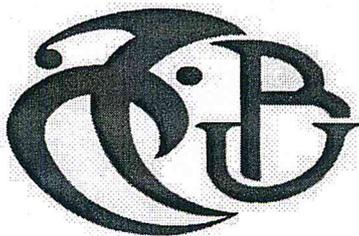


République Algérienne Démocratique et Populaire  
Ministère de l'Enseignement Supérieur et de la Recherche Scientifique

Université Saad Dahlab Blida

N° D'ordre :.....



Faculté des sciences

Département d'informatique

Mémoire Présenté par :

Berdaoui Sami Abdelhafid et Oulahcene Alaeddine

En vue d'obtenir le diplôme de master

Domaine : Mathématique et informatique

Filière : Informatique

Spécialité : Informatique

Option : Ingénierie de logiciel

Sujet :

Analyse d'images par combinaison de méthodes de classification pour l'aide au diagnostic médical.

Soutenu le :

M. Boutoumi Bachir	Président
M. Amine Cherif-Zohra	Examineur
M. F. Mene Chikhi	Examineur
Mlle. Benblidia Nadja	Promotrice
Mlle. Reguieg F. Zohra	Encadrante

Promotion  
2014 / 2015

## Table Des Matières

Liste des figures	
<b>Introduction générale</b> .....	<b>1</b>
Introduction.....	2
<b>Chapitre 1: Contexte Médicale</b> .....	<b>3</b>
1. Introduction .....	4
2. L'anatomie de l'œil .....	4
2.1. La tunique fibreuse .....	4
2.2. La tunique uvéale.....	5
2.3. La tunique nerveuse.....	5
3. Acquisition des images rétiniennes .....	7
3.1. La rétinographie.....	7
3.2. L'angiographies rétiniennes a la fluorescéine.....	8
3.3. Les différents types de clichés utilisés dans le diagnostic de la(RD).....	9
3.3.1. Image couleur .....	10
3.3.2. Image couleur stéréo.....	10
3.3.3. Angiographie a la fluorescéine.....	10
4. La rétinopathie diabétique.....	11
4.1. Etiopathogénie et physiologie de la rétinopathie diabétique.....	11
4.2. Classification de la rétinopathie diabétique.....	12
4.3. Quels sont les symptômes de la rétinopathie diabétique ?.....	14
4.4. Rétinopathie et mortalité.....	14
4.5. Traitement de la rétinopathie diabétique.....	15
5. L'analogie entre les images rétiniennes et la réalité physiologique.....	15
5.1. L'interaction de la lumière avec le fond d'œil .....	16
6. La Télémédecine .....	16
6.1. Bénéfices pour les patients.....	17
7. Conclusion .....	17
<b>Chapitre 2: Les techniques de classification d'images</b> .....	<b>18</b>
1. Introduction.....	19
2. Définition.....	19
3. Les étapes d'une classification.....	20
4. Les méthodes de classification.....	20
5. Les approches de classification.....	21
i. Approche non paramétrique.....	21
ii. Approche paramétrique "probabilistes" .....	21
6. La classification supervisée.....	22
6.1 Méthode KPPV.....	23
6.1.1. Les K plus proches voisins KPPV.....	23
6.1.2. Algorithme de KPPV.....	24
6.1.3 Sélection de la classe.....	24
❖ Distance du $X^2$ (Chi-2).....	25

6.1.4 Les K plus proches voisins flouent.....	26
6.2. Méthode SVM (Support Vector Machines) .....	27
6.2.1. Définition.....	27
6.2.2. Les SVMs linéaires.....	27
a. Classifieurs linéaire.....	27
❖ Algorithme SVM linéaire.....	28
b. Marge maximale de l'hyperplan.....	28
6.2.3. SVM non-linéaires.....	30
a. Noyau polynomial d'ordre p.....	31
b. Noyau linéaire.....	31
c. Noyau gaussien de largeur de bande $\sigma$ .....	31
6.2.4. Domaine d'application de SVM.....	31
6.2.5. Avantages et Inconvénients .....	32
a. Avantages.....	32
b. Inconvénients.....	32
7. La classification Non-Supervisée.....	32
8. Les types du clustering.....	35
8.1. Clustering exclusif.....	35
8.2. Le regroupement Overlapping Clustering (fuzzy Clustering).....	36
8.2.3. Clustering hiérarchique.....	36
8.2.4. clustering probabiliste.....	36
9. les algorithmes de clustering.....	36
9.1. K-means.....	36
9.2. Fuzzy C-means.....	37
10. les Méthodes hiérarchiques.....	38
❖ Classification hiérarchique ascendantes (CHA) .....	38
❖ Classification hiérarchique descendantes.....	39
11. Les Limites de Clustering.....	40
12. Conclusion.....	40

### **Chapitre 3 : Aide au diagnostique par fusion de classifieur..... 41**

1. Introduction .....	42
2. Méthodologie adoptée pour l'analyse d'images rétiniennes.....	42
3. Localisation des caractéristiques.....	45
3.1. Caractéristiques globales.....	45
a. Couleur (Histogramme et dérivés).....	45
b. Forme.....	46
3.2. Caractéristiques locales.....	47
3.2.1. Détection de zones d'intérêt .....	48
3.2.2. Terminologie.....	48
3.2.3. Typologie.....	49
a. Contours .....	49
b. Points d'intérêt.....	49
c. Régions d'intérêt.....	49
3.3. Scale-Invariant Feature Transform (SIFT).....	50
a. Ses applications.....	50
b. Principe de base.....	50
3.3.1. Les étapes de la méthode SIFT.....	51
3.3.1.1 Détection des points-clés et calcul du descripteur SIFT.....	51
3.3.1.2 Détection d'extrema dans l'espace des échelles.....	52

3.3.1.3 Amélioration de la précision.....	53
3.3.1.4 Assignation d'orientation aux points d'intérêt.....	53
3.3.1.5 Les descripteurs des points d'intérêt.....	53
3.3.1.6 Utilisation pour la recherche d'objets dans des images.....	54
4. Description de la base de données.....	55
5. Techniques de classification utilisé.....	56
5.1 Les machines à vecteur support (SVM) .....	56
5.1.1 Principe de fonctionnement.....	57
5.1.2 Classification des SVM multi-classes.....	58
5.2 L'algorithme KNN.....	60
6. Conclusion.....	61
<b>Chapitre 4: Implémentation Expérimentation Et Résultat.....</b>	<b>62</b>
1. Introduction.....	63
2. Présentation de l'environnement du travail .....	63
2.1. Matériel utilisé.....	63
2.2. Langage utilisé.....	63
2.3. Présentation du 'gui' .....	65
3. présentation de notre interface.....	66
4. Test et évaluation.....	70
4.1 Détection d'extrema.....	70
4.2. Assignation d'orientation aux points d'intérêts .....	71
4.3. Descripteur de point-clés.....	72
4.4. Classification des descripteurs.....	73
4.5. La combinaison (Fusion).....	73
4.6. Les résultats obtenus .....	74
5. Conclusion.....	75
<b>Conclusion générale.....</b>	<b>77</b>

## *Liste des Figures*

<b>Figure 1.1 :</b> Anatomie d l'œil.....	4
<b>Figure 1.2 :</b> Structure de la rétine.....	6
<b>Figure 1.3 :</b> La rétinographie et les images traitées par cet appareil.....	8
<b>Figure 1.4 :</b> l'angiographie.....	8
<b>Figure 1.5 :</b> L'angiographie et les images traitées par cet appareil.....	9
<b>Figure 1.6 :</b> Image couleur de rétine.....	10
<b>Figure 1.7 :</b> Images d'angiographie rétinienne a la fluorescéine.....	11
<b>Figure 1.8 :</b> une rétinopathie diabétique pré-proliférative.....	13
<b>Figure 1.9 :</b> Une rétinopathie diabétique proliférative.....	13
<b>Figure 1.10 :</b> Un œdème maculaire diabétique.....	14
<b>Figure 1.11 :</b> La réfraction de la lumière dans les différentes couches de la rétine.....	16
<b>Figure 2.1 :</b> les méthodes de classification .....	21
<b>Figure 2.2:</b> les différentes modèles de classification supervisée.....	23
<b>Figure 2.3:</b> Illustration des K-PPV d'un point.....	25
<b>Figure 2.4:</b> Hyperplan séparateur $\langle w, x \rangle + b = 0$ .....	28
<b>Figure 2.5:</b> Hyperplans canoniques et marge maximale.....	30
<b>Figure 2.6:</b> Illustration de regroupement en clusters.....	33
<b>Figure 2.7:</b> les différentes types de clustering.....	35
<b>Figure 2.8:</b> Exemple d'un problème de discrimination à deux classes, avec un séparateur linéaire : la droite d'équation $y = x$ . le problème linéairement séparable.....	35
<b>Figure 2.9:</b> K-means.....	37
<b>Figure 2.10:</b> Classification hiérarchique descendante.....	39
<b>Figure 3.1 :</b> Sous système d'apprentissage.....	42
<b>Figure 3.2 :</b> Sous système de classification.....	44
<b>Figure 3.3 :</b> Ilustration de DOG.....	52
<b>Figure 3.4 :</b> Illustration des descripteurs des points d'intérêt .....	54
<b>Figure 3.5 :</b> Exemples d'images de la base de données MESSIDOR.....	56
<b>Figure 3.6:</b> (a) Recherche de l'hyperplan optimal ; (b) Hyperplan optimal, marge et vecteurs supports.....	57
<b>Figure 3.7:</b> Exemples de quatre types de problèmes de discrimination binaire où il s'agit de séparer les points bleus des croix rouges. La frontière de décision est représentée en noir....	58
<b>Figure 3.8:</b> Exemple de fonctionnement de classifieur kppv avec $k= 1,2,3$ .....	61
<b>Figure 4.1:</b> L'icône du logiciel Matlab.....	64
<b>Figure 4.2:</b> Fenêtre principale du guide.....	66
<b>Figure 4.3:</b> l'interface d'utilisateur (graphical user interface GUI).....	66
<b>Figure 4.4:</b> Application du filtre gaussien et calcule de la différence de gaussien entre l'image originale et l'image gaussien.....	71
<b>Figure 4.5:</b> Détermination des points d'intérêt de l'image.....	72
<b>Figure 4.6:</b> Figure illustre les valeurs des descripteurs d'une image.....	72
<b>Figure 4.7:</b> Figure illustre l'ensemble des fichiers MAT qui représente les descripteurs calculées à partir des images d'apprentissage et de test.....	73

# Introduction Générale

Le domaine du numérique est un domaine en pleine expansion. depuis quelques années, avec l'explosion d'internet et aussi le développement à grande échelle de la photographie numérique. Il n'est plus rare d'avoir des bases d'images numériques contenant plusieurs centaines d'images médicales acquises par des médecins avec des caméras spéciales telle que la caméra du fond de l'œil (fundus camera).

Pour gérer et utiliser efficacement ces bases d'images, un système de classification et de recherche d'images est nécessaire. C'est pourquoi le sujet de la recherche d'images devient un sujet très actif dans la communauté internationale depuis plus d'une dizaine d'années.

Les nouveaux supports informatiques permettent de manipuler des quantités très importantes d'informations. Parmi ces informations, les images prennent une part de plus en plus grande. Il apparaît donc aujourd'hui essentiel de concevoir des systèmes de classification automatique capables de mener à terme la recherche d'information au sein des collections d'images numériques, où la gestion manuelle devient impossible.

Le contexte de cette étude concerne la rétinopathie diabétique qui est devenue aujourd'hui la maladie la plus fréquente chez les diabétiques menant à la cécité totale. La détection précoce des premiers signes peut éviter la malvoyance. Depuis de nombreuses années, plusieurs études ont été menées pour développer des systèmes automatiques de dépistage et de suivi de la rétinopathie diabétique. Il s'agit ici de réaliser un système d'analyse automatique des images couleur du fond oculaire permettant de détecter et de localiser précisément l'évolution de pathologies rétiniennes. La détection des lésions telles que les micro anévrismes, les exsudats, etc. peut se faire en utilisant entre autres les indices visuels (taille, forme, couleur, .. ) mais aussi la combinaison de plusieurs classifieurs.

Pour mener à bien notre travail, nous adoptons l'organisation suivante :

Le chapitre 1 concerne le contexte médical. Après l'acquisition des images rétiniennes, nous passons à l'étude de la rétinopathie diabétique.

Le chapitre 2 passe en revue les principales techniques de classification ; les limites et les avantages de chaque sont précisées.

Le chapitre 3 décrit la méthodologie adoptée pour l'analyse des images rétiniennes ; les différentes composantes du système sont présentées.

Le chapitre 4 illustre l'environnement de travail ainsi, que la mise en œuvre du système développé. Différents tests sont effectués sur des images rétinienne.

## Résumé

Dans ce travail, nous nous intéressons à l'imagerie rétinienne et plus précisément aux images de fond de l'œil pour l'aide à la décision diagnostique d'une pathologie très répandue : la rétinopathie diabétique. Notre objectif est de concevoir un système pour la détection automatique des pathologies rétiniennes, ce système comporte une étape d'extraction qui permet d'extraire les caractéristiques de cette maladie et les décrire à partir d'une image de fond de l'œil. L'étape de classification qui décide si le cas traité correspond à un cas positif (œil pathologique) ou à un cas négatif (œil sain).

**Mots clés:** Extraction des caractéristiques, Traitement d'image, Classification, Rétinopathie diabétique, images de fond de l'œil.

## Summary

In this work, we study the retinal imaging and more specifically images for the background of the eye to help with diagnosis decision of a widespread pathology: the diabetic retinopathy.

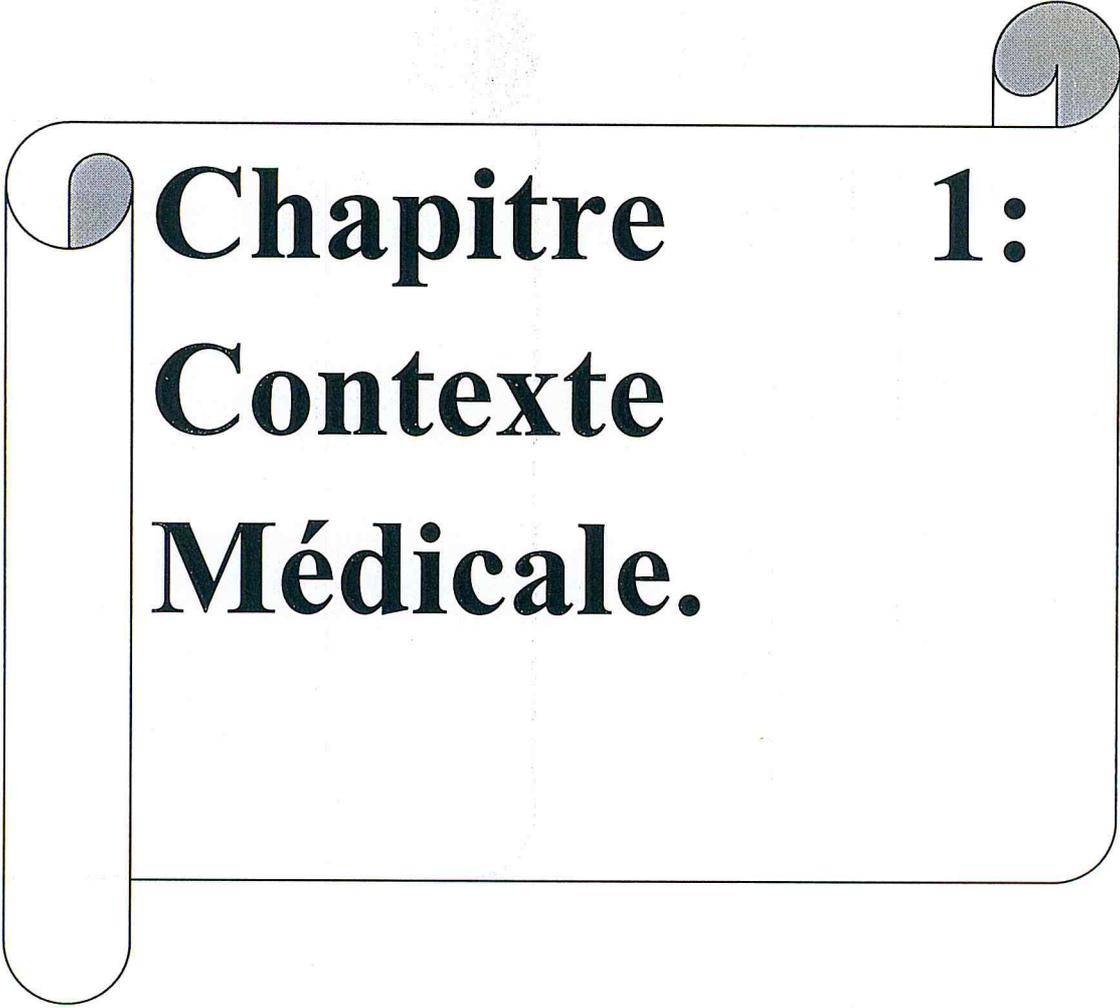
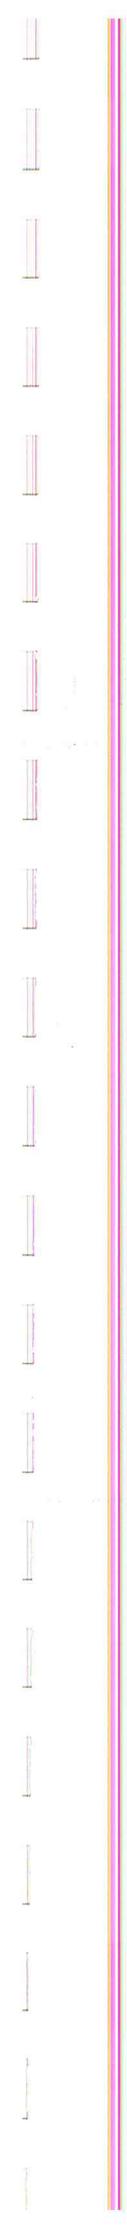
Our goal is to design a system for automatic detection of retinal pathologies, this system comprises an extraction step that extracts the characteristics of the disease and describe them from an image of the background of an eye. The classification step decides if the treated case belongs to a positive case (pathological eye) or a negative case (healthy eye).

**Keywords:** Feature extraction, Image processing, Classification, Diabetic retinopathy, images for the background of the eye.

## ملخص

في هذا العمل، نركز على تصوير شبكية العين وبالتحديد على الصور الملتقطة بواسطة الأنجيوجراف للمساعدة في تشخيص مرض منتشر على نطاق واسع: اعتلال السكري لشبكية العين. هدفنا هو تصميم نظام للكشف التلقائي لأمراض الشبكية، ويضم هذا النظام مرحلة يتم فيها استخراج ميزات أو خصائص المرض ثم وصفها من خلال صورة لشبكية العين. خطوة التصنيف تقرر إذا كانت الحالة حالة إيجابية (وجود مرض) أو حالة سلبية (عين صحية).

الكلمات الرئيسية: استخراج المواصفات، معالجة الصور، التصنيف، اعتلال السكري لشبكية العين، صور شبكية العين.



**Chapitre 1:  
Contexte  
Médicale.**

## 1. Introduction

L'œil est une merveille de la nature, un des organes les plus perfectionnés de notre corps. Miroir de nos émotions et de nos pensées secrètes, les yeux nous apportent une quantité fabuleuse d'informations car ils contiennent des photorécepteurs sensibles à la lumière. Le fonctionnement de l'œil peut être comparé à ce qui se passe quand on prend une photographie. Comme l'appareil photographique, les yeux permettent le contrôle de la focalisation d'une quantité de lumière à travers une lentille sur une surface photosensible ou une pellicule. Mais les yeux sont bien différents d'un appareil photographique, car après que l'image soit produite, elle est intégrée dans le système nerveux central [1].

## 2. L'anatomie de l'œil

L'œil est situé dans l'orbite, une cavité dans la crane : il a environ 2.5 cm de diamètre. La paroi de l'œil est formée de 3 tuniques [1] : la tunique fibreuse, la tunique uvéale, la Tunique nerveuse. Ces tuniques enferment des milieux transparents : l'humeur aqueuse, le Cristallin, le corps vitré.

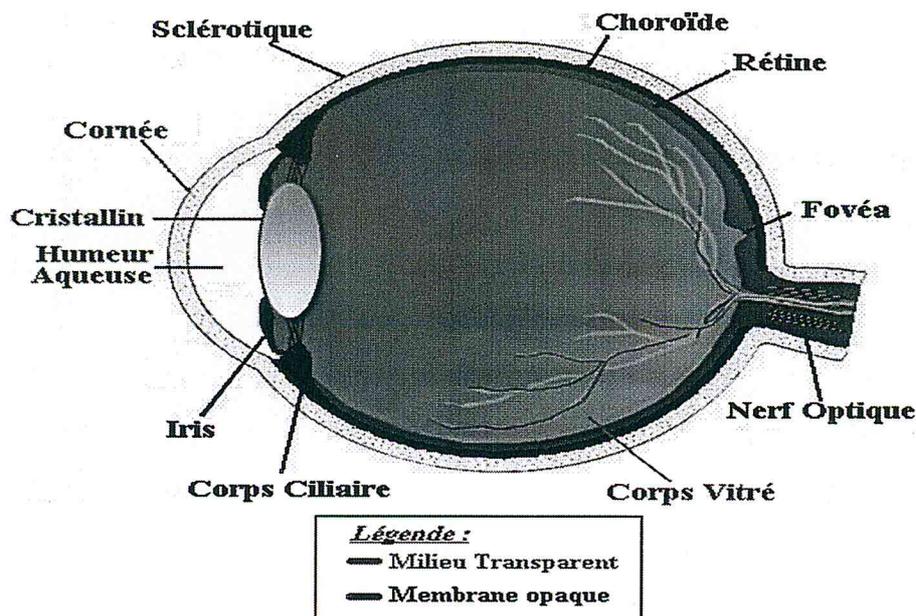


Figure 1.1 : Anatomie d l'œil [2].

### 2.1. La tunique fibreuse

La tunique fibreuse, externe, se compose de la sclérotique opaque en arrière et de la Cornée transparente en avant [1].

**La Sclérotique:** une enveloppe de protection. Elle recouvre environ les cinq sixièmes de la surface de l'œil. Elle donne à l'œil sa couleur blanche et sa rigidité.

**La cornée:** constitue la lentille principale du système optique oculaire. Pour que ce tissu puisse remplir sa fonction, il doit être transparent et tout concourt à assurer cette transparence.

La cornée est enchâssée dans l'ouverture antérieure de la sclérotique, elle est la structure qui a la plus grande sensibilité tactile du corps humain.

## 2.2. La tunique uvéale

La tunique uvéale, dite aussi uvée, se compose de 3 éléments : l'iris en avant, le corps ciliaire, la choroïde en arrière [1].

**L'iris:** est la partie colorée de l'œil, il permet de contrôler la taille de la **pupille** (ouverture centrale de l'œil) et donc la quantité de lumière: diaphragme de l'œil. La contraction ou la dilatation réflexe règlent la quantité de lumière pénétrant dans l'œil par la pupille.

**Le corps ciliaire:** est représenté par un épaississement de l'uvée situé en couronne derrière l'iris contenant des fibres musculaires lisses et des vaisseaux sanguins.

**La choroïde:** est une couche vasculaire de couleur noire qui tapisse les trois cinquièmes postérieurs du globe oculaire. C'est le tissu nourricier de l'œil, il est très riche en vaisseaux sanguins afin de nourrir les photorécepteurs de la rétine.

## 2.3. La tunique nerveuse

La tunique nerveuse se compose de [1]:

### La rétine:

La rétine est un tissu transparent qui est responsable de la transformation de la lumière en impulsion électrique. C'est une structure complexe formée de deux couches de cellules pigmentaires, et de neurones qui reçoivent les rayons lumineux et les convertissent chimiquement en influx nerveux. La rétine recouvre la partie postérieure de l'œil, mais seule sa partie la plus postérieure est photosensible. Il existe deux types de photorécepteurs [1]:

#### a. Les bâtonnets:

Les plus nombreux, essentiellement situés au niveau de la rétine périphérique, sont responsables de la vision périphérique en lumière de faible intensité. Ils ont une très grande sensibilité à la lumière, d'où leur capacité à percevoir de très faibles lueurs la nuit. Ainsi ils

ont une très faible perception des détails et des couleurs car plusieurs dizaines de bâtonnets ne sont liés qu'à une seule fibre du nerf optique.

### b. Les cônes:

Dans principalement regroupés dans la rétine centrale, au sein d'une zone ovale appelée, macula, sont destinés à la vision des détails et à la vision colorée.

Ainsi ils ont une très bonne sensibilité aux couleurs. Ils sont de trois types selon le pigment

qu'ils contiennent et ont donc une sensibilité à des ondes lumineuses de longueurs différentes:

cônes contenant de l'**érythrosine** (sensibles au rouge), de la **chloropsine** (vert), du **cyanopsine** (bleu).

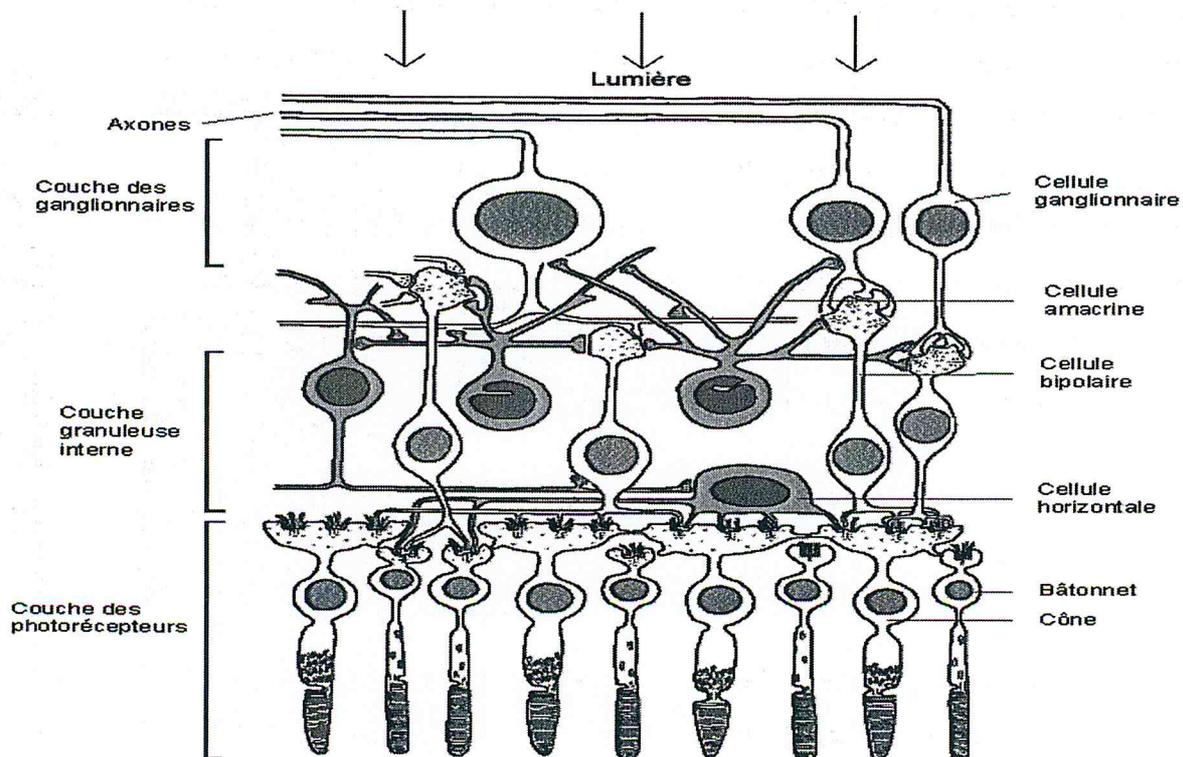


Figure 1.2 : Structure de la rétine [2].

