



**HAL**  
open science

# Définition et mise en place d'un outil temps réel d'analyse des caractéristiques physiques des semences sèches

Vincent Muracciole

► **To cite this version:**

Vincent Muracciole. Définition et mise en place d'un outil temps réel d'analyse des caractéristiques physiques des semences sèches. Sciences de l'ingénieur [physics]. Université d'Angers, 2009. Français. NNT: . tel-00466401

**HAL Id: tel-00466401**

**<https://theses.hal.science/tel-00466401>**

Submitted on 23 Mar 2010

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

**DEFINITION ET MISE EN PLACE D'UN OUTIL  
TEMPS REEL D'ANALYSE DES  
CARACTERISTIQUES PHYSIQUES DES SEMENCES  
SECHES**

**Thèse de Doctorat**

**Spécialité : Sciences de l'ingénieur**

**ECOLE DOCTORALE : STIM**

**Présentée et soutenue publiquement**

**Le : 29 Septembre 2009**

**à : Angers**

**Par Vincent Muracciole**

**Devant le jury ci-dessous :**

**Michel CATTOEN**

Professeur, ENSEEIHT, *Rapporteur*

**Bernard HAUSSY**

Professeur, Université de Nancy, *Rapporteur*

**Armand FEUTRY**

Docteur, Vilmorin, *Examineur*

**Maria-Rosaria MANNINO**

Ingénieur de Recherche, INRA, *Examineur*

**Bertrand VIGOUROUX**

Professeur, Université d'Angers, *Examineur*

**Dominique BERTRAND**

Directeur de recherche, INRA, *Examineur*

**Patrick PLAINCHAULT**

Enseignant-Chercheur, ESEO, *Examineur*

**Directeur de thèse : Dominique BERTRAND et Bertrand VIGOUROUX**

**Co-encadrant : Maria-Rosaria MANNINO, Patrick PLAINCHAULT**

**Laboratoire : BIA, INRA Angers-Nantes; LISA EA4094 - Université d'Angers;**

**SNES, Beaucouzé ; CER de l'ESEO, Angers**



# Résumé

L'objectif de la présente thèse est d'étudier, de définir et de mettre en place un système de vision artificielle permettant de discriminer la nature et la variété de semences à partir de leurs images numériques.

Une première étude a porté sur l'étude d'un dispositif mono-caméra destiné au contrôle de la qualité de lots de semences dans l'optique de leur certification. Il est apparu qu'un système mono-caméra ne permettait pas d'identifier les semences dont les faces présentent une disparité de couleur. Ainsi, les semences endommagées ne peuvent pas être correctement détectées avec un tel dispositif.

Une deuxième étude a porté sur l'étude et la réalisation d'un nouveau système d'acquisition, muni de trois caméras, et capable de prendre plusieurs images de plusieurs faces d'un même objet. Un prototype a été construit, reposant sur une nouvelle architecture optique et électronique. A l'aide de ce prototype, une collection d'images de semences et de contaminants a été acquise. Sur cette collection, des algorithmes de traitement d'images et de discrimination ont été testés. Les semences composant cette collection ont été caractérisées par plusieurs centaines de variables quantitatives, portant sur leur morphologie, leur couleur et leur texture. Plusieurs méthodes de discrimination ont été étudiées : l'analyse discriminante linéaire (ADL), l'analyse factorielle discriminante, l'analyse discriminante PLS et une méthode de réseau de neurones probabilistes à ajustement adaptatif de poids. Dans tous les cas, les variables ont été sélectionnées préalablement par ADL avec introduction successive des variables les plus discriminantes. L'existence de trois images numériques pour chaque objet étudié offre des possibilités nouvelles en ce qui concerne la prise de décision. Plusieurs heuristiques ont été testées. Nous avons comparé les résultats obtenus en concaténant les tableaux de caractéristiques acquises à l'aide des trois caméras ou en mettant en jeu une stratégie de vote, majoritaire ou unanime.

Quelle que soit la stratégie de décision, le réseau de neurones probabilistes donne les résultats les meilleurs, légèrement supérieurs à ceux obtenus par l'ADL. Nous avons conclu que, en considérant la simplicité de l'analyse discriminante linéaire, cette méthode était la plus appropriée pour la réalisation d'un automate fonctionnant en temps réel et capable de répondre aux contraintes de la certification des lots de semences.

Mots clés : Traitement de l'image, Algorithmes de classification, Vision artificielle



# REMERCIEMENTS

Cette thèse est le fruit d'une collaboration entre le laboratoire de Bio-informatique de l'INRA (Institut National de la Recherche Agronomique) d'Angers-Nantes, le GEVES (Groupe d'Etude et de Contrôle des Variétés des Semences), du LISA (Laboratoire d'Ingénierie des Systèmes Automatisés) de l'Université d'Angers et du centre d'étude et de recherche de l'ESEO (Ecole Supérieure d'Electronique de l'Ouest).

Je tiens à remercier mes deux co-directeurs de thèse M. Dominique BERTRAND (Directeur de Recherche à l'INRA), M. Bertrand VIGOUROUX (Professeur à l'Université d'Angers) ainsi que mes deux co-encadrants Mme Maria-Rosaria MANNINO (Responsable du laboratoire d'analyse de pureté spécifique, à la Station Nationale d'Essai des Semences, GEVES, Beaucozéz) et M. Patrick PLAINCHAULT (Directeur de la recherche à l'ESEO), pour leur soutien et leur apport à la fois scientifique, technique et humain tout au long de ces quatre dernières années.

Je tiens à remercier M. Bernard HAUSSY (Enseignant Chercheur à l'ESEO et Professeur de l'Université de Nancy) et M. Michel CATTOEN (Professeur à l'Institut National Polytechnique de Toulouse) qui nous ont fait l'honneur d'accepter d'être rapporteurs de ce travail.

Mes remerciements s'adressent également à M. Armand FEUTRY (Docteur et chercheur dans la société VILMORIN, La Ménitrez) pour avoir accepté de faire partie de mon jury de thèse.

Je remercie la direction du GEVES qui, à chaque entrevue, m'a apporté son soutien et ses encouragements dans la réussite de la thèse et du projet.

Je tiens à remercier toute l'équipe de direction de la SNES (Joël LECHAPPE, Jean-Claude STEPHAN, Maria-Rosaria MANNINO, Didier DEMILLY, Sylvie DUCOURNAU, Valérie GRIMEAU, Corinne GUIMIER et Marie-Hélène WAGNER) mais également toute l'équipe de l'analyse de pureté pour leur grande disponibilité quand il a fallu répondre à mes questions sur la discrimination des semences et sur les réglementations des différentes espèces analysées à la SNES, pour leur accueil et le plaisir que j'ai eu à travailler avec eux.

Je tiens à remercier respectivement les directeurs M. Jean-Louis FERRIER et M. Jean-Louis BOIMON pour m'avoir accueilli au sein de l'équipe du LISA. Je remercie spécialement toute l'équipe du thème de recherche imagerie couleur et multi-composante (Bertrand VIGOUROUX, Alain

CLEMENT, Julio ROJAS-VARELA, Sié OUATTARA, Corinne LORMEL et Cindy TORRES) pour leur accueil chaleureux et l'ambiance agréable qui y régnait.

Je tiens à remercier M. CHARRUAULT pour m'avoir accueilli à l'ESEO. Je remercie tout le corps enseignant de l'ESEO et l'Administration de l'Ecole pour l'accueil que j'ai eu tout au long de ces années passées avec eux et plus particulièrement le département AII et l'équipe TRAME (Jérôme DELATOUR, Guillaume SAVATON, Sébastien AUBIN, Matthias BRUN et Jonathan ILLIAS). Je tiens également à remercier toute l'équipe Evaltech (Sébastien BESSON, Nicolas BRASSEAU, Charles JUCHET, Mireille FOUCHEREAU).

Je tiens à remercier l'unité de Sensométrie et de Chimiométrie de l'ENITIAA (Ecole Nationale d'Ingénieurs des Techniques des Industries de l'Agro-Alimentaire) pour leur accueil.

Je tiens à remercier M. Jean BOIFFIN et M. Jean-François THIBAUT respectivement directeur du centre INRA d'Angers et du centre INRA d'Angers-Nantes pour leur accueil.

Je tiens à remercier également Mme Carolyne DURR et M. Antoine GARDARIN qui m'ont permis d'étudier l'utilisation des algorithmes de traitement de l'image sur des semences de mauvaises herbes dans d'autres conditions que celles de ma thèse.

Je tiens enfin à remercier plus particulièrement M. Charles JUCHET et M. Gaël CESBRON pour l'aide qu'ils m'ont apportée respectivement sur la finalisation du premier système d'acquisition et la création d'une base d'image de semence avec ce même système, M. Sylvain PERPOIL pour son aide sur les quelques modifications mécaniques de précision à réaliser sur le système mécanique du système d'acquisition présenté dans cette thèse et M. Benoit LECOMTE pour son aide quant au routage des cartes électroniques nécessaire à la réalisation de cette nouvelle machine.

De nombreuses personnes ont participé de façon significative au bon déroulement de cette thèse.

Que celles que j'aurais malencontreusement oubliées de citer ne m'en tiennent pas rigueur. Je tiens à ce que tous vous sachiez combien je vous suis reconnaissant pour m'avoir accompagné tout au long de cette magnifique aventure, parfois difficile, mais tellement grande de satisfactions.

# Sommaire

Introduction générale.....	1
Chapitre 1 : Etude et réalisation d'un système d'acquisition d'images.....	11
1. Eléments d'un système de vision.....	12
1.1. Les capteurs photosensibles.....	12
1.1.1. Le capteur CCD.....	12
1.1.1. Le capteur CMOS.....	13
1.2. L'acquisition d'images en couleur .....	14
1.2.1. La méthode « de base », avec roue à filtres .....	15
1.2.2. Le filtre de Bayer.....	15
1.2.3. Le capteur tri-CCD.....	16
1.2.4. La méthode par pénétration des photons dans le silicium.....	16
1.3. L'éclairage .....	17
1.3.1. Nature des sources.....	17
1.3.2. Positionnement des sources lumineuses.....	19
1.4. La conception générale des dispositifs de tri de semences.....	20
1.4.1. Le placement manuel .....	20
1.4.2. Le tapis convoyeur .....	21
1.4.3. Le placement par défilement rotatif .....	23
1.4.4. Le placement par plan incliné .....	23
1.4.5. Le placement par chute libre .....	24
2. Réalisation d'un automate .....	25
2.1. Les choix généraux .....	25
2.2. La mécanique.....	26
2.3. Le capteur .....	26
2.4. L'éclairage .....	27
2.5. L'architecture électronique.....	28
2.6. Réalisation. ....	32
2.6.1. Agencement général .....	32

2.6.2.	Agencement des caméras et éclairage .....	33
2.6.3.	Agencement électronique .....	35
3.	Acquisition d'images avec le système de vision .....	39
3.1.	Etude de la précision et de la répétabilité de l'appareil. ....	39
3.1.1.	Procédure expérimentale .....	39
3.1.2.	Résultats .....	40
3.2.	Création d'une base d'images de semences .....	44
Chapitre 2 :	Analyse d'images des semences et étude exploratoire. ....	48
1.	Extraction des paramètres caractérisant les semences.....	49
1.1	. Espaces colorimétriques. ....	49
1.2	. La segmentation de l'image d'une semence.....	53
1.3	. Les caractéristiques morphologiques.....	54
1.4	. Caractérisation de la couleur. ....	58
1.5	. Caractérisation de la texture d'image. ....	59
1.4.1.	histogramme de différences de niveaux de gris .....	60
1.4.2.	Longueurs de plages.....	61
1.4.3.	Matrices de cooccurrences. ....	63
2.	Méthodes d'exploitation des données.....	65
2.1.	L'analyse en composante principale (ACP) .....	66
2.2.	Présentation générale de l'analyse de tableaux multiples.....	67
2.3.	La distance entre tableaux et sa représentation factorielle par STATIS.....	72
3.	Partie expérimentale .....	73
3.1.	Matériel et méthode. ....	73
3.2.	Résultats.....	76
3.2.1.	Etude de la morphologie des semences.....	76
3.2.3.	Etude de la texture.....	88
3.2.4.	Description des interrelations entre les tableaux.....	94

Chapitre 3 :	Discrimination des semences et prise de décision.....	99
1.	Les algorithmes de discrimination des semences.....	100
1.1.	Les méthodes de discrimination appliquées aux semences.....	100
1.1.1.	Riz.....	100
1.1.2.	Mauvaises herbes.....	101
1.1.3.	Céréales.....	102
1.2.	Les algorithmes de discrimination.....	104
1.2.1.	Analyse discriminante linéaire.....	104
1.2.2.	Analyse discriminante factorielle.....	105
1.2.3.	Analyse discriminante PLS.....	107
1.2.4.	Réseaux de neurones probabilistes.....	109
1.3.	Stratégies de prise de décision dans le cas d'un système tri-caméras.....	112
1.4.	Méthodes de validation.....	115
2.	Partie expérimentale.....	117
2.1.	Matériels et méthodes.....	117
2.2.	Résultats et discussions.....	118
2.2.1.	Modèle mono-caméra.....	118
2.2.2.	Modèle multi-caméra avec concaténation des variables.....	123
2.2.3.	Modèle multi-caméra avec concaténation des observations.....	126
2.2.4.	Modèle caméra indépendante.....	133
3.	Conclusion.....	137
	Conclusion et perspectives.....	139
	Bibliographie	143
	ANNEXES	148



# LISTE DES TABLEAUX

Tableau 1.1 : Moyenne et écart-type de la longueur des billes de calibre 6 et 8 mm sur les trois caméras.....	40
Tableau 1.2 : Moyenne et écart-type du diamètre équivalent des billes de calibre 6 et 8 mm (trois caméras).....	41
Tableau 1.3: Moyenne et écart-type de l'aspect rectangulaire moyen des billes de calibre 6 et 8 mm (trois caméras).....	42
Tableau 1.4: Collection d'images de semences.....	45
Tableau 2.1 : Collection d'images de semences.....	74
Tableau 2.2 : structure des variables caractérisant une semence .....	75
Tableau 3.1 : Variables sélectionnées automatiquement sur la caméra C .....	119
Tableau 3.2: Pourcentage de classification sur la caméra C .....	120
Tableau 3.3 : Matrice de confusion obtenue sur ADL de la caméra 3 .....	121
Tableau 3.4 : Sélection des 25 variables les plus discriminantes sur CONCATCOL.....	123
Tableau 3.5 : Pourcentage de classification obtenue sur CONCATCOL .....	124
Tableau 3.6 : Matrice de confusion sur RNP sur CONCATCOL .....	125
Tableau 3.7 : Sélection des variables sur CONCATLIG .....	127
Tableau 3.8 : Pourcentage de classification obtenue sur CONCATLIG.....	128
Tableau 3.9 : Matrice de confusion sur RNP sur CONCATLIG .....	129
Tableau 3.10 : Pourcentage de classification obtenue sur CONCATLIG+ MAJORITAIRE	129
Tableau 3.11 : Matrice de confusion avec RNP sur CONCATLIG+ MAJORITAIRE.....	130
Tableau 3.12 : Pourcentage de classification obtenue sur CONCATLIG+ UNANIME .....	131
Tableau 3.13 : Pourcentage de classification obtenue sur SEPARE+MAJORITAIRE.....	133
Tableau 3.14 : Matrice de confusion sur RNP sur CONCATLIG+ MAJORITAIRE .....	134
Tableau 3.15 : Pourcentage de classification obtenue sur SEPARE+UNANIME.....	135
Tableau 3.16 : Pourcentage de classification obtenu avec les classifieurs sur données brutes. .....	137
Tableau 0.1 : Pourcentage de classification suivant les différentes méthodes utilisées.....	142



# LISTE DES FIGURES

Figure 1 : Exemple de réglementation sur la présence de semences étrangères et .....	3
Figure 2 : Analyse manuelle d'un lot de tournesol .....	6
Figure 3 : Salle d'analyse des lots de semences de la SNES .....	6
Figure 4 : La chaîne de vision artificielle.....	7
Figure 1.1: Schéma d'un capteur CCD .....	13
Figure 1.2: Capteur CMOS à cellules passives .....	14
Figure 1.3: Capteur CMOS à cellules actives .....	14
Figure 1.4: Système d'acquisition avec roue à filtres .....	15
Figure 1.5 : Capteur avec un filtre de Bayer .....	16
Figure 1.6 : Schéma de principe d'un capteur tri-CCD .....	16
Figure 1.7: Représentation du capteur Foveon® X3.....	17
Figure 1.8 : Deux modes d'illumination réfléchives .....	19
Figure 1.9 : Méthode d'illumination à contre jour.....	19
Figure 1.10: Graincheck 310.....	22
Figure 1.11: Système d'analyse de la qualité du riz .....	22
Figure 1.12 : Système d'analyse colorimétrique des grains.....	23
Figure 1.13 : Schéma de principe du système d'acquisition.....	25
Figure 1.14 : Performance des microprocesseurs Intel .....	31
Figure 1.15 : Système d'acquisition.....	32
Figure 1.16 : Schéma de l'organisation interne du système d'acquisition .....	34
Figure 1.17 : Principe du fond lumineux vu sur la tranche .....	35
Figure 1.18 : Schéma de l'organisation électronique du système d'acquisition .....	37
Figure 1.19 : Image d'une semence de maïs acquise avec les trois caméras.....	37
Figure 1.20 : Image d'une semence de betterave.....	38
Figure 1.21 : Image d'un sclérote. ....	38
Figure 1.22 : Histogramme des longueurs sur les trois caméras .....	41
Figure 1.23 : Schéma décrivant l'aspect rectangulaire .....	42

Figure 1.24 : Histogrammes du diamètre équivalent sur les trois caméras .....	43
Figure 1.25 : Image d'une folle avoine avec une arête .....	46
Figure 1.26 : Image d'une folle avoine sans arête .....	46
Figure 2.1 : Cube colorimétrique RVB .....	49
Figure 2.2 : Espace de représentation HSV .....	51
Figure 2.3 : Représentation des dépendances entre les espaces de couleur .....	52
Figure 2.4 : Détection du seuil de segmentation optimal .....	53
Figure 2.5 : Analyse en composante principale concaténée.....	69
Figure 2.6 : Variables canoniques .....	71
Figure 2.7 : Organisation des données .....	75
Figure 2.8 : Carte factorielle de représentation selon les deux premières composantes .....	78
Figure 2.9: ACP sur les variables de calibre des semences. Cercle de corrélation des variables .....	79
Figure 2.10: ACP sur les variables associées aux moments des semences. Premier plan factoriel.....	81
Figure 2.11: ACP sur les variables associées aux coefficients de Fourier semences. Premier plan factoriel.....	82
Figure 2.12: ACP sur les paramètres de couleurs associés à l'espace RVB. Premier plan factoriel.....	83
Figure 2.13: ACP sur les paramètres de couleurs associés à l'espace RVB. Cercle de corrélation associé aux deux premières composantes .....	84
Figure 2.14: ACP sur les paramètres de couleurs associés à l'espace YCbCr. Premier plan factoriel.....	85
Figure 2.15: ACP sur les paramètres de couleurs associés à l'espace YCbCr.....	86
Figure 2.16: ACP sur les paramètres de couleurs associés à l'espace HSV. Premier plan factoriel.....	87
Figure 2.17: ACP sur les paramètres de couleurs associés à l'espace HSV. Cercle de corrélation sur les deux premières composantes. ....	88
Figure 2.18 : ACP sur les paramètres de texture associés à la méthode des différences d'histogramme de niveau de gris. Premier plan factoriel.....	90
Figure 2.19 ACP sur les paramètres de texture associés à la méthode des différences d'histogramme de niveau de gris. Cercle de corrélation .....	90
Figure 2.20 : ACP sur les paramètres de texture associés à la méthode des matrices de cooccurrence. Premier plan factoriel. codes : Figure 2.8. ....	91

