**MINISTERE DE L'ENSEIGNEMENT SUPERIEUR ET DE LA RECHERCHE SCIENTIFIQUE**
**UNIVERSITE MOULOUD MAMMERI, TIZI-OUZOU**

**FACULTE DE GENIE ELECTRIQUE ET D'INFORMATIQUE**
**DEPARTEMENT AUTOMATIQUE**

# MEMOIRE DE MAGISTER

en ***Automatique***

Option **Traitement d'Images et Reconnaissance de Formes**

Présenté par

**CHELLI Takfrinas**

Ingénieur UMMTO

# Classification Automatique Multimodale : application à l'identification de graines en temps réel

Mémoire soutenu le 06/01/2011 devant le jury d'examen composé de :

| | | |
|---|---|---|
| **DJENNOUNE Saïd** | Professeur à l'UMMTO | **Président** |
| **DIAF Moussa** | Professeur à l'UMMTO | **Rapporteur** |
| **HAMMOUCHE Kamal**, | M.C.A. à l U.M.M.T.O. | **Examinateur** |
| **MAIDI Ahmed**, | M.C.A. à l'U.M.M.T.O | **Examinateur** |
| **AHMED-OUAMAR Rachid** | M.C.A. à l'U.M.M.T.O | **Examinateur** |

# Avant-propos

Ce mémoire a été effectué au laboratoire « robotique et vision du département Automatique de l'UMTO.

Mes vifs remerciements vont tout d'abord à Monsieur DIAF Moussa, professeur à l'UMMTO pour m'avoir proposé le thème de ce mémoire et m'avoir dirigée, aidée et conseillée tout le long de notre travail.

Nous ne manquerons pas de remercier Monsieur DJENNOUNE Saïd, Professeur à l'UMMTO pour m'avoir fait l'honneur d'accepter de présider le jury de ce mémoire.

Nous exprimons notre reconnaissance à Monsieur HAMMOUCHE Kamal Maître de Conférences classe A à l'UMMTO pour avoir accepté de faire partie du jury d'examen de notre mémoire.

Nous tenons à remercier Monsieur AHMED-OUAMER Rachid Maître de Conférences classe A à l'UMMTO pour avoir accepté de faire partie du jury d'examen de notre mémoire.

Ainsi Monsieur MAÏDI Ahmed, Maître de Conférences classe A à l'UMMTO pour avoir accepté de faire partie du jury d'examen de notre mémoire.

Sommaire

**Introduction générale**.....01

**Chapitre 1 : La reconnaissance de forme et applications**.....04
1 Introduction.....05
2 Processus de reconnaissance de formes.....05
2.1 L'acquisition des images.....05
2.2 Les prétraitements.....08
2.3 Les traitements.....08
2.4 Les paramètres caractéristiques.....09
2.5 Réduction des paramètres.....11
2.6 La classification.....12
3 Application de la reconnaissance de formes.....13
3.1 Systèmes généraux.....14
3.2 Systèmes dédiés.....15
3.3 Les systèmes industriels.....16
12. Conclusion.....19

**Chapitre 2 : Combinaison de méthodes de décision**.....21

1. Introduction.....21
2. Les performances d'un système de reconnaissance de fromes.....22
2.1. La robustesse.....22
2.2. La fiabilité des décisions.....22
2.3. La modularité.....22
2.4. Type de méthde de décision.....22
3. La fusion de décision.....24
3.1. Méthode de combinaison parallèle.....25
3.2. Méthode de combinaison série.....26
3.3. Méthode de type classe.....26
3.4. Méthode de type rang.....28
3.5. Méthode de type mesure.....30
3.6. Méthode avec apprentissage.....32
4. Théorie de Dempster-Shafer.....39
4.1. Principe de la théorie de Dempster-Shafer.....39
4.2. règle de combinaison de Demster.....41
5. Analyse de méthode de combinaison de décision.....42
6. Conclusion.....44

**Chapitre3 Identification automatique de graines en temps réel.**.....46

1 Introduction.....46
2 Acquisition des images des graines.....47
2.1. Camera.....48
2.2. Carte d'acquisition.....48
2.3. Communication avec la caméra.....49
3 Le prétraitement et traitement.....49
3.1. La segmentation des images des graines.....51
3.2 L'extraction des contours des graines.....52
3.4 Reconnaissance à partir des paramètres de forme.....53
4.1 Paramètres de forme.....53
4.2 Réductions des paramètres en utilisant l'ACP.....57
4.3 La classification.....58
4.4 La reconnaissance de nouvelles graines.....59
5 Reconnaissance à partir des paramètres de couleur.....59
5.1 Le choix des paramètres.....61
5.2 Réductions des paramètres en utilisant l'ACP.....63
5.3 La classification.....64
5.4 La reconnaissance des graines.....64
6 Reconnaissance à partir des paramètres de texture.....65
6.1 Calcul des paramètres.....66
6.2 Réductions des paramètres en utilisant l'ACP.....68
6.3 La classification.....69
6.4 La reconnaissance de nouvelles graines.....69
7. La fusion à l'aid de la théorie de Dempster-Shafer.....70
7.1 Définition des espaces de discernement.....70
7.2. La modélisation de la fonction de croyance.....70
7.3. La décision.....72
7.4. Les résultats de la fusion.....72
8. Conclusion.....73

**Concussion générale** .....75

# *Introduction Générale*

La filière céréales occupe une place très importante dans le système agroalimentaire algérien. En effet, l'industrie de transformation des graines occupe également la première place dans le secteur agroalimentaire en raison de l'importance de ses capacités de trituration, mais aussi de son réseau de distribution qui mobilise plus de 2000 dépôts de vente et plus de 5000 unités de transport. La progression rapide de la consommation des farines, semoules et aliment de bétail a engendré des transformations structurelles importantes de l'ensemble des segments de la filière ainsi que son processus de régulation. Cependant, cette dernière est caractérisée par la rigidité de la demande en produits transformés et par la stagnation de la production céréalière nationale. Pour répondre aux besoins des industriels, nous mettons en application dans ce mémoire un système reconnaissance de forme rapide et fiable pour l'identification automatique des grains. En effet, la reconnaissance de forme peut être définie comme un ensemble de techniques et méthodes, qui visent à automatiser les caractères de la perception. Plus exactement la reconnaissance de forme permet d'identifier des objets à partir d'un certains nombre de d'observations extraites automatiquement de l'image ou du signal représentant ces objets. De nos jours, elle est étendue à divers domaines d'applications industrielles, médicales, spatiales etc., et selon l'application, deux principales approches peuvent être distinguées à savoir l'approche structurelle ou syntaxique basée sur l'extraction de primitives et l'approche statistique basée sur l'extraction de paramètres.

Dans ce mémoire l'application à laquelle nous nous intéressons et qui consiste à reconnaître quatre types de graines (avoine, blé, lentille et orge), dont les images sont acquises par caméra, s'inscrit dans la seconde approche. Le processus de l'identification, dans ce cas, est constitué des

trois principales phases suivantes : l'acquisition des images des graines, le prétraitement, l'élimination des bruits et amélioration des contrastes, l'extraction, la sélection et la normalisation des paramètres pertinents, l'apprentissage ou classification automatique pour caractériser les classes de formes en présence et l'assignation des formes à ces classes ou reconnaissance proprement dite.

En fonction de la forme, de la couleur et de la texture de l'objet à reconnaître, différentes techniques peuvent être utilisées. Dans ce présents travail, après avoir appliqué chacune des ces trois méthodes pour identifier des graines de blé, d'orge, d'avoine et de lentilles, nous avons constaté que certaines graines non correctement identifiées par l'une des méthodes, le sont correctement par les autres et vice-versa. Dans le but d'élever au maximum le taux de reconnaissance ou d'éviter la confusion entre certaines graines de différentes espèces, nous avons été d'abord amenés à combiner ces trois méthodes et ensuite à les fusionner en unissant les forces de chacune d'elles et pallier, ainsi, leurs faiblesses. Parmi les différentes méthodes permettant de fusionner les méthodes de classification la théorie de l'évidence ou théorie de Dempster-Shafer) est, de loin, celle qui a donné lieu à plusieurs travaux. Elle a la capacité d'exploiter les réponses des méthodes à combiner en prenant en compte (ou non) le comportement de chacune d'elles. Son efficacité a été prouvée par plusieurs auteurs par rapport aux approches usuellement utilisées.

Ainsi Dans ce mémoire, le premier chapitre est consacré à l'introduction de la reconnaissance de formes. C'est ainsi que les étapes composant un système de reconnaissance de formes, à savoir l'acquisition des images, la classification automatique et la décision sont présentées. Pour terminer ce chapitre, quelques applications typiques de la reconnaissance de formes sont décrites.

Dans le deuxième chapitre, ils 'agit de la fusion ou combinaison de méthodes de décision. Les principales méthodes de fusion sont rappelées ainsi que

leurs différentes architectures. Nous avons, particulièrement, insisté sur la méthode de Dempster-Shafer avant de procéder à l'analyse des performances des performances des méthodes de combinaison.

Le troisième et dernier chapitre est consacré à l'application sur la reconnaissance automatique de quatre types de graines. L'aspect pratique de cette étude a été mis en valeur en présent le matériel utilisé et les résultats des différents traitements tels que le filtrage, la binarisation, la classification etc. Ensuite, Après l'analyse des résultats obtenus à partir de trois méthodes de reconnaissance de formes basées sur des paramètres de forme, de couleur et de texture, nous avons procédé à leur fusion en vue d'améliorer le taux de reconnaissance.

Nous concluons sur les points importants du document, notamment sur l'approche de la décision proposée et les résultats obtenus. Nous évoquons les perspectives de ce travail et les voies de recherche qui semblent prometteuses et pour améliorer l'approche de fusion.

# Chapitre 1

## *Reconnaissance de formes et applications*

### 1. Introduction

La reconnaissance de formes peut être définie comme un ensemble de techniques et méthodes permettant d'identifier des objets à partir d'un certains nombre d'observations extraites automatiquement de l'image ou du signal représentant ces objets. De nos jours, elle est étendue à divers domaines d'applications industrielles, médicales, spatiales etc., et selon l'application, deux principales approches peuvent être distinguées à savoir l'approche structurelle ou syntaxique basée sur l'extraction de primitives et l'approche basée sur l'extraction de paramètres caractéristiques [1]. Dans ce chapitre nous présentons les généralités sur

la reconnaissance de formes. Les étapes qui interviennent dans ce processus sont présentées en section 2. Différents domaines et applications spécifiques font l'objet de la section 3.

## 2. Processus de reconnaissance de formes

La plupart des systèmes de reconnaissance des formes peuvent être séparés en modules distincts : acquisition, prétraitement, traitement, extraction des paramètres et classification (fig.1).

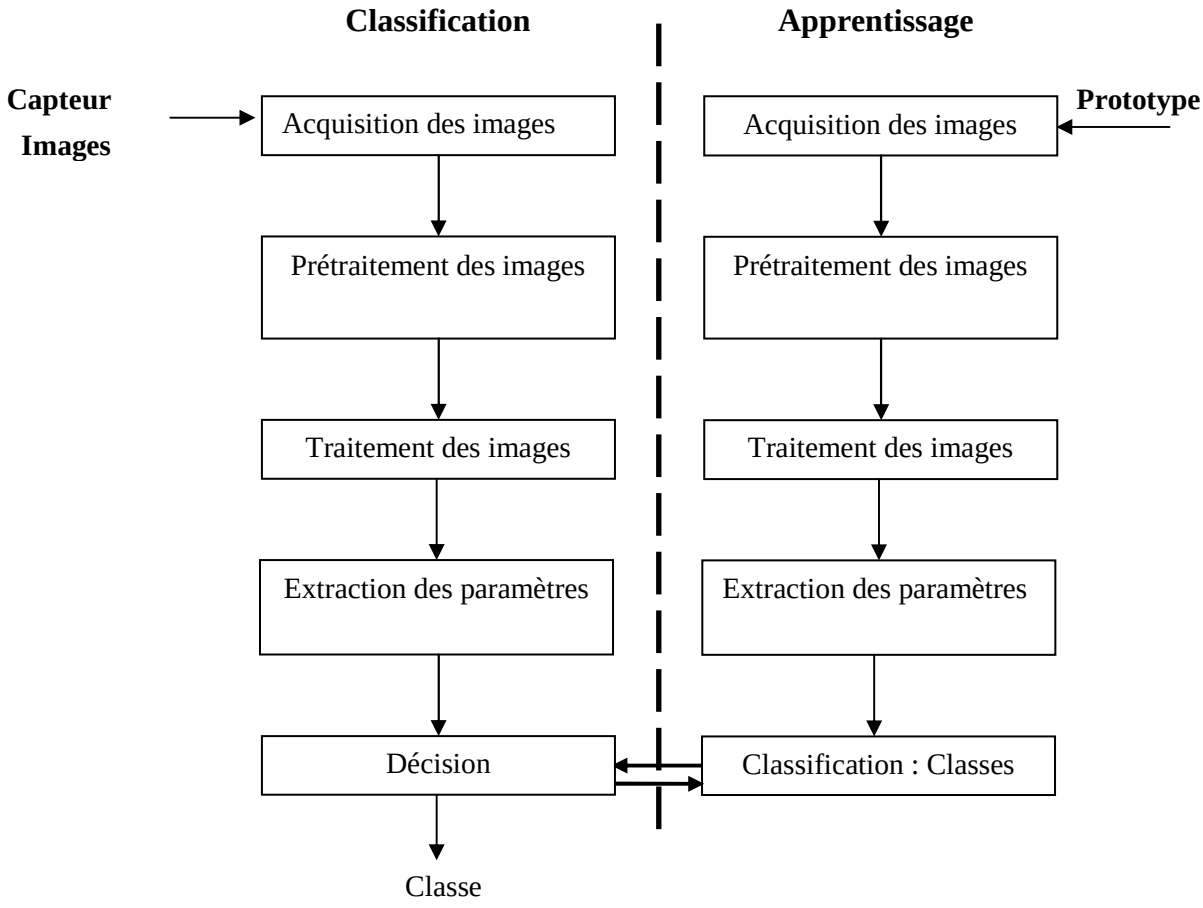


Fig.1. Etapes d'un processus de reconnaissance de formes

### 2.1. Acquisition des images

La phase d'acquisition de l'image est primordiale dans un système de vision. De sa qualité, dépendront la qualité et la robustesse du traitement

ultérieur. Quel que soit le matériel utilisé, l'un des facteurs influant lors de cette opération est sans soute l'éclairage. Plus il est optimisé, plus l'analyse est facile. Un éclairage mal choisi peut causer beaucoup de dégradations sur l'image tels que les reflets, les interférences, les ombres etc. et il dépend essentiellement de la source lumineuse en termes de longueur d'onde, de direction, de distribution spatiale et des surfaces de l'objet et de celle sur laquelle est déposé cet objet en termes de structure, de transparence, de couleur, etc., et enfin des caractéristiques de la caméra en termes de qualité de l'optique, de l'ouverture, de sensibilité du capteur, de gain, de vitesse d'obturation etc.

- *L'éclairage*

Pour un éclairage correct, celui-ci doit être homogène sur tout le champ de vision et pour la luminance ainsi que la chrominance, elles doivent rester stables au cours du temps. Différentes sources lumineuses pouvant être utilisées existent en grand nombre. On peut citer notamment :

- L'éclairage incandescent qui est le mode d'éclairage le plus économique mais dont les inconvénients viennent de la chaleur dégagée et du vieillissement. La température de couleur change également avec la tension d'alimentation,
- L'éclairage fluorescent, facile à mettre en œuvre et souvent utilisé pour les éclairages diffus. Il ne génère que peu de rayonnement infrarouge, donc peu de chaleur. Il est disponible pour plusieurs températures de couleur (blanc, lumière du jour,…). Le champ est large et homogène,
- L'éclairage halogène dont l'intensité lumineuse est quasiment constante. Les lampes halogène ne sont généralement pas utilisées comme éclairage direct, mais plutôt comme sources lumineuses pour des fibres optiques,
- Les lampes à arc, disponibles dans plusieurs couleurs,
- Les lampes à décharge à vapeur de mercure, sodium etc. qui fournissent des lumières composées de radiations monochromatiques.

Elles ont pour avantage des densités de radiation très élevées et une luminance constante dans le temps,

- Les diodes électroluminescentes qui réagissent presque sans inertie pour contrôler l'intensité lumineuse sur une large gamme d'éclairement. Elles peuvent donc être utilisées pour des éclairages stroboscopiques. Elles sont monochromatiques, ce qui les rend utiles dans les applications où les aberrations chromatiques de la caméra sont importantes. De plus, elles sont bon marché, fiables et de faible encombrement. Elles sont souvent arrangées en matrices ou en anneaux ou associées à des fibres optiques,
- L'éclairage laser qui est une lumière monochromatique cohérente obtenue le plus souvent à l'aide d'un laser hélium-néon de faible puissance. Réalisant un éclairage ponctuel, il est associé à un système de balayage (prisme tournant, membrane vibrante, etc.) et sert surtout au contrôle dimensionnel. Les lasers sont maintenant souvent remplacés par des modules utilisant des diodes laser (diode laser associée à un système optique et un système électronique), de petite taille et qui peuvent être utilisés dans de petits espaces,
- Les fibres optiques qui fournissent des éclairages très localisés et permettent d'ajuster précisément la distribution angulaire de l'intensité lumineuse aux besoins. Ils permettent aussi d'éclairer des zones d'accès difficile. Le seul inconvénient de ces sources est la perte d'environ 40% de l'intensité par des effets de diffusion et de réflexion,
- L'éclairage stroboscopique utilisé pour les scènes à mouvements rapides. Il délivre une énergie lumineuse importante pendant un temps très bref (5 à 500 µs) avec un large spectre,
- L'éclairage par flash qui est semblable à l'éclairage stroboscopique avec des puissances plus élevées. L'inconvénient des flashs est le temps relativement long nécessaire pour les recharger. Ils permettent d'obtenir une profondeur de champ importante.

L'éclairage qui nécessite de définir, avant tout, le champ de vision; le niveau de réflectivité de l'objet et la géométrie de la surface en arrière plan

est effectué selon différentes directions par rapport à l'objet à éclairer. Il peut être effectué directement, par l'arrière, indirectement ou de manière oblique. Ainsi, l'éclairage direct est utilisé lorsque l'on souhaite analyser la surface de l'objet (couleur texture, présence d'étiquette etc.). L'éclairage par l'arrière (ombres chinoises) pour obtenir les meilleurs contrastes pour les produits translucides ou lorsque seule la silhouette de l'objet est importante. Un éclairage indirect est réalisé à l'aide d'un miroir semi-transparent tel que la fraction de la lumière réfléchie directement vers la caméra forme l'image. Ainsi, les surfaces perpendiculaires à l'axe optique sont claires, les autres sombres. Les objets sont donc généralement sombres sur un fond clair. Oblique ou rasante, la lumière diffusée est la seule à être captée par la caméra. Les objets apparaissent clairs sur un fond sombre. L'inconvénient est la présence de reflets et d'ombres. Cet éclairage est utile pour visualiser des rayures ou pour observer les objets translucides et donne un contraste important pour les structures internes et les reliefs de surface.

## 2.2 Les prétraitements

L'étape de prétraitement a pour but de faciliter la segmentation en renforçant la ressemblance entre pixels appartenant à une même région ou en accentuant la dissemblance entre les pixels appartenant à des régions différentes. Les images comportent généralement une grande quantité de données. Pour éviter des temps de traitement trop élevés, on cherche donc à leur appliquer des opérateurs locaux, qui ne font appel pour le calcul, qu'à un nombre limité de pixels, situés dans un proche voisinage du pixel courant. Il existe beaucoup de méthodes de prétraitement comme celles qui modifient l'histogramme [2], celles qui réduisent le bruit [3] et celles qui rehaussent le contraste [4]. Ces méthodes peuvent être utilisées si la segmentation est basée sur l'intensité des pixels ou avec tout attribut numérique calculable en chaque pixel.

## 2.3 Les traitements

Pour travailler sur la partie de l'image correspondant à l'objet, deux approches existent. La première cherche à isoler l'objet du fond. Son

principe est de créer un masque binaire dont la partie vraie correspond à l'objet et l'autre partie, au fond. Ceci se fait généralement par une méthode de seuillage. On cherche tout d'abord un canal, formant une image monochrome dans lequel l'objet est contrasté par rapport au fond. On recherche ensuite une valeur de seuil qui permette de séparer les pixels appartenant au fond de ceux présents dans la zone d'intérêt. On obtient ainsi une image binarisée codée sur deux niveaux associés respectivement au fond et à la région d'intérêt. De nombreuses méthodes permettent de déterminer de façon manuelle ou automatique un seuil approprié. Du fait du grand nombre d'images à analyser, seule une méthode automatique de seuillage est envisageable. L'autre approche s'intéresse aux limites de la zone d'intérêt dans l'image. La plupart des algorithmes de cette approche sont locaux, c'est à dire fonctionnent au niveau d'un voisinage. Le résultat est, en général, difficile à exploiter sauf pour des images très contrastées. Les contours extraits sont la plupart du temps morcelés et peu précis et il faut utiliser des techniques de reconstruction de contours. Ces techniques purement locales sont en général trop limitées pour traiter des images bruitées et complexes. D'autres méthodes de détection de contours plus sophistiquées existent telles que les contours actif [5], les filtres à dérivé non entière [6].