Deux endroits importants de la rétine sont encore à définir: la fovéa et la tache aveugle.

**La fovéa** : est le centre géométrique de la rétine plus précisément la zone centrale de la macula. Elle possède une forte densité de cônes, ce qui explique la perfection et la précision des images visuelles qui s'y forment. Elle constitue donc la zone maximale de l'acuité visuelle.

**La tache aveugle** : quant à elle, est un endroit dépourvu de photorécepteurs car c'est le point de convergence de tous les axones des cellules ganglionnaires formant le nerf optique.

**La macula** : est une petite zone de 1mm de diamètre, située au centre de la rétine, juste dans l'axe visuel. Cette petite zone centrale est précieuse car elle contient les cellules photoréceptrices, responsables de la vision précise qui permet la lecture, l'écriture, la reconnaissance des détails. Le reste de la rétine périphérique, contient d'autres cellules photoréceptrices qui nous permettent de percevoir l'environnement, l'espace qui nous entoure, c'est à dire notre champ visuel.

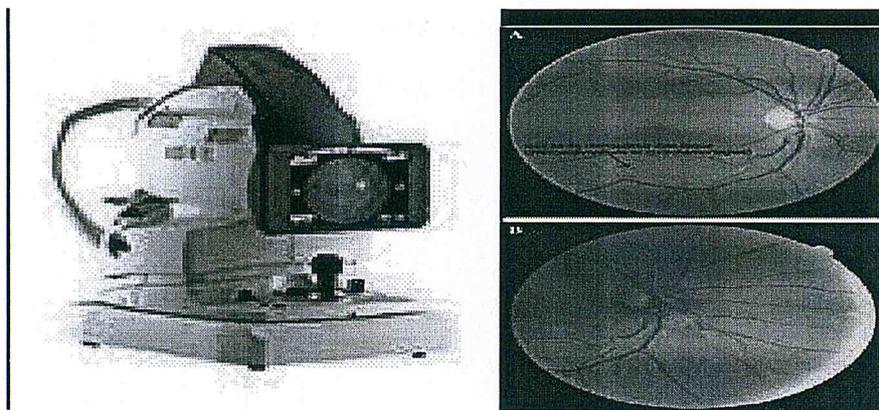
La rétine est irriguée par des vaisseaux sanguins qui lui apportent les éléments nutritifs nécessaires à son fonctionnement. Ces vaisseaux, artères et veines donnent des capillaires très fins qui irriguent les cellules nerveuses de la rétine.

### 3. Acquisition des images rétiniennes

La création des images rétiniennes adoptées sur deux appareils, qui son :

#### 3.1. La rétinographie

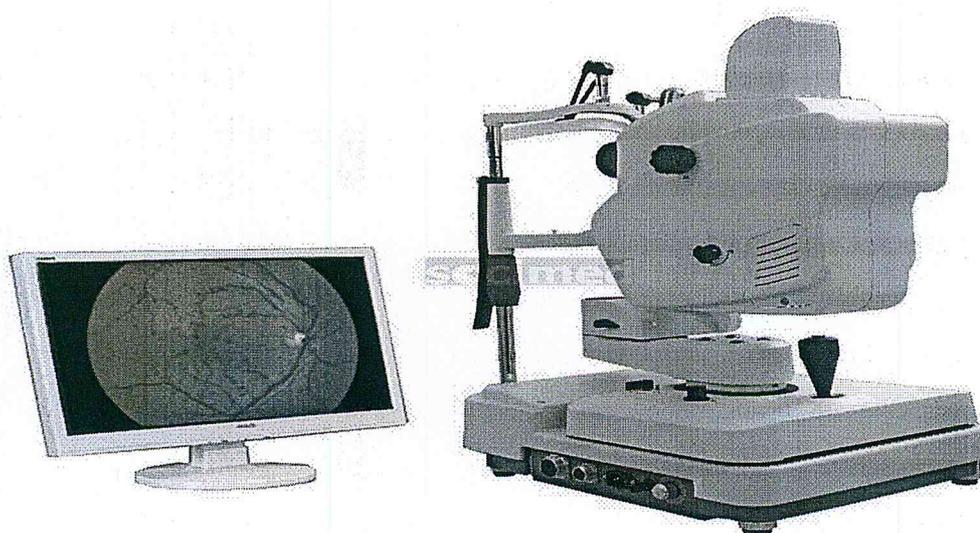
Les rétinographies non mydriatiques sont les appareils de choix pour le dépistage de la RD. En effet, ils sont faciles d'emploi, et ils permettent la prise de photographies sans dilatation pupillaire. Il est difficile d'indiquer leurs caractéristiques précises, compte tenu de l'évolution technologique très rapide de ces appareils, permettant de prendre des photographies ayant une résolution de plus en plus grande. Néanmoins, leur résolution doit être suffisante pour permettre l'identification des lésions élémentaires de la RD (micro anévrysmes, néo vaisseaux pré rétiniens ou pré papillaires, anomalies micro vasculaires intra rétiniennes). Les rétinographies doivent permettre l'acquisition d'images au minimum sur 45 horizontalement et 40 verticalement. Peut s'effectuer en lumière visible ou infrarouge, la lumière infrarouge permet d'examiner l'œil avec une dilatation naturelle [3]. L'écran de visualisation des images a l'acquisition ne sert qu'au contrôle de qualité des images, il peut s'agir d'un simple écran.



**Figure 1.3 :** La rétino-graphie et les images traitées par cet appareil.

### 3.2. L'angiographies rétiniennes à la fluorescéine

L'angiographie est l'appareil utilisé pour un examen d'angiographie rétinienne (figure 1.5). La technique consiste à prendre des photographies de la rétine sur un intervalle de temps d'une dizaine de minutes.



**Figure 1.4 :** L'angiographie

L'angiographie est muni d'un support de filtres afin de choisir différents types de lumière (bleue, verte, rouge) qui sera projetée sur la rétine qui réfléchit une image dont seule la longueur d'onde sélectionnée par un filtre d'arrêt est reçue par une caméra CCD ou un film photographique [4]. Pour obtenir un meilleur contraste et un aspect fonctionnel des structures rétiniennes (arbre vasculaire, dépôts lipidiques, structures pathologiques), on utilise un produit de

contraste injecté dans la circulation sanguine : il s'agit de la fluorescéine en lumière visible et du vert d'indocyanine en infrarouge.

Différentes technique d'imagerie peuvent être utilisées [4] :

1. éclairage par un flash de lumière visible :

- Photographie noir et blanc avec utilisation de divers filtres colorés pour sélectionner la meilleure représentation des structures anatomiques,
- Diapositive couleur (avant injection de produit de contraste) : superposition des différentes informations sur la même photographie.

2. Balayage par un faisceau laser (Scanning Laser ophtalmoscope) : L'image obtenue est fonction de la longueur d'onde du faisceau utilisé :

- Lumière visible : Structures rétinienne.
- Lumière infrarouge : Structures choroïdiennes (couches profondes).

Ce mode d'acquisition permet une meilleure qualité des images, avec un meilleur contraste. En effet, l'éclairage des structures étant ponctuel, il n'y a pas d'effet de diffusion sur les structures éloignées.

L'angiographie est une technique d'imagerie utilisée en routine clinique, elle présente de nombreux avantages : non invasive, a traumatique et permet une bonne visualisation du réseau vasculaire rétinien par injection du produit de contraste, il est ainsi possible de mettre en évidence l'aspect fonctionnel de la rétine et de sa circulation sanguine [4].

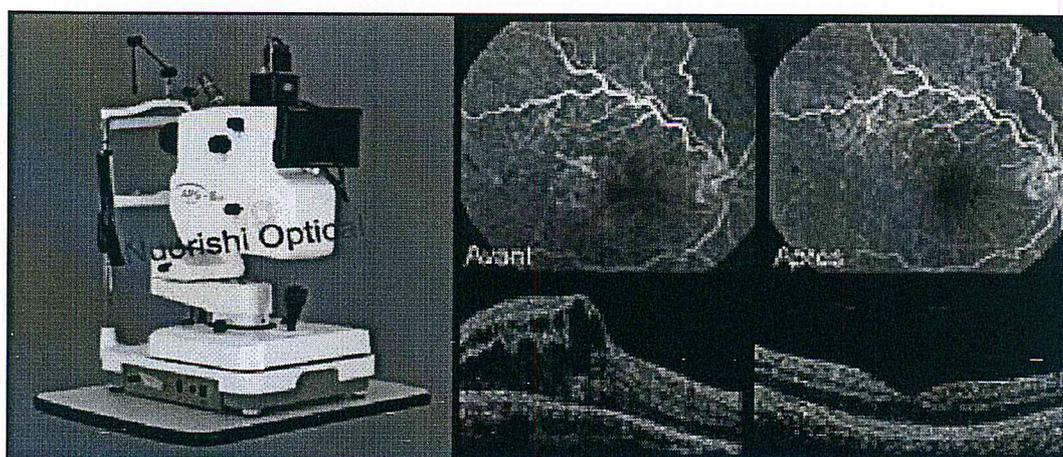


Figure 1.5 : L'angiographie et les images traitées par cet appareil.

### 3.3. Les différents types de clichés utilisés dans le diagnostic de la (RD)

Les clichés utilisés dans le diagnostic sont :

### 3.3.1. Image de couleur

Le médecin peut réaliser une simple photographie en couleur du fond d'œil, en utilisant une caméra du fond d'œil fournissant directement des images digitales ce qui simplifie le stockage et permet un traitement d'images direct (rétinographie).

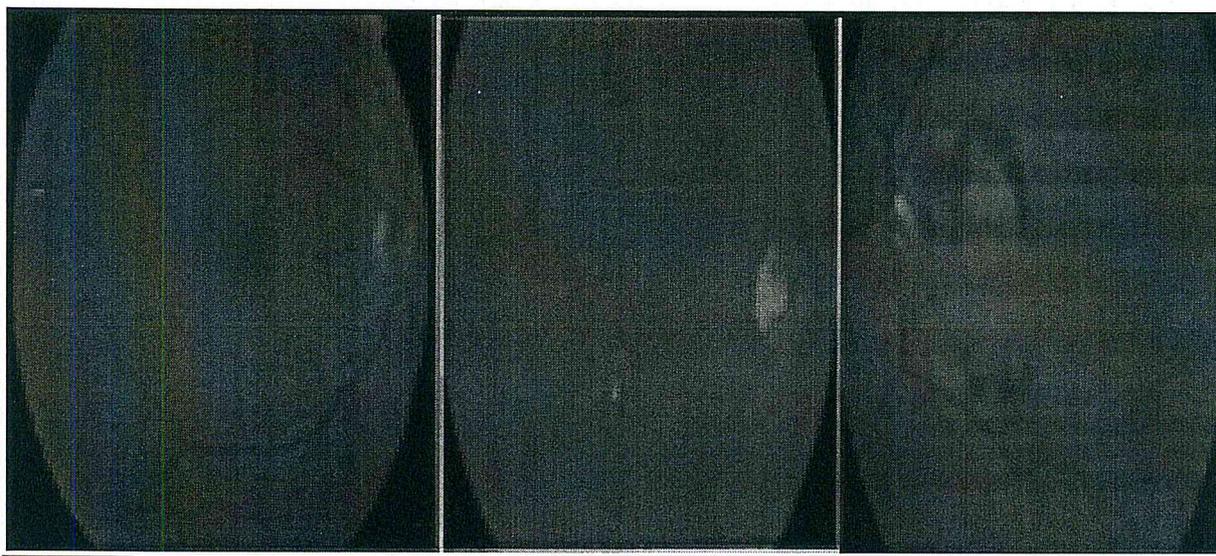


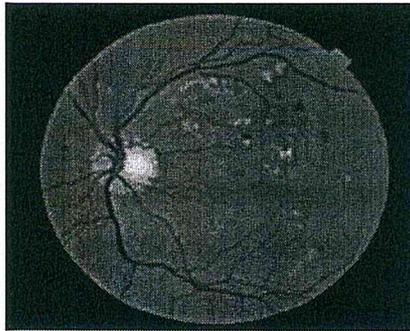
Figure 1.6 : Image couleur de rétine

### 3.3.2. Image couleur stéréo

Il s'agit d'une paire d'images couleur qui sont prises sous des angles différents, ou avec une caméra décalée parallèlement.

### 3.3.3. Angiographie à la fluorescéine

Dans cette méthode, un produit de contraste est injecté par voie intraveineuse. Ce produit est diffusé dans le système sanguin. En prenant une série de photos sous lumière ultraviolette, on obtient des images correspondant aux différentes phases de propagation dans la rétine.



**Figure 1.7 :** Images d'angiographie rétinienne à la fluorescéine

## 4. La rétinopathie diabétique

- \* C'est une micro-angiopathie : capillaropathie.
- \* Touche toute la micro-circulation de l'œil.
- \* Première cause de cécité dans les pays industrialisés.
- \* Survient après 5 à 7 ans d'évolution de la maladie diabétique.
- \* Le pourcentage de diabétiques présentant une rétinopathie diabétique augmente avec l'ancienneté du diabète.
- \* Le diagnostic repose sur l'examen du fond d'œil et l'analyse soignée de l'angiographie fluorescéinique.
- \* le pronostic fonctionnel est redoutable mais : possibilités de traitement par photo coagulation au laser selon les données de l'angiographie [5].

### 4.1. Etiopathogénie et physiologie de la rétinopathie diabétique

La rétinopathie diabétique est une maladie due à une lésion de capillaires rétiens : La micro-angiopathie. Elle dépend de l'ancienneté du diabète, du mauvais équilibre glycémique et des autres facteurs de risque vasculaire (hyper tension artérielle : HTA, Tabac..). La micro-angiopathie touche les capillaires rétiens : leur tortuosité augmente et leur résistance est altérée suite à un épaissement de leur paroi. Cette micro-angiopathie a 2 conséquences : hyperperméabilité capillaire responsable de fuite intra rétinienne de plasma (œdème) ou de globules rouges (hémorragies), et occlusion capillaire responsable d'ischémie de la rétine [4]. Cette redoutable ischémie va déclencher la formation de néo-vaisseaux fragiles et

anarchiques, vont alors être responsables de complications : hémorragies intra-rétiniennes, hémorragies dans le vitré, décollement de la rétine, glaucome néo-vasculaire.

## 4.2. Classification de la rétinopathie diabétique

La rétinopathie diabétique apparaît 7 à 10 ans après le début du diabète. Elle débute par un stade de **rétinopathie diabétique non proliférant**. Caractérisée par la présence de micro-anévrismes et d'hémorragies rétiniennes[6].

### Les micro-anévrismes :

Les micro-anévrismes sont des ectasies développés à partir d'un capillaire rétinien. Ils ont été décrits par Mackenzie et Nettleship il y a plus de cent ans. Ils ont un diamètre de 12 à 100 µm mais seuls ceux de plus de 30 µm sont perceptibles à l'ophtalmoscopie ou ils apparaissent comme de petites taches rouges lorsqu'ils sont récents [4]. Après maturation, ils peuvent devenir jaunâtres car leur paroi s'épaissit, leur lumière diminue et les globules rouges y sont plus difficiles à voir.

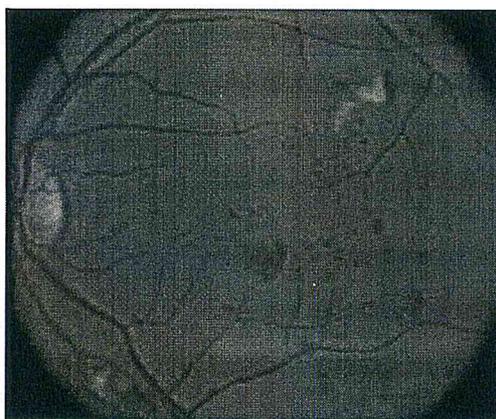
### Les hémorragies rétiniennes :

\_ Les hémorragies ponctiformes : elles sont superficielles, de petite taille, de forme circulaire et aux bords nets. Dans des images couleur, elles ressemblent souvent aux micro-anévrismes tout en étant un peu plus grandes, alors qu'en angiographie il est facile de distinguer ces deux lésions.

\_ Les hémorragies en flammèches : elles sont situées dans la couche des fibres optiques, elles sont de forme allongée.

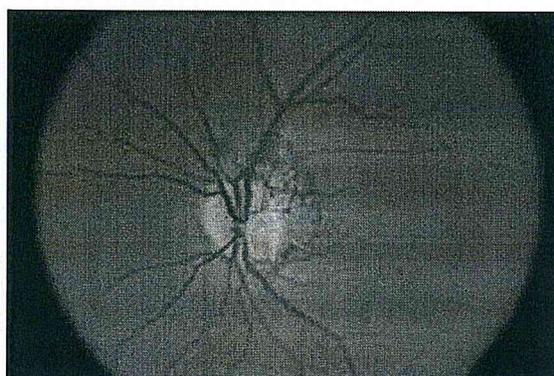
\_ Les hémorragies en taches : elles sont dues à une occlusion capillaire dans une couche profonde. Elles témoignent d'une ischémie rétinienne. Elles apparaissent comme des taches rouges aux bords irréguliers pas toujours très nets et de taille variée.

Dont le nombre augmente progressivement avec le temps. L'ischémie rétinienne périphérique apparaît et s'étend progressivement. Lorsque l'ischémie est déjà très étendue mais qu'il n'y a pas encore de néo-vaisseaux, on parle de **rétinopathie diabétique non proliférant sévère** [6] (ou pré proliférant figure (1.8)).



**Figure 1.8 :** Une rétinopathie diabétique pré-proliférative.

A ce stade il existe un risque élevé d'apparition de néo-vaisseaux a la surface de la rétine. On peut alors proposer un traitement préventif par laser qui évitera l'apparition des néo-vaisseaux [7]. Lorsque des néo-vaisseaux sont déjà apparus a la surface de la rétine ou de papille. On parle de **rétinopathie proliférante** figure (1.9).

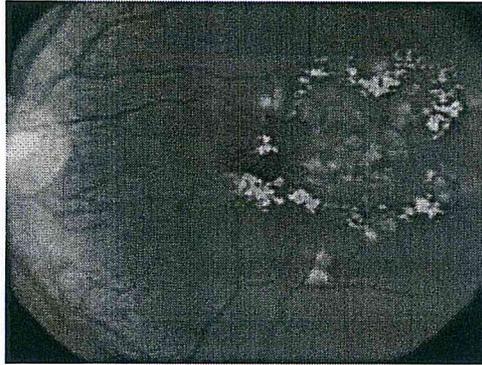


**Figure 1.9 :** Une rétinopathie diabétique proliférative.

Ce sont les néo-vaisseaux qui sont responsables des complications pouvant entrainer la cécité : ils peuvent saigner, entrainant une hémorragie a l'intérieur de l'œil (*hémorragie intravitréenne*), et/ou se rétracter et provoquer un décollement de la rétine. A un stade ultime de la rétinopathie diabétique proliférante, lorsque l'ischémie rétinienne est tres étendue, des néo-vaisseaux peuvent même proliférer a la surface de l'iris (*rubéose irienne*) et conduire a un glaucome néo-vasculaire particulièrement grave pour l'avenir de l'œil atteint. Au niveau de la macula, l'accumulation de liquide en provenance du : plasma sanguin, sérum, aboutit a la constitution d'un œdème maculaire.

### **L'Œdème maculaire diabétique :**

L'œdème maculaire diabétique (OMD) est une complication souvent associée à la RD plus fréquente dans le diabète de type 2 [7] que dans le diabète de type 1 [8]. Un OMD peut survenir tout moment dans l'évolution de la RD et se caractérise par une dilatation veineuse, des anomalies de la micro-vascularisation intra-rétinienne et une rupture de la barrière hémato-rétinienne, avec une fuite de plasma des petits vaisseaux dans la macula (Figure (1.10)).



**Figure 1.10** : Un œdème maculaire diabétique

L'œdème peut s'accompagner d'exsudats qui sont secondaires à une diffusion de lipides à travers la paroi des micro-anévrysmes et des segments capillaires dilatés, et à leur précipitation dans la rétine. La présence d'un œdème signifie un épaississement de la rétine maculaire, au bout d'un certain temps, la distension du tissu rétinien maculaire épaissi par l'œdème provoque des lésions des cellules visuelles et une baisse de la vue.

#### **4.3. Quels sont les symptômes de la rétinopathie diabétique ?**

La rétinopathie diabétique peut rester silencieuse tout au long de son évolution. Les symptômes qu'elle entraîne surviennent tardivement et sont causés par ses complications. Il peut s'agir d'une baisse visuelle progressive dans un œil ou dans les deux, provoquée par l'œdème maculaire, ou bien d'une baisse de la vue brutale, le plus souvent unilatérale, due à une hémorragie intra-vitréenne compliquant une rétinopathie diabétique proliférante. Dans tous les cas, la baisse visuelle est indolore.

#### **4.4. Rétinopathie et mortalité**

La présence et la gravité de la rétinopathie diabétique sont un facteur significatif du pronostic vital du patient diabétique. Caird [4] étudie les taux de mortalité chez les diabétiques selon le degré de gravité de la rétinopathie diabétique après 7 ans d'évolution :

- 4% de mortalité chez les sujets avec fond d'œil normal.
- 10% chez ceux ayant quelques micro-anévrysmes.
- 59% dans les cas d'hémorragies et exsudats.
- 68% en cas de rétinopathie diabétique proliférante.

L'intervalle entre l'apparition de la cécité et le décès de 3 à 5 ans, les principales causes de la mort sont la néphropathie (45%) et les complications cardiovasculaires (37%).

#### **4.5. Traitement de la rétinopathie diabétique**

Les complications de la rétinopathie diabétique, qui sont la cause de malvoyance et de cécité, peuvent être prévenues par un traitement adapté : l'équilibre strict de la glycémie et de la tension artérielle permettent de diminuer l'incidence et de ralentir la progression de la rétinopathie diabétique [4]. Selon le degré d'évolution de la maladie, l'ophtalmologiste peut être amené à proposer un traitement complémentaire par photo-coagulation des lésions rétiniques au LASER. Le succès d'un traitement simple et efficace dépend essentiellement du moment où il est appliqué : la cécité ou la malvoyance ne peuvent être prévenues que si le traitement est appliqué précocement, donc dans un stade asymptomatique. Mais l'évolution des lésions liées à la rétinopathie diabétique se fait le plus souvent sans bruit au début, car elles épargnent la partie centrale de la rétine. La vision ne commence à diminuer que lorsque la macula est elle-même atteinte, alors que la maladie évolue déjà silencieusement depuis longtemps. C'est dire l'intérêt de réaliser des bilans de routine chaque année, à la recherche des lésions insoupçonnées par le malade : la rétinopathie diabétique remplit tous les critères pour faire l'objet d'un dépistage de masse [4]. L'angiographie en fluorescence est indispensable lorsqu'il existe une rétinopathie diabétique. Elle est également pratiquée chez les diabétiques ayant plus de 5 années d'évolution du diabète [4]. L'angiographie permet, en effet de mettre en évidence des signes infra-cliniques de rétinopathie diabétique, ou des signes discrets qui peuvent échapper à l'examen bio-microscopique. Elle sert également de guide au traitement par photo-coagulation.

### **5. L'analogie entre les images rétiniques et la réalité physiologique**

Les images couleur sont bien adaptées par les médecins parce qu'elles correspondent effectivement à ce qu'ils verraient lors d'un examen du fond d'œil. Il est essentiel de savoir quelle information que chaque couleur nous apporte et d'où vient la couleur rouge de la rétine.

### 5.1. L'interaction de la lumière avec le fond d'œil

DELORI et PFLIBSEN ont montré que la réluctance du fond d'œil dépend de longueur d'onde de la lumière incidente. Elle est plus forte pour la partie rouge du spectre que les parties « vert et bleu » : ce qui explique l'apparence rouge de l'image rétinienne. Cela ne veut pas dire que dans le rouge, il y a plus d'informations ou plus de précision sur la rétine. Les rayons lumineux entrent dans la pupille : il ya une partie qui est transmise, une partie qui est absorbée et une partie réfléchi il d'agit de cette dernière partie de la lumière que l'on peut voir si l'on regarde le fond d'œil. Elle varie selon les caractéristiques de la couche réfléchissante : la concentration en hémoglobine, la profondeur [3].

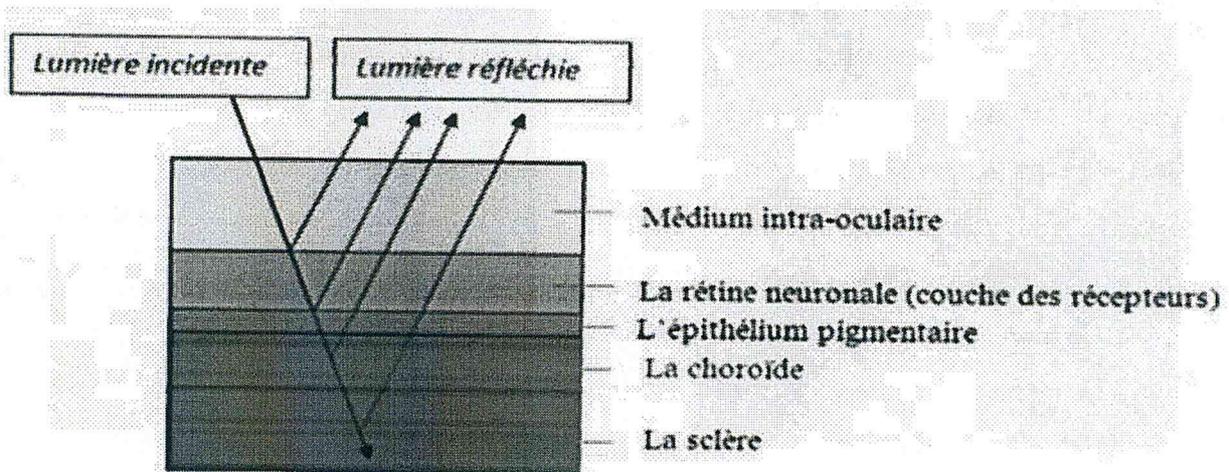


Figure 1.11 : La réfraction de la lumière dans les différentes couches de la rétine[3].

## 6. La Télémédecine

La télémédecine regroupe les pratiques médicales permises ou facilitées par les télécommunications. C'est un exercice de la médecine par le biais des télécommunications et des technologies qui permettent la prestation de soins de santé à distance et l'échange de

l'information médicale s' rapportant, plus largement, on désigne aussi ce concept par de la télé-présence[9].

La télémédecine peut se définir aussi par l'OMS (organisation mondiale de la santé) comme « l'utilisation des moyens et des techniques qui permettent a distance la pratique médicale » [10].

