



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 محمد البشير الابراهيمى برج بوعريريج  
Université Mohammed El Bachir El Ibrahimy B.B.A  
كلية  
Faculté de Mathématiques et d'informatique  
قسم  
Département Informatique



# Mémoire

En vue de l'obtention du diplôme de Master

Domaine : Mathématique et Informatique

Filière : Informatique

Option : Ingénierie de l'informatique décisionnelle

## Thème

**Classification des IRM cérébrales pathologiques par une  
approche semi-supervisée**

Présenté par :

Far balkis

Boussaadia samah

Encadré par :

CHELLAKH Hafida

Soutenu publiquement le / /

devant le jury composé de :

Président :

Examineur :

Encadrant : Chellakh hafida

Promotion : 2020/2021



## *Remerciement*

*Avant tout, nous remercions Dieu tout puissant qui nous a donné la foi, le courage et la patience afin d'accomplir ce Modeste travail*

*Nous tenons à exprimer notre vif remerciement et notre parfondons gratitude à notre encadreur « **Mme chellakh hafida** » D'avoir accepté de nous encadrer et pour les efforts qu'elle a déployé, pour nous aider, conseiller, encourager et corriger,*

*Un grand merci à « **Mr attia abdelouahab** » pour son aide pratique et son soutien moral et ses encouragements,*

*Sans oublier de remercier « **Mr hirache zakaria** » et « **Melle gouader fatima** » et à toutes les personnes qui nous ont aidé,*

*Nos remerciement tous les membres du jury qui ont accepté de juger notre travail et pour l'intérêt qu'ils ont porté à ce dernier.*

*Et enfin nous remercions l'ensemble des collègues de la promotion informatique décisionnelle, et tous ceux qui ont marqué de près et de loin à réaliser notre projet.*



2021

## *Dédicace*

*D'un cœur d'amour et de fierté, je dédie ce modeste travail à mes deux bougies qui brûlent pour m'éclairer le chemin, mon cher père **Far djoudi** qui était plus généreux avec moi, m'aidé, m'encouragé, il était ma source de mon inspiration et de mon ambition, il est toujours consenti d'énormes sacrifices pour mon bien être et mon éducation que dieu ait pitié de lui, à la personne qui m'est la plus chère au monde ma mère **far khadra** qui était la confidente de mes secrets, la plus contente dans les moments de mes réussis qui m'a élevé, sacrifié toutes les belles années de sa vie pour moi, tu es une maman formidable et exceptionnelle que dieu la protège pour nous.*

*A mes chers et adorable sœurs et frères, **mordjana, sihem, racha, meriem, adem, ayoub** et à Ma nièce **soudjoud***

*A ma chère amie **samah** je te remercie pour ton amitié chère à mon cœur, et je te souhaite tout le bonheur du monde*

*A tous mes collègues et les étudiants de math et informatique*

*A tous ma famille far*

*Far balkis*





2021

## *Dédicace*

*Tout d'abord je tiens à remercier dieu le tout puissant de ma voire donné la santé, la patience et la volonté*

*Je dédie ce travail a :*

*A mon très chère maman **mehsas ghania**, qui m'a comblé de son soutien et l'a voué un amour inconditionnel, elle me donne l'encouragement et toujours donné la force de poursuivre mes études ;*

*A mon très cher père **Boussaadia lahcen**, qui a toujours répondu présent dans les moments les plus difficiles ;*

*A mes chers et adorable sœurs et frères : **djihan, A rafik, A rahim, A hake** qui n'ont cessé d'être pour moi des exemples de persévérance, de courage et de générosité*

*A ma chère amie **balkis et dallel** je te remercie pour ton amitié chère à mon cœur, et je te souhaite tout le bonheur du monde*

**Boussaadia Samah**



# Table des matières

Table des figures	iv
Liste des tableaux	ix
Liste des abréviations	xi
Chapitre I : introduction générale	
I.1.Contexte général.....	1
I.2.Problématique .....	1
I.3.Objectifs et contribution.....	2
I.4.Organisation du manuscrit.....	2
Chapitre II : Généralités	
II.1. Introduction .....	3
II.2. L'intelligence artificielle .....	3
II.2.1 méthodes de l'IA .....	4
II.2.1.1. Big Data .....	4
II.2.1.2.L'apprentissage automatique.....	5
II.2.1.2.1.L'apprentissage supervisé.....	6
II.2.1.2.2.Apprentissage non supervisé.....	7
II.2.1.2.3.L'apprentissage semi supervisé.....	7
II.3.1.3.Apprentissage profond .....	8
II.3. L'intelligence artificielle (IA) dans le domaine.....	10
II.3.1. L'imagerie par résonance magnétique (IRM) .....	10
II.3.2. Système nerveux central.....	12
II.3.2.1. La moelle épinière.....	12
II.3.2.2.Le cervelet .....	12
II.3.2.3. Le tronc cérébral .....	13
II.3.2.4. Le cerveau .....	13
II.3.3 les pathologies cérébrales .....	13
I.4.conclusion .....	14
Chapitre III : la classification	
III.1 Introduction.....	15
III.2 La classification.....	15
III.3 Exemples de problèmes de classification.....	15

III.3.1 Prédiction e-mail / Spam.....	15
III.3.2 Reconnaissance de formes.....	16
III.3.3 Des Tableaux.....	17
III.3.4 Classification des images .....	17
III.4 .Les étapes d'une classification .....	17
III.4.1. Choix des données .....	17
III.4.2. Pré-traitement .....	18
III.4.3.Extraction des caractéristiques .....	18
III.4.3.1. Extracteurs de bas-niveau .....	18
III.4.3.2. Extracteurs de plus haut niveau.....	19
III.4.4.Choix d'un algorithme de classification et exécution.....	21
III.5. méthodes de classification .....	21
III.5.1. Arbre de décision .....	22
III.5.2. K-Plus Proches Voisins (KPPV) (KNN) .....	23
III.5.3.Support Vector Machine (SVM) .....	24
III.5.4.Deep Rule-Based Classifier (DRB) .....	24
III.5.4.1.Architecture générale du classifieur DRB .....	25
III.5.4.1.1. pré-traitement.....	26
III.5.4.1.2. Couche d'extraction de caractéristiques .....	26
III.5.4.1.3. Ensemble massivement parallèle de règles SI. . . ALORS hautement interprétables .....	26
III.5.4.1.4. couche de décision .....	27
III.5.5.Semi-supervised Deep Rule-based (SSDRB) .....	28
III.5.5.1.Processus d'apprentissage semi-supervisé à partir d'ensembles de données statiques .....	29
III.6.Conclusion .....	33
Chapitre IV : l'approche proposé	
IV.1.Introduction .....	34
IV.2.Environment de travail .....	34
IV.2.1.Outils et matériels .....	34
IV.2.2.langage de programmation .....	34
IV.2.2.1.Matlab .....	34
IV.3. les modèles et architectures implémentés.....	35

IV.3.1. base de données utilisés .....	35
IV.3. 1.1. Base de données 1 .....	35
IV.3. 1.2. Base de données 2.....	35
IV.4. Les mesures de performance .....	36
IV.4.1. Matrice de confusion .....	36
IV.4.2. Courbe Roc .....	38
IV.5. Résultats et comparaison .....	39
IV.5.1. Comparaison entre les classificateurs et les extracteurs de caractéristiques dans la 1 <sup>ère</sup> base de données .....	39
IV.5.2. Comparaison entre le classificateur et les extracteurs de caractéristiques dans la 2 <sup>ème</sup> base de données .....	40
IV.5.3. Comparaison entre les deux bases de données avec l'extracteur de caractéristique HOG .....	41
IV.5.4. comparissent entre les 2 bases de données et 4 classificateurs avec descripteur LBP.....	43
IV.5.5. comparissent entre les 2 bases de données et les quatre classificateurs avec descripteur GIST .....	45
IV.5.6. Comparaison entre les résultats de différentes distances de SSDRB avec les extracteurs de caractéristique .....	47
IV.6. Conclusion .....	49
Conclusion générale.....	51
Bibliographie.....	52

## Liste des figures

Figure II.1 : Acquisition par IRM.....	4
Figure II.2 : Le système nerveux central (SNC).....	5
Figure II.3 : IRM montre exemple de tumeur Meningioma.....	7
Figure II.4 : Les 3 V du Big Data.....	8
Figure II. 5 : les types de données utilisées dans le domaine de santé.....	9
Figure II.6 : les types de l'apprentissage automatique.....	10
Figure II. 7:exemple d'un apprentissage supervisé.....	10
Figure II.8 : exemple d'un apprentissage non supervisé.....	11
Figure II.9: exemple d'un apprentissage semi-supervisé.....	12
Figure II.10 : les réseaux de neurones profonds.....	13
Figure II.11 : la relation entre l'intelligence artificielle, le ML et le deep Learning.....	14
Figure III.1 : E-mail valide / SPAM.....	16
Figure III.2 : reconnaissance du caractère manuscrit.....	16
Figure III.3 : données bancaires.....	17
Figure III.4 : image gradients and spatial/orientation Binnig.....	19
Figure III.5: Le processus d'extraction LBP.....	20
Figure III.6 : Construction d'un descripteur SIFT.....	20
Figure III.7 : Schéma du réseau AlexNet utilisé.....	21
Figure III.8 : Illustration de la construction d'un arbre de décision à partir des données de la base Iris.....	22
Figure III.9 : méthode des k plus proches voisins.....	23
Figure III.10 : Hyperplan séparateur de marge maximale; deux jeux d'hyperplan, la direction 2 a la marge la plus forte; les vecteurs de supports sont ceux situés sur les droites frontières.....	24
Figure III.11 : L'architecture générale du classifieur DRB.....	25
Figure III.12 : Organigramme du processus de formation du sous-système FRB.....	27
Figure III.13 : Processus d'apprentissage semi-supervisé hors ligne.....	31



Figure III.14 : Apprentissage actif de nouvelles classes, auto-évolutif.....	32
Figure IV.1 : Logo Matlab.....	35
Figure IV.2 : matrice de confusion.....	36
Figure IV.3 : le courbe roc.....	38
Figure IV.4 : matrice de confusion de l'approche HOG – SSDRB.....	42
Figure IV.5 : 2 courbes rocs avec l'approche HOG –SSDRB.....	42
Figure IV.6 : matrice de confusion de l'approche LBP avec SSDRB.....	44
Figure IV.7 : courbe roc avec l'approche LBP – SSDRB.....	44
Figure IV.8 :2 matrices de confusion de l'approche GIST avec SSDRB.....	46
Figure IV.9 : 2 courbes rocs avec l'approche GIST – SSDRB.....	46

## Liste des tableaux

Table IV.1 : Tableau de comparaison entre les quatre classificateurs avec les 3 descripteurs dans la base de données 01.....	39
Table IV.2 : Tableau de comparaison entre les quatre classificateurs avec les 3 descripteurs dans la base de données 02.....	40
Table IV.3 : Tableau de comparaison entre les deux bases de données avec l'extracteur de caractéristique HOG.....	41
Table IV.4 : Tableau de comparaison entre les deux bases de données avec l'extracteur de caractéristique LBP.....	43
Table IV.5 : Tableau de comparaison entre les deux bases de données avec l'extracteur de caractéristique GIST.....	45
Table IV.6 : Tableau évaluation de classifieur SSDRB avec l'extracteur de caractéristique HOG Dans la base de données 01.....	47
Table IV.7 : Tableau évaluation de classifieur SSDRB avec l'extracteur de caractéristique HOG Dans la base de données 02.....	47

## Liste des abréviations

<b>IA</b>	Intelligence artificielle
<b>SNC</b>	Système Nerveux Central
<b>IRM</b>	Imagerie Par Résonance Magnétique.
<b>DSTA</b>	Démence Sénile Type Alzheimer
<b>ADN</b>	Acide désoxyribonucléique.
<b>ML</b>	Machine Learning
<b>DL</b>	Deep Learning
<b>MV</b>	Vision par ordinateur.
<b>NLP</b>	Traitement automatique du langage naturel.
<b>ANN</b>	Réseau neuronal artificiel.
<b>DNN</b>	Réseau de neurones profond.
<b>EEG</b>	Electro encephalo graphy
<b>HOG</b>	Histogram of Oriented Gradients
<b>LBP</b>	Local Binary Patterns
<b>SIFT</b>	Scale Invariant Feature Transform
<b>CART</b>	Classification And Regression Trees
<b>KPPV</b>	K-Plus Proches Voisins
<b>SVM</b>	Support Vector Machine
<b>DRB</b>	Deep Rule-Based Classifier
<b>FRB</b>	Fuzzy Rule Based
<b>SSDRB</b>	Semi-supervised Deep Rule-based
<b>TP</b>	true positive

<b>TN</b>	true négative
<b>FP</b>	false positive
<b>FN</b>	false négative
<b>ROC</b>	Receiver Operating Characteristic)
<b>TVP</b>	taux des vrais positifs
<b>TFN</b>	Taux des faux négatifs

*Chapitre I :*  
*Introduction générale*

## **I.1.Contexte général:**

L'avenir de la pratique médicale « standard » pourrait être là plus tôt que prévu, où un patient pourrait voir un ordinateur avant de voir un médecin. Grâce aux progrès de l'intelligence artificielle (IA), il semble possible que l'époque des diagnostics erronés et du traitement des symptômes de la maladie plutôt que de leur cause profonde passe derrière nous. Pensez au nombre d'années de mesures de la pression artérielle dont vous disposez ou à la quantité de stockage que vous auriez besoin de supprimer pour faire tenir une image 3D complète d'un organe sur votre ordinateur portable ? L'accumulation de données générées dans les cliniques et stockées dans des dossiers médicaux électroniques grâce à des tests communs et à l'imagerie médicale permet davantage d'applications de l'intelligence artificielle et de la médecine basée sur les données de haute performance. Ces applications ont changé et continueront de changer la façon dont les médecins et les chercheurs abordent la résolution de problèmes cliniques.

Semblable à la façon dont les médecins sont formés au cours d'années d'études en médecine, en faisant des devoirs et des examens pratiques, en recevant des notes et en apprenant de leurs erreurs, les algorithmes d'IA doivent également apprendre à faire leur travail. En règle générale, les tâches que les algorithmes d'IA peuvent effectuer sont des tâches qui nécessitent une intelligence humaine, telles que la reconnaissance de formes et de la parole, l'analyse d'images et la prise de décision. Cependant, les humains ont besoin de dire explicitement à l'ordinateur ce qu'ils rechercheraient dans l'image qu'ils donnent à un algorithme, par exemple. En bref, les algorithmes d'IA sont parfaits pour automatiser des tâches ardues et peuvent parfois surpasser les humains dans les tâches pour lesquelles ils sont formés.

