résolution des problèmes. D'autre part, le data mining est un domaine interdisciplinaire qui utilise des techniques issues de l'informatique, des mathématiques, des statistiques et de l'intelligence artificielle, entre autres.

### 1.2.2 Objectifs du Data mining :

Le Data Mining a deux grands objectifs, la compréhension du comportement actuel des données et la prédiction du comportement des données dans le futur. En d'autres termes, il vise à découvrir des modèles, des régularités, des tendances et des anomalies dans les données.

Ces connaissances peuvent ensuite être utilisées pour :[49]

**Améliorer la prise de décision :** Le Data Mining peut aider à identifier les facteurs qui influencent le succès ou l'échec d'une entreprise.[49]

**Optimiser les processus :** Le Data Mining peut aider à identifier les points d'inefficacité et à améliorer les processus métier.[49]

**Développer de nouveaux produits et services :** Le Data Mining peut aider à identifier les besoins des clients et à développer de nouveaux produits et services répondant à leurs attentes.[34]

**Personnaliser l'expérience client :** Le Data Mining peut aider à proposer des offres et des services personnalisés aux clients.[34]

**Applications du Data Mining :**[34] Le Data Mining est utilisé dans de nombreux domaines, tels que :

**Le Marketing :** Le Data Mining est utilisé pour analyser les données clients et identifier les segments de marché les plus prometteurs.

**La Finance :** Le Data Mining est utilisé pour détecter la fraude et évaluer le risque de crédit.

**La Santé :** Le Data Mining est utilisé pour diagnostiquer les maladies et développer de nouveaux traitements.

**L'Industrie :** Le Data Mining est utilisé pour optimiser les processus de production et de maintenance.

### 1.3 Définition du processus d'ECD (Extraction de Connaissances dans les Données) (KDD :Knowledge Discovery in Data ) :

L'Extraction de Connaissances à partir de Données (ECD) est un processus qui vise à découvrir des connaissances nouvelles et utiles à partir de grandes quantités de données. Il s'agit d'un domaine interdisciplinaire qui utilise des techniques issues de l'informatique, des mathématiques, des statistiques et de l'intelligence artificielle.[34]

Le processus de DM s'inscrit en réalité dans une démarche plus globale : l'ECD. [5]

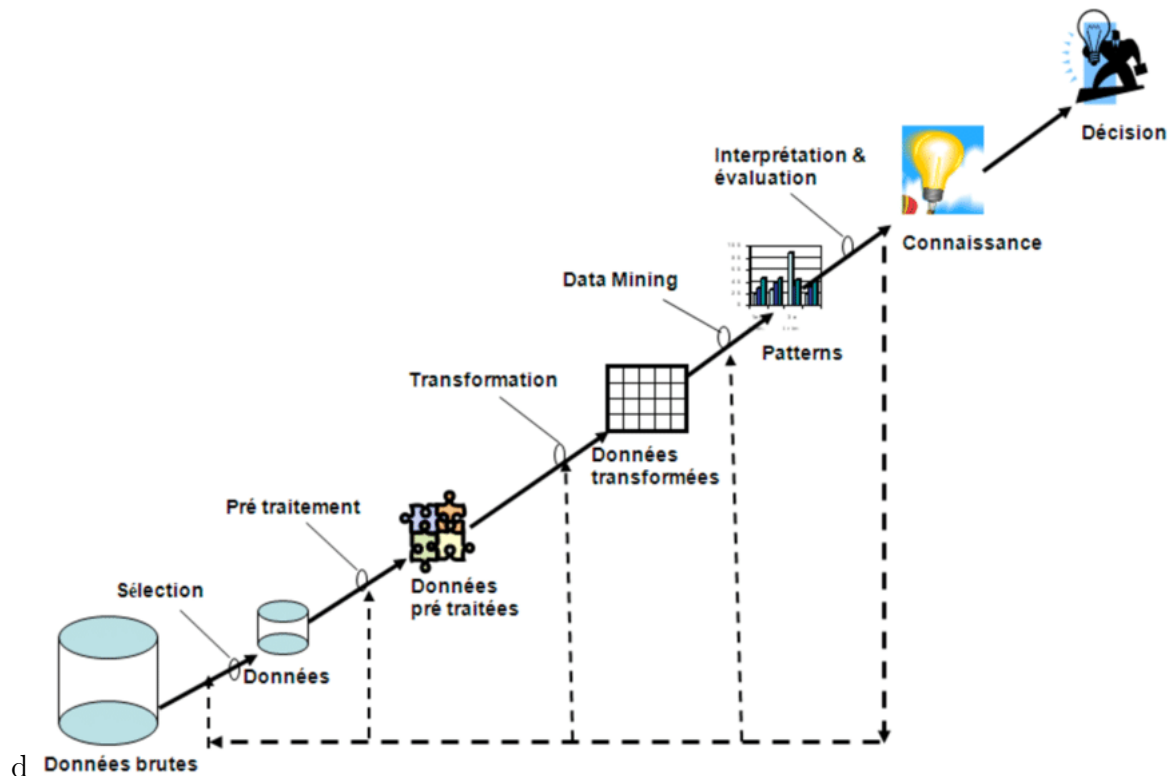


FIGURE 1.1 – Schéma des étapes du processus d'ECD[54]

### 1.3.1 Les étapes du processus d'ECD [1]

Le processus d'ECD, ou "Knowledge Discovery in Databases" (KDD) en anglais, est une méthodologie utilisée pour extraire des connaissances à partir de données. Il se compose de six étapes principales :

#### 1.3.1.1 Sélection des données :

Cette étape implique l'identification et la sélection des sources de données pertinentes pour l'analyse. Il est important de comprendre les objectifs de la recherche, la disponibilité des données et les considérations de qualité des données.

#### **1.3.1.2 Prétraitement des données :**

Le prétraitement des données vise à nettoyer, transformer et intégrer les données sélectionnées afin d'assurer leur qualité et leur cohérence. Cela peut impliquer la gestion des valeurs manquantes, la suppression des valeurs aberrantes, la correction des erreurs de données et la normalisation des formats de données.

#### **1.3.1.3 Réduction des données :**

Pour réduire la dimensionnalité et la complexité des données, des techniques telles que l'échantillonnage et la sélection de caractéristiques sont employées. L'échantillonnage consiste à sélectionner un sous-ensemble représentatif des données, tandis que la sélection de caractéristiques vise à identifier les caractéristiques les plus pertinentes et les plus informatives pour l'analyse.

#### **1.3.1.4 Modélisation des données :**

La modélisation des données implique l'application d'algorithmes d'apprentissage automatique ou statistiques pour identifier des modèles et des relations au sein des données prétraitées et réduites. C'est là que l'analyse principale des données a lieu, en utilisant diverses techniques de modélisation adaptées au problème spécifique.

#### **1.3.1.5 Evaluation du modèle :**

Les performances des modèles générés sont évaluées à l'aide de métriques diverses. Ces métriques évaluent la capacité du modèle à classifier ou à prédire correctement les résultats sur la base des données d'entraînement.

#### **1.3.1.6 Interprétation et déploiement :**

Les connaissances extraites des modèles sont interprétées, affinées et déployées dans des applications ou des processus décisionnels. Cela implique de comprendre les résultats du modèle, d'identifier des informations exploitables et d'intégrer les conclusions dans

des scénarios réels.

Le processus d'ECD est un cycle itératif, ce qui signifie que les étapes peuvent être revisitées et affinées selon les besoins. L'objectif est d'extraire des connaissances significatives des données qui peuvent être utilisées pour résoudre des problèmes réels (ex : Recommandation de produits, Diagnostic médical, etc.) ou acquérir une compréhension plus approfondie des phénomènes sous-jacents.

## 1.4 Les types du processus du Data Mining :

### 1.4.1 Fouille de données structurées :

C'est un type de fouille de données qui s'applique aux données structurées dans les BDDs. Les données structurées sont des données organisées dans un format défini, comme des tableaux ou des listes. Elles peuvent être de nature très variée, y compris des données commerciales, des données financières, des données de santé ou des données scientifiques. La fouille de données structurées est un domaine important du data mining, car il permet d'extraire des connaissances précieuses de grandes quantités de données. Ces connaissances peuvent être utilisées pour prendre des décisions, identifier des tendances et résoudre des problèmes spécifiques.[48]

#### 1.4.1.1 Les étapes de la fouille de données structurées :

La fouille de données structurées se déroule généralement en quatre étapes :

**1.4.1.1.1 1 - Préparation des données :** Cette étape consiste à nettoyer les données, à les formater et à les normaliser.

**1.4.1.1.2 2 - Exploration des données :** Cette étape consiste à examiner les données pour identifier des tendances et des modèles.

**1.4.1.1.3 3 - Modèles de construction :** Cette étape consiste à construire des modèles qui représentent les données.

**1.4.1.1.4 4- Evaluation des modèles :** Cette étape consiste à évaluer les performances des modèles.

La fouille de données structurées est un domaine en pleine croissance, avec de nouvelles applications qui sont constamment développées.[46]

## 1.4.2 Fouille du multimédia

Ce type de fouille est un domaine du data mining qui s'intéresse à l'extraction de connaissances à partir de données multimédia, telles que les images, les vidéos, le texte, l'audio, les pages et sites du Web et réseaux sociaux.

Les données multimédia sont des données qui ne sont pas organisées dans un format défini, comme des tableaux ou des listes. Elles peuvent être de nature très variée, y compris des données visuelles, auditives, textuelles ou interactives.

La fouille multimédia est un domaine difficile, car les données multimédia sont souvent complexes et difficiles à analyser. Cependant, il offre de nombreuses possibilités, car les données multimédia contiennent souvent des informations précieuses qui peuvent être utilisées pour prendre des décisions, identifier des tendances et résoudre des problèmes.[47]

### 1.4.2.1 Exemples d'applications de la fouille du multimédia : [45]

#### - Reconnaissance d'objets :

La fouille multimédia peut être utilisée pour identifier des objets dans des images ou des vidéos. Par exemple, une entreprise peut utiliser la fouille multimédia pour identifier les produits qui sont vendus dans ses magasins, en analysant des images ou des vidéos capturées dans les points de vente, la Fouille Multimédia permet d'identifier auto-

matiquement les produits présents sur les rayons, les affiches ou dans les mains des clients.

**- Reconnaissance du visage :**

La fouille multimédia peut être utilisée pour identifier les visages dans des images ou des vidéos. Par exemple, une entreprise de sécurité peut utiliser la fouille multimédia pour identifier les personnes qui entrent dans ses locaux.

**- Analyse des sentiments :**

La fouille multimédia peut être utilisée pour analyser les sentiments des gens exprimés dans du texte, des images ou des vidéos. Par exemple, une entreprise peut utiliser la fouille multimédia pour analyser les commentaires des clients sur ses produits ou services.

**- Recommandation de produits :**

La fouille multimédia peut être utilisée pour recommander des produits ou des services aux utilisateurs. Par exemple, un site de commerce électronique peut utiliser la fouille multimédia pour recommander des produits aux utilisateurs en fonction de leurs achats précédents ou de leurs intérêts.

Le mining du multimédia est en résumé une discipline qui s'intéresse à l'extraction de connaissances à partir de données multimédias. Ces données peuvent être des images, des vidéos, des sons, ou des combinaisons de ces différents types de données. De plus, le mining multimédia est une discipline interdisciplinaire qui combine des techniques de traitement du signal, d'intelligence artificielle, et de fouille de données. Les techniques de traitement du signal et des images sont utilisées pour extraire des caractéristiques des données multimédias.

Les techniques d'intelligence artificielle sont utilisées pour apprendre des modèles à partir de ces caractéristiques. Les techniques de fouille de données sont utilisées pour découvrir des patterns et des corrélations dans les données.[45]

### 1.4.2.2 Mining du texte :

Le mining du texte, également appelé fouille du texte, est un ensemble de techniques informatiques permettant d'extraire des connaissances à partir de données textuelles. Ces données peuvent être des documents, des articles, des tweets, des commentaires, etc.

Le mining du texte est une discipline interdisciplinaire qui combine des techniques de traitement du langage naturel, d'intelligence artificielle, et de fouille de données. Les techniques de traitement du langage naturel sont utilisées pour analyser la structure et le contenu du texte. Les techniques d'intelligence artificielle sont utilisées pour apprendre des modèles à partir du texte. Les techniques de fouille de données sont utilisées pour découvrir des patterns et des corrélations dans le texte.[50]

**1.4.2.2.1 Les applications du mining du texte :** - **La classification :** Le mining du texte peut être utilisé pour classer des documents dans des catégories prédéfinies.

- **La recherche :** Le mining du texte peut être utilisé pour rechercher des documents qui correspondent à des critères spécifiques. - **L'analyse de sentiments :** Le mining du texte peut être utilisé pour analyser les sentiments exprimés dans un document. - **La détection de spam :** Le mining du texte peut être utilisé pour détecter les messages indésirables.

**1.4.2.2.2 Exemples concrets sur les applications du mining du texte :** - **Dans le secteur du marketing :** Le mining du texte peut être utilisé pour analyser les avis des clients sur les produits ou services d'une entreprise. - **Dans le secteur des médias :** Le mining du texte peut être utilisé pour analyser les tendances et les opinions sur les réseaux sociaux. - **Dans le secteur de la sécurité :** Le mining du texte peut être utilisé pour détecter les discours de haine ou les menaces terroristes.

Le mining du texte est une discipline en pleine expansion, qui offre de nombreuses opportunités de développement.[50]

**1.4.2.2.3 Exemples sur quelques techniques :** - **Extraction de mots clés :** Cette technique consiste à identifier les mots ou les expressions les plus importants dans un document. - **La classification automatique de document :** Cette technique consiste à assigner un document à une catégorie prédéfinie.[50]

### **1.4.2.3 Mining de la vidéo :**

Le mining de la vidéo est une discipline qui s'intéresse à l'extraction de connaissances à partir de données vidéo. Ces données peuvent être des vidéos, des clips vidéo, des flux vidéo, etc. Le mining de la vidéo est une discipline interdisciplinaire qui combine des techniques de traitement du signal, d'intelligence artificielle, et de fouille de données. Les techniques de traitement du signal sont utilisées pour extraire des caractéristiques des données vidéo. Les techniques d'intelligence artificielle sont utilisées pour apprendre des modèles à partir de ces caractéristiques. Les techniques de fouille de données sont utilisées pour découvrir des patterns et des corrélations dans les données.

#### **1.4.2.3.1 Exemples sur les applications du mining de la vidéo :** - **Surveillance Vidéo :**

Le mining de vidéo peut analyser des flux vidéo de caméras de surveillance pour détecter des intrusions, identifier des individus suspects et suivre leurs déplacements. Cela renforce la sécurité des lieux publics et privés.[63]

#### **- Analyse du comportement des personnes :**

Le mining de vidéo peut analyser les comportements des personnes dans des environnements surveillés, comme les magasins ou les transports en commun. Cela permet de comprendre les flux de circulation, les habitudes d'achat ou les interactions sociales, et d'optimiser l'aménagement des espaces ou les services proposés.[13]

#### **- Analyse du comportement des clients :**

*Comportement d'achat et engagement :*

Le mining de vidéo peut analyser les vidéos de clients dans les magasins pour comprendre leurs habitudes d'achat, leur intérêt pour les produits et leur niveau d'engagement. Cela permet d'optimiser l'agencement des rayons, les promotions et l'expérience client en général.[55]

**- Analyse des réseaux sociaux :**

*Suivi des tendances et détection de désinformation :*

Le mining de vidéo peut analyser les vidéos partagées sur les réseaux sociaux pour identifier les tendances, les opinions publiques et les potentielles désinformations. Cela permet aux entreprises et aux organisations de mieux comprendre l'image qu'elles renvoient et de lutter contre la propagation de fausses informations.[63]

**- Analyse des sentiments et des émotions :**

Le mining de vidéo peut analyser les expressions faciales et le langage corporel des personnes dans les vidéos pour identifier leurs sentiments et leurs émotions. Cela permet de mieux comprendre l'opinion publique sur des sujets précis ou l'efficacité de campagnes de communication.[13]

**1.4.2.3.2 Techniques de mining de la vidéo couramment utilisées : - L'ex-**

**traction de caractéristiques :** Cette technique consiste à identifier les caractéristiques importantes d'une vidéo, telles que la couleur, la forme, ou le mouvement.




FIGURE 1.2 – L'extraction des caractéristiques de la vidéo

- **La classification automatique de la vidéo** : Cette technique consiste à assigner une vidéo à une catégorie prédéfinie.
- **La recherche de la vidéo** : cette technique consiste à rechercher des vidéos qui correspondent à des critères spécifiques.
- **La recommandation de la vidéo** : cette technique consiste à recommander des vidéos aux utilisateurs en fonction de leurs intérêts.

#### 1.4.2.4 Mining de l'image :

Le mining d'images, également appelé analyse d'image ou extraction de caractéristiques d'images, est un domaine intéressant du data mining et de la vision par ordinateur qui consiste à extraire des informations et des connaissances à partir d'images et de photos numériques.

##### **Techniques de l'image mining :**

Les techniques de mining d'image peuvent extraire une multitude d'informations à partir d'images, notamment :

- **Reconnaissance des objets et des scènes** : Identifier et localiser des objets spécifiques (voitures, personnes, animaux) ou des scènes (paysages, rues, intérieurs) dans une image.

- **Extraction des caractéristiques d'objets** : Extraire des propriétés d'objets tels que la taille, la forme, la couleur, la texture et la pose.

- **Relations entre objets** : Détecter les relations spatiales et temporelles entre différents objets dans une image.

- **Analyse du mouvement dans une scène** : Analyser le mouvement et l'activité dans une séquence d'images ou une vidéo.

- **Textes et symboles** : Reconnaître et extraire des textes et des symboles présents dans une image.

#### 1.4.2.5 Mining des réseaux sociaux : [68]

La fouille des réseaux sociaux, également connue sous le nom d'analyse des réseaux sociaux ou de "social media mining", est le processus d'extraction et d'analyse de données provenant de plateformes de réseaux sociaux comme Facebook, Twitter, Instagram et LinkedIn. Ces données peuvent inclure du texte, des images, des vidéos et d'autres formes de contenu générées par les utilisateurs.[68]

L'objectif de la fouille des réseaux sociaux est d'identifier des modèles, des tendances et des informations précieuses qui peuvent être utilisées pour une variété d'objectifs, tels que :

Comprendre le sentiment public et les opinions sur des sujets ou des produits particuliers. Identifier les influenceurs clés au sein de réseaux sociaux spécifiques.  
Suivre les campagnes marketing et la réputation de la marque. Obtenir des informations sur les concurrents.

Développer de nouveaux produits et services. Améliorer le service client.

##### 1.4.2.5.1 Applications :

Le Mining des réseaux sociaux a un large éventail d'applications dans divers domaines, tels que :

- **Marketing et publicité** : Analyser les sentiments et les opinions des clients vis-à-vis d'une marque ou d'un produit, identifier les influenceurs potentiels et cibler les campagnes publicitaires de manière plus efficace.

- **Gestion de la relation client** : Gérer les interactions avec les clients, résoudre les problèmes et améliorer l'expérience client globale.

- **Détection des incidents et analyse des risques** : Détection des incidents et analyse des risques : étudier les structures sociales, les comportements collectifs et les tendances culturelles. [68]

#### **1.4.2.5.2 Les techniques différentes pour fouiller les données des réseaux sociaux :**

- **Analyse de texte** :

impliquer l'extraction et l'analyse du contenu textuel des réseaux sociaux, tels que les publications, les commentaires et les messages.

- **Analyse du réseau** :

Examine les relations entre les utilisateurs des réseaux sociaux, tels que les abonnés, les amis et les mentions, ainsi qu'identifier les communautés, les leaders d'opinion et les relations entre les utilisateurs.

- **Analyse des sentiments** : Identifier et classier le sentiment émotionnel du contenu des réseaux sociaux, comme positif, négatif ou neutre.

- **Apprentissage automatique** : Classifier les données, prédire les tendances et identifier les anomalies. [68]

#### **1.4.2.5.3 Les Avantages Du mining des réseaux sociaux :**

- **Meilleure prise de décision** :

Les entreprises peuvent utiliser la fouille des réseaux sociaux pour mieux comprendre leurs clients, leurs concurrents et leur marché, ce qui peut conduire à une meilleure prise de décision.

- **Amélioration du service client** :

Les entreprises peuvent utiliser la fouille des réseaux sociaux pour surveiller les commentaires des clients et identifier les problèmes potentiels, ce qui peut améliorer le service

client.

**- Développement de nouveaux produits et services :**

Les entreprises peuvent utiliser la fouille des réseaux sociaux pour identifier les tendances et les besoins des clients, ce qui peut conduire au développement de nouveaux produits et services.

**- Marketing plus efficace :**

Les entreprises peuvent utiliser la fouille des réseaux sociaux pour cibler leurs campagnes marketing plus efficacement et atteindre un public plus large.

**1.4.2.5.4 Les Risques du mining réseaux sociaux : - Atteinte à la vie privée :**

La fouille des réseaux sociaux peut soulever des inquiétudes concernant la vie privée, car elle implique la collecte et l'analyse de données personnelles.

**- Désinformation et manipulation :**

Les données des réseaux sociaux peuvent être utilisées pour diffuser de fausses informations et manipuler l'opinion publique.