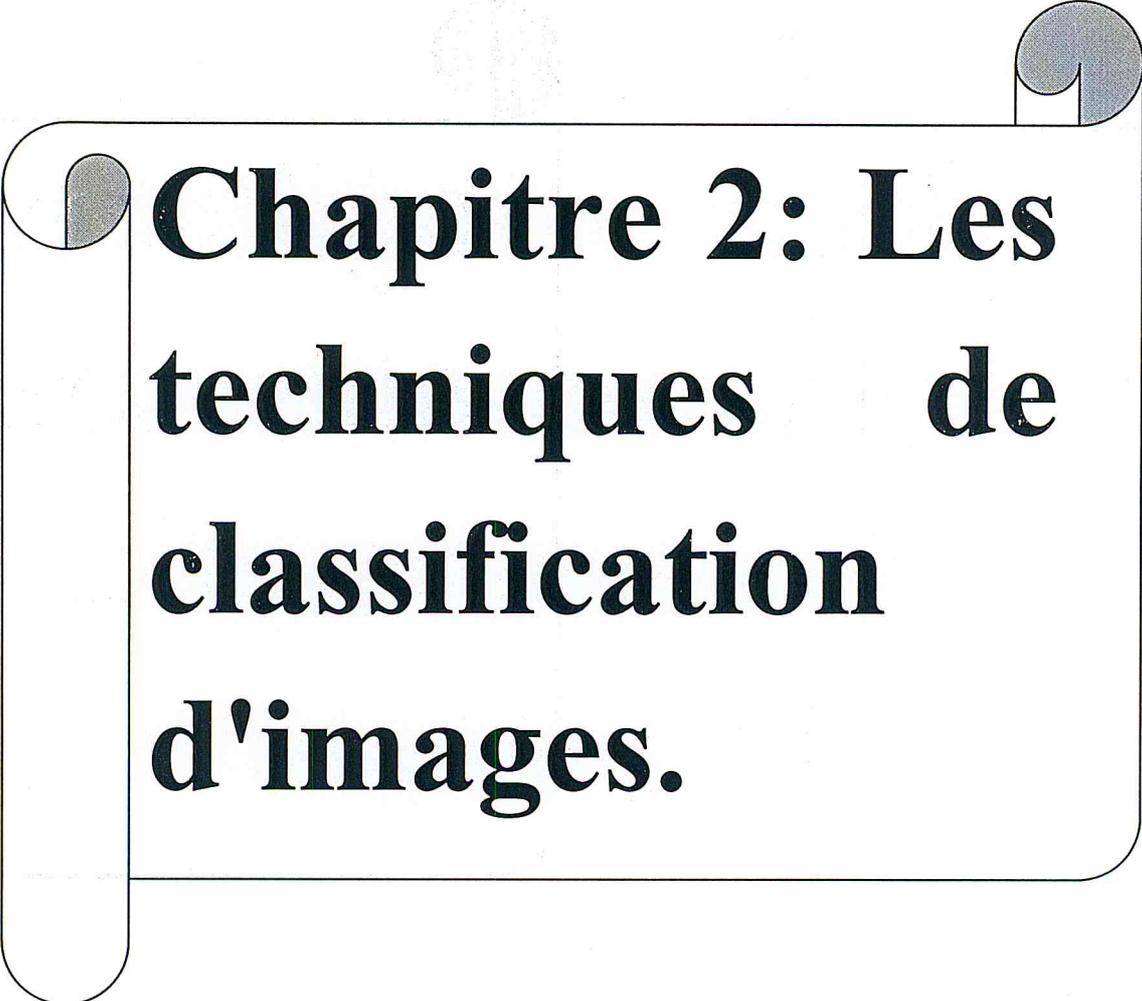
## 6.1. Bénéfices pour les patients

Les bénéfices de la télémédecine pour le patient sont nombreux, mais relèvent tous d'une meilleure qualité de prise en charge :

- Par un meilleur accès aux soins, notamment pour les patients en situation d'isolement ou d'éloignement géographique, ou confrontés a l'absence de professionnel de santé a proximité.
- Par un meilleur suivi médical, notamment pour les patients souffrant d'une pathologie chronique (diabète).
- Par une prise en charge plus rapide, notamment dans les situations d'urgence qui nécessitent le recours a l'expertise médicale (traumatismes crâniens, accident vasculaire cérébral,.....).

## 7. Conclusion

La rétine est la pièce maitresse de l'œil. Elle constitue dans le système visuel humain, le capteur des images du monde environnant. Les altérations des vaisseaux de la rétine peuvent donc être préjudiciables a la vue. La structure vasculaire de la rétine ainsi que la rétinographie qui permet d'observer cette structure aux fins du diagnostic et/ou du traitement de la pathologie oculaire ont été présentés dans ce premier chapitre. La pathologie des vaisseaux de la rétine due a la présence du diabète, et qui peut être diagnostiquée par analyse des images de la rétinographie été également décrite. Il s'agit de la rétinopathie diabétique.

A decorative graphic of a scroll with a black outline and rounded corners. The scroll is partially unrolled, with a grey circular element at the top right corner and a grey circular element at the top left corner. The text is centered within the scroll.

**Chapitre 2: Les  
techniques de  
classification  
d'images.**

### 1. Introduction

Les méthodes de classification ont pour but d'identifier les classes, auxquelles appartiennent des objets à partir de certains traits descriptifs ou caractéristiques.

Elles s'appliquent à un grand nombre d'activités humaines et, conviennent en particulier au problème de la prise de décision automatisée.

La procédure de classification sera extraite, automatiquement à partir d'un ensemble d'exemples. Un exemple consiste en la description d'un cas avec la classification correspondante. Un système d'apprentissage doit alors, à partir de cet ensemble d'exemples, extraire une procédure de classification. Dans ce cas, il s'agit en effet, d'extraire une règle générale à partir des données observées. La procédure générée, devra classer correctement les exemples de l'échantillon et, avoir un bon pouvoir prédictif pour classer correctement de nouvelles descriptions. Le terme de classification peut désigner deux approches distinctes: la classification supervisée et la classification non-supervisée.

Les méthodes non supervisées ont pour but de constituer des groupes d'exemples (ou des groupes d'attributs) en fonction des données observées, sans connaissance a priori. En revanche les méthodes supervisées utilisent la connaissance a priori sur l'appartenance d'un exemple à une classe pour construire un système de reconnaissance de ces classes

### 2. Définition

La classification est une discipline reliée 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 a atteindre.

Pour attribuer une définition au terme « classification », il faudrait d'abord définir ses racines, ça vient du verbe 'classer ' qui désigne plus une action qu'un domaine, ou plutôt une série de méthodes qu'une théorie unifiée.

En mathématique, on appelle classification, la catégorisation algorithmique d'objets. Elle consiste a attribuer une classe ou catégorie a chaque objet(ou individu) a classer, en se basant sur des données statistique. Elle fait couramment appel aux méthodes d'apprentissage et largement utilisée en reconnaissance de formes.

Il est important de noter qu'il ne faut pas confondre entre ces deux termes :

« Classification » et « Classement », au fait le mot classification en anglais signifie une chose, alors que le même mot en français ait une autre signification (utilité).

Dans un classement, on affecte les objets a des groupes préétablis, c'est le but de l'analyse discriminante que de fixer des règles pour déterminer la classe des objets. La classification est donc, en quelque sorte, le travail préliminaire au classement, savoir la recherche des classes 'naturelles' dans le domaine étudié, en anglais « Cluster Analysis».

### 3. Les étapes d'une classification

On peut résumer la classification en quatre étapes [11]:

1. Choix des données.
2. Calcul des similarités entre les n individus a partir des données initiales.
3. choix d'un algorithme de classification et exécution.
4. L'interprétation des résultats :
  - évaluation de la qualité de la classification.
  - description des classes obtenues.

### 4. Les méthodes de Classifications

On peut grouper les méthodes classificatoires en deux grandes familles, cette foi-ci, on prend en considération l' l'intervention ou non d'un << attribut classe >> au fur et a mesure du processus de la classification, ces deux types sont[12] :

- i. Classification non supervisée (Classification, Clustering) appelée aussi classification sans apprentissage qui vise a séparer automatiquement l'image en clusters naturels, c'est -a- dire sans aucune connaissance préalable des classes.
- ii. Classification supervisée (Classement), qui s'opère a partir de la connaissance de chacune des classes définies.

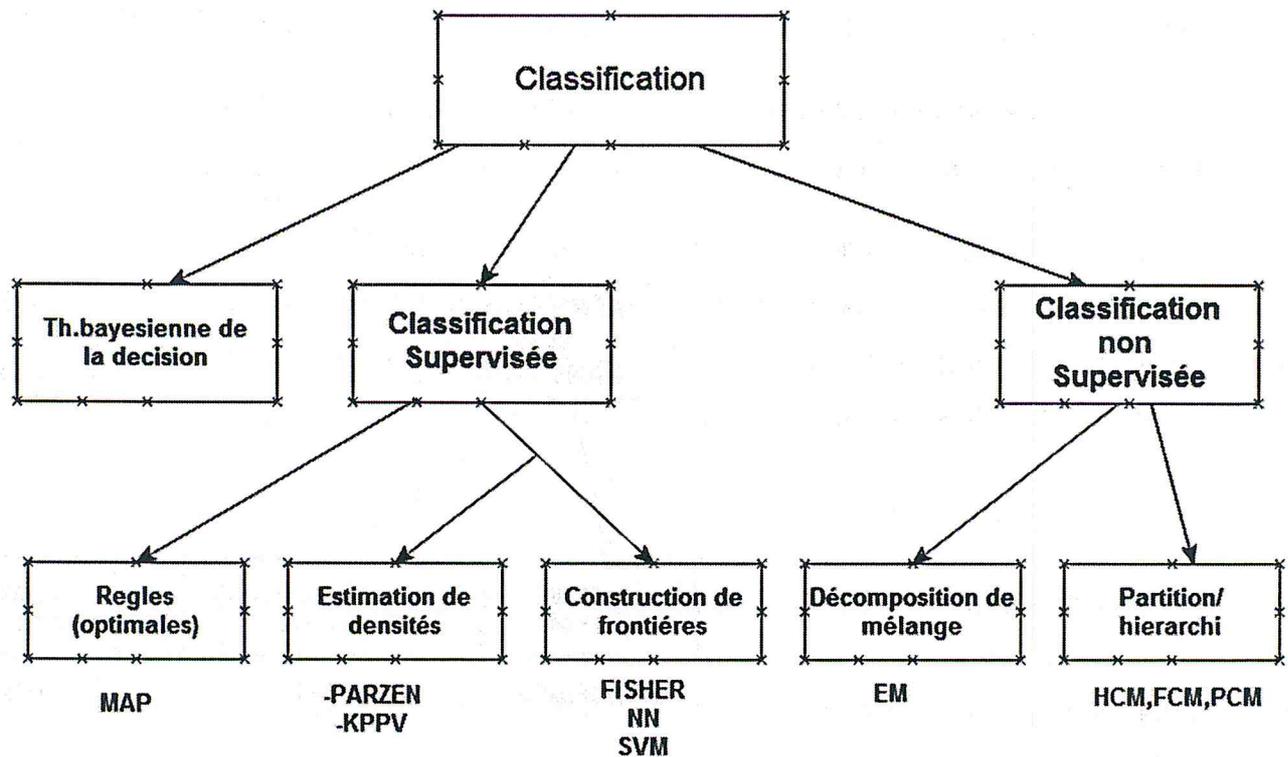


Figure 2.1 : Les méthodes de classification [12].

## 5. Les approches de classifications

On distingue d'une façon générale deux grands types de approches [11] :

### i. Approche non paramétrique :

Les approches dites non paramétriques (classification hiérarchique, méthode des centres mobiles) basée sur l'hypothèse : plus deux individus sont proches, plus ils ont de chances de faire partie de la même classe, en plus ce que distingue cette approche est qu'on ne fait aucune hypothèses sur le modèle que suivent les données, c'est le cas des plus proches voisins (K-PPV), donc il suffit de trouver les propriétés de convergence quand le nombre de données est grand.

### ii. Approche paramétrique "probabilistes :

La seconde grande famille des méthodes de classification, ce sont les approches probabilistes, utilisent une hypothèse sur la distribution des individus à classer, c'est-à-dire, on suppose que l'on connaît la forme du modèle qui a généré les données.

Par exemple, on peut considérer que les individus de chacune des classes suivent une loi normale. Le problème qui se pose, est de savoir déterminer ou estimer les paramètres des lois (moyenne, variance) et à quelle classe les individus ont le plus de chances d'appartenir à partir de l'ensemble d'apprentissage. Les paramètres d'une loi peuvent être déterminés de maintes façons, c'est le cas par exemple des classifications bayésiennes ou encore l'algorithme d'espérance maximisation [12].

Parmi les classificateurs de l'approche paramétrique on trouve : le classificateur euclidien, quadratique, gaussien. On va présenter le classificateur euclidien.

### **6. La classification supervisée**

L'objectif de la classification supervisée est d'apprendre, à l'aide d'un ensemble d'entraînement, une procédure de classification qui permet de prédire l'appartenance d'un nouvel exemple à une classe. En d'autres termes, l'objectif est d'identifier les classes auxquelles appartiennent des objets à partir de leurs variables descriptives [13].

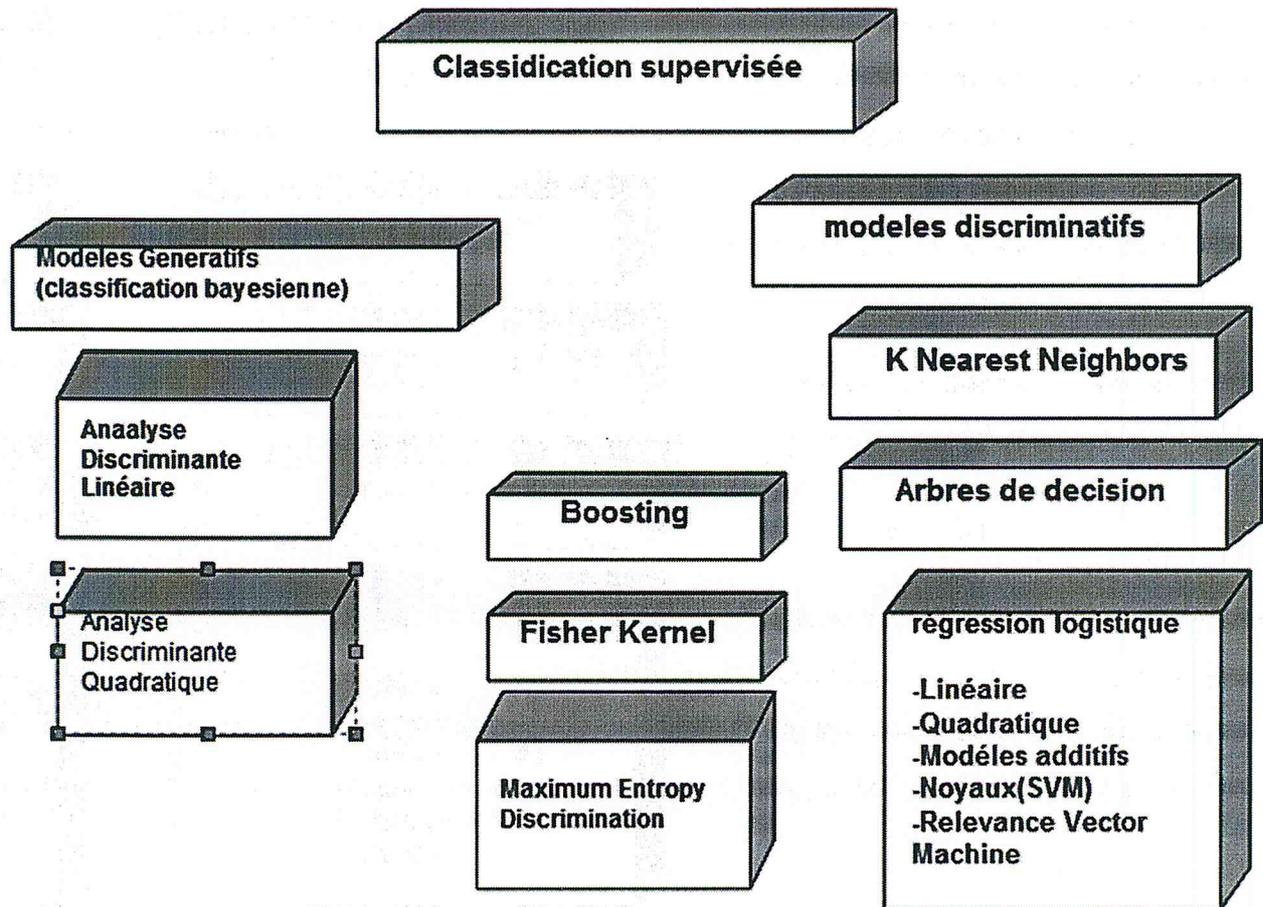


Figure 2.2: Les différentes modèles de classification supervisée [13].

## 6.1 Méthode KPPV

### 6.1.1. Les K plus proches voisins KPPV

Plus connus en anglais sous le nom K- nearest neighbor (K-NN), ou encore Memory Based Reasoning [14]. Cette méthode diffère des traditionnelles méthodes d'apprentissage car aucun modèle n'est induit à partir des exemples. Les données restent telles quelles : elles sont simplement stockées en mémoire.

pour prédire la classe d'un nouveau cas (où ranger un nouveau document par exemple), l'algorithme cherche les K plus proche voisins de ce nouveau cas et prédit (s'il faut choisir) la réponse la plus fréquente de ces k plus proches voisins

La méthode utilise donc deux paramètres : le nombre K et la fonction de similarité pour comparer le nouveau cas aux cas déjà classés.

$$d(x_i, x_j) = \sqrt{\sum_{r=1}^n (\alpha_r(x_i) - \alpha_r(x_j))^2}$$

Cette méthode supervisée et non-paramétrique est souvent performante. de plus, son apprentissage est assez simple, car il est de type apprentissage par cœur (on garde tous les exemple d'apprentissage). Cependant, le temps de prédiction est très long, car il nécessite le calcul de la distance avec tous les exemple, mais il existe des heuristique pour réduire le nombre d'exemples a prendre en compte [12].

### 6.1.2. Algorithme de KPPV

On résume l'algorithme de KPPV en deux étapes essentielles:

1. initialisation, choix de :

- ✓ nombre de classe, Valeur de k, exemples initiaux, mesure de similarité.

2. pour chaque vecteur d'objet a classé :

- ✓ mesurer la distance du vecteur avec tous les autres déjà classés.
- ✓ déterminer la liste des K vecteurs les plus proches de lui (K-ppv)
- ✓ déterminer la classe la plus présentée dans la liste des k-ppv et affecter notre vecteur a cette classe.

### 6.1.3. Sélection de la classe

La méthode la plus simple est de rechercher le cas le plus proche et de prendre la même décision. C'est la méthode 1-PPV (1-NN) du plus proche voisin. Si cette méthode peut fournir de bons résultats sur des problèmes simples pour lesquels les points sont bien répartis en groupes denses de même classe, en règle générale, il faut considérer un nombre de voisins plus important pour obtenir de bon résultat [15].

Une première façon de combiner les K classes des K voisins les plus proches est le vote majoritaire. Elle consiste simplement a prendre la classe majoritaire. Une seconde façon est le vote majoritaire pondéré. Chaque vote, c'est-a-dire chaque classe d'un des K voisins sélectionné, est pondéré. Le poids est inversement proportionnel a la distance entre le cas classer et les autre K plus proches voisin classes (une telle pondération s'appelle un noyau).

Dans les deux cas précédant, il est possible de définir une confiance dans la classe attribuée égale au rapport entre les votes gagnants et le total es votes.

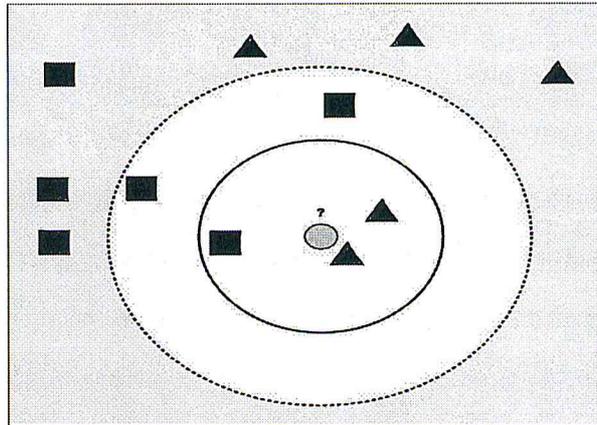


Figure 2.3: Illustration des K-PPV d'un point.

Ce qu'on peut remarquer sur cette méthode, c'est le coût de calcul qu'elle impose au fur et à mesure de ce processus de classification, car ce coût augmente avec chaque vecteur qu'on vient de classifié, plus on ajoute des nouveaux vecteurs déjà classés, plus que ce coût augmente ce qui explique le temps d'exécution qu'elle prend pour classifier.

En plus de la sensibilité de cet algorithme à l'initialisation des paramètres d'entrées que ces derniers respectent certaines contraintes (comme que  $K$  ne soit pas un multiple du nombre de classes pour éviter une surreprésentation d'une classe par rapport à une autre, malgré ces points  $K$ -ppv reste une des méthodes les plus utilisées grâce à sa simplicité et robustesse et son caractère de généralisation à partir d'un nombre éminent de données d'apprentissage.

Ainsi certains travaux ont utilisé les paramètres du classificateur euclidien pour diminuer la contrainte du temps surtout lorsque le nombre d'apprentissage sera trop élevée, au lieu de calculer la distance entre le vecteur de la forme à classer avec les vecteurs d'apprentissage la distance sera calculée que par rapport à la moyenne de chaque classe de données d'apprentissage [12].

### ➤ Distance du $X^2$ (Chi-2)

Mesurons à présent quelque chose de très différent. Il ne s'agit plus de distances entre des points et une droite ou un barycentre mais entre des valeurs observées et des valeurs théoriques.

Cette différence entre observé et théorique est élevée au carré puis rapportée à cette même valeur théorique.

Supposons qu'on compare des effectifs observés  $O$  aux effectifs  $T$  qu'on observerait si la population épousait parfaitement une fonction de densité donnée, par exemple le poids des habitants d'un village par tranches de 5 kg. La distance retenue, dite du  $x^2$ , sera la suivante ( $i$  étant chaque tranche de poids).

$$d^2 = \sum_{i=1}^n \frac{(O_i - T_i)^2}{T_i}$$

#### 6.1.4. Les K plus proches voisins flou

Le principe de la méthode KPPV floue est similaire à la règle des KPPV classiques. Il se base sur une étape de recherche des K points voisins les plus proches du prototype à étudier.

On examine parmi les K voisins retournés, le taux de mélange des classes. Le KPPV flou permet en plus, d'attribuer suivant les distances aux classes des K prototypes voisins, des degrés d'appartenance à ces classes.

Le point à classer  $x$  se voit attribuer un coefficient d'appartenance  $\mu_{ji}$  à chaque classe  $j$ . Celui-ci est fonction des distances et des coefficients d'appartenance de ses K plus proches voisins. Ces coefficients doivent vérifier l'appartenance à l'intervalle  $[0,1]$  de  $\mu_{ji}$ , pour tous les  $i$  et tous les  $j$ .

$$\sum_{j=1}^o u_{\beta} = 1 \text{ pour tous les } 1, \quad 0 < \sum_{i=1}^N u_{\beta} \leq N \text{ pour tous les } j$$

Les coefficients d'appartenance d'un nouveau point  $X_i$  à la classe  $j$  est donnée par :

$$u_{\beta} = \frac{\sum_{i=1}^k u_{\beta} (|x_i - x_1|)^{\frac{m-1}{2}}}{\sum_{i=1}^k \left( \frac{1}{(|x_i - x_1|)^{\frac{m-1}{2}}} \right)}$$

Où  $\mu_{j1}$  le coefficient d'appartenance à la classe  $C_j$ ,  $\mu_{j1} = 1$  si appartient à les K plus proches voisins  $\mu_{j1} = 0$  sinon, de même observation, parmi les K plus proches voisins de  $x_i$ .

La variable  $m$  quant à elle, détermine l'importance de la contribution de la distance dans le calcul de la fonction d'appartenance (contrôle l'efficacité de l'ampleur de la distance). C'est le paramètre fuzzification : si  $m$  croit, la contribution des voisins est d'avantage pondérée et la notion de distance perd de son importance si  $m$  tend vers l'unité, la contribution des voisins les plus proches sera favorisée, ainsi la notion de distance prend de l'importance, si  $m$  vaut 2, la contribution de chaque voisin est pondérée par l'inverse de la distance respective, au carré, qui sépare une observation de l'observation à classer [16].

## 6.2. Méthode SVM (Support Vector Machines)

### 6.2.1. Définition

Les Support Vector Machines souvent traduit par l'appellation de Séparateur à Vaste Marge (SVM) sont une classe d'algorithmes d'apprentissage initialement définis pour la discrimination c'est-à-dire la prévision d'une variable qualitative binaire. Ils ont été ensuite généralisés à la prévision d'une variable quantitative. Dans le cas de la discrimination d'une variable dichotomique, ils sont basés sur la recherche de l'hyperplan de marge optimale qui, lorsque c'est possible, classe ou sépare correctement les données tout en étant le plus éloigné possible de toutes les observations. Le principe est donc de trouver un classifieur, ou une fonction de discrimination, (dont la capacité de généralisation qualité de prévision) est la plus grande possible [17].

### 6.2.2. Les SVMs linéaires

#### a. Classifieurs linéaire

Un Classifieur est dit linéaire lorsqu'il est possible d'exprimer sa fonction de décision par une fonction linéaire. On peut exprimer une telle fonction par :

$$h(x) = \langle w, x \rangle + b = \sum_{i=1}^n w_i x_i + b$$

Où  $(w \in \mathbb{R}^n)$  est le vecteur de poids et  $(b \in \mathbb{R}^0)$  le biais, alors que  $X$  est la variable du problème.  $X$  est l'espace d'entrez et qui correspond à  $\mathbb{R}^n$ , où  $n$  est le nombre de composantes des vecteurs contenant les données. Notons que l'opérateur  $\langle \rangle$  désigne le produit scalaire usuel dans  $\mathbb{R}^n$  sont  $w$  et  $b$  les paramètres à estimer de la fonction de décision  $h(x)$ .

Pour décider à quelle catégorie un exemple estimé  $x'$  appartient, il suffit de prendre le signe de la fonction de décision :  $y = \text{sign}(h(x'))$ . La fonction  $\text{sign}()$  est appelée classifieur.

Géométriquement ( voir figure 2.18), cela revient a considérer un hyperplan qui est le lieu des point satisfaisant  $\langle w, y \rangle + b = 0$  . En orientant l'hyperplan, la règle de décision correspond a observer de quel coté de l'hyperplan se trouve l'exemple  $x'$ . On voit que le vecteur définit la pente de l'hyperplan ( $w$  est perpendiculaire a l'hyperplan). Le terme  $b$  quant a lui permet de translater l'hyperplan parallèlement a lui-même.

L'objectif de la discrimination linéaire est de trouver la bonne fonction de décision  $h(x)$ . La classe de tous les hyperplans qui en découle sera notée  $H$  [18].

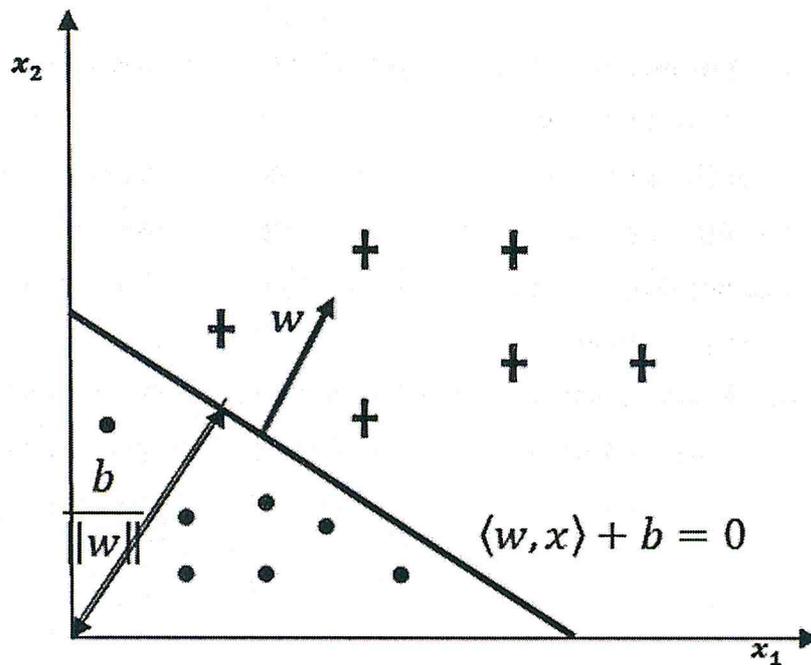


Figure 2.4: Hyperplan séparateur  $\langle w, x \rangle + b = 0$  [18].