## **I.2.Problématique :**

Dans notre vie de tous les jours, la classification nous aide à prendre les décisions. Le besoin de classification survient chaque fois qu'un objet est placé dans un groupe ou une classe spécifique selon les attributs correspondant à cet objet. La plupart des industriels les problèmes sont des problèmes de classification. Les scientifiques ont conçu des techniques de classification avancées pour améliorer précision de la classification. Chaque jour, de nombreuses images sont produites, ce qui crée la nécessité de les classer de sorte que l'accessibilité est plus facile et plus rapide. Le traitement de l'information ce qui est fait lors du classement aide à l'image catégorisation en divers groupes, les problèmes de classification

peuvent être résolus mathématiquement et de façon non linéaire. Ce type de la résolution de problèmes est assez difficile en raison de la précision et la distribution des propriétés des données et des capacités du modèle.

Par voie de conséquence, la problématique traitée dans ce mémoire est la détection intelligente d'une pathologie cérébrale choisie, pour l'aide à la décision pour les diagnostics thérapeutiques médicaux.

### **I.3.Objectifs et contribution :**

L'objectif défini dans notre travail est :

- analyser l'état de l'art pour la classification pathologiques utilisons les techniques de l'intelligence artificielle.
- étudier différents algorithmes de classification.
- développer une approche pour classer automatiquement les tumeurs cérébrale dans les différents types pathologiques
- utiliser et tester un nouveau classifieur SSDRB dans le domaine médical.

### **I.4.Organisation du manuscrit :**

L'organisation de notre mémoire est décline comme suite :

- **Chapitre I** : présente une introduction générale, problématique et les objectifs.
- **Chapitre II** : présente une explication générale sur l'intelligence artificielle (IA) et sa position dans le domaine médical, Le système nerveux central (SNC), et les quatre régions principales puis les différentes pathologies cérébrales et les méthodes d'IA.
- **Chapitre III** : présente la classification et ses grandes étapes puis expliquer les différents algorithmes de classification.
- **Chapitre IV** : Présente l'approche proposée et les résultats obtenus dans le cadre de cette étude.

La conclusion et les perspectives de ce travail seront présentées à la fin de mémoire.

***Chapitre II :***  
***Généralités***



## II.1. Introduction :

Pour comprendre ce qu'est l'intelligence artificielle (IA), nous avons besoin de comprendre ce que l'on entend par « intelligence ». L'intelligence est un concept complexe. Les scientifiques qui étudient l'intelligence cherchent encore la réponse à de nombreuses questions L'intelligence est-elle héritée de nos parents? La taille du cerveau a-t-elle un rapport quelconque avec l'intelligence? Pour cela les chercheurs posent une question simple : il est possible de faire penser les machines « comme des humains » ? En d'autres termes, il est possible d'effectuer des tâches telles que raisonner, planifier, apprendre et comprendre notre langage ? Nous avons répondu dans ce cas dans l'intelligence artificielle (IA).

Dans ce chapitre, nous avons défini l'intelligence artificielle et présenté l'apprentissage automatique et profond, nous avons parlé la relation de (IA) dans le domaine médical ensuite, nous avons défini le système nerveux central (SNC) avec les quatre régions principales Enfin, nous situons quelques pathologies cérébrales.

## II.2. L'Intelligence artificielle :

La définition la plus simple de l'intelligence artificielle est celle de Larousse : « Ensemble de théories et de techniques mises en œuvre, en vue de réaliser des machines capables de simuler l'intelligence humaine. » Marvin Lee Minsky, un des fondateurs de l'IA, la définissait comme « la construction de programmes informatiques, qui s'adonnent à des tâches qui ne sont, pour l'instant, accomplies de façon satisfaisante que par des êtres humains, car elles demandent des processus mentaux de haut niveau tels que : l'apprentissage perceptuel, l'organisation de la mémoire et le raisonnement critique». Les progrès récents rendent partiellement obsolète cette définition datant des débuts de l'IA. Le développement constant de cette technologie explique donc en partie les difficultés dans l'établissement d'une définition consensuelle. Les deux points communs des définitions existantes sont : Le caractère « artificiel » par l'usage de l'informatique avec des algorithmes et de 4 l'électronique avec des processeurs. Le second point est son caractère « intelligent » ? Qui lui permet d'effectuer des tâches cognitives généralement attribuées à l'homme [7] :

- Traitement du langage naturel pour communiquer avec succès.
- Stockage des données et des connaissances.

- Raisonnement logique automatique pour répondre de manière adéquate aux stimuli environnementaux.
- Capacité d'apprentissage pour le réajustement des réactions. [7]

## II.2.1 méthodes de l'IA :

### II.2.1.1 : Big Data :

Le concept du Big Data répond à la règle des 3V. Il doit contenir :

- Un grand Volume de données à traiter
- Une Variété d'informations de diverses sources
- Un certain niveau de Vélocité, à atteindre, c'est-à-dire la rapidité de génération et de traitement des données. [7]




Figure II.1 : Les 3 V du Big Data [7]

Dans le domaine de la santé, différents types de données sont utilisées : (Figure II. 2)

- Cliniques, issues de l'interrogatoire et de l'examen clinique réalisé par le médecin.
- Biologiques, provenant du prélèvement des liquides biologiques.
- (Sang, urines et liquide céphalorachidien ...)
- Imagerie : permettant de mettre en image différents organes.
- Génétiques : apportant des informations relatives à la santé des patients en cherchant des anomalies sur l'ADN. [7]

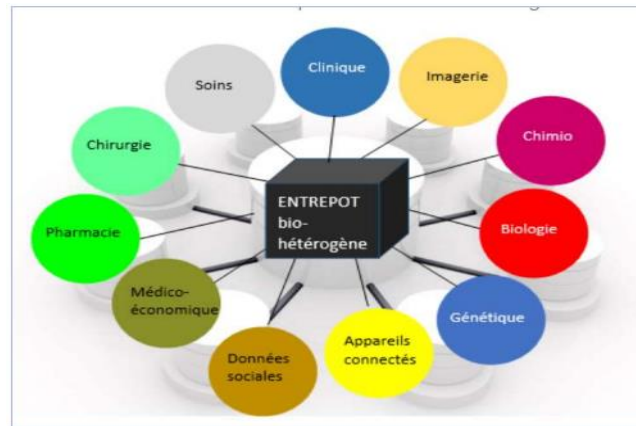


Figure II. 2 : les types de données utilisées dans le domaine de santé [7]

Le Big Data permet à l'intelligence artificielle de stocker un volume important de données, structurées et non structurées, avec une vitesse de traitement satisfaisante afin d'en extraire du sens, de prendre des décisions rapides et d'apprendre à aboutir à des résultats excellents ... ceci a permis d'obtenir des avancées considérables dans l'apprentissage de la machine intelligente.[7]

### II.2.1.2.L'apprentissage automatique :

L'idée de base de l'apprentissage automatique est la suivante : Si un programme informatique a une tâche spécifique, comment faire en sorte que le programme apprenne de sa propre expérience lors de l'exécution de la tâche pour qu'il puisse mieux exécuter la même tâche dans l'avenir ? Mare à différencier entre l'intelligence artificielle et l'apprentissage machine (ML) en disant que l'IA est un concept plus large de machines capables d'exécuter des tâches d'une manière que nous considérons comme "intelligente", et le ML est une application courante de l'IA basée sur l'idée que nous devrions simplement donner aux machines l'accès à des données pour qu'elles apprennent par elles-mêmes.[7]

Le domaine de l'apprentissage automatique peut être divisé en trois sous domaines :

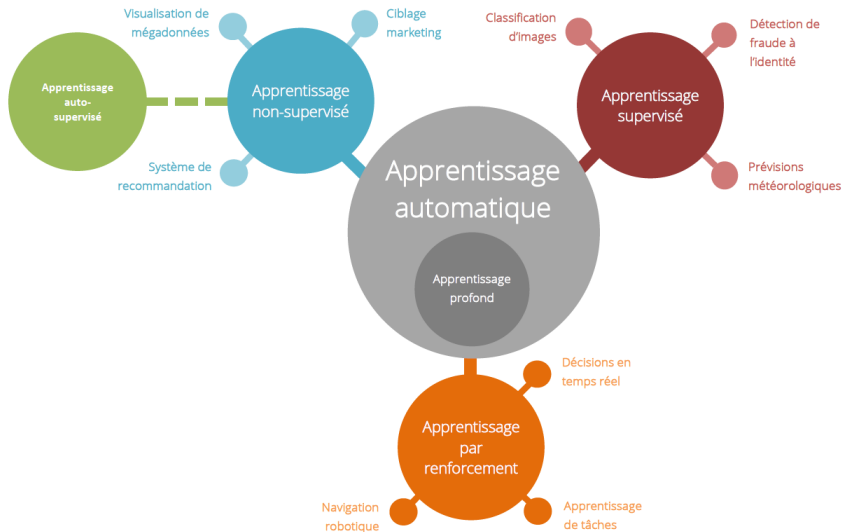


Figure II.3 : les types de l'apprentissage automatique [8]

### II.2.1.2.1.L'apprentissage supervisé :

Signifie que le système apprend à classer selon un modèle de classification.

Le processus se passe en deux phases. Lors de la première phase (dite d'apprentissage), il s'agit de déterminer un modèle à partir des données étiquetées (par un expert). La seconde phase (dite de test) consiste à prédire l'étiquette d'une nouvelle donnée, en se basant sur le modèle préalablement appris. [7] Un exemple serait la reconnaissance d'un cancer :

Phase d'apprentissage : des entrées à types d'images étiquetées (cancer ou pas cancer). Le système apprend alors à quoi ressemble un cancer à partir de ces images de formation (modèle de classification).

Phase de test : afin de vérifier le succès de la formation, une image inconnue est présentée au système et celui-ci doit être capable de dire à partir des caractéristiques précédemment apprises si l'image montre un cancer au pas cancer




Figure II. 4:exemple d'un apprentissage supervisé [9]



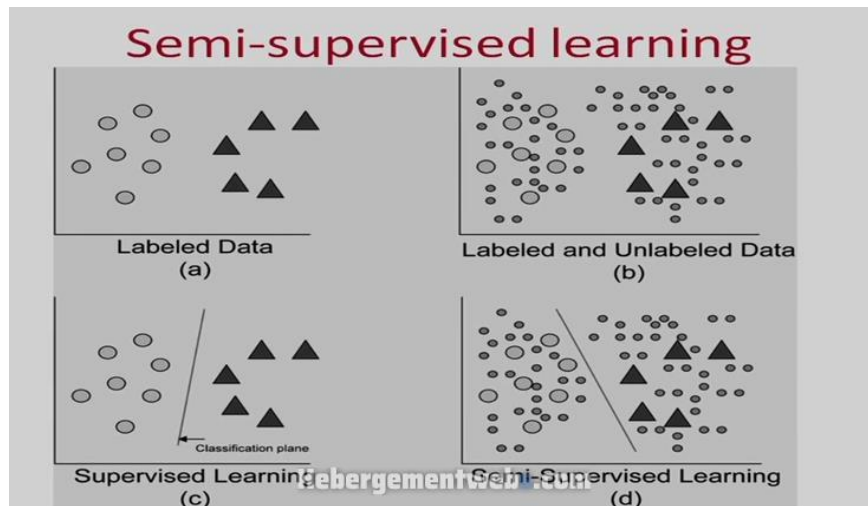


Figure II.6: exemple d'un apprentissage semi-supervisé [11]

### II.3.1.3. Apprentissage profond :

L'apprentissage profond ou apprentissage en profondeur (DL) est un ensemble de méthodes d'apprentissage automatique (ML), supervisés ou non supervisés, tentant de modéliser avec un haut niveau d'abstraction des données, et ceci en utilisant un modèle de DNN multicouche à d'énormes quantités de données .

Le DL a permis des progrès importants dans les domaines :

- De l'analyse des signaux visuels ou sonores,
- De la reconnaissance faciale, de la reconnaissance vocale,
- De la vision par ordinateur MV,
- Et du NLP.

Le DL est le plus utilisé en médecine, en particulier en radiologie, en dermatologie et en anatomopathologie... les ordinateurs permettent d'évaluer et d'apprendre à partir de milliers d'images, ce qui peut aider les médecins et faciliter leurs tâches quotidiennes. [7]

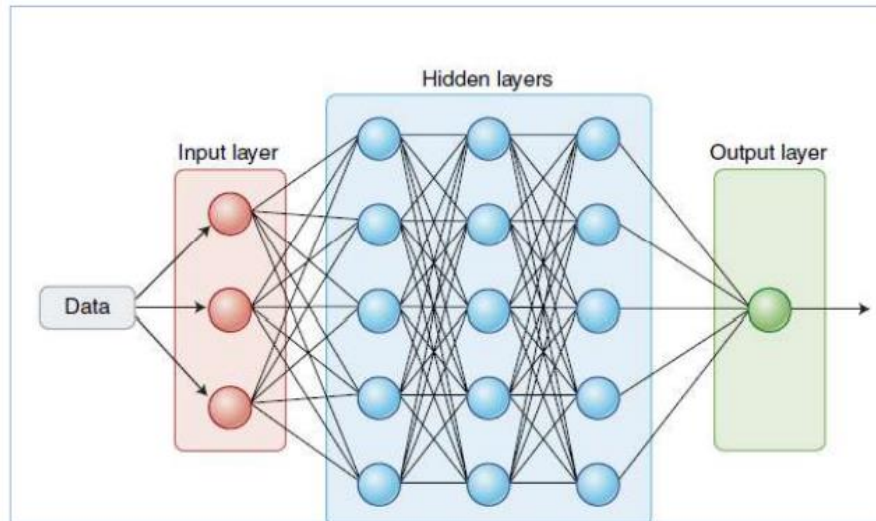


Figure II.7 : les réseaux de neurones profonds [7]

Les réseaux de neurones artificiels (ANN), sont composés de nombreuses unités de calcul appelées « neurones » (cercle rouge en pointillé) qui reçoivent des entrées de données (similaires aux dendrites dans les neurones biologiques), effectuent des calculs et transmettent une sortie (similaire aux axones) au neurone suivant. Les neurones d'entrée reçoivent des données, tandis que les neurones de couche cachée (de nombreuses couches cachées différentes peuvent être utilisées) effectuent les calculs nécessaires pour analyser les relations complexes dans les données. Les neurones de la couche cachée envoient ensuite les données à une couche de sortie qui fournit la version finale de l'analyse pour interprétation. Les ANN sont dites peu profondes lorsqu'elles n'ont qu'une seule couche cachée (c'est-à-dire une couche entre l'entrée et la sortie). Ils sont dits profonds DNN lorsque les couches cachées sont multiples. [7]

Pour résumer les derniers paragraphes, il est nécessaire de délimiter à nouveau brièvement les trois termes IA, ML et DL.