## 2.4 Paramètres caractéristiques

L'image constitue une information graphique qui nécessite une grande capacité mémoire et la manipulation des pixels ou les traitements s'y afférant prennent beaucoup de temps. En plus de des informations superflues liées à la prise de vue, à l'éclairage, aux moyens matériels utilisés à l'environnement et aux différentes autres conditions, la reconnaissance automatique ne peut s'effectuer sur cette image de façon brute même si elle est prétraitée. L'opération de *pattern-matching* entre images ne peut être utilisé. La caractérisation d'une image par un certain nombre de paramètres pertinents présente un certains nombre d'avantages comme la réduction de la capacité mémoire et de temps machine, en plus de l'évitement de certains problèmes liés à la variabilité

en termes des taille, de couleur ou autre. De plus, à partir de ces paramètres, plusieurs concepts mathématiques peuvent être utilisés conduisant ainsi à la reconnaissance. Les paramètres descripteurs d'images se résument généralement, à ceux de la forme, de couleur et de texture.

Les paramètres qui peuvent décrire la forme d'un objet sont très nombreux. Ces paramètres peuvent aller de la simple information telle que la surface de l'objet ou son périmètre jusqu'au calcul d'autres paramètres plus robustes aux transformations géométriques comme la translation, la rotation et le changement d'échelle. Ainsi, deux catégories de paramètres basés régions et basés frontières peuvent être utilisés. Les premiers font classiquement référence aux moments invariants de Hu [7] et sont utilisés pour caractériser l'intégralité de la forme d'une région. Cependant, il est difficile de relier les valeurs des moments de grand ordre aux caractéristiques des formes et les traits (ou l'information locale) ne peuvent pas être détectés grâce aux moments. La seconde approche porte sur une caractérisation des contours de la forme [8]. Ces méthodes sont dépendantes du contour extrait à partir de l'image. Comme nous l'avons mentionné précédemment, les méthodes d'extraction de contours sont nombreuses et leur utilisation dépend de la complexité des objets, de la qualité de l'image etc.

Les paramètres de couleur sont aussi largement utilisés en reconnaissance de formes. Les recherches se sont portées sur le choix de l'espace colorimétrique. Le premier espace colorimétrique utilisé pour la représentation sur un moniteur est l'espace RVB. Il reste utilisé dans le cadre d'études de recherche d'images par le contenu [9]. Cependant il est sensible aux changements d'illumination et d'autres espaces ont été développés. Ainsi l'espace TSI (HSV en Anglais) sépare l'information relative à la teinte, la saturation et à l'intensité. La teinte représente longueur d'onde de la lumière réfléchie, ou transmise par un objet. La saturation indique la pureté ou intensité de la couleur. Enfin, l'intensité désigne la variation d'intensité lumineuse d'une couleur. L'espace TSI est communément utilisé [10]. En se référant au système visuel humain,

l'espace CIELab a été conçu pour être perceptuellement uniforme. Dans cet espace, les couleurs sont définies par trois valeurs : Luminosité (luminance codée en pourcentage, a et b correspondent à l'information colorée (chrominance) où la couleur est définie à partir d'un mélange de vert à magenta (a) et un mélange de bleu à jaune (b). Notons qu'il est possible de passer d'un espace de représentation à un autre par des fonctions de transfert.

Quant à la texture, elle a plusieurs définitions. La notion de texture est utilisée pour traduire un aspect homogène de la surface des niveaux de gris d'un objet sur une image. Dans [11], l'auteur présente la texture comme une structure disposant de certaines propriétés spatiales homogènes et invariantes par translation. Dans [12], l'auteur considère la texture comme une structure spatiale constituée de l'organisation de primitives ayant chacune un aspect aléatoire, donc une structure hiérarchique à deux niveaux. La prise en compte de ce type de caractéristiques pour représenter globalement ou partiellement une image est courante et discriminante dans de nombreux cas.

## 2.5 Réduction des paramètres

Certains paramètres relevés dans l'image n'apportant pas beaucoup informations sont à éliminer. Pour ce faire, il existe plusieurs méthodes qui sélectionnent les paramètres pertinents d'une manière automatique. Parmi ces méthodes nous citons la méthode de Selvestere [13] et l'Analyse en Composantes Principales (ACP). Dans ce travail, nous nous intéresserons seulement à cette dernière. En effet, l'ACP est une méthode particulièrement efficace pour explorer la structure d'ensembles de données. Elle a la capacité de résumer les données sur un espace de dimension réduite tenant compte de leur multi-dimensionnalité. Elle construit de nouvelles variables artificielles qui sont des combinaisons linéaires des variables d'origine. Elle permet de visualiser les relations entre variables ainsi que l'existence éventuelle de groupes d'individus. L'objectif de cette technique est donc de rechercher, par combinaison linéaire, les axes principaux de l'ensemble des données, c'est-à-dire, les

axes suivant lesquels la variabilité est la plus grande. Ainsi, il est possible de transformer un vecteur de $n$ caractéristiques en projetant le point correspondant à ce vecteur sur les $m$ axes principaux ($m < n$) ayant les plus fortes valeurs propres. Le vecteur obtenu après projection est donc de dimension $m$ et est composé de caractéristiques décorrélées. Le principe de l'ACP est donc de traiter des tableaux de variables quantitatives à $m$ caractères de $n$ individus. Ainsi, elle élimine la redondance d'information due aux liaisons qui peuvent exister entre plusieurs variables. Les $n$ individus peuvent être repérés dans un espace à $m$ dimensions. L'ACP étant une opération bien connue, nous proposons les étapes de calculs qui la réalisent (fig.2)

- Centrer et réduire les données,
- Calculer la matrice variance covariance à partir du tableau de données. Cette matrice sert pour le calcul des valeurs et des vecteurs propres,
- Calcul des valeurs propres et des vecteurs propres,
- Ordonner les valeurs propres par ordre décroissant pour sélectionner les composantes les plus significatives,
- Calculer la matrice des composantes principales.

Fig.2 Etapes de réalisation de l'ACP

### 2.6 Classification

Objectif de la classification est d'identifier les classes auxquelles appartiennent des objets à partir de leurs caractéristiques fournies par l'extracteur de caractéristiques. Dans presque tous les domaines d'application de la reconnaissance de formes, un certain nombre d'algorithmes de classification sont disponibles. Ces algorithmes sont basés sur différents principes. Nous distinguons deux grands groupes de méthodes, notamment, celles basées sur un vecteur de caractéristiques numériques (la classification statistique) et les méthodes structurelles (la classification structurelles) pour lesquelles les formes sont essentiellement caractérisées par des propriétés grammaticales. En outre, chaque groupe inclut de nombreux algorithmes basés sur une variété de méthodologies [14]. Dans notre travail, nous intéressons uniquement aux méthodes

statistiques. Si la densité de probabilité de chaque classe est connue, donc la théorie de Bayes et souvent appliquée, sinon, les méthodes de classification sont séparées en deux familles (supervisée et non supervisée). Si nous disposons des connaissances apriori sur les classes aux quelles appartiennent les objets, alors nous parlons d'une classification supervisée. Contrairement, la classification automatique est caractérisée par l'absence de ces connaissances. Dans cette dernière, généralement le nombre de classes est connu. De plus nous pouvons distinguer les méthodes paramétrique et non paramétrique. Les méthodes paramétriques supposent la connaissance des lois de probabilité régissant les observations dans les classes. La connaissance de ces lois se porte sur leur expression mathématique ainsi que sur leurs paramètres réels ou estimés. Les méthodes non paramétriques ne disposent pas de la forme des lois de probabilité régissant les observations dans les classes.

## 3. Application de la reconnaissance de formes

Les applications de la reconnaissance de formes sont apparues au cours de ces vingt dernières années, en même temps que la formidable augmentation de la puissance des ordinateurs. Cependant, la reconnaissance de formes en tant que discipline scientifique est antérieure aux années 60, avec des travaux théoriques principalement dans le domaine des statistiques [15]. Seul l'avènement de l'informatique a permis d'appliquer ces techniques aux traitements de volumes de données conséquents. Dans les paragraphes suivants nous présenterons quelles applications de la reconnaissance de formes réparties en trois groupes [16].

Dans le premier groupe, nous trouvons des systèmes qui cherchent à construire un système de reconnaissance de formes le plus général possible, c'est-à-dire, au sens large de la définition de la reconnaissance de formes. L'intérêt de ces systèmes vient du fait qu'ils mettent en œuvre

des concepts généraux. Cependant ces systèmes ne sont pas capables de résoudre des problèmes réalistes en termes d'applications.

Le deuxième groupe est constitué des systèmes ayant pour objectif de résoudre des problèmes de reconnaissance difficiles et économiquement intéressants. Nous trouvons en particulier l'analyse d'images aériennes, la biométrie, la biologie, l'astronomie, la médecine etc.

Dans le dernier groupe, on classe les systèmes de reconnaissance de forme industriels. Les systèmes industriels doivent répondre à un cahier des charges très précis et exécuter une tâche spécifiée avec des performances de vitesse et de coût du matériel. Ces systèmes souffrent alors d'un manque de généralisation.

### 3.1. Systèmes généraux

Parmi les premiers systèmes de reconnaissance de formes, on retrouve l'analyse de scènes [17], où il arrive à reconnaitre certain nombre d'objets dans une image à plusieurs niveaux de gris. Comme exemple, sur un bureau; il s'agit de reconnaitre une lampe, un rayon à livres, une tasse, un téléphone, un crayon etc. Lors de l'identification, le système parcourt plusieurs fois un cycle de segmentation, jusqu'à ce qu'un nombre suffisant d'objets soit trouvé. La segmentation cherche tous les contours dans l'image, en fonction d'un seuil de gradient qui varie à chaque passe. Les contours sont découpés en segments de droites et arcs d'ellipses. L'ensemble des segments constitue la description de l'image. Les segments de l'image sont comparés aux caractéristiques d'apprentissage pour construire des décisions. Comme autre système apparu presque à la même période que le précédent, il utilise une approche différente. Son principe est de faire une segmentation de l'image en régions homogènes. Chaque région est définie comme un ensemble connexe de pixels satisfaisant une certaine condition. Dans le cas d'une image à plusieurs niveaux de gris, il peut s'agir de pixels ayant le même niveau de gris ou appartenant à une plage de valeurs. Dans [18], le système étudié suit le paradigme de l'identification avec analyse de régions. Il a été expérimenté avec des images en couleur d'un paysage,

d'un compresseur d'air et d'une scène de bureau. La segmentation produit la partition de l'image en régions. L'interprétation doit combiner des régions voisines appartenant à un même objet (fusion de régions) et étiqueter chaque région avec un nom d'objet. La difficulté du problème vient du fait que la segmentation initiale produit un très grand nombre de régions et que la seule donnée de la couleur ne permet pas d'identifier un objet. Ce système exploite alors des contraintes structurelles dans une image en utilisant un algorithme de propagation de contraintes. Initialement toutes les régions reçoivent toutes les étiquettes, en faisant des itérations les contraintes ne laissent qu'une seule étiquette dans une région. Dans le test de la scène de bureau, les objets à identifiés sont la porte, le mur, le sol, une peinture, une plinthe, ou une poignée de porte. Les contrainte prises en compte sont "à l'intérieur de ", " au dessus de" " à côté de". Les résultats sont obtenu s au bout de 4 itérations.

### 3.2. Systèmes dédiés

Les systèmes dédiés sont conçus juste pour des applications des domaines précis comme la médicine, l'identification de personne ou la biométrie, le diagnostique, etc. L'une des applications la plus rencontrée est la reconnaissance des caractères, application classique de la reconnaissance de forme [19]. Elle vise à transformer un texte manuscrit ou typographié, sur tout type de support, vers un texte numérique éditable par un traitement de texte. Le document, sous forme papier par exemple, est préalablement numérisé par un scanner pour en obtenir une représentation sous la forme d'une image. On essaie ensuite d'extraire chacune des lettres présentes sur l'image et d'en déterminer un équivalent informatique (fig.3). Dans les applications actuelles les plus sophistiquées, on enrichit le système d'informations supplémentaires sur le texte à reconnaître en utilisant des grammaires contextuelles et autres règles linguistiques [20]. Aujourd'hui, ce type d'applications est couramment utilisé à des fins d'archivage, d'indexation, de tri automatique du courrier, de traitement des chèques (fig.4), etc.

Fig.3 Reconnaissance de caractères

Fig.4 Traitement des chèques

### 3.3. Systèmes industriels

Parmi les systèmes de type industriel on trouve les systèmes effectuant une analyse de connexité dans les images binaire. Un objet est alors caractérisé par les propriétés de sa projection 2D (surface apparente, périmètre, nombre de trous, moments d'inertie, etc.). Ce type de système a un intérêt commercial considérable car il combine un grand potentiel d'applications industrielles et des possibilités d'implantation rapide à des prix compétitifs. Les problèmes traités sont très simples que dans le cas des problèmes des paragraphes précédents, mais ils ont l'avantage de nécessiter la mise en œuvre des structures informatiques bien maitrisables, aboutissant à des systèmes opérationnels. Ci-dessous nous

présenterons quelques systèmes de conceptions différentes et offrent des possibilités d'applications différentes. Il est donc intéressant de noter qu'qu'aucun de ces systèmes n'est plus général que l'autres. On peut facilement trouver des problèmes que seulement un de ces systèmes saurait résoudre. Le système décrit dans [21] est l'un des premiers systèmes industriel chez General Motors. Il a été conçu pour l'identification d'un ou plusieurs objets dans une image à plusieurs niveaux de gris, Son fonctionnement es le suivant : à l'image initiale (256x256, 64 niveaux de gris) est appliqué un opérateur de détection de contours (operateur de Hueckel). Ensuite les points de contour sont chainés pour former les segments et chaque segment est découpé en des segments de droite ou arcs de cercle formant ainsi une séquence. Les séquences sont comparées aux modèles d'objets avec différentes rotations. La structure simple des modèles et leur nombre réduit rendent l'analyse ascendante possible pour un système industriel, mais elle implique beaucoup de calculs non utilisés. Ainsi le temps de d'exécution est très long. La localisation et l'identification des objets avec les séquences de contours donnent des résultats imprécis et les algorithmes deviennent très combinatoires dans le cas des objets complexes.

Jusqu'à présent, tous les systèmes cités utilisent des paramètres structurels, que ce soit avec des paramètres à base de contour ou à base de région et classification est hiérarchique (ascendante ou descendante). Une autre approche utilise des paramètres de type numérique, et pour la classification, ils utilisent des méthodes telles que le k plus proches voisins [22], la décision de Bayes [23], l'algorithme EM [25], etc.
Le système décrit dans [26], permet d'identifier des objets qui défilent sur un tapi roulant. Ces objets sont des pièces mécaniques. L'objectif de ce système est les bonnes pièces et les mauvaises. Pour l'identification, il calcule des paramètres à base des images binaires des pièces et leurs contours dont les moments invariants, la surface, le périmètre, le nombre de trous, les axes principaux, etc. Ce système dispose d'une base d'apprentissage étiquetée et la décision est prise par le minimum des

distances calculées entre l'objet à identifier et les objets de la base d'apprentissage.

Comme exemple en détection automatique de défauts, des matériaux en feuille et en rouleaux qui doivent être exempts de défauts tels que taches, griffes, trous, plis, reliefs et autres hétérogénéités défilent sous une caméra. Ce type d'application se rencontre dans l'industrie papetière, dans la sidérurgie, la fabrication du verre plat, l'industrie textile, etc. Dans les cas les plus simples, il s'agit de surfaces parfaitement lisses et uniformes où il suffit de détecter des changements de couleur ponctuels. Dans d'autres, on est confronté à des textures périodiques ou non, et il est plus délicat de séparer les variations normales et accidentelles. Ces systèmes sont usuellement appelés systèmes d'inspection de qualité comme dans le cas de contrôle la qualité des tissus à base des modèles des textures [27] (fig.5).

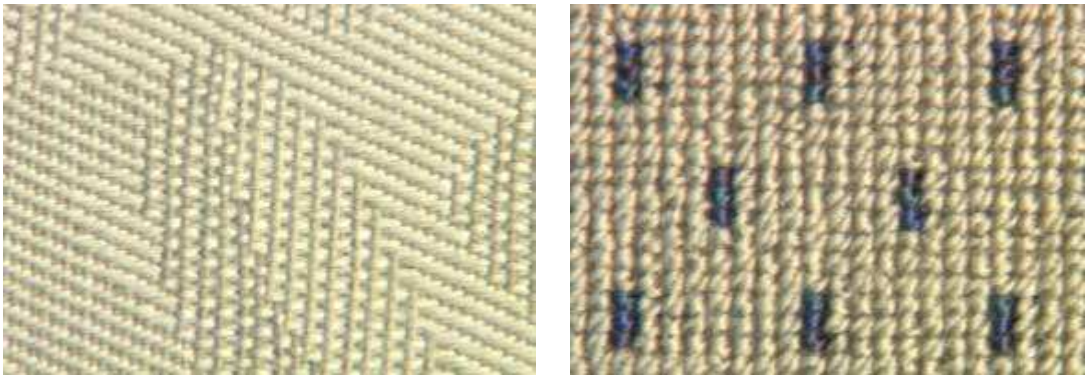

Fig.5 La texture des tissus à contrôler.

Dans d'autres cas, le matériau défilant peut présenter un motif particulier dont on veut vérifier la conformité. C'est le cas, par exemple, en imprimerie où l'on cherche à contrôler la qualité des couleurs et l'opacité des encres, l'absence de bavures et autres défauts d'encrage, ou le désalignement des matrices cyan, magenta, jaune et noire et plus généralement la conformité du motif ou du texte imprimé (fig.6).

Fig.6 Inspection des couleurs.

Il existe d'autres systèmes industriels, dont leur principes est plus ou moins ressemblent aux systèmes des paragraphes précédents. Ils se distinguent uniquement dans leurs missions et leurs environnements.

## 4. Conclusion

Dans ce chapitre nous avons présenté la problématique de la reconnaissance de formes, en les différentes techniques d'éclaires et leurs utilisations, et nous présenté un peu de géométrie d'optique. Les capteurs optiques et leurs caractéristiques, qui se distinguent par leurs les performances et leurs prix ont été présentés. De plus nous avons cité les raison du filtrage, et les différentes techniques de segmentations d'images. Le problème de l'extraction de paramètres et les méthodes de réduction de paramètres ont été présentés. La classification est l'étape la plus importante dans un système de reconnaissance de formes, pour cela, nous avons proposé une catégorisation de méthodes de classification. De plus les méthodes d'apprentissage ont été aussi présentées. Les applications décrites dans ce présent chapitre, que nous avons classé en trois groupes, ont tous des fissures dans la généralité, car ils sont basés sur un seul type de caractéristique, ce que rend l'identification est meilleure pour certains objets et chaotique pour d'autres objets. L'apprentissage est un vrai problème pour les systèmes d'ordre généraux. Avec l'augmentation de nombre d'objets à identifier, l'espace d'apprentissage augment exponentiellement, impliquant des performances moins. Contrairement aux systèmes industriels où le nombre de classes est limité et un apprentissage expertisé, on obtient des performances meilleures. La problématique du temps réel est toutefois souvent posé et

cela dépend se la complexité des objets à reconnaître et du matériel utilisé.

# Chapitre 2

## *Combinaison de méthodes de décision*

### 1. Introduction

Ces dernières années, beaucoup de chercheurs ont lancé des travaux de recherche pour concevoir des systèmes de reconnaissance de formes plus fiables, plus sophistiqués et plus universels en utilisant plusieurs méthodes de décisionqui travaillent en coopération. L'idée est de combiner les décisions issues de chaque méthode de décision en introduisant l'efficacité et les faiblesses de chacune en vu d'obtenir une décision plus juste et plus correcte ou de choisir une décision finale meilleure que les décisions de chacune des méthodes utilisées. Récemment, la combinaison parallèle de méthodes de décision a été proposée comme une voie permettant de perfectionner la reconnaissance en utilisant la complémentarité qui peut exister entre les méthodes de classifications. Ainsi, dans ce chapitre, par la présentation des performances des systèmes de reconnaissance de formes et les causes de dégradation ses performances sont présentées. Ensuite, différentes architectures permettant la combinaison de méthodes de décision sont décrites avant de finir sur les performances des méthodes de combinaison.