**- Discrimination :**

les algorithmes de fouille des réseaux sociaux peuvent être biaisés et conduire à une discrimination.

En résumé, la fouille des réseaux sociaux est un outil puissant qui peut être utilisé pour un large éventail d'objectifs. Cependant, il est important d'être conscient des impacts et des implications potentiels de la fouille des réseaux sociaux avant de l'utiliser. Il est également important d'utiliser la fouille des réseaux sociaux de manière éthique et responsable, en respectant la vie privée des utilisateurs et en évitant de diffuser de fausses informations ou de manipuler l'opinion publique.

#### 1.4.2.6 Mining des times series : [52]

##### 1.4.2.6.1 Définition :

La fouille de séries temporelles, également appelée "*time series mining*", est un domaine de l'analyse de données qui se concentre sur l'extraction de connaissances et de modèles informatifs à partir de données collectées au fil du temps.

Ces données, appelées *séries temporelles*, peuvent représenter des variations de mesures sur une période donnée, comme :

- Les cours de la bourse en finance
- Les ventes quotidiennes d'un magasin
- La température mesurée toutes les heures par une station météo
- Le nombre de publications sur un réseau social par minute

En analysant les séries temporelles, on peut découvrir des tendances, des cycles, des événements anormaux et des relations entre différentes séries.

##### 1.4.2.6.2 Utilisation des connaissances :

Ces connaissances peuvent être utilisées pour diverses applications, telles que :

###### - **Prévision :**

Prévoir les valeurs futures d'une série temporelle, par exemple, pour prévoir la demande d'un produit ou la propagation d'une épidémie.

###### - **Détection d'anomalies :**

Identifier les points de données qui s'écartent de la tendance habituelle, ce qui peut indiquer des problèmes potentiels ou des événements inhabituels.

###### - **Segmentation :**

Diviser une série temporelle en segments présentant des caractéristiques similaires, ce qui peut aider à comprendre la dynamique sous-jacente des données.

- **Classification :**

Classer les séries temporelles en fonction de leurs caractéristiques, ce qui peut être utile pour des applications telles que la maintenance prédictive.

**1.4.2.6.3 Les Techniques de fouille de séries temporelles :**

Plusieurs techniques peuvent être utilisées pour fouiller les séries temporelles. Voici quelques exemples :

- **Analyse des tendances :** Identifier les tendances générales dans les séries temporelles, telles que les augmentations ou les diminutions à long terme. Détection d'anomalies : identifier les points de données qui s'écartent significativement des valeurs attendues.[52]

- **Segmentation :** Diviser les séries temporelles en segments distincts avec des caractéristiques homogènes.[52]

- **clustering :** identifier les groupes de séries temporelles qui présentent des comportements similaires.[52]

- **Apprentissage automatique :** Utiliser des algorithmes d'apprentissage automatique pour prédire des valeurs futures, identifier des relations entre les séries temporelles et construire des modèles explicatifs.[52]

**1.4.2.6.4 Applications de la fouille des séries temporelles :** La fouille des séries temporelles a un large éventail d'applications dans divers domaines, tels que :

- **La Finance :**

Prévision des prix des actions, détection de fraude, gestion des risques.

- **La Santé :**

Surveillance des patients, diagnostic de maladies, développement de nouveaux traitements.

- **L'Environnement :**

Prévision des conditions météorologiques, surveillance du changement climatique, gestion des ressources naturelles.

#### **- L'industrie :**

Prévision de la demande, optimisation de la production, détection de défauts.

#### **- Le Marketing :**

Analyse du comportement des clients, segmentation du marché, ciblage publicitaire. [52]

La fouille de séries temporelles est un domaine important qui permet d'extraire des informations précieuses des données temporelles. En utilisant les techniques et les outils appropriés, nous pouvons découvrir des modèles et des tendances dans les données, ce qui peut aider à prendre de meilleures décisions et à améliorer les résultats.

### **1.4.3 Le Big Data**

Le Big Data, ou mégadonnées en français, désigne l'ensemble des données numériques produites par l'utilisation des nouvelles technologies à des fins personnelles ou professionnelles. Il s'agit d'un ensemble massif, complexe et hétérogène de données présentant trois caractéristiques fondamentales :[11]

#### **1.4.3.1 V1 : Le volume :**

Les données sont produites à un rythme exponentiel, avec des volumes qui peuvent atteindre des dizaines de pétaoctets ou plus.[11]

#### **1.4.3.2 V2 : La vitesse :**

Les données sont générées en temps réel ou quasi-temps réel, nécessitant ainsi des outils et des techniques d'analyse adaptés.[11]

#### **1.4.3.3 V3 : La variété :**

Les données sont de natures variées, allant des données structurées (comme les données de bases de données) aux données non structurées (comme les données textuelles, audio

et vidéo).[11]

Le Big Data a un impact majeur sur de nombreux secteurs d'activité, notamment la santé, la finance, le marketing et la vente au détail. Il permet d'améliorer la prise de décision, de mieux comprendre les comportements des consommateurs et de développer de nouveaux produits et services.[11]

Par exemple, les réseaux sociaux génèrent des données à chaque fois qu'un utilisateur crée un nouveau post, aime un post ou commente un post. Ces données peuvent être utilisées pour analyser les comportements des utilisateurs, cibler les publicités ou améliorer la sécurité des réseaux sociaux.[11]

Le Big Data est important car il permet de mieux comprendre le monde qui nous entoure. Il peut être utilisé pour prendre des décisions plus éclairées, développer de nouveaux produits et services ou résoudre des problèmes complexes.[11]

## 1.5 Les tâches du Data mining [53]

L'exploration de données via le data mining s'appuie sur une ou plusieurs de ces techniques :

### 1.5.1 Recherche de motifs :

L'une des techniques les plus fondamentales de l'exploration de données consiste à apprendre à reconnaître des motifs (ou patterns) dans les données. Il s'agit généralement de la reconnaissance d'une corrélation qui revient à intervalles réguliers. Par exemple : Constater qu'un certain produit semble atteindre un pic juste avant les vacances, ou remarquer que la météo plus clémente attire davantage de personnes sur un site Web.

### 1.5.2 La classification :

La classification est une technique de data mining plus complexe qui nécessite de rassembler divers attributs en catégories discernables. Ces attributs sont par la suite exploités pour regrouper les données par groupes homogènes. Par exemple, l'évaluation

des données commerciales sur les antécédents financiers et l'historique des achats de clients individuels permet de classer ces données suivant des notions de risques de crédit « faibles », « moyens » ou « élevés ». Ce qui constitue une connaissance précieuse sur les clients.

### **1.5.3 Règles d'association :**

L'association est liée au fait de détecter et de suivre des patterns, mais elle est plus spécifique aux variables liées entre elles. Dans ce cas, nous cherchons des événements ou des attributs spécifiques qui sont fortement corrélés à un autre événement ou attribut. Par exemple, que l'achat d'un article, entraîne souvent un deuxième article connexe. C'est généralement ce qui est utilisé pour alimenter les algorithmes de recommandation des sections « les personnes ont également acheté » des sites de e-commerce.

### **1.5.4 Détection des valeurs aberrantes :**

Il est important aussi d'être en mesure d'identifier les anomalies ou les valeurs aberrantes dans les données. Par exemple, si les acheteurs d'un produit sont d'habitude presque exclusivement des hommes, l'apparition subite d'un énorme pic d'acheteurs féminins est considérée comme une anomalie. Il faut alors essayer de comprendre ce pic et ce qui l'a provoqué, afin de pouvoir soit le reproduire, soit mieux comprendre le comportement des clients.

### **1.5.5 Regroupement :**

Le clustering est très similaire à la classification, mais il consiste à regrouper des blocs de données en fonction de leurs similitudes. Par exemple, il est possible de regrouper différentes données démographiques dans différents groupes, en fonction de la fréquence de leurs achats dans un supermarché ou un site de e-commerce.

### **1.5.6 Régression :**

La régression, utilisée principalement comme une forme de planification et de modélisation, sert à expliquer une certaine variable (variable à expliquer), compte tenu de la présence d'autres variables (variables explicatives). Par exemple, il est possible de prévoir un certain prix, en fonction d'autres facteurs, comme la disponibilité, la demande des consommateurs et la concurrence. Plus précisément, l'objectif principal de la régression est d'aider à découvrir la relation entre deux variables (ou plus) dans un ensemble de données.

### **1.5.7 Prédiction :**

La prédiction est l'une des techniques d'exploration de données les plus utiles, car elle est utilisée pour prévoir les types de données dans le futur. Dans de nombreux cas, il suffit de reconnaître et de comprendre les tendances historiques pour établir une prédiction assez précise de ce qui se passera à l'avenir. Par exemple, l'utilisation des antécédents de crédit des consommateurs et leurs achats passés pour prédire s'ils présentent un risque de crédit à l'avenir.

## **1.6 Conclusion :**

Le data mining est une discipline qui consiste à extraire des connaissances pertinentes à partir de grandes quantités de données. Ces connaissances peuvent être utilisées pour prendre des décisions plus éclairées, pour développer de nouveaux produits et services ou pour résoudre des problèmes complexes. Le Data Mining utilise des techniques puissantes qui peuvent être appliquées à de nombreux domaines, tels que la santé, la finance, le marketing, la vente au détail, la production industrielle, la recherche scientifique, etc. Toutefois, le data mining présente également des défis, tels que la confidentialité des données, la sécurité des données et l'interprétation des données. Il est important de prendre en compte ces défis lors de l'utilisation du data mining.

# Chapitre 2

## Présentation du domaine de l'Image Mining

### 2.1 Introduction :

Dans le chapitre précédent, nous avons parlé du data mining en général. Dans ce chapitre nous allons passer à un domaine plus spécifique qui est l'image mining. Le mining de l'image ou fouille de l'image est l'extraction des relations et des modèles qui ne sont pas explicitement stockés dans une base de données à partir d'images brutes. C'est un domaine bien structuré qui s'appuie sur des techniques solides, telles que l'intelligence artificielle, l'apprentissage automatique, la recherche d'images, le traitement d'images, la vision par ordinateur et les bases de données. La principale raison de la popularité croissante de la fouille d'images est sa capacité à inférer automatiquement des connaissances à partir des données d'images. Les images brutes ou les séquences d'images avec une représentation pixellisée de bas niveau sont traitées de manière efficace et efficiente pour extraire les objets de haut niveau et leurs relations à partir de ces images. La fouille d'images est encore au stade expérimental. Elle peut être considérée comme une hybridation efficace des concepts de traitement d'images et de fouille de données pour extraire des connaissances utiles.[\[29\]](#)

## 2.2 Définition de l'image :

Une image est une représentation visuelle d'un objet ou d'une scène. Elle peut être créée par un appareil photo, un scanner, un artiste ou un ordinateur. Les images peuvent être utilisées pour communiquer, informer, divertir ou simplement pour être regardées.[56]

### 2.2.1 Fouille de l'image :

L'image mining, aussi appelé fouille d'images, est un domaine de l'informatique qui vise à extraire des connaissances à partir d'images numériques. Il s'agit d'un domaine interdisciplinaire qui utilise des techniques issues de l'informatique, des mathématiques, des statistiques et de l'infographie, entre autres.[56]

### 2.2.2 Définition d'image dans le contexte du mining :

En fouille d'images, le contexte d'une image est défini comme l'information qui entoure l'image et qui peut être utilisée pour l'analyser. Cette information peut inclure :

Les métadonnées de l'image, telles que la date de création, l'appareil photo utilisé et la légende.

Les images voisines dans une collection d'images. Le texte associé à l'image, telles que les légendes ou les descriptions.

Le contexte peut être utilisé pour améliorer les performances des tâches de fouille d'images telles que la classification d'images, la détection d'objets et la recherche d'images par le contenu.[56]

## 2.3 Les espaces de couleurs de l'image :

Les espaces de représentation d'image sont des techniques qui permettent de représenter les images sous une forme plus compacte et précise. Ils sont utilisés dans de nombreux domaines, tels que la vision par ordinateur, le traitement d'images, la biométrie, la recherche de l'image et la reconnaissance d'images.

### 2.3.1 Le modèle RGB :

RGB signifie rouge, vert, bleu. C'est l'espace de couleurs le plus courant, car il est utilisé par les écrans d'ordinateur, les caméras. Dans l'espace RGB, chaque pixel d'une image est représenté par trois valeurs, chacune correspondant à la quantité de rouge, de vert et de bleu qu'il contient.

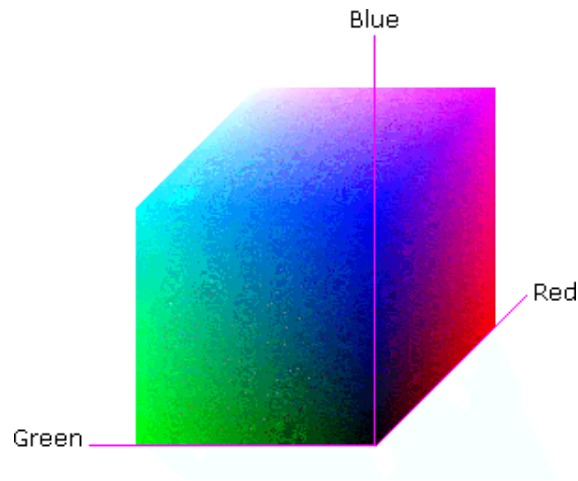


FIGURE 2.1 – Représentation de l'espace RGB[18]

### 2.3.2 HSV :

HSV signifie hue, saturation, value. C'est un espace de couleurs plus intuitif que RGB, car il représente la couleur en termes de ses trois composantes fondamentales :

#### **Hue (teinte) :**

La teinte correspond à la couleur de base de l'image, telle que le rouge, le vert ou le bleu.

#### **Saturation (saturation) :**

La saturation correspond à l'intensité de la couleur. Une saturation élevée correspond à une couleur vive, tandis qu'une saturation faible correspond à une couleur pâle.

#### **Value (valeur) :**

La valeur correspond à la luminosité de l'image. Une valeur élevée correspond à une image lumineuse, tandis qu'une valeur faible correspond à une image sombre.




FIGURE 2.2 – Représentation de l'espace HSV[19]

### 2.3.3 Comparaison entre le RGB et le HSV :

Caractéristique	RGB	HSV
Nombre de dimensions	3	3
Définition	La couleur est représentée par la quantité de rouge, de vert et de bleu.	La couleur est représentée par la teinte, la saturation et la valeur.
Intuition	Moins intuitif	Plus intuitif
Perception humaine	Moins conforme	Plus conforme
Applications	Ecrans, caméras	Vision par ordinateur, traitement d'images

FIGURE 2.3 – Tableau de comparaison entre le RGB et le HSV

### 2.3.4 L'espace LAB :

LAB est un espace de couleurs basé sur la perception humaine de la couleur, ce qui le rend plus adapté à certaines tâches de vision par ordinateur, telles que la reconnaissance

d'objets et la recherche de l'image. LAB est un espace de couleurs tridimensionnel. Les trois dimensions sont :

- **L** : La luminosité, qui correspond à la valeur de l'espace HSV.
- **a** : La teinte rouge-verte.
- **b** : La teinte jaune-bleue




FIGURE 2.4 – Représentation de l'espace LAB[66]

### 2.3.5 CIE-LCH

CIE-LCH est une dérivé du CIE LAB. Il est basé sur l'espace CIE LAB, mais il ajoute deux dimensionss supplémentaire pour représenter la saturation et l'angle de teinte  $h^\circ$ . [38] La première dimension supplémentaire pour représenter la saturation pour le CIE-LCH est appelée "chroma". Le chroma est une mesure de l'intensité de la couleur, indépendante de la luminosité. Une valeur élevée de chroma correspond à une couleur vive, tandis qu'une valeur faible de chroma correspond à une couleur pâle. Cette mesure a été ajouter car la saturation est plus précise que la distance par rapport à l'axe de luminosité. [38]

La deuxième dimension supplémentaire pour représenter l'angle de teinte  $h^\circ$  pour le CIE-LCH qui représente la position de la couleur sur le cercle chromatique. Elle est exprimée en degrés, avec  $0^\circ$  pour le rouge,  $120^\circ$  pour le vert et  $360^\circ$  pour le rouge. [15]

Dans l'espace LAB, la saturation est représentée par la distance entre le point représentant la couleur de l'image et l'axe de luminosité. Cependant, cette représentation n'est pas optimale, car elle ne prend pas en compte l'effet de la luminosité sur la perception humaine de la saturation. [39] Le CIE LCH est représenté sous forme une sphère comme le montre la figure :

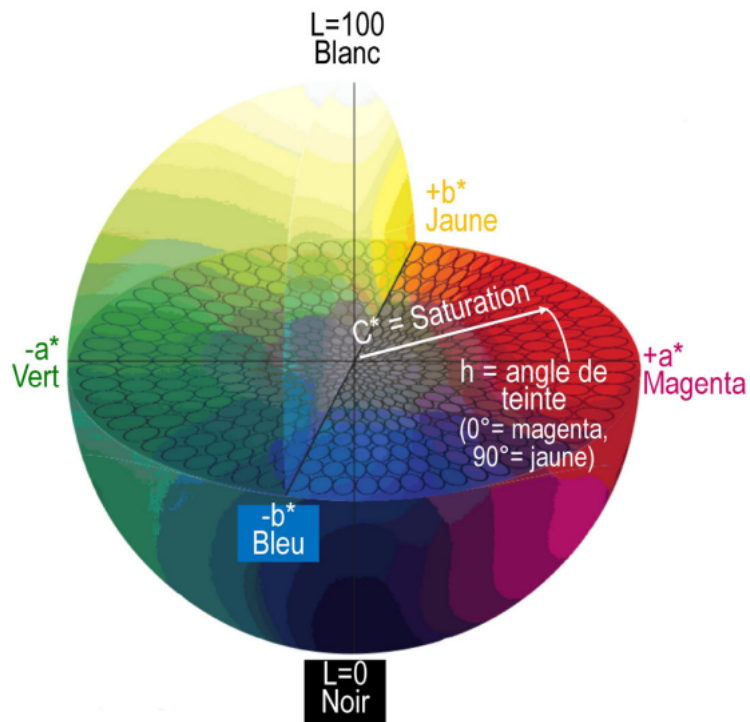


FIGURE 2.5 – Représentation de l'espace CIE-LCH[15]

Le chroma est calculé comme suit :[39]

$$\text{chroma} = \sqrt{a^2 + b^2} \quad (2.1)$$

La teinte  $h^\circ$  est calculé comme suit :[15]

$$h = \arctan\left(\frac{b}{a}\right) \quad (2.2)$$

Où a et b sont les valeurs de la teinte rouge-verte et jaune-bleue dans l'espace LAB.

Il permet alors de mieux représenter la perception humaine de la saturation, ce qui le rend plus adapté à certaines tâches de vision par ordinateur, telles que la classification d'images.

### 2.3.5.1 Avantages du CIE-LCH :

L'espace CIE-LCH présente plusieurs avantages par rapport aux autres espaces de couleur, tels que RGB et CMYK :

- Large gamme de couleurs :

L'espace CIE-LCH peut représenter une large gamme de couleurs, y compris celles qui ne peuvent pas être représentées dans les espaces RGB ou CMYK.[39]

### **2.3.5.2 Applications du CIE-LCH :**

L'espace CIE-LCH est utilisé dans une large gamme d'applications, notamment :

#### **- Gestion des couleurs :**

Le CIE-LCH est couramment utilisé dans les logiciels de gestion des couleurs pour calibrer les moniteurs, les imprimantes et autres appareils d'affichage.

#### **- Impression :**

L'espace CIE-LCH est utilisé pour spécifier les couleurs d'impression dans les workflows d'impression professionnels.

#### **- Éclairage :**

L'espace CIE-LCH est utilisé pour spécifier les couleurs de la lumière dans les applications d'éclairage.

#### **- Textile :**

L'espace CIE-LCH est utilisé pour spécifier les couleurs des textiles dans l'industrie textile.[39]

## **2.4 Les caractéristiques de l'image :**

### **2.4.1 La couleur :**

La couleur d'une image est une mesure de la composition spectrale de la lumière qu'elle contient. Elle peut être décrite par des valeurs RGB, HSV ou XYZ.

#### 2.4.1.1 L'histogramme de couleur :

L'histogramme de couleur est une représentation graphique qui décrit la distribution des couleurs dans une image. Il s'agit d'un outil essentiel pour comprendre la répartition des tons et la dominance des couleurs.[40]

##### 2.4.1.1.1 Fonctionnement :

- L'histogramme se compose d'axes x et y. L'axe x représente les valeurs de couleur, généralement codées par des niveaux de rouge, vert et bleu (RVB) ou des niveaux de gris.[40]
- L'axe y représente le nombre de pixels pour chaque valeur de couleur.[40]

##### 2.4.1.1.2 Interprétation :

- Un pic dans l'histogramme indique une présence dominante de la couleur correspondante.[40]
- Un histogramme plat indique une distribution uniforme des couleurs.[40]
- L'analyse de l'histogramme peut révéler des informations sur l'éclairage, le contraste et le contenu de l'image.[40]

##### 2.4.1.1.3 Application :

- Équilibrage des couleurs : Ajuster la luminosité et le contraste d'une image pour améliorer la qualité visuelle.[40]
- Segmentation d'image : Identifier et séparer des objets distincts dans une image en fonction de leurs couleurs.[40]
- Compression d'image : Réduire la taille d'un fichier image en se concentrant sur les couleurs les plus dominantes.[40]

##### 2.4.1.1.4 L'équation de l'histogramme de couleur :

L'équation de l'histogramme de couleur dépend du modèle de couleur utilisé. En général, l'histogramme de couleur est calculé pour chaque canal de couleur de l'image.