Figure 2.21: ACP sur les paramètres de texture associés à la méthode des matrices de cooccurrence. Cercle de corrélation .....	92
Figure 2.22 : ACP sur les paramètres de texture associés à la méthode des longueurs de plage. Premier plan factoriel .....	93
Figure 2.23: ACP sur les paramètres de texture associés à la méthode des longueurs de plage. Cercle de corrélation .....	94
Figure 2.24: Méthode STATIS sur caméra A. ....	96
Figure 3.1: Formules matricielles intervenant dans l'analyse discriminante.....	106
Figure 3.2 : Modèle par concaténation des données selon les colonnes .....	113
Figure 3.3 : Modèle par concaténation selon les lignes. ....	114
Figure 3.4 : Modèle portant sur des tableaux séparés. ....	114
Figure 3.5 : Fréquence de rejet par espèce en pourcent sur la stratégie CONCATLIG .....	132
Figure 3.6 : Fréquence de rejet par espèce en pourcent sur la stratégie SEPARE .....	135



# INTRODUCTION GENERALE

La France tient une place importante, au niveau mondial, dans la production et la commercialisation de semences. Cette position de leader est le résultat du progrès technique constant que le secteur a connu depuis ses origines. Aujourd'hui la France est au cinquième rang mondial et première au niveau européen pour le chiffre d'affaires lié à la production de semences, qui occupe en France plus de 300 000 ha. Elle est également au troisième rang mondial pour le volume d'exportation après les Etats- Unis et les Pays-Bas. Sept départements présentent des surfaces en multiplication de plus de 10 000 ha et parmi ces derniers le Maine-et-Loire se positionne au quatrième rang après la Marne, le Gers et l'Eure-et-Loir. La place éminente du Maine-et-Loire est confirmée par la présence dans le département de nombreuses entreprises semencières, d'associations professionnelles, d'acteurs de la recherche et d'organismes publics. La force du secteur semences dans le département a contribué à la création de Végépolys, pôle de compétitivité à vocation mondiale. Deux phénomènes importants ont caractérisé l'évolution de la filière au niveau international dans les derniers cinquante ans : la réduction du nombre d'entreprises productrices et l'augmentation des exportations. Ces tendances se sont manifestées également en France, où le nombre d'entreprises produisant des semences a connu une diminution de 36 % entre 1985 et 2005(GNIS 2008). Cette concentration est liée d'une part à l'évolution des technologies dont l'utilisation demande des investissements importants, de l'autre à la compétition entre producteurs accrue par le phénomène de la mondialisation. Dans la même période, le volume des exportations a connu une forte augmentation, conséquence de la spécialisation des zones géographiques de production. De 1985 à 2004, le pourcentage des exportations par rapport au marché total est passé de 6,5 à 15,8 dans le monde et de 16,6 à 31,5 en France (International Seed Federation 2006).

Une des raisons de la place remarquable de la France dans ce domaine tient à ce que le secteur agricole et semencier est depuis longtemps fortement encadré par des organismes relevant de l'Etat ou émanant des professions concernées. Le GNIS (Groupement National de l'Industrie Semencière), établissement public industriel et commercial dépendant du Ministère de l'Agriculture, est l'un d'entre eux. Il fédère toutes les professions concernées par la création, la production, la multiplication, la distribution et l'utilisation de semences et de plants. Le

GNIS assure une concertation permanente entre les différentes familles professionnelles et entre l'interprofession et les pouvoirs publics. Il organise la production et la commercialisation sur les plans économiques et réglementaires, il contrôle la qualité des semences et plants, il assiste l'interprofession au niveau des études économiques et statistiques, de la réglementation et de la formation. Avec ses actions, le GNIS favorise l'expansion du secteur semences et plants en France et au niveau international.

Les acteurs de la filière, tous représentés au sein du GNIS, sont les entreprises spécialisées dans la sélection et la production des semences, les agriculteurs multiplicateurs qui travaillent en contrat avec elles, les associations professionnelles et les organismes publics de contrôle. En France sont présents 85 établissements obtenteurs de variétés, 240 établissements producteurs de semences, 20300 agriculteurs multiplicateurs et 24000 établissements distributeurs (GNIS 2008). Les obtenteurs des variétés sélectionnent et créent des variétés nouvelles, qui répondent aux exigences des utilisateurs en termes, par exemple, de productivité, de résistance aux maladies ou de qualité recherchée pour la transformation industrielle des produits. Les producteurs des semences conditionnent et commercialisent les semences produites par les agriculteurs multiplicateurs. Ces derniers, assurent la multiplication du matériel génétique mis à disposition par les obtenteurs après inscription au Catalogue Officiel des Variétés.

De manière à garantir une qualité minimum des lots de semences, le commerce international met en jeu un système de réglementations définissant les moyens à mettre en œuvre et les mesures de contrôle qui garantissent la mise en commerce de lots de semences de qualité. Au niveau européen, des directives établissent les normes de culture et les standards de qualité qui doivent être atteints par les semences en vue de leur commercialisation. En France, le GNIS transpose au niveau national le contenu de ces directives sous la forme d'un Règlement Technique de Certification. Cette réglementation définit les modalités et les normes de la certification obligatoire et officielle mise en place par les pouvoirs publics. En France, le Ministère de l'Agriculture a délégué la mission de contrôle officiel et de certification au Service Officiel de Contrôle (SOC), service technique du GNIS. Le SOC est responsable des contrôles effectués dans les champs de multiplication visant à vérifier l'identité, la pureté variétale et le respect des règles de production. Dans les usines, des contrôles sont ensuite réalisés sur les lots en cours de triage par les laboratoires d'entreprise. En fin de conditionnement sur les lots destinés à la vente, une dernière série d'analyses est réalisée pour la certification. L'objectif est de garantir une qualité technologique (faculté germinative

minimum, pureté spécifique minimum, présence d'espèces étrangères limitée à celle fixée par les normes, teneur en eau maximum) et, pour certaines espèces, une qualité sanitaire.

A titre d'illustration, le tableau ci-dessous présente la directive 2002-57-CE du GNIS (GNIS, Directive 2002/57/CE 2002) qui concerne les normes de qualité des lots des espèces oléagineuses. On voit par exemple que pour les lots de *Helianthus annuus* (tournesol), la directive prévoit une faculté germinative minimale de 85 % et une pureté spécifique minimale de 98 %. En outre, le lot sera certifiable uniquement s'il est indemne d'espèces particulièrement nuisibles, *Cuscuta* sp. (cuscute), *Avena fatua* (folle avoine), *A. ludoviciana* et *A. sterilis*.

On recherche également d'autres semences étrangères. Le lot ne doit pas contenir plus de 5 semences d'espèces appartenant à d'autres espèces que le tournesol en dehors des espèces particulièrement nuisibles.

Espèces et catégories	Faculté germinative minimale (% des semences pures)	pureté spécifique		Teneur maximale en nombre de semences d'autres espèces de plantes dans un échantillon du poids prévu à l'annexe III - colonne 4 (total par colonne)							Conditions quant à la teneur en graines d'orobanche
		Pureté minimale spécifique (% du poids)	Teneur Maximale Totale en semences d'autres espèces de plantes (% du poids)	Autres espèces de plantes (a)	Avena fatua Avena ludoviciana Avena sterilis	Cuscuta Spp.	Raphanus raphanistrum	Rumex Spp. autre que Rumex acetosella	Alopecurus myosuroides	Lolium remotium	
1	2	3	4	5	6	7	8	9	10	11	12
Arachis hypogaea	70	99		5	0	0 (c)					
Brassica spp. :											
- semences de base	85	98	0,3		0	0 (c) (d)	10	2			
- semences certifiées	85	98	0,3		0	0 (c) (d)	10	5			
Cannabis sativa	75	98		30 (b)	0	0 (c)					(e)
Carthamus tinctorius	75	98		5	0	0 (c)					(e)
Carum carvi	70	97		25 (b)	0	0 (c) (d)	10		3		
Gossypium sp.p.	80	98		15	0	0 (c)					
Helianthus annuus	85	98		5	0	0 (c)					
Linum usitatissimum textile	92	99		15	0	0 (c) (d)			4	2	
Linum usitatissimum oléagineux	85	99		15	0	0 (c) (d)			4	2	
Papaver somniferum	80	98		25 (b)	0	0 (c) (d)					
Sinapis alba :											
- semences de base	85	98	0,3		0	0 (c) (d)	10	2			
- semences certifiées	85	98	0,3		0	0 (c) (d)	10	5			
Glycine max.	80	98		5	0	0 (c)					

**Figure 1 : Exemple de réglementation sur la présence de semences étrangères et la faculté germinative : cas des lots d'oléagineux. (GNIS, Directive 2002/57/CE 2002)**

Les analyses de contrôle des lots sont réalisées par la Station Nationale d'Essais des Semences (SNES) du Groupe d'Etude et de Contrôle des Variétés et des Semences (GEVES) et par les laboratoires agréés des entreprises. Les résultats de ces analyses sont transmis au SOC qui certifiera les lots après vérification de la conformité à la réglementation française et européenne.

Le GEVES est un Groupement d'Intérêt Public qui associe le Ministère de l'Agriculture, l'INRA (Institut National de la Recherche Agronomique) et le GNIS. Cet organisme intervient dans l'inscription des nouvelles variétés au Catalogue Officiel en instruisant les études techniques nécessaires pour le compte du Comité Technique Paritaire pour la Sélection. Il intervient également dans les contrôles de qualité des semences en vue de la certification en se basant sur les essais réalisés par les laboratoires officiels de la SNES. Le laboratoire d'analyses physiques de la SNES analyse environ 17000 échantillons représentatifs des lots de semences de plus de 150 espèces différentes en vue de leur commercialisation. Lors des analyses de pureté spécifique et de recherche de semences étrangères, plus de 350 espèces sont détectées dans environ 30 % de ces échantillons. Dans ce cadre, la SNES reçoit annuellement plus de 40000 échantillons sur lesquels elle réalise plus de 80000 analyses selon les méthodes standardisées de l'International Seed Testing Association (ISTA). Cette association a comme mission de développer, adopter, publier et promouvoir des méthodes normalisées pour l'échantillonnage et l'analyse des semences destinées au commerce international en réponse aux attentes de la filière internationale. Soixante quatorze pays et 176 laboratoires sont aujourd'hui membres de l'ISTA, gouvernée par un Comité Exécutif et structurée en 17 Comités Techniques compétents dans l'échantillonnage, sur le lot et au laboratoire, et dans les différents domaines de l'analyse de qualité des semences.

En ce qui concerne la qualité physique, deux méthodes d'analyse standardisées par l'ISTA sont utilisées aujourd'hui dans le cadre de l'évaluation des lots en vue de leur commercialisation: la *pureté spécifique* et le *dénombrement*.

L'analyse de pureté consiste dans la séparation de l'échantillon d'environ 2500 semences en trois composants : « semences pures », « semences d'autres plantes » et « matières inertes ». Cette séparation se fait sur la base d'un tri manuel et d'une observation de chaque élément qui constitue l'échantillon. Les résultats obtenus, exprimés en pourcentages de semences pures et d'impuretés, permettent l'évaluation du lot de semences par rapport aux valeurs minimales de teneur en semences pures de l'espèce cultivée et aux valeurs maximales de semences étrangères prévues par la réglementation.

L'analyse de dénombrement consiste à la recherche, dans un échantillon d'environ 25000 semences, des semences appartenant à d'autres espèces, qui peuvent être la totalité des espèces (lots de catégorie de base) ou certaines espèces particulières indiquées dans le Règlement Technique de Certification (lots de catégorie certifiée). Les résultats sont exprimés

en nombre de semences de chaque espèce étrangère détectée dans un échantillon de poids déterminé et représentatif du lot. Elles permettent par exemple l'évaluation du lot par rapport aux normes qui concernent des espèces particulièrement nuisibles, comme *Avena fatua* L., *Avena sterilis* L., *Cuscuta* spp., *Melilotus* spp., *Orobanche* spp.

Pour la pureté comme pour le dénombrement le contrôle, qui porte sur la présence des semences d'espèces autres que celle qui constitue le lot, s'explique par la nécessité d'emploi de semences indemnes d'espèces étrangères comme facteur de réussite de la culture. Les semences étrangères recherchées dans les lots et soumises aux normes européennes et nationales sont spécifiques d'un point de vue agronomique aux espèces cultivées dans lesquelles elles sont recherchées. Ainsi, les espèces *Alopecurus myosuroides* et *Elytrigia repens* sont recherchées lors des analyses de contrôle des graminées fourragères. L'emploi de lots à pureté spécifique élevée réduit la diffusion d'espèces à haut degré de nuisibilité (*Avena fatua* L., *Rumex* spp.), ainsi que celles d'espèces difficilement contrôlables aux champs comme en usine (*Alopecurus myosuroides*). Pour les mêmes raisons, les espèces du genre *Melilotus* font l'objet de recherches dans les semences de légumineuses fourragères. Il faut en outre souligner que certaines espèces, comme *Avena fatua* L., *Avena sterilis* L., *Rumex* spp., *Cuscuta* spp., reconnues comme très nuisibles dans toute culture, sont plus largement recherchées dans les semences des différents groupes d'espèces, fourragères, protéagineuses, oléagineuses, céréales et plantes à fibres. Les seuils de tolérance dans les lots de semences tendent à se réduire. Ainsi 20 semences de *Cuscuta* spp. dans un échantillon de 100 grammes était un taux acceptable au début du XX<sup>ème</sup> siècle, alors qu'aujourd'hui la norme européenne est de 0 semence dans un échantillon de même taille. Il en est de même dans de nombreux pays ailleurs dans le monde.

Ces analyses demandent des connaissances approfondies en systématique botanique et représentent un travail de haute technicité, portant sur la détection et l'identification d'impuretés appartenant à des catégories très variées (matières inertes et plusieurs centaines d'espèces différentes). Comme le montrent les Figure 2 et Figure 3, les analyses de pureté et de dénombrement reposent actuellement sur un examen visuel de l'échantillon de semences réalisé par des analystes expérimentés. Le laboratoire d'analyse physique de la SNES compte 20 analystes permanents et 5 à 8 analystes non-permanents compétents recrutés en haute saison. La formation de personnel compétent pour l'analyse des espèces importantes (fourragères, protéagineux, oléagineux, céréales, plantes à fibres et potagères) requiert plusieurs années d'expérience de laboratoire.



*Figure 2 : Analyse manuelle d'un lot de tournesol*



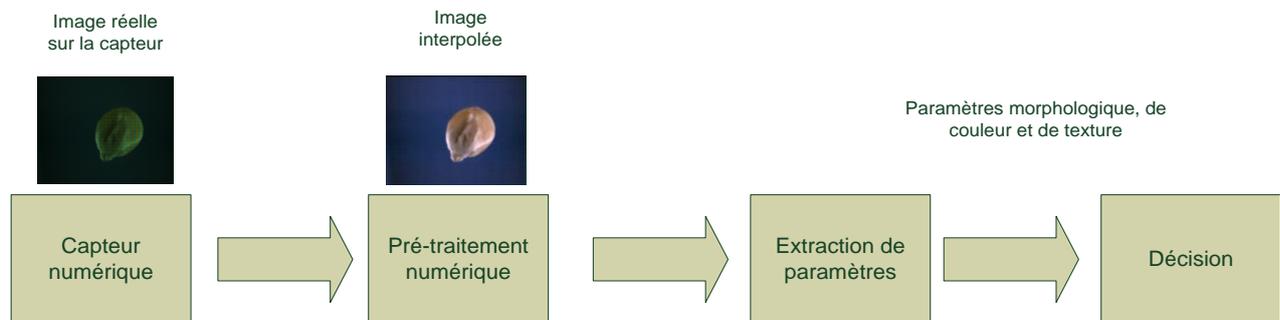
*Figure 3 : Salle d'analyse des lots de semences de la SNES*

Ces analyses représentent un travail non seulement important par l'expertise qu'elles demandent, mais aussi par le temps nécessaire à leur réalisation. Par exemple, pour un échantillon de tournesol, une analyse de dénombrement porte sur un poids de 1 kg, ce qui représente environ 12500 semences. Un opérateur qualifié effectue cette analyse en 15 à 20 minutes. En fonction de la taille et de la nature des semences, ces analyses peuvent être encore plus complexes et requièrent parfois des qualifications particulières de la part d'opérateurs spécialement formés et entraînés. C'est le cas, par exemple, de l'analyse d'espèces de graminées en mélange qui demande entre 4 à 6 heures de travail d'observation.

Les analyses de pureté et de dénombrement sont fondées sur l'examen visuel et individuel de semences caractérisées par une grande variabilité en termes de morphologie, de couleur et de texture.

Ainsi, l'analyse des lots de semences selon les méthodes internationales standardisées relève principalement de la perception humaine et de l'expertise des analystes. Il paraît possible d'en automatiser certaines en mettant en jeu un *système de vision artificielle*. De nos jours de nombreux systèmes basés sur la vision artificielle ont été réalisés ou font l'objet de recherches

pour l'amélioration de la qualité des lots ou leur contrôle. Depuis de nombreuses années, le GEVES est actif dans ce domaine, grâce au concours de compétences pluridisciplinaires issues de la biologie, de la chimométrie, du traitement de l'image, de la physique et de l'électronique. La région Pays de la Loire, par le biais des deux contrats de plan Etat-Région de 1994-1999 et de 2000-2006 (thème VISIOSEM), a permis de créer une collaboration entre différentes unités de recherches spécialisées : le centre d'étude et de recherche de l'Ecole Supérieure d'Electronique de l'Ouest (ESEO), le laboratoire de Chimométrie Sensométrie unité mixte sous contrat de l'Ecole Nationale des Ingénieurs et des Techniques des Industries Agro-alimentaires (ENITIAA) et de l'INRA de Nantes, le Laboratoire d'Instrumentation des Systèmes Automatisés (LISA) de l'Université d'Angers, le secteur recherche de la Fédération Nationale des Agriculteurs Multiplicateurs des Semences (FNAMS) et le laboratoire de technologie des semences de la société Vilmorin.



**Figure 4 : La chaîne de vision artificielle.**

La vision artificielle inclut toutes les étapes de la chaîne de vision (Figure 4) se décomposant en 4 phases successives : l'acquisition de l'image, son pré-traitement, l'extraction de paramètres caractéristiques des objets et la prise de décision faisant appel aux méthodes chimométriques ou de reconnaissance de formes.

Dans une thèse antérieure (Chtioui 1997), effectuée en partenariat avec la SNES, ont été explorées les possibilités offertes par la vision artificielle dans le domaine de l'identification des semences. L'objectif visé dans cette étude était de montrer la faisabilité de la caractérisation des semences à travers un système de vision simple. Ces travaux ont permis d'identifier des caractères et des méthodes de reconnaissance de forme permettant de discriminer des semences à partir d'images numériques. Dans cette étude, les semences étaient placées manuellement devant la caméra. Un tel système qui a démontré son efficacité au niveau de la reconnaissance des semences ne permettait pas d'atteindre les vitesses d'analyse requises pour une application effective.