## 2. Performances d'un système de reconnaissance de formes

Les performances du système de reconnaissance restent un des objectifs privilégiés afin de permettre son intégration dans des applications réelles. Ces performances se traduisent directement par les capacités de reconnaissance du système (taux de reconnaissance) qui pourraient constituer l'objectif de performances. Mais cet objectif ne réalise pas si nous ne satisfaisons la robustesse, la fiabilité des décisions et le principe de modularité

### 2.1. La robustesse

Dans la plupart des problèmes de reconnaissance, deux objets représentant une même forme ne seront pas strictement identifiés comme étant un même objet. Cette variabilité peut avoir plusieurs origines. Elle peut provenir des formes des objets eux-mêmes tout comme elle peut aussi résulter du processus d'acquisitions pendant lequel du bruit peut venir perturber l'image à cause des conditions d'éclairage et de la qualité du capteur peuvent influencer sur la couleur et la texture des objets à reconnaitre.

### 2.2. La fiabilité des décisions

Le processus de décision du système doit fournir des réponses fiables notamment en vue d'intégration dans des systèmes automatiques. Cet objectif est intimement lié à celui de robustesse. Moins le système sera sensible aux variations des données et plus il sera fiable.

### 2.3. La modularité

Pour qu'un système de reconnaissance soit le plus adaptatif possible dans des situations pratiques, il doit présenter une certaine modularité, c'est-à-dire séparer entre les différentes phases de système.

### 2.4 Type de méthode de décision

Le méthode de décision est définie comme étant tout système qui reçoit une forme x et donne des informations à propos de la classe correspondant à cette forme. Selon [28] cette réponse peut être divisée en

trois catégories suivant le niveau d'information apporté par la méthode de décision. Elle peut être de type classe, de type rang ou de type mesure.

- *Méthode de type classe*

Soit $e_j(x)$ la méthode de décision qui affecte la forme inconnue x à la classe $C_i$ : $e_j(x) = C_i$, $i \in \{1,...,N\}$. Dans ce cas, l'avis de la méthode de décision est binaire. On peut alors représenter la réponse de la méthode de décision par un vecteur binaire dans lequel 1 indique la classe proposée par la méthode de classification. Une méthode de décision peut aussi produire un ensemble de classes. Il considère alors que la forme *x* appartient à une des classes de cet ensemble sans donner d'autres informations permettant de discriminer les classes.

- *Méthode de type rang*

Il s'agit d'un classement sur les classes. La méthode de décision indique ce classement en fournissant en sortie un vecteur des rangs de taille N. La classe placée au premier rang de la liste proposée par la méthode de décision est considérée comme la plus probable pour la forme *x* et la classe du dernier rang est la moins probable.

- *Méthode de type mesure*

Si $e_j(x) = \{m_{1j}, m_{2j},...,m_{Nj}\}$, $m_{ij}$ est la mesure attribuée à la classe *i* par la méthode de décision $e_j$ et indique le niveau de confiance de la méthode de décision dans sa proposition. Cette mesure, normalisée ou non, peut être une distance, une probabilité *a posteriori*, une valeur de croyance, un score, une fonction de croyance, une possibilité, une crédibilité, une mesure floue, etc. Parfois, la méthode de décision est incapable de conclure sur la classe de la forme à reconnaître (la forme *x* peut appartenir à plusieurs classes ou forme aberrante). Les informations mises à sa disposition ne lui permettent pas de choisir une classe ou un sous-ensemble de classes parmi les classes disponibles. On dit alors que la méthode de décision rejette la forme *x*. Chaque type de sortie (classe, rang ou mesure) correspond à un niveau d'information différent fourni par

la méthode de classification. La sortie de type classe est la plus simple mais la moins riche en information. La sortie de type rang reflète l'ordre de préférence des propositions fournies par la méthode de classification. La sortie de type mesure est la plus riche en information puisqu'elle reflète le niveau de confiance de la méthode de décision dans ses propositions.
Lorsque les sorties sont de type rang ou de type mesure, on peut les transformer en type classe (avec perte d'informations). Ceci consiste à tenir compte uniquement de la première solution de la liste proposée par chaque méthode de décision. Pour le type rang, il suffit de choisir la classe qui est placée au premier rang. Les autres classes ne seront pas prises en compte. Pour le type mesure, il suffit de choisir la classe ayant la meilleure mesure (valeur minimale ou maximale, selon que la mesure est croissante ou décroissante).

## 3. Fusion de méthodes de décision

Il est difficile de trouver une méthode de décision capable de répondre aux exigences citées précédemment. C'est la raison pour laquelle a été introduite la combinaison de plusieurs méthodes afin de tenir compte des performances de chacune d'elles pour ensuite en tirer une décision de meilleure qualité.
Considérons un système composé d'un ensemble *m* de méthodes de décision permettant de reconnaître une forme x. Chaque méthode de décision $e_j$, $j=1,2,\ldots, L$, produit une réponse sous forme d'un vecteur $e_j=[e_{1j},e_{2j}, \ldots,e_{nj}]^T$ où la composante $e_{ij}(x)$ indique que la méthode de décision $e_j$ a affecté la forme $x$ à la classe $C_j$ parmi l'ensemble des $n$ classes possibles ($i=1, \ldots, n$). Nous pouvons représenter toutes les décisions des méthodes sous forme d'une matrice $MD(x)=[e_1(x), e_2(x),\ldots,e_L(x)]$ qui représente les réponses de l'ensemble des méthodes de décision pour une forme $x$. Chaque ligne $i$ de cette matrice représente la réponse de toutes les méthodes de décision concernant la classe $C_j$ et chaque colonne $j$ représente le vecteur de réponses d'une méthode de

classification $e_j$. Il s'agit de l'espace intermédiaire de caractéristiques du module de combinaison E. MD(x) s'écrit alors sous la forme :

$$MD(x) = \begin{bmatrix} e_{11}(x) & \dots & e_{1j} & \dots & e_{1L}(x) \\ \dots & & & & \\ e_{i1}(x) & \dots & e_{ij}(x) & \dots & e_{iL}(x) \\ \dots & & & & \\ e_{N1}(x) & \dots & e_{Nj}(x) & \dots & e_{NL}(x) \end{bmatrix}$$

La décision de fusion peut alors être obtenue par $E(x)=f(e_1(x), e_2(x),\dots,e_L(x))$ où $f$ est une méthode de combinaison. Plusieurs manières de combinaison ont été citées dans la littérature. Parmi les plus connues, nous citons la combinaison parallèle, sans apprentissage, de type classe, par vote avec seuil, à majorité sans conflit, à majorité notoire, de type rang, de type mesure et avec apprentissage

### 3.1 Méthodes de combinaison parallèle

Dans cette architecture parallèle [29], les méthodes de décision travaillent séparément les unes des autres et leurs réponses respectives sont, ensuite, fusionnées. Cette architecture présente de nombreux avantages parmi lesquels :

- sa facilité de mise en œuvre facile,
- la possibilité de combiner des méthodes de décision quelles soient homogènes ou hétérogènes,
- la possibilité de modifier une ou plusieurs méthodes de décision sans toucher aux autres méthodes et à l'ensemble de système,
- sa capacité d'adaptation,
- le temps de calcul réduit car l'ensemble des méthodes de décision travaille en parallèle, ce qui représente un atout majeur dans les systèmes en temps réel.

### 3.2 Méthodes de combinaison série

Dans l'architecture série [30], la décision d'une méthode de décision ne dépend pas uniquement de son type de paramètres mais aussi de la réponse de la méthode qui le précède. La décision finale dépend, donc, de l'ordre de méthode de classifications. C'est l'inconvénient majeur de cette architecture. L'autre inconvénient concerne le temps de calcul élevé.

### 3.3 Combinaison de type classe

Dans cette combinaison, chaque méthode de décision fournit, en sortie, une réponse sur l'appartenance de la forme inconnue à une classe ou un ensemble de classes (ayant le même degré de préférence). Dans ce cas, la décision d'affecter un objet x à une classe est binaire et la réponse de la décision est représentée par un vecteur binaire. Il arrive qu'une réponse produise un ensemble de classes, ce qui signifie que la forme $x$ appartient à une des classes de cet ensemble sans donner d'autres informations permettant de discriminer les classes. Notons que la combinaison d'un ensemble de méthodes de décision de type classe est souvent basée sur le principe du vote. Il y a maintenant plus deux siècles que ce principe a été formalisé par des mathématiciens. Depuis, plusieurs méthodes de vote ont été proposées. Elles sont surtout utilisées dans les élections. Dans le domaine de la reconnaissance de formes, les méthodes de vote ont été utilisées principalement en reconnaissance de l'écrit [31] ainsi que pour la vérification de signatures [32]. Dans le cadre de la combinaison, les méthodes de vote consistent à interpréter chaque sortie d'une décision comme un vote pour l'une des classes possibles. La classe ayant un nombre de votes supérieur à un seuil préfixé est retenue comme décision finale. Ces méthodes sont les plus simples à mettre en œuvre car les votes des méthodes ne sont pas pondérés et chaque classe reçoit autant de votes qu'il y a de méthodes de décision à combiner. La plupart de ces méthodes ne nécessite qu'un seul niveau de décision. On peut classer ces méthodes en trois catégories: vote avec seuil, à majorité sans conflit et à majorité notoire.

- *Vote avec seuil*

Les méthodes de vote peuvent pratiquement toutes être dérivées de la règle avec seuil exprimée par :

$$E(x) = \begin{cases} C_i & si \quad \sum_{j=1}^{L} e_{ij} = \max_{t=1}^{N} \sum_{j=1}^{L} e_{ij} \geq \lambda.L \\ & rejet \quad si \quad non \end{cases}$$

où λ correspond à la proportion de méthodes de décision devant répondre la même classe pour que cette classe soit retenue comme résultat de la combinaison. Ainsi, pour λ=0, il s'agit du vote à la pluralité e où la classe qui reçoit le plus de votes est choisie comme classe finale. Comme exemple, soit matrice de décision su tableau 1.

Tableau.1 Exemple de matrice de décision

| | $e_1$ | $e_2$ | $e_3$ | $e_4$ | $\sum_{j=1}^{L} e_{ij}$ |
|---|---|---|---|---|---|
| $C_1$ | 0 | 0 | 1 | 0 | 1 |
| $C_2$ | 1 | 1 | 0 | 1 | 3 |
| $C_3$ | 0 | 0 | 0 | 0 | 0 |
| $C_4$ | 0 | 0 | 0 | 0 | 0 |
| $\max_{i=1}^{L}(\sum_{j=1}^{L} e_{ij})$ | | | | | 3 |

Dans le cas où λ=0, alors $C_2$ est retenue comme décision finale, car c'est elle qui a reçu le plus grand nombre de votes. Cette méthode a la forme de vote la plus simple. C'est donc la plus facile à appliquer. Néanmoins, il y a rejet si plusieurs classes ont le même nombre de votes. Dans ce cas, les risques de conflit sont particulièrement importants.

- *Vote à majorité notoire*

Dans ce cas, pour être désignée comme réponse finale, la classe majoritaire doit, de plus, se distinguer de la deuxième classe d'une différence supérieure à un certain seuil. Les résultats de tests dans [33] montrent que cette méthode est meilleure que la majorité avec seuil surtout quand un minimum de fiabilité est exigé. Les méthodes que nous

venons de présenter se composent d'une seule étape. Il existe d'autres méthodes de vote qui nécessitent plusieurs étapes. Elles utilisent des traitements itératifs au cours des différentes étapes permettant de réduire l'ensemble des classes participant au vote.

### 3.3 Méthodes de type rang

Les méthodes de type rang ont été développées essentiellement pour résoudre les problèmes des méthodes de vote. Considérons, par exemple, le problème à trois méthodes de décision avec quatre classes:

$$e_1(x) = \{C_1, C_2, C_3, C_4\}$$
$$e_2(x) = \{C_3, C_1, C_2, C_4\}$$
$$e_3(x) = \{C_2, C_1, C_3, C_4\}$$

Sans qu'il ait des classe majoritaire, les classes $C_1$, $C_2$ et $C_3$ placées en tête de liste reçoivent, toutes, 1 vote. Dans cette situation, il est raisonnable de regarder la suite de chaque liste pour lever l'ambiguïté. Les méthodes de type rang se basent sur ce principe pour résoudre le problème. Les méthodes de type rang n'ont été utilisées dans la reconnaissance de forme que récemment. La première étude est réalisée par Ho dans le cadre de la reconnaissance de mots [34]. Depuis, elles sont appliquées dans d'autres problèmes de reconnaissance [35]. L'avantage para rapport à la méthode de type classe est que, en plus de la facilité de mettre en œuvre, la sortie de type rang est plus riche en information que la sortie de type classe. De plus, il est très facile de transformer le type mesure en type rang en ignorant les confiances dans la sortie proposées mais en conservant l'ordre des classes, et lorsque on ne peut pas normaliser les dégrées de confiances issus de la sortie de type mesure.

Le principe des méthodes de type rang est combiner des listes de propositions de méthode de décision ordonnées de manière décroissante selon leur préférence. Les rangs attribués par chaque méthode de peuvent être considérés comme des votes pour toutes les classes. Ayant un nombre N de classes, chaque méthode de décision attribue un poids N à la classe placée au début de la liste, un poids N-1 à la seconde classe, etc. La classe

placée à la fin de la liste reçoit un seul vote. Les méthodes non-paramétriques de type rang les plus reconnues sont celles de Borda Count (BC) et le meilleur rang.

- *Méthodes de Borda Count et ses variantes*

Il s'agit d'une procédure de vote proposée en 1770 par Jean Charles de Borda [36] dans laquelle chaque votant arrange les N classes selon sa préférence en attribuant un nombre de points à chacune. La classe préférée reçoit N-1 points, la classe suivante reçoit N-2, ainsi de suite. Le nombre de points de la classe placée à la fin de la liste est 0. La règle de Borda offre donc un seul ensemble de rangs, N-1, N-2, ..., 0. Certains auteurs attribuent les rangs autrement: N points à la classe placée en tête (top) de chaque liste de méthode de classifications, N-1 à la classe suivante et 1 à la dernière classe [37]. Pour un problème à deux classes. Pour une classe particulière Ci (i=1,..., N), le BC(Ci) est la somme de tous les rangs proposés par les méthodes de décision pour cette classe tel que :

$$BC(C_i) = \sum_{j=1}^{L} r_{ij}$$

où $r_{ij}$ est le rang attribué par la méthode $e_j$ à la classe $C_i$. Nous aurons $r_{ij}=N$ si la classe $C_i$ est placée au début de la liste, $r_{ij}=N-1$, si la classe $C$ est placée à la place suivante de la liste, etc. Les classes sont ensuite triées selon leur rang total. Le nouvel ordre détermine les rangs finaux. Un exemple est donné au tableau 2.

Tableau.2 Exemple de la Borda Count

| | $C_1$ | $C_2$ | $C_3$ | $C_4$ |
|---|---|---|---|---|
| $e_1$ | 3 | 2 | 1 | 0 |
| $e_2$ | 3 | 2 | 1 | 0 |
| $e_3$ | 0 | 3 | 1 | 2 |
| $BC(C_i) = \sum_{j=1}^{L} r_{ij}$ | 6 | 7 | 3 | 2 |

La décision finale de la combinaison par Borda Count est donc: {$C_2$, $C_1$, $C_3$, $C_4$}.

- *Méthode du meilleur rang*

La méthode du meilleur rang consiste à attribuer à chacune des classes, le rang le plus élevé *MR($C_i$)* parmi les rangs proposés par les méthodes de décision et d'ordonner la liste selon ces rangs [38].

$$MR(C_i) = \max_{j=1}^{L} r_{ij}$$

Cette méthode est adaptée pour des problèmes à plusieurs classes. Son avantage est qu'elle utilise la meilleure réponse de chaque méthode de décision. Cependant, il apparaît que cette méthode peut facilement provoquer des conflits lorsque plusieurs classes obtiennent le même meilleur rang. Ce problème peut être résolu en utilisant des critères supplémentaires [39].

### 3.4 Méthodes de type mesure

Les méthodes de type mesure combinent des mesures qui reflètent le degré de confiance des méthodes de décision sur l'appartenance de la forme à reconnaître en chacune des classes. Toutefois, comme les sorties des méthodes de décision ne sont pas toujours comparables, une normalisation est souvent nécessaire [40]. Les méthodes de combinaison non-paramétrique les plus utilisées sont les règles fixes et la moyenne de Bayes.

- *Méthodes fixes*

Le principe de base derrière les méthodes fixes est le suivant : les méthode de classifications sont indépendants et estiment des probabilités *a posteriori* des classes. Ainsi, pour reconnaitre une forme x, on utilise une règle de décision *E(x)* qui revient à choisir la classe $C_i$ pour laquelle la probabilité *a posteriori* $P_i$ est la plus élevée :

$$E(x) = \begin{cases} C_i & si \quad \max_{i=1}^{N} P_i \\ rejet & si \quad non \end{cases}$$

La probabilité *a posteriori* $P_m$ peut être calculée par l'une des règles suivantes :

-. La règle maximum

$$P_i = \max_{j=1}^{L} m_{ij}$$

-. La règle minimum

$$P_i = \min_{j=1}^{L} m_{ij}$$

-. La règle médiane

$$P_i = med_{j=1}^{L} m_{ij}$$

-. La règle produit

$$P_i = \prod_{j=1}^{L} m_{ij}$$

-. la règle linéaire

$$P_i = \lambda \sum_{j=1}^{L} m_{ij}$$

Les trois premières règles sont connues sous le nom d'opérateurs d'ordre statique. La règle maximum consiste à choisir la classe pour laquelle la probabilité $m_{ij}$ est la plus élevée. Si la méthode de décision qui propose cette confiance a une mauvaise performance, alors la règle maximum n'est pas fiable. Dans [41], il est dit qu'il est difficile de trouver dans la littérature un exemple applicatif pour lequel la règle maximum est la plus performante La règle minimum consiste à choisir la méthode de décision qui propose la probabilité la plus faible. Comme la règle maximum, il est difficile de prédire les situations dans lesquelles cette règle est la plus efficace. Pratiquement, tous les travaux qui ont utilisé les opérateurs d'ordre statique montrent clairement que la règle médiane est plus robuste que maximum et minimum [42]. Cependant, la décision par la règle médiane ne prend pas en compte toutes les informations de l'ensemble de méthode de classifications. Dans la règle linéaire, λ est une constante. Ainsi, pour λ=1, on obtient la règle de somme. Si λ=1 = 1/L alors la règle est la moyenne simple. Il est constaté que la règle de somme est la plus robuste par rapport aux autres règles fixes. Elle améliore la performance de la combinaison et est moins sensible aux erreurs des méthodes de classification. Pour la règle de produit, si l'une des méthodes de décision produit une décision avec une faible confiance alors elle réagit

de manière dramatique sur la combinaison, mais elle reste efficace pour un nombre faible de méthode de classifications [43].

Le tableau 3 donne un exemple de fonctionnement de ces règles de combinaison avec *N=3* et *L=5.*

Tableau.3 Exemple de méthodes fixes

| | $e_1$ | $e_1$ | $e_1$ | $e_1$ | $e_1$ | Max | Min | Méd | Prod | Som | moy |
|---|---|---|---|---|---|---|---|---|---|---|---|
| $C_1$ | 0.1 | 0.0 | 0.4 | 0.2 | 0.1 | 0.4 | 0.0 | 0.1 | 0.0 | 0.8 | 0.16 |
| $C_2$ | 0.5 | 0.0 | 0.3 | 0.7 | 0.8 | 0.8 | 0.0 | 0.5 | 0.0 | 2.3 | 0.46 |
| $C_3$ | 0.4 | 1.0 | 0.4 | 0.1 | 0.1 | 1.0 | 0.1 | 0.1 | 0.016 | 2.0 | 0.4 |
| $\max(P_i)$ | | | | | | 1.0 | 0.1 | 0.5 | 0.016 | 2.3 | 0.46 |

La décision finale obtenue par les règles minimum, maximum et produit est la classe 3 alors que celle obtenue par la règle de somme et moyenne est la classe 2.

- *Moyenne de Bayes*

Les méthodes s sont utilisées pour fusionner des sorties de méthode de classifications exprimées en probabilités *a posteriori*. Parmi les méthodes de fusion les plus simples mettre en œuvre, on trouve la règle moyenne de Bayes. Si chaque méthode de décision $e_j$ propose une probabilité a posteriori $P_j(x\ 2\ Ci=x)$ attribuée à la classe $C_i$ (i=1, …, N) pour une forme x à reconnaître, il est alors possible de calculer la probabilité *a posteriori* moyenne à partir de tous les méthodes de classification.

$$P_{moy}(x \in C_i / x) = \frac{1}{L} P_j(x \in C_i / x)$$

La décision finale est obtenue selon le critère de Bayes : la forme x est classée $C_i$ si $P_{moy}(x \in C_i / x)$ est maximale. La probabilité *a posteriori* $P_j(x \in C_i / x)$ peut être directement fournie par les méthodes de décision de type bayésienne.