Pour un canal de couleur donné, l'histogramme est une fonction discrète qui compte le nombre de pixels ayant une valeur de couleur spécifique.[40]

Voici l'équation de l'histogramme de couleur pour un canal de couleur donné  $c$  d'une image  $I$  :

$$h(k) = N(I, c = k)[64] \quad (2.3)$$

$h(k)$  : est le nombre de pixels de l'image  $I$  ayant une valeur de couleur  $k$  pour le canal  $c$ .

$N(I, c = k)$  :est le nombre de pixels de l'image  $I$  pour lesquels la valeur du canal  $c$  est égale à  $k$ .

#### **2.4.1.1.5 La représentation graphique de l'histogramme de couleur :**

La représentation graphique de l'histogramme de couleur est un diagramme qui montre la distribution des couleurs dans une image. L'axe horizontal du graphique représente les valeurs de couleur possibles, tandis que l'axe vertical représente le nombre de pixels de l'image ayant chaque valeur de couleur.[40]

##### **2.4.1.1.5.1 Les étapes générales pour créer une représentation graphique de l'histogramme de couleur pour une image donnée :**

###### **1 - Calculer l'histogramme de couleur :**

Pour chaque canal de couleur de l'image, comptez le nombre de pixels ayant chaque valeur de couleur possible. Cela peut être fait en utilisant l'équation de l'histogramme de couleur.[40]

###### **2 - Créer le graphique :**

Créez un diagramme avec les valeurs de couleur sur l'axe horizontal et le nombre de pixels pour chaque valeur de couleur sur l'axe vertical.[40]

###### **3 - Tracer les données :**

Tracez les points de données calculés à l'étape 1 (1- Calculer l'histogramme de couleur) sur le graphique. Ajouter des étiquettes et un titre : Ajoutez des étiquettes aux axes et un titre au graphique.

### 2.4.1.1.5.2 Un exemple de représentation graphique d'un histogramme de couleur pour une image RVB :

Nous notons que l'axe horizontal représente les valeurs de rouge, vert et bleu, de 0 à 255.

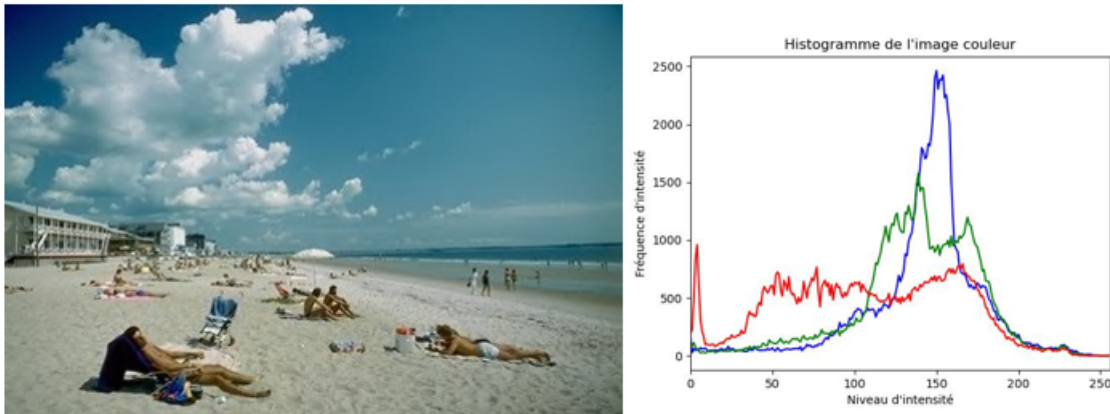


FIGURE 2.6 – Représentation graphique de l'histogramme de couleur RGB[58]

L'axe vertical représente le nombre de pixels de l'image ayant chaque valeur de couleur. Les pics de l'histogramme indiquent qu'il y a beaucoup de pixels dans l'image qui ont des valeurs de rouge, vert et bleu élevées. Cela signifie que l'image est probablement très lumineuse.

### 2.4.1.2 Les moments de couleur :

Les moments de couleurs jouent un rôle important dans la classification d'images par extraction de caractéristiques. Ils permettent de capturer des informations statistiques sur la distribution des couleurs dans une image, ce qui peut être utile pour distinguer différentes classes d'images.[40]

Voici les équations pour calculer les moments statistiques de couleur :[6]

#### 1- Moyenne de couleurs :

$$\mu = \frac{1}{N} \sum_{i=1}^N C_{ij} \quad (2.4)$$

- $\mu$  : Représente la moyenne de la couleur choisie  $C$ .
- $N$  : Ce terme représente le nombre totale de pixels.

- $\Sigma$  : Ce symbole représente le symbole de la somme.
- $C$  : Représente l'axe de la couleur choisie (Rouge ou vert ou Bleu).

## 2 - Écart-type de couleur :

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (C_{ij} - \mu)^2 \quad (2.5)$$

- $\sigma^2$  : Représente la variance de l'axe de la couleurs choisie  $C$ .
- $\mu$  : Représente la moyenne de la couleur choisie  $C$ .
- $N$  : Ce terme représente le nombre totale de pixels.
- $\Sigma$  : Ce symbole représente le symbole de la somme.
- $C$  : Représente l'axe de la couleur choisie (Rouge ou vert ou Bleu).

## 3 - Skewness (asymétrie) de couleur :

$$Skewness = \frac{1}{N} \sum_{i=1}^N \left( \frac{C_{ij} - \mu}{\sigma} \right)^3 \quad (2.6)$$

- $\sigma$  : Représente la variance de l'axe de la couleurs choisie  $C$ .
- $\mu$  : Représente la moyenne de la couleur choisie  $C$ .
- $N$  : Ce terme représente le nombre totale de pixels.
- $\Sigma$  : Ce symbole représente le symbole de la somme.
- $C$  : Représente l'axe de la couleur choisie (Rouge ou vert ou Bleu).

### 2.4.1.2.1 Quelques avantages de l'utilisation des moments de couleurs pour la classification d'images :

- Simplicité et efficacité : Les moments de couleurs sont faciles à calculer et à interpréter.[40]
- Robustesse : Ils sont relativement robustes au bruit et aux variations d'éclairage.[40]
- Invariant de rotation et d'échelle : Certains moments de couleurs, comme les moments de Hu, sont invariants à la rotation et à l'échelle de l'image.[40]
- Capacité à discriminer les textures : Ils peuvent être utilisés pour discriminer les textures fines dans les images.[40]

#### 2.4.1.2.2 Combinaison de l'histogramme et des moments de couleur :

L'utilisation conjointe de l'histogramme de couleur et des moments de couleur offre une analyse d'image plus complète et plus informative.[40]

- L'histogramme fournit des détails granulaires sur la distribution des couleurs à chaque niveau de valeur.[40]
- Les moments de couleur résument les caractéristiques globales des couleurs, permettant une comparaison rapide entre les images.[40]
- Les moments de couleur résument les caractéristiques globales des couleurs, permettant une comparaison rapide entre les images.[40]

En combinant ces deux approches, les systèmes d'analyse d'images peuvent obtenir une compréhension plus approfondie du contenu chromatique et des propriétés des images, ce qui améliore les performances dans diverses tâches de traitement d'images.[40]

L'histogramme de couleur et les moments de couleur sont des outils essentiels pour l'analyse d'images, fournissant des informations précieuses sur la distribution et les caractéristiques des couleurs dans les images. Leur utilisation combinée permet une analyse plus complète et plus nuancée des images, ce qui est crucial pour une large gamme d'applications en vision par ordinateur, traitement d'images et intelligence artificielle.[40]

La couleur est une caractéristique importante des images, car elle peut être utilisée pour identifier des objets, des scènes ou des personnes. Par exemple, la couleur peut être utilisée pour identifier une pomme comme étant rouge, ou pour identifier une plage comme étant bleue.

#### 2.4.2 La texture :

La texture d'une image est une mesure de la variation des valeurs des pixels. Elle peut être décrite par des mesures telles que la variabilité, la rugosité et la fréquence.[40]

### 2.4.2.1 Caractéristique de la texture :

**2.4.2.1.1 Variabilité :** La variabilité est une mesure de la différence entre les valeurs des pixels. Une variabilité élevée correspond à une image avec une texture riche, tandis qu'une variabilité faible correspond à une image avec une texture uniforme.[40]

#### **Exemples d'images à haute et basse variabilité :**

##### **- Images à haute variabilité :**

**Image de l'écorce d'un arbre :** L'écorce d'un arbre présente une surface très rugueuse et texturée, ce qui se traduit par une grande variabilité des valeurs des pixels dans l'image. Les différentes nuances de brun et les motifs irréguliers de l'écorce créent beaucoup de contraste et de détails.[40]

##### **- Images à faible variabilité :**

**Image d'un ciel bleu clair :** Un ciel bleu clair est une image très uniforme, avec très peu de variation dans les valeurs des pixels. Le ciel est généralement d'un bleu uni, avec très peu de nuages ou d'autres caractéristiques.[40]

**2.4.2.1.2 Rugosité :** La rugosité est une mesure de la régularité de la variation des valeurs des pixels. Une rugosité élevée correspond à une image avec une texture irrégulière, tandis qu'une rugosité faible correspond à une image avec une texture régulière.[40]

**2.4.2.1.3 Fréquence :** La fréquence est une mesure de la distance entre les changements de valeur des pixels. Une fréquence élevée correspond à une image avec une texture fine, tandis qu'une fréquence faible correspond à une image avec une texture grossière.[40]

La texture est une caractéristique importante des images, car elle peut être utilisée pour identifier des objets, des scènes ou des personnes. Par exemple, la texture peut être utilisée pour identifier un mur de briques comme étant rugueux, ou pour identifier un tapis comme étant lisse.

### 2.4.2.2 LBP :

LBP, ou Local Binary Pattern, est une technique de texture couramment utilisée en vision par ordinateur. Elle permet de décrire la texture d'une image en calculant des motifs binaires locaux autour de chaque pixel.[40]

La LBP (Local Binary Pattern) est une technique utilisée en traitement d'images pour décrire les textures. Voici les équations associées :

#### 2.4.2.2.1 Calcul du motif binaire local (LBP) :

Soit  $p$  le nombre de pixels dans le voisinage de chaque pixel central  $x_c$  et  $f(x)$  la fonction qui compare l'intensité des pixels avec celui du pixel central. La LBP de  $x_c$  est définie comme suit :

$$LBP(x_c) = \sum_{i=0}^{p-1} f(g_i - g_c) \times 2^i [40] \quad (2.7)$$

Où  $g_i$  est l'intensité des pixels voisins et  $g_c$  est l'intensité du pixel central.

Cela peut être appliqué comme suit :

- **Fenêtre d'analyse** : Autour de chaque pixel, on définit une petite fenêtre d'analyse (par exemple, 3x3 pixels).
- **Comparaison avec le pixel central** : On compare la valeur du pixel central de la fenêtre avec les valeurs des pixels voisins.[40]
- **Attribution de valeurs binaires** : Si la valeur d'un pixel voisin est supérieure au pixel central, on lui attribue un 1 ; sinon, on lui attribue un 0.[40]
- **Code binaire** : En concaténant les valeurs binaires obtenues, on forme un code binaire représentant le motif local autour du pixel central.

#### 2.4.2.2.2 Histogramme des motifs LBP :

Une fois que tous les pixels ont été transformés en motifs LBP, un histogramme est généralement calculé pour représenter la distribution des motifs dans l'image.

Cela peut être représenté par l'équation suivante :

$$H_{LBP} = \{h_0, h_1, h_2, \dots, h_{N-1}\} \quad (2.8)$$

où  $h_i$  est le nombre de pixels dans l'image dont le motif LBP est  $i$ , et  $N$  est le nombre total de motifs LBP possibles ( $2^p$ ).

Voici un exemple d'une image ainsi que son histogramme :




FIGURE 2.7 – Illustration d'une image (gauche) et de son image (droite) LBP

#### 2.4.2.2.3 Représentation graphique du Motif Binaire Local (LBP) :

La représentation graphique d'un motif LBP (Local Binary Pattern) se fait généralement de deux manières :

##### **Histogramme circulaire :**

- Un histogramme circulaire est utilisé pour représenter la distribution des valeurs LBP dans un voisinage.[40]
- L'axe  $x$  représente les valeurs LBP possibles (de 0 à  $2^p - 1$ , où  $P$  est la taille du voisinage).[40]
- L'axe  $y$  représente le nombre de fois que chaque valeur LBP apparaît dans le voisinage.[40]
- Les valeurs LBP les plus fréquentes correspondent aux pics de l'histogramme.[40]

#### 2.4.2.2.4 Matrice d'image LBP :

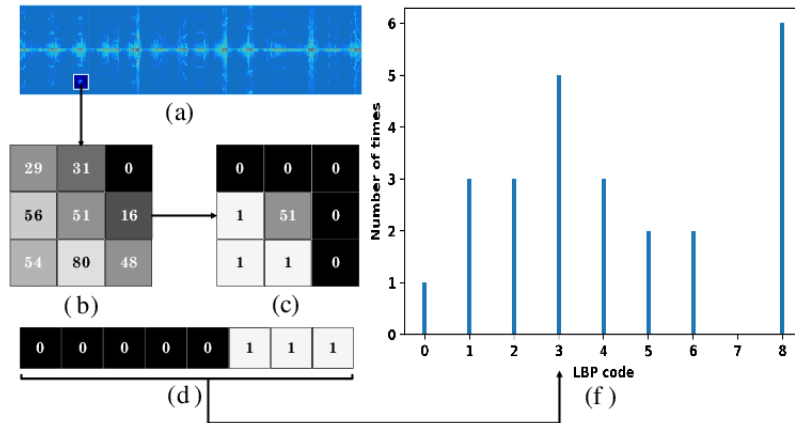


FIGURE 2.8 – Exemple d’histogramme circulaire LBP

- Une matrice d’image LBP peut être créée en attribuant à chaque pixel de l’image sa valeur LBP correspondante.[40]
- Cette matrice permet de visualiser spatialement la distribution des motifs LBP dans l’image.[40]
- Les zones avec des valeurs LBP similaires apparaissent comme des régions homogènes dans l’image.[40]




FIGURE 2.9 – Exemple de matrice d’image LBP[42]

#### 2.4.2.2.5 Illustration du Motif Binaire Local (LBP) :

L’illustration du LBP (Local Binary Pattern) peut se faire de deux manières complémentaires :

##### Exemple d’image avec motif LBP calculé :

Imaginons une image simple contenant une texture de briques. Pour un pixel central donné dans cette image, on peut définir un voisinage de 3x3 pixels. En comparant l’intensité du pixel central avec celle de ses voisins et en appliquant la fonction de comparaison LBP, on obtient un motif binaire. Ce motif peut être représenté par un nombre binaire

(par exemple, 01001011).[40]

### Visualisation du motif LBP :

Une fois le motif LBP obtenu sous forme de nombre binaire, on peut le visualiser schématiquement :

1. On dessine un cercle pour représenter le voisinage. Le pixel central est placé au centre du cercle.[40]
2. Les positions des pixels voisins sont réparties autour du cercle de manière uniforme (par exemple, à des angles de 0°, 45°, 90°, etc.).[40]
3. Chaque bit du motif binaire est associé à un pixel voisin. Un bit à 1 correspond à une intensité de pixel voisin supérieure ou égale à celle du pixel central. Un bit à 0 correspond à une intensité inférieure.[40]
4. En coloriant en noir les positions des bits à 1 et en laissant en blanc celles des bits à 0, on obtient une représentation visuelle du motif LBP.[40]

### 2.4.2.3 Matrice de cooccurrence Haralick :

La matrice de Haralick est une matrice carrée qui caractérise la texture d'une image. Elle est calculée à partir de la cooccurrence des niveaux de gris dans l'image. La matrice de Haralick contient 14 features qui décrivent différentes propriétés de la texture de l'image, telles que :

**1 - L'énergie :** L'énergie mesure l'uniformité de la texture de l'image.

L'énergie de la matrice de cooccurrence de Haralick est définie comme la somme des carrés des éléments normalisés de la matrice  $M^*$  :

$$E = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \left( \frac{M_{ij}}{N} \right)^2 \quad [40] \quad (2.9)$$

$E$  : est l'énergie.

$M_{ij}$  : est la valeur de l'élément  $(i, j)$  de la matrice de cooccurrence  $M$ .

$N_g$  : est le nombre de niveaux de gris dans l'image.

**2 - L'entropie :** L'entropie mesure la complexité de la texture de l'image.

L'entropie de la matrice de cooccurrence de Haralick est définie comme la somme des produits des éléments de la matrice par leurs logarithmes en base 2 :

$$H = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} \left( \frac{M_{ij}}{N} \right) \cdot \log_2 \left( \frac{M_{ij}}{N} \right) [40] \quad (2.10)$$

H : est l'entropie.

M<sub>ij</sub> : est la valeur de l'élément (i, j) de la matrice de cooccurrence M.

N<sub>g</sub> : est le nombre de niveaux de gris dans l'image.

N : est le nombre total de pixels dans l'image.

**3 - Le contraste :** Le contraste mesure la différence entre les niveaux de gris voisins dans l'image.

Le contraste de la matrice de cooccurrence de Haralick est défini comme la somme des produits des éléments de la matrice par leurs différences de niveaux de gris au carré :

$$C = \sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} (i - j)^2 \cdot \left( \frac{M_{ij}}{N} \right) [40] \quad (2.11)$$

C : est le contraste.

M<sub>ij</sub> : est la valeur de l'élément (i, j) de la matrice de cooccurrence M.

N<sub>g</sub> : est le nombre de niveaux de gris dans l'image.

N : est le nombre total de pixels dans l'image.

$$N = \frac{\sum_{i=0}^{N_g-1} \sum_{j=0}^{N_g-1} ((i - \mu_i)(j - \mu_j) \cdot \left( \frac{M_{ij}}{N} \right))}{\sigma_i \sigma_j} [40] \quad (2.12)$$

N : est la corrélation.

M<sub>ij</sub> : est la valeur de l'élément (i, j) de la matrice de cooccurrence M.

N<sub>g</sub> : est le nombre de niveaux de gris dans l'image N est le nombre total de pixels dans l'image.

$\mu_i$  : est la moyenne des niveaux de gris de la ligne i de l'image.

$\mu_j$  : est la moyenne des niveaux de gris de la colonne j de l'image.

$\sigma_i$  : est l'écart-type des niveaux de gris de la ligne i de l'image.

$\sigma_j$  : est l'écart-type des niveaux de gris de la colonne j de l'image.

**4 - La corrélation :** La corrélation mesure la dépendance entre les niveaux de gris voisins dans l'image.

La corrélation de la matrice de cooccurrence de Haralick est définie comme la somme des produits des éléments de la matrice par leurs écarts moyens normalisés :[40]

La matrice de Haralick est souvent utilisée pour la classification d'images. Pour cela, les features de la matrice de Haralick sont utilisées comme attributs pour un classifieur.[40] Le classifieur peut ensuite être utilisé pour prédire la classe d'une image inconnue.[40]

#### **2.4.2.3.1 Avantages de la Matrice de co-occurrence Haralick :**

- La matrice de Haralick est simple à calculer.[40]
- La matrice de Haralick est robuste au bruit.[40]
- La matrice de Haralick est discriminante, c'est-à-dire qu'elle permet de distinguer différentes textures d'images.[40]

#### **2.4.2.3.2 Inconvénients de la Matrice de co-occurrence Haralick :**

- La matrice de Haralick est sensible à la taille de la fenêtre d'analyse.[40]
- La matrice de Haralick ne prend pas en compte la structure spatiale de l'image.[40]

La matrice de Haralick est un outil puissant pour la classification d'images. Elle est simple à calculer, robuste au bruit et discriminante. Cependant, elle est sensible à la taille de la fenêtre d'analyse et ne prend pas en compte la structure spatiale de l'image.[40]

### 2.4.3 La forme (Shape) :

#### 2.4.3.1 Les Polynômes de Hu :

Le polynôme de Hu est un ensemble de moments invariants utilisés pour la reconnaissance de formes et la classification d'images. Il est particulièrement utile pour comparer des images qui ont subi des transformations géométriques, comme des rotations, des translations et des changements d'échelle.[40]

##### **Rôle du polynôme de Hu dans la classification d'images :**

Le polynôme de Hu joue un rôle important dans la classification d'images par minage de données car il permet de :

- **Réduire la dimensionnalité des images :**

Les moments de Hu ne sont que 7 invariants, ce qui est beaucoup moins que le nombre de pixels dans une image. Cela permet de réduire la complexité du processus de classification.[40]

- **Capturer des informations de forme :**

Les moments de Hu sont invariants aux transformations géométriques, ce qui permet de capturer des informations de forme importantes pour la classification d'images.[40]

- **Améliorer la précision de la classification :**

Le polynôme de Hu a été montré efficace pour améliorer la précision de la classification d'images par rapport à d'autres méthodes.[40]

#### 2.4.3.2 Les Polynôme de LEGENDRE :

Les polynômes de Legendre et les coefficients de Fourier peuvent être utilisés pour analyser la forme des images et ainsi contribuer à leur classification.