➤ **Algorithme SVM linéaire**

- Trouver un hyperplan.
- $(w, b) \in \mathbb{R}^{d+1}$  Qui classe aussi bien que possible les données ( points).
- Progressivement : un point à la fois, en modifiant les poids si nécessaire.

**b. Marge maximale de l'hyperplan**

La marge est la distance entre la frontière de séparation et les échantillons les plus proches. Dans les SVM, la frontière de séparation est choisie comme celle qui maximise la marge.

La marge géométrique représente la distance euclidienne prise perpendiculairement entre l'hyperplan et l'exemple  $x_i$ . En prenant un point quelconque  $x_p$  se trouvant sur l'hyperplan, la marge géométrique peut s'exprimer par :

$$\frac{w}{\|w\|} \cdot (X_i - X_p)$$

L'hyperplan a marge maximale est le modèle le plus utilisé dans la machines a vecteurs support. L'estimation des paramètres  $(w^*, b^*)$  de l'hyperplan qui maximise la marge se fait en résolvant le problème d'optimisation suivant:

$$(w^*, b^*) = \operatorname{argmax}_{(w,b)} \{ \min_i (y_i (w x_i + b)), \|w\| = 1 \}$$

Dire que les deux classes de l'échantillon d'apprentissage  $S$  sont linéairement séparables est équivalent a dire qu'il existe des paramètres  $(w^*, b^*)$  tels que l'on a pour tout  $(i = 1, 2, 3, \dots, n)$  :

$$w^* x_i + b^* > 0 \text{ si } y_i = 1$$

$$w^* x_i + b^* < 0 \text{ si } y_i = -1$$

Ce qui est équivalent à :

$$y_i (w^* x_i + b^*) > 0; \forall i = 1, 2, \dots, n$$

La définition consiste a dire qu'il doit exister un hyperplan laissant d'un coté toutes les données positives et de l'autre, toutes les données négatives. Dés lors, on peut définir deux plans se trouvant de part et d'autre de l'hyperplan et parallèles a celui-ci, sur lesquels reposent les exemples les plus proches. La figure 2.19 illustre cette situation[18].

Dans notre définition de l'hyperplan, il est possible que différentes équations correspondent au même plan géométrique :

$$\alpha (\langle w, x \rangle + b) = 0$$

$\alpha$ : est une constante quelconque.

Il est possible de redimensionner  $(w^*, b^*)$  de telle sorte que les deux plans parallèles aient respectivement pour équations :

$$(w^* x_i + b^*) = 1$$

$$(w^* x_i + b^*) = -1$$

Ces deux hyperplans sont appelés hyperplans canoniques. Ainsi la marge  $\gamma$  entre ces deux plans est égale à :

$$\gamma = \frac{2}{\|w^*\|}$$

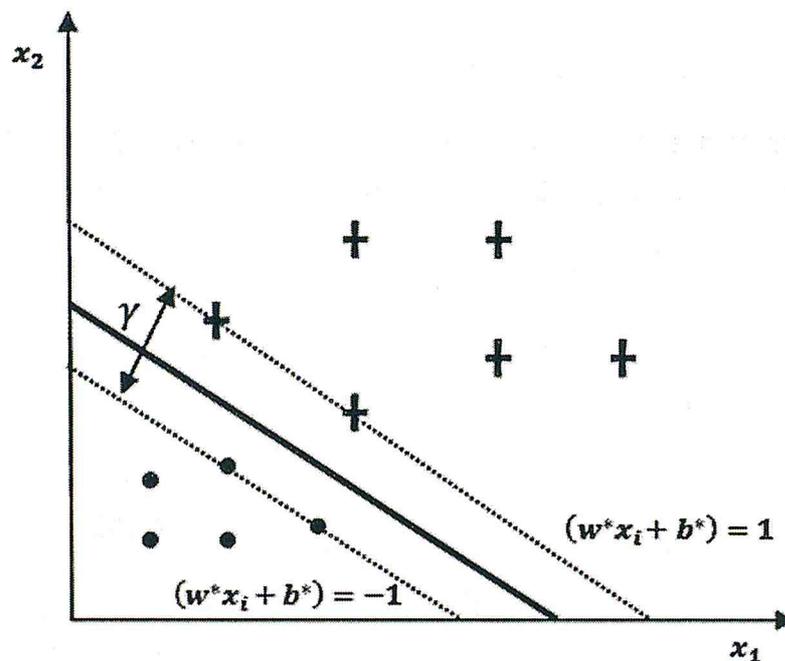


Figure 2.5: Hyperplans canoniques et marge maximale [18].

### 6.2.3. SVM non-linéaires

Le paragraphe précédent décrit le principe des SVM dans le cas où les données sont linéairement séparables. Cependant, dans la plupart des problèmes réels, ce n'est pas toujours le cas et il est donc nécessaire de contourner ce problème (difficile de séparer n'importe quel jeu de données par un simple hyperplan). Si par exemple les données des deux classes se chevauchent sévèrement, aucun hyperplan séparateur ne sera satisfaisant.

L'idée est de projeter les points d'apprentissage  $X_i$  dans un espace  $T$  de dimension  $q$ , plus élevée que  $n$  grâce à une fonction non-linéaire  $\phi$  qu'on appelle fonction noyau, choisie a priori et d'appliquer la même méthode d'optimisation de la marge dans l'espace  $T$ . L'espace  $T$  ainsi obtenu est appelé espace des caractéristiques ou aussi espace transformé.

Tout ce qu'il nous reste à faire c'est de résoudre le problème (2.18) dans l'espace  $T$ , en remplaçant  $\langle X_i, X_j \rangle$  par  $\langle \Phi(X_i), \Phi(X_j) \rangle$ . L'hyperplan séparateur obtenu dans l'espace  $T$  est appelé hyperplan optimal généralisé. Le produit scalaire peut se calculer facilement à l'aide d'une fonction symétrique, dite noyau, définie par :

$$K(x_i, x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle$$

Le noyau est une fonction de deux variables, symétrique et positive. Dans ce cas, la frontière de décision devient :

$$h(x) = \text{sign} \left( \sum_{i=1}^n y_i \alpha_i^* K(x_i, x_j) + b^* \right)$$

Dans la pratique on choisit un noyau  $K$  qui satisfait les conditions de Mercer afin de garantir la décomposition (2.24). Une famille de ces fonctions noyaux qui sont très appropriées aux besoins des SVM peut être définie. En voici les plus utilisés :

#### a. Noyau polynomial d'ordre $p$ :

$$K(x_i, x_j) = (\langle x_i, x_j \rangle + 1)^d$$

La dimension de l'espace transformé induit par un noyau polynomial est de l'ordre  $\frac{(p+d)!}{p!d!}$ , où  $p$  la dimension de l'espace de départ.

#### b. Noyau linéaire

$$K(x_i, x_j) = x_i \cdot x_j$$

#### c. Noyau gaussien de largeur de bande $\sigma$

$$K(x_i, x_j) = \exp \left( -\frac{\|x_i - x_j\|^2}{2\sigma} \right)$$

Le paramètre permet de régler la largeur de la gaussienne. En prenant un grand, la similarité d'un exemple par rapport à ceux qui l'entourent sera assez élevées, alors qu'on prenant un tendant vers 0, l'exemple ne sera similaire à aucun autre [18].

### 6.2.4. Domaine d'application de SVM

Vu leur composition comme des techniques d'apprentissage, les SVMs sont utilisés dans les domaines de [11] :

- Reconnaissances des formes / Classification
- Vision Machines : Identification de visage, reconnaissances d'expression faciale :  
Surpasse les approches alternatives (1.5% taux d'erreur).
- Reconnaissances des chiffres manuscrits : les résultats d'USPS (service de la poste des états unis) data base comparable à la meilleure approche (1.1 % taux d'erreur).
- Reconnaissances de visage.
- Images satellite et surveillance.
- Diagnostic médical (cancer du sein).

### 6.2.5. Avantages et Inconvénients [11]

#### a. Avantages

- Les SVM possèdent des fondements Mathématiques solides.
- Les exemples de test sont comparés juste avec les supports vecteur et ne pas avec tous les exemples d'apprentissages.
- Décision rapide. la classification d'un nouvel exemple consiste à voir le signe de la fonction de décision  $f(x)$ .

#### b. Inconvénients

- Classification binaire d'où la nécessité d'utiliser l'approche un-contre-un.
- Grande quantité d'exemples en entrées implique un calcul matriciel important.
- Temps de calcul élevé lors d'une régularisation des paramètres de la fonction noyau.

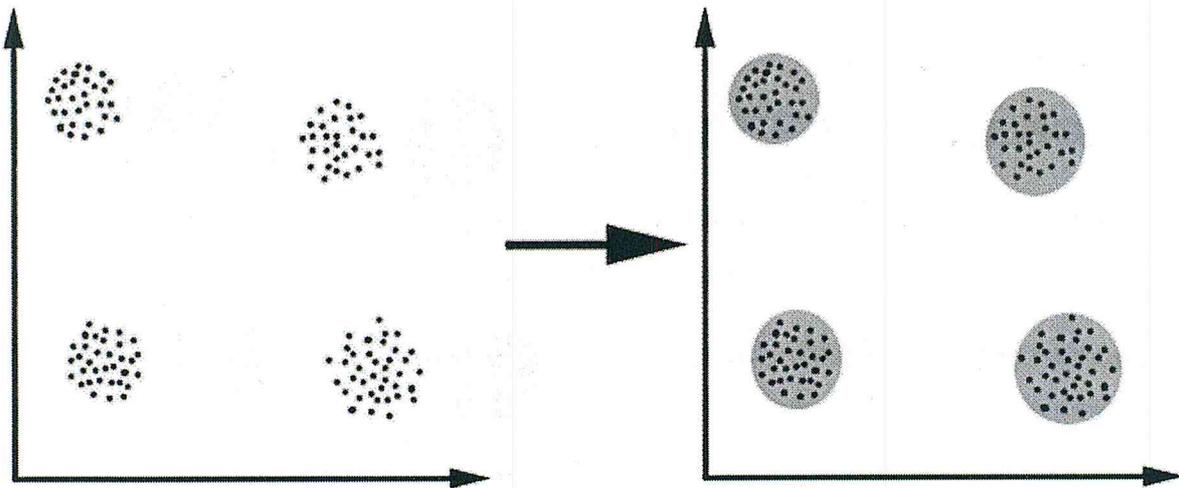
## 7. La classification Non-Supervisée

Le Clustering aussi connu sous nom (Segmentation) est un regroupement en classes homogènes consistant à représenter un nuage des points d'un espace quelconque en un ensemble de groupes appelé Cluster.

C'est un traitement sur un ensemble d'objets qui n'ont pas été étiquetés par un superviseur.

Généralement lié au domaine de l'analyse des données comme ACP (analyse linéaire en composantes principales) [19], ce type de méthodes vise à répondre au problème de : diminution de la dimension de l'espace d'entrée, ou pour le regroupement des objets en plusieurs catégories (clusters) non définies à l'avance. parmi les méthodes qu'on peut trouver dans ce type de classification : les cartes auto-organisatrices de kohonen, GMM.. etc.

Un " cluster " est donc une collection d'objets qui sont " similaires " entre eux et qui sont " dissemblables " par rapport aux objets appartenant à d'autres groupes. On peut voir cette définition clairement graphiquement dans l'exemple suivant :



**Figure 2.6:** Illustration de regroupement en clusters.

Contrairement à la classification (méthode supervisées), on ne possède pas des connaissances a priori sur les classes prédéfinies des éléments. donc la division des objets dans les différents groupes (clusters) se procède en se basant sur le calcul de similarité entre les éléments.

Alors que l'objectif des méthodes du clustering est de grouper des éléments proches dans un même groupe de manière à ce que deux données de même groupe soient le plus similaires possibles et que deux éléments de deux groupes différents soient le plus dissemblables possible.

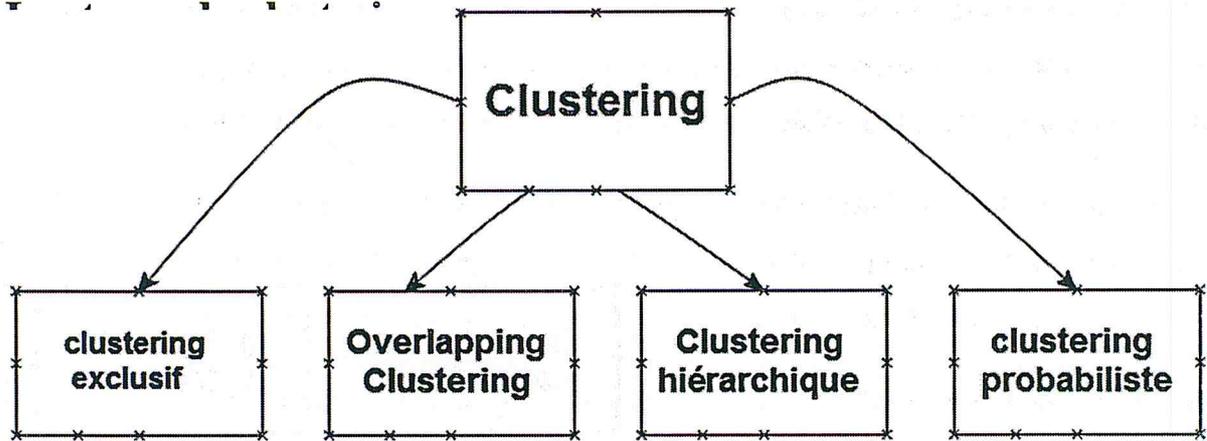
Mathématiquement, on a un ensemble  $X$  de  $N$  données décrites chacune par leurs  $P$  attributs. Donc le clustering consiste à créer une partition ou une décomposition de cet ensemble en sous-parties (cluster) telle que :

- Les données appartenant au même groupe se ressemblent.
- Les données appartenant à deux groupes différents soient peu ressemblantes.

On utilise souvent ce type de classification en traitement d'images pour fixer les divers objets qu'elles contiennent (segmentation) : routes, villes, rues, des organes humains pour les images médicales).

Les principales exigences qu'un algorithme de clustering doit répondre sont les suivantes :

- évolutivité des clusters.
- traiter les différents attributs.
- découvrir les clusters de forme arbitraire.
- exigences minimales pour la connaissance du domaine afin de déterminer les paramètres d'entrée.
- capacité de décomposer avec le bruit et les valeurs manquantes traitées des dimensionnalités élevées.
- l'intelligibilité et la convivialité.

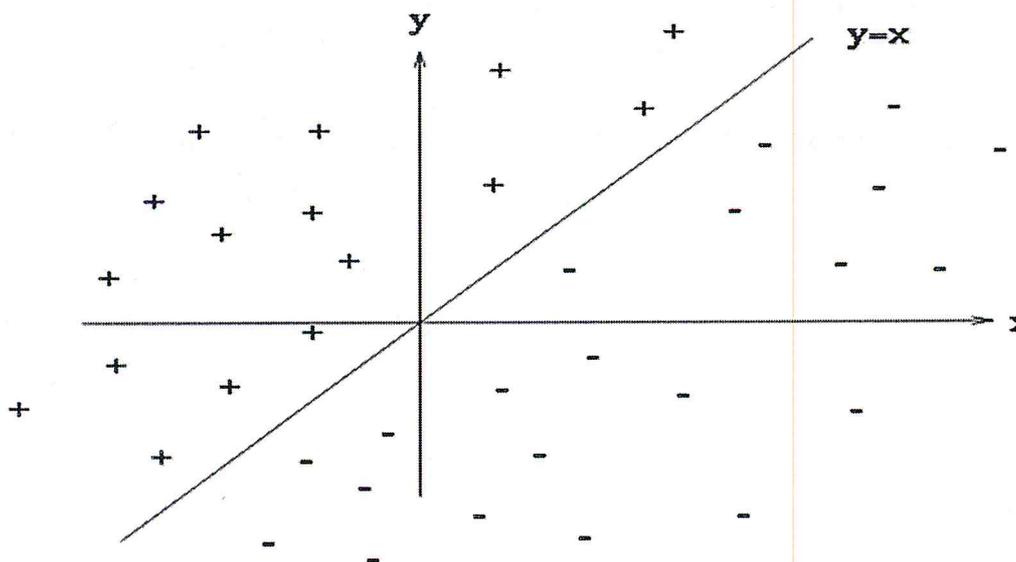


**Figure 2.7:** les différents types de clustering [20].

### 8.1 Clustering exclusif

Les données sont regroupées d'une manière exclusive, de sorte que si une donnée certaine appartient à un amas définie alors il ne pourrait pas être dans un autre cluster.

Un simple exemple de cela est montré dans la figure ci-dessous, où la séparation des points est définie par une ligne droite sur un plan bidimensionnel.



**Figure 2.8:** Exemple d'un problème de discrimination à deux classes, avec un séparateur

linéaire : la droite d'équation  $y = x$ . le problème linéairement séparable [18].

### 8.2. Le regroupement Overlapping Clustering (fuzzy Clustering)

Utilise des ensembles flous aux données de cluster, de sorte que chaque Point peut appartenir à deux ou plusieurs groupes avec différents degrés d'appartenance. dans ce cas, les données seront associées à une valeur d'une composition appropriée.

### 8.3. Clustering hiérarchique

Un algorithme hiérarchique consiste à trouver des clusters successifs utilisant des clusters précédemment établis. la première condition est de mettre, au début, chaque objet dans un cluster distinct et les fusionner en clusters successivement plus grand. après quelques itérations on atteint le final cluster voulu qui regroupe tous les sous-clusters (sous-partitions).

### 8.4. Clustering probabiliste

Utilise une approche complètement probabiliste basant sur la probabilité d'appartenance aux clusters

## 9. Les algorithmes de clustering

Parmi les algorithmes appartient à l'un des types de clustering, K-means est un algorithme de clustering exclusif, pendant que Fuzzy C-means Overlapping Clustering, alors que le clustering hiérarchique il est clair qu'il s'agit de troisième type de clustering, et enfin Mélange de Gaussien est un algorithmes de clustering probabiliste.

### 9.1 K-means

Le principe de " K-Means " est le suivant : on part de K données synthétique (c'est-à-dire des points de l'espace de données D ne faisant pas forcément parti du jeu de données) que l'on nomme des " Centres " chaque centre caractérise un groupe. A chaque centre sont associées les données qui sont lui les plus proche ; cela crée un groupe autour de chaque centre.

Ensuite on calcul le centre de gravité de chacun de ces groupes ; ces K centres de gravité deviennent les nouveaux centres et on recommence tant que les groupes ne sont pas stabilisés, i.e. tant que il ya des données qui changent du groupe d'une itération à la suivantes ou encore, tant que l'inertie varie substantiellement d'une itération a la suivante.

Cet algorithmes converge en un nombre finie d'itération [21], il existe des versions améliorées des K-moyennes.

La figure (2.23) illustre le déroulement étape par étape d'un tel algorithme. Lors de la phase d'initialisation, un pixel est sélectionné de façon aléatoire parmi l'ensemble des pixels de l'image afin de représenter son centre de gravité initial et ce pour chaque classe (figure 2.23(a)). L'algorithme affecte ensuite à chaque pixel de L'images la classe  $C_i$  dont le centre de gravité et le plus proche (figure 2.4(b)).

A chaque fois qu'un pixel de l'image et affecté à sa classe respective, le centre de gravité de la classe est recalculé (figure 2.23(c)). ce processus réitéré jusqu'à convergence de l'algorithme c'est-a-dire jusqu'à l'obtention d'un minimum local de la somme des distance entre les points de chaque classe et son centre de gravité (figure 2.4(c)).

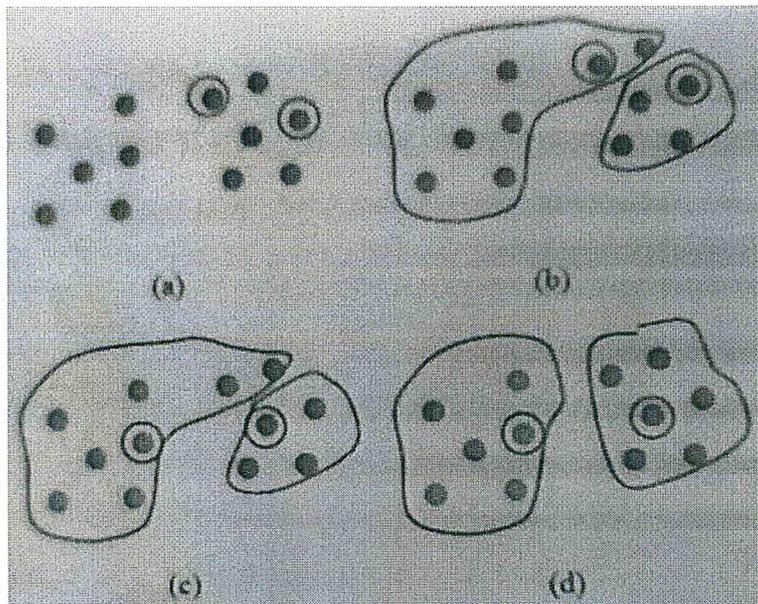


Figure 2.9: K-means[21].

## 9.2 Fuzzy C-means

Fuzzy C-means (FCM) est une méthode de clustering qui permet à un objet de données d'appartenir à deux ou plusieurs clusters. cette méthode dérivée de l'algorithme C-means, identique à l'algorithme k-means décrit précédemment, elle a été développée par dunn en 1973 et améliorée pas bezdek en 1981, est fréquemment utilisée dans la reconnaissance des formes. Il est basé sur la minimisation de la fonction objective suivant :

$$J_m = \sum_{i=1}^N \sum_{j=1}^C u_{ij}^m \|x_i - c_j\|^2 \quad 1 \leq m < \infty$$

Où  $m$  est un nombre réel ( $>1$ ),  $u_{ij}$  est le degré d'appartenance de  $x_i$  dans le  $j$ ème Cluster,  $x_i$  est le  $i$ ème élément des données mesurées,  $c_j$  est le centre d'un cluster et  $\|*\|$  est toute norme exprimant la similarité entre les données mesurées et le centre. Ce partitionnement logique flou (Fuzzy) est réalisé grâce à une optimisation itérative de la fonction objectif indiquée ci-dessus, avec la mise à jour de l'appartenance  $u_{ij}$  et les centres de clusters  $c_j$ .

la FCM exige des paramètres d'entrées, et que la matrice de partition floue, doit être initialisée d'une manière appropriée. Ces paramètres sont choisis d'une façon arbitraire, ces paramètres ont une grande influence sur les résultats attendus. Ce qui nous oblige de faire une étude appropriée sur les données en entrée et le regroupement que l'on souhaite obtenir.

## 10. Les Méthodes hiérarchiques

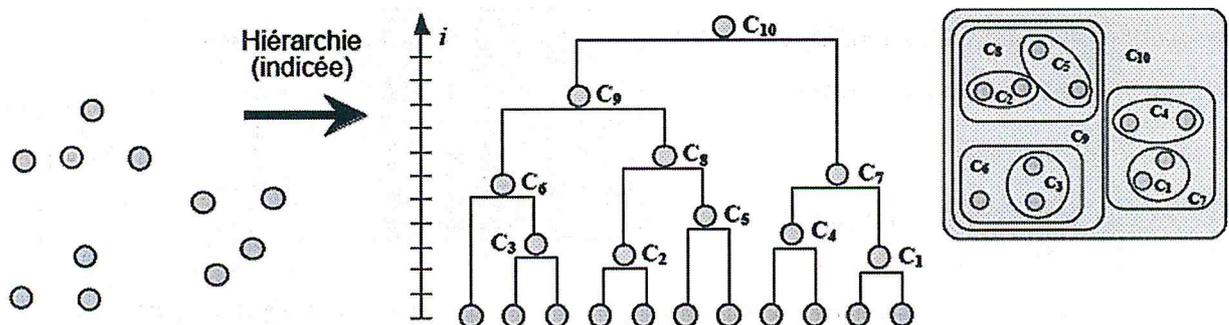
La classification hiérarchique, consiste à effectuer une suite de regroupement en classes de moins en moins fines en agrégeant à chaque étape les objets ou les groupes d'objets les plus proches. Le nombre d'objets n'est pas fixé a priori, mais sera fixé a posteriori. Elle fournit ainsi un ensemble de partitions de l'ensemble d'objet, Il existe deux type de méthodes :

### ➤ Classification hiérarchique ascendantes (CHA)

Ces méthodes sont les plus anciennes et les plus utilisées dans la classification automatique. supposons que nous avons  $N$  objet à classer. Les algorithmes agglomératifs suivant cette approche, définissent d'abord une partition initiale en  $N$  classes unitaires. par la suite, ils fusionnent successivement les classes jusqu'à ce que toutes entités soient dans la nouvelles classes est nécessaire. Le choix des classes se fait selon le critère qui caractérise la méthodes. Les méthodes de cette catégorie diffèrent selon le critère local choisi et selon la méthodes de calcul des dissimilarités interclasses.

Ce principe est de fournir un ensemble de partitions de moins en moins fines obtenues par regroupement successifs de parties, Une fois cet algorithme terminé, on ne récupère donc pas directement une partition, mais une hiérarchie de partitions en  $n, \dots, 1$  classes, avec diminution de l'inertie interclasses à chaque agrégation. On résume ce principe avec ces étapes suivantes :

- ✓ Initialisation : les classes initiales sont les  $n$  singletons-individus. Calculer la matrice de leurs distances deux à deux.
- ✓ Itérer les deux étapes suivantes jusqu'à l'agrégation en une seule classe.
- ✓ regrouper les deux éléments (classes) les plus proches au sens de la distance entre groupes choisie.
- ✓ Mettre à jour le tableau de distances en remplaçant les deux classes regroupées par la nouvelle et en calculant sa distance avec chacune des autres classes.
- ✓ Nécessité de définir une distance entre groupes d'individus (appelé stratégie d'agrégation).
- ✓ Nécessité de choisir le nombre de classes à retenir.



**Figure 2.10:** Classification hiérarchique descendante.

### ➤ Classification hiérarchique descendantes

Dans le paragraphe précédent, nous avons vu que la classification hiérarchique ascendante se base sur un seul critère à la fois. Ceci engendre uniquement une séparation (méthode du lien simple) ou une homogénéité (méthodes du lien complet) optimale des classes. ce qui risque de donner naissance à l'effet de chaînage (deux entités très dissimilaire appartenant aux points extrêmes d'une longue chaîne, peuvent appartenir à la même classe) ou l'effet de dissection (deux entités très similaire peuvent appartenir à deux classes différentes). pour faire face à ces deux problèmes, nous retrouvons les algorithmes divisifs de la classification hiérarchique descendantes.