### 3.5. Méthodes avec apprentissage

Par rapport aux méthodes précédentes, les méthodes de combinaison paramétrique (avec apprentissage) sont plus complexes à mettre en

application. Elles utilisent des paramètres supplémentaires calculés pendant une phase d'apprentissage. La performance de ces méthodes dépend alors de la bonne estimation des paramètres donc de la base d'apprentissage. Dans la combinaison avec apprentissage, deux cas d'utilisation de la base d'apprentissage sont possibles en utilisant la même base pour entrainer les méthodes de décision et la méthode de combinaison, ou en utilisant deux parties, l'une pour les méthodes de décision et l'autre pour la combinaison. Il est noté que la réutilisation de la même base d'apprentissage au niveau de la combinaison, le premier cas est à éviter. Il est toujours préférable d'utiliser une deuxième base d'apprentissage.

- *Méthodes avec apprentissage de type classe*

Les méthodes avec apprentissage de type classe ne sont pas très nombreuses. Les méthodes les plus utilisées sont principalement le vote pondéré, la théorie de Bayes, la méthode de Dempster-Shafer et la méthode d'espace de connaissance du comportement (*Behaviour Knowledge Space ou BKS*).

Dans la méthode avec apprentissage de type classe utilisant le vote avec apprentissage, la réponse $e_{ij}$ de chaque méthode de décision $e_j$ est pondérée par un coefficient $\omega_j$ indiquant son importance dans la combinaison.

$$E(x) = \begin{cases} C_i & si \quad \sum_{j=1}^{L} w_j e_{ij} = \max_{i=1}^{N} \sum_{j=1}^{L} w_j e_{ij} \\ rejet & si \quad non \end{cases}$$

Il existe plusieurs façons de déterminer les coefficients $w_j$. La forme $x$ d'entrée est attribuée à la classe pour laquelle la somme des votes, qui sont pondérés par la fiabilité (taux de reconnaissance) estimée de chacun des méthodes de décision est la plus élevée. Cette méthode n'introduit pas de critère de rejet.

Dans la méthode avec apprentissage de type classe utilisant le modèle probabiliste pour une méthode de combinaison bayésiennne, la règle de Bayes est utilisée. Rappelons que :

$$P(C_i / e_1,...,e_j,...,e_L) = \frac{P(e_1,...,e_j,...,e_L / C_i) * P(C_i)}{P(e_1,...,e_L)}$$

Il s'agit donc de déterminer la classe $C_i$ pour laquelle la probabilité a posteriori $P(C_i / e_1,...,e_j,...,e_L)$ est la plus élevée, autrement dit,

$$E(x) = C_i \quad si \quad P(C_i / e_1,...,e_L) = \max_{i=1}^{L} P_i(C_i / e_1,...,e_L)$$

Pour calculer la probabilité *a posteriori*, plusieurs travaux supposent que les méthodes de décision sont indépendantes c'est-à-dire :

$$P(e_j / C_i, e_k) = P(e_j / C_i) \quad avec \quad j \neq k$$

$$P(e_1,..., e_L / C_i) * P(C_i) = P(C_1, e_1,..., e_L)$$
$$P(e_1,..., e_L / C_i) * P(C_i) = P(C_i) * P(e_1 / C_i) * P(e_2,..., e_L)$$
$$P(e_1,..., e_L / C_i) * P(C_i) = P(C_i) * P(e_1 / C_i) * P(e_2 / C_i, e_1) * P(e_3,...e_L)$$
$$P(e_1,..., e_L / C_i) * P(C_i) = P(C_i) * \prod_{j=1}^{L} P(e_j / C_i)$$

Donc la règle de Bayes précédente s'écrit à nouveau de la manière suivante :

$$P(C_i / e_1,..., e_j,..., e_L) = \frac{P(C_i) * \prod_{j=1}^{L} P(e_j / C_i)}{P(e_1,..., e_L)}$$

Les probabilités $P(e_j / C_i)$ peuvent être calculées à partir de la matrice de confusion obtenue pour les méthodes de décision sur une base d'apprentissage. Cette solution peut être simplifié dans la mesure où l'on ignore complètement les probabilités *a priori* des classes $P(C_i)$.

Dans la méthode avec apprentissage de type classe utilisant La méthode d'espace de connaissance du comportement appelée aussi BKS [44], on utilise un espace de connaissance contenant les décisions de toutes les méthodes. Cet espace permet de connaître le comportement des méthodes de classifications d'où son nom d'espace de connaissance du comportement. La méthode BKS permet alors de tenir compte des informations de cet espace en les intégrant directement dans la règle de décision afin d'obtenir la solution finale. L'espace de connaissance du comportement BKS est un espace à $L$ dimensions où chaque dimension

correspond à la décision d'une méthode de décision. Chaque méthode de décision possède *N* décisions possibles. L'intersection des décisions des méthodes de décision individuelles occupe une unité de l'espace BKS $(e_1,...,e_l)$ appelée unité focale. Elle accumule le nombre d'entités reconnues par les *L* méthodes de classifications pour chaque classe. Un exemple d'espace de BKS à 2 dimensions est présenté dans le tableau 4 où $(i, j)$ représente une unité focale avec $e_1 = C_i$ et $e_2 = C_j$.

Tableau.4 Espace BSK à 2 dimensions

| $e_1/e_2$ | 1 | … | $j$ | … | $N$ |
|---|---|---|---|---|---|
| 1 | 1,1 | … | $1, j$ | … | $1, N$ |
| ⋮ | ⋮ | | ⋮ | | ⋮ |
| $i$ | $i$,1 | … | $i, j$ | … | $i, N$ |
| ⋮ | ⋮ | | ⋮ | | ⋮ |
| $N$ | $N$,1 | … | $N, j$ | … | $N, N$ |

Chaque unité focale comporte 3 types d'informations :

- Le nombre total d'échantillons $n_{e_1,...,e_L}(C_m)$ appartenant à la classe $C_m$.
- Le nombre total d'échantillons $T_{e_1,...e_L}$ présents dans l'unité.

$$T_{e_1,...e_L} = \sum_{m=1}^{N} n_{e_1,...e_L}(C_m)$$

- L'ensemble des classes les plus représentées $R_{e_1,....e_L}$ dans l'unité.

$$R_{e_1,...e_L} = \left\{ C_i / n_{e_1,...e_L}(C_i) = \max(n_{e_1,...e_l}(C_m)) \right\}$$

La méthode BKS est constituée de deux étapes : une étape d'apprentissage et une étape de décision. Au cours de l'apprentissage, BKS est construit à partir des résultats fournis par les *L* méthodes de classifications. Les valeurs $n_{e_1,...e_L}$ sont déterminées après un passage complet de la base d'apprentissage (l'étiquetage). Les valeurs de $T_{e_1,...e_L}$ et $R_{e_1,....e_L}$ de chaque unité de BKS $(e_1,e_2,...,e_L)$ sont ensuite calculées en utilisant les deux équations précédentes. L'étape de décision repose sur l'utilisation des réponses des L méthode de classifications à la forme présentée pour

choisir l'unité focale correspondante. La règle de décision suivante est ensuite utilisée pour donner le résultat final à propos de la classe x :

$$E(x)=\begin{cases} R_{e_1,\ldots,e_L} & si \quad T_{e_1,\ldots,e_L} \succ 0 \quad et \quad \dfrac{n_{e_1,\ldots,e_L}(R_{e_1,\ldots,e_L})}{T_{e_1,\ldots,e_L}} \\ rejet & si \quad non \end{cases}$$

où $\lambda$ est un seuil qui contrôle la fiabilité de la décision finale $(0 \le \lambda \le \lambda)$. Plusieurs méthodes existent pour la recherche automatique de ce seuil [45].

La prise de décision dans BKS peut être illustrée par l'exemple du tableau 5 où il s'agit de 3 classes (N=3), de 2 décisions (L=2) et de 100 éléments de la base d'apprentissage (S=100).

Tableau.5 Exemple d'un BSK

| $e_1, e_2$ | {1,1} | {1,2} | {1,3} | {2,1} | {2,2} | {2,3} | {3,1} | {3,2} | {3,3} |
|---|---|---|---|---|---|---|---|---|---|
| $n_{e_1,e_2}$ | 10/3/3 | 3/0/6 | 5/4/5 | 0/0/0 | 1/16/6 | 4/4/4 | 7/2/4 | 0/2/5 | 0/0/6 |
| $T_{e_1,e_2}$ | 16 | 9 | 14 | 0 | 23 | 12 | 13 | 7 | 6 |
| $R_{e_1,e_2}$ | $C_1$ | $C_3$ | $C_1,C_3$ | *rejet* | $C_2$ | $C_1,C_2,C_3$ | $C_1$ | $C_3$ | $C_3$ |

La première ligne de ce tableau représente toutes les combinaisons possibles des réponses des deux méthodes de décision $e_1$ et $e_2$. La deuxième ligne contient le nombre de fois où les méthodes de décision proposent la réponse de la première ligne pour les différentes classes. Par exemple, 10=3=3 ($2^{ième}$ colonne du tableau) indique que les deux méthodes de décision proposent 10 fois la réponse (1,1) pour la classe 1, 3 fois cette même réponse pour les classes 2 et 3. Supposons maintenant que pour une forme x à reconnaître, la première méthode de décision propose 3 alors que la deuxième méthode en propose 1, c'est-à-dire $e_1$=3 et $e_2$=1

(colonne 7 du tableau). Dans ce cas, l'unité focale à considérer est BKS(3,1) et la classe de x est 1. Cette méthode présente une efficacité en termes de taux de reconnaissance par rapport à d'autres méthodes comme le vote majoritaire et la méthode bayésienne. Cependant, l'utilisation de cette méthode reste dépendante de la taille de la base d'apprentissage qui doit être représentative et riche.

- *Méthodes avec apprentissage de type rang*

La limites des méthodes sans apprentissage de type rang est qu'elles ne tiennent pas compte de la fiabilité et des performances des méthodes de décision (tous les méthodes de décision ont le même poids dans la prise de décision finale). Or, il est important d'intégrer le degré de crédibilité des méthodes de décision dans la combinaison surtout lorsqu'une des méthodes est plus performant que les autres. Dans ce travail nous citons uniquement la méthode de la somme pondéré de type rang, car elle est la plus citées dans la littérature. En effet, dans cette méthode, les rangs attribués par les méthodes de décision pour une classe $C_i$ sont pondérés par des coefficients $w_i$ indiquant la crédibilité accordée à chaque méthode de décision $e_j$. Il s'agit d'une généralisation du borda count lorsque $w=1$. La somme pondérée (SP) d'une classe $C_i$ s'écrit :

$$SP(C_i) = \sum_{j=1}^{L} w_j r_{ij}$$

Il existe plusieurs méthodes pour calculer les $w_j$, en utilisant les matrices de confusion ou les notions de distances. La nouvelle liste ordonnée par $SP(C_i)$ est prise comme une décision finale. Le tableau 6 reprend l'exemple précédemment donné sur la méthode de borda count, en ajoutant les coefficients $w_j$.

Tableau.6 Exemple d'une combinaison avec la somme pondérée

| | $C_1$ | $C_2$ | $C_3$ | $C_4$ |
|---|---|---|---|---|
| $e_1$, $w_1 = 0.9$ | 3 | 2 | 1 | 0 |
| $e_2$, $w_2 = 0.8$ | 3 | 2 | 1 | 0 |
| $e_3$, $w_3 = 0.5$ | 0 | 3 | 1 | 2 |
| $SP(C_i) = \sum_{j=1}^{L} w_j r_{ij}$ | 5.1 | 4.9 | 2.2 | 1 |

La décision finale de la combinaison est donc {$C_1$, $C_2$, $C_3$, $C_4$}. Cet exemple montre l'influence de $w_j$ sur la décision.

- *Méthodes avec apprentissage de type mesure*

Les méthodes de combinaison avec apprentissage de type mesure sont utilisées dans divers problème de décision. Elles considérés flexibles et riches en information. Parmi ces méthodes, nous citerons celles basées sur les règles pondérées et la théorie Dempster-Shafer.

Les méthodes basées sur les règles pondérées consistent à utiliser des pondérations aux sorties des méthodes de décision. Chaque probabilité *a posteriori* $P_i$ d'une classe $C_i$ peut être calculée par l'une des règles suivantes :

$$P_i(C_i) = \lambda \sum_{j=1}^{L} w_i m_{ij}$$

$$P_i(C_i) = \prod_{j=1}^{L} m_{ij}^{w_j}$$

où $w_j$ est le coefficient qui détermine l'importance (fiabilité ou performance) attribuée au $j^{ième}$ méthode de décision dans la combinaison (j=1,2,…, L).

La décision finale est prise sur le maximum des probabilités a posteriori $P_i$

Avec $\lambda = 1$, la première règle est nommée la somme pondérée. Pour $\lambda=1$, il s'agit de la moyenne pondérée. Il existe plusieurs manières de manipuler $\lambda$. Dans [46], il a été proposé une méthode linéaire et adaptative pour la reconnaissance dans un problème à très grand nombre de classes et son efficacité a été montrée par rapport à d'autres méthodes comme le vote.

La deuxième règle est le produit pondéré. Dans [47], une application de reconnaissance des mots manuscrits en utilisant les règles de somme et de produit pondérées a montré que la règle de multiplication qui améliore les taux de reconnaissance.

Quant à la méthode de Dempster-Shafer, elle fait, particulièrement l'objet su paragraphe suivant.

## 4. Théorie de Dempster-Shafer

La théorie Dempster-Shafer, appelée aussi théorie de l'évidence ou de croyance, a été introduite par Shafer en 1976 en prenant appui sur les bases formulées par Dempster. L'avantage de cette théorie est sa flexibilité pour représenter l'information et son principe d'inclure une modélisation à la fois de l'incertitude et de l'imprécision dans les systèmes à plusieurs méthodes de décisions [48]

### 4.1 Principe de la théorie Dempster-Shafer

Soit un ensemble $\Omega$ de $N$ hypothèses (Classes) appelé cadre de discernement tel que $\Omega=\{C_i / i=1,...,N\}=\{C_1,...,C_N\}$ . Il est supposé que le cadre de discernement est exhaustif et les hypothèses sont exclusives, autrement dit, la solution au problème est obligatoirement l'une des classes $C_i$ du cadre de discernement et que la solution est unique. Cette notion est aussi appelée monde fermé (*closed world).* À partir de cet ensemble $\Omega$, il est défini un ensemble noté $2^p$ qui est l'ensemble de tous les $2^N$ sous-ensembles $A$ de $\Omega$ tel que :

$$2^{\Omega}=\{A/A\subseteq\Omega\}=\{\phi,\{C_1\},\{C_2\},...,\{C_1,C_2\},...,\Omega\}$$

Cet ensemble contient les hypothèses singletons de $\Omega$, toutes les disjonctions possibles de ces hypothèses ainsi que l'ensemble vide. Lorsque $A$ désigne une seule classe $C_i$, il s'agit d'une hypothèse singleton. Si $A$ désigne un ensemble de classes, il s'agit d'une hypothèse composite.

La théorie de l'évidence est caractérisée par une mesure, traduisant une opinion sur chaque sortie issue de méthode de décision. Cette mesure est appelé aussi la fonction de masse ou degré de croyance représentée par $m(.)$, et définie de la manière suivante :

$$m: 2^{\Omega} \rightarrow [0,1]$$

Cette fonction vérifie les propriétés suivantes :

$$m(\phi) = 0$$

$$\sum_{A \subseteq \Omega} m(A) = 1$$

La quantité $m(A)$ est la part de croyance placée strictement sur $A$. Les éléments de $2^{\Omega}$ dont la masse est non nulle sont appelés éléments focaux, Une situation d'ignorance totale est donnée par m(.)=1 et de certitude totale sur une hypothèse singleton par $m(C_i)=1$

A partir de la fonction de masse précédemment définie, il est possible de définir d'autres représentations de l'information comme la plausibilité et la crédibilité.

- *La. plausibilité*

Une fonction de plausibilité est une fonction de $2^{\Omega} \rightarrow [01]$ définie à partir de la fonction de masse de la manière suivante :

$$pl(A) = \sum_{B \cap A \neq \phi} m(B) \qquad \forall B \subseteq \Omega \quad et \quad B \neq \phi$$

- *La crédibilité*

Une fonction de crédibilité est une fonction de $2^{\Omega} \rightarrow [01]$ définie à partir d'une fonction de masse de la manière suivante :

$$bel(A) = \sum_{B \subseteq A} m(B) \qquad A \subseteq \Omega \quad et \quad A \neq \phi$$

Ces deux fonctions ont un sens concret dans le cadre de la théorie de l'évidence, la fonction de crédibilité *bel* représente une mesure globale de croyance attribuée à une hypothèse. La fonction de plausibilité $p_i$ représente le degré de croyance maximal qui pourrait âtre attribué à l'hypothèse.

### 4.2 Règle de combinaison de Dempster

Si nous disposons de plusieurs sources d'information et de fonctions d'allocation de masse, le problème est de combiner les sorties. Par exemple pour deux sorties $S_1$ et $S_2$ produisant les masses $m_1$ et $m_2$, sur le même cadre de discernement $\Omega$. Le vecteur de masse $m$ par fusion ($m=m_1 \oplus m_2$), d'après la règle orthogonale de Dempster, est donné par :

$$m_{1,2}(\phi) = 0$$

$$m_{1,2}(A) = \frac{1}{1-K} \sum_{B \cap C = A} m_1(B).m_2(C) \qquad \forall A \subseteq \Omega \quad et \quad A \neq \phi$$

$$où \qquad K = \sum_{B \cap C = \phi} m_1(B).m_2(C)$$

On notera que *(1-K)* sert de facteur de normalisation et $K$ une mesure de conflit entre les masses.

L'utilisation de la règle de Dempster est possible si est seulement si $m_1$ et $m_2$ ne sont pas en conflit total, autrement dit, s'il existe deux éléments focaux avec une fonction de masse non nulle $B$ et $C$ de $m_1$ et $m_2$ qui satisfont $B \cap C \neq \phi$. Cette règle possède les propriétés d'associativité et de commutativité [49].

Une fois toutes les masses obtenues, la dernière étape est de prendre la décision. Plusieurs règles de décision sont déjà définies et, le plus souvent, elles reposent sur le maximum de la crédibilité ou de plausibilité sur les éléments singletons. Plus généralement, la fonction de décision $\delta$ pour une forme entrante $x$ est de la forme :

$$\delta(x) = C_f \quad avec \quad C_f = \arg\{\max[bel(C_i)]\}, \quad C_i \in \Omega$$

$$\delta(x) = C_f \quad avec \quad C_f = \arg\{\max[pl(C_i)]\}, \quad C_i \in \Omega$$

Lorsque, la décision est prise sur le maximum de crédibilité, la décision est qualifiée de trop pessimiste. Si elle prise sur le maximum de la plausibilité, la décision est qualifiée de trop optimiste.

Comme exemple, supposons un système composé de deux méthode de décision et un cadre de discernement de trois classes $\Omega(a,b,c)$. Les sorties

des méthodes de classifications par rapport à une forme $x$ sont *e(x)={0.5(a), 0.3(b),0.2(c)}et e(x)={0.4(a), 0.6(b),0.0(c)}.* Le tableau 6 nous montre la fonction de masse, de crédibilité et de plausibilité construites à partir des sorties des méthodes de classifications $e_1$ et $e_2$.

Cet exemple nous montre que lorsque nous misons uniquement sur les éléments singletons de $2^{\Omega}$ , c'est-à-dire tous les éléments focaux sont des éléments singletons, alors, la fonction de masse, la fonction de crédibilité et la fonction plausibilité ont les mêmes valeurs pour les singletons. La décision dans ce cas est prise directement sur le maximum des $m_j\ (C_i)$.

Tableau.7 Exemple d'application de théorie de Dempster-Shafer

avec 2 décisions et 3 classes

| | Méthode de décision1 | | | Méthode de décision2 | | |
|---|---|---|---|---|---|---|
| | $m_1(.)$ | $bel_1(.)$ | $pl_1(.)$ | $m_2(.)$ | $bel_2(.)$ | $pl_2(.)$ |
| $\phi$ | 0 | 0 | 0 | 0 | 0 | 0 |
| $\{a\}$ | 0.5 | 0.5 | 0.5 | 0.4 | 0.4 | 0.4 |
| $\{b\}$ | 0.3 | 0.3 | 0.3 | 0.6 | 0.6 | 0.6 |
| $\{c\}$ | 0.2 | 0.2 | 0.2 | 0 | 0 | 0 |
| $\{a,b\}$ | 0 | 0.8 | 0.8 | 0 | 1 | 1 |
| $\{a,c\}$ | 0 | 0.7 | 0.7 | 0 | 0.4 | 0.4 |
| $\{b,c\}$ | 0 | 0.5 | 0.5 | 0 | 0.6 | 0.6 |
| $\{a,b,c\}$ | 0 | 1 | 1 | 0 | 1 | 1 |

Nous remarquons que $bel_2(\{a,b\}=pl_2(\{a,b\})=1$, c'est-à-dire l'ignorance totale, ou d'une autre manière, la décision se résume entre $a$ et $b$.