Les moments de Legendre, dérivés des polynômes de Legendre, peuvent être utilisés pour capturer des informations sur la forme globale d'une image. En calculant les moments de Legendre d'une image, on obtient une représentation mathématique de sa forme, qui peut ensuite être utilisée pour la distinguer d'autres images.

L'équation est représentée comme suit :

$$L_n(X) = \frac{1}{2^n n!} ((X^2 - 1)^n) [40] \quad (2.13)$$

Le polynôme  $L$  étant la dérivée nième d'un polynôme de degré  $2n$ , est donc de degré  $n$

### 2.4.3.3 Les Coefficients de Fourier :

La transformée de Fourier permet de décomposer une image en ses composantes fréquentielles.

En analysant les composantes fréquentielles dominantes d'une image, on peut obtenir des informations sur sa forme. Par exemple, une image avec des bords nets aura des composantes fréquentielles élevées, tandis qu'une image floue aura des composantes fréquentielles plus basses.

L'équation est représentée comme suit : [40]

$$F(k, 1) = \sum_{i=0}^{N-1} \sum_{j=0}^{N-1} f(i, j) e^{-\frac{1}{2\pi} i(k_1 i + k_2 j)} [40] \quad (2.14)$$

Les polynômes de Legendre et les coefficients de Fourier peuvent être combinés pour une analyse plus complète de la forme des images. Par exemple, on peut utiliser les moments de Legendre pour capturer des informations sur la forme globale de l'image, tandis que les coefficients de Fourier peuvent être utilisés pour analyser les détails locaux de la forme. [40]

#### 2.4.3.3.1 Avantages de l'utilisation des polynômes de Legendre et des coefficients de Fourier pour la classification d'images :

##### 2.4.3.3.1.1 Invariance à l'échelle et à la rotation :

Les moments de Legendre et les coefficients de Fourier sont invariants à l'échelle et à la rotation, ce qui signifie qu'ils peuvent être utilisés pour comparer des images même si elles ont été redimensionnées ou rotées. [40]

#### **2.4.3.3.1.2 Robustesse au bruit :**

Les moments de Legendre et les coefficients de Fourier sont relativement robustes au bruit, ce qui signifie qu'ils peuvent fournir des informations fiables sur la forme des images même en présence de bruit. [40]

#### **2.4.3.3.1.3 Efficacité computationnelle :**

Le calcul des moments de Legendre et des coefficients de Fourier peut être effectué efficacement, ce qui les rend adaptés à une utilisation dans des applications de classification d'images en temps réel.

#### **2.4.3.3.2 Exemples d'applications :**

##### **2.4.3.3.2.1 - Reconnaissance d'objets :**

Les polynômes de Legendre et les coefficients de Fourier peuvent être utilisés pour reconnaître des objets dans des images, tels que des visages, des chiffres ou des logos. [40]

##### **2.4.3.3.2.2 - Inspection d'images :**

Les polynômes de Legendre et les coefficients de Fourier peuvent être utilisés pour inspecter des images afin de détecter des défauts ou des anomalies. [40]

##### **2.4.3.3.2.3 - Biométrie :**

Les polynômes de Legendre et les coefficients de Fourier peuvent être utilisés pour des applications biométriques, telles que la reconnaissance faciale ou l'identification de l'iris. [40]

les polynômes de Legendre et les coefficients de Fourier constituent des outils puissants pour l'analyse de la forme des images et peuvent être utilisés efficacement pour la classification d'images dans divers domaines.

## 2.4.4 Les Motifs :

### 2.4.4.1 Définition : [31]

En fouille d'images, les motifs (ou patterns en anglais) désignent des structures récurrentes ou des configurations spécifiques dans les données visuelles qui sont représentatives de certaines caractéristiques ou d'éléments pertinents de l'image. Ces motifs peuvent être des formes géométriques, des textures, des couleurs, ou des arrangements spécifiques de pixels qui se répètent au sein de l'image ou dans un ensemble d'images. L'extraction de motifs vise à identifier et à extraire ces éléments pertinents afin d'en tirer des informations utiles pour diverses applications comme la reconnaissance d'objets, la classification d'images, la segmentation, et plus encore.

### 2.4.4.2 Les techniques d'extraction des motifs : [32]

Il existe plusieurs techniques pour l'extraction des motifs en fouille d'image, notamment :

#### 2.4.4.2.1 Analyse de textures :

Les motifs de texture représentent les arrangements répétitifs ou quasi-répétitifs de tons ou de couleurs dans une image.

Les techniques d'analyse de textures incluent :

- **Matrices de co-occurrence** : Elles mesurent la fréquence des paires de pixels avec des valeurs spécifiques, permettant ainsi de capturer la structure spatiale de la texture.

- **Histogramme des orientations des gradients (HOG)** : Cette méthode encode les distributions des orientations des gradients dans une région, souvent utilisée pour la reconnaissance d'objets.

- **Transformée de Fourier** : Elle décompose l'image en ses composantes fréquentielles, facilitant l'identification des motifs périodiques.

#### 2.4.4.2.2 Analyse de formes et des contours :

Les formes et contours sont des motifs géométriques présents dans les images :

- **Transformée de Hough** : Une technique robuste pour détecter des formes géométriques (lignes, cercles) en transformant les coordonnées de l'image en un espace de paramètres.

- **Détection de contours** : Utilisation d'algorithmes comme Sobel, Canny pour identifier les bords qui délimitent les objets dans une image.

#### 2.4.4.2.3 Analyse de régions :

Segmentation et regroupement des pixels en régions homogènes :

- **Segmentation basée sur les régions** : Techniques comme le seuillage, la région en croissance et les méthodes par graphes pour diviser l'image en segments significatifs.

- **Superpixels** : Réduction du nombre de primitives en regroupant des pixels contigus et similaires, facilitant une analyse plus efficace et précise.

#### 2.4.4.2.4 Caractéristiques locales et descripteurs :

Points d'intérêt et descripteurs pour capturer des informations locales :

- **Points d'intérêt** : Algorithmes comme SIFT (Scale-Invariant Feature Transform), SURF (Speeded Up Robust Features) et ORB (Oriented FAST and Rotated BRIEF) détectent des points robustes aux transformations.

- **Descripteurs locaux** : Caractérisation des régions autour des points d'intérêt avec des descripteurs comme SIFT, SURF, et BRIEF pour une reconnaissance robuste.

#### 2.4.4.2.5 Réseaux de neurones convolutionnels (CNN)

L'apprentissage profond permet l'extraction automatique de motifs complexes en utilisant les **Convolutional Neural Networks (CNNs)** qui apprennent des représentations hiérarchiques à partir des données visuelles, capturant des motifs de bas niveau (bords, textures) aux motifs de haut niveau (objets, scènes).

## 2.5 Les mesures de distances et les mesures de similarité

### 2.5.1 Les mesures de distance :

Les mesures de distance sont utilisées pour quantifier la différence entre deux objets ou deux ensembles d'objets. Elles sont souvent utilisées dans les applications de fouille d'images pour comparer des images ou des ensembles d'images.

Il existe de nombreux types de mesures de distance, mais certaines des plus courantes sont les suivantes :

#### 2.5.1.1 Distance Euclidienne :

La distance euclidienne est la distance la plus couramment utilisée. Elle est définie comme la longueur du segment de ligne reliant deux vecteurs dans un espace euclidien.

[22]

L'équation de la distance euclidienne entre deux vecteurs  $\mathbf{P}, \mathbf{Q}$ . [20]

$$d_{\text{euclid}}(\mathbf{P}, \mathbf{Q}) = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (2.15)$$

où  $\mathbf{P} = (p_1, p_2, \dots, p_n)$  et  $\mathbf{Q} = (q_1, q_2, \dots, q_n)$  sont des vecteurs dans  $R^n$ .

#### 2.5.1.2 Distance Manhattan :

La distance de Manhattan est une mesure de distance alternative qui est définie comme la somme des différences absolues entre les coordonnées de deux points. [62]

L'équation de la distance de Manhattan entre un ensemble de vecteur :[20]

$$distmanhat(\mathbf{P}, \mathbf{Q}) = \sum_{i=1}^n |p_i - q_i| \quad (2.16)$$

où  $\mathbf{P} = (p_1, p_2, \dots, p_n)$  et  $\mathbf{Q} = (q_1, q_2, \dots, q_n)$  sont des vecteurs dans  $R^n$ .

### 2.5.1.3 Distance de Tchebyshev :

La distance de Tchebyshev est une mesure de distance qui est définie comme la plus grande différence absolue entre les coordonnées de deux vecteurs.[62]

Elle est souvent utilisée dans des applications où la distance maximale entre les points est la plus importante.

L'équation de la distance de Tchebyshev entre deux vecteurs, P et Q, représentés par leurs vecteurs de coordonnées respectives  $(p_1, \dots, p_n)$  et  $(q_1, \dots, q_n)$  est donnée par :[20]

$$disttcheb(P, Q) = \max_{i \in [1, n]} (|p_i - q_i|) \quad (2.17)$$

$dist(P, Q)$  : représente la distance de Tchebyshev entre les vecteur P et Q.

$\max$  : symbolise la fonction maximum, qui renvoie la plus grande valeur parmi un ensemble de nombres.

$|p_i - q_i|$  : représentent les différences absolues entre les coordonnées correspondantes deux vecteurs P et Q.

### 2.5.1.4 Distance de Canberra :[21]

en tant que mesure de distance. Cette mesure est une version pondérée de la distance Manhattan et est définie par : L'équation de la distance  $d(P, Q)$  entre deux vecteurs  $p$  et  $q$  dans  $R^n$  est définie comme suit :

$$distcanb(P, Q) = \frac{\sum_{i=1}^n |p_i - q_i|}{\sum_{i=1}^n (|p_i| + |q_i|)} \quad (2.18)$$

où  $P = (p_1, p_2, \dots, p_n)$  et  $Q = (q_1, q_2, \dots, q_n)$  sont des vecteurs dans  $R^n$ .

## 2.5.2 Mesures de similarité :

Les mesures de similarité sont utilisées pour quantifier la similitude entre deux objets ou deux ensembles d'objets. Elles sont souvent utilisées dans les applications de fouille d'images pour trouver des images similaires ou pour classer des images.[62]

Certaines des mesures de similarité les plus courantes sont les suivantes :

### 2.5.2.1 Coefficient de corrélation :

Le coefficient de corrélation est une mesure de similarité qui est définie comme la corrélation entre deux variables. Il est souvent utilisé pour comparer des images qui ont été représentées sous forme de vecteurs de caractéristiques.[62]

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (2.19)$$

où :

- $r$  représente le coefficient de corrélation,
- $x_i$  et  $y_i$  sont les valeurs individuelles des deux variables,
- $\bar{x}$  et  $\bar{y}$  sont les moyennes des valeurs de  $x$  et  $y$  respectivement.
- $n$  est le nombre d'observations.

### 2.5.2.2 Indice de Jaccard :

L'indice de Jaccard est une mesure de similarité qui est définie comme le rapport du nombre d'éléments communs entre deux ensembles au nombre total d'éléments des deux ensembles. Il est souvent utilisé pour comparer des images qui ont été représentées sous forme de listes de mots.[62] La formule est comme suit :[23]

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} \quad [62] \quad (2.20)$$

### 2.5.2.3 Coefficient de Dice :

Le coefficient de Dice est une mesure de similarité qui est définie comme le rapport de la somme des intersections des deux ensembles au produit des cardinalités des deux ensembles. Il est souvent utilisé pour comparer des images qui ont été représentées sous forme de listes de mots.[62]

$$\text{Dice}(A, B) = \frac{2 \times |A \cap B|}{|A| + |B|} [62] \quad (2.21)$$

### 2.5.2.4 Similarité Cosinus :

La mesure du cosinus est une mesure de similarité qui est définie comme le cosinus de l'angle entre deux vecteurs. Elle est souvent utilisée pour comparer des images qui ont été représentées sous forme de vecteurs de caractéristiques.[62]

$$\cos \theta = \frac{A \cdot B}{\|A\| \|B\|} [62] \quad (2.22)$$

où teta est l'angle entre A et B dans l'espace des attributs.

## 2.6 Les taches de l'image mining :

### 2.6.1 La classification de l'image :

La classification d'image mining est une technique de fouille d'images qui consiste à assigner une étiquette à chaque image d'une collection d'images. L'étiquette peut correspondre à une classe d'objets, une catégorie, ou une propriété.

Par exemple, on peut utiliser la classification d'image mining pour identifier les visages de différentes personnes, les types de voitures, ou les maladies d'une plante.[28]

### 2.6.2 clustering d'ensemble d'images :

Le clustering d'ensemble d'images est une technique d'exploration de données d'images qui regroupe les images en différents clusters en fonction de leurs similitudes. Les connais-

sances extraites par cette tâche est justement l'ensembles des clusters ou classes qui sont ici extraites de façon automatique et non supervisée (classes inconnues initialement, contrairement à la classification supervisée où les classes sont déjà existantes).[28]

### **2.6.2.1 Applications du clustering d'ensemble d'images :**

**Aide a la prise de décision médicale basée images :** Pour identifier des groupes de patients avec des caractéristiques radiologiques similaires.[28]

**Robotique et perception :** Pour permettre aux robots de reconnaître et de réagir à différents objets dans leur environnement.[28]

### **2.6.3 Recherche d'images par le contenu :**

Pour regrouper des images similaires et faciliter la recherche. Analyse médicale : Pour identifier des groupes de patients avec des caractéristiques radiologiques similaires.

### **2.6.4 Détection d'anomalies :**

La détection d'anomalies est une tâche de science des données qui consiste à identifier des données qui s'écartent de la norme. Les anomalies peuvent être des erreurs, des fraudes, des intrusions ou d'autres événements indésirables.[28]

Les techniques de détection d'anomalies peuvent être divisées en deux catégories principales : les techniques basées sur les modèles et les techniques basées sur les règles.[28]

Les techniques basées sur les modèles utilisent des modèles mathématiques pour apprendre à identifier les anomalies. Les modèles peuvent être des réseaux neuronaux, des arbres de décision ou des SVM.[28]

Les techniques basées sur les règles utilisent des règles explicites pour identifier les anomalies. Les règles peuvent être basées sur des connaissances expertes ou sur des données historiques.[28]

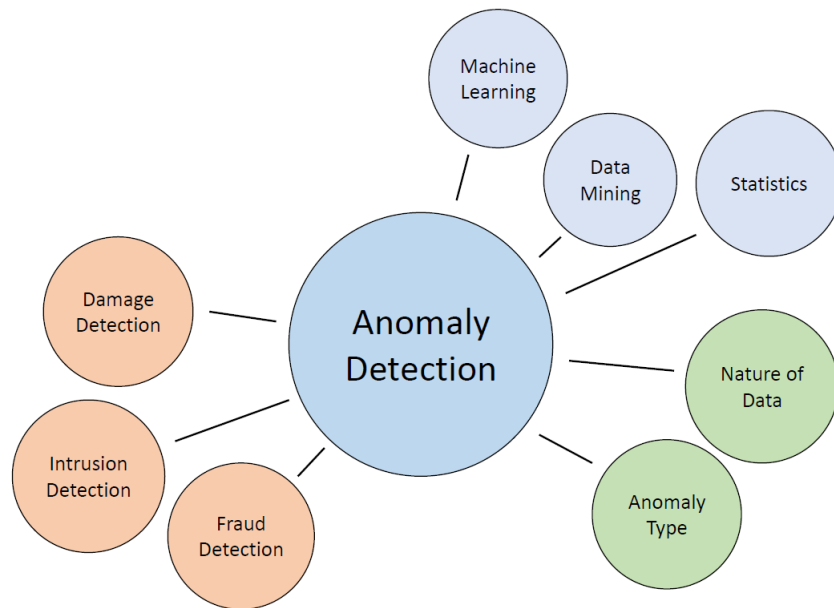


FIGURE 2.10 – Domaine et application de la détection d’anomalie[2]

L’efficacité d’une technique de détection d’anomalies dépend de la qualité des données utilisées, de la nature des anomalies à détecter et du contexte d’application.

### 2.6.5 Recherche de l’image par le contenu visuel :

La recherche d’image est une tâche d’exploration de données d’images qui consiste à rechercher des images qui correspondent à un certain thème ou à une certaine requête. Elle est utilisée dans une variété d’applications, telles que le marketing, la recherche scientifique et l’éducation.

## 2.7 Conclusion

L’exploration de données d’images s’occupe principalement de la classification, du clustering et/ou de l’extraction de connaissances à partir d’images en utilisant des règles d’association et des réseaux neuronaux, entre autres outils. Elle peut être utilisée, par exemple, pour regrouper les images de télédétection, du World Wide Web, de diagnostic médical, pour une récupération efficace d’images, ou pour extraire des informations cachées et significatives des ensembles de données d’images qui ne sont pas explicitement

disponibles à partir des sources d'images.

# Chapitre 3

## La classification de l'image

### 3.1 Introduction

Le Data mining, également appelé "fouille de données", est un domaine qui vise à extraire des informations précieuses à partir de divers sources de données, structurées ou non structurées. Les images constituent une source de données très importante pour divers domaines. Le mining des images est alors aussi important. Particulièrement, la classification d'images joue un rôle crucial dans l'exploitation du contenu et sémantiques de l'image, dans le contexte des outils du mining.

### 3.2 Définition de la classification d'image :

La classification d'images permet d'automatiser l'organisation et l'étiquetage des images en fonction de leur contenu. Cela permet d'extraire des connaissances et des modèles à partir de vastes collections d'images. La classification d'images est une tâche du mining de l'image qui consiste à attribuer une ou plusieurs étiquettes à une image numérique. Ces étiquettes représentent les catégories auxquelles l'image appartiendrait, et ce, en fonction de son contenu visuel. La classification d'images est particulièrement utilisée dans une large gamme d'applications, notamment la reconnaissance d'objets, la détection de visages, l'analyse de scènes et le filtrage de contenu.[43]

Dans ce qui suit, nous présentons les deux types de classification d'images : Supervisée

et non supervisée.

## **3.2.1 Classification supervisée de l'image :**

### **3.2.1.1 Définition :**

La classification d'images supervisée est un processus d'apprentissage automatique dans lequel un modèle de classification est entraîné à l'aide d'un ensemble de données d'images étiquetées. Les images de l'ensemble de données d'apprentissage sont associées à des étiquettes qui indiquent leur catégorie, et le modèle apprend à associer les caractéristiques visuelles des images aux étiquettes correspondantes.

### **3.2.1.2 Fonctionnement :**

Le processus de classification d'images supervisée comprend les étapes suivantes :

**3.2.1.2.1 Collecte d'un ensemble de données d'apprentissage :** Un ensemble de données d'images étiquetées est collecté. Les images de l'ensemble de données doivent être représentatives des images que le modèle devra classifier dans le futur.[43]

**3.2.1.2.2 Extraction de caractéristiques :** Les caractéristiques visuelles sont extraites des images de l'ensemble de données d'apprentissage. Ces caractéristiques représentent les informations pertinentes pour la classification, telles que la couleur, la texture, la forme et les bords.[43]

**3.2.1.2.3 Sélection d'un algorithme de classification :** Un algorithme de classification approprié est sélectionné en fonction de la complexité des données et de la tâche de classification. Parmi les algorithmes de classification courants, on trouve les machines à vecteurs de support (SVM), les réseaux neuronaux convolutifs (CNN) et les forêts aléatoires.[43]

**3.2.1.2.4 Entraînement du modèle :** Le modèle de classification est entraîné à l'aide de l'ensemble de données d'apprentissage. Le modèle apprend à associer les carac-

téristiques extraites aux étiquettes correspondantes.[43]

**3.2.1.2.5 Évaluation du modèle :** Le modèle de classification est évalué sur un ensemble de données de test distinct. L'ensemble de données de test est utilisé pour mesurer la performance du modèle sur des images qu'il n'a jamais vues auparavant.[43]

**3.2.1.3 Avantages :**

- La classification d'images supervisée est généralement plus précise que la classification non supervisée car elle dispose d'informations sur les catégories des images.[43]
- Elle peut être utilisée pour classifier un large éventail d'images, notamment des images complexes avec plusieurs objets.[43]

**3.2.1.4 Inconvénients :**

- La classification d'images supervisée nécessite un ensemble de données d'apprentissage étiqueté, ce qui peut être coûteux et chronophage à collecter.[43]
- Le modèle de classification peut être biaisé si l'ensemble de données d'apprentissage n'est pas représentatif des images qu'il devra classifier dans le futur. [43]

**3.2.2 Classification non supervisée de l'image :**

**3.2.2.1 Définition :**

La classification d'images non supervisée est un processus d'apprentissage automatique dans lequel un modèle de classification est entraîné à l'aide d'un ensemble de données d'images non étiquetées. Les images de l'ensemble de données d'apprentissage n'ont pas d'étiquettes qui indiquent leurs catégories, et le modèle apprend à identifier des groupes d'images similaires sans aucune information de supervision.