Ces algorithmes commencent par former une seule class qui englobe tous les objets. Par la suite, ils choisissent une class de la partition en cours selon un premier critère local. Ils procèdent ensuite à une bipartition successive selon un deuxième critère local des classes choisies. Cette bipartition continue jusqu'à ce que toutes les entités soient affectées à différentes classes [13].

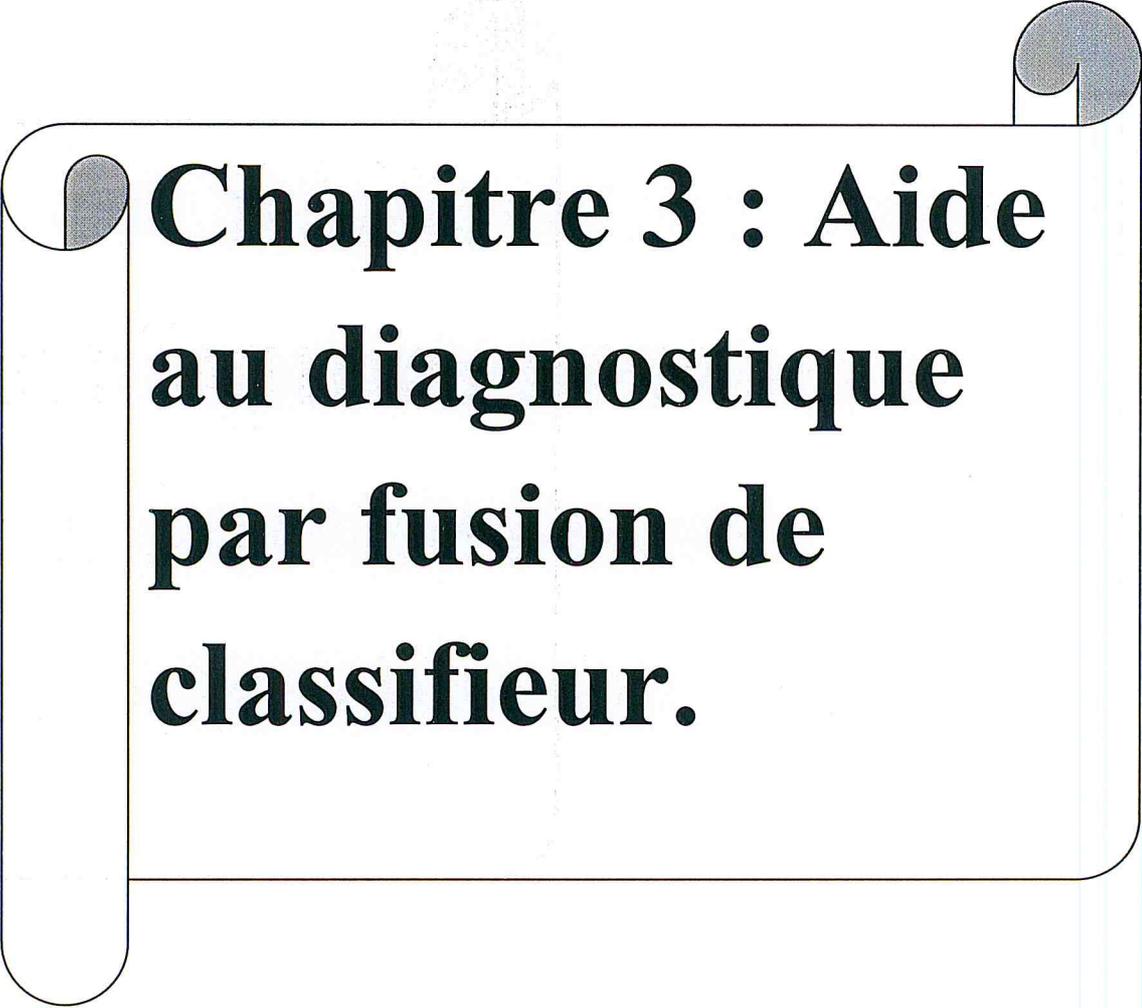
## 11. Les Limites de Clustering

Il y a un certain nombre de problèmes avec le Clustering. Parmi eux :

- ✓ Les Techniques de clustering actuelles ne traitent pas tous les besoins de façon adéquate ( et simultanément), comme le fait que si nous n'avons pas des variables continuées (la longueur), mais les catégories nominales, comme les jours de la semaine. dans ces cas encore, la connaissance du domaine doit être faite pour formuler le clustering appropriée.
- ✓ Traitement d'un grand nombre de dimension et de grand nombres de données, question peut être problématique en raison de la complexité du temps de calcul.
- ✓ L'efficacité de la méthode dépend de la définition de "distances" utilisée.
- ✓ Si la mesure de la distance n'existe pas, nous devons la "définir", ce qui n'est pas toujours facile, surtout des espaces multidimensionnels.
- ✓ Le résultat de l'algorithme de clustering peut être interprété de différentes manières.
- ✓ beaucoup d'algorithmes de clustering exigent la spécification du nombre de clusters à produire en entrée de l'ensemble de données, avant l'exécution de l'algorithme. i.e.: connaissance de la valeur correcte à l'avance, la valeur appropriée doit être déterminée.

## 12. Conclusion

Dans ce chapitre on a définie les techniques de classification supervisée comme le classifieur K-PPV (K-NN) et le SVM (support Vector Machines) et les techniques de classification non-supervisée (Clustering) avec les méthodes K-means et C-means et le CHA.



**Chapitre 3 : Aide  
au diagnostique  
par fusion de  
classifieur.**

## 1. Introduction

L'objectif de ce chapitre, est de faire une extraction de caractéristiques visuelles (ou visual features extraction en anglais) qui consiste à des transformations mathématiques calculées sur les pixels d'une image numérique. Les caractéristiques visuelles permettent généralement de mieux rendre compte de certaines propriétés visuelles de l'image, utilisée pour des traitements ultérieurs entrant dans le cadre d'applications telles que la détection d'objets ou la recherche d'images par le contenu, qui nous permettront d'établir une classification par la fusion de deux classifieurs : les supports à vecteur machine (SVM) et les k plus proches voisins (KPPV), afin d'extraire un certain nombre de propriétés caractéristiques et, à les exprimer sous forme paramétrique.

## 2. Méthodologie adoptée pour l'analyse d'images rétinienne

Le sous système d'apprentissage:

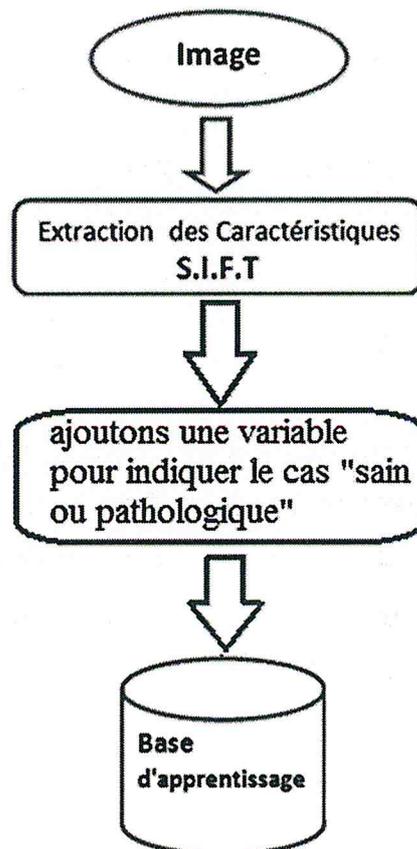


Figure 3.1 : Sous système d'apprentissage.

Dans notre Sous système de d'apprentissage, on prend une image de fond d'œil a partir de la base d'images "MESSIDOR", et on exécute l'algorithme SIFT (Scale-invariant feature transform) sur cette image pour extraire une matrice (.MAT).

Après l'extraction des données de cette image (matrice .mat), nous ajoutons une variable à la matrice, pour indiquer si la matrice est appartient a un cas sain ou cas pathologique, puis nous stockons la nouvelle matrice dans la base d'apprentissage. pour l'utiliser dans la prochaine étape "la classification".

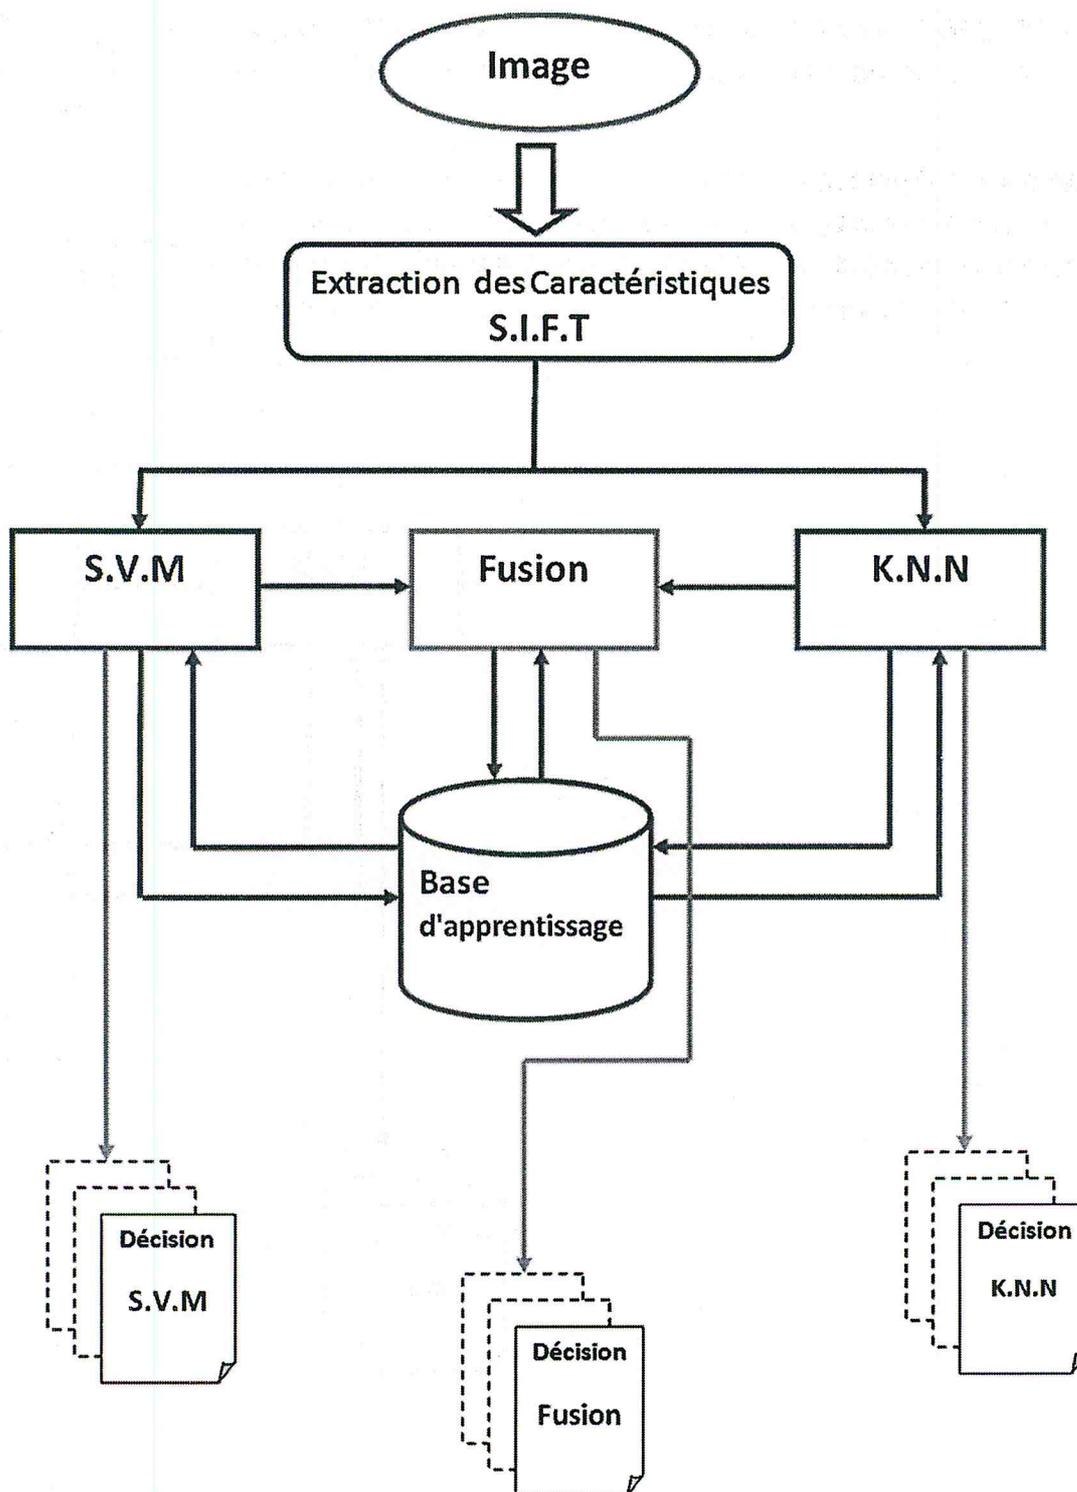


Figure 3.2 : Sous système de classification.

Dans notre Sous système de classification, on prend une image de fond d'œil a partir de la base d'images "MESSIDOR", et on exécute l'algorithme SIFT (Scale-invariant feature transform) sur cette image pour extraire une matrice (.MAT).

Après l'extraction des données de cette image (matrice .mat), on commence la classification de cette image avec l'algorithme K.N.N (K Nearest Neighbors), qu'il va trouver les K plus proches voisins a la matrice en question a partir de la base d'apprentissage, et voir le nombre majoritaire de voisins, si la majorité sont des cas sain on considère l'image une cas sain, si la majorité sont des cas pathologique on considère l'image cas pathologique.

Après le K.N.N on utilise le S.V.M (Support vector machine) sur la matrice (.MAT), qu'il vas déterminer a partir de la longueur de la marge entre les données stocké dans la base d'apprentissage la class le plus proche a le cas en question, soit sain, soit pathologique.

Après on fait une Fusion des scores avec une consultation de la base d'apprentissage, pour obtenir une troisième résultat (troisième décision) soit cas sain, soit cas pathologique.

### 3. Localisation des caractéristiques

On distingue usuellement les caractéristiques globales qui sont calculées sur toute l'image et les caractéristiques locales qui sont calculées autour de point d'intérêt. On peut aussi parler des caractéristiques semi-locales quand celle-ci sont extraites dans des zones restreintes de l'image, résultant d'une segmentation de l'image en région ou simplement selon une grille arbitraire [22].

La distinction entre caractéristiques globales et locales a un intérêt taxinomique. Les caractéristique locales se distinguent par le fait qu'elles sont distinctes, robustes à l'occlusion (car il y en a beaucoup sans une image ou une région) et qu'elles ne nécessitent pas de segmentation, un descripteur local calculé en chaque pixel d'une image ou d'une région obtenue par segmentation, puis accumulé dans un histogramme est donc une description globale de l'image ou la région [23].

#### 3.1. Caractéristiques globales

##### a. Couleur (Histogramme et dérivés)

La prise en compte de la couleur des images a été l'une des premières caractéristiques employées pour la recherche d'images par le contenu et produit encore du résultat parfois spectaculaire sur certaines bases. C'est en 1991 que swain et ballard ont proposé d'utiliser un histogramme couleur pour ce genre de tache. Il représente la distribution globale du couleur dans l'image. Son calcul consiste en une quantification de l'espace couleur choisi (RVB par exemple) suivie du calcul de l'histogramme des pixels ainsi transformés. Par exemple, si l'on

considère une image RVB classique et que l'on quantifie chaque plan couleur sur 4 bits, l'histogramme résultant aura une dimension  $4^3=64$ . Si l'image est originellement codée sur 24 bits (la valeur de chaque plan est dans l'intervalle [0-255]), l'histogramme couleur sur 64 bits pourrait être représenté par un "cube"  $4 \times 4 \times 4$ . Chaque couleur représentant l'un des 64 bits quantifiés, et  $x$  étant alors le nombre de pixels de l'image correspondant à ce bit. En pratique, ce descripteur est généralement représenté par un vecteur mono dimensionnel à 64 dimensions.

De nombreux descripteurs peuvent être dérivés de la représentation par histogramme, dont plusieurs ont été inclus au modèle expérimental de norme MPEG-7. Il s'agit notamment de :

**Dominant color** : rend compte de la couleur dominante d'une image, calculée comme celle du bit ayant la plus grande valeur. L'espace de couleur peut être quelconque en théorie, mais l'utilisation de HSV donne des résultats intéressants [24].

**Scalable color** : il s'agit de la transformée de Haar de l'histogramme couleur dans l'espace HSV, ce qui résulte en un code très compact.

**Color structure** : il s'agit d'un histogramme couleur. Sa construction est identique au principe présenté précédemment (histogramme couleur global), si ce n'est qu'une fenêtre de taille réduite ( $8 \times 8$  pixels) parcourt l'image lors du compactage des couleurs en chaque pixel. Il reflète ainsi une certaine information sur la structure spatiale de la répartition des couleurs.

**Color layout** : la transformée en cosinus discrète de la représentation en histogramme est calculée et seule une partie des coefficients peut être utilisée pour la signature. Cela donne la possibilité d'obtenir un descripteur relativement grossier mais très compact ou bien un descripteur plus fin mais prenant plus de place. Un tel descripteur est intéressant pour des applications nécessitant une certaine scalabilité.

### b. Forme

Décrire les formes nécessite une identification préalable de régions. Cela peut résulter d'une segmentation de l'image ou de la détection de leurs contours. On peut alors caractériser les régions au moyen de divers indices tels leur orientation principale (par exemple leur premier axe propre), leur symétrie ou encore leurs moments de Zernike (les polynômes de Zernike sont une série de polynômes qui sont orthogonaux sur le disque unité).

Une méthode de description particulièrement utilisée est celle proposée par Mokhtarian, appelée "Curvature scale space"[25]. Elle consiste à décrire une région en fonction des variations de courbure de son contour. Pour une courbe plane en coordonnées paramétrique dans un repère orthonormé  $r(t)=(x(t),y(t))$ , la courbure  $\gamma$  s'exprime par :

$$\gamma(t) = \frac{x'y'' - y'x''}{(x'^2 + y'^2)^{3/2}}$$

Cette description est invariante en rotation et translation. Concernant le zoom, il faut à minima normaliser par la longueur du contour. Plus important, le descripteur est généralement calculé à différentes échelles, chacune correspondant à la convolution par un noyau gaussien.

### C. Texture

La définition de la texture n'est pas évidente et dépend de l'échelle, On distingue trois approches pour définir la notion de texture. Dans la veine des travaux pionniers de Haralick [26], une première approche considère une texture comme résultant d'un processus stochastique et cherche à les décrire en termes de propriétés statistiques des valeurs et positions relatives des pixels. La seconde approche suppose l'existence de primitives fondamentales permettant de décrire les textures, tels les Textons définis par Julesz. Par suite, une texture donnée est décrite comme une combinaison complexe de ces primitives, exprimée par exemple avec des graphes.

Une approche plus récente s'inspire plutôt de la perception visuelle et tend à rendre compte du processus de formation des textures du point de vue humain [27].

### 3.2. Caractéristiques locales

La caractérisation d'une image peut être calculée en un nombre restreint de pixel. Il faut pour cela d'abord détecter les zones d'intérêt de l'image puis calculer en chacune de ces zones un vecteur caractéristique. Ces zones d'intérêt sont par exemple les arêtes ou les points saillants de l'image (zones de fort contraste). Il peut aussi s'agir de points pris aléatoirement ou régulièrement dans l'image (échantillonnage dit dense).

Le vecteur caractéristique contient parfois des données provenant de la détection, telles que l'orientation de l'arête ou la magnitude du gradient dans la zone d'intérêt. Généralement, le vecteur caractéristique en un pixel est calculé sur un voisinage de ce pixel, c'est-à-dire à partir d'une image centrée sur ce pixel. Il peut être calculé à différentes échelles de manière à

s'affranchir du facteur de zoom. Parmi les caractéristiques locales couramment calculées, on retrouve des motifs préalablement utilisés globalement, tels que des histogrammes de couleur ou des vecteurs rendant compte de l'orientation des gradients des niveaux de gris.

Certaines méthodes telles SIFT ou SURF incluent à la fois la détection de zone d'intérêt et le calcul d'un vecteur caractéristique en chacune de ces zones. Concernant le vecteur caractéristique, les SIFT sont grossièrement un histogramme des orientations du gradient et SURF consistent en le calcul d'approximation d'ondelettes de Haar. Dans une veine similaire, les motifs binaires locaux sont un calcul de cooccurrence des niveaux de gris locaux d'une image et les HOG des histogrammes de gradients orientés, assez similaires aux SIFT, calculés selon un échantillonnage dense.

### 3.2.1. Détection de zones d'intérêt

En vision par ordinateur et en traitement d'images, la détection de zones d'intérêt d'une image numérique (feature detection) consiste à mettre en évidence des zones de cette image jugées pour l'analyse, c'est-à-dire présentant des propriétés locales remarquables. De telles zones peuvent apparaître, selon la méthode utilisée, sous la forme de points, de courbes continues, ou encore de régions connexes rectangulaires ou non et qui constituent le résultat de la détection.

### 3.2.2. Terminologie

Nous utilisons la locution zone d'intérêt pour traduire dans ce contexte précis le terme feature omniprésent dans la littérature anglo-saxonne, mais qui n'a pas de réelle définition standard. La définition dépend plutôt de la famille de problèmes que l'on cherche à traiter. Comme expliqué plus haut, une zone d'intérêt est une zone "intéressante" d'une image. De ce fait, la qualité de l'algorithme utilisé pour détecter les zones d'intérêt conditionne souvent la qualité du résultat de la chaîne de traitement entière que l'on souhaite appliquer à une image. Aussi, la répétabilité, c'est-à-dire le fait que les mêmes zones d'intérêt (ou à peu près) puissent être détectées sur deux images (numériquement) différentes mais représentant la même scène, est une propriété importante et généralement exigée pour tous les algorithmes de détection de zones d'intérêt.

Après la détection, on applique souvent un algorithme de description qui va se concentrer sur chaque zone d'intérêt détectée pour calculer des caractéristiques (numériques, en général), que les anglo-saxons désignent aussi sous le terme générique de Feature[28].

### 3.2.3. Typologie

Selon la méthode de détection utilisée, les zones peuvent être de différentes natures.

#### a. Contours

Les premières méthodes proposées historiquement se fondent sur l'analyse des contours et des arêtes, c'est-à-dire des zones où la luminance (ou la couleur) de l'image change brusquement - en d'autres termes, comporte une discontinuité. On peut utiliser pour cela les opérateurs de Canny ou de Sobel, par exemple. Ces détecteurs sont basés sur une dérivation de l'image (au sens mathématique), c'est-à-dire sur le gradient de l'image vue comme une fonction de deux variables réelles, à valeurs dans  $\mathbb{R}$  pour les images en niveaux de gris ou dans  $\mathbb{R}^3$  pour les images en couleurs. Les points de discontinuité connexes trouvés peuvent être reliés entre eux pour former des arêtes (edges), linéaires ou non, par des post-traitements appropriés [29].

#### b. Points d'intérêt

Les algorithmes de détection de points d'intérêt se focalisent en général sur des points particuliers des contours, sélectionnés selon un critère précis.

Ainsi, les coins (corners) sont les points de l'image où le contour (de dimension 1) change brutalement de direction, comme par exemple aux quatre sommets d'un rectangle. Il s'agit de points particulièrement stables, et donc intéressants pour la répétabilité. La méthode la plus répandue pour le détecter est probablement le détecteur de Harris.

Comme celle de Harris, la plupart des autres techniques de détection de points d'intérêt sont basées sur une analyse locale de l'image à l'ordre 2. Ce qui les différencie entre elles est l'opérateur de dérivation utilisé. Nous pouvons par exemple citer les méthodes basées sur l'analyse des DoG (Difference of Gaussians), des LoG (Laplacian of Gaussian) ou des DoH (Difference of Hessians) [30].

#### c. Régions d'intérêt

Il s'agit de zones d'intérêt plus générales que les points, utiles lorsque les structures recherchées dans une image ne correspondent pas à des points saillants. Par exemple, lorsque l'image a subi un lissage important ou lorsque les contours sont épais et progressifs.

Souvent, ces techniques commencent par identifier des points d'intérêt qui vont se révéler être des sortes de barycentres des régions recherchées (blobs), telles que les méthodes multi-

échelles basées sur l'étude de détecteurs des points d'intérêt cités précédemment (Harris, DoG, etc), a différentes échelles de l'image, Ceci permet d'obtenir des régions soit circulaires soit elliptiques, selon le niveau de raffinement voulu. Ces méthodes sont souvent intégrées a des algorithmes plus généraux tels que SIFT ou SURF, qui incluent un descripteur de région d'intérêt en plus d'un détecteur.

Parmi les détecteurs de régions d'intérêt plus généraux existe également MSER (Maximally Stable Extremal Regions).

Plus spécifiquement enfin, la recherche d'objets particulièrement allongés fait souvent appel a des techniques dites de détection de crête (ridge detection) qui se prête bien a l'analyse de vues aériennes de réseaux routiers, ou a la détection de vaisseaux sanguins dans l'imagerie médicale par exemple [31].

### 3.3. Scale-Invariant Feature Transform (SIFT)

Scale-invariant feature transform (SIFT), que l'on peut traduire par « transformation de caractéristique visuelles invariante a l'échelle », est un algorithme utilisé dans le domaine de la vision assistée par ordinateur pour détecter et identifier les éléments similaires entre différentes images numériques( éléments de paysages, objets, personnes...), ceci ayant pour objectif de décrire des zones d'intérêts dans une image. Il a été développé en 1999 par le chercheur David Lowe, et le propriétaire de brevet et l'université de la Colombie-Britannique.

#### a. Ses applications

Les applications de la méthode sont nombreuses et ne cessent de s'étendre, elles couvrent actuellement des domaines tels que la détection d'objet, la cartographie et la navigation, l'assemblage de photos, la modélisation 3D....

#### b. Principe de base

La méthode proposée par lowe comprend deux parties[15] :

- ✓ un algorithme de détection de caractéristiques et de calcul de descripteurs.
- ✓ un algorithme de mise en correspondance proprement dit.

Le premier est sans doute celui qui a le plus assuré la popularité de la méthode, Il s'agit tout d'abord de détecter sur l'image des zones circulaires "intéressantes", centrées autour d'un point-clé et de rayon déterminé appelé facteur d'échelle. Celles-ci sont caractérisées par leur

unité visuelle et correspondent en général à des éléments distincts sur l'image. Sur chacune d'elles, on détermine une orientation intrinsèque qui sert de base à la construction d'un histogramme des orientations locales des contours, habilement pondéré, seuillé et normalisé pour plus de stabilité. C'est cet histogramme qui sous la forme d'un vecteur à 128 dimensions (ou valeurs) constitue le descripteur SIFT du point-clé, et l'ensemble des descripteurs d'une image établit ainsi une véritable signature numérique du contenu de celui-ci.

Une fois le calcul des descripteurs effectué, l'algorithme de mise en correspondance intervient dans but de rechercher les zones d'une image dite suspecte qui contiennent des éléments visuellement similaires à ceux d'une bibliothèque d'images de référence, c'est-à-dire des descripteurs numériquement proches. Ceci ne peut fonctionner que parce que les descripteurs SIFT sont à la fois robustes (aux principales transformations affines et aux changements d'exposition ou de perspective) et discriminants (deux objets différents ont une grande probabilité d'avoir des descripteurs différents).