## 5. Analyse des méthodes de décision

Les chercheurs ont analysé le comportement des méthodes de combinaison en utilisant taux d'erreurs et taux de reconnaissance comme performances des méthodes de décision. La somme est la plus résistante aux erreurs par rapport aux autres règles fixes alors que le produit et le minimum sont les plus sensibles aux erreurs de décision. Pour un

problème à deux classes et avec une distribution normale des erreurs de décision, la moyenne, la médiane et le vote à la majorité sont similaires. Pour un problème à deux classes avec une distribution gaussienne des erreurs, la somme est toujours meilleure que le vote à la majorité. La meilleure performance de la moyenne simple est obtenue avec des méthodes de décision ayant le même taux d'erreurs alors que la moyenne pondérée se comporte mieux quand les méthodes de décision ont des performances différentes. Avec des méthodes de décision produisant des erreurs non corrélées, la performance de la moyenne simple ne dépend que des performances des méthodes de décision même si un critère du rejet est utilisé. Avec des méthodes de décision ayant le même taux de reconnaissance, les méthodes de vote garantissent toujours une amélioration de performance [50].

Quant aux règles fixes, elles sont sensibles à la corrélation des méthodes de décision alors que dans les méthodes avec apprentissage (BKS par exemple), elles sont moins sensibles. En ce qui concerne le vote à la majorité, il présente souvent des rejets, lorsque il n'a y pas de classe majoritaire et il est préférable d'utiliser un nombre impair de méthode de décision.

Dans le cadre qui concerne le nombre de classes, la moyenne et le produit ont été comparées expérimentalement dans [51]. Les résultats ont montré que dans un problème à 2 classes et avec des méthodes de décision estimant correctement les probabilités *a posteriori*, les deux règles sont similaires. Dans un problème à plusieurs classes et avec des méthodes de décision produisant de faibles erreurs, le produit est meilleur. Dans le cas d'un bruit important, la moyenne arithmétique se révèle plus robuste [52].

Une étude comparative entre le vote à la pluralité et le vote à la majorité a été menée Dans [53]. Cette comparaison a révélé que pour un problème à plusieurs classes, la performance du vote à la pluralité est croissante lorsque le nombre de méthodes de décision augmente. Dans le cas d'un problème à 2 classes et avec un nombre impair de méthodes de

classifications, le comportement du vote à la pluralité est similaire à celui du vote à la majorité.

En ce qui concerne la taille de la base de données, celle constitue un critère qui est utilisé pour évaluer essentiellement les méthodes avec apprentissage. Dans [54] par exemple, les chercheurs ont évalué les performances des méthodes de type classe (BKS et règle de bayes) en fonction de la taille de la base de validation qui a servi à estimer les paramètres nécessaires à la combinaison. Cette étude, menée sur deux problèmes réels à 2 et 5 classes, a montré que les performances des règles avec apprentissage augmentent pour une base de validation suffisamment importante. Lorsque celle-ci est de petite taille, il vaut mieux utiliser les règles simples sans apprentissage comme le vote à la majorité.

## 6 Conclusion

Ce chapitre est consacré à un état de l'art sur les méthodes de la combinaison parallèle des méthodes de classification. Nous avons présenté les performances d'un système de reconnaissance de forme, et nous avons défini trois méthodes de décision dans le cadre de la combinaison qui se différencient par la nature de sortie de ces méthodes de décision. De plus, nous avons présenté les avantages et inconvénients de différentes architectures de combinaison possibles qui se distinguent, essentiellement, par la position des méthodes de classification. Nous avons, ensuite, vu deux catégories de méthodes de combinaison parallèle. La première englobe toutes les méthodes qui ne nécessitent aucune base d'apprentissage (méthodes sans apprentissage), elle-même divisée en sous-catégories selon le type des méthodes de décision utilisés dans la combinaison. Par contre la deuxième est constituée de toutes les méthodes qui nécessitent une base d'apprentissage. Elle est aussi divisée en trois sous-catégories de type classe, rang et de mesure. La méthode Dempster-Shafer a été présentée minutieusement, avec son principe mathématiques, et son interprétation en pratique (reconnaissance de

formes). Ainsi nous avons illustré avec un exemple. A la fin de ce chapitre, nous avons cité les techniques d'analyse des méthodes combinaison des méthodes de classification, en tenant compte de tous facteurs qui interviennent dans la combinaison.

Dans le prochain chapitre, nous appliquerons la combinaison de trois méthodes de décision appliquées à la reconnaissance de graines.

# Chapitre 3

## *Identification automatique de graines en temps réel*

### 1. Introduction

Dans le présent chapitre, nous allons concevoir un système de reconnaissance de formes qui a pour mission l'identification automatique de quatre types de graines de semences. La reconnaissance de des ces graines sera effectuée sur la base des trois type de paramètres à savoir ceux de forme, de couleur et de texture. Une classe de rejet est prévue en cas de non reconnaissance. Etant donné que, quelle que soit le type de paramètres utilisé, des confusions existent toujours, les techniques de fusion de classifieurs sera introduite, Il s'agit donc de fusionner les trois différentes modalités à savoir la forme, couleur et la texture. La figure 1 suivante représente les différents modules qui composent le système que nous projetons de réaliser.

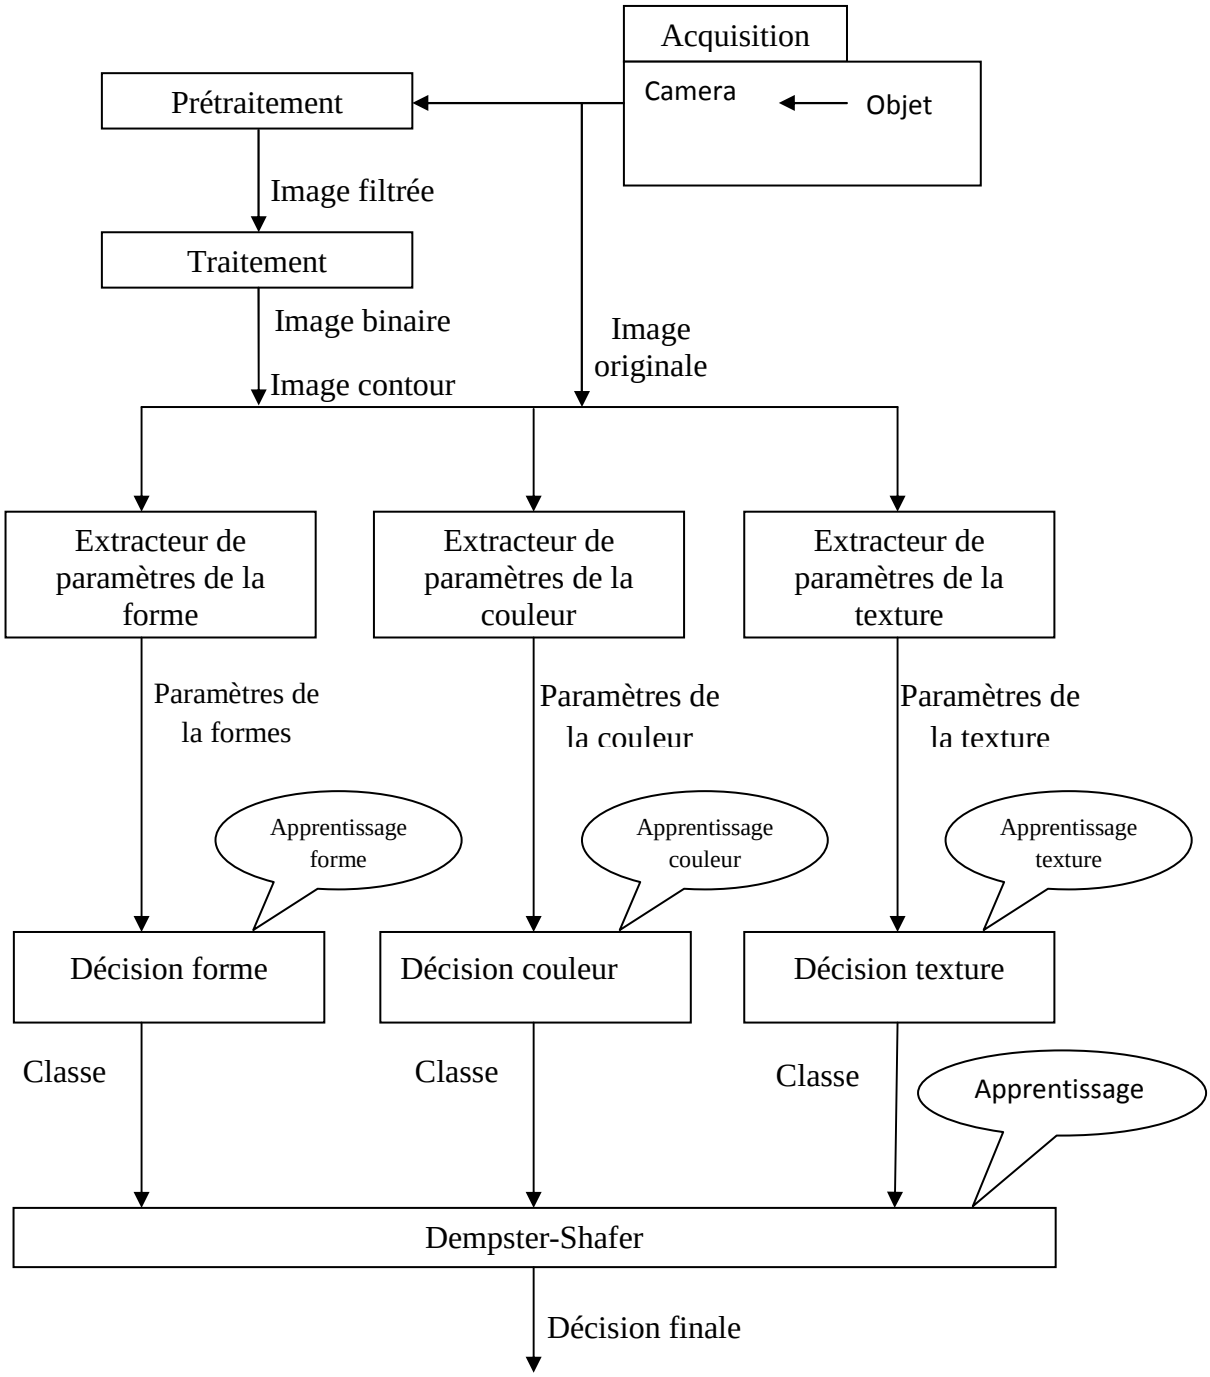


Fig.1 Différents modules du système de reconnaissance de formes

## 2. L'acquisition des images des graines

Cette étape dépend toujours de l'application et son environnement. Les équipements matériels pour cette étape sont choisis de manière à satisfaire certaine conditions, comme la variation de la lumière, la transmission de données, et la capacité de machine traitante.

### 2.1. La camera

La camera que nous avons utilisée est une micro-caméra industrielle dotée d'un capteur mono CCD couleur d'une résolution de 2 méga pixels, de marque SONY, modèle XCL-U1000C. Elle possède différents moyens de communication. L'objectif que nous avons utilisé possède un angle de champs de 15° avec une distance focale de 15 cm.

### 2.2. La carte d'acquisition

La carte d'acquisition d'images utilisée est la carte IMAQ PCI-1426 de National Instrument (NI). Elle fonctionne sous environnement Windows et on peut luifaire appel avec différents langages d eprogrammation évolués tel le Visual C++, LabView et le C#. Cette carte procède des fonctionnalités qui lui permettent de s'adapter à la quasi-totalité des caméras du marché à savoir, :

- Lignes de données TTL ou RS-422
- Signaux de synchronisation TTL ou RS-422
- Fréquence d'horloge allant jusqu'à 50 MHz
- L'horloge pixel peut provenir de la caméra ou bien être générée par la carte 1426, si la caméra le nécessite
- Un, deux ou quatre taps de 8 bits, un ou deux taps de 16 bits, un tap de 32 bits
- Port série RS-232 intégré (UART 16550) pour la configuration de la caméra
- 4 lignes numériques TTL dédiées à la communication avec les caméras sur lesquelles il est possible de générer tout type d'impulsions
- Support des caméras Line Scan, le driver NI-IMAQ reconstitue alors des trames à partir des lignes acquises (le nombre de lignes par trame se règle dans l'utilitaire de configuration)
- Support des caméras couleur. Toute caméra 24 bits est supposée couleur.

En ce qui concerne la mémoire, certaines caméras numériques peuvent avoir des capteurs de grande taille ou des taux de rafraîchissement importants, impliquant ainsi un débit de données très important qui peut

aller au-delà de la vitesse du bus PCI (132 Mo/s en mode burst, 60 Mo/s en continu), Il est alors intéressant de pouvoir stocker les images acquises à très haute vitesse dans la mémoire embarquée sur la carte (vitesse de transfert allant jusqu'à 200 Mo/s) et ensuite prendre un peu plus de temps pour rapatrier les images dans la mémoire du PC et effectuer le traitement. La mémoire embarquée est également utilisée comme FIFO géante lors des transferts DMA vers la mémoire du PC. La carte IMAQ PCI-1426 dispose d'une mémoire de 16 Mo d'origine qui peut être étendue à 72 Mo par l'ajout d'une barrette mémoire standard.

### 2.3. Communication avec la caméra

La communication avec la caméra se fait au moyen d'un port série intégré à la carte ou bien de quatre lignes numérique de communication. Certains fabricants de caméra fournissent un utilitaire pour communiquer avec la caméra, d'autres non. Cependant, le driver NI-IMAQ se charge de la communication. La figure 2 montre les images de graines obtenues avec le système d'acquisition.

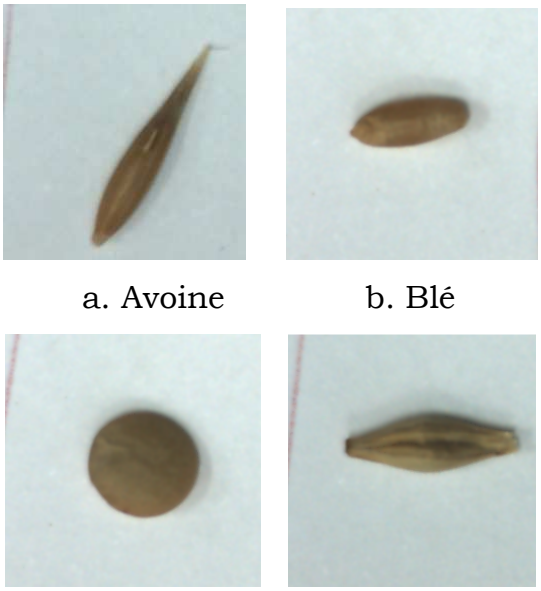

a. Avoine b. Blé

c. Lentille d. Orge

Fig.2 Image des graines acquises

## 3. Le prétraitement

L'étape de prétraitement a pour but de faciliter l'étape de la segmentation en renforçant la ressemblance entre les pixels appartenant à

une même région, ou en accentuant la dissemblance entres les pixels appartenant à des régions différentes. Il existe deux manières de classifier les filtres. Dans la première, on peut trouver des filtres globaux et locaux. Les filtres globaux reposent, essentiellement, sur la manipulation d'histogramme de l'image. Par contre, les filtres locaux traitent l'image, pixel par pixel et les calculs se sur des fenêtres de voisinage. Les filtres linéaires sont habituellement invariants par translation. Ils sont bien adaptés aux problèmes engendrés par des phénomènes linéaires. Leur principal inconvénient est que la réduction du bruit s'accompagne d'un étalement des transitions entre régions. Cet inconvénient peut être remédié par l'utilisation des filtres non linière tels les filtres morphologique, les filtres homomorphiques et filtres d'ordre. Ceux sont ces derniers que nous avons utilisés dans notre application et plus précisément, le filtre médian. Leur principe et de prendre une fenêtre de taille $(2M+1)\times(2N+1)$ pixels, centrée sur le pixel $[i, j]$ d'une image. En numérotant de 1 à $L=(2M+1)\times(2N+1)$ les pixels de cette fenêtre, on définit une liste $a=\{a_k \mid k=1...L\}$, puis on trie les éléments de cette liste par ordre croissant. La sortie de ce filtre est la valeur d'un rang bien spécifié. Avec le filtre médian, comme son nom l'indique, c'est la valeur médiane de la liste qui remplace la valeur du pixel autour duquel est construit le voisinage. Ce filtre est insensible à la présence des valeurs aberrantes. Il est très utilisé dans le cas des perturbations à caractère impulsionnel. De plus, il laisse inchangées les transitions entre régions. En plus de ces propriétés, les calculs sont rapides et se font en temps réel. Les résultats du filtrage sont présentés dans la figure suivante. La figure 3 montre un exemple d'images ayant subi ce filtrage.

a: Image non filtrée b: Image filtrée

Fig.3 Filtre médian

### 3.1. La segmentation des images des graines

Pour travailler sur la partie de l'image correspondant à la graine, il faut isoler la graine du fond. Ceci peut être effectué par des méthodes de seuillag. Dans notre application, nous utilisé la binarisation. Nous avons effectué cette binarisation en utilisant la méthode de Otsu décrite dans le premier chapitre [55]. Rappelons que, à partir de l'histogramme des niveaux de gris, la méthode d'Otsu détermine la valeur du seuil qui minimise la variance intra-classe associée aux deux groupes formés par le fond et par l'objet. La détermination du seuil optimum est obtenue en maximisant le critère $\eta(t)=\frac{\sigma_b^2}{\sigma^2}$ avec $\sigma_w^2$ comme variance d'une classe, $\sigma_b^2$, variance interclasse et $\sigma^2$, variance totale avec: $\sigma^2 = \sum_{i=0}^{n_g-1}(i-\mu)^2 p_i$ où :

$\mu = \sum_{i=0}^{n_g-1} i p_i$ , $p_i = \frac{h_i}{N}$ , $\sigma_b^2 = p_t q(\mu_1-\mu_2)^2$ , $p_t = \sum_{i=0}^{t} p_i$

$q = 1 - p_t$ , $\mu_1 = \frac{\mu-\mu_s}{1-p_t}$ , $\mu_2 = \frac{\mu_s}{p_t}$ et $\mu_s = \sum_{i=0}^{t} i p_i$

Les images de la figure 4 montrent les résultats de segmentation des graines

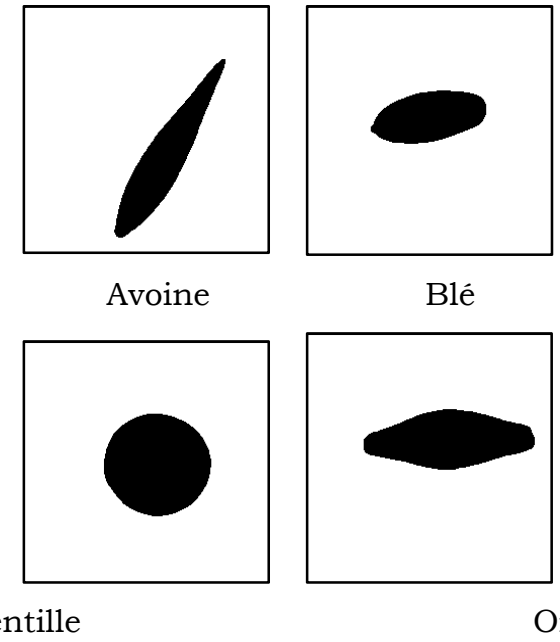

Avoine Blé

Lentille Orge

Fig.4 Image binaire obtenues avec la méthode d'Otsu

### 3.2. L'extraction des contours des graines

La recherche des contours dans une image numérique est un des problèmes les plus étudiés depuis l'origine des travaux sur le traitement d'images. Ceci est en grande partie dû à la qualité intuitive du contour qui apparaît très naturellement comme l'indice visuel idéal dans la reconnaissance de forme. Les contours sont des variations d'intensité dans l'image. Ils constituent les frontières de régions correspondant à des bords ou parties de l'objet présent dans l'image. Il existe plusieurs approches de la détection de contour, des approches surfaciques, morphologiques, et dérivatives. Dans notre application, la détection de contour d'une graine se fait avec le filtre de Canny [56] appliqué à l'image binaire. Ce choix est justifié par ses performances à savoir sa robustesse au bruit, la précision de la localisation du point contour et l'unicité de la réponse par contour. Les images de la figure 5 montrent les contours obtenus pour les images précédentes.