*La présente thèse a comme objectif de définir et de mettre en place un système automatisé d'analyse de caractéristiques visibles à haut débit. Cette étude comprend également la mise en place des outils statistiques permettant de discriminer les semences et les contaminants à partir des caractéristiques extraites.*

Il s'agit donc de mettre au point un automate qui mobilise ces méthodes. Cet automate comporte nécessairement un mécanisme introducteur qui permet le défilement des semences, un système de capteurs capable de prendre des clichés, un système électronique récupérant les images.

Ce travail comprend différents aspects liés à la mécanique, à l'optique, à l'électronique, à la vision artificielle et aux statistiques. Cette thèse est divisée en plusieurs chapitres traitant de ces différents points.

Du fait de la nature très pluridisciplinaire de cette thèse, nous avons choisi de traiter dans chaque chapitre de l'état de l'art et de la réalisation effective sur chaque domaine.

Dans une première partie, nous présenterons l'état de l'art des différents systèmes automatisés d'analyse des semences. Nous justifierons les choix technologiques (mécanique, optique, électronique) du système retenu. Le système issu de ces choix, et réalisé, sera présenté. Nous donnerons des indications sur les inconvénients et les avantages du système effectivement réalisé. Deux collections d'images numériques sont créées grâce à ce système. Une première est composée d'images de billes calibrées qui nous permet de mener une étude métrologique du système. Une seconde est composée d'images de semences représentatives d'une situation pratique de certification de lot. Cette collection nous servira de référence pour les chapitres suivants.

La deuxième partie porte sur l'extraction des caractéristiques descriptives des semences à partir de la collection d'images acquises. Nous recenserons et nous décrirons tout d'abord les méthodes du domaine de la vision artificielle adaptées à cet objectif. Nous appliquerons ces méthodes à la collection d'images de semences et nous effectuerons une étude descriptive permettant de connaître les relations entre les différentes caractéristiques extraites. Nous chercherons également à identifier les ressemblances et les différences des espèces entre elles.

Dans un troisième chapitre, nous développerons les méthodes permettant de discriminer les semences à partir de leurs caractéristiques. Nous comparerons les performances de ces méthodes sur la collection de référence. Nous définirons des stratégies d'identification

permettant de répondre aux contraintes de rapidité et de précision liées à la certification des lots de semences.

Dans la conclusion, nous ferons une étude critique et prospective des méthodes de vision artificielle et d'identification qui répondent aux contraintes d'un système à haut débit. Nous présenterons la spécification du système permettant d'atteindre la réalisation d'un système autonome de tri en vue de la certification ainsi que la démarche optimale que nous jugeons réalisable pour y arriver.



# CHAPITRE 1 : ETUDE ET REALISATION D'UN SYSTEME D'ACQUISITION D'IMAGES.

*Ce premier chapitre est consacré à l'étude du système d'acquisition d'images et à sa réalisation effective.*

*Un système d'acquisition se compose d'un système optique comprenant un capteur photosensible (caméra), d'un système d'éclairage et d'un dispositif de présentation des objets (ici des semences). Les différents éléments du système doivent être contrôlés par un système électronique approprié.*

*Les deux premières parties seront consacrées aux capteurs photosensibles dans leurs deux fonctions fondamentales, capter la lumière (partie 1.1) et restituer la couleur (partie 1.2). Nous examinerons ensuite les problèmes liés à l'illumination (partie 1.3). A partir de la bibliographie sur les automates de tri des semences, nous étudierons les différentes méthodes de positionnement et de défilement des semences devant un système d'acquisition (partie 0). La partie suivante sera consacrée aux différentes possibilités d'architecture électronique.*

*A partir de ces études, nous présenterons nos choix technologiques pour la réalisation d'un automate (partie 2.1) ainsi que le système effectivement réalisé (partie 2.6).*

*Grâce à ce système nous effectuerons une étude métrologique nous permettant d'évaluer la performance du système et nous pourrons constituer une collection d'images de semences (partie 3.2).*

# 1. Eléments d'un système de vision

## 1.1. Les capteurs photosensibles

Les capteurs (Fisher, Tadic-Galeb et Yoder 2008) sont composés de cellules photosensibles qui recueillent la lumière. Ils utilisent des technologies CCD (*Charged Coupled Device* ; dispositif à transfert de charge) ou CMOS (*Complementary Metal Oxyde Semiconductor* ; semiconducteur à jonction métal oxyde) aussi bien dans le milieu industriel, qu'en laboratoire. Leur principe est toujours le même : une cellule photosensible transforme une énergie, fruit de l'excitation par des photons, en une tension électrique.

Chaque cellule photosensible communique une information qui correspond à la sommation des photons qu'elle a accumulés pendant le temps de pose. Un convertisseur analogique-numérique (CAN) transforme cette tension électrique en une valeur numérique.

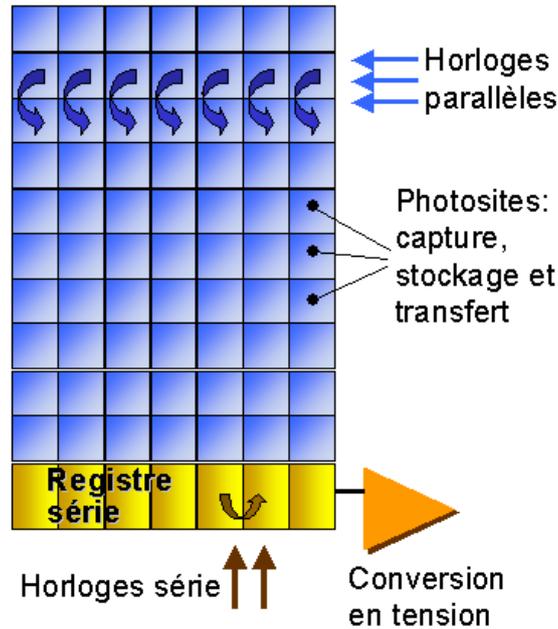
La surface du capteur est divisée en lignes et en colonnes, qui sont autant de surfaces sensibles dont les cotés ne font que quelques microns. Elle constitue un maillage réalisant l'échantillonnage spatial de la scène ou de l'objet.

Les capteurs CCD ou CMOS diffèrent par le mode de traitement de l'information une fois celle-ci recueillie.

### 1.1.1. Le capteur CCD

Le capteur CCD est un composant basé sur une technologie à semi-conducteur et composé de cellules de silicium. Sur ces cellules, des charges électriques s'accumulent au fur et à mesure de l'arrivée des photons, et remplissent des zones appelées "puits". Les charges se déplacent séquentiellement sur un amplificateur puis sortent du circuit CCD vers un circuit de mise en forme qui peut être numérique ou analogique (signaux émis vers une sortie analogique).

Ces charges électriques se déplacent sur une distance qui peut atteindre une quinzaine de millimètres. Cette distance liée à la fréquence de fonctionnement du capteur ne permet de négliger le temps de propagation dans le capteur. Les capteurs CCD doivent par conséquent disposer d'une zone de stockage intermédiaire où s'opère le découplage entre le temps d'intégration et le temps de transfert des données (Figure 1.1).

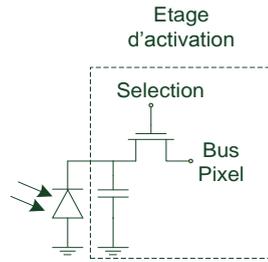


*Figure 1.1: Schéma d'un capteur CCD*

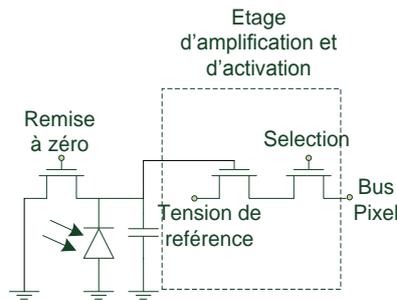
### 1.1.1. Le capteur CMOS

Comme dans le cas du capteur CCD, l'arrivée de photons sur le silicium crée des charges électriques, qui vont s'accumuler durant un certain temps. La différence est qu'une cellule de capteur CMOS est composée d'un photorécepteur et de transistors jouant le rôle d'interrupteurs. Un maillage en X et Y permet, en fermant les transistors voulus, de lire la tension individuellement pour chacune des cellules. Cette tension est proportionnelle à la quantité de photons reçue par la cellule. Le capteur CMOS est d'une technologie plus récente que le CCD. Il est très couramment utilisé par exemple dans le domaine de la téléphonie mobile. Moins coûteux à produire qu'un capteur CCD, il est donc devenu compétitif.

Il existe deux familles de capteurs CMOS, ceux à cellules passives (Figure 1.2) et ceux à cellules actives (Figure 1.3). Dans la première, l'information brute est recueillie sans aucune correction tandis que dans la seconde un étage d'amplification et d'offset est ajouté, ce qui réduit le bruit de l'acquisition. Apparemment meilleure, la seconde a cependant pour inconvénient d'avoir une surface sensible réduite sur chacune de ses cellules.



**Figure 1.2: Capteur CMOS à cellules passives**



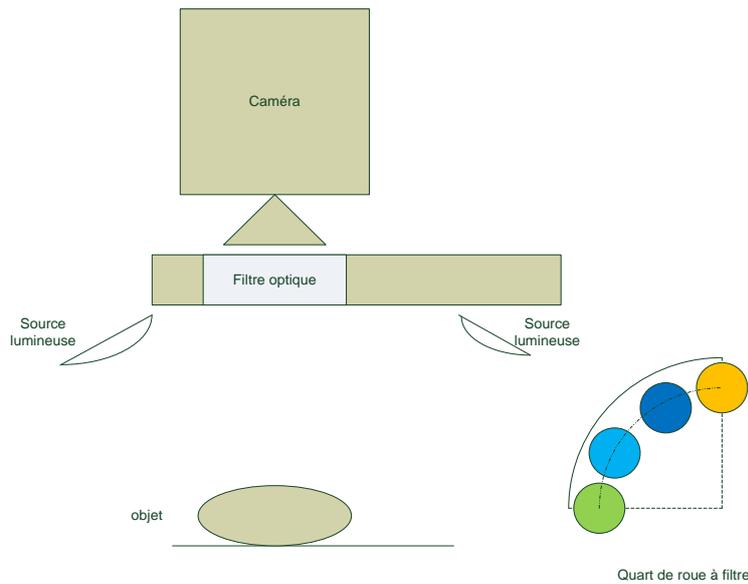
**Figure 1.3: Capteur CMOS à cellules actives**

## 1.2.L'acquisition d'images en couleur

Le système visuel humain est sensible aux longueurs d'ondes électromagnétiques comprises entre 380 et 780 nm. L'oeil reçoit la lumière à travers une lentille épaisse, le cristallin, qui focalise les rayons lumineux sur la rétine. Les récepteurs rétiniens sont de deux types : (i) les *bâtonnets* pour la vision scotopique (faible luminance) sont à réponse achromatique et se rencontrent majoritairement dans la périphérie de la rétine ; leur maximum de sensibilité est à 507 nm ; (ii) les *cônes* pour la vision photo-optique (luminance élevée), présents majoritairement au centre de la rétine, réagissent de manière spécifique à certaines gammes de longueurs d'ondes. On distingue trois classes de cônes, qui contiennent des photo-pigments dont l'absorption culmine aux longueurs d'ondes d'environ 420, 530 et 560 nm, ce qui correspond à des illuminants monochromatiques perçus respectivement comme jaunes-verts, verts et bleus.

Ces observations constituent le socle de la théorie trichromatique, affirmant que la plupart des stimuli peuvent être égalisés par la synthèse additive de trois primaires fixes. Les techniques de visualisation d'images se sont naturellement inspirées des processus mis en œuvre dans le système visuel humain : les caméras fournissent trois signaux centrés sur le rouge (*R*), le vert (*V*) et le bleu (*B*) ; c'est le codage *RVB*.

### 1.2.1. La méthode « de base », avec roue à filtres



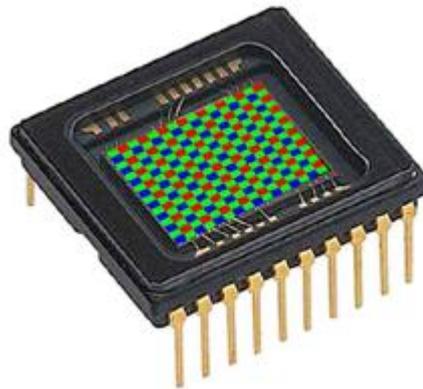
*Figure 1.4: Système d'acquisition avec roue à filtres*

Cette méthode consiste à intercaler entre l'objectif de la caméra et la scène acquise un système comportant trois filtres optiques, placés sur des supports : un filtre rouge, un vert et un bleu (Figure 1.4). Cette méthode ne se réduit pas à l'acquisition d'images couleur. Son principe est très utilisé en astronomie car il permet de multiplier les filtres spécifiques de longueurs d'onde autres que celles du domaine visible. Ils permettent de décomposer la lumière reçue de manière extrêmement fine. En revanche, on ne peut utiliser cette méthode que pour des objets statiques ou dont le déplacement est très lent.

### 1.2.2. Le filtre de Bayer

Une approche générale consiste à placer un filtre de couleur sur chaque élément photosensible d'un capteur matriciel. Pour obtenir une image couleur, les filtres sont disposés selon un agencement particulier dont le plus connu a été défini par Bayer (Bayer 1976). Il s'agit d'un capteur (Figure 1.5) sur lequel la partie jouant le rôle de surface sensible présente une alternance de cellules de couleur rouge, verte et bleue. Il offre une excellente réponse dans le vert puisqu'il dispose de deux fois plus de cellules sensibles au vert que dans chacune des deux autres couleurs. Cependant il présente l'inconvénient que, sur chaque cellule, toutes les couleurs ne sont pas représentées, d'où l'obligation de compenser cela par des techniques d'interpolation (Alleysson 2004 ; Gunturk et al. 2005). La société Fuji Film, sous le nom de « Super-CCD », a proposé un système de filtres sur le principe du filtre de Bayer intéressant

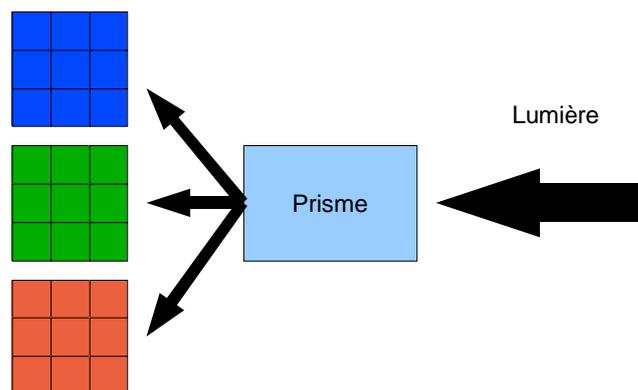
car, au lieu de cellules carrées, il utilise des cellules octogonales. Cette organisation permet d'avoir une meilleure résolution spatio-colorimétrique.



*Figure 1.5 : Capteur avec un filtre de Bayer*

### 1.2.3. Le capteur tri-CCD

Dans les systèmes tri-CCD, un prisme disperse les rayons incidents en fonction de leur longueur d'onde. Trois capteurs matriciels, placés respectivement sur le trajet des rayons rouges, verts et bleus, et recouverts chacun d'un filtre adapté afin de ne retenir que la composante chromatique souhaitée, fournissent les trois signaux R, V et B (Figure 1.6). Les capteurs Tri-CCD donnent des images de résolution maximale. Ils évitent d'avoir à recourir à un traitement de séparation des canaux *a posteriori* comme dans le cas du filtre de Bayer décrit précédemment.

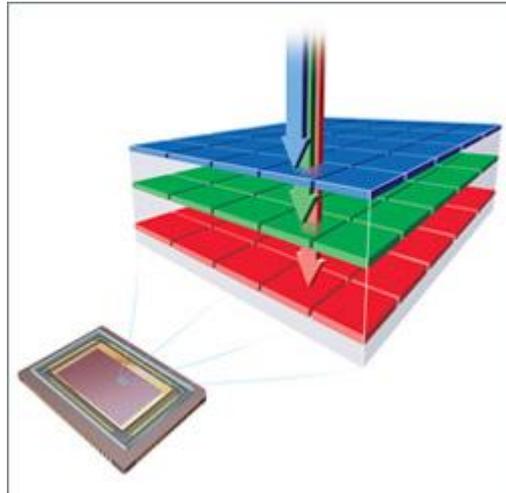


*Figure 1.6 : Schéma de principe d'un capteur tri-CCD*

### 1.2.4. La méthode par pénétration des photons dans le silicium

Cette méthode repose sur un principe physique selon lequel la pénétration des photons dans un objet dépend de la longueur d'onde. Les photons dont la longueur d'onde est la plus longue pénètrent le plus profondément. Un capteur reposant sur cette méthode est commercialisé par

la société Foveon (Figure 1.7). Il comprend trois couches photosensibles. L'image est obtenue par soustraction successive des valeurs acquises sur les différentes couches. Chaque couche est construite selon le même principe que celui des capteurs CMOS. Ce système conserve donc les avantages de la technologie CMOS tout en y ajoutant l'avantage d'un capteur Tri-CCD c'est-à-dire une grande précision spatiale.



*Figure 1.7: Représentation du capteur Foveon® X3*

*(Merill 2002)*

### **1.3.L'éclairage**

Les techniques d'éclairage sont nombreuses de manière à répondre aux besoins de l'industrie, qui sont très variés. Nous présenterons tout d'abord les différentes sources lumineuses, puis les différentes méthodes de positionnement de ces sources par rapport aux objets étudiés. Les choix des sources lumineuses et de leur positionnement ont évidemment un impact marqué sur la qualité des images obtenues. Les défauts présents dans une image d'objets mal éclairés ne peuvent généralement pas être totalement éliminés par des algorithmes de traitement ou de restauration d'images. Il est donc très important de consacrer beaucoup d'attention aux conditions d'éclairage.

#### **1.3.1. Nature des sources**

Dans l'optique de cette thèse, les sources lumineuses monochromatiques ne semblent pas appropriées. En conséquence, les sources telles que les lasers ne sont pas présentées ici.

Il existe dès lors trois grands types de sources lumineuses : les sources thermiques, les sources spectrales ou lampes à décharge dans des gaz et les diodes électroluminescentes.

- *Sources thermiques*

Quand un solide est chauffé, il émet une énergie lumineuse. La puissance lumineuse de chaque longueur d'onde émise dépend de la température du matériau chauffé. La réponse spectrale de ce type de source est fonction de la température. Dans le cas de lampe à incandescence, le matériau utilisé est un filament de tungstène placé dans une enveloppe de verre de forme variée remplie d'un gaz inerte. Il est élevé à une température importante par le passage de courant dans le fil. L'énergie fournie au filament est alors convertie en chaleur et en énergie lumineuse. La lumière émise par une source thermique est par nature polychromatique. Dans les ampoules, la température du filament est comprise entre 2500°K et 2800°K. Le remplacement du gaz inerte par un gaz halogène permet d'atteindre des températures de filament supérieures à 3000°K. Ces différentes sources thermiques suivent le rayonnement d'un corps noir.