L'intelligence artificielle en général comprend les systèmes intelligents simulant la pensée et le comportement humains. L'apprentissage automatique est un sous-domaine de l'IA et comprend des processus, qui permettent aux ordinateurs d'apprendre par l'expérience.

L'apprentissage profond est un sous-domaine de l'apprentissage automatique et comprend des DNN multicouches, qui apprennent par une hiérarchie de concepts, étant appliquée à d'énormes ensembles de données.




Figure II.8 : la relation entre l'intelligence artificielle, le ML et le deep Learning [12]

### II.3. L'intelligence artificielle (IA) dans le domaine médical :

L'émergence de l'intelligence artificielle (IA), dont les premiers concepts datent des années 1950 dans le domaine médical est la conséquence de trois bouleversements radicaux : la numérisation des images médicales permettant leur paramétrage, le développement des algorithmes autorisant l'utilisation des données saisies en langage naturel, et l'apprentissage profond (*deep learning*) permettant à partir de données radiologiques massives de développer des algorithmes de traitement automatique d'images médicales. Ces systèmes permettent dès aujourd'hui la détection automatique de lésion et ouvre la voie au dépistage du cancer du poumon, du sein ou de la prostate. Leur fiabilité est supérieure à celles des radiologues. Intégrées aux données médicales cliniques, biologiques, génétiques, ces techniques modifient considérablement l'organisation et la structuration du monde de la santé. [1]

L'intelligence artificielle médicale (IA) utilise principalement des techniques informatiques pour effectuer des diagnostics cliniques et proposer des traitements. L'IA a la capacité de détecter des relations significatives dans un ensemble de données et a été largement utilisée dans de nombreuses situations cliniques pour diagnostiquer, traiter et prédire les résultats.



### II.3.1. L'imagerie par résonance magnétique (IRM) :

L'imagerie par résonance magnétique (IRM) constitue une des avancées les plus significatives en médecine ; elle est issue des travaux sur les propriétés magnétiques des noyaux des atomes menés par F. Bloch et E. Purcell en 1946. Aujourd'hui, elle constitue une technique privilégiée pour l'observation in vivo des structures anatomiques cérébrales et de leurs pathologies. [2]

L'IRM est une modalité d'imagerie médicale utilisée le plus souvent à des fins de diagnostic. Le patient est placé dans un puissant champ magnétique qui va stimuler les noyaux d'hydrogène trouvés dans les molécules d'eau du corps humain et orienter leurs aimantations propres (ou spins) dans le même sens. Ensuite, des impulsions électromagnétique appelées ondes radiofréquence sont émises puis relâchées dans le but de détourner les spins de leur alignement afin de générer un signal de résonance magnétique qui sera capté par l'appareil. Grâce a des algorithmes de Reconstructions d'images, il est alors possible de former des images 3D représentant les propriétés spécifique des tissus relativement à ces stimuli électro-magnétiques. L'IRM est souvent utilisée pour la planification des chirurgies ainsi que dans plusieurs recherches cliniques dans l'étude de la scoliose.



Figure II.9 : Acquisition par IRM [3]

### II.3.2. Système nerveux central :

Le système nerveux central (SNC), ou névraxe, se divise en quatre régions principales : la moelle épinière, le tronc cérébral, le cervelet et le cerveau. L'encéphale, qui se compose essentiellement de matière blanche, de matière grise et de liquide céphalo-rachidien, représente l'ensemble des parties du névraxe localisées dans la cavité crânienne, c'est-à-dire le tronc cérébral, le cervelet et le cerveau. [2]

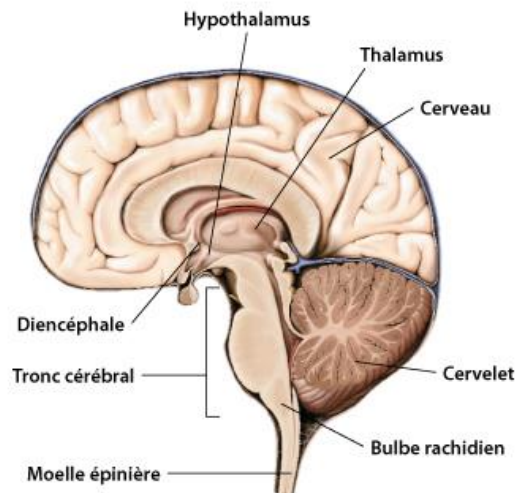


Figure II.10 : Le système nerveux central (SNC) [4]

#### II.3.2.1. La moelle épinière :

La moelle épinière (appelée aussi moelle spinale) fait référence au prolongement du système nerveux central qui se situe en dessous du tronc cérébral. Elle est contenue au sein du canal rachidien qui lui sert de support et de protection. Constituée de neurones et de cellules gliales, elle arbore une forme aplatie avec un diamètre d'environ 0.5 cm. Ses fonctions principales sont de relayer les informations motrices aux muscles, relayer les informations sensorielles au cerveau, et la gestion de certains réflexes. [5]

#### II.3.2.2. Le cervelet :

Le cervelet est une composante de l'encéphale responsable principalement de la régulation de la fonction motrice (équilibre, posture, mouvement) et dans une moindre mesure, des fonctions cognitives telles que l'attention, le langage, ou encore le plaisir. Il est situé au niveau de la fosse crânienne postérieure. Il reçoit des informations de la moelle épinière, du cerveau, ainsi que du tronc cérébral, et le traitement qu'il en fait donne au programme qui contrôle le mouvement une organisation chronologique et spatio-temporelle cohérente. [5]

### II.3.2.3. Le tronc cérébral :

Le tronc cérébral est une composante de l'encéphale située au niveau de la fosse crânienne postérieure entre le cerveau à proprement dit et la moelle épinière. Il s'occupe principalement de la régulation du rythme cardiaque, de la respiration, ainsi que de la douleur. Il constitue aussi une importante zone de passage pour les voies motrices et sensibles. [5]

### II.3.2.4. Le cerveau :

Le cerveau constitue la plus grande partie de l'encéphale. Il ne représente que 2% du poids total du corps humain et pourtant il est responsable de la gestion de la quasi-totalité des fonctions biologiques des plus basiques (mouvements, sommeil,..., etc.) aux plus complexes (émotions, raisonnement,..., etc.). Il est composé de deux hémisphères ; droit et gauche dont la surface présente de nombreuses circonvolutions limitées par des sillons. Sa structure spatiale fait aussi apparaître 4 régions distinctes s'occupant chacune de fonctions différentes : le lobe occipital (la vision), le lobe pariétal (le calcul, l'orientation spatiale), le lobe temporal (le langage, la mémoire, l'interprétation des sons), et le lobe frontal (le raisonnement abstrait : planification, conceptualisation). [5]

## II.3.3 les pathologies cérébrales :

Une maladie neurologique est une pathologie touchant le système nerveux, central ou périphérique. Elle peut donc affecter des cellules nerveuses se trouvant dans le cerveau, la moelle épinière, les nerfs périphériques, les jonctions neuromusculaires, le système nerveux autonome... certaines maladies neurologiques sont associées au vieillissement, comme la maladie d'Alzheimer ou la maladie de parkinson.

Dans le cadre de cette thèse, les pathologies cérébrales sont divisées en six catégories :

- **Traumatismes crâniens** : on cite Les hématomes intracrâniens, Les engagements cérébraux, Les contusions cérébrales.
- **pathologies tumorales encéphaliques** : es tumeurs neuroépithéliales, Tumeurs de la gaine des nerfs, Les tumeurs malformatives
- **Pathologies neurodégénératives** : Démence Sénile Type Alzheimer (DSTA), Maladie d'Alzheimer, Maladie de Parkinson.
- **Pathologies infectieuses intracrâniennes** : Les infections bactériennes, Parasitoses

- **Pathologies vasculaires cérébrales :** Les accidents vasculaires cérébraux ischémiques, Les accidents vasculaires cérébraux hémorragiques.
- **Affections de la substance blanche :** pathologies démyélinisantes, Pathologies dysmyélinisantes.




Figure II.11 : IRM montre exemple de tumeur Meningioma [6]

#### I.4.conclusion :

Avec l'IA, les professionnels de la santé peuvent s'attaquer à des problèmes complexes difficiles à résoudre seuls ou qui nécessitent beaucoup de temps. L'IA peut être une ressource précieuse pour les professionnels de la santé, leur permettant de mieux utiliser leur expertise et de créer de la valeur dans tout l'écosystème de la santé.

***Chapitre III :***  
***La classification***

### **III.1 Introduction :**

La classification des images est le domaine principal, dans lequel les réseaux de neurones profonds jouent le rôle le plus important de l'analyse d'images médicales.

Dans ce chapitre, nous présenterons tout d'abord ce que c'est la classification, ses méthodes, Ses étapes, ensuite on détaillera le processus de classification et on présentera quelques algorithmes de classification avec leurs avantages et leurs inconvénient.

### **III.2 La classification :**

La classification est une discipline relié de près ou de loin a plusieurs domaines, elle est connue aussi sous noms variés (classification, clustering, segmentation,. . .) selon les objets qu'elle traite et les objectifs qu'elle vise à atteindre.

la classification se définit alors comme une méthode mathématique d'analyse de données, pour faciliter l'étude d'une population d'effectif important, généralement des bases d'observations caractérisent un domaine particulier (animaux, plantes, malades, gènes,. . . etc.), où on les regroupe en plusieurs classes. [13]

### **III.3 Exemples de problèmes de classification :**

Nous avons présenté les domaines que la classification pourrait viser :

#### **III.3.1 Prédiction e-mail / Spam :**

Comme le fait de différencier un E-mail valide d'un SPAM , d'ailleurs la classification est fort utile en ce qui concerne la catégorisation des documents sur internet quel que soit la nature du document ( image , fichier , son . . .etc) et elle peut même être utilisée pour classifier les document selon leur sens (le web sémantique et les moteurs de recherche où on associe des sens pour les termes et pour les classifier il faut développer un langage de traitement/classification sémantique par exemple à base d'ontologie).[13]

e-mail valide	SPAM
<p><u>From</u> : KOUDRI                      &lt;KOUDRI_MOHAMMED@LIVE.fr&gt;                      To : <u>Mr</u> BENAZOUZ &lt;BENAZOUZ@UNIV_TLEMCEN.fr&gt;</p> <p><u>Subject</u> : SALAM !                      Au fait, j'ai oublié de vous dire [...]</p> <p>Koudri</p>	<p>From : Pugh F Trina                      &lt;LarsenSRTQG@power.ufscar.br&gt;                      To : hue@ensmp.fr, hulin@ens.fr,                      item@ens.fr,jacq@ens.fr</p> <p>Subject: ENTIRE AMERICANHOSPITAL                      RESOURCE,                      NEW! NEW! INTRODUCTORY OFFER!                      JUST RELEASED!                      In a rapidly-changing industry, current                      healthcare information                      is an invaluable resource to businesses and                      organizations.                      The United States Healthcare Email                      Database includes [...]</p>

Figure III.1 : E-mail valide / SPAM [13]

### III.3.2 Reconnaissance de formes :

Généralement c'est une question qui vise à reconnaître ou identifier certain motifs à partir de données brutes afin de prendre une décision dépendant de la catégorie attribuée à ce motif, ces motifs (formes) peuvent s'agir d'une image (visage, empreinte digitale, rayon X, EEG,...) ou sonore (reconnaissance de parole) [13]



Figure III.2 : reconnaissance du caractère manuscrit [13]

### III.3.3 Des Tableaux :

comme les données bancaires : ce type de données est représenté sous forme des tableaux  $N \times M$  où  $N$  le nombre d'exemples ( individus , objets ) et  $M$  l'ensemble des descripteurs ou qualité de ce qui a été décrit ( attributs ) la case  $(i,j)$  de ce tableau contient l'information relative de l'élément  $j$  sur  $i$  ; le rôle de la classification dans ce cas , consiste à déterminer le comportement d'un individu par rapport a ce qu'on a appris des autres ( base d'apprentissage) [13]

Transactions nationales	Taux de fraude (Montant de la fraude, en millions d'euros)			
	2004	2005	2006	2007
<b>Palements</b>	<b>0,036 %</b> <b>(81,2)</b>	<b>0,033 %</b> <b>(82,8)</b>	<b>0,035 %</b> <b>(92,3)</b>	<b>0,032 %</b> <b>(95,6)</b>
- dont paiements de proximité et sur automate	0,029 % (63,5)	0,025 % (59,2)	0,024 % (59,1)	0,017 % (45,4)
- dont paiements à distance	0,177 % (17,7)	0,196 % (23,6)	0,199 % (33,2)	0,236 % (50,1)
- dont par courrier / téléphone	nd	nd	0,194 % (18,8)	0,201 % (23,8)
- dont sur Internet	nd	nd	0,208 % (13,4)	0,281 % (26,4)
<b>Retraits</b>	<b>0,027 %</b> <b>(22,7)</b>	<b>0,017 %</b> <b>(15,0)</b>	<b>0,019 %</b> <b>(17,4)</b>	<b>0,020 %</b> <b>(19,0)</b>
<b>Total</b>	<b>0,033 %</b> <b>(103,9)</b>	<b>0,029 %</b> <b>(97,8)</b>	<b>0,031 %</b> <b>(109,6)</b>	<b>0,029 %</b> <b>(114,5)</b>

Figure III.3 : données bancaires [13]

### III.3.4 Classification des images :

La classification d'images est un problème fondamental en vision par ordinateur, qui a de nombreuses applications concrètes. Le but est de construire un système capable d'assigner correctement une catégorie à n'importe quelle image en entrée. Un tel système exploite des algorithmes de Machine Learning issus de l'apprentissage supervisé.

## III.4 .Les étapes d'une classification :

Un système de classification automatique d'images est composé des étapes suivantes :

### III.4.1. Choix des données :

Chaque classification nécessite un ensemble de données par exemple la classification des images médicales nécessite des bases de données des images pour commencer la procédure de classification.