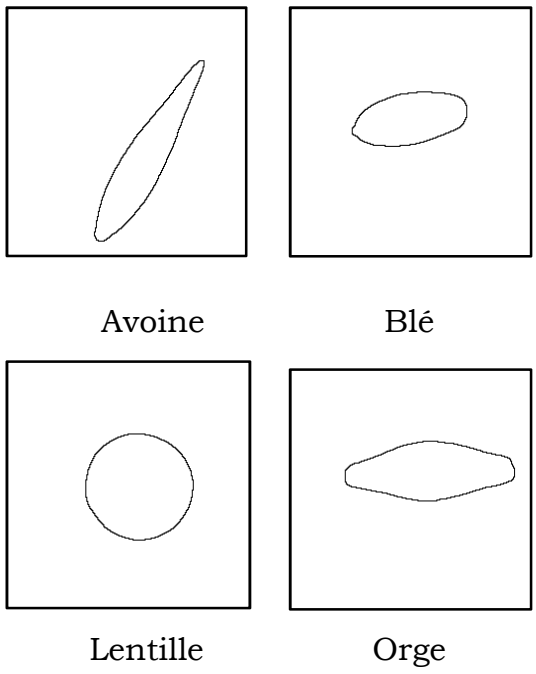


Fig.5 Images-contours des graines obtenues par filtrage de Canny

A partir de ces images des figures 2, 3, 4 et 5, différents paramètres de forme, de couleur et de texture sont calculés en vue de la reconnaissance automatique des graines.

# 4. Reconnaissance à partir des paramètres de forme

La caractérisation d'un objet est une étape très importante dans tout processus de reconnaissance de formes. Habituellement, l'expérience a montré qu'il faut extraire le maximum de paramètres à partir de l'image de l'objet. Le nombre de ces paramètres ne peut être réduit qu'en appliquant une méthode automatique comme, par exemple, l'Analyse en Composantes Principales.

## 4.1. Paramètres de formes

Dans la présente étude, pour caractériser les graines, seuls les paramètres de forme extraits sont présentés. Ainsi, la première catégorie de paramètres calculés est la suivante (fig.6): le périmètre P, la surface S**,** la compacité C, l'axe majeur AA' et l'axe mineur BB'

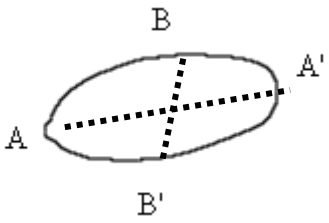


Fig.6 Axes calculés

- *Le périmètre*

C'est le nombre de pixels qui composent le contour de l'objet. Dans la réalité il est donné par la somme des segments de droits reliant les points consécutifs du contour de l'objet. La distance entre deux points A, B de contour de coordonnées $(x_1, y_1)$, $(x_2, y_2)$ respectivement est donnée par la formule suivante .

$$d(A,B) = \sqrt{(x_2 - x_1)^2 + (y_2 - y_1)^2}$$

- *La surface*

La surface d'objet dans une image peut être définie comme étant le nombre de pixels constituant l'image de l'objet.

- *La compacité*

L'attribut compacité mesure la tendance du contour à être un cercle. Elle a une valeur comprise entre 0 et 1, elle prend la valeur 0 pour un segment de droit et la valeur 1 pour un cercle. Elle est définie par :

$$C = 4\pi S / P^2$$

- *l'axe majeur AA'*
- *l'axe mineur BB'*

Ces deux axes sont calculés à partir di centre de gravité G($X_g$ , $Y_g$ ) ou l'axe d'inertie : I($X_I$,$Y_I$) avec :

$$X_g = \sum_{i=1}^{i=N} x_i \Big/ N \qquad \text{et } Y_g = \sum_{i=1}^{i=N} y_i \Big/ N .....$$

$$X_I = \sum_{s=1}^{s=Ns} x_s \Big/ Ns \quad \text{et } Y_I = \sum_{s=1}^{s=Ns} y_s \Big/ Ns.$$

Le tableau 1 donne les valeurs de ces paramètres pour les différents pollens étudiés.

Tableau.1 Exemples de valeurs des paramètres

| | S | P | C | L | AA' | BB' |
|---|---|---|---|---|---|---|
| Avoine | 6128 | 645.00 | 0.18 | 3.52 | 162.35 | 46.34 |
| Blé | 4396 | 457.00 | 0.26 | 2.20 | 110.13 | 50 |
| Lentille | 7865 | 333.00 | 0,87 | 1.15 | 107.51 | 93.13 |
| Orge | 6462 | 371.45 | | 2.93 | 155.01 | 53.07 |

- *La signature polaire*

Puisque tous les contours de graines sont fermés, il est possible de calculer la signature polaire d'une graine à partir du contour de son image. La signature polaire est la courbe $\rho(\theta)$ représentant la distance du centre de gravité *G* du contour aux points de ce contour à chaque angle polaire $\theta$ (fig.7). Le point initial à partir duquel on commence ces calculs est le point le plus éloigné de *G.* Les expressions permettant le calcul de $\rho(\theta)$ et de $\theta$ sont les suivantes :

$$\theta_i = Arctg\left(\frac{y_i - y_G}{x_i - x_G}\right)$$

$$\rho(\theta_i) = \sqrt{(x_i - x_G)^2 + (y_i - y_G)^2}$$

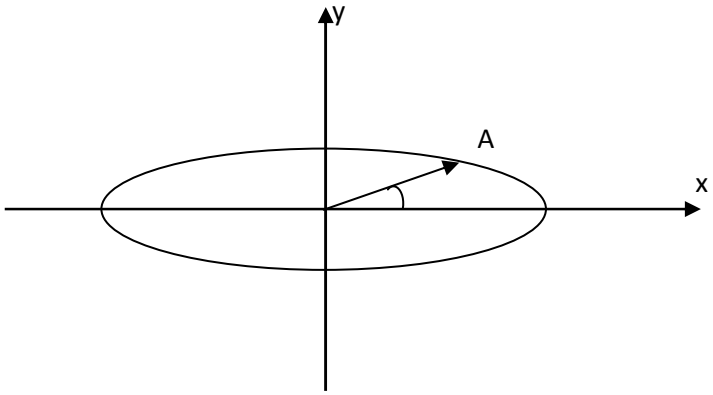


Fig.7 Procédure de calcule de la signature polaire

Les images de la figure 8 nous donnent des exemples de signatures polaires des quatre types de graines.

a) Avoine

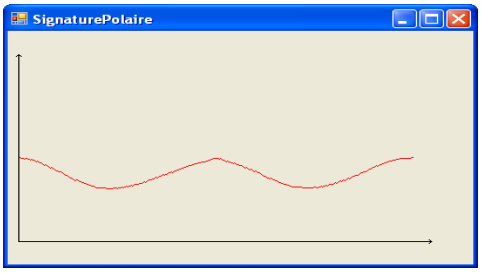


b) Blé

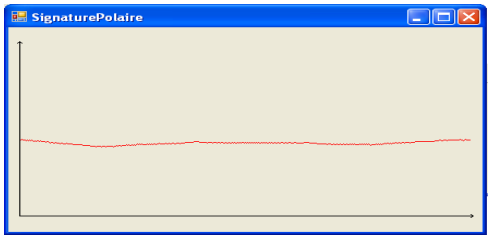


c) Lentille

d) orge

Fig. 3.13 : les signatures polaires obtenues

- *Les moments invariants*

D'autres paramètres invariants de moments ont été ensuite calculés. La formulation générale de ces moments géométriques d'ordre (p+q), dans le cas d'une image numérique, est donnée par l'équation suivante :

$$m_{pq} = \sum_{i=0}^{M-1}\sum_{j=0}^{N-1} i^p j^q f(i,j)\ ;\ \ p,q = 0,1,...,\infty$$

où *M* et *N* sont respectivement les dimensions horizontale et verticale de l'image et *f(i,j),* l'intensité du point *(i, j)* dans l'image.

Le moment d'ordre 0, $m_{00}$ et ceux d'ordre 1, $m_{01}$, *et* $m_{10}$, sont d'utilité limitée puisqu'ils varient à chaque changement de l'origine, de l'échelle et de l'orientation de l'objet. Un ensemble de moments invariants serait, ainsi, plus utile. Ceci peut être effectué en calculant, d'abord, les moments centrés donnés par l'équation:

$$\mu_{pq} = \sum_i \sum_j (i-\bar{x})^p (j-\bar{y})^q f(i,j)$$

où $\bar{x} = \frac{m_{10}}{m_{00}}$ et $\bar{y} = \frac{m_{01}}{m_{00}}$

Ceci nous permet de calculer, ensuite, les moments centrés normalisés en utilisant l'expression:

$$\eta_{pq} = \frac{\mu_{pq}}{s^{\frac{p+q}{2}+1}}\ ;\ \ p+q \geq 2$$

où *S* représente la surface de l'objet.

A partir de ces moments centrés normalisés, nous avons calculé un ensemble de six paramètres invariants par translation, rotation et homothétie pour caractériser la forme des graines. Ces moments invariants sont les suivants :

- *Invariants du second ordre*

$$\Phi_1 = \eta_{20} + \eta_{02}$$

$$\Phi_2 = (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2$$

- *Invariants du troisième ordre*

$$\Phi_3 = (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2$$

$$\Phi_4 = (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2$$

$$\Phi_5 = (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] +$$

$$(3\eta_{21}-\eta_{03})(\eta_{21}+\eta_{03})[3(\eta_{30}+\eta_{12})^2-(\eta_{21}+\eta_{03})^2]$$

$$\Phi_6=(\eta_{20}-\eta_{02})[(\eta_{30}+\eta_{12})^2-(\eta_{21}+\eta_{03})^2]+4\eta_{11}(\eta_{30}+\eta_{12})(\eta_{21}+\eta_{03})$$

$$\Phi_7=(3\eta_{21}-\eta_{03})(\eta_{30}+\eta_{12})[(\eta_{30}+\eta_{12})^2-3(\eta_{21}+\eta_{03})^2]+$$

$$(3\eta_{12}-\eta_{30})(\eta_{21}+\eta_{03})[3(\eta_{30}+\eta_{12})^2-(\eta_{21}+\eta_{03})^2]$$

Le tableau 2 montre des valeurs des ces moments pour les quatre différentes graines.

Tableau.2 Exemples de valeurs (x$10^{-3)}$ des moments

| | $\Phi_1$ | $\Phi_2$ | $\Phi_3$ | $\Phi_4$ | $\Phi_5$ | $\Phi_6$ | $\Phi_7$ |
|---|---|---|---|---|---|---|---|
| Avoine | 0.3344 | 0.0863 | 0.0001 | 8.1553 E-5 | 8.37 E-9 | 2.37 E-5 | 2.00 E-10 |
| Blé | 0.2238 | 0.0247 | 9.65 E-6 | 9.05 E-7 | -1.40 E-14 | -4.25 E-08 | -2.67 E-12 |
| Lentille | 0.1593 | 3.74 E-5 | 2.67 E-6 | 7.44 E-10 | -2.73 E-17 | -3.66 E-12 | 1.89 E-17 |
| Orge | 0.2730 | 0.0489 | 3.95 E-5 | 8.68 E-6 | 1.32 E-10 | 9.52 E-07 | 9.13 -11 |

### 4.2. Réduction des paramètres en utilisant l'ACP

L'application de l'ACP sur l'ensemble de paramètres de la forme nous a révélé que la première composante qui est l'étalement, contient 99% de l'information. La figure 7 suivante montre la projection des graines sur ces deux axes principaux avant l'ACP et la figure 8 après l'ACP.

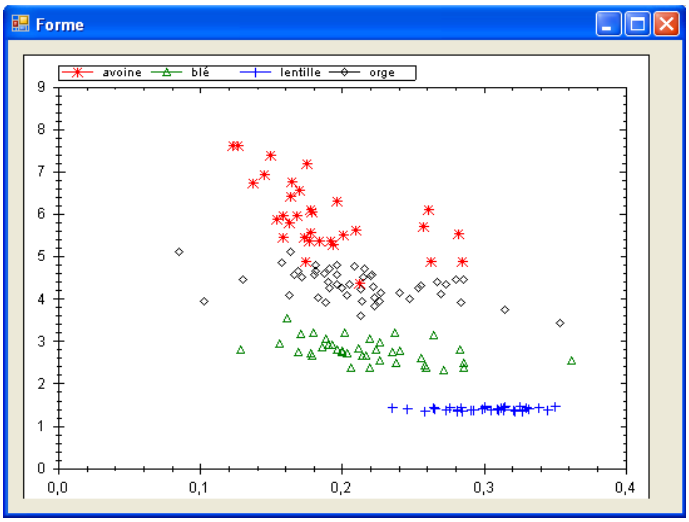


Fig.7 Projection avant l'ACP

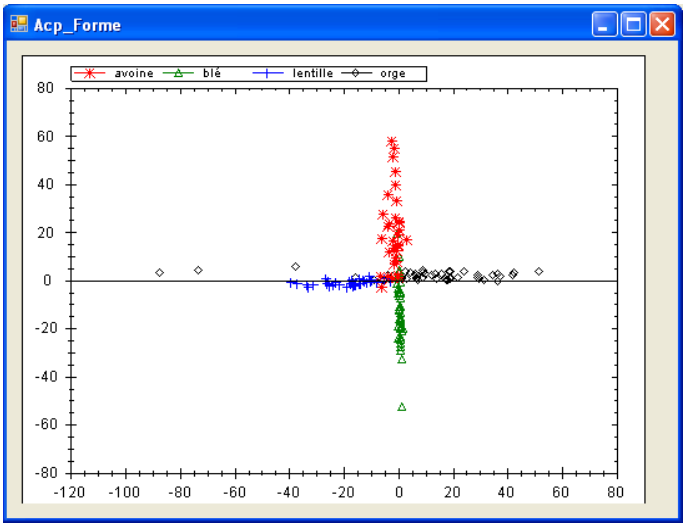


Fig.8 Projection après l'ACP

Le pourcentage d'inertie des composantes principales est présenté par le tableau 3 suivant:

Tableau.3 Pertinence des composantes principales

| Composante | 1 | 2 |
|---|---|---|
| Le pourcentage | 99% | 0.3 |
| Total | 99.3% | |

### 4.3. La classification

La base d'apprentissage est constituée de 100 graines d'avoine, 100 gaines de blé, 100, graines de lentille et 100 graines d'orge. Pour former les classes en présence, nous avons utilisé la méthode des k-means décrite dans le chapitre 1. Les résultats de cette classification sont présentés au tableau 4 suivant :

Tableau.4 Etiquetage de la base d'apprentissage

| | Avoine | Blé | Lentille | Orge | *N=Card(Classe)* |
|---|---|---|---|---|---|
| Classe 1 | 74 | 2 | 0 | 15 | 91 |
| Classe 2 | 0 | 0 | 100 | 0 | 100 |
| Classe 3 | 19 | 7 | 0 | 67 | 93 |
| Classe 4 | 7 | 91 | 0 | 18 | 116 |

En fonction des éléments contenus en grande majorité dans chaque classe, la classe 1 reçoit l'étiquette 'avoine', classe 2, l'étiquette 'lentille', la classe 3, l'étiquette 'orge' et la classe 4, celle du 'blé'.

### 4.4. La reconnaissance de nouvelles graines

En utilisant la même base de test que la modalité précédente et avec la même règle de décision nous obtenons le tableau 5 suivant:

Tableau.5 Matrice de confusion de la modalité forme

| | Avoine | Blé | Lentille | Orge |
|---|---|---|---|---|
| Avoine | 72 | 2 | 0 | 26 |
| Blé | 3 | 93 | 0 | 4 |
| Lentille | 0 | 0 | 100 | 0 |
| Orge | 16 | 21 | 0 | 63 |

Le tableau 6 suivant présente les taux de reconnaissance et de confusion. Le taux de reconnaissance global est de 82%.

Tableau.6 Taux de reconnaissance et de confusion

| | Avoine | Blé | Lentille | orge |
|---|---|---|---|---|
| Taux de reconnaissance | 72% | 93% | 100% | 63% |
| Taux de confusion | 28% | 7% | 0% | 37% |
| Total reconnaissance | 82% | | | |

## 5. Reconnaissance à partir des paramètres de couleur

Comme nous l'avons mentionné dans le premier chapitre, l'image couleur acquise à l'aide d'une caméra numérique est codée sous forme de trois composantes chromatiques Rouge, Vert et Bleu dans l'espace colorimétrique RGB. Un des principaux inconvénients de cet espace est que certaines couleurs peuvent avoir une composante négative et sont donc non représentable en synthèse additive. Sur la base de ces couleurs primaires, plusieurs systèmes de représentation ont vu le jour. L'espace de couleur YCbCr, permet de décorréler la luminance Y des chrominances Cb et Cr. Historiquement, cet espace a été défini pour permettre aux possesseurs

d'un téléviseur en niveaux de gris (composante Y) de continuer à capter les émissions lorsqu'elles ont été émises en couleurs (norme NTSC des télévisions américaines). La formule de passage de l'espace RGB à l'espace YCbCr est donnée par la relation linéaire suivante :

$$\begin{bmatrix} Y \\ C_b \\ C_r \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ -0.169 & -0.331 & 0.500 \\ 0.500 & -0.419 & -0.081 \end{bmatrix} * \begin{bmatrix} R \\ G \\ B \end{bmatrix}$$

On peut constater, par exemple, que la luminance Y est une somme des composantes chromatiques initiales pondérées par des coefficients positifs représentatifs de la sensibilité de l'œil humain aux différentes longueurs d'onde. Les espaces LTS décrivent la couleur à partir de trois attributs de type luminosité, teinte et saturation, fondés sur l'interprétation visuelle. La luminosité L traduit l'aspect clair, foncé ou terne d'une couleur. La teinte T ou tonalité chromatique (en anglais hue) correspond à la longueur d'onde prédominante présente dans la couleur. La saturation S caractérise le côté plus ou moins délavé, pâle ou vif. C'est le degré de mélange de la longueur d'onde prédominante avec le blanc. De nombreux espaces couleurs ont été définis en fonction de ces trois attributs. Ils partitionnent l'espace couleur selon un pas de discrétisation arbitrairement fixé. Par exemple, le système HSV (teinte, saturation, luminosité) fournit une représentation géométrique de la couleur en forme de cône de révolution inversé, posé sur sa pointe (Fig.9). A la base de ce cône (donc en haut sur la figure) se situe l'information sur la teinte et la saturation, alors que l'axe du cône repère la luminosité. La teinte est exprimée en degrés ou en valeurs normalisées entre 0 et 100%. Les distances entre deux points représentatifs de deux couleurs différentes dans les espaces RVB, YCbCr ou HSV sont très différentes des distances perçues par un observateur standard. Pour remédier cet inconvénient, la CIE (Compagnie Internationale de l'Eclairage) a défini l'espace L*a*b*, très utilisé en analyse sensorielle. Contrairement à l'espace HSV, construit directement à partir de la représentation RGB, l'espace L*a*b* utilise un espace Intermédiaire (l'espace XYZ), qui nécessite un étalonnage du point blanc de l'ensemble constitué par le capteur et l'illuminant. Cet étalonnage,

difficile à réaliser en pratique, ne serait pas applicable dans le cas du système de reconnaissance de formes que nous avons développé.