- *Sources spectrale*

Lorsque deux électrodes sont soumises à une différence de potentiel (ddp) suffisante, le gaz qui les entoure peut être ionisé, libérant des électrons. Si la ddp est ramenée à zéro, les atomes de gaz se reforment, et, en se recombinaut, les électrons perdent de l'énergie qu'ils libèrent sous forme de photons. Ce principe est utilisé dans le cas des tubes fluorescents. L'ajout de certains gaz permet de contrôler les longueurs d'ondes émises par la source.

- *Les sources à semiconducteurs*

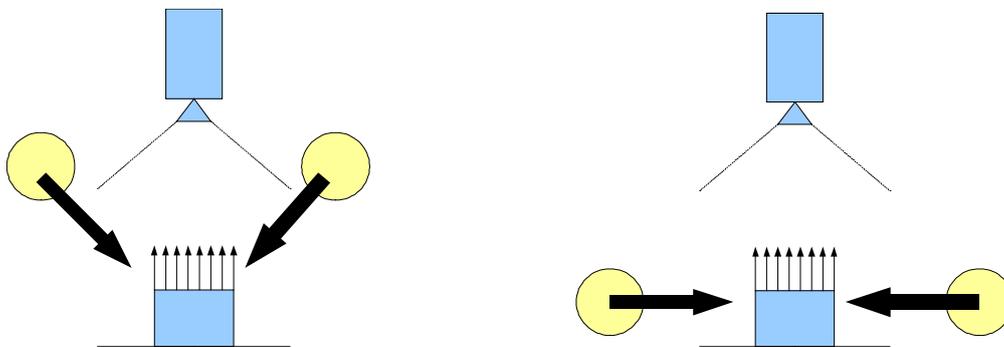
Les diodes électroluminescentes (DEL) utilisent des semi-conducteurs à jonction P-N comme source de photons. La jonction de type P se compose d'atomes accepteurs d'électron et de « trous ». La jonction de type N se compose d'atomes donneurs d'électrons et d'électrons. Lorsque la diode est soumise à une tension directe adéquate, les électrons et les trous sont attirés respectivement vers la jonction. Il en résulte, au voisinage de la jonction une zone, dite « zone de déplétion », dont l'épaisseur est fonction de la tension appliquée aux bornes du semi-conducteur. Dans la zone de déplétion, les électrons et les trous se recombinaut, restituant de l'énergie sous forme de photons. Suivant les matériaux utilisés, différentes longueurs d'ondes du spectre visible peuvent être émises.

### 1.3.2. Positionnement des sources lumineuses

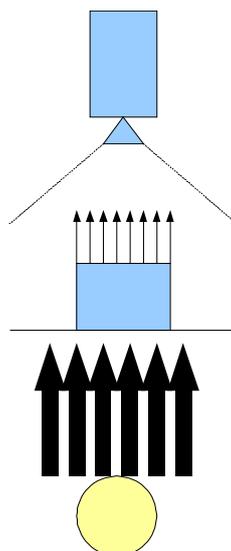
Selon le positionnement des sources lumineuses, on obtient un contre-jour ou un éclairage de face, qui peuvent conduire à des résultats très différents.

Placées au-dessus ou sur les côtés de l'objet, les sources lumineuses révèlent bien sa surface. Il s'agit de méthodes d'illumination réfléctive (Figure 1.8). Un tel positionnement génère inévitablement des zones d'ombres plus ou moins importantes selon l'inclinaison des sources lumineuses et la distance de l'objet par rapport au fond.

Placées en arrière de l'objet, les sources lumineuses ont pour effet de révéler le contour de l'objet et donc de bien le distinguer du fond, à la façon des photographies en contre-jour (Figure 1.9). Dans ce cas, l'objet lui-même est évidemment faiblement éclairé.



*Figure 1.8 : Deux modes d'illumination réfléchives*



*Figure 1.9 : Méthode d'illumination à contre jour*

Après avoir étudié les capteurs et les différentes méthodes d'illuminations d'un objet, il faut s'attacher maintenant à étudier les méthodes de placement d'objets dans le champ de vision de l'ensemble caméra-objectif.

## **1.4. La conception générale des dispositifs de tri de semences**

La bibliographie montre qu'il existe de nombreuses solutions pour introduire et faire défiler des semences afin de les photographier. Les modes de positionnement des semences existants se classent en quatre grands groupes : la disposition manuelle, le convoyage sur tapis (avec une variante mettant en œuvre un système rotatif), le défilement sur plan incliné et la chute libre.

### **1.4.1. Le placement manuel**

Cette solution consiste à placer manuellement une ou plusieurs graines devant la caméra. Les graines ainsi placées par un opérateur ne bougent donc pas durant la prise de vue. Fastidieux, lent et inutilisable si l'on doit prendre beaucoup de clichés, le procédé a en revanche l'avantage de donner des images de haute qualité. Cette méthode est la plus utilisée dans le domaine de la recherche sur la caractérisation de semences et d'objets en tous genres, car elle est bien adaptée à l'exploration de méthodes nouvelles.

Dans le cadre d'une thèse, Younès Chtioui, (1997), a mis en place un système d'analyse des semences de mauvaises herbes. Ce système nommé « Artivisu » a permis de constituer une base d'images de 7 espèces d'environ 600 images par espèce. Il se compose d'une caméra numérique avec sortie à composante analogique. L'éclairage du plan d'acquisition est réalisé par deux néons de puissance fixe de 18 watts disposés de part et d'autre du plan. A partir de cette base d'images de nombreuses études ont pu être menées sur la performance des algorithmes de classification pour la reconnaissance de certaines mauvaises herbes. Ces études seront présentées plus en détail dans les chapitres suivants.

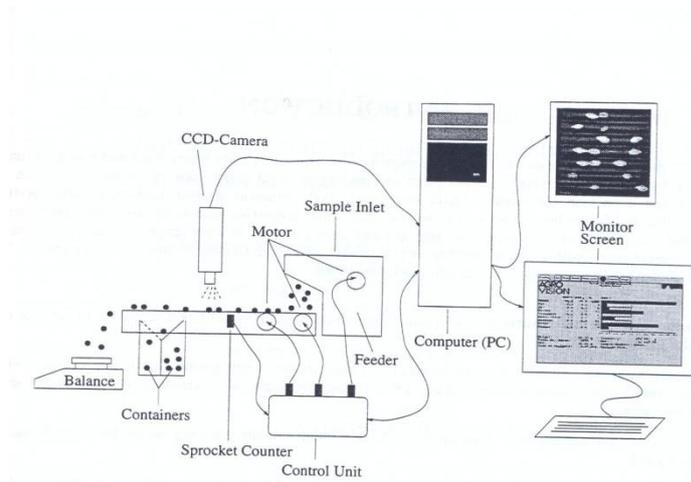
Une étude portant sur l'identification des mauvaises herbes a également été menée par Granitto, Verdes et Ceccatto, (2005). Une base comprenant 10310 images de 236 espèces différentes de semences et de mauvaises herbes a été créée. Le système d'acquisition se compose d'une caméra CCD avec une résolution de 768x512 pixels ainsi que d'un système d'éclairage composé d'une lampe halogène de 150W. L'illumination de la scène d'acquisition est assurée par quatre fibres optiques de diamètre 12,7 mm. A partir de cette base de données

75 paramètres caractérisant les semences sont extraits. Parmi ces 75 paramètres, seulement 12 sont finalement retenus comme paramètres de classification. Deux algorithmes d'identification ont été étudiés, un premier utilisant une méthode utilisant la règle de Bayes comme élément de décision et une deuxième utilisant une méthode à réseau de neurones avec 12 entrées, 80 neurones sur la couche cachée et 236 sorties correspondant à la classification de chaque espèce. Cette étude conclut que la sélection de 12 paramètres (6 paramètres morphologiques, 4 paramètres décrivant la couleur et 2 paramètres décrivant la texture) sont suffisants pour obtenir un taux d'identification compris entre 92.4% et 99.1% suivant la méthode d'identification utilisée. La méthode fondée sur la règle de Bayes apparaît plus simple, stable et performante que la méthode à base de réseau de neurones.

#### **1.4.2. Le tapis convoyeur**

La solution de convoyage par tapis est une évolution logique de la solution précédente, qui ne nécessite aucune modification des procédures de traitement de l'image et de discrimination des semences. Les semences sont transportées par un tapis mobile et passent devant un système d'acquisition qui met en œuvre un capteur CCD de type linéaire. L'image est reconstruite au fur et à mesure du défilement du tapis. De nos jours, l'emploi de capteurs linéaires a cédé la place à des capteurs CCD ou CMOS prenant une zone déterminée en deux dimensions. Nous retrouvons ainsi un mode opératoire analogue au placement manuel.

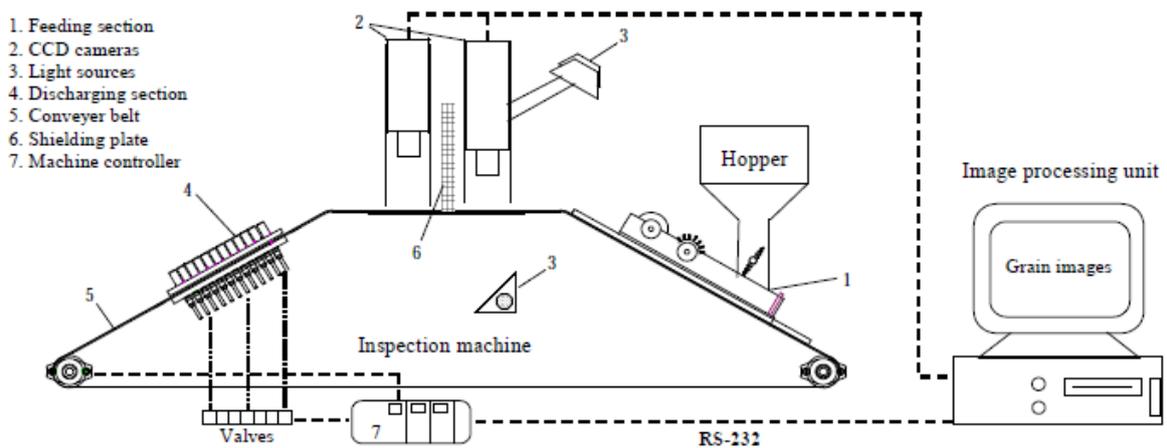
Egelberg, Mansson et Petersen, (1994), ont retenu cette solution, et l'ont appliquée à l'étude de cinq espèces de blé. Le système, commercialisé sous le nom de Graincheck 310, se compose d'une caméra CCD, d'un tapis de convoyage rainuré et d'un ordinateur (Figure 1.10). Ce tapis permet de placer les graines sur 8 rainures parallèles permettant ainsi l'acquisition d'un nombre important d'image de graines lors de l'arrêt de défilement du tapis. Un algorithme de traitement de l'image permet alors de caractériser un à un les grains étudiés. Les caractéristiques extraites sont analysées par un réseau de neurones permettant de discriminer les différentes espèces. Environ 15 graines sont analysées dans chaque image numérique, et le système permet une cadence de 8 objets par seconde.



**Figure 1.10: Graincheck 310**

*(Egelberg, Mansson et Petersen 1994)*

Wan, (2002) a eu comme objectif de réaliser un système capable d'analyser les grains de riz selon 13 catégories de critères de qualité. Il a construit un système incluant un dispositif de convoyage sur tapis commandé par un ordinateur (Figure 1.11). Il utilise deux systèmes d'acquisition d'images. Le premier consiste en une caméra CCD couleur permettant l'analyse de la surface des grains pour détecter des défauts de couleurs et les grains endommagés par des insectes ou anormaux. Un deuxième est composé d'une caméra CCD en niveau de gris et d'un retro-éclairage pour détecter les grains cassés et fissurés. Le système permet d'analyser en moyenne 200 grains par minute.



**Figure 1.11: Système d'analyse de la qualité du riz**

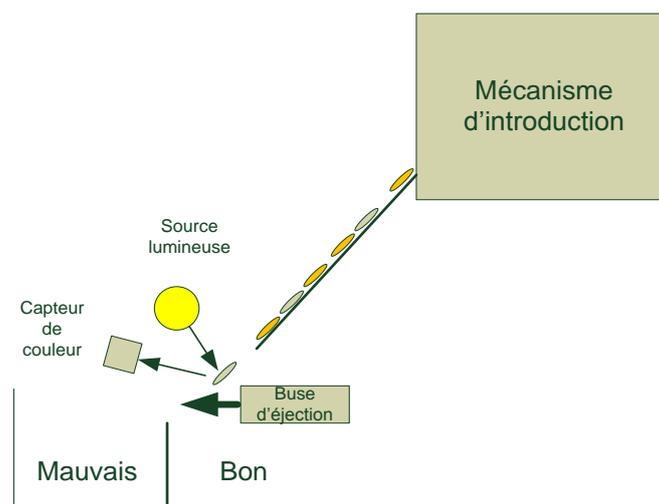
*(Wan 2002)*

### 1.4.3. Le placement par défilement rotatif

Ce système est une variante du convoyage sur tapis : tapis y est remplacé par un plan rotatif sur lequel sont déposées les graines. Le plan rotatif peut être lisse ou perforé pour permettre un bon placement des semences. Ainsi, les graines se présentent une par une et non par rangées. Une étude utilisant un système commercial reposant sur cette solution a été présentée par Feng et al., (2004). Cette étude met en œuvre un système automatisé de la société FOSS, le *Cervitec 1625 Grain Inspector*. Elle a pour but d'étudier la faisabilité d'un système de vision pour l'analyse du degré de vitrosité des grains de blé dur. Cette machine est capable de faire l'acquisition d'environ 8 grains par seconde.

### 1.4.4. Le placement par plan incliné

Un plan incliné permet d'obtenir une chute contrôlée le long d'une surface qui peut être lisse, rainurée, et munie d'éléments aptes à ralentir, réguler et guider la descente. Une telle disposition est présente dans de nombreuses machines de tri colorimétrique. Grâce à de telles machines, il est possible d'analyser la réponse spectrale de l'objet excité par une source lumineuse connue à haut débit. Certains systèmes de tri colorimétrique utilisent des caméras linéaires ou à deux dimensions, d'autres sont équipés de spectrophotomètres, de capteurs ponctuels sensibles aux lumières rouges, vertes ou bleues ou à la lumière obtenue en luminescence.



*Figure 1.12 : Système d'analyse colorimétrique des grains*

*(Hamid 2004)*

Les machines de tri colorimétrique telles que la machine *Sortex* (Hamid 2004) (Figure 1.12) atteignent des cadences de 160 semences à la seconde grâce à un traitement simultané de huit rangées de capteurs. Ces machines analysent la couleur réfléchi par la semence selon deux composantes chromatiques, généralement associées au rouge et vert. Le tri repose sur la comparaison des valeurs lumineuses mesurées par rapport à celles d'un échantillon moyen de référence.

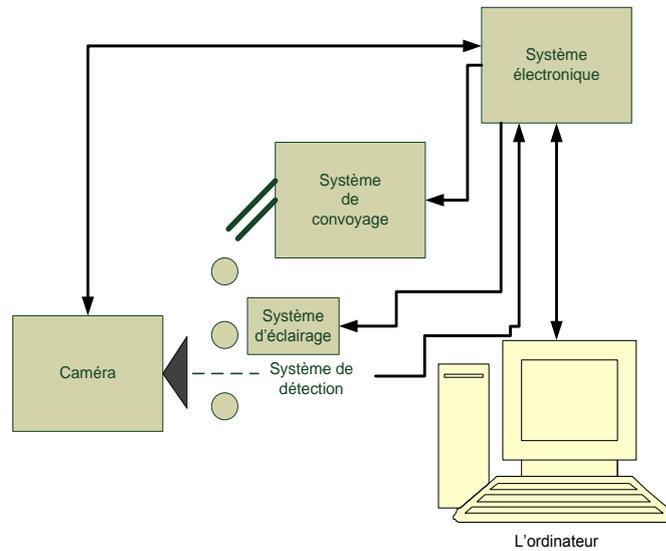
Dans le but de trier des pistaches, Pearson, (1994) a utilisé un système de tri colorimétrique de la société *Satake* proche, dans son principe, de la machine présentée précédemment. Afin de permettre l'analyse de la quasi-totalité de la surface de la pistache, le système comprend trois caméras linéaires. Le système d'acquisition est couplé à un PC contenant des cartes d'acquisition et de traitement numérique à base de microprocesseurs spécialisés dans le traitement du signal (*Digital Signal Processor, DSP*). Le système fonctionne à une cadence de tri de 40 pistaches à la seconde. Il permet de détecter et de classer les pistaches tachées avec un taux de succès de 85%. Une partie de l'erreur de classification est due à la variation de vitesse de passage des pistaches devant les capteurs.

#### **1.4.5. Le placement par chute libre**

Cette solution est apparemment la plus simple à concevoir. La semence admise dans le système tombe par son propre poids et se présente ainsi devant le système de prise de vue. Ce dispositif évite certains des inconvénients associés aux solutions précédemment présentées. Il n'y a pas de face cachée liée à l'introduction mécanique car le défilement des semences ne dépend d'aucun support de convoyage. Il n'est pas nécessaire de faire un pré-traitement pour isoler une semence de ses voisines dans les images numériques acquises. La cadence est libre et ne dépend que des capacités du système d'introduction.

Cette solution a été retenue par Plainchault et al., (2003). Le dispositif utilise un système de défilement de semences en chute libre couplée à un éclairage stroboscopique (Figure 1.13). Une caméra matricielle de type CMOS permet d'acquérir des images RGB, à une cadence d'environ 3 semences par seconde. Ce système a fait l'objet d'une étude de faisabilité portant sur les algorithmes d'identification des semences Muracciole et al., (2007). Une base de 5393 images de semences appartenant à 19 groupes qualitatifs a été acquise. Les taux d'identification correcte des semences variaient entre 88 et 95 % en fonction de la méthode de discrimination mise en œuvre. Ce travail nous a permis de mener une première réflexion sur les algorithmes de traitement d'image et de discrimination. Afin d'éviter des redites, seuls les

résultats obtenus sur le dispositif conçu et réalisé dans le cadre du présent travail seront présentés ici.



**Figure 1.13 : Schéma de principe du système d'acquisition**  
(Plainchault et al. 2003; Muracciole et al. 2007)

## 2. Réalisation d'un automate

Dans cette partie, nous justifierons tout d'abord les différents choix dans la conception et la réalisation d'un système d'acquisition des semences à haut débit. Nous présenterons les choix généraux, puis l'organisation et l'agencement des périphériques.

### 2.1. Les choix généraux

La réalisation d'un système d'acquisition nécessite la prise en compte de différentes contraintes dans des domaines tels que l'optique, l'électronique et la mécanique. Les précédentes études (Plainchault et al. 2003 ; Muracciole et al. 2007), nous ont montré que l'introduction de *semences en chute libre* avec un système de flash de type stroboscopique donnaient des résultats satisfaisants. Ces études nous ont également montré qu'un système mono-caméra n'était pas capable d'identifier les semences qui présentent des faces d'apparence hétérogène. C'est le cas, par exemple, des semences cassées ou multicolores. Pour cette raison, nous avons développé un *système à trois caméras* capable de caractériser la quasi-totalité de la surface des semences.

## **2.2.La mécanique**

Dans le cas d'un système d'acquisition en chute libre, les parties mécaniques peuvent être considérées comme indépendantes les unes des autres. Dès lors qu'un des étages est capable de prendre en compte toutes les sollicitations de l'étage précédent, nous pouvons considérer que les différents étages sont indépendants. Cette décomposition nous permet également de pouvoir intervenir sur les différents étages et mécanismes du système sans remettre en cause profondément les choix mécaniques des autres étages. Cette modularité permet également de pouvoir ajouter facilement des fonctionnalités suivant les besoins du système.