**3.2.2.2 Fonctionnement :**

Le processus de classification d'images non supervisée comprend les étapes suivantes :

**3.2.2.2.1 Collecte d'un ensemble de données non étiqueté :** Un ensemble de données d'images non étiquetées est collecté. Les images de l'ensemble de données doivent être représentatives des images que le modèle devra classifier dans le futur.[37]

**3.2.2.2.2 Extraction de caractéristiques :** Les caractéristiques visuelles sont extraites des images de l'ensemble de données non étiqueté. Ces caractéristiques représentent les informations pertinentes pour la classification, telles que la couleur, la texture, la forme et les bords.[37]

**3.2.2.2.3 Sélection d'un algorithme de clustering :** Un algorithme de clustering approprié est sélectionné en fonction de la complexité des données et de la tâche de classification. Parmi les algorithmes de clustering courants, citons le k-means, le clustering hiérarchique et le clustering par mélange de gaussiennes.[37]

**3.2.2.2.4 Apprentissage du modèle :** Le modèle de clustering est appliqué à l'ensemble de données non étiqueté pour identifier des groupes d'images similaires. Le modèle apprend à regrouper les images en fonction de leurs caractéristiques visuelles sans aucune information de supervision.[37]

**3.2.2.2.5 Évaluation du modèle :** Le modèle de clustering est évalué sur un ensemble de données de test distinct. L'ensemble de données de test est utilisé pour mesurer la qualité des clusters identifiés par le modèle.[37]

### **3.2.2.3 Applications :**

La classification d'images non supervisée est utilisée dans une variété d'applications, notamment :

**3.2.2.3.1 Détection d'anomalies :** Identification d'images qui ne correspondent pas aux autres images du dataset, ce qui peut être utile pour la détection de fraude ou de défauts.[37]

Découverte de motifs : Identification de motifs ou de structures récurrents dans les images, ce qui peut être utile pour l'analyse de scènes ou la segmentation d'images.[37]

**3.2.2.3.2 Organisation d'images :** Organisation d'images non étiquetées en groupes thématiques ou visuellement similaires.[37]

**3.2.2.3.3 Recommandation d'images :** Recommandation d'images similaires à une image donnée, ce qui peut être utile pour les moteurs de recherche d'images ou les plateformes de médias sociaux.[37]

**3.2.2.4 Avantages de ce genre de classification :**

- Ne nécessite pas d'ensemble de données d'apprentissage étiqueté : Ce qui peut être un avantage important si l'étiquetage des images est coûteux ou chronophage.[37]
- Peut découvrir des structures ou des motifs inconnus : Ce qui peut être utile pour l'exploration de données ou la découverte de nouvelles connaissances.[37]

**3.2.2.5 Inconvénients de ce genre de classification :**

- Les résultats peuvent être difficiles à interpréter : Car il n'y a pas d'étiquettes pour les groupes d'images identifiés. [37]
- Performance peut être moins précise que la classification supervisée : Surtout pour les tâches complexes avec de nombreuses classes. [37]

**3.2.3 Processus de classification de l'images :**

Le processus de classification d'images comprend généralement les étapes suivantes :

**3.2.3.1 Acquisition d'images :**

Les images numériques peuvent être acquises à partir de diverses sources, telles que des caméras, des scanners ou des bases de données en ligne.[43]

### **3.2.3.2 Prétraitement d'image :**

Les images peuvent être prétraitées pour améliorer leur qualité et faciliter la classification. Cela peut inclure des opérations telles que le redimensionnement, le rognage, la normalisation et la correction de l'éclairage.[43]

### **3.2.3.3 Extraction de caractéristiques :**

Les caractéristiques visuelles sont extraites des images prétraitées. Ces caractéristiques représentent les informations pertinentes pour la classification, telles que la couleur, la texture, la forme et les bords.[43]

### **3.2.3.4 Apprentissage du modèle :**

Un modèle de classification est entraîné à l'aide d'un ensemble de données d'images étiquetées. Le modèle apprend à associer les caractéristiques extraites aux étiquettes correspondantes.[43]

### **3.2.3.5 Classification des nouvelles images (données de teste) :**

Les nouvelles images sont classées en utilisant le modèle de classification appris. Les caractéristiques visuelles des nouvelles images sont extraites et comparées aux caractéristiques des images d'apprentissage. Le modèle attribue ensuite aux nouvelles images les étiquettes les plus probables.[43]

## **3.3 Exemples de classifieurs :**

Le domaine de l'apprentissage automatique offre une multitude d'algorithmes puissants pour la classification, tâche fondamentale qui consiste à assigner des étiquettes ou des catégories à des points de données.

Parmi ces algorithmes, certains se distinguent par leur efficacité et leur polyvalence, permettant de traiter une large gamme de problèmes de classification avec des perfor-

mances remarquables.

Ce document s'engage à vous fournir une analyse approfondie de quatre algorithmes de classification de premier plan : les réseaux de neurones artificiels (RNA), les arbres de décision, les machines à vecteurs de support (SVM) et les classifieurs naïfs bayésiens (NB). De plus, nous explorerons l'algorithme K plus proche voisin (KNN), une méthode de classification par similarité.[51]

### **3.3.1 RNA (réseaux de neurones artificiels) :**

#### **3.3.1.1 Définition :**

Les réseaux de neurones artificiels (RNA) sont des systèmes informatiques inspirés du cerveau humain. Ils sont composés d'un grand nombre de neurones artificiels interconnectés, qui sont capables d'apprendre et de traiter des informations. Les RNA sont utilisés dans une large variété d'applications, notamment la reconnaissance d'images, le traitement du langage naturel et la prise de décision automatique.[51]

#### **3.3.1.2 Structure d'un RNA :**

Un RNA est composé de trois couches principales :

*La couche d'entrée :* Cette couche reçoit les données d'entrée.

*La couche cachée :* Cette couche est composée de neurones artificiels qui traitent les données d'entrée.

*La couche de sortie :* Cette couche produit les données de sortie.

Les neurones artificiels sont connectés entre eux par des synapses. Chaque synapse a un poids qui détermine la force de la connexion entre les neurones.[51]




FIGURE 3.1 – Figure illustrative d’une structure d’un RNA[67]

### 3.3.1.3 Fonctionnement d’un RNA :

Les RNA fonctionnent en apprenant des données. Les données d’apprentissage sont présentées au RNA, et les poids des synapses sont ajustés pour minimiser l’erreur entre les données de sortie du RNA et les données de sortie souhaitées. Ce processus est appelé apprentissage par rétropropagation.[51]

### 3.3.1.4 Types de RNA :

Il existe différents types de RNA, notamment :

**3.3.1.4.1 Les réseaux de neurones perceptron multicouche (MLP) :** Ce sont les RNA les plus simples. Ils sont composés d’une couche d’entrée, d’une ou plusieurs couches cachées et d’une couche de sortie.[51]




FIGURE 3.2 – Figure illustrative d’un MLP[10]

**3.3.1.4.2 Les réseaux de neurones convolutifs (CNN) :** Ces RNA sont utilisés pour la reconnaissance d’images. Ils sont composés de couches convolutives et de couches de pooling.[51]

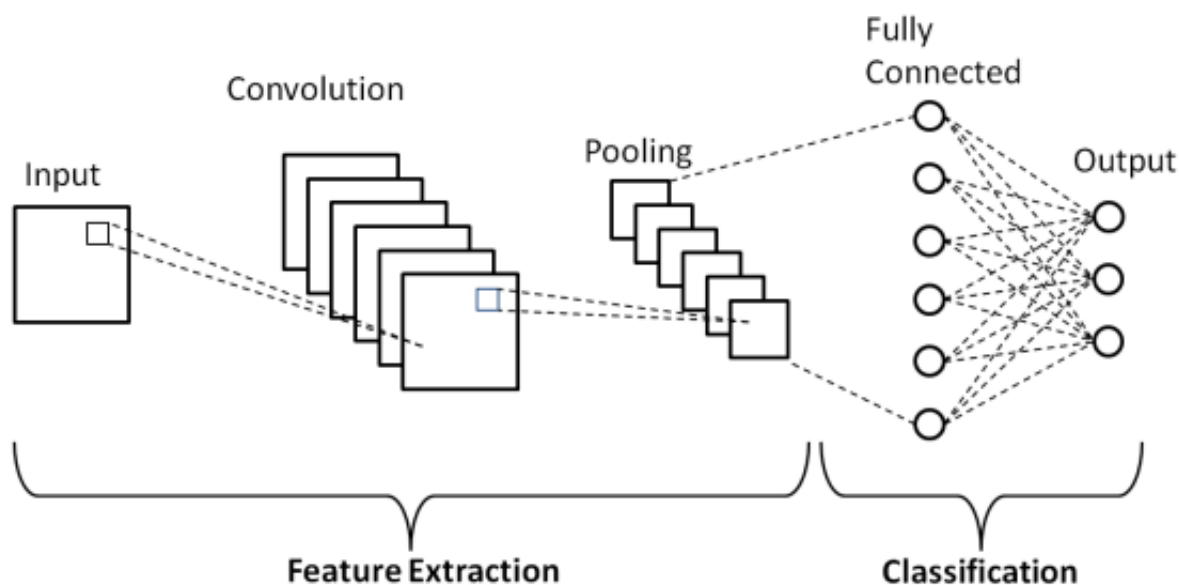


FIGURE 3.3 – Figure illustrative des réseaux de neurones convolutifs (CNN)[59]

**Couches convolutives :** Les couches convolutives (représentées par les cubes) appliquent des opérations de convolution aux entrées. Les opérations de convolution permettent d’extraire des caractéristiques spatiales des données d’entrée.[17]

**Couches de pooling :** Les couches de pooling (représentées par les flèches vers le

bas) réduisent la dimensionnalité des données. Cela permet de réduire le nombre de paramètres du réseau et d'éviter le sur ajustement.[17]

**Couches entièrement connectées :** Les couches entièrement connectées (représentées par les rectangles) relient tous les neurones d'une couche à tous les neurones de la couche suivante. Ces couches permettent d'apprendre des relations complexes entre les caractéristiques extraites par les couches convolutives et de pooling.[17]

**3.3.1.4.3 Les réseaux de neurones récurrents (RNN) :** Ces RNA sont utilisés pour le traitement du langage naturel. Ils sont capables de traiter des séquences de données, telles que des phrases.[51]




FIGURE 3.4 – Figure illustrative des réseaux de neurones récurrents (RNN)[36]

### 3.3.1.5 Avantages des RNA :

Les RNA présentent plusieurs avantages, notamment :

- Ils sont capables d'apprendre des données complexes.
- Ils sont robustes au bruit et aux erreurs.
- Ils peuvent être utilisés pour résoudre une grande variété de problèmes.[51]

### 3.3.1.6 Inconvénients des RNA :

Les RNA présentent également quelques inconvénients, notamment :

- Ils peuvent être difficiles à apprendre.[51]
- Ils peuvent être sujets au sur-apprentissage.[51]
- Ils peuvent être difficiles à interpréter.[51]

Les RNA sont des outils puissants qui peuvent être utilisés pour résoudre une grande variété de problèmes. Ils sont encore en développement, mais ils ont déjà eu un impact significatif sur de nombreux domaines.

### 3.3.2 Arbres de décision :

#### 3.3.2.1 Définition :

Dans le contexte du data mining d'images, un arbre de décision est une structure arborescente qui permet de classer des images en fonction de leurs caractéristiques visuelles. Chaque nœud de l'arbre représente une question sur une caractéristique de l'image, et chaque branche représente une réponse possible. La feuille finale de chaque branche représente une classe d'image.[61]

#### 3.3.2.2 Fonctionnement :

Les arbres de décision pour la classification d'images sont construits à partir d'un ensemble d'images d'apprentissage étiquetées. L'algorithme d'apprentissage sélectionne récursivement la meilleure caractéristique visuelle à utiliser pour diviser les données en fonction de sa capacité à discriminer les différentes classes d'images.[61]

La figure 3.5 représente un arbre de décision simple utilisé pour diagnostiquer des problèmes médicaux courants en fonction des symptômes présentés par le patient. Il fonctionne en posant une série de questions et en dirigeant le patient vers une branche ou une autre de l'arbre en fonction de ses réponses. L'objectif final est d'arriver à un diagnostic ou à une recommandation de traitement.

**Explication de la figure :** Supposons qu'un patient ait les symptômes suivant : aucune douleur, une toux, et une fièvre. Cet arbre de décision procédera comme suit :

- Avez-vous une douleur ?

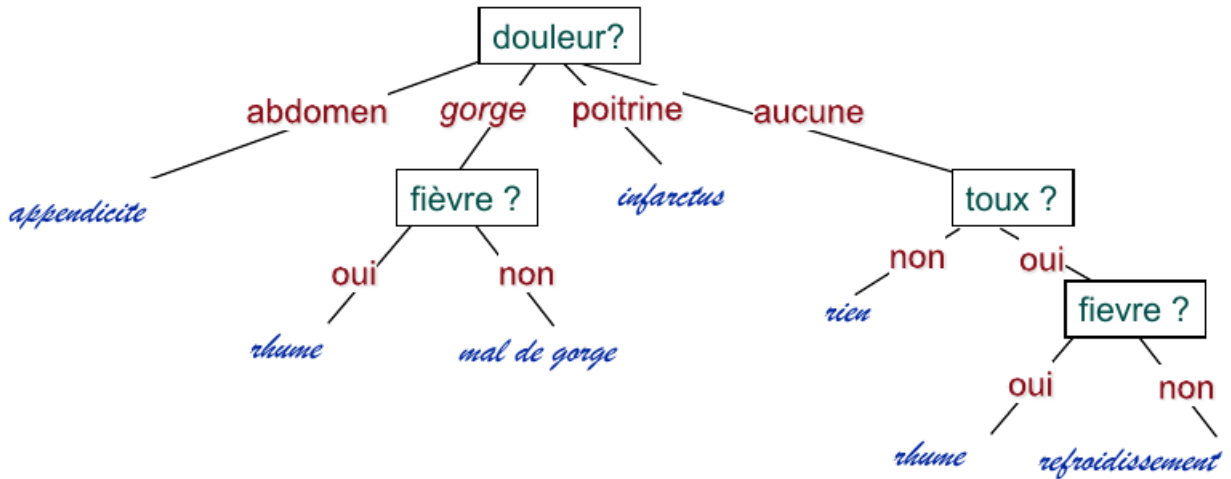


FIGURE 3.5 – Figure illustrative d’un exemple d’arbres de décision[3]

- non
- Avez-vous une toux ?
- oui
- Avez-vous une fièvre ?
- oui
- Vous-avez donc a un rhume

Il est important de noter que :

- Un médecin devra toujours tenir compte des antécédents médicaux du patient, d’autres symptômes et d’un examen physique pour établir un diagnostic précis.
- Les arbres de décision ne sont pas toujours précis et il est important de consulter un médecin pour obtenir un diagnostic définitif.

### 3.3.2.3 Application :

Les arbres de décision sont populaires pour leur simplicité, leur interprétabilité et leur robustesse au bruit. Ils sont utilisés dans une variété d’applications de classification d’images, notamment la reconnaissance d’objets, la détection de défauts et l’analyse de texture.[61]

### 3.3.3 Les SVM :

#### 3.3.3.1 Définition :

Les SVM *Support Vector Machines* Les SVM Support Vector Machines sont des algorithmes d'apprentissage automatique supervisé utilisés , entre autres, pour la classification d'images. Ils sont basés sur l'idée de trouver un hyperplan qui sépare au mieux les images appartenant à différentes classes dans un espace de caractéristiques visuelles.[25]

#### 3.3.3.2 Fonctionnement :

Les SVM sont particulièrement efficaces pour traiter les données d'images non linéaires en utilisant un noyau, qui permet de transformer les caractéristiques visuelles des images dans un espace de dimension supérieure où la séparation linéaire devient possible.[25]




FIGURE 3.6 – Figure illustrative d'un support-vector-machine(SVM) [4]

#### 3.3.3.3 Application :

Les SVM sont couramment utilisés dans une variété d'applications de classification d'images, notamment la reconnaissance de visages, la classification de scènes et la détection d'anomalies.[25]

### 3.3.4 Classifieur Bayes naïf :

#### 3.3.4.1 Définition :

Un classifieur Bayes est un algorithme d'apprentissage automatique probabiliste utilisé pour la classification de données. Il est basé sur le théorème de Bayes, qui permet de calculer la probabilité d'appartenance d'une image à une classe d'image donnée en se basant sur ses caractéristiques visuelles.[30]

#### 3.3.4.2 Fonctionnement :

Le classifieur Bayes suppose que les caractéristiques visuelles d'une image sont indépendantes les unes des autres, ce qui n'est pas toujours le cas dans la réalité. Cependant, il s'agit d'une hypothèse simple qui permet d'obtenir de bons résultats dans de nombreux cas de classification d'images.[30]

$$P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)} \quad (3.1)$$

#### 3.3.4.3 Application :

Les classifieurs Bayes sont populaires pour leur simplicité, leur efficacité et leur robustesse au bruit. Ils sont utilisés dans une variété d'applications de classification d'images, notamment la reconnaissance de textures, la segmentation d'images et le filtrage du spam d'images.[30]

### 3.3.5 KNN : K Nearest Neighbors :

#### 3.3.5.1 Définition :

KNN (K Nearest Neighbors) est un algorithme d'apprentissage automatique supervisé utilisé, notamment, pour la classification d'images. Il classe une nouvelle image en fonction de la classe des K images les plus proches (en termes de similarité visuelle) dans l'ensemble de données d'apprentissage. [26]

### **3.3.5.2 Fonctionnement :**

L'algorithme KNN pour la classification d'images calcule la distance entre les caractéristiques visuelles de la nouvelle image et celles de chaque image de l'ensemble de données d'apprentissage. Ensuite, il classe la nouvelle image en fonction de la classe ayant le maximum de voix, selon un vote majoritaire, parmi les k images les plus proches.[26]

### **3.3.5.3 Application :**

KNN est populaire pour sa simplicité et son efficacité. Il est utilisé dans une variété d'applications de classification d'images, notamment la reconnaissance d'objets, la classification de textures et la recommandation d'images.[26]

## **3.4 Les techniques avancées de la classification de l'image :**

### **3.4.1 Combinaison de classifieurs :**

#### **3.4.1.1 Définition :**

La combinaison de classifieurs est une stratégie qui consiste à combiner les prédictions de plusieurs classifieurs individuels afin d'obtenir une prédiction plus précise et robuste. Cette approche est particulièrement utile lorsque les classifieurs individuels ont des forces et des faiblesses différentes.[14]

La combinaison de classifieurs, également connue sous le nom d'apprentissage par ensemble, regroupe plusieurs modèles de classification indépendants pour générer une prédiction collective plus robuste et précise. Cette approche exploite la diversité des modèles pour réduire la variance et améliorer la généralisation.[16]

#### **3.4.1.2 Avantages de la combinaison de classifieur :**

**3.4.1.2.1 Amélioration de la précision :** En combinant les prédictions de plusieurs classifieurs, il est possible de réduire l'erreur globale et d'obtenir des prédictions plus précises.[14]

**3.4.1.2.2 Robuste à l'erreur :** Si un des classifieurs individuels commet une erreur, les autres classifieurs peuvent compenser et fournir une prédiction correcte.[14]

**3.4.1.2.3 Réduction du sur-apprentissage :** La combinaison de classifieurs peut aider à réduire le sur-apprentissage, qui se produit lorsque le classifieur s'adapte trop aux données d'apprentissage et ne parvient pas à bien généraliser aux nouvelles données.[14]

## 3.4.2 Le Bagging et le boosting :

### 3.4.2.1 Le Bagging :

**3.4.2.1.1 Définition :** Le Bagging (Bootstrap Aggregation) est une technique d'apprentissage par ensemble qui consiste à entraîner plusieurs modèles de classification sur des sous-ensembles aléatoires du jeu de données, avec remise des données. Chaque sous-ensemble est généré en tirant aléatoirement des exemples du jeu de données original, avec possibilité de dupliquer certains exemples. Les modèles ainsi entraînés sont ensuite combinés pour générer une prédiction finale.[16]

#### 3.4.2.1.2 Avantages du Bagging :

- Réduction de la variance des modèles individuels.[16]
- Amélioration de la robustesse aux erreurs de données.[16]
- Meilleure généralisation à de nouvelles données.[16]

**3.4.2.1.3 Exemple d'application :** Classification d'images de documents manuscrits avec une combinaison de classificateurs à base de SVM.[16]

### 3.4.2.2 Le Boosting :

#### 3.4.2.2.1 Définition :

Le boosting est une autre technique d'apprentissage par ensemble qui consiste à construire une séquence de classifieurs en se concentrant sur les exemples que les classifieurs précédents ont mal classés. Les prédictions finales sont ensuite combinées par une pondération

des prédictions de chaque classifieur. Le boosting est particulièrement efficace pour améliorer la précision des classifieurs.[14]

#### **3.4.2.2.2 Types de Boosting :**

##### **3.4.2.2.2.1 AdaBoost :**

Utilise une fonction de pondération exponentielle pour ajuster les poids des exemples.[16]

##### **3.4.2.2.2.2 Gradient Boosting :**

Utilise des arbres de décision peu profonds comme modèles de base et ajuste les poids en fonction des gradients de l'erreur de prédiction.[16]

#### **3.4.2.2.3 Avantages du Boosting :**

- Réduction de la variance et du biais des modèles individuels.[16]
- Amélioration de la précision et de la robustesse.[16]
- Meilleure capacité de généralisation à de nouvelles données.[16]

**3.4.2.2.4 Exemple d'application :** Détection d'anomalies dans des images médicales avec une combinaison de classificateurs à base de CNNs.[16]

### **3.4.3 Le deep Learning (CNN)**

Ce point a été présenté précédemment dans le titre "Les réseaux de neurones convolutifs (CNN)" :

#### **3.4.3.1 Avantages des CNN :**

- Apprentissage automatique de caractéristiques à partir des données.
- Robustesse aux variations de luminosité, de perspective et de distorsion.
- Capacité à traiter des images de grande taille et de haute résolution.