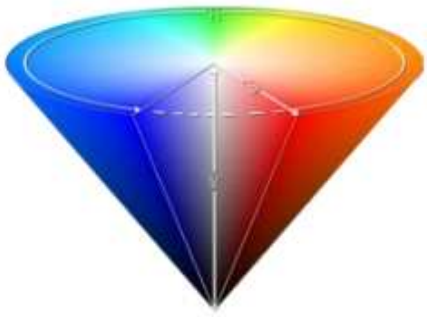

Fig.9 Espace de représentation HSV

### 5.1. Choix des paramètres

Le choix d'un espace de représentation n'est pas évident. En effet, chaque espace présente des avantages et des inconvénients. L'espace RGB est évidemment intéressant dans la mesure où il est directement obtenu par les caméras, mais il présente une corrélation entre les composantes, ce que nous conduit à s'éloigner de lui. L'espace YCbCr a l'avantage de faire apparaître une composante de luminance qui peut être informative mais il est juste une transformation linéaire de l'espace RGB. L'espace HSV a comme avantage de décomposer la couleur selon la teinte, la saturation et la luminance ce qui permet une analyse de l'aspect des objets proches de celle que pourrait effectuer un observateur expert. Ainsi, dans notre travail, nous avons opté pour cet espace de couleur que l'on peut l'obtenir directement en effectuant une transformation non linéaire à l'espace RGB, exprimée par les expressions suivantes :

$$V = \max(R,V,B), \quad S = \frac{V - \min(R,V,B)}{V}$$

$$H = \begin{cases} \dfrac{G-B}{V - \min(R,V,B)} & si \quad V = R \\ 2 + \dfrac{B-R}{V - \min(R,V,B)} & si \quad V = G \\ 4 + \dfrac{R-G}{V - \min(R,V,B)} & si \quad V = B \end{cases}$$

L'espace colorimétrique étant choisi, les paramètres habituellement utilisés dans ce cas sont la moyenne et la variance qui caractérise la

dispersion des niveaux de gris autour de la moyenne. La fréquence relative d'un niveau de gris $k$ étant notée $p(k)$ les expressions permettant le calcul de la moyenne $S_m$ et la variance $S_v$ sont respectivement les suivantes:

$$s_m = \sum_{k=0}^{255} kp(k)$$

$$s_v = \sum_{k=0}^{255} (k - s_m)^2 p(k)$$

La figure 10 montre les histogrammes de chaque type de graines selon les trois composantes (teinte, saturation et luminance)

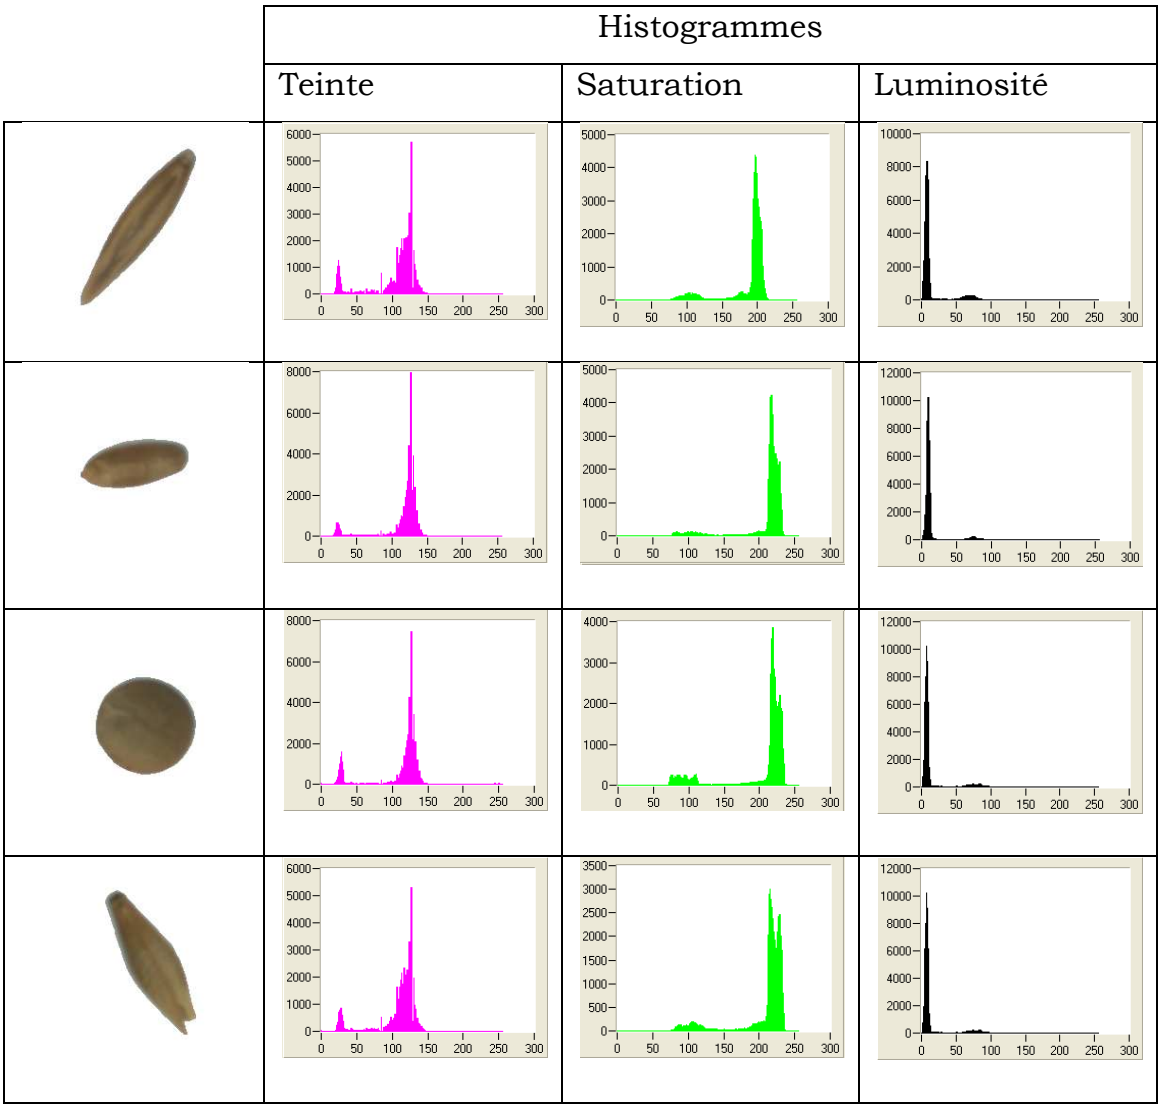


Fig.10 Histogrammes de couleur des graines

Les valeurs de paramètres de la couleur sont présentées par le tableau 7.

Tableau 7 moyenne et variances des selon les composantes de la couleur

| | Moyenne | | | Variance | | |
|---|---|---|---|---|---|---|
| | V | S | H | V | S | H |
| Avoine | 195.06 | 238.70 | 152.04 | 43.77 | 45.70 | 16.80 |
| Blé | 202.09 | 244.03 | 142.49 | 36.98 | 39.43 | 12.27 |
| Lentille | 191.17 | 231.84 | 137.03 | 51.33 | 56.44 | 19.81 |
| Orge | 197.37 | 239.86 | 141.63 | 43.22 | 44.67 | 14.20 |

## 5.2. Réduction des paramètres en utilisant l'ACP

Il est utile d'appliquer l'ACP à ces paramètres de couleur aux paramètres de la modalité couleur. La figure 11 montre la projection des graines sur ces deux axes principaux avant l'ACP et la figure 12 la projection après l'ACP.

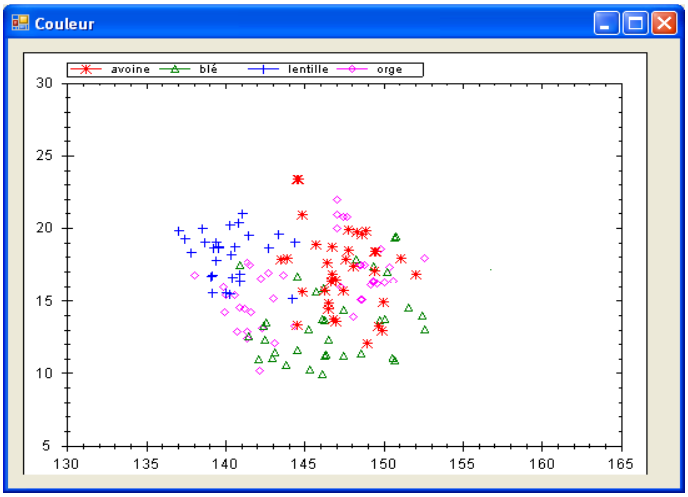


Fig. 11 Projection avant l'ACP

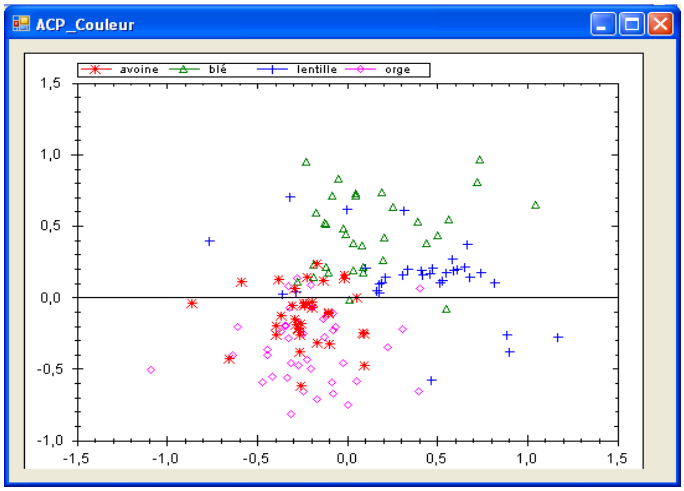


Fig.12 Projection après l'ACP

Pourcentage d'inertie des composantes principales est présenté par le tableau suivant :

Tableau.8 Pertinence de deux premières composantes principales

| Composante | 1 | 2 |
|---|---|---|
| % | 76% | 20% |
| Total | 96% | |

### 5.3. La classification

La base d'apprentissage est constituée de 100 graines d'avoine, 100 gaines de blé, 100, graines de lentille et 100 graines d'orge. Nous avons appliqué l'algorithme de k-means sur cette base. Cette opération est suivie d'étiquetage. Les résultats obtenus sont présentés dans le tableau 9.

Tableau.8 Etiquetage de la base d'apprentissage

| | Avoine | Blé | Lentille | Orge | *N=Card(Classe)* |
|---|---|---|---|---|---|
| Classe 1 | 48 | 20 | 14 | 28 | 110 |
| Classe 2 | 9 | 7 | 73 | 11 | 100 |
| Classe 3 | 27 | 12 | 10 | 43 | 92 |
| Classe 4 | 16 | 61 | 3 | 18 | 98 |

La classe 1 contient 48 graines d'avoine, 20 de blé, 14 de lentille et 28 d'orge. Comme elle contient plus d'avoine que les autres types de graine, l'étiquette «avoine » lui est attribuée. Il est de même pour les autres.

### 5.4. La reconnaissance de nouvelles graines

En utilisant la même base de test que la modalité précédente et avec la même règle de décision nous obtenons le tableau 9 suivant:

Pour la reconnaissance, il s'agit d'assigner les graines inconnues acquises par la camera en temps réel à une classe par le calcul de distances de entre le vecteur de paramètres de cette graine et les centres de gravité des quatre classes de graines. La graine est affectée à la classe correspondant à la distance la plus faible. Cette opération a donné les résultats présentés dans le tableau 9.

Tableau.9 Matrice de confusion de la modalité couleur

| | Avoine | Blé | Lentille | Orge |
|---|---|---|---|---|
| Avoine | 46 | 17 | 12 | 25 |
| Blé | 22 | 58 | 2 | 18 |
| Lentille | 15 | 4 | 71 | 10 |
| Orge | 16 | 21 | 11 | 42 |

Le tableau 10 présente les performances de l'identification avec les paramètres de la modalité couleur.

Tableau.10 Taux de reconnaissance et de confusion

| | Avoine | Blé | Lentille | orge |
|---|---|---|---|---|
| Taux de reconnaissance | 46% | 58% | 71% | 42% |
| Taux de confusion | 54% | 42% | 29% | 58% |
| Total reconnaissance | 54.25% | | | |

## 6. Reconnaissance à partir des paramètres de texture

La texture correspond à la variation locale de la couleur ou des niveaux de gris. Sa caractérisation peut se faire par des méthodes fréquentielles, structurelles ou statistiques. Les méthodes fréquentielles reposent typiquement sur la transformation de Fourier bidimensionnelle ou sur la transformation en ondelettes. Elles engendrent une charge de calcul importante, même en utilisant des algorithmes rapides. Les méthodes structurelles, qui appartiennent au domaine de la description syntaxique, sont basées sur la construction d'adjacences définissant les liaisons entre les différentes zones de couleurs homogènes. Elles reviennent à considérer que l'image est formée de motifs répétitifs appelés primitives. Elles ne sont applicables que pour les images présentant une structure très organisée formée d'éléments très semblables. Les méthodes fréquentielles ou structurelles ne conviennent pas pour l'analyse des graines en raison de la grande variabilité de la texture qu'on observe sur les différentes types et à l'intérieur d'une même graine. Selon [57] les méthodes statistiques sont plus appropriées pour l'intégration dans un module de caractérisation d'objets. Il existe trois méthodes statistiques,

parmi les plus universellement utilisées : la méthode des différences de niveaux de gris, les matrices de cooccurrences et les matrices de longueurs de plages. Dans notre application nous avons opté pour les matrices de cooccurrences. Notons $MC_t(a,b)$ le nombre d'occurrences de couples de pixels de niveaux de gris respectivement $a$ et $b$, séparés par le vecteur de translation $t$. Ce vecteur de translation est une relation géométrique qui relie les niveaux de gris $a$ et $b$ définie avec un pas et une direction. Pour une image quantifiée sur $L$ niveaux de gris, la matrice de cooccurrence est carrée et d'une dimension $L \times L$. Ainsi que la taille d'une matrice de cooccurrence est proportionnelle au nombre de niveaux de gris de la texture. Pour $L$ = 256, il faudrait donc des matrices carrées de taille 256×256. De plus, il faut considérer une matrice par vecteur de translation, ce qui entraîne un nombre assez élevé de descripteurs de texture. Plusieurs paramètres peuvent être calculés à partir de ces matrices de cooccurrences. Nous présentons les paramètres les plus fréquemment utilisés et sous forme normalisée, c'est-à-dire leurs valeurs comprises entre 0 et 1.

### 6.1. Calcul des paramètres

Si $N_C$ est le nombre total d'occurrences, ces paramètres sont :

- *L'homogénéité H*

$$H = \frac{1}{N_C^{\,2}} \sum_{a}^{L-1} \sum_{b}^{L-1} (MC_t(a,b))^2$$

Ce paramètre est d'autant plus élevé que l'on retrouve souvent le même couple de pixels, ce qui est le cas quand il y a une périodicité selon le vecteur de translation.

- *Le contraste CONT*

$$CONT = \frac{1}{N_c (L-1)^2} \sum_{k=0}^{L-1} k^2 \sum_{|a-b|=k} MC_t(a,b)$$

Ce paramètre correspond à la notion du contraste. Il est élevé quand les éléments éloignés de la diagonale de la matrice de cooccurrence sont suffisamment grands, c'est-à-dire quand on passe d'un pixel très foncé vers un pixel très clair ou inversement.

- *L'entropie ENT*

$$ENT = 1 - \frac{1}{N_C . In(N_C)} \sum_a \sum_b MC_t(a,b).In(MC_t(a,b)).1_{MC_t(a,b)}$$ où :

$$1_{MC_t(a,b)} = \begin{cases} 1 & si \quad MC_t(a,b) \neq 0 \\ 0 & si \quad non \end{cases}$$

L'entropie présente un indice du désordre que peut exister dans une texture. Elle est faible si on a souvent le même couple de pixels, forte si chaque couple est peu présenté.

- *La corrélation Corr*

$$Corr = \frac{1}{N_C . \sigma_x . \sigma_y} \left| \sum_a \sum_b (a - m_x)(b - m_y) MC_t(a,b) \right|$$

avec : $m_x = \frac{1}{N_C} \sum_a \sum_b a MC_t(a,b)$

$$m_y = \frac{1}{N_C} \sum_a \sum_b b MC_t(a,b)$$

$$\sigma_x^{\,2} = \frac{1}{N_c} \sum_a \sum_b (a - m_x)^2 MC_t(a,b)$$

$$\sigma_y^{\,2} = \frac{1}{N_C} \sum_a \sum_b (b - m_b)^2 MC_t(a,b)$$

*où* $m_x$ est la moyenne pondérée des lignes de $MC_t(a,b)$, $m_y$ est la moyenne pondérée des colonnes, $\sigma_x$, la variance des lignes et $\sigma_y$, la variance des colonnes.

- *L homogénéité locale*

$$HL = \frac{1}{N_C} \sum_a \sum_b \frac{1}{1 + (a+b)^2} MC_t(a,b)$$

- *La directivité*

$$Dir = \frac{1}{N_C} \sum_a MC_t(a,a)$$

La directivité est importante si la texture présente des pixels de même niveau de gris selon le vecteur de translation.

- *L'uniformité*

$$Unif = \frac{1}{N_C{}^2} \sum_a MC_t{}^2(a,a)$$

L'uniformité est importante lorsque la texture présente un niveau de gris qui apparaît souvent selon le vecteur de translation.

Un exemple de valeurs obtenues est présenté au tableau suivant 11.

Tableau.11 Valeurs des paramètres de texture

| | H | Con | Ent | Corr | HL | Dir | Unif |
|---|---|---|---|---|---|---|---|
| Avoine | 0,5090 | 0,0908 | 0,9482 | 0,9693 | 0,9387 | 0,5178 | 0,6840 |
| Blé | 0,8069 | 0,0427 | 0,9887 | 0,9935 | 0,9870 | 0,8069 | 0,6959 |
| Lentille | 0,5965 | 0,0840 | 0,9825 | 0,9814 | 0,9628 | 0,5962 | 0,6926 |
| Orge | 0,6963 | 0,0750 | 0,9796 | 0,9824 | 0,9649 | 0,6662 | 0,6874 |

## 6.2. Réduction des paramètres en utilisant l'ACP

En appliquant l'ACP à l'ensemble de paramètres de la modalité texture, nous obtenons la projection de la figure 13 sur deux axes principaux avant l'application de l'ACP et la figure 14, après.

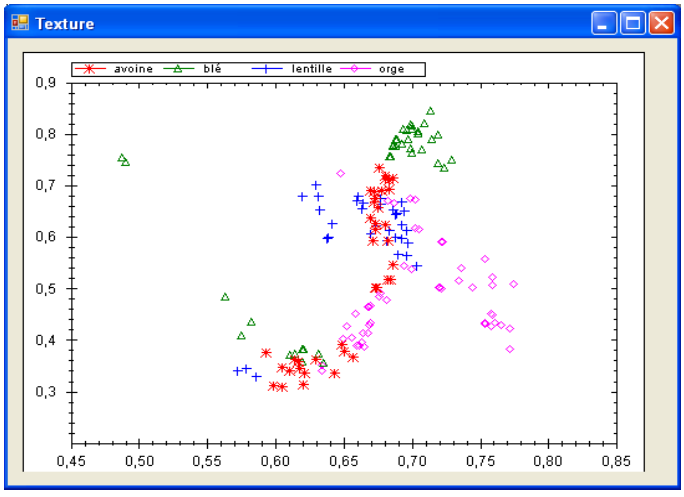


Fig.13 Projection avant l'ACP

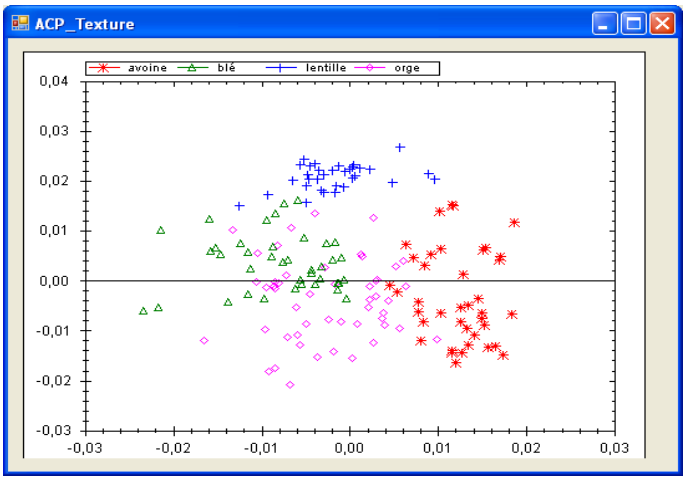


Fig.14 Projection après l'ACP

Le pourcentage d'inertie des composantes principales est présenté par le tableau 12.

Tableau.12 Pertinence des deux composantes principales de texture

| Composante | 1 | 2 |
|---|---|---|
| % | 95%% | 1.74% |
| Total | 96.74% | |

### 6.3. La classification

La base d'apprentissage est toujours la même que les autres. Après le k-means, c'est l'étiquetage, voici les éléments de chaque classe présentés par le tableau 13.

Tableau.12 Etiquetage de la base d'apprentissage

| | Avoine | Blé | Lentille | Orge | *N=Card(Classe)* |
|---|---|---|---|---|---|
| Classe 1 | 23 | 48 | 6 | 23 | 100 |
| Classe 2 | 9 | 5 | 64 | 3 | 81 |
| Classe 3 | 41 | 14 | 19 | 31 | 105 |
| Classe 4 | 27 | 33 | 11 | 43 | 114 |

Les étiquettes des classes sont : classe 1 :'blé', classe 2 : 'lentille', classe 3 : 'avoine' et classe 4 : 'orge'.

### 6.4. La reconnaissance de nouvelles graines

En réalisant les mêmes opérations sur la même base de test, en utilisant les paramètres de la texture, on obtient les résultats présentés par le tableau 13.

Tableau.13 Matrice de confusion de la modalité texture

| | Avoine | Blé | Lentille | Orge |
|---|---|---|---|---|
| Avoine | 51 | 6 | 9 | 34 |
| Blé | 17 | 61 | 7 | 15 |
| Lentille | 5 | 4 | 64 | 27 |
| Orge | 14 | 20 | 18 | 48 |

Le tableau 14 présente les performances de l'identification avec les paramètres de la texture.

Tableau.14 Taux de reconnaissance et de confusion

| | Avoine | Blé | Lentille | orge |
|---|---|---|---|---|
| Taux de reconnaissance | 51% | 61% | 64% | 48% |
| Taux de confusion | 49% | 39% | 36% | 52% |
| Total reconnaissance | 56% | | | |

# 7 La fusion à l'aide théorie de Dempster-Shafer

Dans notre application, nous choisi de combiner les résultats avec la théorie de Dempster-Shafer, car elle présente certaines performances, que nous avons cités dans la chapitre précédent.