Dans le domaine de la certification des semences, de nombreux systèmes destinés à la séparation et au comptage des grains sont couramment utilisées. Ces systèmes utilisent soit un système de bol à défilement linéaire, soit un système de bol à défilement rotatif.

Les études précédentes déjà mentionnées nous ont montré que l'acquisition d'images de semences en chute libre avec un système d'introduction par le biais d'un bol vibrant de type linéaire donnait des résultats intéressants. Cependant, la séparation des grains n'est pas optimale quand les semences sont de calibres et de formes différentes : deux semences peuvent tomber en même temps. Notre choix s'est donc porté sur le système à bol vibrant rotatif : il permet de mieux séparer les semences, quelles soient ou non de même calibre.

## **2.3.Le capteur**

Le choix du capteur dépend essentiellement de la vitesse de chute d'une semence, laquelle est principalement conditionnée par la distance de chute. Le principe de la chute libre montre que le temps de chute est constant quelque soit la masse, mais les chocs sur les parois ou une introduction défectueuse peuvent modifier la vitesse.

Les capteurs linéaires sont utilisés lorsque la vitesse de déplacement est constante. Les capteurs matriciels sont préconisés lorsqu'il faut tenir compte de variations possibles dans un système donné. Nous avons choisi un capteur matriciel pour cette raison. Parmi les types de capteurs nous avons sélectionné le CMOS.

Plusieurs arguments nous ont conduits à préférer les caméras reposant sur la technologie CMOS. Nous avons déjà indiqué au paragraphe 1.1, que les images d'objets en mouvement obtenues avec une caméra CCD risquent d'être plus floues que celles obtenus avec une caméra CMOS. En effet, le temps de transfert de charge dans les caméras CCD n'est pas

instantané. Dans le cas des capteurs CMOS, la numérisation de l'intensité lumineuse se fait indépendamment pour chaque cellule de la matrice photosensible. Il est ainsi possible de n'en activer physiquement qu'une partie. Cette fonctionnalité permet d'augmenter la vitesse d'acquisition et de réduire le champ de vision du système, ce qui est très intéressant car la semence n'occupe qu'une petite partie de la surface du capteur (dans les caméras CCD au contraire, seules les lignes peuvent être désactivées, et non les colonnes).

## **2.4. L'éclairage**

L'éclairage stroboscopique suppose une source lumineuse dont le temps de réponse soit très court. Ce n'est pas le cas des tubes fluorescents, qui génèrent en outre un bruit électromagnétique, rendant difficile l'utilisation de circuits électroniques à proximité, à plus forte raison à l'intérieur d'un automate. Les lampes à incandescence sont souvent utilisées pour réaliser des flashes, mais leur filament ne peut pas supporter de cadences supérieures à un ou deux déclenchements par seconde. De plus, elles ont une durée de vie trop courte pour être applicables ici.

Les diodes électroluminescentes de conception plus récente, sont plus appropriées à notre étude. Leurs conditions d'utilisation et leur puissance conviennent en termes de robustesse, de spectre lumineux et de temps de réponse.

Lors d'une étude exploratoire (Muracciole et al. 2007), il a été montré qu'un fond de couleur bleue favorisait la procédure de segmentation des images : il n'existe pas en effet de semences de cette couleur dans la nature. Seules les semences enrobées de produits phytosanitaires peuvent présenter de telles couleurs. Du fait de la future disparition de tels traitements lors de la certification, il n'est pas nécessaire de prévoir des fonds d'une autre couleur. Pour éviter de saturer les trois caméras, le système d'éclairage doit être extrêmement directif. Pour cela les diodes doivent être disposées de part et d'autre de l'objectif des caméras et orientées de telle sorte qu'elles créent un halo de lumière au niveau du point de chute. Cette méthode d'éclairage peut cependant engendrer un fond non homogène compliquant la détermination de la position de la semence sur l'image numérique. Un système de fond rétro-éclairé nous permet de réduire ou d'éliminer ce problème.

## 2.5.L'architecture électronique

Le choix de la présentation des semences en chute libre impose de concevoir une architecture électronique permettant le traitement des données en temps réel : il est nécessaire que la totalité du traitement de la chaîne de vision s'effectue en un temps inférieur au temps de passage de la semence devant le capteur.

De nombreux circuits électroniques programmables peuvent en principe convenir, une présentation des différentes architectures possibles dans le domaine de l'embarqué a été présenté par Batlle et al., (2002).

- Le micro-processeur *CPU (Control Processor Unit)*

Le CPU (*Control Processor Unit*), composant puissant, rapide et généraliste, est au cœur des microordinateurs. Il est donc possible d'effectuer le traitement des images à l'aide du CPU d'un ordinateur lié au système. Dans une telle approche, l'automate transmet des images brutes à l'ordinateur, qui en assure le traitement. Pendant les périodes de latence ou de faible charge de travail de l'ordinateur, le CPU peut effectuer d'autres tâches en « parallèle ». Le CPU est adapté aux traitements en temps réel. Il y parvient par l'intermédiaire d'un système d'exploitation adapté (*Operating System ; OS*), qui doit être lui aussi capable de prendre en compte les contraintes temporelles. C'est le cas des OS « temps réel » qui permettent de contrôler le temps d'exécution des tâches et leur répétabilité. Cependant, les OS les plus courants ont d'autres objectifs et c'est probablement la raison pour laquelle les automates de tri de semence fonctionnant, par exemple, sous Windows utilisent des mécanismes d'introduction tels que le défilement sur tapis. En effet, de tels mécanismes permettent de ralentir ou d'accélérer le passage des semences, et il est assez facile de subordonner la vitesse de l'automate à la rapidité de calcul du couple OS/CPU.

Dans notre projet nous cherchons une solution radicalement différente puisque l'électronique doit s'adapter à la vitesse de défilement des semences et non l'inverse.

- Le microcontrôleur *MCU (Micro Controller Unit)*

Comme pour le CPU, le MCU (*Micro Controller Unit*) peut travailler en temps réel si le système d'exploitation le prévoit. Fondamentalement, l'architecture interne du MCU diffère très peu de celle du CPU. La principale différence tient à l'ajout de la gestion des périphériques à l'intérieur du MCU. De plus le MCU est en général conçu de manière à

présenter un rapport « efficacité/consommation énergétique » performant, ce qui le rend plus intéressant pour la réalisation d'un système autonome et embarqué. La gamme des MCU est aujourd'hui très étendue. Il existe des MCU à très grosse capacité qui sont cependant incapables de prendre en charge des opérations mathématiques indispensables pour nos traitements. Nous observons cependant que les fabricants cherchent à introduire des co-processeurs mathématiques dans les MCU afin justement de les rendre aptes à ce genre de calcul. C'est notamment le cas des MCU EP9315 de CirrusLogic qui est composé d'un noyau ARM 920T et d'un co-processeur mathématique Maverick ou encore des MCU Freescale comportant des instructions de calcul matriciel AltiVec bien connue des possesseurs de Macintosh puisque présent dans ces ordinateurs sur les architecture MCU du G3 au G5 et maintenant disponible sur les MCU Power.

- Le processeur de traitement du signal (Digital Signal Processor)

Le DSP (Digital Signal Processor) est en revanche un composant bien adapté aux calculs mathématiques exigés par le traitement du signal. Son rapport puissance sur consommation d'énergie est excellent. Il est capable de charger un grand nombre d'informations en parallèle. Mais à l'instar des CPU ou des MCU, les DSP ne peuvent satisfaire aux contraintes de parallélisme et de temps réel que grâce à des systèmes multi-processeurs (Batlle et al. 2002) ou à l'utilisation d'OS temps réel. Certains DSP sont également pourvus de solution pour le traitement de l'image pré-cablé comme le zoom des données et le filtrage FIR des données sur les DSP Multimedia TriMedia de Philips ou les architecture DaVinci de Texas Instrument. Lohier, (2000) présente l'utilisation d'une solution à base d'architecture C8X et C6X de Texas Instrument pour l'évaluation de système de vision industriel. La solution préconisée par Analog Device et son triplet de solution Blackfin, Sharc et TigerSharc sont des DSP à architecture de type Harvard à chargement parallèle de plusieurs instructions offrant également une conception simplifiée de systèmes multi-processeurs performants.

- Le circuit logique programmable

La famille des circuits logiques programmables regroupe une série de composants formés d'éléments logiques indépendants les uns des autres. Au sein de cette famille, les FPGA (*Field Programmable Gate Array* ; réseau logique programmable) sont les composants les plus utilisés. Ils incorporent de plus en plus de ressources spécifiques tels que des

convertisseurs analogiques-numériques (Actel s.d.), des multiplieurs, de la mémoire et des unités de calcul numérique permettant d'effectuer des opérations de multiplication et d'accumulation (fonction de sommation) (Altera s.d. ; Xilinx s.d.), et même des circuits spécifiques à l'amélioration d'images pour des solutions multimédia embarqué (QuickLogic Corporation s.d.).

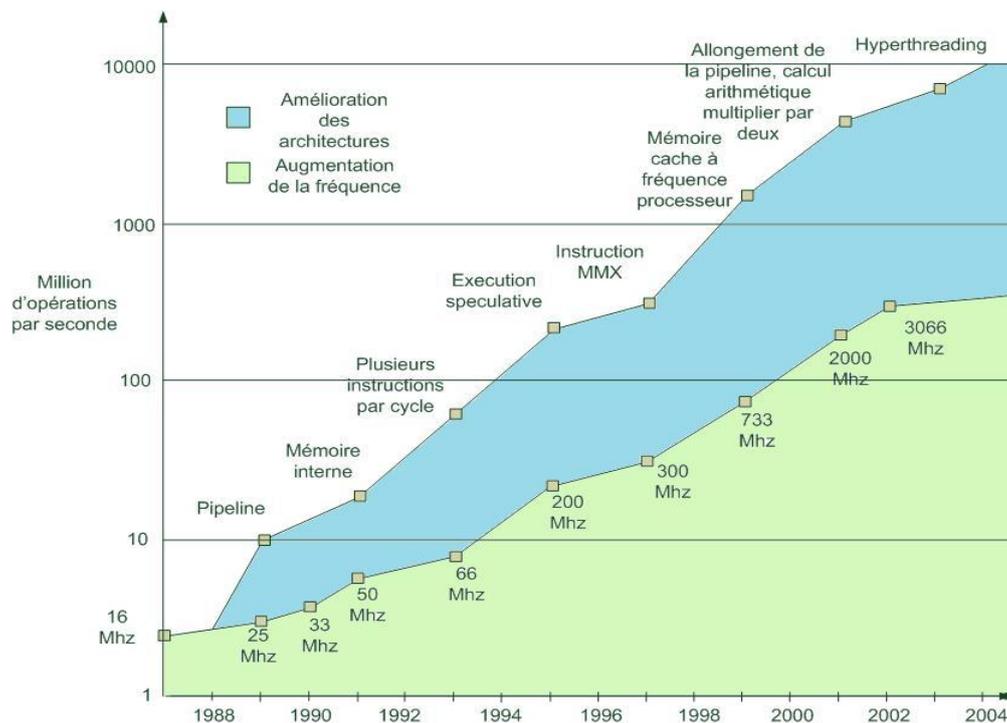
L'indépendance entre les cellules opérationnelles constitutives du FPGA permet de traiter des informations en parallèle. Un système de codage permet de décrire la liaison entre les cellules et de définir ainsi le fonctionnement d'un processus. Il est également possible d'estimer le temps de propagation entre la sortie d'une cellule et l'entrée de la suivante. Une analyse du chemin critique de la liaison permet ainsi de déterminer le temps minimal entre l'entrée et la sortie d'une architecture logique complexe. Cette analyse temporelle conduit ainsi à une approche déterministe. Le FPGA offre donc structurellement une capacité de traitement massivement parallèle. Un langage de programmation spécifique comme le VHDL (*Very High Speed Description Language* ; langage de description à très haute vitesse) ou Verilog, permet de planifier les chemins empruntés par l'information et de synthétiser toute une organisation logique.

Ces éléments opérationnels étant tous indépendants, il est ainsi possible de partager l'espace programmable en autant de zones dédiées aux traitements à effectuer. La « parallélisation » peut être organisée à l'intérieur même d'une seule puce. C'est cette particularité que nous avons souhaité utiliser au maximum afin de permettre une future cadence très élevée dans le traitement de l'information.

La chaîne de vision est structurellement séquentielle. Cependant, au sein de cet ensemble séquentiel certaines opérations peuvent être traitées de manière indépendante et parallèle. C'est notamment le cas du traitement colorimétrique des images qui peut s'effectuer de manière indépendante et parallèle pour les composantes de couleurs Rouge, Vert et Bleu. Ceci se traduit par une accélération notable par rapport aux DSP, MCU et CPU. Grâce au FPGA, nous pouvons ainsi réaliser une « architecture dédiée ».

Dans notre projet nous cherchons une solution radicalement différente aux architectures dites « figées » (CPU, MCU, DSP) puisque l'électronique doit s'adapter à la vitesse de défilement des semences et non l'inverse.

L'évolution de l'architecture des CPU de type x86 est un exemple intéressant pour comprendre la dualité fréquence-architecture dans l'efficacité de calcul. La Figure 1.14 présente l'évolution de cette architecture depuis son introduction en 1980 jusqu'à 2004. Nous constatons que l'efficacité de calcul provient principalement des améliorations de l'architecture des CPU plus que de la fréquence qui de nos jours semble marquer le pas avec la difficulté de dépasser des fréquences supérieures à 4 GHz avec des systèmes de refroidissement conventionnel. Dans cette lignée, nous considérons que les progrès réalisés par les principaux fondateurs de circuit logique programmable que sont ALTERA et XILINX dans l'efficacité de cette solution pour leur utilisation dans le cas de traitement de l'image ou de solution dédiée (SoPC, System on Programmable Chip) à base de MCU permettent d'envisager leur utilisation pour la réalisation d'un système d'acquisition à haut débit. C'est pourquoi nous avons choisi de réaliser une carte spécifique utilisant des cartes à base de FPGA afin de répondre au mieux à la problématique d'acquisition de semences en chute libre. Nous détaillerons plus précisément dans la partie suivante l'agencement et la réalisation de l'ensemble de l'automate.

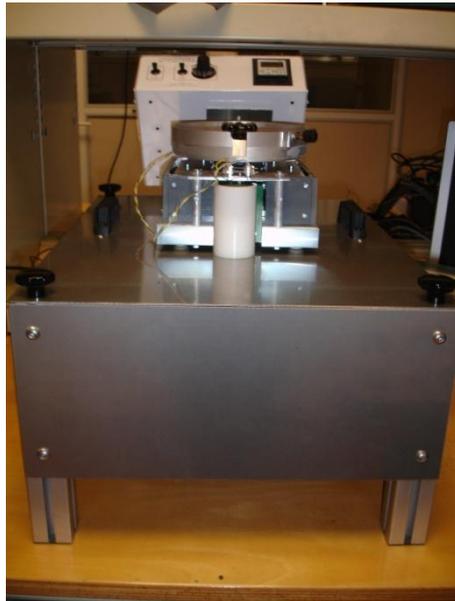


**Figure 1.14 : Performance des microprocesseurs Intel**

*(Stallings 2006).*

## 2.6.Réalisation.

L'automate que nous avons réalisé comprend deux étages (Figure 1.15). Le premier est celui de l'introduction des semences ou des objets. Le deuxième assure l'acquisition des images.



*Figure 1.15 : Système d'acquisition*

### 2.6.1. Agencement général

Le système d'introduction utilisé est une adaptation d'un compteur à grain de marque Chopin (Chopin technologies, Numigral I). Initialement carrossé avec un plan incliné, il a été modifié afin de permettre une introduction des semences en chute libre. Il permet d'introduire les semences une à une dans un entonnoir spécialement usiné pour cette application. L'entonnoir conduit les semences jusqu'à une barrière de détection permettant le déclenchement de la prise d'images.

La présence d'une semence en face des caméras est détectée par un système composé d'une barrette de diodes infrarouges émettrices et d'une barrette de diodes réceptrices. La distance entre l'émetteur et le récepteur permet de régler la sensibilité de détection des petits objets. Ainsi plus le récepteur est loin de l'émetteur, plus il est sensible à la modification du signal car il reçoit moins de puissance lumineuse. Un seuil réglable sur la tension des diodes réceptrices permet de faire varier la sensibilité de la détection en fonction du calibre des

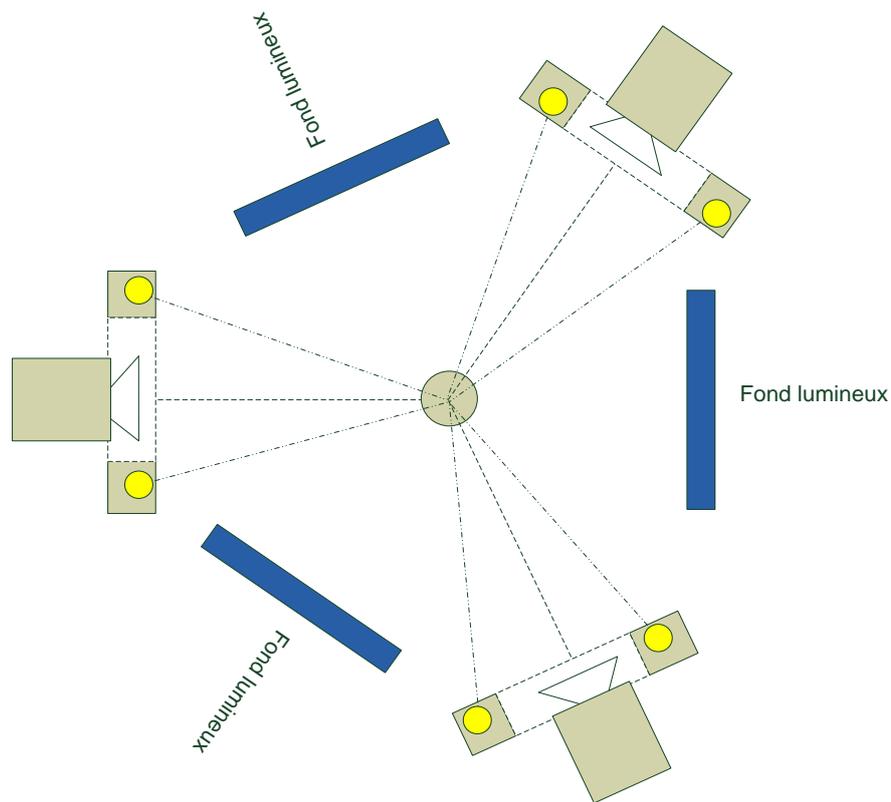
semences analysées. Le réglage choisi dans la présente application permet de détecter des semences de calibre supérieur à 1 mm. Dans un système comprenant 3 caméras, la barrière infrarouge ne peut plus être placée parallèlement à l'axe optique de l'ensemble caméra-objectif. Il faut la placer au-dessus des caméras, ce qui implique qu'un délai est à prévoir entre le passage de la semence à travers le faisceau infrarouge et le déclenchement de la prise de vue. La distance de chute est de 33 cm. Le temps entre le passage devant la barrière et l'entrée de la semence dans le champ de vision de la caméra peut donc être considéré comme constant quelles que soient la masse. Il reste donc à étalonner le système de temporisation, ce qui est réalisé dans le système électronique.