Donc cet algorithme consiste à rechercher des points caractéristiques (souvent appelés "features points" ou points d'intérêt) sur une photo qui seront décrits chacun par des coordonnées, une orientation, une échelle, ainsi que 128 descripteurs. L'idée générale de SIFT est donc de trouver des points-clés qui sont invariants à plusieurs transformations:

- ✓ Rotation.
- ✓ Echelle.
- ✓ Illumination.
- ✓ Changements mineurs du point de vue (inférieur à 30 degrés).

Les points d'intérêt sont des points particuliers des contours: des points isolés, des coins, des intersections.

### 3.3.1. Les étapes de la méthode SIFT

L'étape fondamentale de la méthode proposée par Lowe consiste à calculer ce que l'on appelle les "descripteurs SIFT" des images à étudier. Il s'agit d'informations numériques dérivées de l'analyse locale d'une image et qui caractérisent le contenu visuel de cette image de la façon la plus indépendante possible de l'échelle [32].

#### 3.3.1.1. Détection des points-clés et calcul du descripteur SIFT

La première étape de l'algorithme est la détection des points d'intérêt, dite points-clés.

Chacun de ces points particuliers est défini d'une part par ses coordonnées sur l'image ( $x$  et  $y$ ) et d'autre part par son facteur d'échelle caractéristique ( $\sigma$ ). En toute rigueur, il s'agit d'une zone d'intérêt circulaire, le rayon de la zone étant proportionnel au facteur d'échelle. Il s'ensuit une étape de convergence et de filtrage qui permet d'améliorer la précision sur la localisation des points-clés et d'en éliminer un certain nombre jugés non pertinents. Chaque point-clé restant est ensuite associé à une orientation intrinsèque, c'est-à-dire ne dépend que du contenu local de l'image autour du point clé, au facteur d'échelle considéré. Elle permet d'assurer l'invariance de la méthode à la rotation et est utilisée comme référence dans le calcul du descripteur, qui constitue la dernière étape de ce processus [33].

### 3.3.1.2. Détection d'extrema dans l'espace des échelles

La détection se fait dans un espace discret qu'on appelle l'espace des échelles ("scale space") qui comporte trois dimensions: les coordonnées cartésiennes  $x$  et  $y$  et le facteur d'échelle  $\sigma$ . On appelle "gradient de facteur d'échelle  $\sigma$ " (noté  $L$ ) le résultat de la convolution d'une image  $I$  par un filtre gaussien  $G$  de paramètre  $\sigma$ .

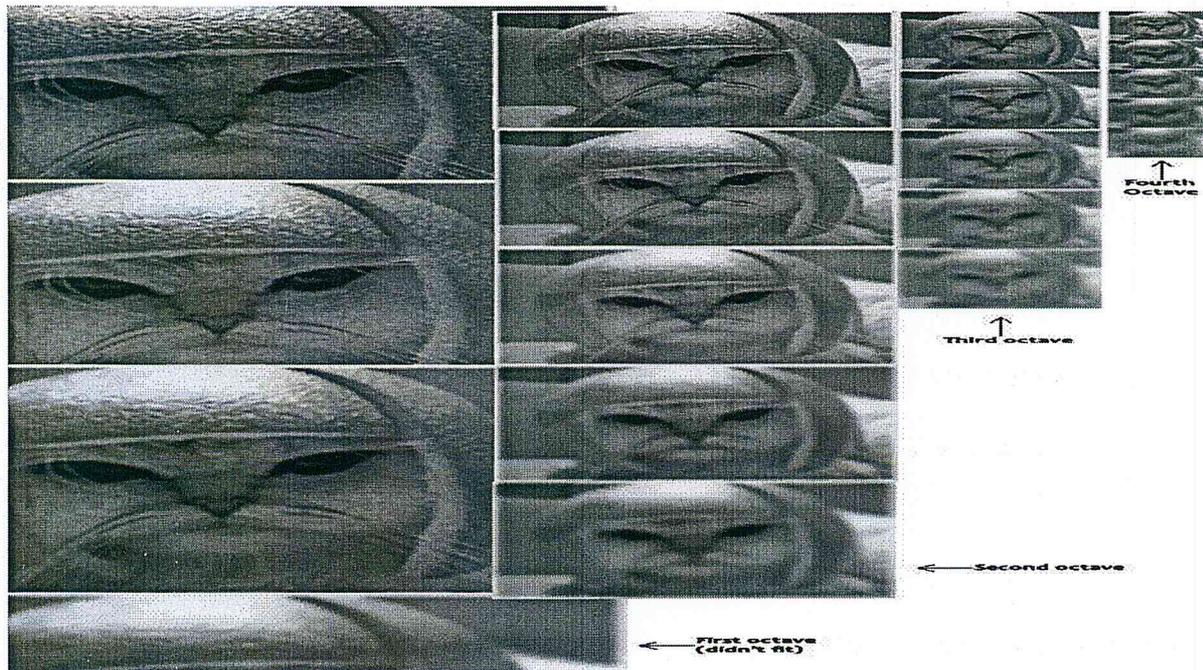


Figure 3.3 : Illustration de DOG.

Cette convolution a pour effet de laisser l'image originale de telle sorte que les détails trop petits, c'est-à-dire de rayon inférieur à  $\sigma$ , sont estompés. Par conséquent, la détection des objets approximativement égaux à  $\sigma$  se fait en étudiant l'image appelée "différences de gaussiens" (en anglais "difference of gaussians", DoG).

L'illustration d'une pyramide préconisée pour optimiser le temps de calcul des images floutées à un grand nombre d'échelles différents. la base de la pyramide est en général l'image original et le niveau donné (on parle d'octave par analogie avec la musique) est obtenu à partir du précédent en divisant la résolution de l'image par 2, ce qui revient à doubler le facteur d'échelle. au sein d'une même octave , le nombre de convolées à calculer est constant [30].

Un point-clé candidat est définie comme un point où un extremum du DoG est atteint par rapport à ses voisins immédiates. C'est comme cela que l'invariance par échelle est obtenue aux niveaux des points d'intérêts.

### 3.3.1.3. Amélioration de la précision

L'étape de détection d'extremums produit en général un grand nombre de point d'intérêt candidats, dont certains sont instables. De plus, leur localisation, en particulier aux échelles les plus grands (autrement dans les octaves supérieur de la pyramide où la résolution est plus faible) reste approximative. De ce fait, des traitements supplémentaires doivent être appliqués, pour un objectif double :

- ✓ reconverger la position des points pour améliorer la précision sur x, y et sigma.
- ✓ éliminer les points de faible contraste.
- ✓ supprimer les points situés sur des arêtes de contour à faible courbure et donc susceptibles de "glisser" facilement [34].

### 3.3.1.4. Assignation d'orientation aux points d'intérêt

L'étape d'assignation d'orientation consiste à attribuer à chaque point d'intérêt de l'image une ou plusieurs orientation déterminer localement (sur l'image) à partir de direction des gradients dans un voisinage autour du point. Dans la mesure où les descripteurs sont calculés relativement à ces orientations, cette étape est essentielle pour garantir l'invariance de ceux-ci à la rotation: les mêmes descripteurs doivent pouvoir être obtenus à partir d'une même image, quelle qu'en soit l'orientation [35].

### 3.3.1.5. Les descripteurs des points d'intérêt

Une fois que les points d'intérêts associés à des facteurs d'échelles et à des orientations ont été détectés et que leur invariance aux changements d'échelles et aux rotation est assurée, l'algorithme SIFT arrive alors à l'étape de calcul des vecteurs descripteurs, traduisant numériquement chacun de ces points d'intérêt (ou points-clés). Au cours de cette étape, des

traitements supplémentaires sont appliqués, permettent d'assurer un surcroît de robustesse de l'algorithme, en rendant les descripteurs invariants à d'autres transformations telle que:

- ✓ la luminosité
- ✓ le changement de point de vue 3D...

Cette étape est réalisée sur l'image lissée avec des paramètres de facteur d'échelle le plus proche de celui du point-clé considéré [36].

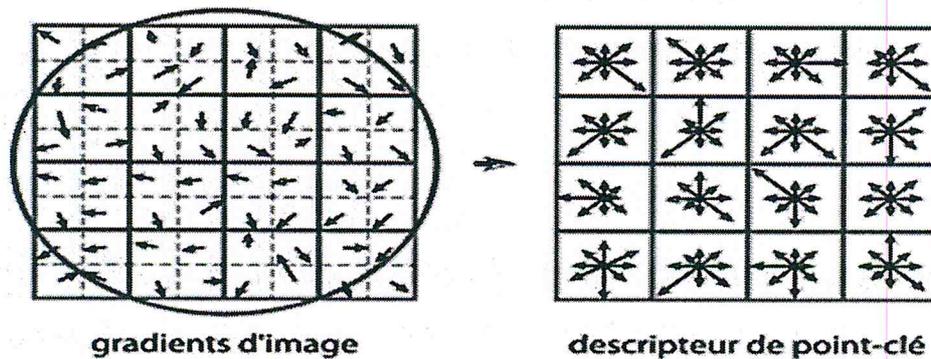


Figure 3.4 : Illustration des descripteurs des points d'intérêt.

### 3.3.1.6. Utilisation pour la recherche d'objets dans des images

La problématique de base pour laquelle la méthode SIFT a été conçue est la suivante: peut-on trouver dans une image donnée (dite image question ou image suspecte), des objets déjà présents dans une collection d'images de référence préétablie ?

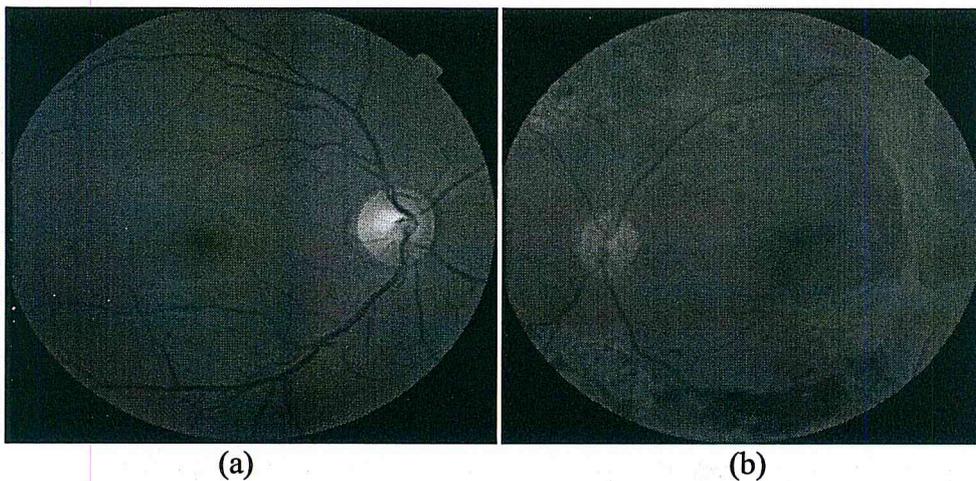
Dans la méthode originale de David Lowe [37], les points-clés et mes descripteurs SIFT sont tout d'abord extraites des images de référence et stockés dans une sorte de base de données. Un objet est identifié dans l'image question en effectuant une comparaison de ses descripteurs à ceux des images de référence disponibles en base de données, fondée simplement sur la distance euclidienne. Parmi toutes les correspondances ainsi établies, des sous-ensembles (clusters) sont identifiés, au sein desquels la mise en correspondance est cohérente du point de vue des positions des points, des facteurs d'échelle et des orientations. Les clusters contenant au moins trois correspondances ponctuelles sont conservés. Dans chacun d'eux, on modélise la transformation permettant de passer de l'image question à l'image de référence, et on élimine les correspondances aberrantes par simple vérification de ce modèle. Enfin, Lowe applique un modèle probabiliste pour confirmer que la détection d'une correspondance d'objets entre l'image question et l'une des images de référence n'est pas due au hasard, basé sur l'idée que si de nombreux points n'ont pas pu être mis en correspondance c'est que l'on a peut-être affaire à un faux positif [38].

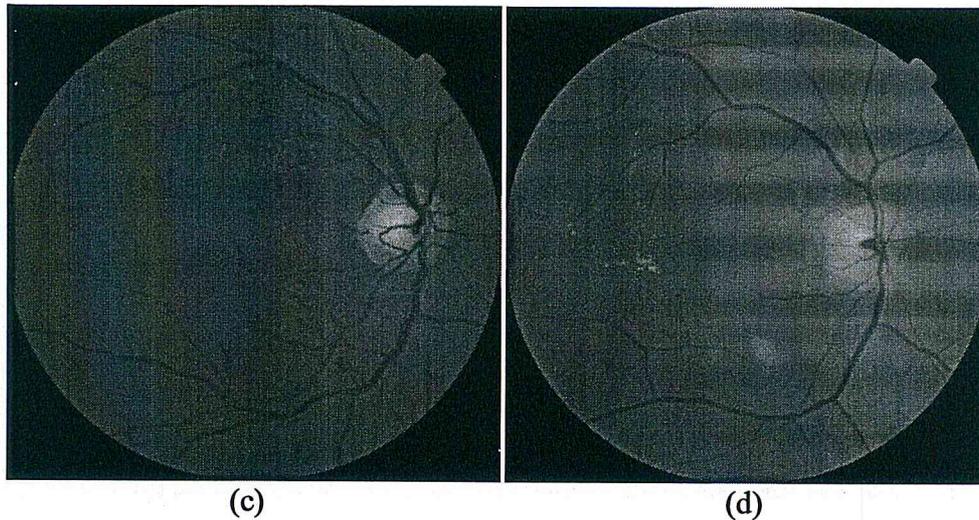
## 4. Description de la base de données

Les bases d'images sont une ressource essentielle dans le développement des Algorithmes d'analyse d'images rétiniennes, Elles conduisent à la mise au point de meilleurs algorithmes. Dans cette section, nous présentons la base de données utilisées dans notre travail.

### Base d'image « MESSIDOR »

La base de données Messidor contient 1200 images couleur du fond d'œil. Ces images ont été acquises par l'Hôpital Lariboisière à Paris, la Faculté de Médecine Saint-Etienne CHU de Brest (France). 800 images sont acquises avec dilatation de la pupille et 400 images sans dilatation ; en utilisant un rétinographe non mydriatique de type Topcon TRC NW6 avec un champ de vision de 45°. Les images ont une taille de 1440 \* 960 en 588 images, 2240 \* 1488 en 400 images et 2304 \* 1536 en 212 images. Toutes les images sont enregistrées en format TIFF non compressé. Pour chaque image, le grade de la RD et le risque d'œdème maculaire (EM) est fournit par des experts. Le diagnostic est considéré comme la norme de référence pour l'analyse des performances de notre travail. Quelques exemples d'images de la base de données sont illustrés dans la figure.(3.4) [39].





**Figure.3. 5:** Exemples d'images de la base de données MESSIDOR ; (a) : image saine  
(b) : image pathologique avec une RD de stade 3 et aucun risque d'un œdème maculaire ; (c) : image pathologique avec une RD de stade 3 et risque d'un œdème maculaire stade 2 ; (d) : image pathologique.

## 5. Techniques de classification utilisé

Dans notre travail on a fusionné deux type de classifieur :

### 5.1. Les machines à vecteur support (SVM)

Les machines à vecteur support(SVM) ont reçu une attention considérable, ces dernières années et un grand nombre d'applications sont décrites, dans la littérature .

L'objectif des SVM est de maximiser la marge de séparation, entre les classes. Les SVM sont des algorithmes d'apprentissage faisant l'hypothèse que les éléments sont linéairement séparables, s'ils sont préalablement projetés dans un espace de dimensions adéquat.

Le principe des approches SVM est de trouver l'hyperplan optimal, parmi l'ensemble des hyperplans possibles (figure (3.4)) permettant de classifier correctement les données (i.e. les données des classes de label +1 et -1 se trouvent de chaque côté de l'hyperplan)mais également tel que sa distance aux vecteurs (exemple d'apprentissage) les plus proches soit maximale (i.e. le plus loin possible de tous les exemples). Les vecteurs les plus proches sont alors dénommés "vecteurs supports" et la distance constitue la marge optimale [40] .

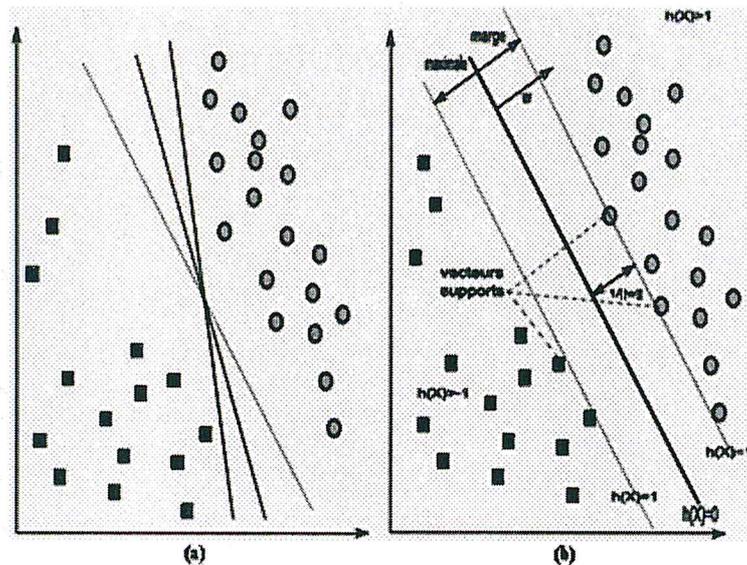


Figure3. 6: (a) Recherche de l'hyperplan optimal ; (b) Hyperplan optimal, marge et vecteurs supports [40].

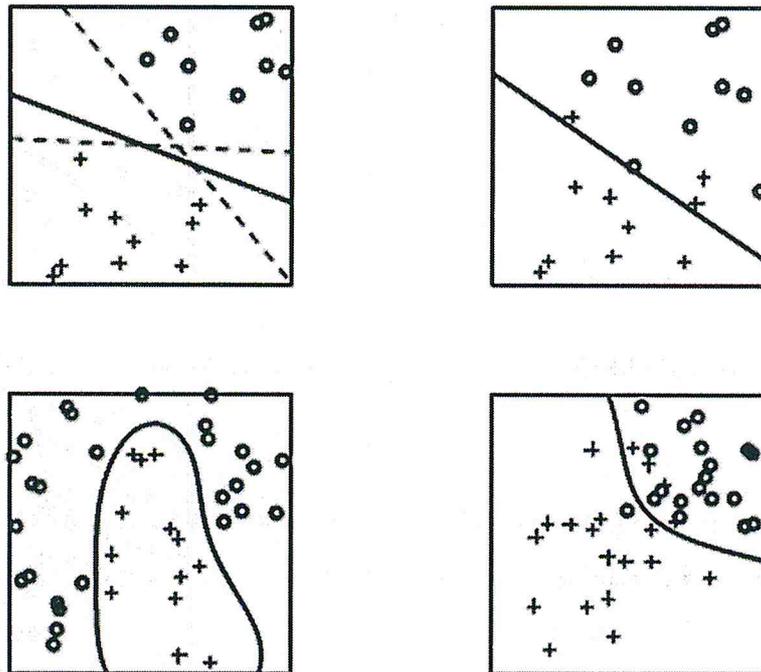
### 5.1.1. Principe de fonctionnement

Le principe de base des SVM, consiste de ramener le problème de la discrimination à celui, linéaire, de la recherche d'un hyperplan optimal. Deux idées ou astuces permettent d'atteindre cet objectif [41]:

- La première consiste à définir l'hyperplan comme solution d'un problème d'optimisation, sous contraintes dont la fonction objectif ne s'exprime qu'à l'aide de produits scalaires, entre vecteurs et dans lequel le nombre de contraintes "actives" ou vecteurs supports contrôle, la complexité du modèle.
- Le passage à la recherche de surfaces séparatrices, non linéaires est obtenu par l'introduction d'une fonction noyau (kernel) dans le produit scalaire induisant, implicitement une transformation non linéaire des données vers un espace intermédiaire, de plus grande dimension. D'où l'appellation couramment rencontrée de machine à noyau ou kernel machine. Sur le plan théorique, la fonction noyau définit un espace hilbertien, dit auto-reproduisant et isométrique par la transformation non linéaire de l'espace initial et dans lequel, est résolu le problème linéaire (figure 3.5).

Cet algorithme devient largement, utilisé dans de nombreux types d'applications et s'avère un concurrent sérieux des algorithmes les plus performants (agrégation de modèles). L'introduction de noyaux, spécifiquement adaptés à une problématique donnée, lui confère une grande flexibilité pour s'adapter à des situations très diverses (reconnaissance de formes, de caractères, détection, diagnostic...). À noter que, sur le plan algorithmique, ces algorithmes

sont plus pénalisés par le nombre d'observations, c'est-à-dire le nombre de vecteurs supports potentiels, que par le nombre de variables. Néanmoins, des versions performantes, permettent de prendre en compte des bases de données volumineuses, dans des temps de calcul acceptables [41].



**Figure 3. 7:** Exemples de quatre types de problèmes de discrimination binaire où il s'agit de séparer les points bleus des croix rouges. La frontière de décision est représentée en noir [41].

### 5.1.2. Classification des SVM multi-classes

L'adaptation des SVM bi classe au cas multi classe, peut se faire de trois façons différentes. Le choix va dépendre de la taille du problème.

1. L'approche un contre tous consiste, à entrainer un SVM bi-classe en utilisant les éléments d'une classe contre tous les autres. Il s'agit de résoudre les problèmes de l'ordre de,  $c$  SVM chacun de taille  $n$ .
2. L'approche un contre un : consiste à entrainer  $\frac{c(c-1)}{2}$  SVM sur chacun des couples de classes, puis à décider de la classe gagnante soit par un vote majoritaire soit, en traitant les résultats grâce à l'estimation de probabilités a posteriori. Le nombre de classifieurs SVM à entrainer, peut être réduit en utilisant un codage astucieux pour les classes, à travers un code correcteur d'erreur ou un graphe direct acyclique [41].
3. L'approche globale, consiste à traiter le problème en une seule fois. Cela peut se faire en posant formellement le problème, par exemple si l'on note  $f_\ell(x) - b_\ell$  la fonction de discrimination associée à la classe  $\ell$  se réduit à la relation 3.10.

$$\left\{ \begin{array}{l} \min_{f \in \mathcal{H}, b, \xi \in \mathbb{R}^n} \frac{1}{2} \sum_{\ell=1}^c \|f_{\ell}\|_{\mathcal{H}}^2 + \frac{c}{d} \sum_{i=1}^n \sum_{\ell=1, \ell \neq y_i}^c \xi_{i\ell}^d \\ \text{avec} \quad y_i (f y_i(x_i) + b y_i - f_{\ell}(x_i) - b_{\ell}) \geq 1 - \xi_{i\ell} \\ \xi_{i\ell} \geq 0 \text{ pour } i = 1, \dots, n; \ell = 1, \dots, c; \ell \neq y_i \end{array} \right. \quad 3.10$$

Ce problème est un programme quadratique, de même nature que celui des SVM et de taille  $n \times c$ . L'estimateur associé, est non consistant mais donne de bons résultats en pratique.

### 1. Trouver l'hyperplan

On peut montrer que pour un hyperplan, canonique  $w \cdot x + b = 0$ , la marge

est donnée par l'expression 3.11.

$$M = \frac{1}{\|w\|} \quad 3.11$$

Où  $\|w\| = \sqrt{w_1^2 + \dots + w_n^2}$ . On voit donc que plus la norme  $\|w\|$  est petite, plus la marge de l'hyperplan canonique correspondant, est grande. Ainsi, afin de trouver l'hyperplan qui sépare le mieux les données, il faut trouver celui qui respecte les conditions d'un hyperplan canonique et pour lequel, la norme  $\|w\|$  est minimale.

La recherche du meilleur hyperplan peut donc s'écrire, sous la forme du problème d'optimisation suivant:

$$\text{Minimiser } \|w\| \quad \text{sujet à } y_i (w \cdot x_i + b) \geq 1, i = 1, \dots, l \quad 3.12$$

Les contraintes  $y_i (w \cdot x_i + b) \geq 1, i = 1, \dots, l$  assurent d'une part que l'hyperplan sépare les données correctement et d'autre part, qu'il est canonique. En effet,  $y_i (w \cdot x_i + b) > 0$  si et seulement si  $(w \cdot x_i + b) = y_i$ , donc si et seulement si  $x_i$  est du bon côté de l'hyperplan. Ainsi, l'hyperplan doit correctement séparer les données. Ensuite, on peut montrer qu'imposer  $y_i (w \cdot x_i + b) \geq 1$  assure que pour toutes les données qui ne sont pas sur la marge,  $|w \cdot x_i + b| > 1$  et que  $|w \cdot x_i + b| = 1$  pour les données sur la marge, donc que l'hyperplan est canonique.

Nous avons ainsi formulé un problème d'optimisation dont la solution optimale, est l'hyperplan canonique séparant les données avec la plus vaste marge possible. Cependant, il

est possible de formuler un problème équivalent, mais avec une fonction objectif plus simple. En effet, comme la relation 3.13 ;

$$\| w \| = \sqrt{w \cdot w} \quad 3.2$$

minimiser  $\| w \|$  est équivalent à minimiser  $w \cdot w$ . Évidemment, minimiser  $w \cdot w$  est équivalent à minimiser  $\frac{1}{2} w \cdot w$  (cette petite modification permet d'éviter d'avoir une constante dans la représentation duale du problème. Par conséquent, afin de trouver l'hyperplan canonique qui sépare les données avec la plus grande marge possible, il suffit de résoudre le problème d'optimisation suivant :

$$\text{minimiser } \frac{1}{2} w \cdot w \text{ Sujet à } y_i(w \cdot x_i + b) \geq 1, i = 1, \dots, l \quad 3.3$$

Une propriété très intéressante de ce problème est que la relation 3.15, est une fonction strictement convexe. Ceci assure qu'il n'y a pas de minimum relatif et qu'il n'existe qu'une unique solution optimale [41].

$$f(w) = w \cdot w = w_1^2 + \dots + w_n^2 \quad 3.15$$

## 5.2. L'algorithme KNN

L'algorithme KNN figure parmi les plus simples algorithmes d'apprentissage artificiel. Dans un contexte de classification d'une nouvelle observation  $x$ , l'idée fondatrice simple est de faire voter les plus proches voisins de cette observation. La classe de  $x$  est déterminée en fonction de la classe majoritaire parmi les  $k$  plus proches voisins de l'observation  $x$ .

La méthode KNN est donc une méthode à base de voisinage, non-paramétrique ; Ceci signifiant que l'algorithme permet de faire une classification sans faire d'hypothèse sur la fonction  $y=f(x_1, x_2, \dots, x_p)$  qui relie la variable dépendante aux variables indépendantes.