### 3.4.3.2 Exemples d'application :

1. Reconnaissance d'objets dans des images naturelles avec des CNNs pré-entraînés (e.g., ResNet, VGGNet).[16]
2. Segmentation d'images : Les CNN sont utilisés pour segmenter des images en différentes régions, telles que le premier plan et l'arrière-plan.[33]
3. Détection d'anomalies : Les CNN sont utilisés pour détecter des anomalies dans les images, telles que des tumeurs dans des images médicales.[33]

## 3.5 Conclusion

La classification d'image est un domaine crucial de la fouille d'images qui permet d'automatiser l'analyse et la catégorisation d'images numériques. Elle trouve des applications dans de nombreux domaines, tels que la reconnaissance d'objets, l'analyse médicale, la robotique et la vision par ordinateur.

Les méthodes de classification d'image se divisent en deux grandes catégories : supervisée et non supervisée. La classification supervisée utilise des données étiquetées pour apprendre à associer des images à des classes prédéfinies, tandis que la classification non supervisée découvre automatiquement des groupes d'images partageant des caractéristiques similaires.

De nombreux algorithmes de classification d'image existent, chacun avec ses propres avantages et inconvénients. Les algorithmes populaires incluent les réseaux neuronaux artificiels (RNA), les arbres de décision, les machines à vecteurs de support (SVM), les classifieurs bayésiens et le K-nearest neighbors (KNN).

Les techniques avancées de classification d'image combinent plusieurs algorithmes ou utilisent des approches plus sophistiquées pour améliorer les performances. Le bagging et le boosting sont des exemples de techniques d'apprentissage par ensemble qui combinent

plusieurs classifieurs faibles pour obtenir un classifieur plus performant. Le deep learning, en particulier les réseaux neuronaux convolutifs (CNN), a révolutionné la classification d'image en apprenant automatiquement des représentations hiérarchiques des images à partir de données brutes.

La classification d'image est un domaine en constante évolution avec de nouvelles recherches et de nouveaux développements. L'amélioration des algorithmes, l'augmentation de la disponibilité des données et l'utilisation de puissances de calcul croissantes permettent d'obtenir des résultats de plus en plus précis et performants.

# Chapitre 4

## Une étude comparative de plusieurs classifieurs d'images : Algorithmes, Datasets, Distances :

### 4.1 Introduction

L'objectif de ce chapitre est de présenter une étude comparative de plusieurs méthodes de classification de l'image, dans le cadre du Mining. Les méthodes utilisées prennent en compte les espaces de couleur (RGB, LAB, HSV), les attributs (histogrammes pour la couleur, LBP : Local Binary Pattern, pour la texture), les distances et mesures de similarité (Euclidienne, Canberra). Ces éléments, dits *handcrafted features*, sont intégrés dans un classifieur simple, mais efficace : KNN (K-Nearest Neighbours). L'étude considère aussi l'utilisation d'un classifieur de type CNN (Convolutional Neural Networks, Deep Learning). Ces classifieurs, eux, exploitent ce qui est dit *Deep-Features* ou *Implicite Features*, dans le sens où, ce sont les CNNs eux-mêmes qui extraient les features de façon opaque à l'utilisateur. Le CNN choisi, à titre d'expérimentation et de comparaison, est le TensorFlow de Google. L'étude comprend alors pas moins de 15 classifieurs 5NN d'un 1NN, en plus du classifieur CNN : TensorFlow.

Pour les données, nous avons utilisé une BDD d'image, universellement connue : La base

Corel1000 (dite : Wang, du nom de son initiateur ou encore, Corel1K). Nous détaillons, d'abord, l'environnement de programmation utilisé, puis, la description des expérimentations effectuées.

## **4.2 Les outils et langages utilisés :**

### **4.2.1 Ordinateurs :**

Dans ce projet nous avons utilisé deux types de micro-ordinateur :

- Dell Latitude Core i7 version pro 8ème génération.
- Acer Aspire A315-51 i3 7ème génération.

### **4.2.2 Le langage de programmation utilisé : Python**

Le python est un langage de programmation créé par Guido van Rossum, un langage parmi plusieurs, connu pour être puissant, élégant et facile à apprendre, un langage très moderne et très utilisé de nos jours [60]. Ce langage est un langage de très haut niveau, dynamique et orienté objet, il est utilisé dans l'analyse, la conception, le prototypage, le codage, les tests, le débogage, l'optimisation, la documentation, déploiement et bien sûr la maintenance.[57]

### **4.2.3 Le langage Latex :**

Nous avons utilisé Latex pour la création de ce mémoire. Le latex est un langage de documentation et une surcouche d'un formateur de texte appelé TEX[12], les documents obtenue seront de haute qualité typographique. Ce langage aide l'utilisateur à ne plus se focaliser sur les tâches de mises en pages et de construction.[27]

## 4.2.4 Application utilisé pour le codage :

Afin de pouvoir utiliser le python, nous avons utilisé un éditeur de code extensible développé par Microsoft pour Windows [24] nommé visual studio code, où nous avons installé toutes les extensions nécessaires pour exécuter nos algorithmes.

## 4.2.5 DataSet D'images utilisée :

### 4.2.5.0.1 Corel 1K :

Comme mentionné, nous avons utilisé la base d'images universelle Corel1000 ou autrement appelée Base de Wang. Cette base de données contient 1000 images. Cette base de données contient 10 classes : plages, bus, dinosaures, éléphants, fleurs, nourriture, chevaux, monuments, montagnes et neige, peuple et villages d'Afrique.

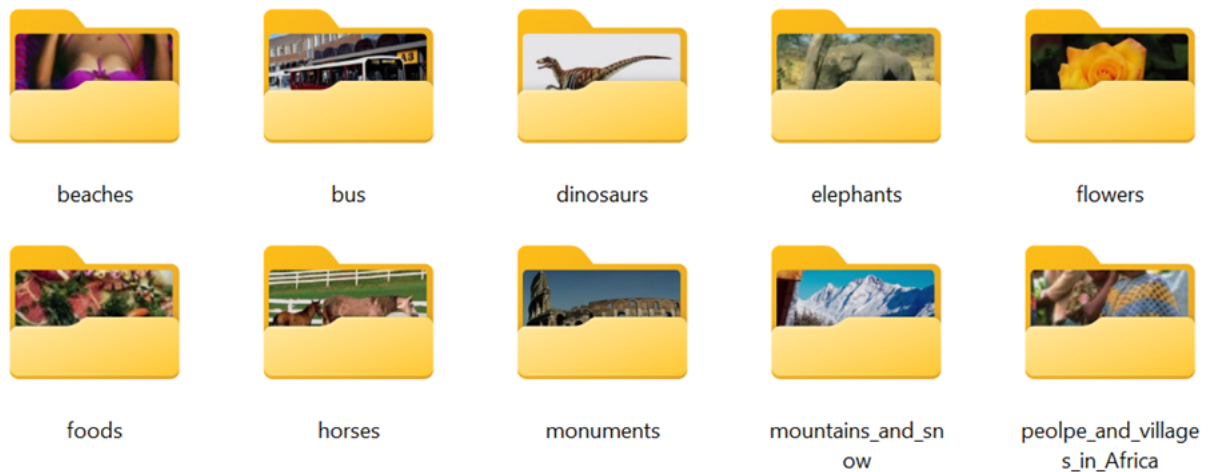


FIGURE 4.1 – La base Corel 1K

#### 4.2.5.0.2 KIMIA path 960 :

Comme mentionné, nous avons utilisé la base d'images en pathologie numérique nommée KIMIA path 960. Cette base de données contient 960 images distribuées sur 20 classes. Elle est une collection d'images histopathologiques de plus de 400 WSI des images de tissus musculaires, épithéliaux et conjonctifs, etc. [44] Utiliser dans la médecine afin de détecter certaines maladie, tel que le Cancer.

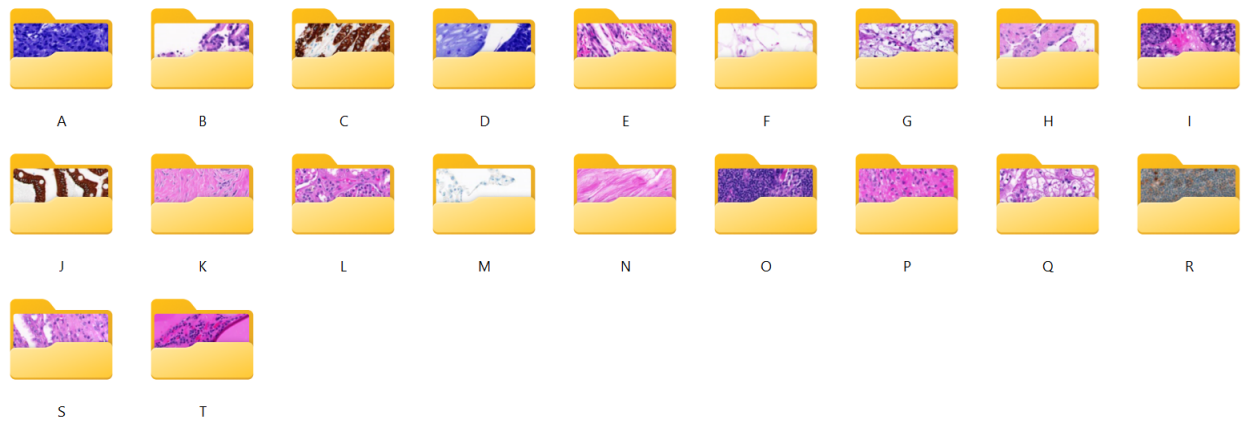


FIGURE 4.2 – La base Kimia path 960

**4.2.5.0.3 Organisation des bases :** Nous alors utilisé pratiquement cette base selon plusieurs arrangement, pour mieux l'exploiter et enrichir ainsi notre étude,

Nous avons utilisé la base de données telle qu'elle est, nous avons décidé de changer

Arrangement	Dataset entrainement	Dataset Tests
Telle quelle	100	900
Inversée	900	100
Half	500	500
Rouge	100 ou 500 ou 900	900 ou 500 ou 100
Vert	100 ou 500 ou 900	900 ou 500 ou 100
Bleu	100 ou 500 ou 900	900 ou 500 ou 100

FIGURE 4.3 – Tableau d'arrangement des bases

le nombre d'image ainsi que les couleurs utilisé dans l'entrainement et le teste afin d'enrichir le travail. Nous avons donc obtenue 6 autres bases de données.

#### **4.2.5.0.3.1 DatasetRouge :**

Dans cette base nous travaillons sur l'axe rouge, en ignorant les autres axes. Nous obtiendrons donc une base avec une nuance de rouge(Fig. 4.3 et Fig 4.4)

Corel 1K :



FIGURE 4.4 – DatasetRouge

Kimia Path960 :



FIGURE 4.5 – DatasetRouge

#### 4.2.5.0.3.2 DatasetVert :

Dans cette base nous avons travaillons sur l'axe Vert, en ignorant les autres axes. Nous obtiendrons donc une base avec une nuance de Vert (Fig. 4.5 et Fig 4,6).

Corel 1K :



FIGURE 4.6 – DatasetVert

Kimia path960 :




FIGURE 4.7 – DatasetVert

#### 4.2.5.0.3.3 DatasetBleu :

Dans cette base nous avons travaillons sur l'axe Bleu, en ignorant les autres axes. Nous obtiendrons donc une base avec une nuance de Bleu (Fig. 4.7 et Fig 4.8).

Corel 1K :



FIGURE 4.8 – DatasetBleu

Kimia path960 :




FIGURE 4.9 – DatasetBleu

#### 4.2.5.0.3.4 DatasetMini :

Dans cette organisation de base de données nous avons inversé les contenus de la base

de données. En d'autres termes, nous avons inversé le contenu de la base d'entraînement et la base de tests. Nous avons donc obtenue 10% des images pour le test et 90% pour l'entraînement. Nous avons appliqué cela également dans la base DatasetRouge, DatasetBleu et DatasetVert.

#### 4.2.5.0.3.5 DatasetHalf :

Dans cette organisation de base de données nous avons divisé le contenu de la base d'entraînement et la base de tests d'une manière équivalente, 50% pour les tests et 50% pour l'entraînement. Nous avons appliqué cela également dans la base DatasetRouge, DatasetBleu et DatasetVert.

## 4.2.6 Bibliothèques et méthodes utilisées :

Dans toute notre application, nous importons les bibliothèques suivantes :

```
import numpy as np
import cv2 as cv
import os
from sklearn.neighbors import KNeighborsClassifier
from sklearn.model_selection import train_test_split
from sklearn.metrics import accuracy_score
```

FIGURE 4.10 – Bibliothèque utilisé

- **Numpy** : propose des fonctions mathématiques complètes, des générateurs de nombres aléatoires, des routines d'algèbre linéaire, etc.[7]
- **Cv2** : OpenCV une bibliothèque de liaisons Python conçue pour résoudre les problèmes de vision par ordinateur[8].
- **Os** : Il est intégré avec des méthodes d'interaction avec le système d'exploitation, telles que la création de fichiers et de répertoires, la gestion des fichiers et des répertoires, les entrées, les sorties, les variables d'environnement, la gestion des processus, etc. [35]

Les 3 dernières lignes sont importées pour pouvoir utiliser le KNN et calculer l'accuracy, autrement dit, la précision des différents classifieurs.

## 4.2.7 Méthodes utilisées et comparaison :

### 4.2.7.1 Méthodes utilisées :

Dans ce projet nous avons utilisé en premier lieu 16 différentes méthodes, afin d'effectuer une étude comparative des résultats obtenus. Toutes les méthodes utilisées sont intégrées dans le classifieur KNN,  $K=5$ .

1. LBP Rouge : nous avons utilisé la méthode LBP (Local Binary Pattern, un attribut efficace de texture) sur les bases DatasetRouge, DatasetRouge Half et DatasetRouge Mini.
2. LBP Bleu : nous avons utilisé la méthode LBP sur les bases DatasetBleu, DatasetBleu Half et DatasetBleu Mini.
3. LBP Vert : nous avons utilisé la méthode LBP sur les bases DatasetVert, DatasetVert Half et DatasetVert Mini.
4. LBP : nous avons utilisé la méthode LBP sur les bases Dataset, Dataset Half et Dataset Mini.
5. LAB L : nous avons utilisé l'espace de couleurs LAB, en prenant en compte seulement l'axe L, sur les bases Dataset, DatasetHalf et DatasetMini.
6. LAB A : nous avons utilisé l'espace de couleurs LAB en prenant en compte seulement l'axe A, sur les bases Dataset, DatasetHalf et DatasetMini.
7. LAB B : nous avons utilisé l'espace de couleurs LAB, en prenant en compte seulement l'axe B, sur les bases Dataset, DatasetHalf et DatasetMini.
8. LAB : nous avons utilisé l'espace de couleurs LAB, en prenant en compte les 3 axes, sur les bases Dataset, DatasetHalf et DatasetMini.
9. HSV H : nous avons utilisé l'espace de couleurs HSV, en prenant en compte seulement l'axe H, sur les bases Dataset, DatasetHalf et DatasetMini.
10. HSV S : nous avons utilisé l'espace de couleurs HSV, en prenant en compte seulement l'axe S, sur les bases Dataset, DatasetHalf et DatasetMini.
11. HSV V : nous avons utilisé l'espace de couleurs HSV, en prenant en compte seulement l'axe V, sur les bases Dataset, DatasetHalf et DatasetMini.

12. HSV : nous avons utilisé l'espace de couleurs HSV, en prenant en compte les 3 axes, sur les bases Dataset, DatasetHalf et DatasetMini.
13. HistogrammeBleu : nous avons utilisé l'attribut Histogramme de couleurs, en prenant en compte seulement l'axe Bleu, sur les bases Dataset, DatasetHalf et DatasetMini.
14. HistogrammeRouge : nous avons utilisé l'attribut Histogramme de couleurs, en prenant en compte seulement l'axe Rouge, sur les bases Dataset, DatasetHalf et DatasetMini.
15. HistogrammeVert : nous avons utilisé l'attribut Histogramme de couleurs, en prenant en compte seulement l'axe Vert, sur les bases Dataset, DatasetHalf et DatasetMini.
16. HistogrammeRGB : nous avons utilisé la méthode Histogramme de couleurs, en prenant en compte les 3 axes de couleurs : Vert, Rouge et Bleu, sur les bases Dataset, DatasetHalf et DatasetMini.

Nous avons également utilisé une autre méthode, en utilisant le KNN avec un  $K=1$ , cette méthode se base sur **les couleurs dominantes**.

Nous commençons par créer un dictionnaire de couleur contenant les 50 couleurs dominantes de toute la base. Etant donné que nous avons 10 classes, nous avons supposé que pour chaque classe on obtiendra 10 couleurs dominantes, évidemment cela peut ne pas être le cas. Ces couleurs sont extraites des couleurs originelles de la base comme suit :

1. Initialiser le dictionnaire  $\text{Dict}(\text{Couleur}_i, \text{fréquence}_i)$  à vide.  
 $\text{NbCouleur} \leftarrow 0$ .
2. Insérer la couleur du premier pixel de la première ligne, première colonne dans la première position de Dict avec une fréquence 1.  
 $\text{NbCouleur} \leftarrow \text{NbCouleur} + 1$ .
3. Pour toutes les images, pour toutes les lignes, pour toutes les colonnes :
  - Si la couleur du pixel courant est présente dans Dict, mettre à jour sa fréquence.
  - Sinon, insérer la couleur dans la position  $\text{NbCouleur} + 1$ .

4. Trier le dictionnaire Dict sur la fréquence, en descendant.
5. Couper le dictionnaire trié à la position 50 : Les 50 couleurs dominantes étant celles avec les plus grandes fréquences.
6. Les couleurs au-delà de 50 sont alors remplacées (mise à jour de la fréquence) par la couleur la plus proche à chacune selon une distance (par exemple, euclidienne) dans l'espace RGB.

Nous avons aussi utiliser une autre méthode qui est : Les couleurs dominantes.

Cette méthode consiste à créer un dictionnaire de couleurs commun pour la base Corel1k tel que montré dans la Figure 4.10.



FIGURE 4.11 – Le dictionnaire des 50 couleurs dominantes extraites de la base Corel1k

Nous avons également varié les mesures de distances et les mesures de similarité. Nous avons, ainsi, utilisé :

1. La distance Euclidienne : Comme déjà mentionné dans le chapitre 2 formule 15.
2. La distance de Manhattan : Comme déjà mentionné dans le chapitre 2 formule 16.
3. La mesure Canberra : Comme déjà mentionné dans le chapitre 2 formule 18.
4. DTW (Dynamic Time Warping) :C'est une méthode utilisée pour déterminer le meilleur appariement entre deux séries temporelles ou signaux. Elle est intégrée dans l'espoir d'améliorer les appariements d'histogrammes de couleurs, et elle est définie en fonction des contraintes de l'application.[41] Exemple illustratif (Fig 4.11) d'appariment en utilisant la distance usuelle (euclidienne) ainsi que la distance DTW




FIGURE 4.12 – Figure illustrative d’un appariement en utilisant la distance usuel (eucledienne) ainsi que la distance DTW [9]

Et pour finir nous allons adapter **un CNN** à notre base de données Corel1000 et Kimia path960.

Nous avons utilisé la bibliothèque tensorflow de Google qui combine plusieurs modèles et algorithmes de machine learning et de deep learning afin de les rendre exploitables par le biais d’une interface commune. Nous avons aussi utilisé La bibliothèque Keras qui est un API puissant de réseau de neurones open source et de haut niveau.[65]

Nous allons expliquer certains détails descriptifs de ce classifieur.

```

model = tf.keras.Sequential([
    layers.Rescaling(1./255),
    layers.Conv2D(128, 4, activation='relu'),
    layers.MaxPooling2D(),
    layers.Conv2D(64, 4, activation='relu'),
    layers.MaxPooling2D(),
    layers.Conv2D(32, 4, activation='relu'),
    layers.MaxPooling2D(),
    layers.Conv2D(16, 4, activation='relu'),
    layers.MaxPooling2D(),
    layers.Flatten(),
    layers.Dense(64, activation='relu'),
    layers.Dense(num_classes, activation='softmax')
])

```

FIGURE 4.13 – Couches utilisé pour la classification

Dans cette partie de code nous avons :

- Rescaling : Transformer en binaire.
- Conv2D : Une couche de convolution.