### 2.6.2. Agencement des caméras et éclairage

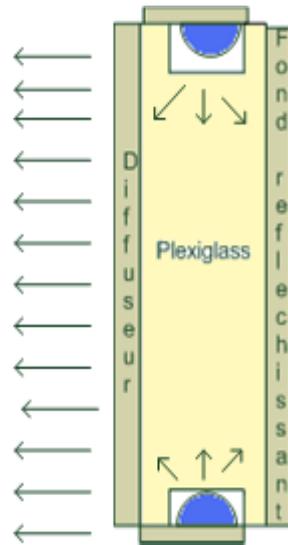
Les trois caméras sont disposées sur un même plan, chacun des axes optiques étant à  $120^\circ$  des deux autres (Figure 1.16).

Cette disposition des caméras impose une forte contrainte sur le système d'éclairage. En effet, les sources lumineuses sont à placer de telle sorte qu'elles ne saturent pas les capteurs. Celles retenues sont des diodes blanches de type *Luxeon star V* (Philips Lumileds) d'une puissance unitaire de 5W. Elles sont collées sur un support métallique dont la flexibilité est suffisante pour pouvoir régler l'inclinaison des diodes à l'aide de vis. La colle utilisée est une pâte thermique adhésive. Cette pâte assure une bonne dissipation de la chaleur des diodes, par répartition sur tout le support. Les diodes sont équipées de lentilles qui concentrent les rayons lumineux sur la semence en chute, de manière à réduire la puissance lumineuse nécessaire et éviter de saturer les caméras. Cette organisation pose cependant un problème : elle ne permet pas d'avoir un fond homogène, élément clé pour une détection sans défaut de la semence sur l'image. Une solution simple serait de soustraire l'image obtenue avec semence d'une image obtenue sans semence. Cela nécessiterait le stockage d'une image de référence, solution non souhaitable, dans le cas d'un système embarqué. Un système de fond lumineux auxiliaire nous a paru plus approprié. Il est réalisé à l'aide de diodes bleues pour faciliter la segmentation des images. Ce fond doit être à effet stroboscopique, synchrone avec l'éclairage par diodes blanches, pour éviter l'apparition d'une traînée sur l'image (liée à la chute de la semence). Des essais préliminaires nous ont montré qu'une durée d'éclairement comprise entre 20 et 120  $\mu$ s permettait un ajustement satisfaisant de la luminosité des images. D'autre part, l'intensité d'éclairage du fond doit être suffisante pour saturer la composante bleue du capteur en moins de 120  $\mu$ s. Les contraintes d'intégration nous ont donc amené à imaginer une solution

spécifique pour le fond (Figure 1.17) : un bloc rectangulaire de « plexiglass », d'épaisseur 8 mm, est éclairé par quatre diodes bleues, d'une puissance de 4W, équipées de lentilles dont le diamètre ne dépasse pas 6mm. Deux circuits intégrés servant de support aux diodes ont été réalisés au laboratoire. Une des faces du plexiglass est peinte en blanc pour réfléchir la totalité des longueurs d'onde du visible, augmentant ainsi la puissance lumineuse émise par la face non traitée. Cette dernière est surmontée d'une plaque diffusante d'épaisseur de 4 mm, qui homogénéise le fond.



**Figure 1.16 : Schéma de l'organisation interne du système d'acquisition**



*Figure 1.17 : Principe du fond lumineux vu sur la tranche*

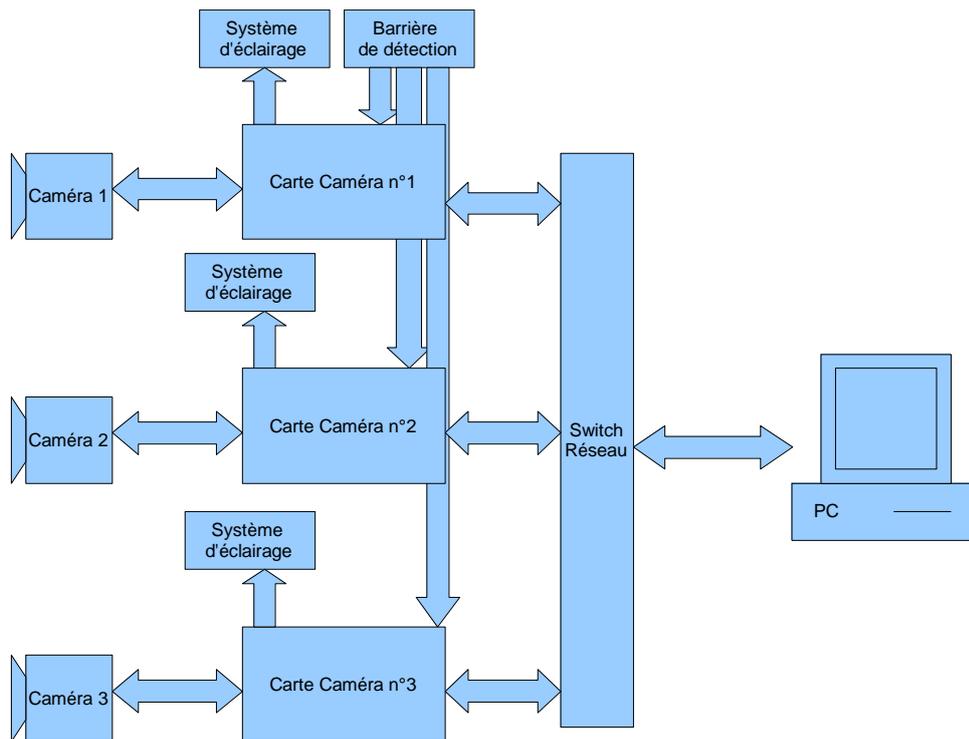
### 2.6.3. Agencement électronique

Tout comme le système mécanique, la partie électronique est modulaire. Le système d'acquisition est constitué de trois cartes de contrôle des différentes caméras. Chacune de ces cartes se compose de deux circuits électroniques, un premier chargé du contrôle de la caméra et de la prise d'image, un second chargé de la sauvegarde de l'image acquise et de son transfert par une interface réseau de l'image vers le PC. L'utilisation d'une interface réseau comme interface de communication entre la carte et le PC permet d'identifier chaque caméra par une adresse fixe définie préalablement. Ainsi chaque image acquise est alors référencée selon son adresse et un numéro défini par le défilement des semences devant la caméra. Cet agencement optique et électronique permet d'augmenter rapidement et simplement le nombre de caméras sans avoir à remettre en cause toute l'architecture des cartes associées aux caméras mais également l'application logiciel sur le PC pour le stockage des images.

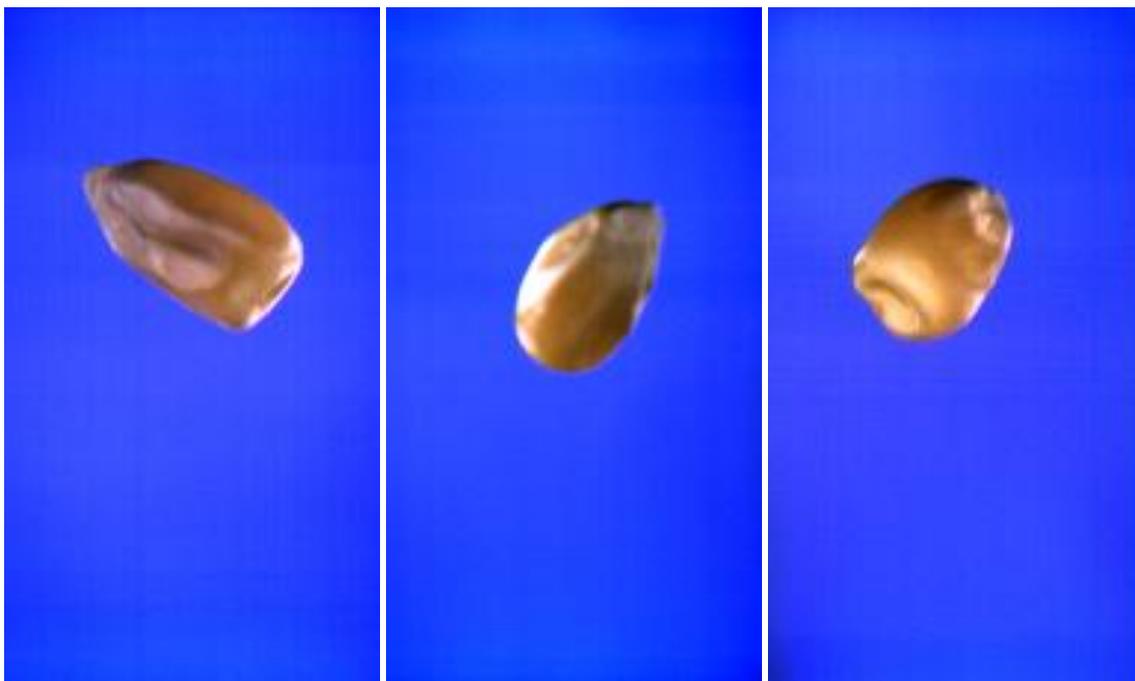
Comme le montre la Figure 1.18, le signal de la détection d'une semence par la barrière infrarouge est utilisé pour la synchronisation de la prise d'image par les trois caméras. Ce signal est analysé par le premier circuit. Ce premier circuit est une carte d'évaluation de la société Xess XSA-3S1000. Il est chargé du contrôle de la caméra et de la temporisation entre le moment où la semence coupe le faisceau et le moment où le signal de prise d'une image est activé.

Lors de la prise d'image le capteur renvoi un flux de pixels synchronisé par une horloge correspondant à leurs transferts. Ce flux est alors transféré par l'intermédiaire du premier circuit vers le deuxième circuit électronique servant d'interface entre le PC et la carte caméra. Ce deuxième circuit est une carte d'évaluation mini-module de la société MEMEC comportant une interface réseau, 64 Mb de RAM (Random Access Memory) et un FPGA Virtex4 FX12 de la société Xilinx. La particularité de ce dernier composant est d'avoir un cœur de microcontrôleur PowerPC 405 sur lequel il est possible de définir une architecture répondant au mieux à nos besoins. Il s'agit dans notre cas d'un système de mémorisation à haut débit d'un flux de pixel et du transfert d'une image par le biais d'un client-serveur embarqué vers le PC. Dans cette carte le flux de pixel est redirigé directement vers une zone de la mémoire RAM permettant de stocker 400 images. La mémoire RAM est partagée entre le microcontrôleur et le flux de pixels par le biais d'un contrôleur mémoire multi-port (Xilinx, Multi Port Memory Controller Reference Design s.d.) permettant un accès parallèle à la mémoire. Une fois l'image acquise un signal est envoyé au microcontrôleur qui transfère alors l'image vers le PC. Cet agencement et la reconfigurabilité naturelle du FPGA permet une grande modularité du système au prix d'une complexité dans la réalisation. Il ne faut pas moins de 5 logiciels différents (suite logiciel Xilinx comportant un outil de synthèse pour FPGA, un outil de réalisation et de programmation d'architecture microcontrôleur, et un outil d'analyseur logique invasif pour l'analyse des signaux intra-FPGA, un logiciel de développement intégré Eclipse pour la réalisation du serveur programmé en JAVA sur le PC et d'un logiciel de réalisation de circuit électronique Orcad), et autant de langage et d'interface de programmation pour pouvoir réaliser ce genre de système. Avec cet agencement, le circuit électronique prend en charge le fonctionnement de la caméra, la gestion de l'activation de l'éclairage ainsi que sa durée, la gestion de la détection des semences et la synchronisation de l'ensemble. Le rôle de l'ordinateur est ainsi réduit à l'interface Homme-Machine, alors que dans la plupart des applications précédemment décrites, c'est l'ordinateur qui orchestre le fonctionnement de l'ensemble.

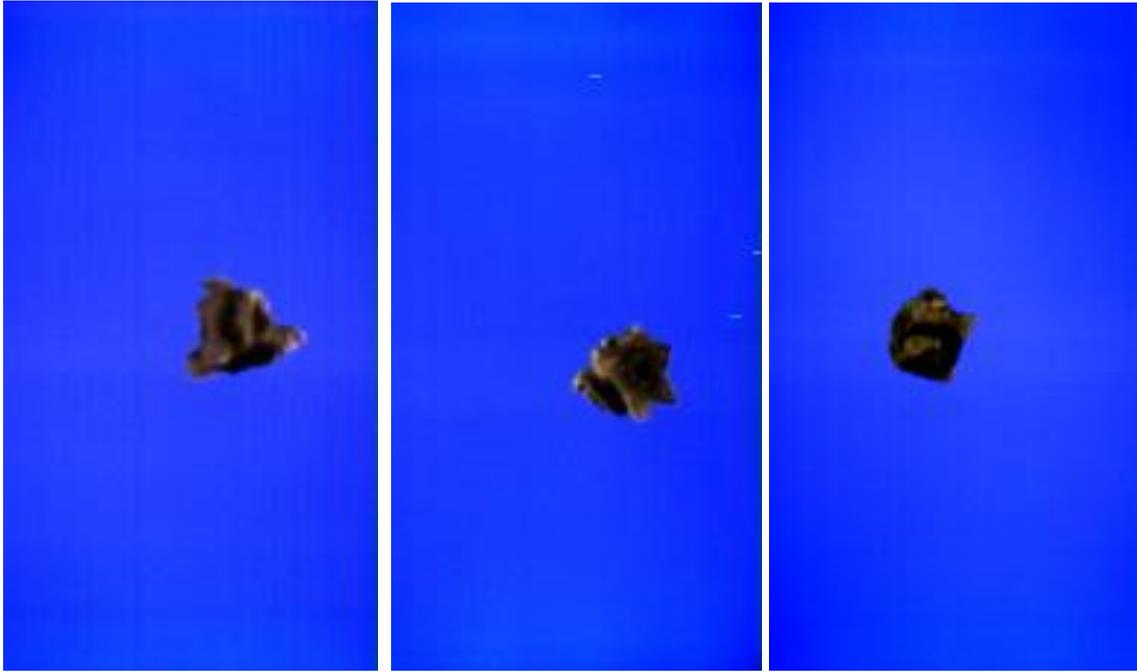
Le système d'acquisition réalisé permet de prendre plus de 50 images par seconde ce qui est la cadence maximale atteignable par le capteur utilisé dans cet automate. Les figures Figure 1.19 à Figure 1.21 montrent des images de semences acquises avec le système que nous avons réalisé.



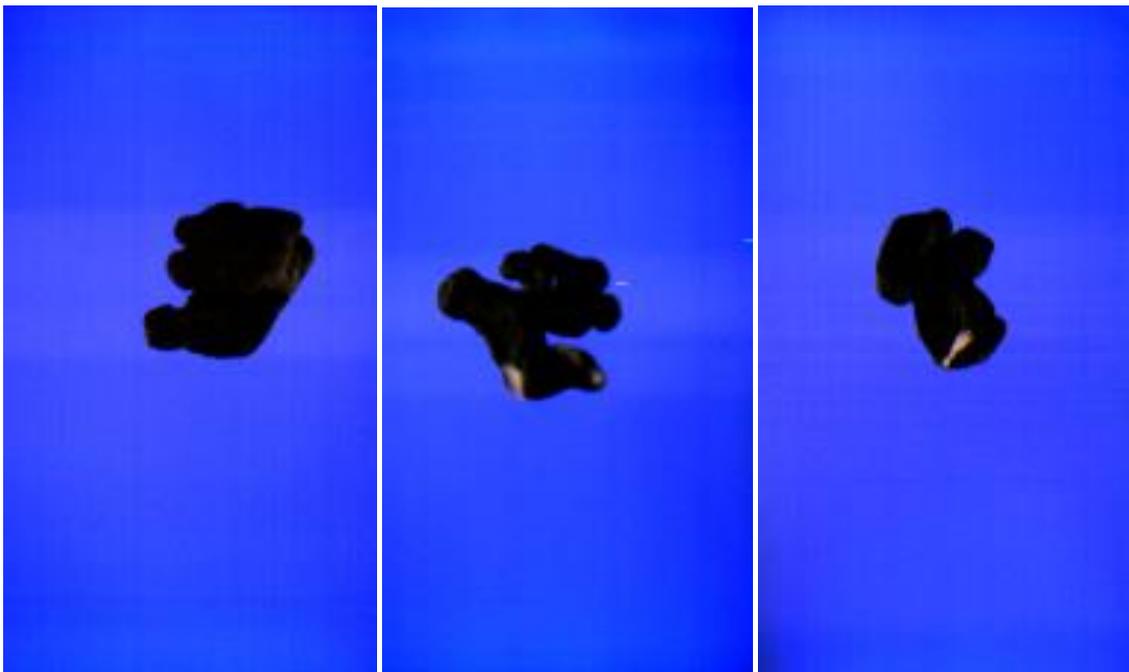
*Figure 1.18 : Schéma de l'organisation électronique du système d'acquisition*



*Figure 1.19 : Image d'une semence de maïs acquise avec les trois caméras.*



*Figure 1.20 : Image d'une semence de betterave.*



*Figure 1.21 : Image d'un sclérote.*

### **3. Acquisition d'images avec le système de vision**

#### **3.1. Etude de la précision et de la répétabilité de l'appareil.**

Il nous a paru nécessaire d'évaluer la précision et la répétabilité du système de vision. Dans cette partie, nous présenterons les résultats obtenus en testant l'appareil avec des billes plastiques sphériques calibrées de 6 mm et de 8 mm de diamètre.

##### **3.1.1. Procédure expérimentale**

Les images d'un ensemble de billes de diamètre de 6 mm et de 8 mm ont été acquises par le système de vision. Le diamètre de ces billes a été préalablement vérifié par mesure manuelle à l'aide d'un pied à coulisse. A la précision de 20  $\mu\text{m}$  du pied à coulisse, les diamètres sont parfaitement égaux. Les caméras ont été calibrées en ajustant la balance des blancs, à l'aide d'une charte de couleur de type QPCard (QPCARD s.d., référence 101 et 201). Le calibrage de la balance des blancs n'a pas été réalisé dynamiquement car il est difficile et coûteux de trouver des billes de même calibre et dont la couleur soit calibrée. Pour cette raison, les caméras ont été calibrées *in situ*, dans la machine même, à l'aide d'écrans composés de feuilles provenant de la mire de couleur recevant la lumière prévue pour révéler la surface de la graine, en éclairage frontal ou réfléchif. La fenêtre d'activation du capteur a été réglée expérimentalement. Nous avons choisi une résolution d'image brute de 256 par 512 pixels. Cette fenêtre d'activation correspond à la dimension du fond lumineux. Les caméras CMOS du système utilisent un filtre de Bayer (voir paragraphe 1.2.2). Dans un tel filtrage, chaque pixel est représenté par 4 valeurs de luminance, associées au rouge, au vert (deux valeurs) et au bleu. Nous considérons dans la suite qu'un pixel est composé des trois composantes chromatiques rouge, bleu et de la moyenne des deux pixels verts. Ceci a pour effet de réduire l'image à trois matrices de 128 par 256 pixels, associées aux trois canaux de couleur. Nous avons éliminé toutes les images peu exploitables, ce qui nous a conduit à ne conserver que 80 billes de 6 mm et 65 billes de 8mm. Les clichés considérés comme inexploitables correspondent à des billes collées à l'un des bords de l'image (cas le plus fréquent), des billes hors du champ d'une des caméras, ou à la présence de plusieurs billes sur un même cliché. Ces différents problèmes résultent principalement de l'inadaptation du système d'introduction à ce genre d'objets. Les billes plastiques sont en effet des objets avec des caractéristiques très particulières en termes de densité et de surface. Leur densité génère des phénomènes de

rebond à l'intérieur de l'entonnoir d'introduction. Cela explique le fort pourcentage de clichés rejetés. Leur surface lisse est à l'origine de points lumineux provenant des différentes sources d'illumination. Les billes trop hautes ou trop basses dans chaque cliché apparaissent sombres tandis que celles qui sont au centre sont correctement éclairées. Cette variabilité très forte dans le positionnement des billes ne se retrouve pas dans les semences qui sont plus facilement introduites par le mécanisme automatique. Chaque bille est caractérisée par trois paramètres de forme : la *longueur* (illustrée par la figure Figure 1.23), le *diamètre équivalent* et l'*aspect rectangulaire*. Ces paramètres sont évalués sur les images numériques, par des méthodes de traitement d'images qui seront présentées dans le chapitre 3.