### III.4.2. Pré-traitement :

Cette phase a pour but de nettoyer l'image, c'est-à-dire d'isoler le contenu informatif ou d'intérêt dans l'image. Cette opération permet ainsi d'occulter ou d'atténuer toute information susceptible de nuire à la description du contenu pertinent lors de la phase d'extraction de caractéristiques. On retrouve ainsi des techniques d'atténuation de bruits, de renforcement de contours, des techniques d'amélioration de l'image comme le rehaussement de contraste, la réduction de la dimension de l'image par la binarisation, la réduction de l'image à ses primitives visuelles comme la squelettisation ou encore l'extraction de contours à l'aide de techniques de filtrage. Les étapes nécessaires de cette phase sont : lire l'image, redimensionner l'image et utiliser quelques techniques d'augmentation des données.

### III.4.3. Extraction des caractéristiques :

L'extraction de caractéristique est une étape importante dans le processus de la classification. Cette étape consiste à convertir chaque image d'entrée du système en un vecteur de caractéristiques contenant plus d'information avec dimension réduite. Plusieurs techniques d'extraction sont proposées :

#### III.4.3.1. Extracteurs de bas-niveau :

- **Histogram of Oriented Gradients(HOG) :**

Les descripteurs HoG sont introduits par Naveet Dalal et Bill Triggs, chercheurs à l'INRIA de Grenoble, à la conférence CVPR de juin 2005 dans leurs travaux de détection des piétons. L'idée essentielle derrière l'histogramme de gradient orienté c'est que l'apparence locale et la forme d'objet dans une image peut être décrite par la distribution d'intensité des gradients ou de direction des contours. La mise en œuvre de ces descripteurs peut être obtenue en divisant l'image en petites régions connectées, appelées cellules, et pour chaque cellule on calcule un histogramme des directions de gradient ou des orientations de contour pour les pixels dans la cellule. La combinaison de ces histogrammes représente alors le descripteur. Le descripteur HoG maintient quelques avantages clés par rapport aux autres méthodes. Puisque le descripteur histogramme de gradient orienté « HoG » opère sur les cellules localisées, la méthode maintient l'invariance à des transformations géométriques et photométriques, ces changements ne feront leur apparition que dans les larges régions d'espaces. [14]




Figure III.4 : image gradients and spatial/orientation Binnig [15]

- **GIST extracteur :**

GIST est un descripteur d'image développé par Oliva et al. Qui se base sur une représentation en très faible dimension d'une image donnée qui est surnommée l'Enveloppe Spatiale. Ils ont proposé un ensemble de dimensions perceptives (naturel, ouverture, rugosité, expansion, rugosité) afin de représenter la structure spatiale dominante d'une scène donnée. Par la suite, ils ont démontré que ces dimensions pouvaient être estimées efficacement en utilisant les informations spectrales et grossièrement localisées. Leur modèle a généré un espace multidimensionnel dans lequel des scènes qui partagent l'appartenance à des catégories sémantiques telles que les rues, les autoroutes, les côtes ont été projetées fermées ensemble. Les performances du modèle d'enveloppe spatiale ont prouvé que des informations spécifiques sur la forme ou l'identité de l'objet n'étaient pas nécessaires pour la catégorisation de la scène et que la modélisation de la représentation holistique de la scène fournissait des informations sur sa catégorie sémantique probable. Oliva et al. ont appliqué la méthodologie sur la reconnaissance d'objets. Dans notre approche, nous étendons leur philosophie à la reconnaissance de visage. [16]

### III.4.3.2. Extracteurs de plus haut niveau:

- **III.4.3.2.1. Local Binary Patterns (LBP) :**

L'opérateur de motif binaire local (LBP) est une statistique primitive de texture invariante en échelle de gris, qui a montré d'excellentes performances au classement de divers types de textures. Pour chaque pixel d'une image, un code binaire est produit en souillant son voisinage avec la valeur du pixel central. Le code LBP du pixel central du quartier est obtenu en convertissant le code binaire en un décimal. Basé sur l'opérateur LBP, chaque pixel d'une image est étiqueté avec un code LBP. Le 256- l'histogramme bin des étiquettes contient la

densité de chaque étiquette et peut être utilisé comme descripteur de texture de la région considérée. Le processus d'extraction des fonctionnalités LBP est résumé comme suit:

Tout d'abord, une image faciale est divisée en plusieurs blocs non superposés. Deuxièmement, les histogrammes LBP sont calculés pour chaque bloc. Enfin, le bloc LBP les histogrammes sont concaténés en un seul vecteur. Comme un résultat, l'image du visage est représentée par le LBP code. La figure III.5 présente le processus de la fonction LBP extraction




Figure III.5: Le processus d'extraction LBP [17]

- **Scale Invariant Feature Transform (SIFT) :**

SIFT (Scale Invariant Feature Transform) propose par Lowe, 2004, est à la fois un détecteur et un descripteur de points d'intérêts dans l'image de la famille des histogrammes de gradients orientés. Les caractéristiques principales résident dans ses nombreuses invariances aux transformations affines, au changement d'échelles (ou résolution), de perspectives de faible distorsion et sa robustesse au bruit, à l'occlusion et à l'illumination dans l'image. SIFT est une approche générique et est considérée comme l'une des approches les plus performantes de la littérature. [18]




Figure III.6 : Construction d'un descripteur SIFT. [19]

- **AlexNet :**

Est un réseau de neurones convolutifs de 8 couches de profondeur. Vous pouvez charger une version pré-entraînée du réseau entraînée sur plus d'un million d'images de la base de données ImageNet. Le réseau pré-entraîné peut classer les images en 1000 catégories d'objets, telles que le clavier, la souris, le crayon et de nombreux animaux. En conséquence, le réseau a appris de riches représentations de caractéristiques pour un large éventail d'images. Le réseau a une taille d'entrée d'image de 227 par 227. [20]




Figure III.7 : Schéma du réseau AlexNet utilisé. [21]

- **VGG-16 :**

VGG16 est un modèle de réseau de neurones à convolution conçu par K. Simonyan et A. Zisserman. On retrouve les détails d'implémentation dans le document « Very Deep Convolutional Networks for Large-Scale Image Recognition ». Ce modèle atteint une précision de test de 92,7% dans ImageNet, qui regroupe plus de 14 millions d'images appartenant à 1000 classes. [22]

### III.4.4.Choix d'un algorithme de classification et exécution :

Une fois l'ensemble des caractéristiques utilisées pour la classification fixé, la dernière étape est la classification. C'est la phase la plus importante qui permet de classer des objets d'après leurs représentations. Le but de cette étape est de construire une fonction de décision à partir de données d'apprentissage projetées dans cet espace de description.

### III.5. méthodes de classification :

Nous nous intéressons dans cette section aux méthodes d'apprentissage standards de littérature, il existe plusieurs algorithmes de classification qui nous allons présenter :

### III.5.1. Arbre de décision :

L'arbre de décision est une méthode de classification popularisée par Breiman et al. via la monographie dans laquelle l'algorithme "Classification And Regression Trees" (CART) a été introduit. L'algorithme est jusqu' à présent très populaire dans divers domaines avec des applications comme la détection de tumeurs musculaires la détection de tuberculose pulmonaire la classification de l'émotion la reconnaissance d'activités physiques réalisées par un individu ou encore la classification de types d'occupation de sols dans le domaine de l'imagerie par satellite.

Il s'agit d'une méthode de classification qui décompose le domaine d'apprentissage en des sous-domaines les plus purs possibles, i.e. contenant une population la plus homogène possible en terme de classes, en utilisant une structure hiérarchique séquentielle partitionnant de façon récursive l'espace de caractéristiques.[18]

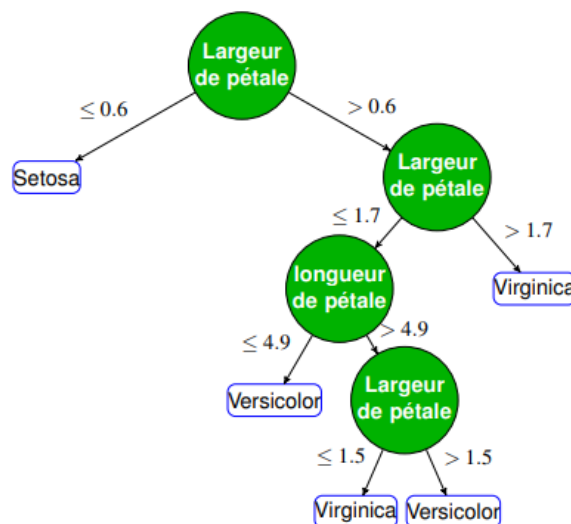


Figure III.8 : Illustration de la construction d'un arbre de décision à partir des données de la base Iris [18]

- **Les avantages :** La simplicité de compréhension et d'interprétation.
- **Inconvénients :** L'existence d'un risque de sur-apprentissage si l'arbre devient très complexe. On utilise des procédures d'élagage pour contourner ce problème.

### III.5.2. K-Plus Proches Voisins (KPPV) (KNN) :

L'algorithme des K-Plus Proches Voisins (KPPV) est une approche basée sur l'estimation de distance. Il n'a pas besoin d'apprentissage car le modèle de classification est directement le set d'apprentissage (ce classifieur est ainsi dit à mémoire). Lors de la phase de décision, l'algorithme évalue la classe majoritaire des  $K$  individus du set d'apprentissage les plus proches de l'exemple un testeur.  $K$  représente un paramètre important de l'approche car il conditionne la façon dont le classifieur va s'adapter aux données en présence, la résolution du classificateur et sa généralité. Si la valeur de  $K$  est faible, on obtient un classifieur dit de bonne résolution (très proche des données, avec ainsi un biais d'autant plus faible que  $K$  est petit), il arrive à définir des fonctions complexes entre les classes mais est très sensible aux bruits sur les données (le classifieur généralise mal d'où une variance élevée); si en revanche  $K$  est élevé, on obtient un classifieur qui lisse la frontière de décision donc peu sensible au bruit, avec une variance faible mais un biais élevé. Il est démontré qu'une façon de réduire l'erreur d'un classifieur est de diminuer à la fois son biais et un écart. Cependant, il est difficile de réduire l'un sans augmenter l'autre. [18]




Figure III.9 : méthode des k plus proches voisins [23]

- **Avantages :** simple à concevoir.
- **Inconvénients :** Sensible aux bruits, Pour un nombre de variable prédictif très grand, le calcul de la distance devient très coûteux

### III.5.3.Support Vector Machine (SVM) :

Le Support Vector Machine ou Séparateur à Vaste Marge(SVM) est un classifieur discriminant paramétrique établissant un hyperplan séparateur de marge maximale entre les exemples représentants de chacune des classes des données d'apprentissage.

Sur la (figure II.10), nous illustrons un problème de classification binaire en 2 dimensions. Il existe une infinité de droites séparatrices des deux classes en présence mais une seule maximise la distance aux exemples aux frontières des classes (i.e. maximise la distance  $z_2$  à l'hyperplan). Ces exemples frontières sont appelés vecteurs de support. Le SVM est l'un des algorithmes les plus cités dans la littérature en raison de ses performances, de sa généralité et de ses fondations théoriques. [18]

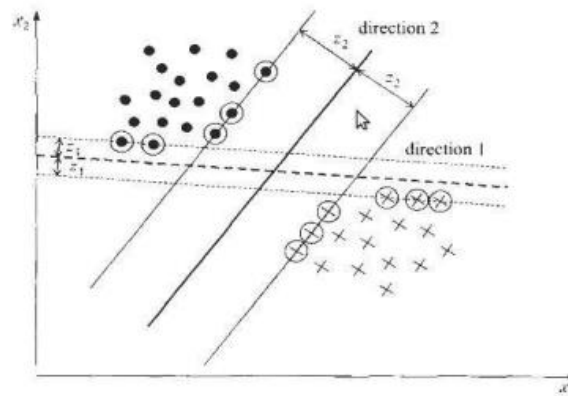


Figure III.10 : Hyperplan séparateur de marge maximale; deux jeux d'hyperplan, la direction 2 a la marge la plus forte; les vecteurs de supports sont ceux situés sur les droites frontières. [18]

- **Les avantages :** SVM s'adapte bien à des ensembles de données relativement volumineux.
- **Inconvénients :** Les SVM sont souvent moins performants que les forêts aléatoires

### III.5.4.Deep Rule-Based Classifier (DRB) :

Un nouveau type de classificateur multicouche basé sur des règles est proposé et appliqué à l'image problèmes de classement. L'approche proposée est entièrement basée sur les données et entièrement automatique. Il est générique et peut être appliqué à divers problèmes de classification et de prédiction, mais dans cet article, nous nous concentrons sur le traitement d'images, en particulier. Le noyau du classificateur est un ensemble entièrement interprétable, compréhensible et auto-organisé de SI... ALORS... des règles floues basées sur les prototypes identifiés de manière autonome en utilisant un processus d'apprentissage de type one-pass. Le classifieur peut s'auto-évoluer et être mis à jour en permanence sans un

recyclage complet. En raison du prototype nature, il est non paramétrique ; son processus d'apprentissage est non itératif, hautement parallélisable et informatique efficace. Dans le même temps, l'approche proposée est capable d'atteindre une précision de classification très élevée sur divers ensembles de données de référence dépassant la plupart des méthodes publiées, soient comparables aux capacités humaines. De plus, il peut commencer la classification à partir de la première image de chaque classe de la même manière que les humains, ce qui rend le classifieur proposé adapté aux applications en temps réel. Exemples numériques d'image de référence le traitement démontrent les mérites de l'approche proposée.