- MaxPooling : Prend le maximum du pooling.
- Flatten : Transformation en 1D.
- Dense : Sont des architectures inspirer du cerveau : composés d'un système de neurones, ils sont capables d'apprendre à partir d'exemple, sans être programmés à l'aide de règles spécifiques.[65]
- relu : une fonction d'activation

#### 4.2.7.2 Résultat des expérimentations en utilisant la base de données Corel 1K :

Dans ce chapitre nous présentons des graphiques qui résument les résultats obtenus de toutes les méthodes.

##### 4.2.7.2.1 Grpahique des résultats en utilisant la mesure Euclidienne :

Ce graphe représente le pourcentage d'accuracy de chaque méthode en utilisant la mesure de distance Euclidienne (Fig 4.13) :




FIGURE 4.14 – Graphique représentant les résultats du Classifieur KNN – Euclidienne . K= 5

Nous remarquons ici que la meilleure méthode utilisée est le HSV qui combine tous les axes quelques soit la base utilisée. Nous atteignons, ainsi, jusqu'à 71% de précision,

lorsqu'on utilise la base de donnée initial a 100 test, suivit par le LAB a 70% et l'histogramme de couleur a 69%. Nous avons aussi remarqué que le pourcentage change à chaque fois qu'on change de base. Cela reste logique, étant donné que la taille de la base augmente. Cependant le meilleur espace de couleur reste toujours le HSV.

Donc, nous avons une connaissance extraite de ces expérimentations :

**Connaissance 1 :** Dans le cadre du mining de l'image, en utilisant le classifieur KNN, Distance Euclidienne, le meilleur espace de couleur est le HSV complet.

Résultats détaillés par classe (Classe-Wise) : Nous allons détailler les résultats de la meilleure méthode de classification utilisée jusque-là : Le Classifieur KNN – Histogramme de couleurs – Euclidienne – Espace HSV complet. Ce détail est illustré graphiquement sur la Figure 4.14

Le graphique montre le pourcentage de prédiction correcte de chaque classe, dépendant de la base de données utilisée.

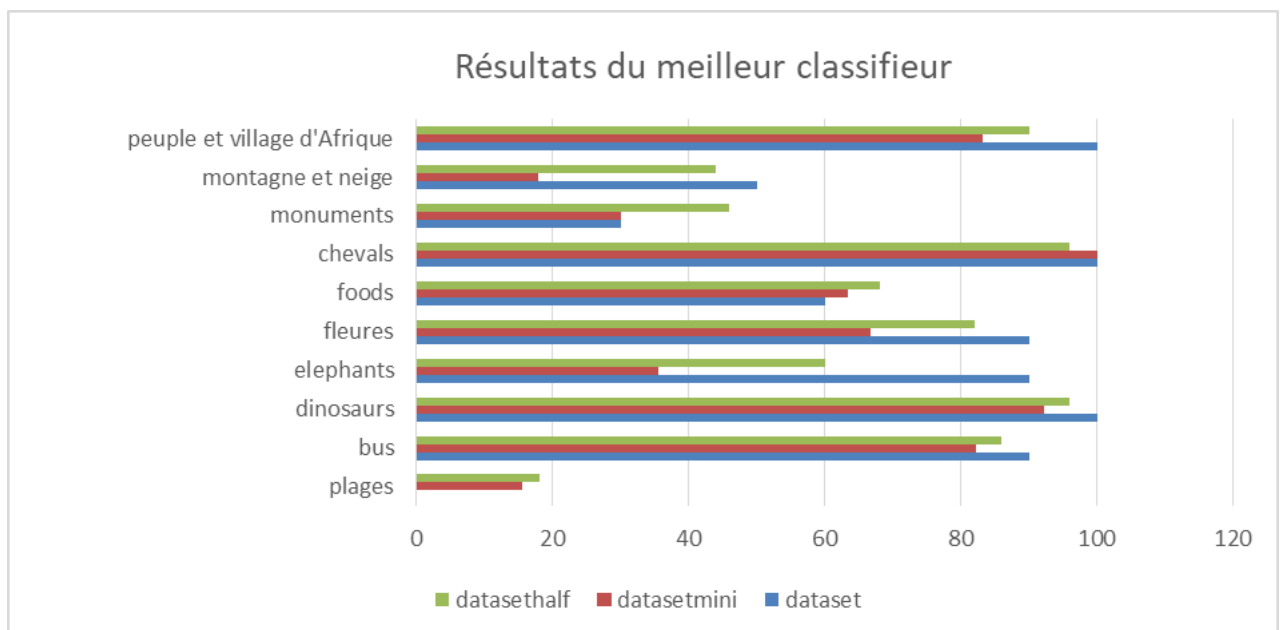


FIGURE 4.15 – Détail par classe des résultats du meilleur classifieur, jusque-là : Le Classifieur KNN – Euclidienne – Espace HSV complet.

Nous remarquons alors que, lorsqu'on utilise la base de données initiale, nous obtenons

dans certains cas, tels que « les dinosaures », « les chevaux » et « le peuple et villages d’Afrique » un pourcentage de 100%. Tout cela peut être interprété comme une deuxième connaissance, extraite dans cette étude.

**Connaissance 2 :** Relativement au Dataset Corel1000, en utilisant le classifieur KNN – Distance Euclidienne, espace de couleurs HSV, certaines classes sont plus faciles à classifier que d’autres. Globalement parlant : Les classes les plus faciles à classifier sont celles : Simples, pas trop riches en contenu sémantique (objets, textures, couleurs, etc.).

**4.2.7.2.2 Graphique des résultats en utilisant la mesure Canberra :** Ce graphique représente le pourcentage d’accuracy de chaque méthode, en utilisant la mesure de distance canberra. Il est représenté sur la Figure 4.15 :




FIGURE 4.16 – Graphique représentant les résultats du Classifieur KNN – Canberra  $k=5$

Nous remarquons ici que la meilleure méthode utilisée est le LAB qui combine tous les axes. Nous atteignons ainsi jusqu’à 81% de précision, lorsqu’on utilise la base de donnée initiale à 100 tests, suivi par le HSV à 78% et le LBPbleu à 73%.

Nous remarquons que le pourcentage change à chaque fois qu’on change de base, cela reste logique étant donné que la taille de la base augmente. Cependant la meilleure méthode reste toujours le LAB. Nous tirons encore une autre connaissance extraite des expériences

tations réalisées :

**Connaissance 3 :** Dans le cadre du mining de l'image, en utilisant le classifieur KNN, Distance Canberra, le meilleur espace de couleur est le LAB complet.

Nous allons détailler par classe, les résultats de la meilleure méthode dans le graphique de la Figure 4.16. Ce graphique qui montre le pourcentage de prédiction correcte de chaque classe, dépendant de la base de données utilisée. Nous remarquons que lorsqu'on utilise la base de données initiale nous obtenons dans certains cas, tels que « les dinosaures », « les chevaux » et « le peuple et villages d'Afrique » un pourcentage de 100%.




FIGURE 4.17 – Détail par classe des résultats du meilleur classifieur, juque-là : Le Classifieur KNN – Canberra – Espace LAB complet

Tout cela peut être interprété comme une autre connaissance, extraite dans cette étude.

**Connaissance 4 :** Relativement au Dataset Corel1000, en utilisant le classifieur KNN, distance de Canberra, espace de couleurs LAB, certaines classes sont plus faciles à classifier que d'autres. Globalement parlant : Les classes les plus faciles à classifier sont celles : Simples, pas trop riches en contenu sémantique (objets, textures, couleurs, etc.).

**4.2.7.2.3 Grpahique des résultats en utilisant la mesure Manhattan :** Ce graphique représente le pourcentage d'accuracy de chaque méthode en utilisant la mesure de distance Manhattan. Il est représenté sur la Figure 4.17.

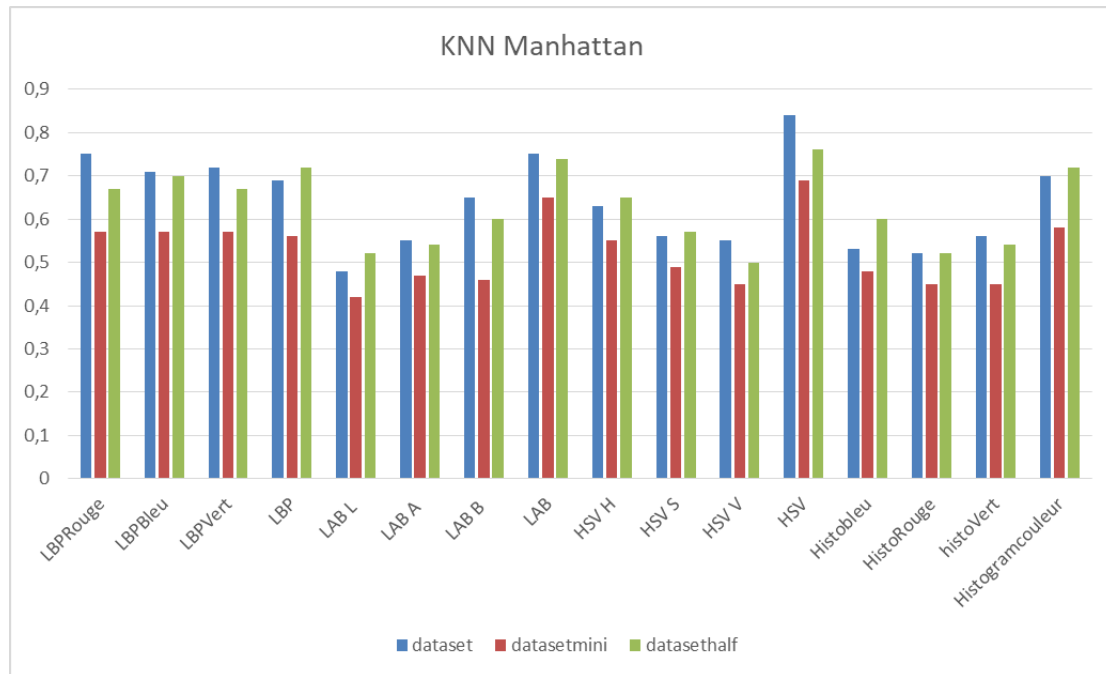


FIGURE 4.18 – Graphique représentant les résultats du Classifieur KNN – Manhattan K= 5

Ici aussi, nous remarquons que la meilleure méthode utilisée est le HSV qui combine tous les axes. Nous atteignons ainsi, jusqu'à 84%, lorsqu'on utilise la base de donnée initiale à 100 tests, suivi par le LAB à 75% et le LBPRouge à 75%.

Nous remarquons que le pourcentage change à chaque fois qu'on change de base. Cela reste logique étant donné que la taille de la base augmente. Cependant la meilleure méthode reste toujours le LAB. Nous en tirons alors une autre connaissance, dans le cadre de cette étude :

**Connaissance 5 :** Dans le cadre du mining de l'image, en utilisant le classifieur KNN, Distance Manhattan, le meilleur espace de couleur est le HSV complet.

Dans ce qui suit, nous allons détailler les résultats de la meilleure méthode. Les détails sont représentés graphiquement sur la Figure 4.18. Ce graphique montre le pourcentage de prédiction correcte de chaque classe dépendant de la base de données utilisée.




FIGURE 4.19 – Détail par classe des résultats du meilleur classieur, jusque-là : Le Classifieur KNN – Manhattan – Espace HSV complet.

Nous remarquons alors que, lorsqu'on utilise la base de données initiale, nous obtenons dans certains cas, tels que « les dinosaures », « les chevaux » et « le peuple et villages d'Afrique » un pourcentage de 100%. Nous en tirons alors une autre connaissance extraite de cette étude.

**Connaissance 6 :** Relativement au Dataset Corel1000, en utilisant le classifieur KNN, distance de Manhattan, espace de couleurs HSV, certaines classes sont plus faciles à classifier que d'autres. Globalement parlant : Les classes les plus faciles à classifier sont celles : Simples, pas trop riches en contenu sémantique (objets, textures, couleurs, etc.).

#### 4.2.7.2.4 Grpahique des résultats en utilisant la mesure DTW :

Le graphique de la Figure 4.19 représente le pourcentage d'accuracy de chaque méthode en utilisant la mesure de similarité DTW :

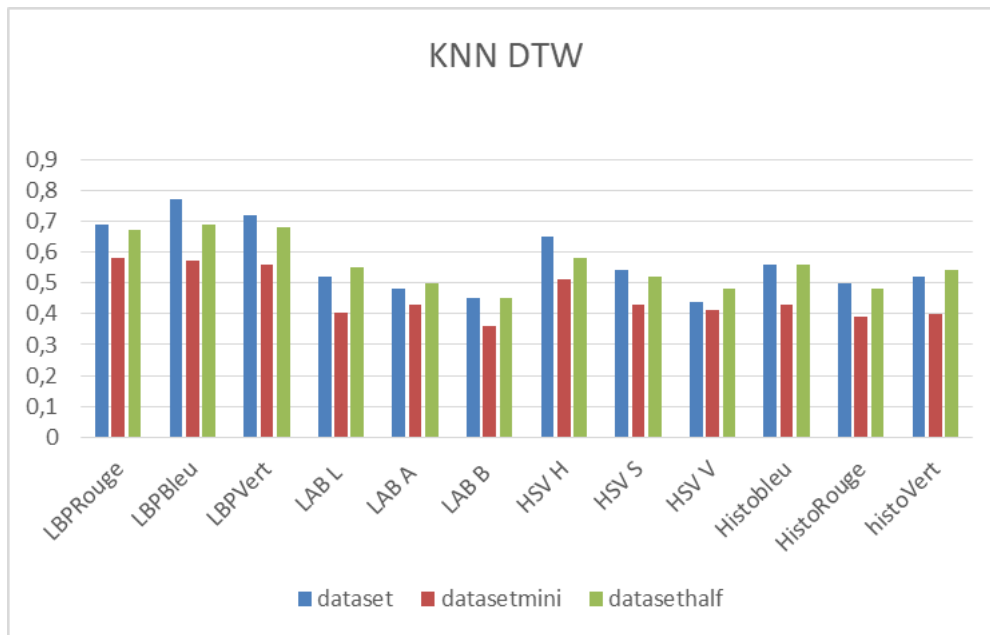


FIGURE 4.20 – Graphique représentant les résultats du Classifieur KNN DTW.  $K=5$

Nous remarquons ici que la meilleure méthode utilisée est le LBP Bleu, atteignant jusqu'à 77% lorsqu'on utilise la base de donnée initiale à 100 tests, suivie par le LBPVert à 72% et le LBPRouge à 69%. Nous remarquons aussi un changement radical en ce qui concerne les meilleures méthodes utilisées lors de l'utilisation du DTW : Les 3 méthodes non mentionnées se sont énormément améliorées. Nous pouvons en conclure qu'il existe une grande ressemblance entre les histogrammes des images qui appartiennent à la même classe. Ce constat est représenté par un exemple : une image test (Fig 4.20) et une image entraînement (Fig. 4.21) :

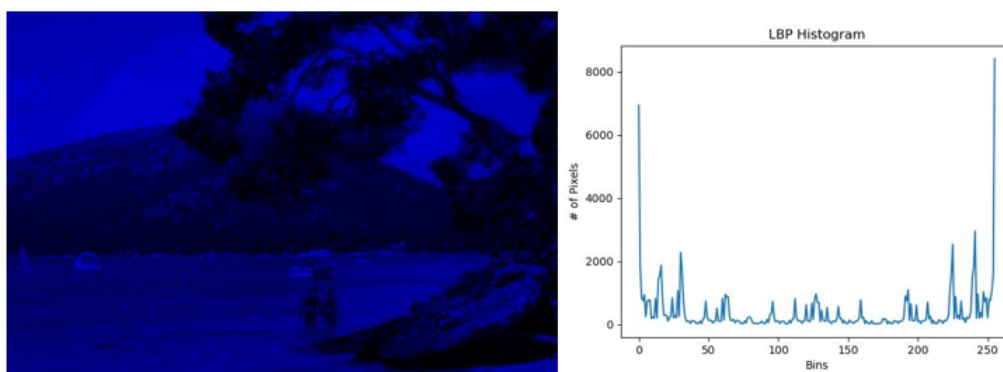


FIGURE 4.21 – Image originale test et son histogramme LBP Bleu

Nous remarquons ici que les histogrammes sont très ressemblants, avec quelques varia-

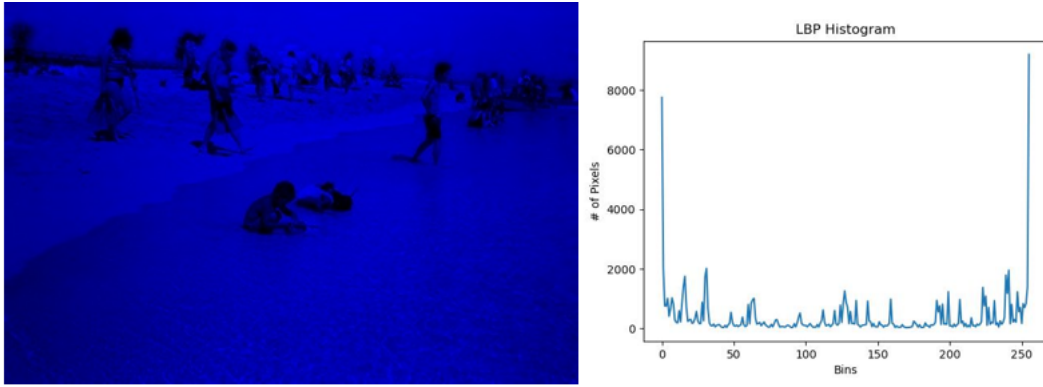


FIGURE 4.22 – Image originale entraînement et son histogramme LBPBleu

bilités locales. Nous tirons la conclusion que c'est le pouvoir extraordinaire d'alignement de la DTW qui a pu rapprocher ces images, comme étant de même classe, via leurs histogrammes respectifs LBPBleu.

**Connaissance 7 :** Dans le cadre du mining de l'image, en utilisant le classifieur KNN, Mesure de similarité (appariement) DTW, attribut LBP, le meilleur espace de couleur est le RGB, canal Bleu.

**4.2.7.2.5 Grpahique des résultats en utilisant les couleurs dominantes** Nous utilisons alors le classifieur KNN combiné avec la distance Euclidienne – Histogrammes de couleurs dominantes pour classifier les éléments de test. Les résultats obtenus sont représentés graphiquement sur la Figure 4.22.




FIGURE 4.23 – Résultats du classifieur KNN, Histogramme de couleurs dominantes

Ce graphique montre alors qu’il y a une grande différence entre les résultats obtenus avec les méthodes auparavant. Tout cela est dû au fait que nous avons réduit l’espace de couleur a 50 couleurs uniquement, ce qui explique le changement et la diminution des résultats. Nous en tirons alors une autre connaissance extraite dans le cadre de cette étude.

**Connaissance 8 :** Dans le cadre du mining de l’image, le classifieur KNN – Distance Euclidienne – espace RGB est sensible au nombre de couleurs dominantes utilisées.

**4.2.7.2.6 Grpahique des résultats en utilisant le CNN :** Nous avons donc appliqué le CNN à notre base de données Corel 1K. Nous avons fait 10 itérations à effectuer sur l’ensemble de données d’entraînement.

Les résultats de l’apprentissage sont représentés graphiquement sur la Figure 4.23. Cette Figure illustre la progression du taux de classification correcte (Précision), en fonction du nombre d’itérations.




FIGURE 4.24 – Evolution des résultats du CNN : Précision de classification, en fonction du nombre d'itérations qui est de 10

Nous remarquons, alors, l'amélioration de la précision au fil des itérations jusqu'à arrive à 90,82% dans le cas ou à 900 en entrainement cependant, plus la base d'entrainement devient de plus en plus petite passant de 90,82% à 67,14% dans le cas 100 entrainement et 87,06% avec 500. Nous en tirons alors une autre connaissance extraite dans le cadre de cette étude.

**Connaissance 9 :** Dans le cadre du Mining de l'image, le classifieur basé CNN est sensible au nombre d'itérations et nombre d'image utiliser pour l'entrainement.

### 4.2.7.3 Résultat des expérimentations en utilisant la base de données Kimia path 960 :

#### 4.2.7.3.1 Graphique des résultats en utilisant la mesure Euclidienne :

Ce graphe représente le pourcentage d'accuracy de chaque méthode en utilisant la mesure de distance Euclidienne :




FIGURE 4.25 – Graphique représentant les résultats du Classifieur KNN – Euclidienne  $k=5$

Nous remarquons ici que la meilleure méthode utilisé lors de l'utilisation de la base :

**Connaissance 10 :** Lors de l'utilisation de la base Dataset nous remarquons dans ce cas que la meilleure méthode utilisée est le HSV qui combine tous les axes. Nous atteignons ainsi jusqu'à 94% de précision, suivi par l'histogramme de couleurs qui combine les 3 axes à 93% et le LAB avec les 3 axes à 92%.

**Connaissance 11 :** Lors de l'utilisation de la base DatasetMini nous remarquons ici que la meilleure méthode utilisée est le LAB qui combine tous les axes. Nous atteignons ainsi jusqu'à 80% de précision, suivi par le HSV qui combine les 3 axes jusqu'à 78% et le

LAB axes B axes à 74%.

**Connaissance 12** : Lors de l'utilisation de la base DatasetHalf nous remarquons ici que la meilleure méthode utilisée est le HSV qui combine tous les axes. Nous atteignons ainsi jusqu'à 94% de précision, suivi par le LAB des 3 axes a 92% et l'histogramme de couleurs des 3 axes jusqu'à 90%.