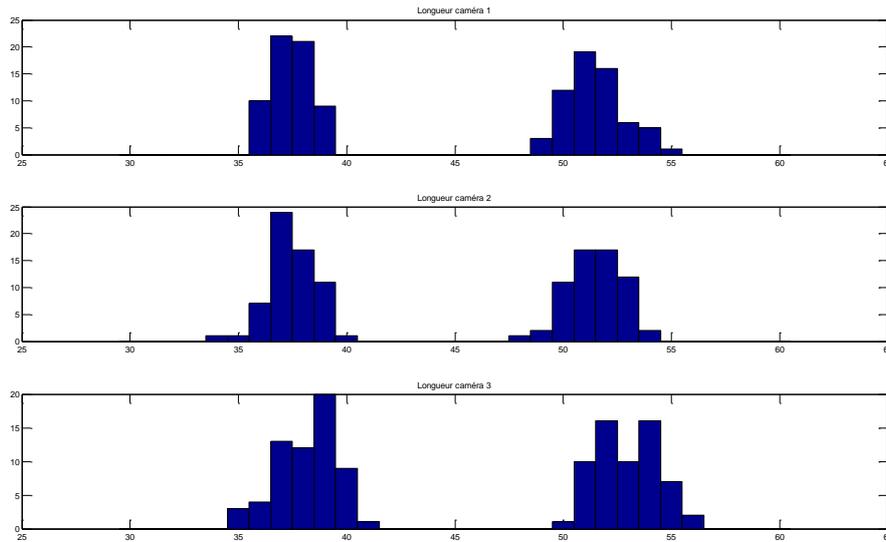
### 3.1.2. Résultats

#### - *Longueur mesurée*

Le tableau 1 donne les moyennes et les écart-types des longueurs mesurées sur les images obtenues avec les trois caméras. Ces données sont également présentées sous forme d'histogramme sur la Figure 1.22. Les valeurs moyennes obtenues avec les différentes caméras sont très proches pour un même calibre de bille. Exprimés en pixels, les écarts sont tous inférieurs à 2, et si on les ramène en pourcentage, ils ne sont jamais supérieurs à 5%. L'écart entre les caméras en valeur moyenne est de 1,5% pour les billes de calibre 6, et de 2,6% pour les billes de calibre 8.

	Caméra 1	Caméra 2	Caméra 3
Longueur moyenne Bille 6 mm (Pixels)	37.46	37.48	38.17
Ecart type Bille 6 mm (Pixels)	0.87	1.23	1.95
Longueur moyenne Bille 8 mm (Pixels)	51.46	51.46	52.95
Ecart type Bille 8 mm (Pixels)	1.82	1.59	2.07

**Tableau 1.1 : Moyenne et écart-type de la longueur des billes de calibre 6 et 8 mm sur les trois caméras.**



**Figure 1.22 : Histogramme des longueurs sur les trois caméras**

La caméra 3 a en effet une position légèrement différente par rapport au point de chute. Cet effet est visible sur l’histogramme des longueurs (Figure 1.22). L’histogramme de la caméra 3 est légèrement décalé vers les hautes valeurs. La caméra 3 est probablement légèrement décalée par rapport au point de chute.

**- Diamètre équivalent**

Le diamètre équivalent est celui d’un cercle ayant une surface égale à celle de la forme étudiée. D’une manière similaire à la longueur, le diamètre équivalent mesuré avec la caméra 3 est significativement différent de celui obtenu avec les autres caméras (Tableau 1.2). La différence reste cependant faible et inférieure à 1 pixel.

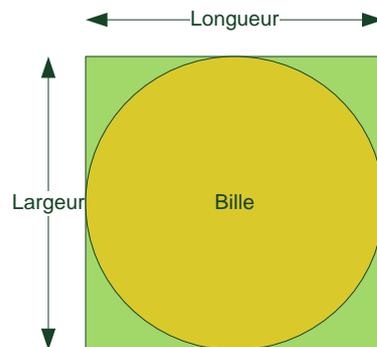
	Caméra 1	Caméra 2	Caméra 3
Diamètre équivalent moyenne Bille 6 mm (Pixels)	40.76	40.56	41.18
Ecart type Bille 6 mm (Pixels)	0.80	0.87	1.8
Diamètre équivalent moyenne Bille 8 mm (Pixels)	54.74	54.49	55.94
Ecart type Bille 8 mm (Pixels)	1.56	1.48	1.98

**Tableau 1.2 : Moyenne et écart-type du diamètre équivalent des billes de calibre 6 et 8 mm (trois caméras)**

De plus, le diamètre équivalent est un peu plus élevé en moyenne que la longueur des billes de même calibre. Cette différence, qui reste faible, est probablement en relation avec la procédure d'évaluation de la surface des formes.

- *Aspect rectangulaire*

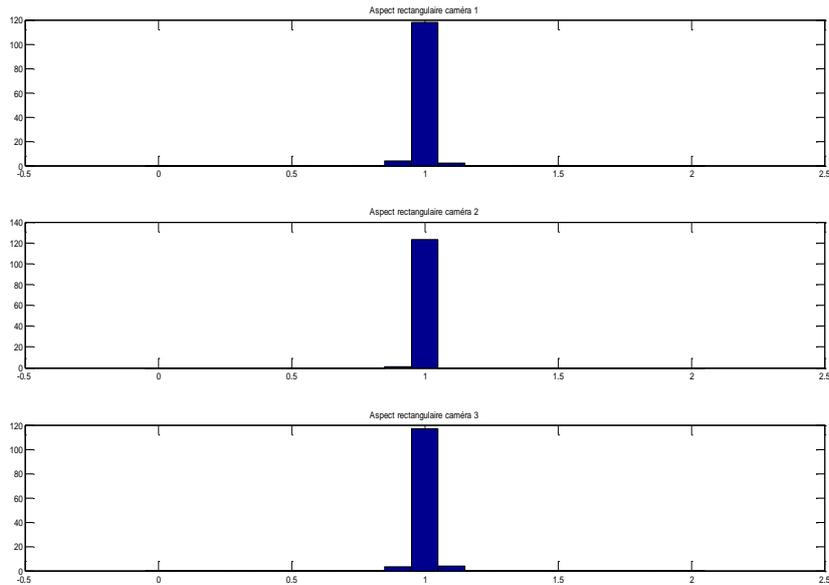
L'aspect rectangulaire est le rapport entre la longueur et la largeur du rectangle exinscrit (Figure 1.23) à un objet. Dans le cas d'une sphère, ce rapport est égal à 1. Le Tableau 1.3 et la Figure 1.23 montrent que ce diamètre équivalent est très proche de 1 quelle que soit la caméra étudiée. Ainsi, grâce au système d'éclairage stroboscopique, la prise d'image est suffisamment rapide pour éviter une déformation apparente de l'objet. Il n'y a pas d'allongement de la forme de la bille qui pourrait résulter d'un effet de flou dû au mouvement.



*Figure 1.23 : Schéma décrivant l'aspect rectangulaire*

	Caméra 1	Caméra 2	Caméra 3
Aspect rectangulaire moyen Bille 6 mm	0.98	0.99	0.99
Ecart type Bille 6 mm	0	0	0
Aspect rectangulaire moyen Bille 8 mm	0.98	0.99	1.00
Ecart type Bille 8 mm	0	0	0

*Tableau 1.3: Moyenne et écart-type de l'aspect rectangulaire moyen des billes de calibre 6 et 8 mm (trois caméras)*



**Figure 1.24 : Histogrammes du diamètre équivalent sur les trois caméras**

- **Test d'équivalence des caméras**

Les différentes mesures présentées précédemment nous ont montré que le système d'acquisition ne déformait pas les billes en chute libre. Elles montrent également que nous avons une précision de l'ordre de 140  $\mu\text{m}/\text{pixel}$  sur la bille. Nous pouvons donc maintenant nous poser la question de l'équivalence de la prise d'image. Pour cela une analyse de variance (Wonnacott 1998) a été réalisée sur l'analyse de longueur des billes perçues par les différentes caméras. Nous avons considéré comme hypothèse nulle  $H_0$  l'égalité entre les moyennes des longueurs des billes perçues par les caméras.

Pour cela nous avons appliqué la fonction Matlab® `anova1` sur les données. Le résultat obtenu avec cette fonction montre que la probabilité que  $H_0$  soit vérifiée sur les trois caméras est de 0.073%. Par conséquent, nous pouvons considérer que les trois caméras ne sont pas égales.

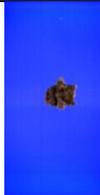
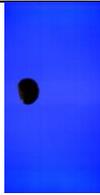
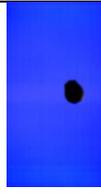
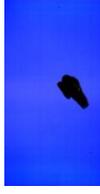
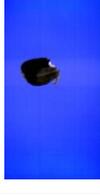
La même démarche menée sur les caméras A et B montre que l'hypothèse  $H_0$  a une probabilité de 93,05%. Cela nous permet de considérer que les résultats obtenus sur les deux caméras sont identiques.

### 3.2. Création d'une base d'images de semences

Dans le but de tester le système et également de disposer de données pour l'étude d'analyse d'images et de discrimination des espèces, une collection d'images de semences a été créée. Cette collection est composée de 1617 semences, prises par chacune des caméras soit 4851 images. Elle comprend 11 espèces habituellement présentes dans les lots certifiés de tournesol auxquelles s'ajoutent deux catégories correspondant aux amandes et aux semences cassées de tournesol (Tableau 1.4). Parmi ces onze espèces, les graines de folle avoine présentent une morphologie atypique et variable : elles comportent une arête parfois absente à la suite de chocs ou de manipulations (Figure 1.25 et Figure 1.26). Ces arêtes entrent cependant dans la collection d'images, car elles restent présentes dans le lot. La folle avoine présente aussi la particularité d'avoir des poils qui forment autant de points d'accrochage où peuvent se prendre d'autres semences. Cette semence a été particulièrement difficile à introduire par le mécanisme automatique. Ceci explique le faible nombre d'images exploitables pour cette espèce dans la base d'images.

Les sclérotés ne sont pas des semences mais des champignons qui accompagnent couramment les lots de tournesol. Ce champignon a pour particularité d'être présent sur la fleur de tournesol. Il est revêtu d'une enveloppe durcie qui peut avoir des formes et des calibres très variés. Cet objet est de couleur sombre, et, dans certain cas, il ressemble à des semences de tournesol. Ces deux groupes, folle avoine et sclérotés, sont particulièrement visés par la réglementation puisque les critères de certification des lots exigent que la folle avoine soit totalement absente et que les sclérotés (Figure 1.21) soient en proportion inférieure à 5 objets pour chaque échantillon réglementaire de tournesol. Par ailleurs, les autres espèces exigent moins d'attention mais nécessitent d'être identifiées. Ainsi, la base contient les semences dont la fréquence au sein des lots de tournesol est la plus élevée. Ces espèces sont des semences dont le calibre est conforme à la capacité du système à les détecter et à les traiter. Un problème se pose pour les cuscutes par exemple, qui sont, comme la folle avoine, des semences tout à fait indésirables. Mais leur calibre est très petit, de l'ordre du millimètre, ce qui rend malaisé l'acquisition de leurs images par le système. Cependant ce n'est pas un inconvénient majeur dans la mesure où le calibre très petit écarte les cuscutes du traitement d'ensemble : par exemple elles ne déclenchent pas la prise d'image faute d'être repérées par la barrière de détection.

Contrairement aux billes calibrées, les semences ont posé peu de problèmes au mécanisme d'introduction, hormis le cas de la folle avoine. L'essentiel des images s'est révélé exploitable.

Nom de l'espèce (code, effectif)	Image de l'espèce	Nom de l'espèce (code, effectif)	Image de l'espèce
<b>Folle avoine</b> (Af, 74)		<b>Soja</b> (Gl, 156)	
<b>Betterave</b> (Bv, 103)		<b>Mais</b> (Ma, 176)	
<b>Lentille</b> (Lc, 103)		<b>Liseron des haies</b> (Cs, 135)	
<b>Pois</b> (Pi, 155)		<b>Orge</b> (Hv, 99)	
<b>Sclérote</b> (Sc, 165)		<b>Blé tendre</b> (Ta, 105)	
<b>Tournesol cassé</b> (Td, 108)		<b>Amande de tournesol</b> (Am, 83)	
<b>Tournesol</b> (To, 155)			

*Tableau 1.4: Collection d'images de semences*



*Figure 1.25 : Image d'une folle avoine avec une arête*



*Figure 1.26 : Image d'une folle avoine sans arête*

## Récapitulation et conclusion du chapitre 1

*En considérant les spécifications attendues du système, et à partir de l'étude bibliographique, nous avons pu effectuer des choix techniques pour la réalisation d'un système de vision des semences. Les principaux éléments du choix portaient sur le mode de présentation des semences devant la caméra, les sources d'éclairage, la nature et le nombre de caméras et l'architecture électronique. Nous avons retenu un mode de présentation consistant en la chute libre des objets. Ceci permet à la fois de présenter au système des objets très hétérogènes en taille et forme, et de pouvoir étudier toutes les faces de ces objets. L'acquisition d'image d'objets en chute libre ne peut se faire qu'avec un système de flash lumineux, de manière à éviter les problèmes de traînée sur les images numériques. Ceci nous a conduits à sélectionner un système d'éclairage à diode luminescente. Une barrière infrarouge détecte le passage de la graine devant le système optique. La nécessité de pouvoir observer toutes les faces d'un même objet nous a amenés à concevoir un système original comportant trois caméras disposées autour de l'objet en chute libre. En ce qui concerne l'architecture électronique du système, pour respecter des contraintes de rapidité d'acquisition des images, nous avons choisi de construire le système en utilisant des composés de type FPGA (Field Programmable Gate Array). Ce choix est également dicté par la présence de 3 caméras, qui peuvent être programmées et activées indépendamment les unes des autres. Ainsi, le système reste ouvert dans sa conception, et peut éventuellement être modifié pour d'autres applications envisageables.*

*Le système a été construit et testé. L'étude de la forme de billes calibrées nous a permis de montrer que les objets en mouvement étudiés n'étaient que très faiblement déformés lors de la prise d'image. Nous avons également étudié la fonctionnalité du système en acquérant de nombreuses images de semences qui nous serviront de base de travail dans les deux chapitres suivants portant respectivement sur l'analyse d'images et l'identification des semences.*

# CHAPITRE 2 : ANALYSE D'IMAGES DES SEMENCES ET ETUDE EXPLORATOIRE.

*Pour exploiter les images numériques de semences, il est tout d'abord nécessaire d'en extraire un ensemble de valeurs numériques décrivant leur apparence. Chaque semence est finalement décrite par un vecteur de caractéristiques censé contenir une information suffisante pour permettre l'identification de la nature variétale.*

*Nous présentons tout d'abord les méthodes d'analyse d'images permettant d'extraire ces caractéristiques. Elles permettent de décrire la forme, la couleur et la texture d'image des objets étudiés. Nous nous intéressons en particulier aux différents espaces de couleur sur lesquels peut porter l'analyse d'image.*

*Nous décrivons ensuite les méthodes exploratoires (ou « descriptives ») qui sont appliquées pour analyser les matrices de données résultant de l'étape d'extraction des caractéristiques.*

*Enfin, nous appliquons l'ensemble de ces méthodes à la base de données d'images numériques de semences acquises avec l'automate de vision artificielle que nous avons présenté dans le chapitre 1.*

*Ce travail nous permet d'avoir un regard critique sur les variables utiles dans l'optique de l'identification des semences, et guide notre choix pour le chapitre suivant, consacré à la discrimination.*

## 1. Extraction des paramètres caractérisant les semences.

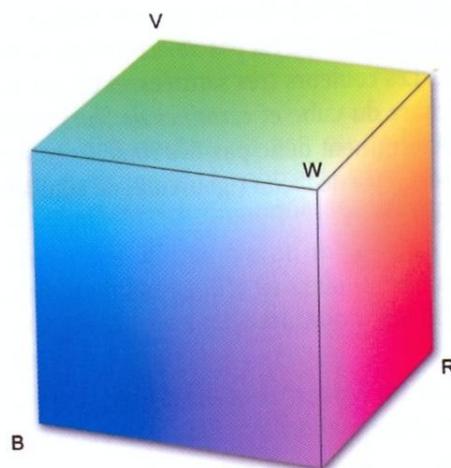
### 1.1. Espaces colorimétriques.

De nombreuses caractéristiques des images numériques d'objets, en particulier celles liées à la couleur et à la texture, dépendent par nature de la manière dont la couleur est représentée. Après avoir rappelé brièvement les modes les plus courants de codage de la couleur, nous justifierons notre choix des codages particuliers utilisés dans le cadre de cette étude.

Nous avons vu au chapitre 1 que l'image couleur fournie par une caméra numérique était codée sous forme de trois composantes chromatiques (rouge, vert et bleu) : on est alors dans l'espace colorimétrique *RVB*. Pour des raisons d'ordre technique, ou pour faciliter l'analyse des images, il peut être utile de changer d'espace colorimétrique. Les composantes colorimétriques dans ces nouveaux espaces se déduisent des composantes *RVB* par des relations qui peuvent être linéaires, ou non linéaires.

- L'espace *RVB*

L'espace *RVB* est celui représenté par le cube de la figure Figure 2.1. L'origine *O* de l'espace (sommet du cube non visible sur la figure) représente le noir, le sommet *W* le blanc, qui a pour coordonnées (255, 255, 255) dans l'hypothèse courante où les composantes colorimétriques sont codées chacune sur 8 bits.



**Figure 2.1 : Cube colorimétrique *RVB***

*(Gaudin 2006).*

La diagonale du cube reliant les points O (noir) et W (blanc) est l' « axe chromatique ». Elle rassemble les niveaux de gris, dont les trois composantes sont égales.

Dans l'espace *RVB*, les trois composantes chromatiques sont corrélées entre elles, car chacune d'elles comporte une partie de l'information relative à la luminosité de la scène. Avec un tel codage, un traitement marginal des images, dans lequel chaque composante colorimétrique est traitée indépendamment des deux autres, n'est pas très pertinent. C'est dommage, car le traitement marginal permet d'utiliser toutes les méthodes pré-existantes, élaborées pour les images monocomposantes. C'est pourquoi des espaces dont les composantes colorimétriques sont partiellement ou totalement décorréles ont été proposées.