### III.5.4.1. Architecture générale du classifieur DRB :

L'architecture générale du classifieur DRB a été donnée Dans notre thèse, nous utilisons le Classificateur DRB avec une architecture telle que représentée sur la Figure III.11. Il se compose des composants suivants :

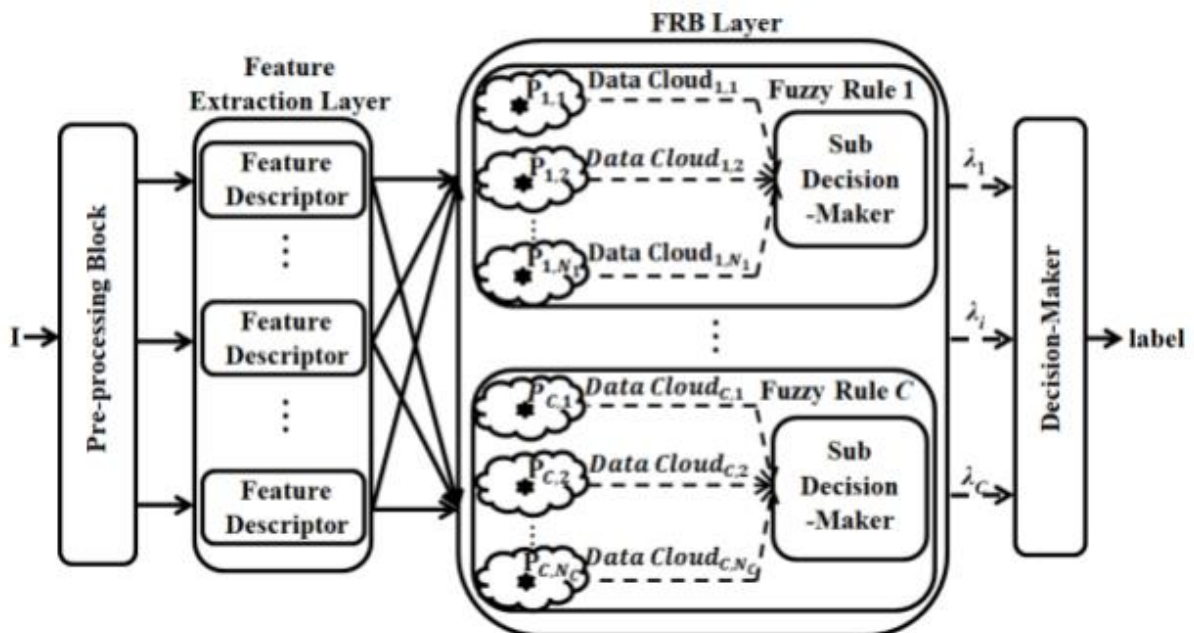


Figure III.11 : L'architecture générale du classifieur DRB [24]



#### III.5.4.1.1. pré-traitement. :

Le bloc de prétraitement du classifieur DRB n'implique que les techniques de prétraitement les plus fondamentales et les plus largement utilisées, à savoir : i) la normalisation, iii) la mise à l'échelle, ii) la rotation et iv) la segmentation d'image. Ainsi, il est, en fait, composé d'un certain nombre de sous-couches servant à des fins diverses. Le but principal du bloc de prétraitement dans le classifieur DRB est d'améliorer la capacité de généralisation du classifieur et d'augmenter l'efficacité des descripteurs de caractéristiques dans la collecte d'informations à partir de l'image. Une description plus détaillée des techniques de prétraitement que nous avons utilisées peut également être trouvée dans la section de processus de la classification.

#### III.5.4.1.2. Couche d'extraction de caractéristiques :

Le classifieur DRB peut utiliser différents types de descripteurs de caractéristiques qui sont utilisés dans le domaine de la vision par ordinateur. Différents descripteurs de fonctionnalités présentent différents avantages. Nous avons parlé des descripteurs de caractéristiques et des différents niveaux, deux descripteurs de caractéristiques de bas niveau et un de haut niveau dans la section de processus de la classification.

#### III.5.4.1.3. Ensemble massivement parallèle de règles SI. . . ALORS hautement interprétables :

Est un ensemble massivement parallèle de règles SI. . . ALORS C'est le «moteur» du classifieur DRB et il est basé sur les modèles à base de règles floues à développement autonome du type dit AnYa avec des singletons dans la partie conséquente (modèles d'ordre 0). AnYa représente un ensemble de règles non paramétriques SI. . . ALORS floues qui ne nécessitent pas que la fonction d'appartenance soit prédéfinie. Au lieu de cela, ils émergent automatiquement du modèle de données en suivant le concept d'analyse empirique des données. La structure d'une règle floue de type AnYa particulière est représentée sur ?? . Ainsi que. Comme on peut le voir, chaque règle floue utilisée dans cet article lui-même est une disjonction (opérateurs logiques «OU») d'un (potentiellement, grand) nombre d'ensembles flous formés à partir de nuages de données associés aux prototypes respectifs. Les prototypes eux-mêmes sont identifiés à l'aide d'un processus d'apprentissage de type en une seule passe, qui peut être massivement parallélisé si l'on considère chaque nuage de données / prototype comme une règle floue distincte. Le décideur local est un opérateur «gagnant-prend-tout».

**III.5.4.1.4. couche de décision :**

Est le décideur, qui décide de l'étiquette de classe gagnante sur la base des suggestions partielles des décideurs locaux / sous-décodeurs massivement parallèles par SI. . . ALORS règle / par classe. Cette couche n'est utilisée que pendant la phase de validation et applique également le principe du «gagnant-prend tout». En conséquence, on peut voir que le classifieur DRB proposé utilise en fait une structure de prise de décision en deux étapes.

• **Algorithme 1**

L'organigramme du processus d'apprentissage du sous-système FRB est représenté sur la figure III.12 (**algorithme 1**) :

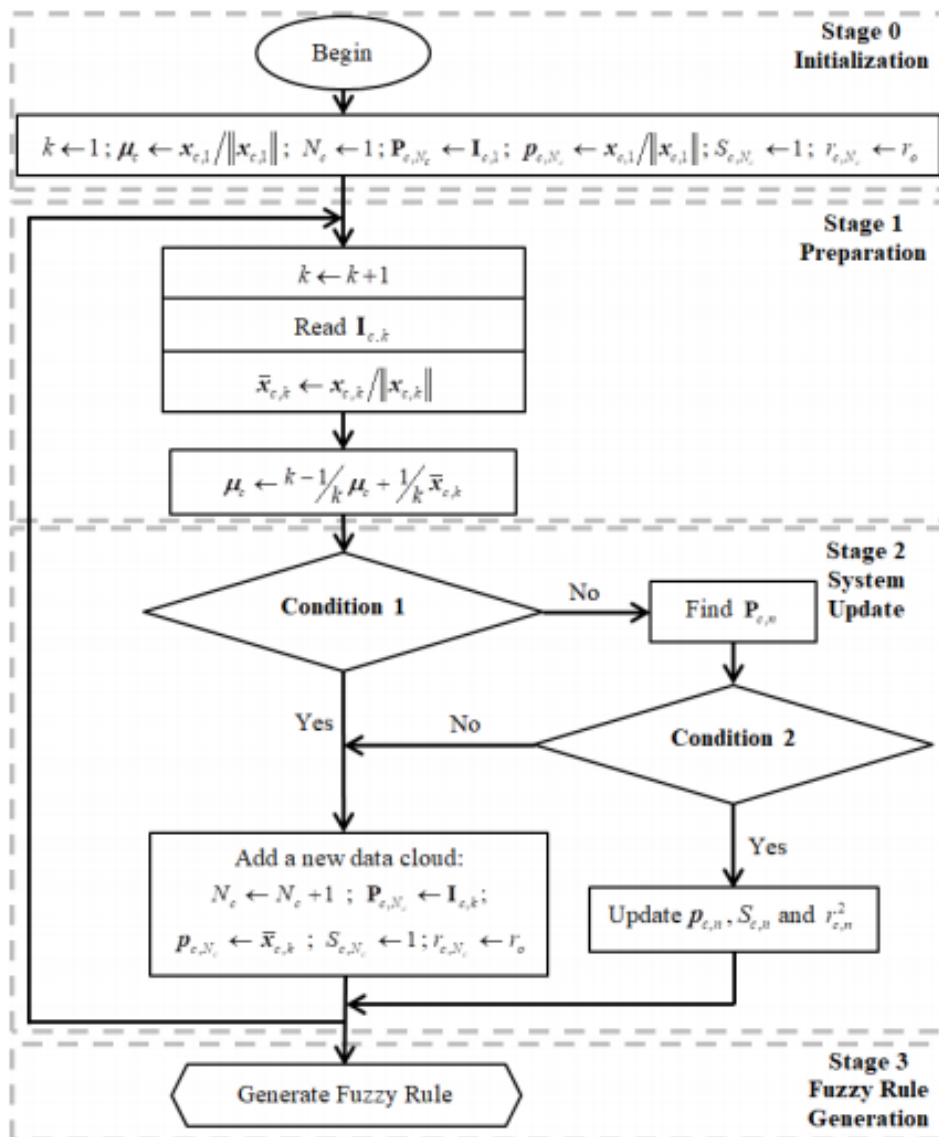


Figure III.12 : Organigramme du processus de formation du sous-système FRB. (**Algorithme 01**)[24]

- **Les avantages :** le classificateur DRB est capable d'offrir une classification extrêmement élevée, comparable aux capacités humaines et à égalité ou surpassant les meilleures alternatives d'apprentissage en profondeur grand public publiées.
- **Inconvénients :** travaillent sans disposer d'instructions réelles, dans l'apprentissage dirigé.

### III.5.5.Semi-supervised Deep Rule-based (SSDRB) :

Une approche d'apprentissage semi-supervisée basée sur un classifieur basé sur des règles profondes (DRB) est introduit. Grâce à sa nature unique basée sur des prototypes, le classifieur DRB semi-supervisé (SSDRB) est capable de générer des règles SI... ALORS... interprétables par l'homme à travers le processus d'apprentissage semi-supervisé d'une manière auto-organisée et hautement transparente. Il prend en charge l'apprentissage en ligne sur une base échantillon par échantillon ou sur une base morceau par morceau. Il est également capable d'effectuer une classification sur des images hors échantillon. De plus, le SSDRB Le classifieur peut apprendre de nouvelles classes à partir d'images non étiquetées de manière active en devenant dynamiquement auto-évolutif. Des exemples numériques basés sur des ensembles d'images de référence à grande échelle démontrent la forte performance du classifieur SSDRB proposé ainsi que ses particularités par rapport aux approches « state-of-the-art ».

Le classifieur SSDRB proposé peut non seulement effectuer une classification sur des images hors échantillon, mais aussi prendre en charge la formation en ligne récursive sur une base échantillon par échantillon ou morceau par morceau. De plus, contrairement d'autres approches semi-supervisées, l'approche proposée est capable d'apprendre de nouvelles classes activement sans l'implication des experts, ainsi, à s'auto-évoluer. Exemples numériques basés sur des ensembles d'images de référence à grande échelle démontrer le processus d'apprentissage transparent et la haute performance du classificateur SSDRB proposé. En bref, par rapport aux approches semi-supervisées existantes, le SSDRB proposé le classifieur présente les caractéristiques distinctives suivantes en raison de sa nature basée sur des prototypes :

- Son processus d'apprentissage semi-supervisé est entièrement transparent et interprétable par l'homme.
- Il peut être formé en ligne échantillon par échantillon ou morceau par morceau.
- Il peut classer les images hors échantillon.

- Il est capable d'apprendre de nouvelles classes (auto-évoluer).

### III.5.5.1. Processus d'apprentissage semi-supervisé à partir d'ensembles de données statiques :

- **Algorithme 2 :**

Dans un scénario hors ligne, toutes les images d'entraînement non étiquetées sont disponibles et le classifieur DRB commence à apprendre à partir de ces images une fois le processus d'apprentissage avec des images étiquetées terminé. Tout d'abord, définissons les images d'entraînement non étiquetées comme ensemble  $\{U\}$ , et le nombre d'images d'entraînement non étiquetées comme  $U$ . Les principales étapes de la stratégie d'apprentissage semi-supervisé sont décrits comme suit :

- **Étape 1 :** Extraire le vecteur des scores de confiance/degrés de proximité aux prototypes les plus proches pour chacun image d'entraînement non étiquetée, désignée par  $\lambda(U_i)$  ( $i = 1, 2, \dots, U$ )
- **Étape 2 :** Découvrez toutes les images d'entraînement non étiquetées satisfaisant la

**condition 3 :**  $IF (\lambda^{max}(U_i) > \varphi \cdot \lambda^{**max}(U_i)) THEN (U_i \in \{V\}_0)$

Où  $\lambda^{max}(U_i)$  désigne le score de confiance le plus élevé Interface utilisateur  $U_i$  obtient, et  $\lambda^{**max}(U_i)$  désigne le deuxième plus haut But ;  $\varphi$  ( $\varphi > 1$ ) est un paramètre libre  $\{V\}$  désigne la collection des images d'entraînement non étiquetées qui répondent

**Condition 3 :** Alors  $\{V\}$  est supprimé de  $\{U\}$

Pour les images d'entraînement non étiquetées  $\{V\}_0$  qui répondent à la **condition 3**, le classifieur DRB est très confiant à propos de la classe à laquelle appartiennent ces images et elles peuvent être utilisées pour mettre à jour sa structure et ses méta-paramètres. Sinon, cela signifie que le classificateur DRB n'est pas très confiant quant à son jugement et, par conséquent, ces images ne sont pas utilisés pour mettre à jour les règles floues.

Par rapport à d'autres mécanismes de pseudo-étiquetage utilisés dans d'autres travaux, la condition 3 considère non seulement les distances mutuelles entre l'image non étiquetée et tous les prototypes identifiés, mais aussi les distinguabilité de l'image non étiquetée, ce qui conduit à un processus de pseudo-étiquetage plus précis.

- **Étape 3 :** Classe les éléments dans  $\{\mathbf{V}\}_0$  dans un ordre décroissant en fonction des valeurs de  $(\lambda^{*\max}(\mathbf{V}) - \lambda^{**\max}(\mathbf{V}))$  ( $\mathbf{V} \in \{\mathbf{V}\}_0$ ), et notons l'ensemble classé comme  $\{\mathbf{V}\}_1$

Comme on peut le voir à partir de la définition de l'équation du score de confiance, le plus haut  $\lambda^{*\max}(\mathbf{V})$  c'est-à-dire que plus l'image est similaire à un prototype particulier du classifieur DRB. Pendant Ce temps, le plus haut  $(\lambda^{*\max}(\mathbf{V}) - \lambda^{**\max}(\mathbf{V}))$  c'est-à-dire que moins la décision prise par le classifieur DRB est ambiguë. Depuis la DRB le classifieur apprend échantillon par échantillon sous la forme d'un flux de données, en classant  $\{\mathbf{V}\}_0$  à l'avance, le classificateur se mettra d'abord à jour avec des images plus proches des prototypes identifiés précédemment et ayant moins d'ambiguïté dans les décisions concernant leurs étiquettes, et plus tard avec les moins familières, ce qui garantit un apprentissage plus efficace

- **Étape 4:** Mettez à jour le classifieur DRB à l'aide de **l'algorithme 1** avec l'ensemble  $\{\mathbf{V}\}_0$

Ensuite, le classifieur SSDRB revient à l'étape 1 et répète l'ensemble du processus, jusqu'à ce qu'il n'y ait plus d'images d'entraînement non étiquetées pouvant répondre **la condition 3**. Une fois le processus d'apprentissage semi-supervisé hors ligne terminé, si le classifieur DRB n'est pas conçu pour apprendre de nouvelles classes, les étiquettes de toutes les images d'entraînement non étiquetées seront estimées sur la base du « gagnant- stratégie du « tout ». Sinon, le classifieur DRB produira d'abord les pseudo étiquettes des images qui peuvent répondre à la condition 3, puis apprendra de nouvelles classes à Travers les images non étiquetées restantes (s'auto-évoluera).