## 7.1 Définition des espaces de discernement

Dans notre application nous avons 4 classes. Ainsi, Ω = {avoine, blé, lentille, orge}.

$2^{\Omega}$ = {ф,{avoine},{blé},{lentille},{orge},{avoine, blé},{avoine, lentille},{avoine, orge},{blé, lentille},{blé, orge},{lentille, orge},{avoine, blé, lentille},{avoine, blé, orge},{avoine, lentille, orge}, {blé, orge, lentille}, {avoine, blé, lentille, orge}.}.

## 7.2. La modélisation de la fonction de croyance

La fonction de croyance que nous avons développée repose essentiellement sur la prise en compte des erreurs identification de trois méthodes (couleur, forme et texture), donc notre modèle exploite la matrice de confusion. De plus ce modèle doit respecter les conditions citées en section 4.1. Dans notre modèle, nous intéressons uniquement

aux éléments singletons. D'autre part, les éléments multiples auront une fonction de croyance nulle. À partir des résultats de tests obtenus pour chaque méthode (tableaux 5, 6 et 13), nous calculons, pour chaque méthode, une sortie de type mesure. Les trois tableaux 15, 16 et 17 présentent les valeurs des fonctions de masse pour chaque méthode.

Tableau.15 Les fonctions de masse de la modalité forme

| $2^{\Omega}$ | Avoine | Blé | Lentille | Orge |
|---|---|---|---|---|
| Φ | 0 | 0 | 0 | 0 |
| {avoine} | 0.72 | 0.03 | 0 | 0.16 |
| {blé} | 0.02 | 0.93 | 0 | 0.21 |
| {lentille} | 0 | 0 | 1 | 0 |
| {orge} | 0.26 | 0.04 | 0 | 0.63 |
| {avoine, blé} | 0 | 0 | 0 | 0 |
| {avoine, lentille} | 0 | 0 | 0 | 0 |
| {avoine, orge} | 0 | 0 | 0 | 0 |
| {blé, lentille} | 0 | 0 | 0 | 0 |
| {avoine, blé, lentille} | 0 | 0 | 0 | 0 |
| {avoine, blé, orge}, | 0 | 0 | 0 | 0 |
| {avoine, lentille, orge}, | 0 | 0 | 0 | 0 |
| {blé, orge, lentille}, | 0 | 0 | 0 | 0 |
| {avoine, blé, lentille, orge}. | 0 | 0 | 0 | 0 |
| $\sum m(.)$ | 1 | 1 | 1 | 1 |

Tableau.16 Les fonctions de masse de la modalité couleur

| $2^{\Omega}$ | Avoine | Blé | Lentille | Orge |
|---|---|---|---|---|
| Φ | 0 | 0 | 0 | 0 |
| {avoine} | 0.46 | 0.22 | 0.15 | 0.16 |
| {blé} | 0.17 | 0.58 | 0.04 | 0.21 |
| {lentille} | 0.12 | 0.02 | 0.71 | 0.11 |
| {orge} | 0.25 | 0.18 | 0.10 | 0.42 |
| {avoine, blé} | 0 | 0 | 0 | 0 |
| {avoine, lentille} | 0 | 0 | 0 | 0 |
| {avoine, orge} | 0 | 0 | 0 | 0 |
| {blé, lentille} | 0 | 0 | 0 | 0 |
| {avoine, blé, lentille} | 0 | 0 | 0 | 0 |
| {avoine, blé, orge}, | 0 | 0 | 0 | 0 |
| {avoine, lentille, orge}, | 0 | 0 | 0 | 0 |
| {blé, orge, lentille}, | 0 | 0 | 0 | 0 |
| {avoine, blé, lentille, orge}. | 0 | 0 | 0 | 0 |
| $\sum m(.)$ | 1 | 1 | 1 | 1 |

Tableau.17 Les fonctions de masse de la modalité texture

| | La sortie | | | |
|---|---|---|---|---|
| $2^{\Omega}$ | Avoine | Blé | Lentille | Orge |
| Φ | 0 | 0 | 0 | 0 |
| {avoine} | 0.51 | 0.17 | 0.05 | 0.14 |
| {blé} | 0.06 | 0.61 | 0.04 | 0.20 |
| {lentille} | 0.09 | 0.07 | 0.64 | 0.18 |
| {orge} | 0.34 | 0.15 | 0.27 | 0.48 |
| {avoine, blé} | 0 | 0 | 0 | 0 |
| {avoine, lentille} | 0 | 0 | 0 | 0 |
| {avoine, orge} | 0 | 0 | 0 | 0 |
| {blé, lentille} | 0 | 0 | 0 | 0 |
| {avoine, blé, lentille} | 0 | 0 | 0 | 0 |
| {avoine, blé, orge}, | 0 | 0 | 0 | 0 |
| {avoine, lentille, orge}, | 0 | 0 | 0 | 0 |
| {blé, orge, lentille}, | 0 | 0 | 0 | 0 |
| {avoine, blé, lentille, orge}. | 0 | 0 | 0 | 0 |
| $\sum m(.)$ | 1 | 1 | 1 | 1 |

### 7.3. La décision

La décision est faite selon le maximum de plausibilité.

### 7.4. Les résultats de la fusion

Les tests sont toujours effectués avec la base de 100 graines pour chaque type. Les tableaux 18 et 19 montrent les résultats de cette fusion.

Tableau.18 Reconnaissance après la fusion

| | Avoine | Blé | Lentille | Orge |
|---|---|---|---|---|
| Avoine | 76 | 9 | 0 | 15 |
| Blé | 3 | 93 | 0 | 4 |
| Lentille | 0 | 0 | 100 | 0 |
| Orge | 14 | 21 | 0 | 65 |

Tableau.19 Performances après la fusion

| | Avoine | Blé | Lentille | orge |
|---|---|---|---|---|
| Taux de reconnaissance | 76% | 93% | 100% | 65% |
| Taux de confusion | 24% | 7% | 0% | 35% |
| Total reconnaissance | 83.5% | | | |

## 8. Conclusion

Dans ce chapitre, nous avons mis en œuvre un système d'identification automatique des graines. En fusion trois méthode d'identification automatique, chacune d'elle utilise une modalité différente de l'autres, les modalités que nous avons utilisé sont la couleur, la forme et la texture. Nous avons appliqué les mêmes modules d'acquisition, prétraitement et traitement pour les trois méthodes. L'étape d'acquisition des images, où le choix du matériel à utilisés comme la camera et la carte d'acquisition dépend essentiellement de l'application. La partie prétraitement et la partie segmentation d'image sont un peu du classique, le filtre médian a éliminé pratiquement les bruits dans les images acquises par la camera. Nous avons remarqué la perfection de la méthode d'Otsu qui présente une segmentation excellente, avec cette dernière et en utilisant le filtre de Canny, nous avons obtenu facilement les contours des graines dans les images. La réduction des paramètres est faite par analyse en composante principale (ACP), cette méthode et gourmande en question de temps. Nous avons renforcé l'algorithme de k-means par une initialisation par les formes forte, qui nous ramène à une stabilité rapide et une meilleure répartition des graines dans la base d'apprentissage. Par contre la décision c'est à dire l'identification des est faite par la minimale distance euclidienne calculée entre la graine à identifier et les centres finals des calasses de la base d'apprentissage. Ces trois dernières étapes sont appliquées pour les trois méthodes. Nous avons calculé la moyenne et la variance des pixels de l'objet dans l'espace VSH pour la méthode de couleur, l'ACP a montré que la moyenne et la variance de la luminance sont les deux composantes principales de ces paramètres avec une précision de 96%. Cette méthode identifie une minière plus ou moins satisfaisante les graines de lentille avec un taux de reconnaissance de 71%, et moyennement satisfaisante pour le blé (58%), mais on retrouve beaucoup de confusion entre l'avoine, l'orge et le blé, son taux de reconnaissance total est de 54.25%, qui ne présente pas d'intérêt pratique. Les paramètres de la méthode de la forme sont calculés à partir de l'image binaire et l'image contour des graines, l'étalement et la

compacité sont deux résultats de l'ACP avec une précision de 99.3%. Cette méthode identifie à 100% les graines de lentille, à 93% les graines de blé, l'avoine à 72% et l'orge à 63%, cette méthode présente une légère confusion entre l'orge et l'avoine dû à la ressemblance morphologique entre les deux espèces, aux total elle présente une performance de 82%. Pour la méthode de la texture, nous avons utilisé beaucoup de statistique, mais l'ACP a réduit l'ensemble des paramètres à deux avec une précision de 96.74%. Cette méthode présente une confusion entre toutes les espèces de graine, nous avons des taux de reconnaissance qui n'ont aucun intérêt pratique, ce résultat est dû à essentiellement ressemblance des textures des graines. Dans le but d'avoir un seul système avec des performances supérieures, nous avons appliqué la théorie de Dempster-Shafer pour fusionner les identifications des trois méthodes. Cette théorie repose sur le calcul des fonctions de masse, pour cela, les taux de reconnaissance de chaque méthode sont utilisés. Nous avons misé uniquement sur les éléments singletons de cadre de discernement, pour des raisons pratiques. Les performances de l'indentification avec la fusion sont de 76% pour l'avoine, 93%, pour le blé, 100% pour lentille et 65% pour l'orge, il y a une amélioration par apport à la méthode de couleur et la méthode de texture, mais juste une légère amélioration par apport à celle de la forme.

# Conclusion Générale

La reconnaissance des formes est un domaine de recherche qui, aujourd'hui, donne lieu à de nombreuses études et à des approches très diverses. Dans cette problématique, nous nous sommes plus particulièrement intéressés à l'approche statistique et aux méthodes de la classification automatique.

Nous avons commencé notre étude par les principes de la reconnaissance de formes et à leurs applications, et nous avons présenté et distingué trois types de systèmes de reconnaissance de forme (généraux, dédiés et industriels). De plus, les deux constatations suivantes ont étés dégagées :

– il existe toujours, à l'heure actuelle, des besoins importants en termes de système de reconnaissance de formes. Cela est vrai d'une façon générale, mais aussi pour des domaines plus précis comme celui de l'industrie.

– l'échec de la plupart des systèmes de reconnaissance de formes pour aboutir aux performances souhaitées. Du fait que ces systèmes sont confrontés à des situations délicates de traitement ou d'identification.

Ces constatations nous ont motivé à suivre la démarche de fusion de décisions. Dans ce contexte, la seconde partie du travail a concerné l'analyse des travaux existant dans le domaine. Nous avons limité notre étude à l'approche parallèle qui est adaptée au temps réel et qui distingue principalement deux grandes familles. Les méthodes de combinaison avec apprentissage et les méthodes sans apprentissage et chacune se divise en trois groupes, selon le type de sortie des méthodes de classification à combiner. Particulièrement nous avons mis met l'accent sur la méthode de Dempster-Shafer. L'étude bibliographique de ces méthodes de combinaison nous a permis de dégager les différentes caractéristiques de chacune de ces

méthodes. Cette étude nous a permis de fusionner trois méthodes de classification reconnaissance de formes basées sur des modalités différentes (couleur, forme et texture) des images de graines. Cette fusion a été réalisée avec la théorie de Dempster-Shafer. L'identification de chaque méthode a été exploitée pour élaborer une fonction de masse qui la clé de la combinaison avec cette théorie. Les performances obtenues avec cette combinaison ont donné des taux reconnaissance nettement améliorés par à ceux obtenus par chaque méthode utilisée séparément. Malgré tout, ces résultats ne sont pas très satisfaisants, ce qui ouvre des perspectives tel que

- renforcer les méthodes de classification en utilisant autres algorithmes de classification automatiques plus sophistiqués.
- utiliser d'autres méthodes qui se basent sur d'autres paramètres, et ayants des structures hétérogènes.
- perfectionner les modèles de fonction de masse et améliorer la prise de décision pour la théorie de Dempster-Shafer.

[1] M. Diaf. Méthodes de décision en reconnaissance de formes, traitement d'image et en ophtalmologie. Thèse Doctorat, UMMTO, 1994.

[2] J.-P. COCQUEREZ et S. PHILIPP. Analyse d'images : filtrage et segmentation. Edition : MASSON, chapitre IV.

[3] J.-P. COCQUEREZ et S. PHILIPP. Analyse d'images : filtrage et segmentation. Edition : MASSON, chapitre X.

[4] J.-P. COCQUEREZ et S. PHILIPP. Analyse d'images : filtrage et segmentation. Edition : MASSON, chapitre XI.

[5] P. SCHWARTZ. Méthodes des contours actifs, revue Developpez.NET, 2005.

[6] S.Mavromatis. analyse d'images, Détection de contour, cours.

[7] M. K. Hu. "Visual pattern Recognition by Moment Invariant", IRE Transaction on Information Theory, IT-8:179-187, 1962.

[8] Desiree M. Leonard. Analysis of object in bianry images. Technical report, NASA, 1991.

[9] Markus A. Stricker andM. Orengo. Similarity of color images. In Ramesh C. JainWayne Niblack, editor, Proc. of Storage and Retrieval for Image Video Databases III, volume 2420, pages 381–392. SPIE, mars 1995.

[10] Greg Pass, Ramin Zabih, and Justin Miller. Comparing images using color coherence vectors. In ACM International Multimedia Conference, pages 65–73, 1996.

[11] M. Unser. Texture classification and segmentation using wavelet frames. IEEE Trans. on Image Processing, 4 :1549–1560, novembre 1995.

[12] A. Gagalowicz. Vers un modèle de texture. PhD thesis, Universit´e Pierre et Marie Curie, Paris VI, 1983.

[13] K. Hammouche. Méthodes de classification automatique utilisant les paramètres de texture. Thèse Doctorat, UMMTO, 2007.

[14] J. RACHEDI, « *Reconnaissance et classification de phonèmes*» Mémoire pour le Master Sciences et Technologie de l'UPMC, Août 2005.

[15] J.B. MacQueen, Some methods for classification and analysis of multivariate observations. Proceedings Symp. Math. Statist. And probability (5th ), Berkley, 1, pp. 281-297,University of Californie. Press, Berkley, 1967.

[16] Anil K. Jain, Fellow, Statistical Pattern Recognition: A Review, IEEE TRANSACTIONS ON PATTERN ANALYSIS AND MACHINE INTELLIGENCE, VOL. 22, NO. 1, JANUARY 2000

[17] A. LUX, Algorithme et contrôle en vision par ordinateur, thèse, 1985.

[18] Y. SHIRAI, Recognition of real world objects using edge cues, CVS, p.53-362, 1978.

[19] Tenenbaum, J. M. et Barrow, H.G. Experimentation in interpretation-guided segmentation, Artificial Intelligence V8, p.241-274.

[20] V. Govindan and A. Shivaprasad. Character recognition - a survey. PatternRecognition, 23(7) :671-683, 1990.

[21] T. Steinherz, E. Rivlin, and N. Intrator. O-line cursive script word recognition : A survey. International Journal of Document Analysis and Recognition, 2(2) :90110, 1999.

[22] Perkins, W. A. A model based vision system for industrial parts, IEEE trasaction on computer, vol. C-27, 2, p. 126-143.

[23] T.M. Cover et P.E. Hart. Nearest neighbor pattern classification.

[24] P. Barbe et M. Ledoux. Probabilit´e, de la licence `a l'agr´egation. Belin, 1998.

[25] C.SAINT-JEAN »*Classification paramétrique robuste partiellement supervisée on reconnaissance de forme*» thèse de doctorat, université de la rochelle, 2001.

[26] Nikhil R Pal, Pattern Recognition in Soft Computing Paradigm volume I, edition: World Scientific, USA, 2001.

[27] Sung-Bae Cho (Yonsel University, Korea), Practical Applications of Soft Computing in Engineering, edition: World Scientific, USA, 2004.

[28] N. RAGOT. Reconnaissance de forme par modélisation mixte intrinsèque/discriminante. Thèse, 2003.

[29] L. HEUTTE, Combinaison de Classifieurs, Méthodes pour la Construction d'Ensembles de Classifieurs. Cours.

[30] L. HEUTTE, Combinaison de Classifieurs, Méthodes parallèles. Cours.

[31] M. Condorcet, Essai sur l'application de l'analyse à la probabilité des décisions rendues à la pluralité des voix. Paris.1785.

[32] Cohn, D. et Atlas, L., Improving generalization with active learning. Machine Learning, 15(2):201-221. 1994.

[33] L. Xu, et All, Methods of combining multiple classifiers and their applications to handwriting recognition. IEEE Transactions on Systems, Man, and Cybernetics, 22(3):418-435. 1992.

[34] A theory of multiple classifier systems and its application to visual word recognition. PhD thesis, Department of Computer Science, Suny at Buffalo, New York. 1992.

[35] J. Parker. Multiple/parallel hand printed digit recognition. Vision Interface. 1997.

[36] J.-C. Borda, Mémoire sur les élections au scrutin. Histoire de l'Académie Royale des Sciences, Paris.1781.

[37] 2000] K. Jiang et Bunke, Combining acoustic and visual classifiers for the recognition of spoken sentences. In International Conference in Pattern recognition, volume 2, pages 491-498, 2000, Barcelona.

[38] T. Ho and Hull, Decision combination in multiple classifier systems. IEEE Transactions on Pattern, Analysis and Machine Intelligence, 1994, 16(1) pages: 66-75.

[39] Van-Erp, M. and L. Schomaker. Variants of the borda count method for combining ranked classifier hypotheses. 7th International, Workshop on Frontiers in Handwriting Recognition, pages 443-452, Amsterdam. 2000.

[40] Parker, J. Evaluating classifier combination using simulated classifiers. Technical report, Department of Computer Science, University of Calgary, Canada.

[41] R. Duin. The combining classifier: to train or not to train: volume II of 16th International Conference on Pattern Recognition (ICPR), IEEE Computer Society Press, Los Alamitos,, p 765-770, Quebec City, Canada, 2002.

[42] J. Kittler, M. Hatef, et R. Duin, On combining classifiers. IEEE Transactions on Pattern Analysis and Machine Intelligence, 20(3), p. 226-239, 1998.

[43] E. Alpaydin. Multiple networks for function learning. In IEEE International Conference on Neural Networks, volume 1, p 27-32, 1993.

[44] Y. Huang, and C. Suen. A method of combining multiple experts for the recognition of unconstrained handwritten numerals. IEEE Transactions on Pattern Analysis and Machine Intelligence, 17(1):90-94, 1995.

[45] F.Alkoot, and J. Kittler, Modified product fusion. Pattern Recognition Letters, 23: p. 957-965, 2002.

[46] B. Xiao, C. Wang, and R. Dai, Adaptive combination of classifiers and its application to handwritten Chinese characters recognition. In International Conference on Pattern Recognition (ICPR), volume 2, pages 2327-2330, Barcelona, Spain, 2000.

[47]J. Kittler and F. Alkoot, Sum versus vote fusion in multiple classifier systems. IEEE Transactions on Pattern Analysis and Machine Intelligence, 25(1), pages: 110-115, 2003.

[48] J. Kim, K. Kim, C. Nadal, and C. Suen. A methodology of combining hmm anf mlp classifiers for cursive word recognition. International Conference Document Analysis and Recognition(ICDAR), 2 : p. 319-322, 2000

[49] D. Tax, R. Duin, and M. Breukelen, Comparison between product and mean classifier combination rules. In International Workshop, Statistical Techniques in Pattern Recognition, p 165-170, 1997.

[50] L. Kuncheva, A theoretical study on expert fusion strategis. IEEE Transactions on Pattern Analysis and Machine Intelligence, 4(4), pages: 327-336.

[51] L. Lam et C. Suen. A theoretical analysis of the application of majority voting to pattern recognition. In International Conference on Pattern Recognition, p 418-420, Jerusalem, 1994.

[52] G. Fumera, G. et F. Roli, Performance analysis and comparison of linear combiners for classifier fusion. In IAPR International Workshop on Statistical Pattern Recognition (SPR), pages 424-432, Windsor, Canada. Springer-Verlag, LNCS.

[53] Giacinto, G. and Roli, F. (2001b). Design of effective neural network ensembles for image classi_cation processes. Image Vision and Computing Journal, 19(9) pages:699-707.

[54] V. Gunes, Reconnaissance des formes évolutives par combinaison, coopération et sélection de classifieurs. PhD thesis, 2001, Université de la Rochelle.

[55] J. F. Canny. “A Computational Approach to Edge Detection”, IEEE trans. On PAMI, vol 8, N° 6, pp 679-698, 1986.

[56] J.-P. COCQUEREZ et S. PHILIPP. Analyse d’images : filtrage et segmentation. Edition : MASSON, chapitre I.

[57] Saporta, Gilbert. "Probabilités et statistique : analyse des données 2ème édition :Technip, 2006.