#### 4.2.7.3.2 Grpahique des résultats en utilisant la mesure Canberra :

Ce graphique représente le pourcentage d'accuracy de chaque méthode, en utilisant la mesure de distance Canberra. Il est représenté sur la Figure 4.25 :




FIGURE 4.26 – Graphique représentant les résultats du Classifieur KNN – Canberra k =5

Nous remarquons ici que la meilleure méthode utilisée est le HSV qui combine tous les axes. Nous atteignons ainsi jusqu'à 99% de précision, lorsqu'on utilise la base de donnée initiale à 100 tests, suivi par l'histogramme de couleurs avec les 3 axes combiné jusqu'à 98% et le LAB avec les 3 axes à 96%.

Nous remarquons que le pourcentage change à chaque fois qu'on change de base, cela reste

logique étant donné que la taille de la base augmente. Cependant la meilleure méthode reste toujours le HSV.

**Connaissance 13 :** Le meilleur classifieur est le HSV qui combine tous les axes.

#### 4.2.7.3.3 Grpahique des résultats en utilisant la mesure Manhattan :

Ce graphique représente le pourcentage d'accuracy de chaque méthode, en utilisant la mesure de distance Manhattan. Il est représenté sur la Figure 4.26 :




FIGURE 4.27 – Graphique représentant les résultats du Classifieur KNN – Manhattan  $k=5$

Nous remarquons ici que la meilleure méthode utilisée lors de l'utilisation de la base :

**Connaissance 14 :** Lors de l'utilisation de la base Dataset, nous remarquons dans ce cas que la meilleure méthode utilisée est l'histogramme de couleurs qui combine tous les axes. Nous atteignons ainsi jusqu'à 95% de précision, suivi par le HSV avec les 3 axes combiné et le LAB avec les 3 axes à 93%.

**Connaissance 15 :** Lors de l'utilisation de la base DatasetMini, nous remarquons ici que la meilleure méthode utilisée est l'histogramme de couleur qui combine tous les axes.

Nous atteignons ainsi jusqu'à 84% de précision, suivi par le LAB combiné jusqu'à 83% et le HSV combiné à 82%.

**Connaissance 16 :** Lors de l'utilisation de la base DatasetHalf, nous remarquons ici que la meilleure méthode utilisée est le HSV qui combine tous les axes. Nous atteignons ainsi jusqu'à 96% de précision, suivi par le LAB des 3 axes à 93% et l'histogramme de couleurs des 3 axes jusqu'à 91%.

#### 4.2.7.3.4 Grpahique des résultats en utilisant la mesure DTW :

Ce graphique représente le pourcentage d'accuracy de chaque méthode, en utilisant la mesure de distance DTW. Il est représenté sur la Figure 4.27 :




FIGURE 4.28 – Graphique représentant les résultats du Classifieur KNN – DTW  $k = 5$

Nous remarquons ici que la meilleure méthode utilisée est le LBPRouge. Nous atteignons ainsi jusqu'à 88% de précision, suivi par le LBPRouge et LBPBleu à 84%.

Nous remarquons que le pourcentage change à chaque fois qu'on change de base, cela reste logique étant donné que la taille de la base augmente. Cependant la meilleure méthode reste toujours le HSV.

**Connaissance 17 :** Le meilleur classifieur est le LBPRouge.

#### 4.2.7.3.5 Graphique des résultats en utilisant le CNN :

Nous avons donc appliqué le CNN à notre base de données Kimia path960. Nous avons fait 20 itérations à effectuer sur l'ensemble de données d'entraînement.

Les résultats de l'apprentissage sont représentés graphiquement sur la Figure 4.28. Cette Figure illustre la progression du taux de classification correcte (Précision), en fonction du nombre d'itérations.




FIGURE 4.29 – Evolution des résultats du CNN : Précision de classification, en fonction du nombre d'itérations qui est de 20

**Connaissance 18 :** Lors de l'utilisation de la base d'entraînement à 90% nous remarquons l'amélioration de la précision au fil des itérations jusqu'à arrive à 85%. Cependant, lors de l'utilisation d'une base d'entraînement inférieur à 90% nous remarquons l'irrégularité de la croissance du graphe, l'amélioration n'est pas remarquable, elle arrivera jusqu'à 22,3% dans le cas 10% de l'entraînement et de 6,1% avec 50% d'entraînement.

## 4.3 Conclusion

L'objectif de ce chapitre était de présenter une étude comparative de plusieurs méthodes de classification d'images sur plusieurs bases.

L'étude a porté sur 17 classifieurs KNN et un classifieur CNN, en utilisant différentes distances et mesures de similarité, basées sur les espaces de couleurs et des attributs d'image, appliquée sur les deux bases d'images : Corel1000 et Kimia Path 960.

Les résultats de l'étude ont montré que :

- La performance de la méthode dépend de la complexité et la richesse du contenu sémantique.
- La meilleure méthode change dépendant de la mesure de distance ou des mesures de similarité, ainsi que l'organisation de la base.
- Le classifieur CNN a obtenu de bons résultats, mais reste sensible au nombre d'itérations et à la taille de la base d'entraînement.

En conclusion, cette étude a permis de mieux comprendre les performances de certaines méthodes, afin d'en extraire des connaissances. Les résultats obtenus peuvent être utile pour reconnaître la valeur et la puissance de la méthode dépendant des critères de besoins.

# Conclusion générale

La classification d'images s'affirme comme un domaine crucial du Data Mining, ouvrant un large éventail d'applications dans des domaines tels que la reconnaissance d'objets, la détection d'anomalies, la recherche d'images par le contenu et l'analyse médicale basée image.

En particulier, nous avons utilisé le classifieur KNN en lui diversifiant les descripteurs hand crafted, les mesures de distances et de similarité ainsi que les espaces de couleurs. Nous avons aussi utilisé un classifieur Deep learning à titre de comparaison. Aussi bien que les classifieurs KNN et CNN ont été appliqués sur deux bases, la base Wang (une base de scène générale) et la base spécialisée Kimia 960 (base histologique) utilisée en médecine. Les résultats essentiels tirés de cette étude sont :

1. Nous avons constaté que tous les paramètres utilisés ont une influence sur les résultats obtenus sur les deux Dataset : la distance, l'espace de couleur, L'attribue, classifieur et arrangement des datasets utilisées.
2. Les résultats obtenus montrent que Les CNN sont beaucoup plus efficaces dans le cas d'images riches en concept (base Wang) que dans les images pauvres en concept (base Kimia).
3. Certaines images se prêtent beaucoup plus facilement à être classifiées que certaines sur la base de leurs richesses et leurs pauvretés en concept.

En conclusion, la classification d'images s'impose comme un outil puissant pour l'analyse et l'extraction de connaissances à partir d'images numériques. Le choix de la technique et de l'approche appropriée dépend des exigences spécifiques de chaque application. Les recherches futures continueront à explorer de nouvelles techniques et à améliorer les

performances de la classification d'image pour relever les défis croissants dans divers domaines. A travers ce mémoire nous avons appris ce qui suit :

1. Nous avons été introduit dans un domaine d'actualité le Data mining en général, le Mining de l'image en particulier, plus spécifiquement la tâche de la classification de l'image.
2. Nous avons pris conscience de l'importance des espaces de couleurs concernant les différentes tâches de l'image mining (la recherche de l'image, la classification de l'image, la détection d'anomalie dans les images,etc.
3. Nous avons aussi pris conscience de l'importance de la mesure de distance et de similarité dans le cadre générale et plus précisément du mining de l'image.
4. Nous avons aussi pris conscience de l'importance des descripteurs (hand crafted) de l'image dans le cadre du mining de l'image en général.
5. Nous avons pris connaissance de l'existence d'une diversité de classifieurs de l'image, en particulier, nous avons exploité deux d'entre eux : le classifieurs KNN configuré de façon diversifiée, et un classifieur de type CNN. Comme déjà mentionné il s'avère que dépendant de la complexité de l'image l'un ou l'autre des deux classifieurs est plus performant que l'autre.

Il serait intéressant dans le futur de mener cette étude dans un contexte spécialisé tel que dans le domaine médical.

# Bibliographie

- [1] MOKHBI Ryane. Classification d'images basée Deep-Learning : Utilisation des réseaux de neurones à convolution (CNNs) sous la plateforme google-colab, Mémoire de Master, Spécialité : Informatique, Université de Skikda, Juin 2020.
- [2] [https://leanbi.ch/fr/blog/qu\\_est\\_ce\\_que\\_detection\\_d\\_anomalies/](https://leanbi.ch/fr/blog/qu_est_ce_que_detection_d_anomalies/).
- [3] <https://cedric.cnam.fr/vertigo/cours/ml2/coursArbresDecision.html>.
- [4] [https://www.researchgate.net/figure/a-SVM-classifier-Courtesy-google\\_fig3\\_370589237](https://www.researchgate.net/figure/a-SVM-classifier-Courtesy-google_fig3_370589237).
- [5] Bendjama Abdelali et Hocine Nassim. Classification des images numériques dans le cadre du data mining. Mémoire de Master, spécialité : Informatique, Université de Skikda, Juin 2021.
- [6] MENSOURI Zoheir. Comparaison d'images par le contenu visuel et applications : Une étude théorique. Mémoire de Master, Spécialité Informatique, Université de Skikda, Juin 2023.
- [7] <https://numpy.org>.
- [8] <https://opencv.org>.
- [9] <https://www.databricks.com/blog/2019/04/30/understanding-dynamic-time-warping.html>, 2019.
- [10] <https://blog.sinatechnologie.com/presentation-des-reseaux-de-neurones-artificiels> 2021.

- [11] S. Asur, B. A. Huberman, and D. S. Weld. A framework for data science and applications. *Science*, 345(6197) :1322–1328, 2014.
- [12] Marc Baudoin. Apprends latex! *École nationale supérieure de techniques avancées, Paris*, 1994.
- [13] Alexander Bohan and Xiaolong Li. A survey on video mining. *ACM Computing Surveys (CSUR)*, 48(2) :1–37, 2016.
- [14] Leo Breiman. Bagging predictors. *Machine learning*, 24(2) :243–270, 1996.
- [15] Iris Brémaud, Dominique Cardon, Backes Bernadette, Pierre Cabrolhier, Daniel Guibal, and Patrick Langbour. Colorimétrie des bois : Diversité du matériau et complexité de son apparence. *Coré. Conservation et restauration du patrimoine culturel*, 1 :61–84, 2021.
- [16] Rich Caruana. Ensemble learning for image classification. *arXiv preprint arXiv :1602.04481*, 2016.
- [17] Wikimedia Commons. Convolutional neural network. [https://en.wikipedia.org/wiki/Convolutional\\_neural\\_network](https://en.wikipedia.org/wiki/Convolutional_neural_network).
- [18] Wikimedia Commons. Rgb color cube.svg. [https://commons.wikimedia.org/wiki/File:RGB\\_Colorcube\\_Corner\\_Blue.png](https://commons.wikimedia.org/wiki/File:RGB_Colorcube_Corner_Blue.png).
- [19] Wikipedia contributors. [https://en.wikipedia.org/wiki/HSL\\_and\\_HSV](https://en.wikipedia.org/wiki/HSL_and_HSV).
- [20] Wikipedia contributors. [https://fr.wikipedia.org/wiki/Distance\\_\(mathematiques\)](https://fr.wikipedia.org/wiki/Distance_(mathematiques)), 2022.
- [21] Wikipedia contributors. Canberra distance. [https://en.wikipedia.org/wiki/Canberra\\_distance](https://en.wikipedia.org/wiki/Canberra_distance), 2024.
- [22] Wikipedia contributors. Euclidean distance. 2024.
- [23] Wikipedia contributors. Indice et distance de jaccard. [https://fr.wikipedia.org/wiki/Indice\\_et\\_distance\\_de\\_Jaccard](https://fr.wikipedia.org/wiki/Indice_et_distance_de_Jaccard), 2024.

- [24] Wikipedia contributors. Visual studio code. [https://fr.wikipedia.org/wiki/Visual\\_Studio\\_Code](https://fr.wikipedia.org/wiki/Visual_Studio_Code), 2024.
- [25] C. Cortes and V. Vapnik. Support-vector networks. *Machine Learning*, 20(3) :273–297, 1995.
- [26] T. M. Cover and P. E. Hart. Nearest neighbor pattern classification. *IEEE Transactions on Information Theory*, 13(1) :21–27, 1967.
- [27] Bernard Desgraupes. *LATEX : apprentissage, guide et référence*. De Boeck Supérieur, 2019.
- [28] Elakkiya Devi and K. Thangavel. Image classification methods and techniques : A review. *International Journal of Scientific & Engineering Research*, 4(7) :2392–2397, 2013.
- [29] Nilanjan Dey, Wahiba Ben Abdesslem KarÁç a, Sayan Chakraborty, Sukanya Bannerjee, Mohammed AM Salem, and Ahmad Taher Azar. Image mining framework and techniques : a review. *International Journal of Image Mining*, 1(1) :45–64, 2015.
- [30] R. O. Duda and P. E. Hart. *Pattern Classification and Scene Analysis*. Wiley, New York, 1973.
- [31] Jean Dupont and Claire Martin. Techniques d’extraction des motifs en fouille d’image. *Revue des Sciences Informatiques*, 20(3) :45–67, 2024.
- [32] Jean Dupont, Claire Martin, and Pierre Legrand. Techniques avancées d’extraction des motifs en fouille d’image. *Journal des Sciences Informatiques et Applications*, 25(4) :102–123, 2024.
- [33] Yann LeCun et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11) :2278–2324, 1998.
- [34] Usama M. Fayyad, Gregory Piatesky-Shapiro, and Peter Smyth. Data mining and knowledge discovery : Kdd process for large datasets. *Knowledge Discovery and Data Mining*, 1(1) :119–131, 1996.

- [35] geeksforgeeks. What is an operating system ? <https://www.geeksforgeeks.org/what-is-an-operating-system/>.
- [36] geeksforgeeks. <https://www.geeksforgeeks.org/introduction-to-recurrent-neural-network/>, 2023.
- [37] Xiang He and Enze Wang. Unsupervised image classification : A survey and comparative study. *arXiv preprint arXiv :2004.11712*, 2020.
- [38] Min Huang, Haoxue Liu, Guihua Cui, and M Ronnier Luo. Testing uniform colour spaces and colour-difference formulae using printed samples. *Color Research & Application*, 37(5) :326–335, 2012.
- [39] Commission internationale de l’éclairage. Recommendations on uniform color spaces and color difference formulas, 1976. Publication CIE No. 15.
- [40] Yih-Cherng Juan, Dau-Cheng Lyu, and Wen-Tsuen Chen. Content-based image retrieval using color and texture combined features. *Pattern Recognition*, 34(6) :119–130, 2001.
- [41] Hagen Kaprykowsky, SIPT Master, Place Igor Stravinsky, Xavier Rodet, and Jocelyn Chanussot. *Alignement d’un enregistrement Audio avec sa Partition : passage de l’algorithme DTW global a un DTW a court terme*. PhD thesis, Master Thesis, Ircam Centre Pompidou, Paris, France, 2005.
- [42] Norman Kerle, Rob Stekelenburg, Frank Heuvel, and Ben Gorte. *Near-Real Time Post-Disaster Damage Assessment with Airborne Oblique Video Data*, pages 337–353. 01 2005.
- [43] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E. Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in Neural Information Processing Systems*, pages 1097–1105, 2012.
- [44] Kimia Lab. Pathologie images : Kimia path24 dataset. <https://kimialab.uwaterloo.ca/kimia/index.php/pathology-images-kimia-path24/>.

- [45] Yannick Lechevalier. Des exemples concrets pour illustrer la puissance de la fouille multimédia. *Blog personnel*, 2024.
- [46] Yannick Lechevalier. La fouille de données structurée : Une exploration méthodique en quatre étapes. *Blog personnel*, 2024.
- [47] Yannick Lechevalier. La fouille multimédia : Dévoiler les secrets cachés des données non structurées. *Blog personnel*, 2024.
- [48] Yannick Lechevalier. La fouille structurée : Déchiffrer les secrets des données organisées. *Blog personnel*, 2024.
- [49] Yannick Lechevalier. Le data mining : Extraire des connaissances précieuses des données. *Blog personnel*, 2024.
- [50] Yannick Lechevalier. Le mining du texte : Dévoiler les secrets cachés des données textuelles. *Blog personnel*, 2024.
- [51] Yann LeCun. Deep learning. *Nature*, 521(7553) :436–444, 2015.
- [52] Gaëtan Leeucq and Christos Faloutsos. Fast umap : A versatile technique for uniformity and proximity approximation. *Data Mining and Knowledge Discovery*, 31(2) :345–376, 2006.
- [53] lemagit. Data mining les sept techniques les plus importantes. <https://www.lemagit.fr/tip/Data-Mining-les-sept-techniques-les-plus-importantes>, 2022. Accessed : 2024-05-25.
- [54] Hela Ltifi. [https://www.researchgate.net/figure/Le-processus-dECD-Les-differentes-etapes-du-processus-dECD-sont-les-suivantes\\_fig3\\_229429865](https://www.researchgate.net/figure/Le-processus-dECD-Les-differentes-etapes-du-processus-dECD-sont-les-suivantes_fig3_229429865), 2010.
- [55] Wei-Mei Ma, Zhigang Lu, Hongdong Zhang, and Yanwei Liu. Learning from videos : A review. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 37(9) :1956–1975, 2015.

- [56] BS Manjunath, Murat Kunt, et al. A survey of image mining. *IEEE Signal Processing Magazine*, 18(6) :49–66, 2001.
- [57] Alex Martelli. *Python : en concentré*. O'Reilly Media, Inc., 2004.
- [58] Bipul Neupane, Teerayut Horanont, and Nguyen Hung. Deep learning based banana plant detection and counting using high-resolution red-green-blue (rgb) images collected from unmanned aerial vehicle (uav). *PLOS ONE*, 14 :e0223906, 10 2019.
- [59] Phung and Rhee. A high-accuracy model average ensemble of convolutional neural networks for classification of cloud image patches on small datasets. *Applied Sciences*, 9 :4500, 10 2019.
- [60] Why Python. Python. *Python releases for windows*, 24, 2021.
- [61] J. R. Quinlan. Induction of decision trees. *Machine Learning*, 1(1) :81–106, 1986.
- [62] Chandan K. Reddy. A survey of clustering data mining techniques. *Journal of Data Mining and Knowledge Discovery*, 2(1) :1–45, 2011.
- [63] Alan F. Smeaton, Fei Sha, and Patrick Poncelet. Video mining : A technical survey. *IEEE Transactions on Multimedia*, 15(6) :1223–1249, 2013.
- [64] John R Smith and Shih-Fu Chang. Tools and techniques for color image retrieval. In *Storage and retrieval for still image and video databases iv*, volume 2670, pages 426–437. SPIE, 1996.
- [65] Tensorflow. Neural structured learning. <https://www.databricks.com/fr/glossary/tensorflow-guide>.
- [66] Wikimedia. Lab color model color meter. [https://commons.wikimedia.org/wiki/File:CIE-1931\\_diagram\\_in\\_LAB\\_space.svg?uselang=fr](https://commons.wikimedia.org/wiki/File:CIE-1931_diagram_in_LAB_space.svg?uselang=fr).
- [67] Wikipedia. Réseau de neurones artificiels. <https://wikipedia.fr/>. Consulté le 8 mai 2024.

- [68] Tianqi Yang. Social media data mining. *ACM Computing Surveys*, 49(1) :1–36, 2016.

الجمهورية الجزائرية الديمقراطية الشعبية

République Algérienne Démocratique et Populaire

وزارة التعليم العالي والبحث العلمي

Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

جامعة 20 أوت 1955 - سكيكدة

Université 20 Août 1955- skikda-

Faculté des Sciences

Département d'Informatique



كلية العلوم

قسم الاعلام الالى

الرقم : ..... / 3 / 1 / أ / ل.م.ع / 2024

## Autorisation de Dépôt de Mémoire de Master

Je soussigné: ...Pr. BOUCHEHAM Bachir.....

Certifie que l'étudiant(e) ...Harbi Wissa et Nedjar Soumaya

Spécialité : ...Informatique - M2 SIAA.....

Ayant soutenu le projet intitulé : "Classification d'images dans le contexte de l'Image Mining : une étude Comparative selon plusieurs critères".....

A apporté les corrections nécessaires sur son manuscrit de Master



Signature de l'encadreur

Pr Boucheham B.



## بطاقة معلومات خاصة بذاكرة التخرج

رقم التسجيل :

اسم و لقب الطالب :

.....36.00.23.05.....\* Harbi.....Wissal.....\*

.....36.00.17.24.....\* Nedjar.....Soumaya.....\*

.....\*.....\*

.....\*.....\*

..Pr.....Boucheham.....Bachir..... : اسم و لقب المشرف على المذكرة :

"Classification d'images...dans...le...contexte... : عنوان المذكرة :

de...l'image...mining...une...étude...comparative...selon...plusieurs...critères"

.....Informatique..... : القسم

.....Master 2 S.I.A.A..... : المستوى

SI.A.A. : Systèmes d'information avancés et applications : التخصص