Une caractéristique distinctive du classifieur SSDRB est sa robustesse aux images incorrectement pseudo-étiquetées grâce à sa nature basée sur des prototypes et le processus d'apprentissage de type « un seul passage » (non itératif). Les images incorrectement pseudo-étiquetées peuvent influencer le classifieur SSDRB de deux manières : 1) elles peuvent légèrement décaler les positions de certains des prototypes ; 2) ils peuvent créer de nouveaux faux prototypes en attribuant des pseudo-étiquettes erronées (voir **algorithme 1**).

Cependant, le classifieur SSDRB a une forte tolérance à une petite quantité d'images incorrectement pseudo-étiquetées car les erreurs ne seront pas propagées à la majorité des prototypes déjà existants dans la base de règles SI... ALORS... (en d'autres termes, il n'y a pas d'erreur propagation).

La procédure principale du processus d'apprentissage semi-supervisé hors ligne (**algorithme2**) est résumée dans un forme d'un organigramme dans la Figure III.13 :

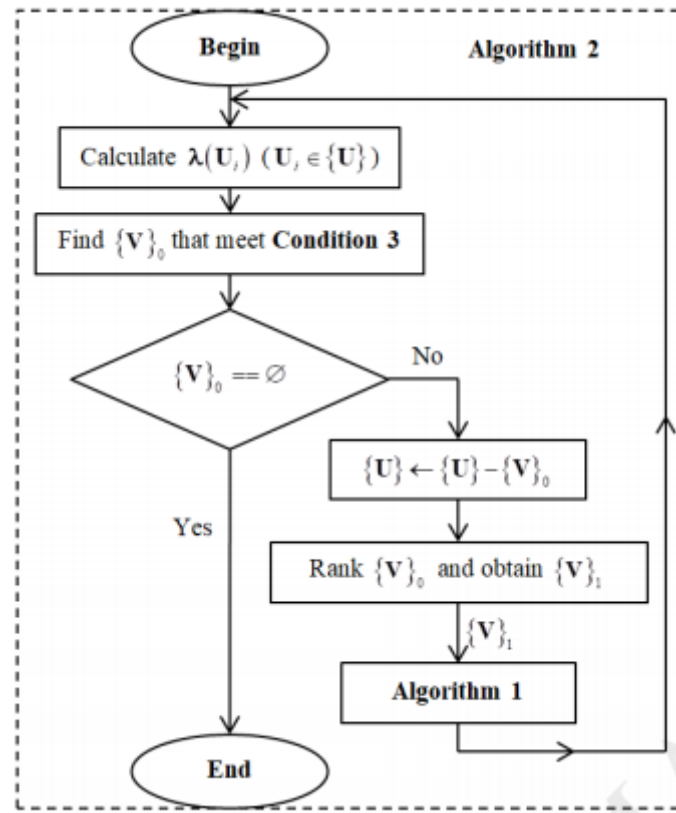


Figure III.13 : Processus d'apprentissage semi-supervisé hors ligne (**algorithme 2**) [25]

### • Algorithme 3 :

Pour une image d'entraînement non étiquetée  $U_i$ , si la condition 4 est remplie, cela signifie que le classifieur DRB n'a pas vu d'images similaires auparavant, et par conséquent, une nouvelle classe est ajoutée.

**Condition 4:**  $IF (\lambda^{*max}(U) \leq \gamma) THEN (U \in the (C+1)^{th} class)$

Dans  $\lambda$  est un paramètre libre servant de seuil. En conséquence, une nouvelle règle floue est également ajoutée à la base de règles avec cette image d'apprentissage comme premier prototype. En général, plus  $\lambda$  est faible, plus le classifieur DRB sera prudent lors de l'ajout de nouvelles règles à la base de règles.

Dans le scénario hors ligne, il peut rester un certain nombre d'images non étiquetées dans  $\{U\}$  après le processus d'apprentissage semi-supervisé hors ligne, redénoté par  $\{U\}$ . Certains d'entre eux peuvent satisfaire à la condition 4, notée par  $\{V\}$ ,  $\{V\} \subseteq \{U\}$ . Beaucoup d'images

dans  $\{U\}$  peut en fait appartenir à quelques classes inconnues. Pour classer ces images, le classifieur DRB doit ajouter quelques nouvelles règles floues à la base de règles existante de manière active.

Le classifieur DRB commence par l'image qui a le plus bas  $\lambda^{*max}$ , désigné par  $V$  ( $V \in \{V\}$ ), et ajoute une nouvelle règle floue avec cette image comme prototype. Cependant, avant d'ajouter une nouvelle règle floue, le classifieur DRB répète le processus d'apprentissage semi-supervisé hors ligne (**algorithme 2**) sur les non sélectionnés restants. images dans  $\{U\}$  pour trouver d'autres prototypes associés à la règle floue nouvellement ajoutée. Cela peut résoudre le problème potentiel d'ajouter trop de règles. Une fois la règle floue nouvellement formée entièrement mise à jour, le classifieur DRB commencera à ajouter la nouvelle règle suivante.

La procédure principale d'apprentissage de nouvelles classes à partir de données d'entraînement non étiquetées (auto-évolutives) est résumée dans l'organigramme suivant (**algorithme 3**):

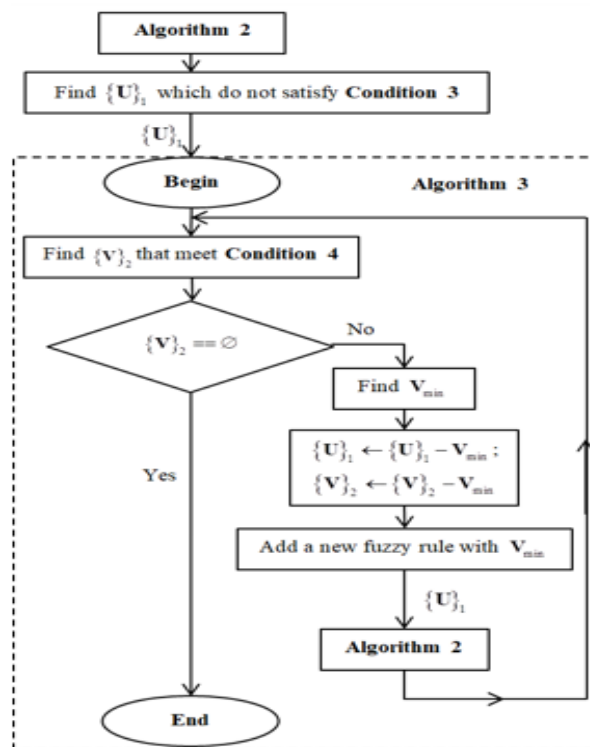


Figure III.14 : Apprentissage actif de nouvelles classes, auto-évolutif (**Algorithme 3**) [25]

### **III.6.Conclusion :**

Nous avons vu dans ce chapitre les étapes d'une classification en détail ainsi que les différentes techniques d'extraction de caractéristiques, dans cette étude, nous avons présenté des extracteurs de bas niveau comme HOG et GIST ainsi que des extracteurs de haut niveau comme LBP, SIFT, Alexnet et VGG.

Nous avons introduit dans cette section quelques méthodes de classification, leurs avantages et inconvénients, nous avons choisi un classifieur semi-supervisé basé sur des règles profondes (SSDRB) et montrer également ses caractéristiques distinctives par rapport aux autres classifieurs.



***Chapitre IV :***  
***L'approche proposé***

## **IV.1.Introduction :**

Dans ce chapitre nous avons présenté en détail les algorithmes utilisés et les différents descripteurs lesquelles nous avons parlé dans le chapitre précédente ensuite, nous avons amélioré l'approche proposé et expliqué comment réalisé l'implémentation ainsi que l'outil qui a servi à la réalisation et sans oubliée l'analyse des résultats et les mesures de performance obtenus.

## **IV.2.Environment de travail :**

### **IV.2.1.Outils et matériels :**

Pour que notre travail atteigne l'objectif qu'on visait, on a pris l'initiative d'exploiter et d'implémenter notre algorithme sur un ordinateur personnel :

- Processeur : Intel (R) Core (TM) i5-4210U, CPU 1.70GHz
- Système d'exploitation 64 bits Windows 10
- Disque dure de taille 1 To et RAM 4.00Go

### **IV.2.2.langage de programmation :**

#### **IV.2.2.1.Matlab :**

MATLAB est une abréviation de Matrix LABORatory (laboratoire de matrice). Il a été conçu par Cleve Moler en 1977 à partir des bibliothèques Fortran, LINPACK et EISPACK2. MATLAB est un langage de programmation de quatrième génération est dédié aux applications scientifiques. Il est un environnement d'analyse numérique, permet de faire du calcul matriciel et de développer et d'exécuter des algorithmes, ainsi que créer des interfaces utilisateur (IU) et de visualiser des données, Il est utilisé pour développer des solutions nécessitant une très grande puissance de calcul.

Les ingénieurs et les scientifiques utilisent MATLAB dans de nombreux domaines, tels que le traitement des images et des signaux, les communications, les systèmes de contrôle du secteur industriel, la conception de réseaux intelligents, la robotique et la finance computationnelle.



Figure IV.1 : Logo Matlab

### IV.3. les modèles et architectures implémentés :

Nous avons présenté dans ce chapitre les architectures développées pour réaliser ce travail nous avons implémenté les quatre classifieurs **SSDRB**, **DRB**, **Dtee**, **KNN** et utiliser 3 descripteurs bas niveau comme **HOG**, **GIST** et haut niveau comme **LBP**.

#### IV.3.1. bases de données utilisés :

On a utilisé 2 bases de données pour notre implémentation :

##### IV.3. 1.1. Base de données 1 :

Cette base de données contient 253 images divisées en 2 classes (**yes**, **no**)

**Source** : <https://www.kaggle.com/navoneel/brain-mri-images-for-brain-tumor-detection>

**Taille** : 8.27 MB.

##### IV.3. 1.2. Base de données 2:

Cette base de donnée divisé en 2 dossier Training et Testing.

Chaque dossier est divisé à 4 sous dossier (**glioma\_tumor**, **meningioma\_tumor**, **no\_tumor**, **pituitary\_tumor**)

**Source** : <https://www.kaggle.com/sartajbhuvaji/brain-tumor-classification-mri>

**Taille** : 88.77 MB

**Nombre d'images IRM** : 3264.

## IV.4. Les mesures de performance :

Nous avons présenté la démarche à suivre pour mesurer la performance de notre classifieur . Nous avons présenté 3 indicateurs, adaptés pour évaluer la performance du notre modèle de classification qui est calculés à partir de la matrice de confusion. Ils sont assez simples à comprendre et sont très complémentaires : l'accuracy, le rappel et la précision.

### IV.4.1. La matrice de confusion :

Une matrice de confusion est un tableau qui est souvent utilisé pour décrire les performances d'un modèle de classification (ou "classificateur") sur un ensemble de données de test dont les vraies valeurs La matrice de confusion elle-même est relativement simple à comprendre.

Pour bien comprendre le fonctionnement d'une matrice de confusion, il faut d'abord comprendre les quatre terminologies principales : TP, TN, FP ; FN :

**TP (true positive) :** les cas où la prédiction est positive, et où la valeur réelle est effectivement positive.

**TN (true négative) :** les cas où la prédiction est négative et où la valeur réelle est effectivement négative.

**FP (false positive) :** les cas où la prédiction est positive, et où la valeur réelle est effectivement négative.

**FN (false négative) :** les cas où la prédiction est négative et où la valeur réelle est effectivement positive.

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

Figure IV.2 : matrice de confusion [26]

- **Exactitude (an anglais Accuracy) :**

L'indicateur le plus simple est l'exactitude : il indique le pourcentage de bonnes prédictions. C'est un très bon indicateur parce qu'il est très simple à comprendre.

$$\text{Accuracy} = \frac{\text{Vrai positif} + \text{Vrai négatif}}{\text{Total}} \qquad \text{Accuracy} = \frac{(TP + TN)}{(TP + FP + TN + FN)}$$

- **Sensibilité (SA) (en anglais Recall) :**

Le rapport entre les observations positives correctement prédites et toutes les observations de la classe réelle

$$\text{Recall} = \frac{TP}{TP + FN}$$

- **Précision (P) :**

La précision est le rapport entre les observations positives correctement prédites et le total des observations positives prédites.

$$\text{Precision} = \frac{TP}{TP + FP}$$

- **F- mesure (en anglais score-F) :**

Il s'agit de la moyenne harmonique de la précision et le rappel. Il prend des valeurs entre 0 et 1. Cette mesure est utilisée quand on cherche une balance entre la précision et le rappel. Plus que la valeur de cette mesure s'approche de 1, plus que notre modèle fait une bonne décision, et le contraire est vrai, quand elle s'approche de zéro.

$$F1 = \frac{2 \times \text{precision} \times \text{recall}}{\text{precision} + \text{recall}}$$

- **La Spécificité (Sp) :**

Présente la proportion entre les échantillons qui sont réellement négatifs par rapport aux échantillons négatifs globaux. Elle se définit comme suite :

$$\text{La Spécificité} = \frac{TN}{TN+FP}$$

#### IV.4.2. Courbe Roc :

La courbe ROC (Receiver Operating Characteristic) a été utilisée dans le traitement de signal pour faire la distinction entre le signal et le bruit. Elle est très utilisée en apprentissage automatique pour évaluer la performance des classifieurs. Il s'agit d'une courbe où on croise le taux des vrais positifs (TVP) avec celui des faux négatifs (TFN) pour tous les seuils de classification. On utilise un classifieur aléatoire comme une ligne de base. Si on classe aléatoirement nos instances, on est censé avoir cette ligne.