Dans notre système on a utilisé la distance euclidienne pour calculer la similarités entre les classes. Elle est définie comme suit[42] :

$$d(x_i, x_j) = \left( \sum_{s=1}^p (x_{is} - x_{js})^2 \right)^{\frac{1}{2}}$$

## 1st, 2nd, and 3rd Nearest Neighbors of a Test Instance

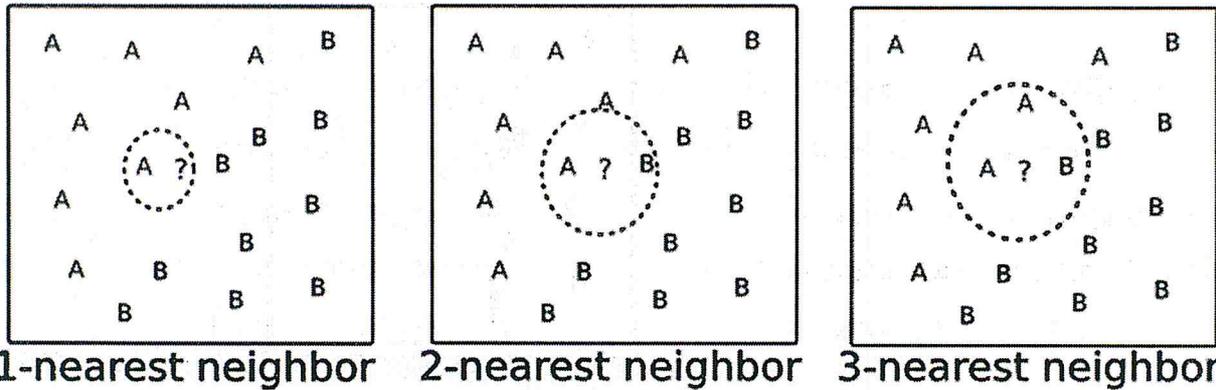


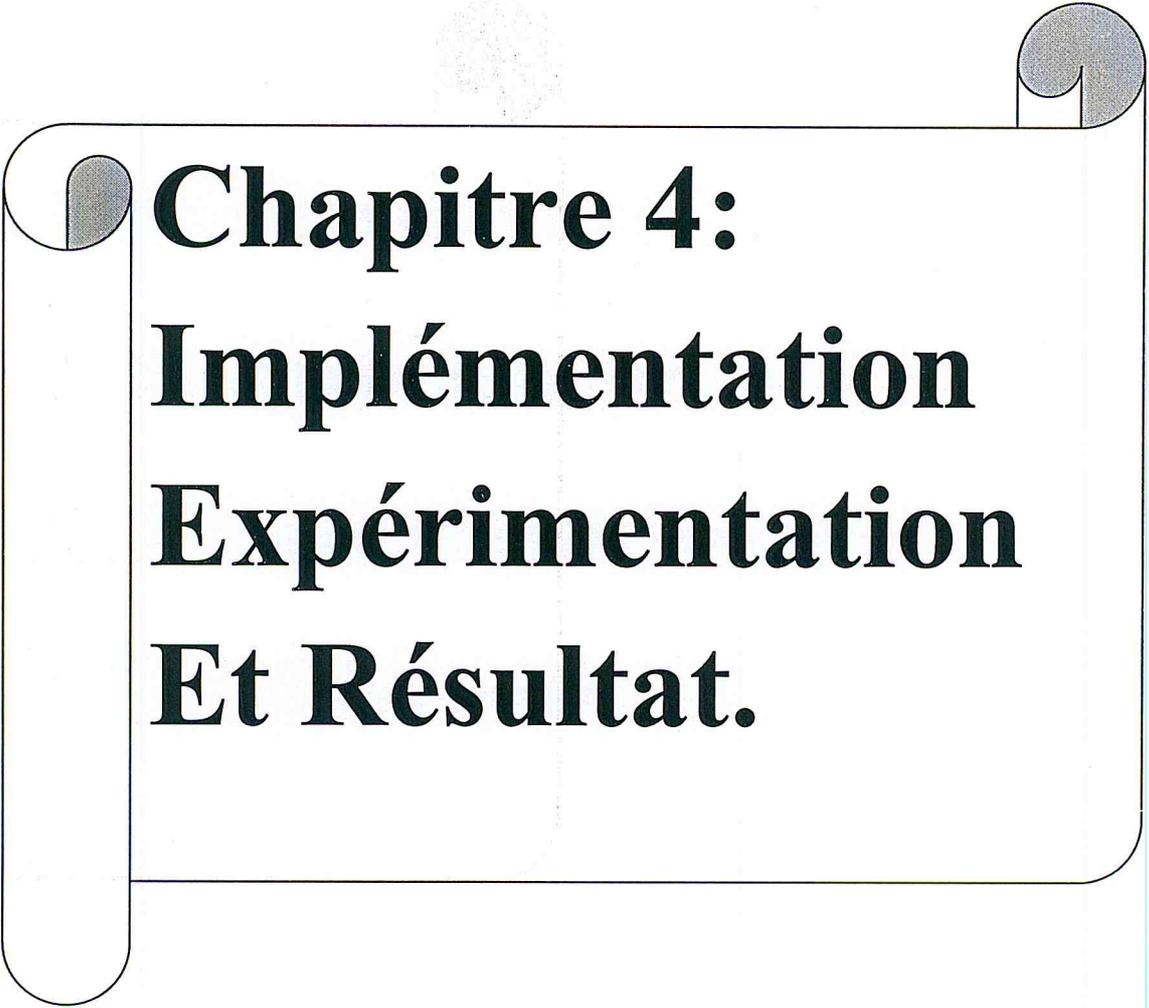
Figure 3.8: Exemple de fonctionnement de classifieur kppv avec  $k=1,2,3$  [42] .

### Algorithm[42] :

- pour chaque exemple d'apprentissage  $\langle x, f(x) \rangle$ ,
  - ❖ ajouter l'exemple à la liste d'apprentissage (base d'apprentissage).
  
- un exemple donné  $x_q$  pour classifier.
  - en prendre  $x_1, x_2, \dots, x_k$  les  $k$  plus proches voisins à  $x_q$  dans les exemples d'apprentissage (la base d'apprentissage).
  - retourner la classe qui représente le maximum a partir des  $K$  plus proches voisins (la classe majoritaire dans les  $k$  plus proches ).

## 6. Conclusion

Nous avons présenté dans ce chapitre la chaîne d'analyse d'images. L'extraction Permet de détecter les caractéristiques et de calculer les descripteurs de chaque objet présent dans l'image, a fin d'avoir comme résultat une matrice qui va être utilisé par les deux classifieurs, la fusion de ces derniers permet d'avoir un résultat plus exacte pour obtenir une décision soit sain soit malade pour le cas traité.

A decorative scroll graphic with a black outline and grey shading on the top and bottom edges, containing the chapter title. The scroll is positioned on the right side of the page, with its top edge curving upwards and its bottom edge curving downwards.

**Chapitre 4:  
Implémentation  
Expérimentation  
Et Résultat.**

## 1. Introduction

L'objectif de ce chapitre, est de présenter l'application développée, les traitements illustrés par des images de fond de l'œil dans le but de l'extraction et de la classification des pathologies rétiniennes issues de la base de données « MESSIDOR » qui contient 1200 images couleur du fond d'œil. Ces images ont été acquises par l'Hôpital Lariboisière à Paris, la Faculté de Médecine Saint-Etienne CHU de Brest (France). Notre système détecte les cas sains et pathologiques de cette Base (MESSIDOR) suivant les machines à support de vecteurs (SVM) et le l'algorithme de k-plus proche voisins (KNN), en vue d'une aide à la décision.

## 2. Présentation de l'environnement du travail

Notre système est développé, sous environnement Windows 7, à l'aide de l'outil de programmation MATLAB de la version R2014b.

### 2.1. Matériel utilisé

L'implantation de nos codes, est réalisée grâce à un PC portable, ayant un :

Micro Processeur possède 2 cœurs physique et quatre virtuel Intel Core i5 3337U CPU (1.80 GHz)

6 GB Mémoire Vive (RAM)

1 TB Disque Dur (HDD HARD DRIVE)

1366 x 768

Windows 7 (64 bits)

### 2.2. Langage utilisé

Notre système est développé sous environnement Windows, à l'aide de l'outil de programmation MATLAB (abréviation de " **Matrix Laboratory**") de la version R2014b [55], qui est un environnement informatique conçu pour le calcul matriciel. L'élément de base est une matrice, dont la dimension n'a pas à être fixée. Matlab est un outil puissant qui permet la résolution de nombreux problèmes, en beaucoup moins de temps. On peut se rendre compte de la puissance du logiciel en lançant la commande *demo*. Les compléments d'information peuvent être facilement obtenus, grâce à l'aide en ligne. Matlab (figure 4.1) s'élargit sur la librairie des fonctions mathématiques, l'environnement graphique, ainsi que sur une interface de développement.

On le trouve dans les applications de :

- Calcul numérique,
- développement d'algorithmes et la programmation
- modélisation et simulation,
- analyse et visualisation de données,
- création de graphiques scientifiques,
- création d'application avec interfaces utilisateurs.
- l'interfaçage avec d'autres langages (**Fortran, C++**).
- le développement d'interface utilisateur (**GUI**).
- L'utilisation des boîtes à outils (Toolboxes) spécialisées.

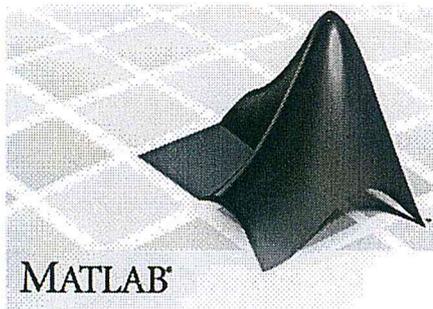


Figure : 4.1 L'icône du logiciel Matlab [43].

S'il est parfaitement adapté à l'automatique et au traitement du signal, sa facilité d'emploi avec des nombres complexes et ses possibilités d'affichages graphiques, en font un outil intéressant pour plusieurs types d'applications. De plus, des " toolboxes " (boîtes à outils) sont disponibles dans de nombreux domaines du traitement du signal, de la commande des systèmes, des réseaux de neurones, de la logique floue, des ondelettes, de la simulation, etc.

### ➤ Première utilisation de Matlab

Pour découvrir matlab d'une façon efficace, il faut utiliser son aide en ligne. On présente ci-dessous, quelques commandes intéressantes:

- **Help** : « help » donne la liste des aides générales possibles;

- **Helpwin:** ouvre une fenêtre et donne accès, à une aide détaillée;
- **Info :** fournit des informations sur la version de Matlab;
- **Lookfor<mot clé> :** Recherche du mot-clé indiqué dans toutes les entrées d'aide.
- **Help+ nom de commande :** donne l'utilisation de cette commande;
- **Démo :** lance une démo générale de matlab;
- **Help demos :** donne une liste des démos existantes.

Quelques commandes importantes, liées à l'espace de travail :

- **Clear:** supprime la variable de l'espace de travail;
- **Clc:** efface l'écran son toucher les variables.
- **CTRL + C :** (touches du clavier) permet d'interrompre un programme (ie : récupérer la main).
- **Exit/quit:** permet de sortir de matlab;
- **Who/whos:** donne le nom de variable présente dans l'espace de travail;
- **Look for+commande:** donne une Liste de commandes, qui ont un rapport avec le

nom de commande.

- **mkdir :** réalise la création d'un répertoire;
- **pwd :** indique le répertoire courant;
- **cd :** permet de changer de répertoire;
- **path :** visualise ou change le chemin de recherche du répertoire de MATLAB.

### 2.3. Présentation du 'gui'

Les interfaces graphiques (ou interfaces homme-machine) sont appelées GUI (pour Graphical User Interface) sous MATLAB. Elles permettent à l'utilisateur d'interagir avec un programme informatique, grâce à différents objets graphiques (boutons, menus, cases à cocher...). Ces objets sont généralement actionnés à l'aide de la souris ou du clavier. Malgré le fait que les interfaces graphiques semblent secondaires, par rapport au développement du cœur d'une application, elles doivent néanmoins être conçues et développées avec soin et rigueur. Leur efficacité et leur ergonomie sont essentielles dans l'acceptation et l'utilisation de ces outils par les utilisateurs finaux.

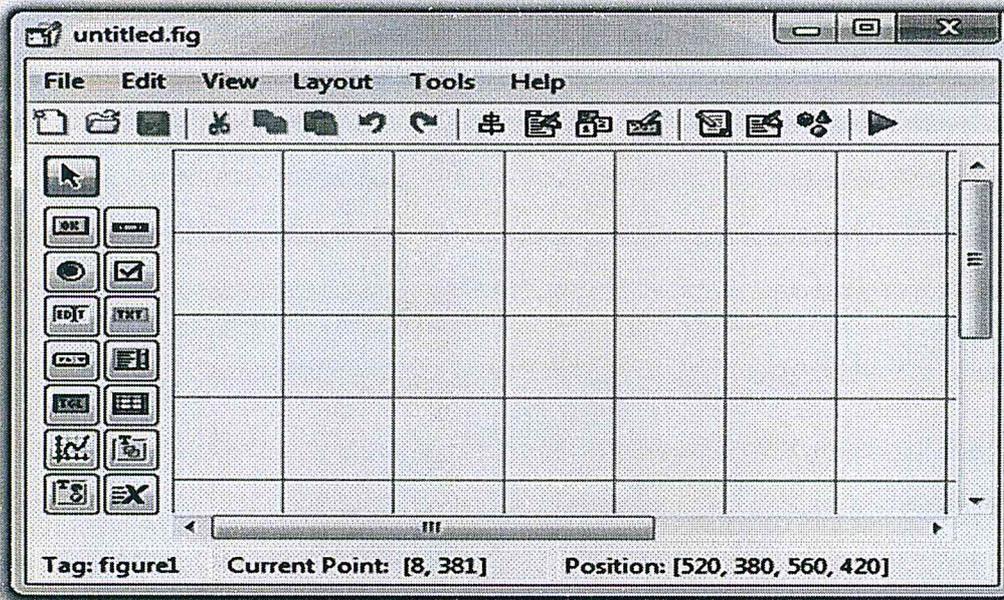


Figure 4.2: Fenêtre principale du guide [55].

### 3. présentation de notre interface

Notre interface utilisateur :

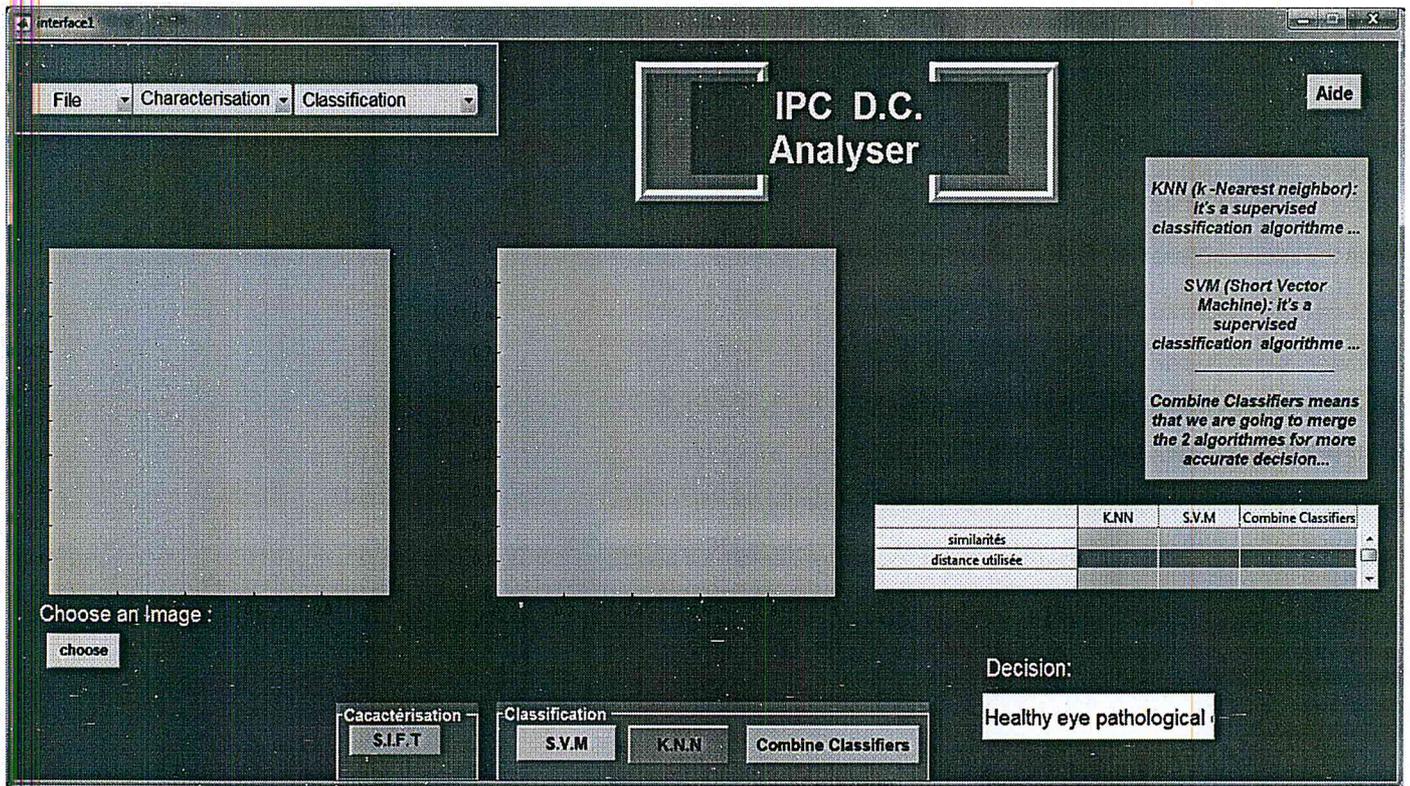


Figure 4.3 : l'interface d'utilisateur (graphical user interface GUI)

La barre menu contient 3 champs:

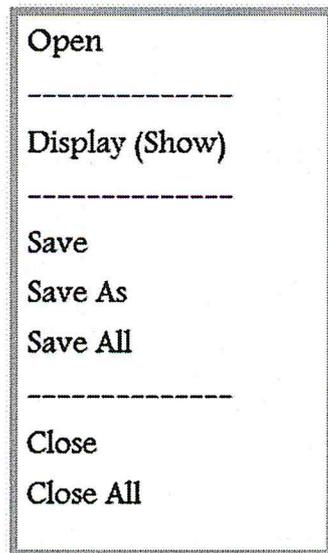


1. **File:** ce champs gère les fichiers (les images) Ouvrir "Open", Fermer "Close" ou bien Visualiser "Display" une image dans une grand Figure pour mieux voir et zoomer dans l'image ou bien sauvegarder "Save" cette image.

2. **Characterisation :** ce champs gère la partie Extraction des caractéristiques comme l'affichage des points clés "keypoints" dans l'image ou bien les points d'intérêts "interest point" ou afficher les octave et les niveaux de "blur" de l' image et l'affichage de "Difference of Gaussian" entre ces octaves ou bien exécuter l'algorithmes SIFT sur l'image susceptible pour extraire les caractéristiques et les décrire dans une matrice qu'on va Classifier avec SVM et KNN pour prenez une décision (cas sain ou bien pathologique)

3. **Classification:** ce champs gère la partie Classification dans notre système à partir de la résultats de l'étape précédant (extraction des caractéristiques), on va utiliser (combiner) les deux classifieurs KNN et SVM pour classifier cette cas si c'est une cas sain ou pathologiques on utilisons la matrice résultat de l'algorithme SIFT et notre base d'apprentissage.

**File:** un sous-menu va ouvrir avec la liste Suivant :



**Characterisation:** un sous-menu va ouvrir avec la liste Suivant :

Octaves and Blur Level  
-----  
Difference of Gaussian  
Keypoint  
Interest Points  
-----  
Rental Vascular Tree  
-----  
S.I.F.T

**Classification:** un sous-menu va ouvrir avec la liste Suivant :

Supervised  
K.N.N  
S.V.M  
-----  
Unsupervised  
K-Means  
H.A.C  
-----  
Combine Classifiers

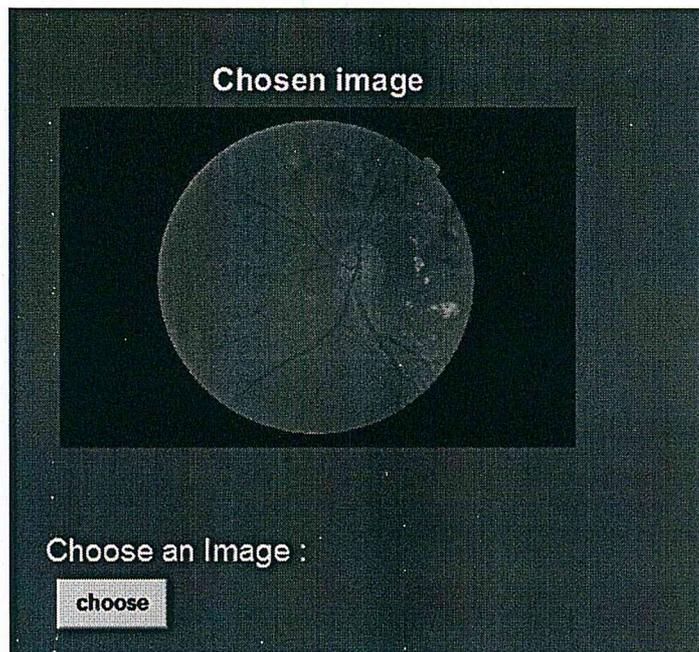
Le champ de résultat (Décision): soit un cas sain ou cas pathologique

Decision:  
Healthy eye

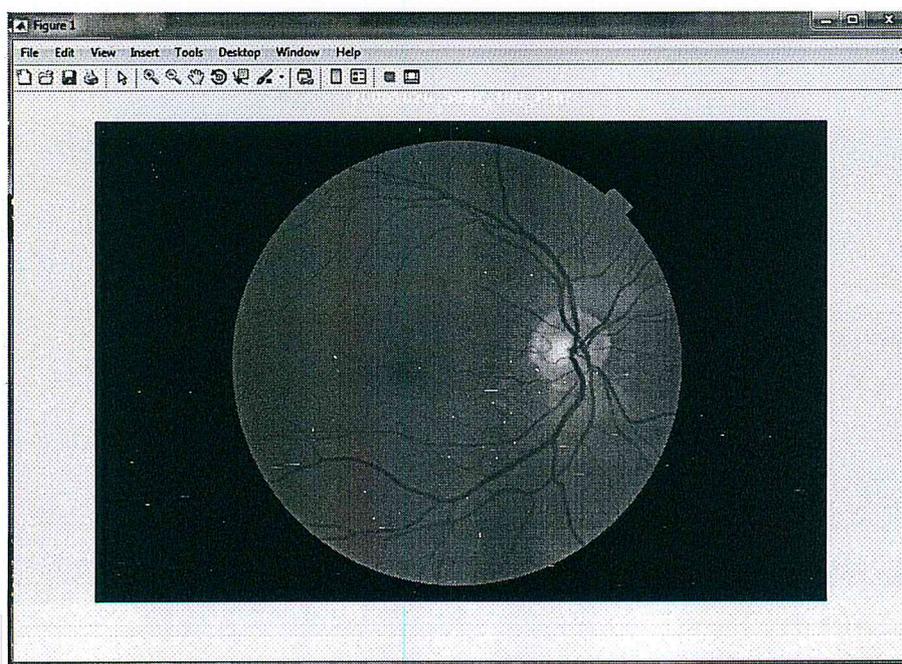
Decision:

Pathological eye

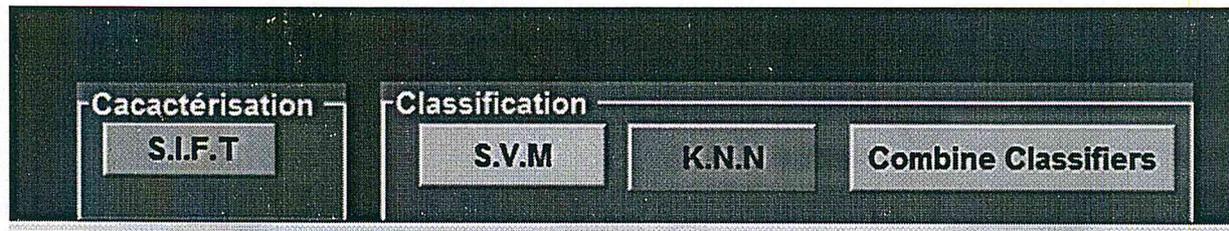
Ouverture de l'image dans l'interface:



Le Bouton "Choose" c'est un raccourci pour ouvrir une Image rapidement.  
 visualisation de l'image dans une figure pour mieux manipuler l'image:



et les Boutons suivant sont des raccourcis pour SVM et SIFT et KNN et la fusion (combinaison) des deux classifieurs



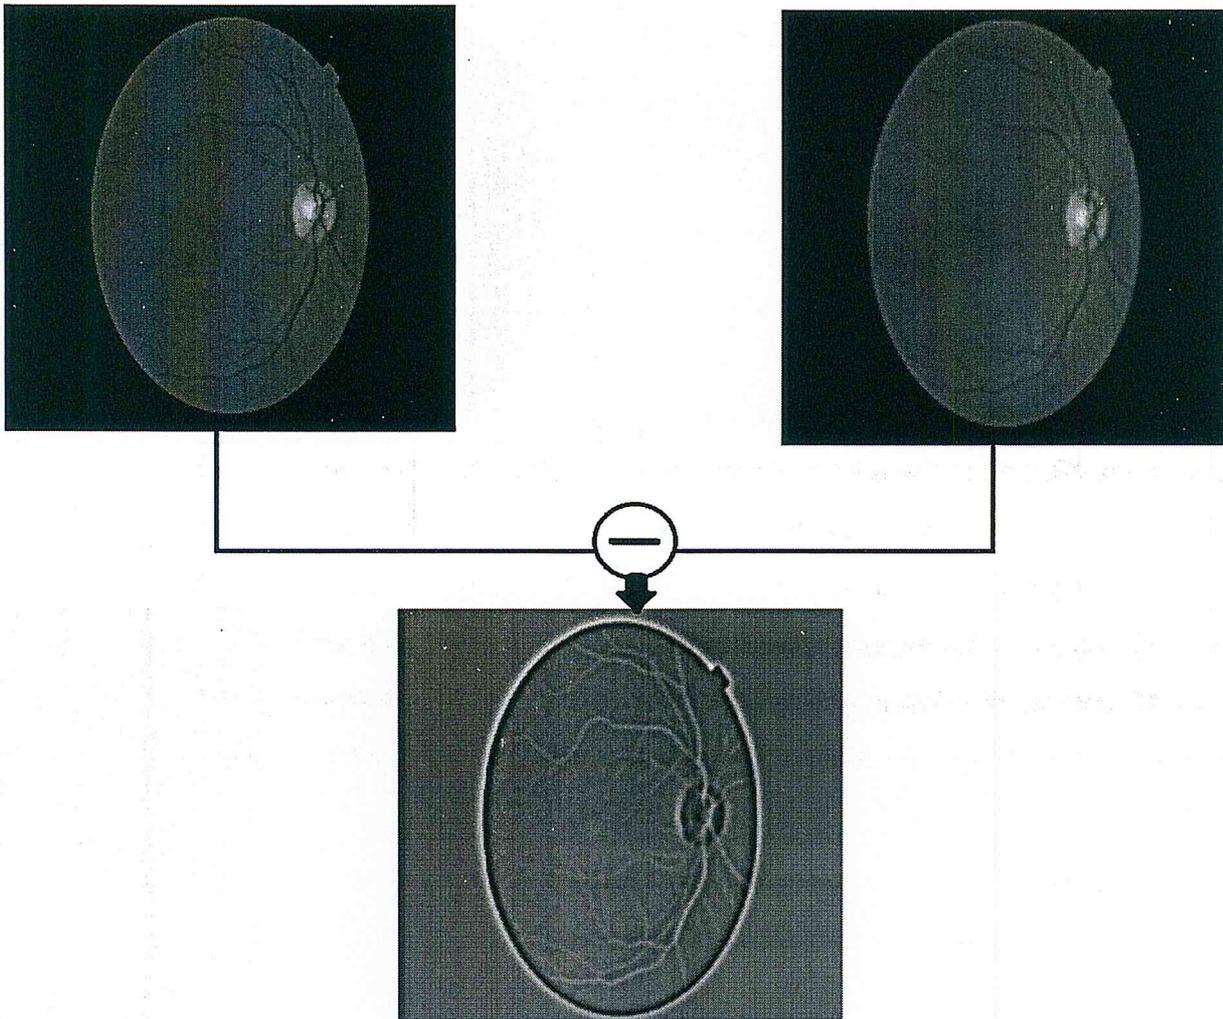
## 4. Test et évaluation

Dans cette partie on applique la méthode SIFT pour chaque image. La première étape de l'algorithme est la détection des points d'intérêts et la seconde étape est le calcul des descripteurs.