- **Le taux de true positifs (TTP) :** est l'équivalent du rappel. Il est donc défini comme suit :

$$TTP = TP / (TP + FN)$$

- **Le taux de faux positifs (TFP) :** est défini comme suit :

$$TFP = FP / (FP + TN)$$

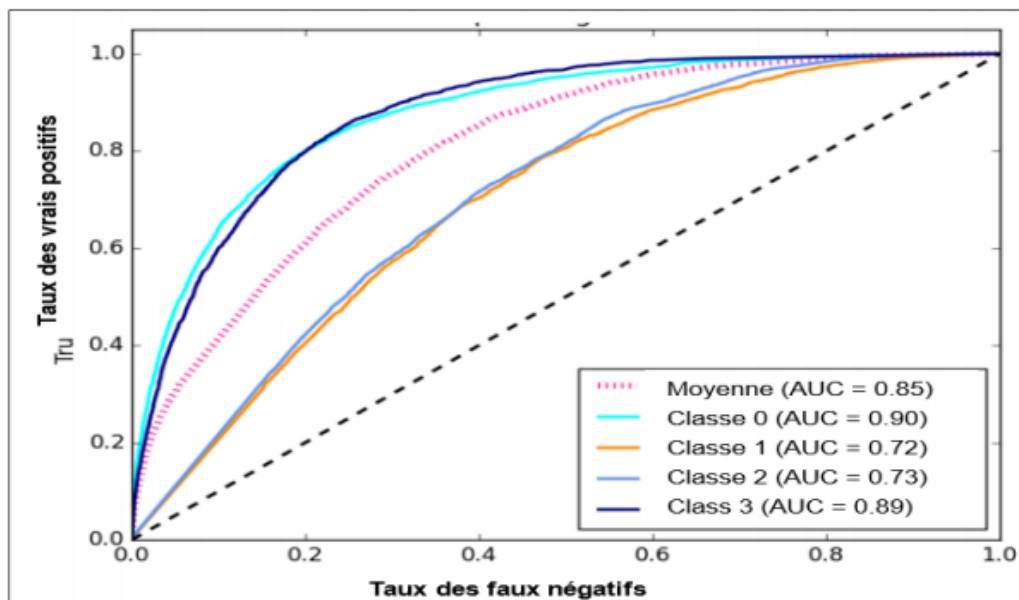


Figure IV.3 : le courbe roc [27]

## IV.5.Résultats et comparaison :

Nous avons d'abord concentrés sur les quatre classificateurs SSDRB, DRB, KNN, Décision Tree et nous avons utilisé des extracteurs de caractéristiques pour faire une comparaison entre les résultats. Ces extracteurs de caractéristiques sont : **LBP** (local binary patterns), **HOG** (histogramme de gradient orienté) et **GIST**.

### IV.5.1.Comparaison entre les classificateurs et les extracteurs de caractéristiques dans la 1<sup>ère</sup> base de données :

Nous avons présenté la premier base de données qui contient deux dossier (Testing, Training), chaque dossier divisé en deux sous-dossier (**yes,no** ) .et testé cette base de données avec les différents classificateur et les extracteurs de caractéristiques, nous avons obtenus ces résultats :

Base de données	Algorithme	Descripteur	Accuracy
<b>Base de données 01</b>	SSDRB	HOG	<b>0.8161</b>
		LBP	0.6512
		GIST	0.7674
	DRB	HOG	<b>0.8046</b>
		LBP	0.6092
		GIST	0.7241
	KNN	HOG	<b>0.8736</b>
		LBP	0.5862
		GIST	0.7816
	Dtree	HOG	0.5057
		LBP	0.6322
		GIST	0.5632

Table IV.1 : Tableau de comparaison entre les quatre classificateurs avec les 3 descripteurs dans la base de données 01.

Comme on peut le voir dans le tableau IV.1 le classifieur **SSDRB** est efficace en résultat avec le descripteur **LBP** par rapport à les classificateurs **DRB**, **KNN**, **Dtree** avec le descripteur **LBP**, mais le résultat le plus efficace dans les quatre classificateurs c'est le **SSDRB** avec l'extracteur de caractéristique **HOG** avec une exactitude de **81.61%**.

On peut remarquer que le classifieur **SSDRB** fonctionne bien dans la petite base de données et le descripteur **HOG** efficace avec les images médicales.

#### IV.5.2.Comparaison entre les classificateurs et les extracteurs de caractéristiques dans la 2<sup>ème</sup> base de données :

Dans cette étape nous avons choisi de testé les différents classificateurs **SSDRB**, **DRB**, **KNN**, **Dtree** avec les mêmes extracteurs de caractéristiques (**LBP**, **HOG**, **GIST**) et une grande base de données qui contient (2870 images).

Base de données	Algorithme	Descripteur	Accuracy
Base de donnée 02	SSDRB	HOG	<b>0.8071</b>
		LBP	0.6286
		GIST	0.7193
	DRB	HOG	<b>0.7766</b>
		LBP	0.6168
		GIST	0.7792
	KNN	HOG	<b>0.5571</b>
		LBP	0.5464
		GIST	0.6244
	Dtree	HOG	<b>0.7429</b>
		LBP	0.3731
		GIST	0.6954

Table IV.2 : Tableau de comparaison entre les quatre classificateurs avec les 3 descripteurs dans la base de données 02.

Dans le tableau IV.2 nous avons remarqué que le classifieur **SSDRB** avec l'extracteur de caractéristique **HOG** donne une exactitude de **80.71%** .il est efficace par rapport les classificateurs **DRB**, **KNN**, **Dtree** avec l'extracteur de caractéristique **HOG** ainsi que le



classifieur **SSDRB** donne un résultat supérieur avec l'extracteur de caractéristique **LBP** par rapport à les classifieurs **DRB, KNN, Dtree**.


### IV.5.3. Comparaison entre les deux bases de données avec l'extracteur de caractéristique HOG :

Base de données	Algorithme	Accuracy
<b>Base de données 01</b>	SSDRB	<b>0.8161</b>
	DRB	0.8046
	KNN	0.8736
	Dtree	0.6322
<b>Base de données 02</b>	SSDRB	<b>0.8071</b>
	DRB	0.7766
	KNN	0.5571
	Dtree	0.7429


Table IV.3 : Tableau de comparaison entre les deux bases de données avec l'extracteur de caractéristique HOG.

Le classifieur **SSDRB** produit les résultats de classification les plus précis sur ce problème avec l'extracteur de caractéristique **HOG**, le classifieur **SSDRB** peut gérer des base de donner volumineuses contrairement à **Dtree , KNN** .

Nous avons présenté la matrice de confusion et le courbe ROC de l'approche **SSDRB** pour les deux bases de données avec l'extracteur de caractéristique **HOG** :

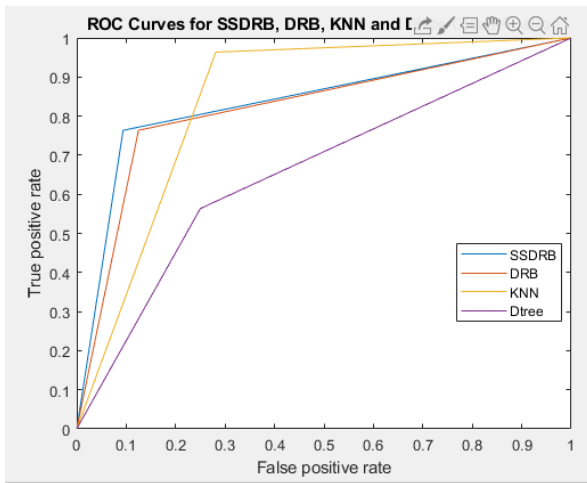


Base de données 01




Base de données 02

Figure IV.4 : matrice de confusion de l'approche HOG – SDRB



Base de données 01



Base de données 02

Figure IV.5 : 2 courbes rocs avec l'approche HOG -SSDRB

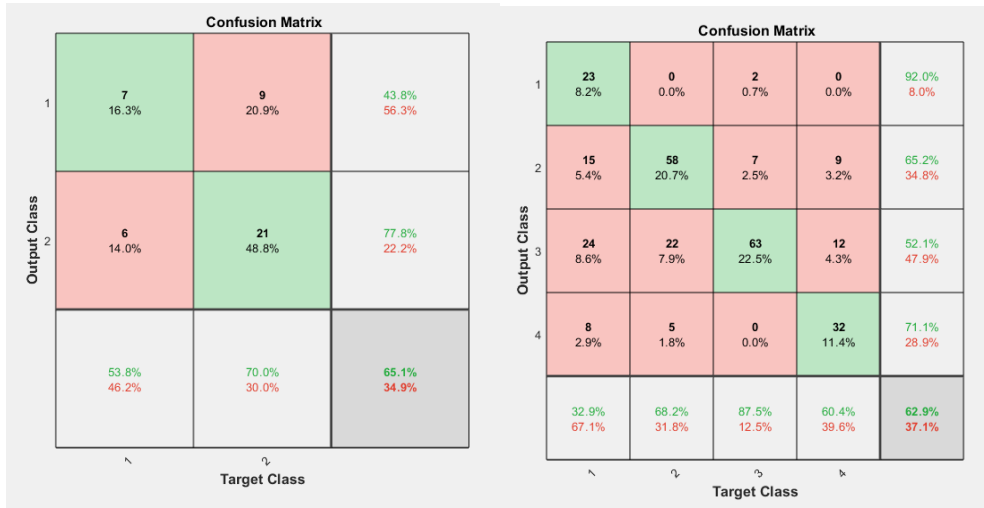
#### IV.5.4.comparaison entre les 2 bases de données et 4 classificateurs avec descripteur LBP :

Base de données	Algorithme	Accuracy
<b>Base de données 01</b>	SSDRB	<b>0.6512</b>
	DRB	0.6092
	KNN	0.5862
	Dtree	0.6322
<b>Base de données 02</b>	SSDRB	<b>0.6296</b>
	DRB	0.6168
	KNN	0.5464
	Dtree	0.37.31

Table IV.4 : Tableau de comparaison entre les deux bases de données avec l'extracteur de caractéristique LBP

Comme on peut le voir dans le tableau précédent le classifieur **SSDRB** donne de résultat entre **60-70** pour les deux base de donné avec l'extracteur de caractéristique **LBP** mais par vraiment efficace et éteindre pas notre objectif

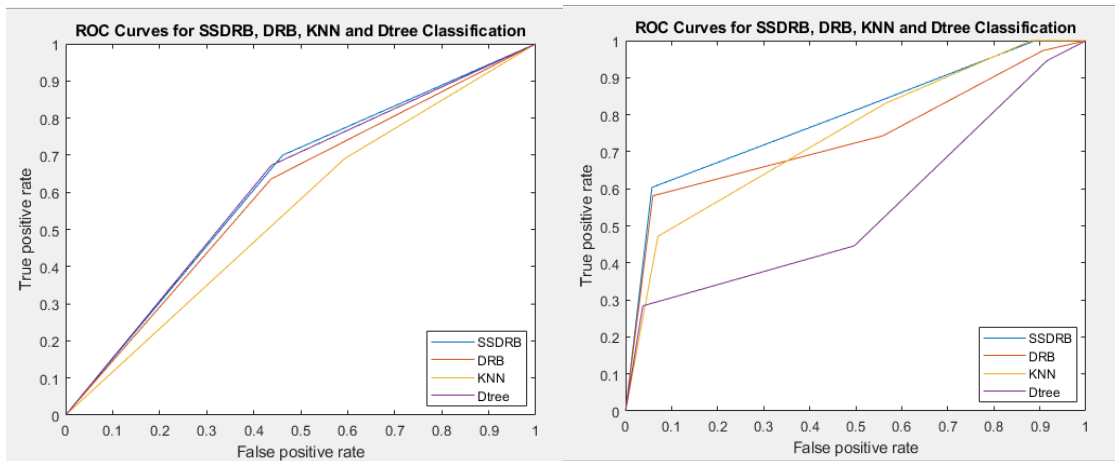
D'autre part, nous avons présenté la matrice de confusion et le courbe ROC de l'approche **SSDRB** pour les deux bases de données avec le descripteur **LBP** dans les figures suivante :



Base de données 01

Base de données 02

Figure IV.6 : matrice de confusion de l'approche LBP avec SSDRB



Base de données 01

Base de données 02

Figure IV.7 : courbe roc avec l'approche LBP - SSDRB


### IV.5.5.comparaison entre les 2 bases de données et les quatre classificateurs avec descripteur GIST :

Base de données	Algorithme	Accuracy
<b>Base de données 01</b>	SSDRB	<b>0.76.74</b>
	DRB	0.7241
	KNN	0.7816
	Dtree	0.7126
<b>Base de données 02</b>	SSDRB	<b>0.7193</b>
	DRB	0.7793
	KNN	0.6244
	Dtree	0.6954

Table IV.5 : Tableau de comparaison entre les deux bases de données avec l'extracteur de caractéristique GIST

Pour le résultat obtenu le classifieur **SSDRB** avec l'extracteur de caractéristique **GIST** donne des résultats entre **70\_80%** mais il fonctionne bien dans la petite base de données par rapport à la grande base de données.