### 4.1 Détection d'extrema

Pour chaque image, on applique une convolution par un filtre de Gaussien pour obtenir l'image appelée différence de Gaussien (DoG) pour localiser les points d'intérêts.

Voici une image de notre base après l'application de cette fonction:



**Figure 4.4 :** Application du filtre gaussien et calcul de la différence de gaussien entre l'image originale et l'image gaussien.

#### 4.2. Assignment d'orientation aux points d'intérêts

L'étape d'assignment d'orientation consiste à attribuer à chaque point d'intérêt de l'image une ou plusieurs orientations déterminées localement (sur l'image) à partir de la direction des gradients dans un voisinage autour du point. Dans la mesure où les descripteurs sont calculés relativement à ces orientations.

Voici une image de notre base des points d'intérêt :

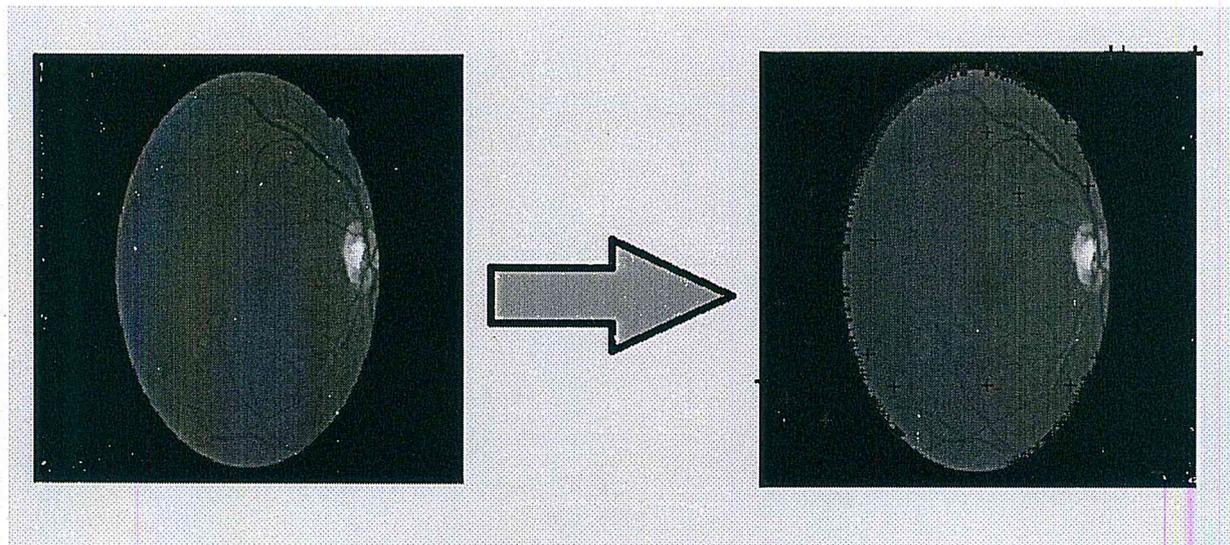


Figure 4.5: Détermination des points d'intérêt de l'image.

### 4.3. Descripteur de point-clés

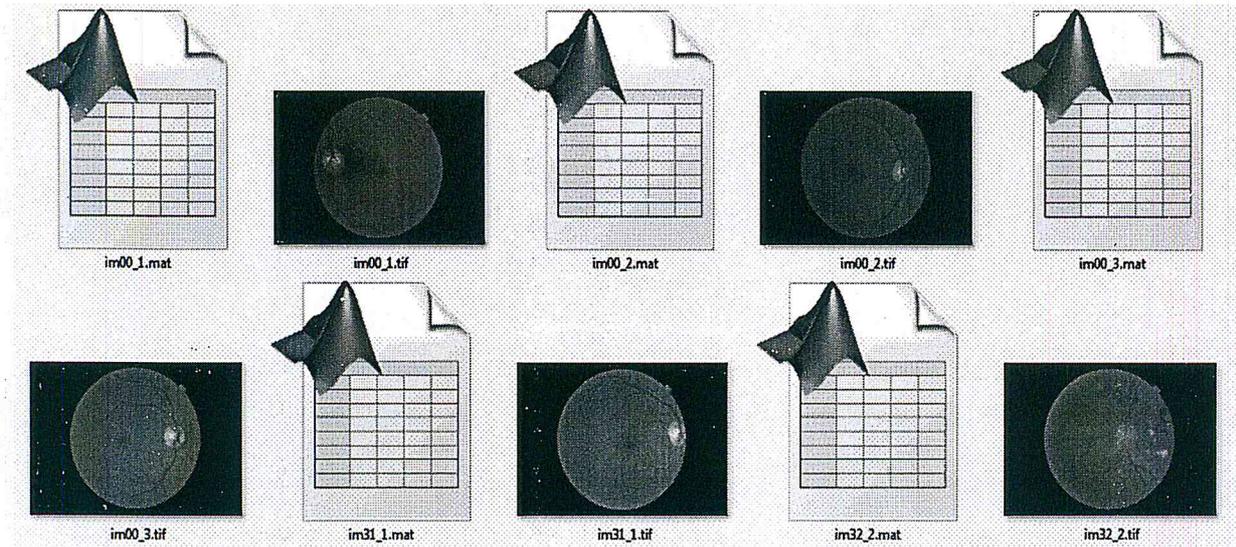
Pour le descripteur, on estime le gradient par son amplitude et son orientation.

L'algorithme SIFT arrive alors a l'étape de calcul des vecteurs descripteurs, traduisant numériquement chacun de ces points d'intérêts ( ou interest points), La valeur des descripteurs de chaque image sera sauvegardée dans un fichier ".MAT" Voici un exemple de fichier MAT qui contient les valeurs des descripteurs d'une image :

	4596	4597	4598	4599	4600	4601	4602	4603	4604	4605
42	0	0	0	0	0	0	0	0	0	0
43	0.2493	0.2668	0.2050	-0.0033	-0.0931	0.2421	0.2497	0.7071	1.0902e-12	1.0589e-12
44	0	-0.0014	0.0017	0.0872	0.1770	-0.0822	0.2497	2.0468e-13	2.0388e-11	0.7071
45	0	-0.0014	0.0017	0.0872	0.1770	-0.0822	0.2497	2.0468e-13	2.0388e-11	0.7071
46	0.2493	0.2668	0.2050	-0.0033	-0.0931	0.2421	0.2497	0.7071	1.0902e-12	1.0589e-12
47	0	0	0	0	0	0	0	0	0	0
48	0	0	0	0	0	0	0	0	0	0
49	0	0	0	0	0	0	0	0	0	0
50	0	0	0	0	0	0	0	0	0	0
51	0	-0.0091	-0.0096	0.2863	0.2431	-0.0196	-0.1192	-4.1151e-12	-2.4809e-12	-1.2670e-12
52	-0.0371	-0.0290	0.0609	-0.0146	0.1405	0.1022	0.0173	5.5646e-13	0.7071	-1.8272e-13
53	-0.0371	-0.0290	0.0609	-0.0146	0.1405	0.1022	0.0173	5.5646e-13	0.7071	-1.8272e-13
54	0	-0.0091	-0.0096	0.2863	0.2431	-0.0196	-0.1192	-4.1151e-12	-2.4809e-12	-1.2670e-12
55	0	0	0	0	0	0	0	0	0	0
56	0	0	0	0	0	0	0	0	0	0
57	0	0	0	0	0	0	0	0	0	0
58	0	0	0	0	0	0	0	0	0	0
59	-0.0218	6.6814e-04	0	0	0.1571	0.0863	0.0645	-4.8941e-12	-1.0512e-12	-1.6195e-13
60	-0.0399	-0.0453	-0.0402	-0.0485	0.2431	-0.0944	0.0315	1.8759e-11	-4.8621e-12	-1.0652e-12
61	-0.0399	-0.0453	-0.0402	-0.0485	0.2431	-0.0944	0.0315	1.8759e-11	-4.8621e-12	-1.0652e-12
62	-0.0218	6.6814e-04	0	0	0.1571	0.0863	0.0645	-4.8941e-12	-1.0512e-12	-1.6195e-13

Figure 4.6: Figure illustre les valeurs des descripteurs d'une image.

Pour chaque image on calcule les descripteurs des points d'intérêts, donc on obtient une base d'image comme la figure le montre :



**Figure 4.7:** Figure illustre l'ensemble des fichiers MAT qui représente les descripteurs calculées à partir des images d'apprentissage et de test.

#### 4.4. Classification des descripteurs

Dans cette étape on applique KPPV et SVM pour la classification des descripteurs de chaque point d'intérêt, qui se trouve dans chaque fichier MAT généré par l'algorithme SIFT.

On obtient par l'application de ces algorithmes (KPPV, KNN) sur les fichiers MAT des images d'apprentissage, une base d'apprentissages qui nous aidera à établir une comparaison entre les points d'intérêts des images de test et les images d'apprentissage.

#### 4.5. La combinaison (Fusion)

Le principe de la combinaison de plusieurs classifieurs est le fait de ne pas connaître les résultats et d'estimer les résultats.

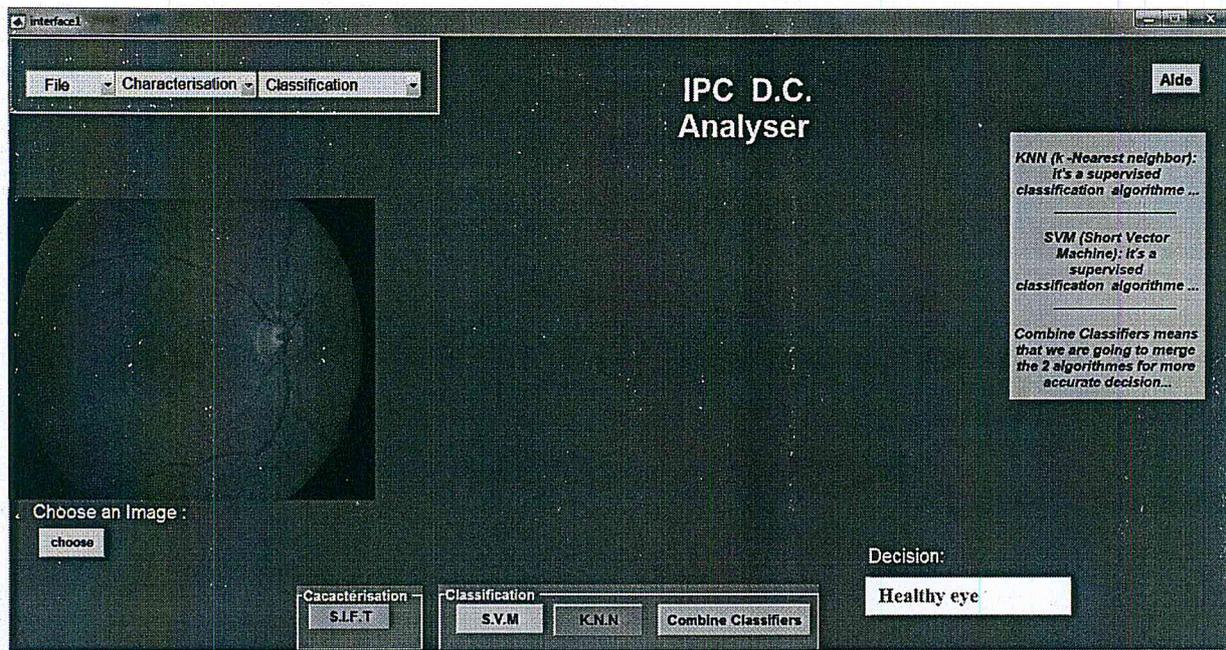
Nous avons utilisé la méthode BORDA pour la combinaison qui travaille avec les degrés d'appartenance de chaque image de test à toutes classes. Les degrés calculés par chaque classifieur sont enregistrés dans des matrices.

Puis on fait la somme des matrices de chaque classifieurs(maatrice1 + matrice2) pour aavoir une matrice somme. On prend le max de chaque ligne pour déduire la classe de chaque image test.

## 4.6. Les résultats obtenus

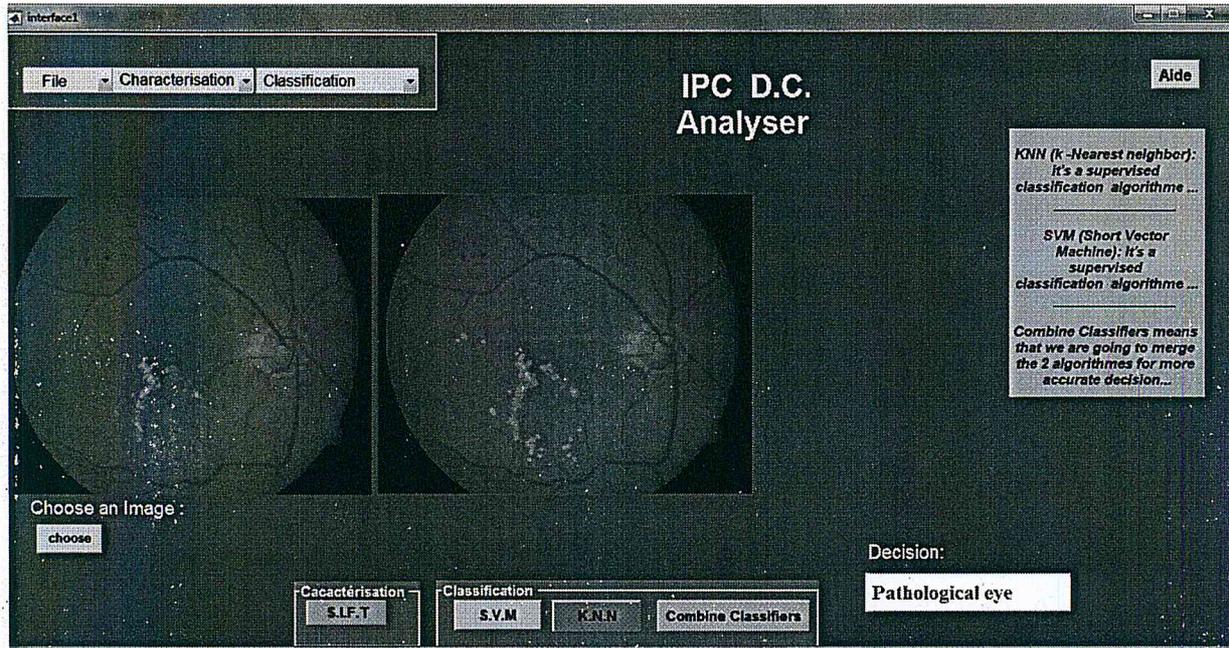
### 1. Cas Sain:

la résultat de notre application en cas sain :



## 2. Cas Pathologique :

la résultat de notre application en cas pathologique :

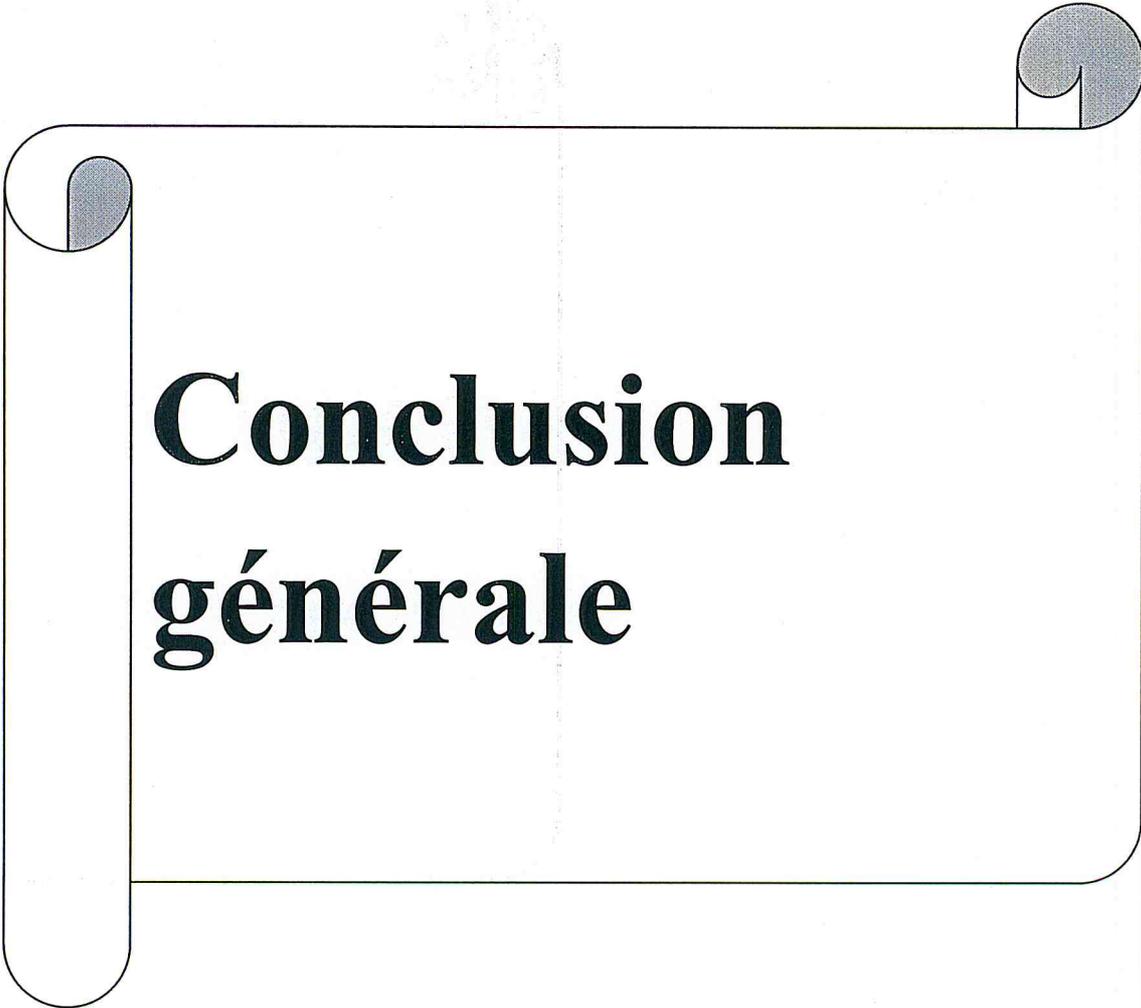


## 5. Conclusion

Nous avons présenté dans ce chapitre l'architecture de notre système de classification des images à base de caractéristiques locales.

Dans ce chapitre, nous avons présenté la détection des lésions sombres (les micros anévrysmes et les hémorragies) dans des images couleur, en utilisant un algorithme de l'extraction des caractéristiques SIFT et deux algorithmes pour la classification KPPV, SVM et un algorithme pour la fusion BORDA, pour avoir une résultat final soit cas sain ou bien pathologique.

Les résultats de la combinaison ne sont pas toujours meilleur et on a trouvé que le classifieur tout seul donne une meilleur résultat.

A decorative graphic of a scroll with a black outline and grey shading at the top corners, containing the text.

# **Conclusion générale**

### Conclusion générale

Nous avons présenté dans ce mémoire, une étude sur les images du fond d'œil. L'analyse des besoins des médecins nous a amenée à diriger nos efforts sur le traitement automatique des images rétinienne.

Pour qu'un outil soit bien accepté par les médecins, il est nécessaire de n'automatiser que les tâches pénibles et ne sont pas facilement réalisables.

Nous avons consacré notre étude sur la détection des lésions sombres (les micros anévrismes et les hémorragies) principales causes de la rétinopathie diabétique. Nous avons d'abord présenté quelques notions sur l'œil, les différentes maladies qui peuvent l'attaquer, les appareils d'acquisition, les différents clichés.

Nous avons validé notre travail sur des images couleur. Il a été testé sur des images pathologiques des images de la base de donnée 'Base MESSIDOR'.

Pour la détection des lésions sombres (les micros anévrismes et les hémorragies), l'étude est basée sur la méthode SIFT pour extraire les caractéristiques de ces lésions et SVM et KPPV pour la classification et un algorithme de combinaison (Fusion) des classifieurs BORDA.

De nombreux progrès restent à faire car il n'existe pas encore d'algorithme assez robuste permettant de détecter ces lésions sombres avec une grande précision.

Le taux de reconnaissance obtenu n'est pas très satisfaisant, lors de l'utilisation de la combinaison de plusieurs classifieurs.

comme dans tout logiciel, des améliorations restent toujours à apporter.

- [1]: Le corps humain : Etude, structure et fonction, Brooker de boeck, 2 édition 2001.
- [2]: The Bioinformatics Organisation: La perception des couleurs par l'oeil: chapitre 1. L'oeil.  
Website : <http://www.bioinformatics.org/oeil-couleur/dossier/anatomie.html>, visité : avril 2015.
- [3]: Salah Anissa, Medjaoui Asmae, Analyse des images rétiniennes : Application à la détection des lésions sombres, Université Abou Bakr Belkaid de Telemcen 25 juin 2013, page 74.
- [4]: Belhadi Somia, Analyse automatique des angiographies rétiniennes pour l'aide au diagnostic de la rétinopathie diabétique, Université Saad Dahleb Blida.
- [5]: Professeur Michel Mouillon, La rétinopathie diabétique, Faculté de Médecine de Grenoble, Juillet 2005, page 7.
- [6]: Information sur La rétinopathie diabétique, Révision AG 18/01/10 13:01, page 17.
- [7]: <http://www.tsi.enst.fr/Downloads/bio/Clinique%20de%20l'oeil.htm>, visité : avril 2015.
- [8]: Recalage non rigide d'images cérébrales 3D avec contrainte de conservation de la topologie mémoire docteur de l'université louis pasteur, 10 mars 2006, page 228.
- [9]: R. Anquetil, R. Babertéguyjm. Bernou, P. Labes, C. Belhomme. le réseau de transfert d'image interhospitalier d'aquitaine 1999.
- [10]: Field, M.J. 1996. Telemedicine: A Guide to Assessing Telecommunications in Health Care. Washington, D.C., National Academy Press.
- [11]: N.Bettiche Classification des images par combinaison de classifieur a base des caractéristiques locales.
- [12]: Berrani, & all, a. 2002, les approches de classifications.
- [13]: Chu, T.Q. 2005, juillet, classification automatiques des textes vietnamiens. Institut de la francophonie pour l'informatique.
- [14]: S.Craig D.Walts Toward memory-based reasoning, December 1986,  
<http://www.cs.columbia.edu/~waltz/Papers/Toward%20Memory-Based%20Reasoning-ACM%201986.pdf>, visité : avril 2015.
- [15]: E. Angelini, I. Bloch, Y. Gousseau, S. Ladjal, B. Pesquet-Popescu, M. Sigelle, F. Tupin, Méthodes Avancées de Traitement d'Images - Polycopié du cours SI343 – MATIM, Ecole Nationale Supérieure des Télécommunications. février 2007.

- [16]: Keller, J. M., 1999, A Fuzzy K-nearest neighbor algorithm, IEEE transaction on Systems, man, and cybernetics.
- [17]: Vladimir, V., 1992, le développement d'une théorie statistique de l'apprentissage.
- [18]: Classifieurs SVM et Réseaux de Neurones, <http://www.dspace.univ-tlemcen.dz/bitstream/112/322/11/ChapitreII.pdf> , visité : avril 2015.
- [19]: Lebart, L., Morineau, A., Piron, M., 2004, Statistique exploratoire multidimensionnelle, Dunod, Paris.
- [20]: David, G.L, 2002, local feature view clustering for 3D object recognition. IEEE conference on computer.
- [21]: Jean, Y.T., 2010, Classification et Reconnaissance des Formes, "Analyse et Synthèse de l'information".
- [22]: Hervé, L. B., 2009, Recherche d'information dans les. ERMITES
- [23]: Krystian, M., & Cordelia, S., 2005, A performance evaluation of local descriptors (Vol. vol. 27). IEEE translations on pattern analysis and machine intelligence.
- [24]: Liu, Y. D., Zhang, & lu S. G., 2004, region-based image retrieval with perceptual colors.
- [25]: Stricker, M., & M, O., 2009, Similarity of color images. In In SPIE Conference on Storage.
- [26]: Gevers, T., & Smeulder, W. M., 2004, content-based image retrieval: an overview, from the book emerging topics in computer vision.
- [27]: Julesz, B., 2002, textons, the elements of texture perception, and their interactions.
- [28]: Mikolajczyk, k., & Schmid, C., Oct 2005, A performance evaluation of local descriptors. Pattern analysis and machine intelligence, IEEE transaction .
- [29]: Canny, J, 1986, détecteur de contour de Canny, Vol. vol. 8, IEEE transformations on pattern analysis and machine intelligence.
- [30]: Lindeberg, T., 2001, feature détection with automatic scale selection, Vol. vol. 30, international journal of computer vision
- [31]: Matas, J. O., & Chum, M. U. 2002, le détecteur de régions d'intérêt MSER, British Machine Vision Conference.
- [32]: Lowe, D, sep 1999, Le détecteur SIFT, incluant une détection de régions d'intérêt circulaires Vol. vol. 60, International journal of Computer Vision.
- [33]: Haralick, R., 2004, Ridges and Valleys on Digital Images.
- [34]: Johannes, B., & Niko, S., 2007, comparing several implementations of two recently published feature detectors. Toulouse: proceedings of the international conference on intelligent and autonomous systems.

- [35]: Yan,C.,Nils,H., & Thorsten,T., 2009, Scale invariant feature transform with irregular orientation histogram binning. Halifax Canada , Proceedings of the International Conference on Image Analysis and Recognition.
- [36]: Paul, S., Saad, A., & Mubarak, S. 2007, A3-dimesional SIFT descriptor and its application to action recognition. dans proceedings of the 15th international conference on multimedia.
- [37]: David, G. L., 2002, local feature view clustering for 3D object recognition, IEEE conference on computer.
- [38]: Jeffrey, & David, L, 2001, shape indexing using approximate nearest-neighbor search in high-dimensional spaces. san jaun, Porto-Rico: proceedings of IEEE computer society conference on computer vision and pattern recognition.
- [39]: <http://www.adcis.net/en/Download-Third-Party/Messidor.html> , visité: juin 2015.
- [40] O. Kadri, L. H. Mouss, M. D. Mouss, A. Abdelhadi.Reconnaissance des Formes par SVM pour le Diagnostic du Système de Pasteurisation d'une Usine de Lait.Laboratoire d'Automatique et Productique Université de Batna,janvier 2013.
- [41]: <http://www.math.univ-toulouse.fr/~besse/Wikistat/pdf/st-m-app-svm.pdf>, visité : juin 2015.
- [42]:[http://www.csee.umbc.edu/~tinoosh/cmpe650/slides/K\\_Nearest\\_Neighbor\\_Algorithm.pdf](http://www.csee.umbc.edu/~tinoosh/cmpe650/slides/K_Nearest_Neighbor_Algorithm.pdf), visité : juin 2015.
- [43]: R. C. Gonzalez, Digital Image processing using Matlab, Pearson publication, 2005.