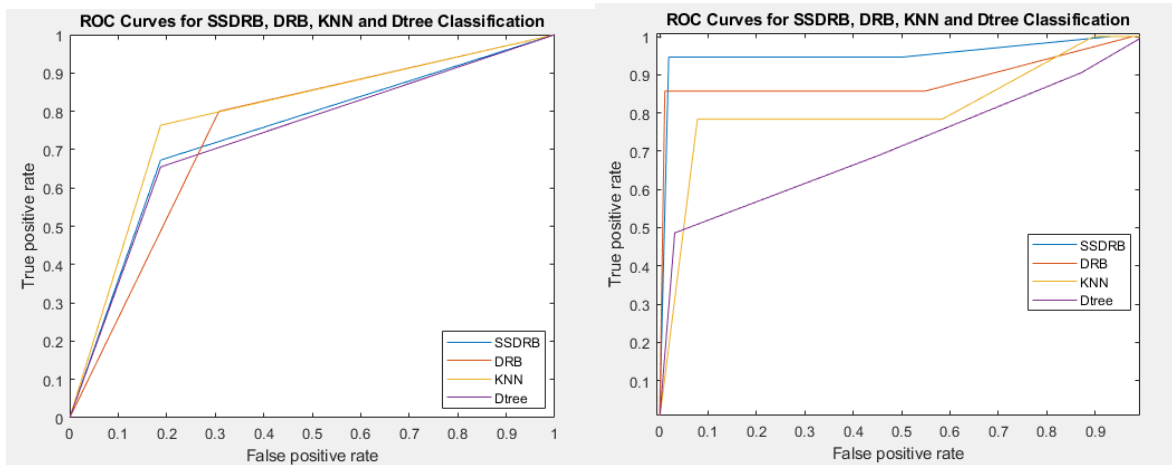
La figure suivante représente la matrice de confusion et le courbe roc de l'approche **SSDRB** pour les deux bases de données avec le descripteur **GIST** :



Base de données 01

Base de données 02

Figure IV.8 : 2 matrices de confusion de l'approche GIST avec SSDRB



Base de données 01

Base de données 02

Figure IV.9 : 2 courbes rocs avec l'approche GIST - SSDRB

Évaluation de classifieur SSDRB avec l'extracteur de caractéristique HOG utilisant les deux bases de données :

<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specifity</b>	<b>Precision</b>	<b>F_mesure</b>
0.8161	0.9063	0.7636	0.6905	0.7838

Table IV.6 : Tableau évaluation de classifieur SSDRB avec l'extracteur de caractéristique HOG

Dans la base de données 01

<b>Accuracy</b>	<b>Sensitivity</b>	<b>Specifity</b>	<b>Precision</b>	<b>F_mesure</b>
0.8071	0.2714	0.9857	0.8638	0.4130

Table IV.7 : Tableau évaluation de classifieur SSDRB avec l'extracteur de caractéristique HOG

Dans la base de données 02

#### **IV.5.6. Comparaison entre les résultats de différentes distances de SSDRB avec les extracteurs de caractéristique :**

Dans le but d'améliorer les performances de notre classifieur SSDRB nous avons testé plusieurs distances (euclidean, city block, ...), les résultats obtenus sont présentés dans les tableaux suivants :

Méthodes	HOG	LBP	GIST
<b>Euclidean</b>	81.61 %	65.12 %	76.74 %
<b>Squaredeuclidean</b>	<b>90.80 %</b>	65.12 %	68.18 %
<b>Cityblock</b>	44.83 %	51.16 %	59.09 %
<b>Chebychev</b>	42.53 %	<b>67.44 %</b>	<b>77.27 %</b>
<b>Cosine</b>	80.46 %	65.12 %	65.91 %
<b>Correlation</b>	88.51 %	58.14 %	68.18 %
<b>hamming</b>	41.38 %	32.56 %	43.18 %
<b>Jaccard</b>	36.78 %	32.46 %	43.18 %

Table IV.8 : tableau de comparaison entre les différentes méthodes de distance de SSDRB avec base de données 01

Méthodes	HOG	LBP	GIST
<b>Euclidean</b>	80.71 %	62.86%	71.93 %
<b>Squaredeuclidean</b>	78.17 %	74.64 %	71.93 %
<b>Cityblock</b>	<b>86.04 %</b>	<b>77.86%</b>	<b>71.93 %</b>
<b>Chebychev</b>	76.14 %	74.29 %	71.05 %
<b>Cosine</b>	55.84 %	74.64 %	71.93 %
<b>Correlation</b>	78.17 %	74.29 %	71.05 %
<b>hamming</b>	78.17 %	70.71%	63.16 %
<b>Jaccard</b>	29.44 %	70.71%	63.16 %

Table IV.9 : tableau de comparaison entre les différentes méthodes de distance de SSDRB avec base de données 02



Dans les tableaux précédent nous avons remarqué que la distance **Squaredeclidean** donne le meilleur résultat avec le descripteur **HOG** dans la première base de données et la distance **Cityblock** donne le meilleur résultat avec tous les descripteurs dans la deuxième base de données par rapport les autres distances.

Les résultats que nous avons obtenus montrent que les distances (**Squaredeclidean**, **Cityblock**) contribué Significativement à l'amélioration de l'approche proposée.

#### **IV.6.Conclusion :**

Dans ce chapitre, nous avons présenté les résultats de notre approche, en utilisant deux bases de données différentes.

Nous avons fait aussi, une comparaison avec d'autres classifieurs (DTree, KNN, DRB). Les résultats montrent l'efficacité de notre approche par rapport à l'état de l'art de problématique de détection de pathologies cérébrales.

## Conclusion générale:

Le champ d'application de l'IA et des technologies liées à l'IA en médecine est vaste et s'élargit rapidement. Les avancées récentes offrent une opportunité très prometteuse d'améliorer médical.

À travers ce mémoire nous avons pu répondre à la problématique que nous avons discutée au début du chapitre 1.

Dans le chapitre 2, on a tout d'abord parlé la relation de (IA) dans le domaine médical ensuite, présentés la technique d'imagerie par résonance magnétique (IRM), ainsi que défini le système nerveux central (SNC).

Dans le chapitre 3 on a expliqué bien les étapes de classification et quelques descripteurs de bas et hauts niveaux et quelques algorithmes supervisé et semi supervisé.

Dans le chapitre 4, nous avons abordé les métriques et les méthodes qui peuvent être utilisés pour tester et évaluer la performance prédictive pour les problèmes de classification, on commence par définir c'est quoi une matrice de confusion. Ensuite, on présente les mesures qui sont directement calculées à partir de cette matrice (précision, rappel, spécificité et taux des faux négatifs) ainsi que la courbe ROC, nous avons mise en œuvre une solution intelligente pou le problème de détection des pathologies cérébrale, nous avons comparé entre les différents méthodes pour calculé la distance de classifieur SSDRB.

Dans ce mémoire, nous avons abordé le problème de classification d'images. Plus précisément, nous nous sommes focalisés à la classification d'images, précisément de la méthode de classification SSDRB et l'approche de classification semi supervisé.

Nos système a été pour objectif d'évaluer une méthode de classification semi supervisé et l'appliquer sur les images médicales,

Dans cette mémoire, nous avons proposé un classifieur semi-supervisé basé sur des règles profondes (SSDRB). Il offre un très haut taux de classification sur les images non étiquetées surpassant d'autres méthodes et, en même temps, un humain interprétable ensemble de règles SI... ALORS... après un processus d'apprentissage semi-supervisé très transparent. Par rapport au approches d'apprentissage semi-supervisées existantes, le classifieur SSDRB proposé a les particularités suivantes fonctionnalités:

- il a une nature basée sur un prototype ;
- il est capable d'apprendre à partir d'un flux d'images en ligne (vidéo) ;
- la structure de son système est interprétable par l'homme ;
- il est capable d'effectuer une classification sur des images hors échantillon.

## Bibliographie

- [1] Pierre J. L. Brunelle - DI, MSc, MRes - Department of DIRD, Arts & Métiers ParisTech - Product Management Technical, Amazon, Greater Seattle Area, USA
- [2] Anne-Sophie Capelle-Laizé. Segmentation des images IRM multi-échos //tridimensionnelles pour la détection des tumeurs cérébrales par la théorie de l'évidence. //Interface homme-machine [cs.HC]. Université de Poitiers, 2003.
- [3] Moussa SEMCHEDINE. Système Coopératif Hybride de Classification dans un SMA : « Application à la segmentation d'images IRM ». Université farhat abbas – Sétif (UFAS). (Algérie)
- [4] [http://www.ikonet.com/fr/ledictionnairevisuel/static/qc/le\\_systeme\\_nerveux](http://www.ikonet.com/fr/ledictionnairevisuel/static/qc/le_systeme_nerveux)
- [5] Mohamed Mokhtar Bendib. Détection de pathologies à partir d'IRM cérébrales. Université badji Mokhtar Annaba
- [6] <https://www.alamyimages.fr/photo-image-meningiome-irm-49221798.html>
- [7] Amine benraha, les applications des intelligences artificielle dans le domaine de la santé, université Mohammed v de rabet.
- [8] <https://www.coe.int/fr/web/artificial-intelligence/glossary>
- [9] <https://markdown.data-ensta.fr/s/machine-learning-introduction>
- [10] <http://www2.agroparistech.fr/ufr-info/membres/cornuejols/Research/Tr-Montpellier-07-12-2018-v1x4.pdf>
- [11]<https://www.hebergementwebs.com/blockchain/quatre-nouvelles-methodes-d'apprentissage-automatique-pour-analyser-les-ensembles-de-donnees-blockchain>
- [12]\_et al L.Deng, D. Yu. « Deep learning : méthodes and applications. Foundation and trends R in Sgnal processing, 7(3-4) :197-387-2014.
- [13]\_horri Mohamed, kessi Ali, Calcule des descripteurs dans le but de la classification automatique d'objet 3D, Faculté Du Génie Electrique Et D'informatique Département D'automatique.

- [14] Mme. benhallou Khadidja Ep. benachenhou, Interface Design for Human Pose Estimation Ecole Doctorale NTIC, Signaux, Systèmes Intelligents et Robotique.
- [15] D. Lowe. Distinctive Image Features from Scale-Invariant Keypoints. IJCV, 60(2):91–110, 2004.
- [16] A. Vinay et al. / Procedia Computer Science 79 (2016) 533 – 542
- [17] shiqing zhang, xiaoming zhao, bicheng lei. «''Facial Expression Recongnition Using Sparse Representation''. » Volume 11. china : taizhou University, 2012 pp 440-452.
- [18] Chesner Desir. Classification Automatique d'Images, Application à l'Imagerie du Poumon Profond. Apprentissage [cs.LG]. Université de Rouen, 2013. Français. fftel-00879356f.
- [19] [https://www.researchgate.net/figure/Construction-dun-descripteur-SIFT-a-partir-de-gradients-calculés-dans-une-fenetre\\_fig9\\_318888444](https://www.researchgate.net/figure/Construction-dun-descripteur-SIFT-a-partir-de-gradients-calculés-dans-une-fenetre_fig9_318888444).
- [20] [https://fr.mathworks.com/help/deeplearning/ref/alexnet.html?s\\_tid=srchtitle](https://fr.mathworks.com/help/deeplearning/ref/alexnet.html?s_tid=srchtitle).
- [21] Jose Llamas 1,\*, Pedro M. Leronés 1 , Roberto Medina 1 , Eduardo Zalama 2 and Jaime Gómez-García-Bermejo 2, Classification of Architectural Heritage Images Using Deep Learning Techniques , Received: 7 September 2017; Accepted: 21 September 2017; Published: 26 September 2017
- [22] <https://www.datacorner.fr/vgg-transfer-learning/>
- [23] [https://fr.wikipedia.org/wiki/M%C3%A9thode\\_des\\_k\\_plus\\_proches\\_voisins](https://fr.wikipedia.org/wiki/M%C3%A9thode_des_k_plus_proches_voisins).
- [24] Plamen P. Angelov<sup>1,2</sup> and Xiaowei Gu<sup>1\*</sup> <sup>1</sup> School of Computing and Communications, Lancaster University, Lancaster, LA1 4WA, UK <sup>2</sup> Technical University, Sofia, 1000, Bulgaria (Honorary Professor), Deep Rule-Based Classifier with Human-level Performance and Characteristics
- [25] Xiaowei Gu<sup>1</sup> and Plamen P. Angelov<sup>1,2\*</sup> <sup>1</sup> School of Computing and Communications, Lancaster University, Lancaster, LA1 4WA, UK <sup>2</sup> Technical University, Sofia, 1000, Bulgaria (Honorary Professor), Semi-supervised Deep Rule-based Approach for Image Classification.

[26] <https://www.lebigdata.ma/la-precision-le-rappel-et-de-la-matrice-de-confusion-dans-lapprentissage-automatique/>

[27] Rachid mifdal, mémoire présenté à l'école de technologie supérieur comme exigence partielle à l'obtention de la maitrise avec mémoire en génie, concentration personnalisées M. Sc. A.

---

## Résumé

---

Cette thèse porte sur la classification automatisée d'images, appliquée aux images médicales d'IRM cérébrales pathologiques, L'objectif est de proposer et de développer une approche semi supervisé considère à la fois les données étiquetées et non étiquetées. Le but de l'apprentissage semi-supervisé est d'utiliser les données non étiquetées pour améliorer la généralisation, dans ce travail nous avons utilisé un nouveau classifieur SDRB pour la classification, en effet nous avons utilisé 2 base de données avec plusieurs approches, nous avons utilisé différents descripteurs utilisés dans la classification d'apprentissage automatique, la solution obtenue dans les résultats de notre travail, pour la 1ère base de données nous avons obtenu une exactitude **81.61%** avec l'approche **HOG+SSDRB** , Pour la classification binaire nous avons obtenu une exactitude **80.71%** avec l'approche **HOG+SSDRB**.

**Mots clés :** IRM cérébrale, semi-supervisé, classification, apprentissage profond

---

## Abstract

---

This thesis focuses on the automated classification of images, applied to pathological brain MRI medical images. The objective is to propose and develop a semi-supervised approach that considers both labeled and unlabeled data. The goal of semi-supervised learning is to use unlabeled data to improve generalization, in this work we used a new SDRB classifier for classification, indeed we used 2 databases with several approaches, we used different descriptors used in the machine learning classification, the solution obtained in the results of our work, for the 1st database we obtained an accuracy of 81.61% with the HOG + SDRB approach, For the binary classification we have achieved 80.71% accuracy with the HOG + SDRB approach.

**Keywords:** brain MRI, semi-supervised, classification, deep learning

---

## ملخص

---

تركز هذه الأطروحة على التصنيف الآلي للصور المطبقة على الصور الطبية المرضية في التصوير بالرنين المغناطيسي للدماغ، والهدف هو اقتراح وتطوير نهج شبه خاضع للإشراف يأخذ في الاعتبار البيانات المصنفة وغير المصنفة. الهدف من التعلم شبه الخاضع للإشراف هو استخدام البيانات غير المسماة لتحسين التعميم ، في هذا العمل استخدمنا مصنف SDRB جديدًا للتصنيف ، وبالفعل استخدمنا قاعدتي بيانات بعدة طرق، واستخدمنا واصفات مختلفة مستخدمة في تصنيف التعلم الآلي ، الحل الذي تم الحصول عليه في نتائج عملنا ، بالنسبة لقاعدة البيانات الأولى ، حصلنا على دقة 81.61٪ باستخدام نهج HOG + SDRB ، وبالنسبة للتصنيف الثنائي ، فقد حققنا دقة 80.71٪ باستخدام نهج HOG + SDRB.

**الكلمات المفتاحية:** تصوير الدماغ بالرنين المغناطيسي ، شبه مراقب ، التصنيف ، التعلم العميق.