- L'espace YCbCr

C'est le cas de l'espace de couleur *YCbCr*, qui 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 *RVB* à l'espace *YCbCr* est donnée par la relation linéaire :

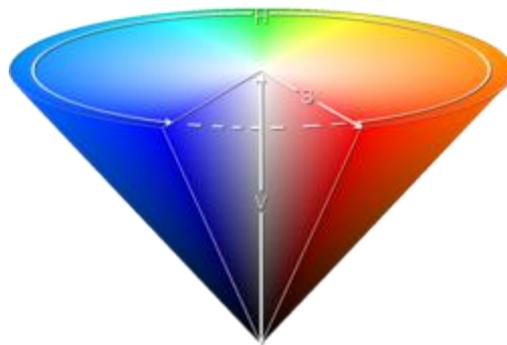
$$\begin{bmatrix} Y \\ Cb \\ Cr \end{bmatrix} = \begin{bmatrix} 0.299 & 0.587 & 0.114 \\ -0.169 & -0.331 & 0.500 \\ 0.500 & -0.419 & -0.081 \end{bmatrix} * \begin{bmatrix} R \\ V \\ B \end{bmatrix}$$

On voit, 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

Ils 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 (Figure 2.2). A la base de ce cône – et 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%.



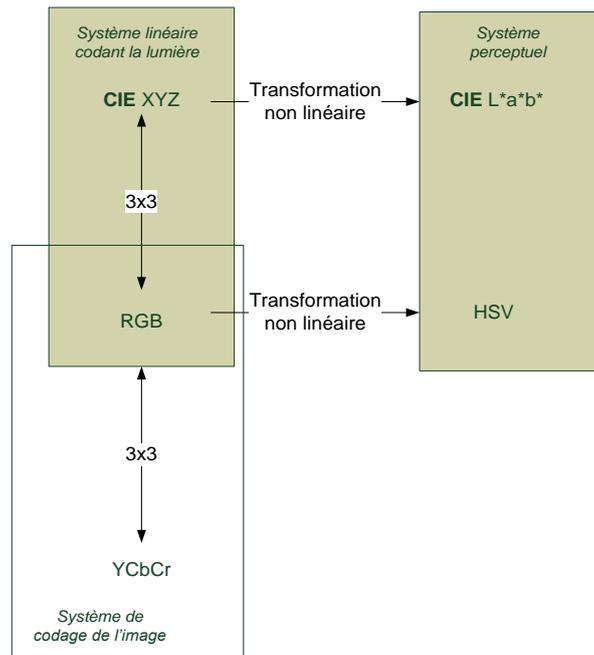
**Figure 2.2 : Espace de représentation HSV**

- Les espaces perceptuels

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 pallier 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 *RVB*, 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 vision que nous avons développé.

La relation entre les différents espaces de couleurs a été présentée sous la forme d'un graphique de dépendance (Figure 2.3) par Poynton, (2003). Dans le cadre de notre étude, nous avons retenu trois espaces de couleur pour coder et analyser les images : *RVB*, *YCbCr* et *HSV*. L'espace *RVB* est évidemment intéressant puisque il est directement obtenu par les caméras.

L'espace  $YCbCr$  a l'avantage de faire apparaître une composante de luminance, qui peut être informative. 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 proche de celle que pourrait effectuer un observateur expert jugeant les couleurs. Le codage des images dans l'espace  $L^*a^*b^*$  n'était pas applicable dans notre cas.

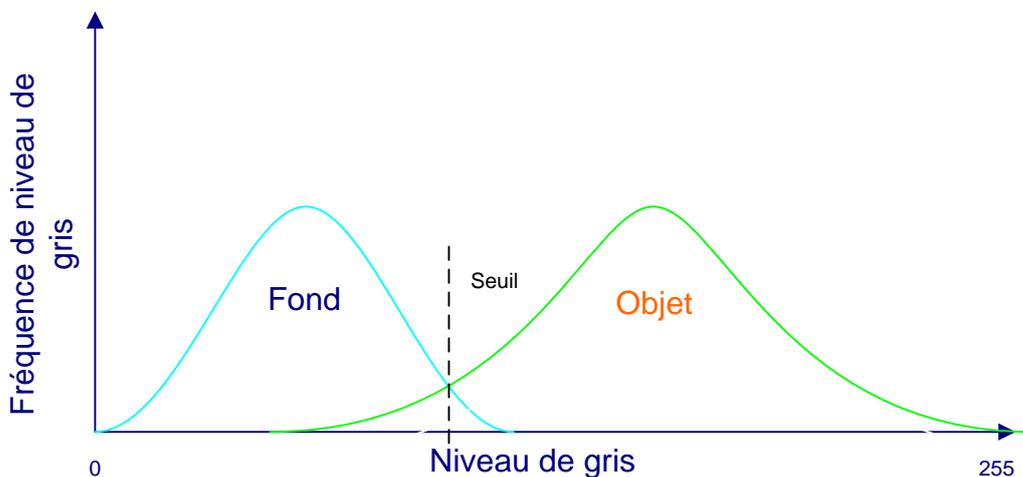


**Figure 2.3 : Représentation des dépendances entre les espaces de couleur**  
(Poynton 2003).

Dans le cadre de notre étude, nous avons retenu trois espaces de couleur pour coder et analyser les images : RVB,  $YCbCr$  et  $HSV$ . L'espace RVB est évidemment intéressant puisque il est directement obtenu par les caméras. L'espace  $YCbCr$  a l'avantage de faire apparaître une composante de luminance, qui peut être informative. 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 proche de celle que pourrait effectuer un observateur expert jugeant les couleurs. Le codage des images dans l'espace  $L^*a^*b^*$  n'était pas applicable dans notre cas.

## 1.2. La segmentation de l'image d'une semence.

Pour travailler sur la partie de l'image correspondant à la seule semence (isolée du fond), il faut créer un masque binaire dont la partie « vraie » corresponde à la semence, et la partie « fausse » au fond. Ceci se fait en général 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. Si, par exemple, l'objet d'intérêt est clair par rapport à un fond plus sombre, on attribue à la région d'intérêt tous les pixels dont la valeur dépasse le seuil. 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 était pour nous envisageable. Une des plus connues est celle d'Otsu (Otsu 1979) qui s'appuie sur l'étude de la variance des niveaux de gris (Figure 2.4). A partir de l'histogramme des niveaux d'une (au choix) des composantes colorimétriques, 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.



*Figure 2.4 : Détection du seuil de segmentation optimal*

Dans notre étude, le seuillage est effectué, à partir de l'image codée dans l'espace couleur YCbCr, sur le canal de la chrominance Cb.

### 1.3. Les caractéristiques morphologiques.

A partir de l'image binarisée de nombreuses caractéristiques morphologiques peuvent être extraites, nous regrouperons ces caractéristiques sous la dénomination de caractéristiques de *contour*, de *moment* et de *calibre*.

- *Les caractéristiques de contour.*

Il existe de nombreuses méthodes permettant de décrire le contour d'un objet (Kunt 2000), celles couramment utilisées sont les techniques d'analyse de chaînage du contour, statistique et fréquentielle. Dans le cas d'un contour fermé, il est possible de représenter le contour d'un objet comme une « signature polaire » par rapport au barycentre de l'objet. Dans cette thèse, nous n'utiliserons que les descripteurs *statistiques* et *fréquentiels*.

Pour calculer les descripteurs statistiques, un histogramme des distances entre le centre de gravité et les points appartenant au contour est tout d'abord calculé (Chtioui 1997 ; Nair 1997 ; Majumdar et Jayas 2000a). A partir de cet histogramme différents paramètres sont extraits tels que le *rayon maximum* et *minimum*, la *moyenne* et *l'écart type des rayons*.

Le rapport entre le rayon maximum et minimum est défini comme le *rapport de rayon*. En complément de ces valeurs le rapport entre la moyenne et l'écart type est calculé. Ce dernier paramètre est appelé le *rapport d'Haralick*.

Le terme de « descripteurs fréquentiels » est associé à la notion de descripteurs de Fourier. Pour une région fermée, le contour peut être représenté par les coordonnées  $x(t)$  et  $y(t)$ . Les courbes  $x(t)$  et  $y(t)$  peuvent être considérées comme représentant des fonctions périodiques et paramétriques. On peut les écrire sous une forme complexe selon la relation :

$$z(k) = x(k) + iy(k) \text{ avec } k = 1, 2, \dots, p$$

Le signal ainsi obtenu peut être représenté par ses coefficients de Fourier  $f(k)$  appelés descripteurs de Fourier,

$$f(k) = \sum_{n=0}^{p-1} z(n) e^{-\frac{i2\pi nk}{p}}$$

Le nombre de descripteurs de Fourier qui peuvent être extraits dépend de la longueur du contour. La représentation obtenue dans l'espace de Fourier permet d'extraire des

caractéristiques géométriques telles que la surface et certains moments du second ordre (Kiryati et Maydan 1989). Le coefficient associé à la première harmonique de Fourier représente le centre de gravité de la région. Chtioui, (1997) a montré que les 10 premiers coefficients de Fourier étaient suffisants pour la caractérisation du contour des semences. Les coefficients d'ordre supérieur décrivent de petites variations du contour dont les valeurs sont instables. Les descripteurs de Fourier ne sont pas invariants par rapport à la rotation et à la translation de l'objet et dépendent fortement du point de départ choisi pour l'analyse du contour.

- Les caractéristiques de région

### Les moments

La forme des objets peut être analysée et décrite par les moments.

Un moment d'ordre  $pq$  est défini par :

$$m_{pq} = \sum_i \sum_j i^p j^q$$

Où  $i$  et  $j$  désignent respectivement les coordonnées selon les axes  $x$  et  $y$  des pixels appartenant la forme.

Les moments d'ordre peu élevé sont également peu sensibles au bruit.

Le centre de gravité d'une région est simplement le rapport de moments,

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

Le centre de gravité est utilisé pour le calcul des moments centrés,

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

Les moments peuvent être rendus invariants à la translation, à la rotation et à l'agrandissement par centrage et normalisation.

Les moments centrés sont utilisés dans le calcul des moments centrés normalisés définis par :

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

Où  $s$  représente la surface de la région. Plusieurs paramètres sont calculés à partir des moments.

L'excentricité est définie par :

$$excentricité = \frac{(\mu_{02} - \mu_{20})^2 + 4\mu_{11}}{s}$$

La longueur d'un objet est estimée à partir de la matrice de variance-covariance entre les axes  $x$  et  $y$  définie par :

$$C = \begin{bmatrix} \mu_{20} & \mu_{11} \\ \mu_{11} & \mu_{02} \end{bmatrix}$$

L'orientation de l'axe principal d'une semence est déterminée par le vecteur propre, de la matrice  $C$  associé à la plus grande valeur propre. On peut montrer que la pente  $\theta$  de l'axe principal vérifie l'équation quadratique suivante :

$$(\tan \theta)^2 + \frac{(\mu_{20} - \mu_{02})}{\mu_{11}} \tan \theta - 1 = 0$$

La solution de cette équation permet d'avoir la direction de l'axe principal :

$$\theta = \frac{1}{2} \tan^{-1} \left( \frac{2\mu_{11}}{\mu_{20} - \mu_{02}} \right)$$

Cette orientation n'a de sens que si la région ne présente pas de symétrie de révolution, c'est-à-dire si  $\mu_{20} \neq \mu_{02}$ . La longueur d'une région est ensuite obtenue en projetant le contour sur la droite qui passe par le centre de gravité et d'orientation  $\theta$ . La largeur est obtenue de la même manière mais pour la direction  $\theta + \frac{\pi}{2}$ . L'*élongation*, qui caractérise l'allongement d'une graine, est également extraite et définie par le rapport entre *l'axe majeur* et *l'axe mineur*.

## Paramètres de calibre

Les caractéristiques de calibre donnent une analyse globale de la forme de l'objet. Ces caractéristiques sont souvent obtenues par comparaison à des formes géométriques simples telles que des rectangles, des cercles ou encore des ellipses.

La semence est ici caractérisée par 6 paramètres de calibre : la *longueur* et la *largeur du rectangle enveloppant* (exinscrit), le *périmètre*, le *diamètre équivalent*, le *coefficient d'amincissement* et le *rapport de surface*.

La surface représente la somme des pixels appartenant à la semence, incluant le contour de celle-ci.

Le périmètre est une des caractéristiques dont l'estimation est problématique. En effet l'échantillonnage spatial étant effectué par des capteurs de forme carrée, il y a une erreur dans l'estimation de ce paramètre pour des objets de forme quelconque. Cette erreur diminue avec l'augmentation de la résolution du capteur. Nous considérerons que le périmètre est la somme des pixels composant le contour de l'objet. Les pixels du contour sont obtenus par la soustraction de la forme initiale à la forme résultant d'une opération d'érosion binaire unitaire.

Une fois ces paramètres extraits il est possible d'extraire de nouveaux paramètres issus de calculs de différents rapports.

Ainsi le diamètre équivalent d'un objet est extrait en considérant un disque de même surface que celle de l'objet. Il est donné par:

$$\text{diamètre équivalent} = 2 * \sqrt{\frac{\text{Surface}}{\pi}}$$

Le coefficient d'amincissement mesure la rotondité de la semence:

$$\text{Coefficient d'amincissement} = \frac{\text{Périmètre}^2}{4 * \pi * \text{Surface}}$$

Il est possible de déterminer si la semence est d'aspect rectangulaire en calculant le rapport entre la longueur et la largeur :

$$\text{aspect rectangulaire} = \frac{\text{Longueur}}{\text{Largeur}}$$

Le dernier paramètre extrait pour caractériser le calibre de la semence est le rapport de surface. Il s'agit d'estimer le rapport entre la surface extraite et la surface décrite par le rectangle exinscrit :

$$\text{Rapport de surface} = \frac{\text{Longueur} * \text{Largeur}}{\text{Surface}}$$

#### 1.4. Caractérisation de la couleur.

La caractérisation marginale de la couleur repose sur la distribution des niveaux de gris sur chacune des composantes colorimétriques de l'image.

Pour chaque canal étudié, il est naturel de caractériser la distribution des niveaux de gris par des paramètres habituellement utilisés en statistique descriptive : la *moyenne*, la *variance*, l'*énergie*, l'*entropie*, la *dissymétrie* et l'*aplatissement*. La fréquence relative d'un niveau de gris  $k$  est notée  $p(k)$ . Le nombre total de niveaux de gris, ici 256, est noté  $n_g$ .

- La moyenne est donnée par :

$$s_m = \sum_{k=1}^{n_g} kp(k)$$

La variance caractérise la dispersion des niveaux de gris autour de la moyenne dont la formule est :

$$s_v = \sum_{k=1}^{n_g} (k - s_m)^2 p(k)$$

- La dissymétrie est un paramètre dimensionnel défini par :

$$s_d = \frac{1}{s_v^2} \sum_{k=1}^{n_g} (k - s_m)^3 p(k)$$

Une valeur positive de ce paramètre signifie une distribution plus étalée vers la droite de la moyenne, et inversement pour une valeur négative.

- L'aplatissement est aussi un paramètre a-dimensionnel:

$$s_a = \left[ \frac{1}{s_v^2} \sum_{k=1}^{n_g} (k - s_m)^4 p(k) \right]$$

Il compare la distribution de l'histogramme à une gaussienne. Plus un histogramme est plat, plus la valeur de son aplatissement est négative. L'aplatissement d'un histogramme comportant un pic aigu est positif.

L'entropie mesure l'homogénéité de l'histogramme dont la formule est :

$$S_h = - \sum_{k=1}^{n_g} p(k) \ln(p(k))$$

L'énergie présente une valeur faible pour des histogrammes uniformes. Sa formule est:

$$s_e = \sum_{k=1}^{n_g} p(k)^2$$

Dans notre étude, ces paramètres sont mesurés sur chaque canal, dans les espaces RVB, YCbCr et HSV.

### 1.5. Caractérisation de la texture d'image.

La texture correspond à la variation locale de la couleur. 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 (Nixon et Aguado 2008). 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 semences en raison de la grande variabilité de la texture qu'on observe sur les différentes espèces et à l'intérieur d'une même espèce.

Les méthodes statistiques sont plus appropriées pour l'intégration dans un automate de caractérisation des semences (Haralick 1979). Nous avons retenu trois méthodes statistiques, parmi les plus universellement utilisées : *histogramme de différences de niveaux de gris*, *matrice de cooccurrences* et *matrice de longueurs de plages*.

### 1.4.1. histogramme de différences de niveaux de gris

Cette méthode est fondée sur la différence  $g$  des niveaux de gris entre paires de points selon un vecteur de déplacement ayant pour composantes  $(dx, dy)$ :

$$g = |f(x, y) - f(x + dx, y + dy)|$$

Où  $f(x, y)$  est le niveau de gris au point de coordonnées  $x, y$ .

Dans cette méthode, on considère que la distribution des valeurs prises par  $g$  pour l'ensemble des pixels appartenant à l'objet caractérise la texture. On résume la distribution de  $g$  par les paramètres usuels de la statistique.

La valeur du vecteur de déplacement est évidemment un paramètre important dans cette méthode. Dans notre étude, le déplacement est fixé à  $(1,1)$ . Il n'est pas nécessaire ici d'étudier plusieurs directions du vecteur de déplacement car les textures des graines n'ont pas de direction privilégiée. L'histogramme des différences de niveaux de gris comporte des informations importantes sur l'organisation spatiale des niveaux de gris. Ainsi, pour une texture grossière, l'histogramme  $p(g)$  a tendance à avoir des fréquences élevées pour les classes autour de  $g = 0$ . L'histogramme est plus étalé pour les textures fines. Dans la présente étude, nous avons résumé chaque histogramme à l'aide de cinq paramètres.

- **Moyenne :**

$$d_m = \sum_{g=1}^{n_g} gp(g)$$

$n_g$  représente le nombre total de niveaux de gris. Une petite valeur de  $d_m$  indique que la texture est grossière.

- **Variance :**

$$d_v = \sum_{g=1}^{n_g} (g - d_m)^2 p(g)$$

La variance  $d_v$  est une mesure de la dispersion des différences de niveaux de gris.

- **Contraste :**

$$d_c = \sum_{g=1}^{n_g} g^2 p(g)$$

Le contraste est le moment d'inertie de l'histogramme autour de  $g=0$  ;

- **Entropie :**

$$d_h = - \sum_{g=1}^{n_g} p(g) \ln(p(g))$$

C'est une mesure de l'homogénéité de l'histogramme. L'entropie est maximum pour un histogramme uniforme.

- **Energie :**

$$d_e = \sum_{g=1}^{n_g} p(g)^2$$

L'énergie est une mesure de l'hétérogénéité des différences de niveaux de gris  $g$  dans l'image.

### 1.4.2. Longueurs de plages

Pour une direction donnée, la longueur de plage d'un niveau de gris est le nombre de pixels consécutifs ayant ce niveau de gris (Galloway 1975). Une matrice de longueurs de plages peut

ainsi être extraite à partir de la région de chaque graine pour chaque direction. Chaque élément de cette matrice noté  $h(i, j)$ , représente le nombre de fois où le niveau de gris  $i$  présente une plage de longueur  $j$ . Etant donné que les textures des graines ne sont pas orientées et que ces objets ont une position aléatoire pendant la chute, on peut se contenter de n'étudier qu'une direction de longueur de plage. Nous avons choisi d'utiliser une direction de  $0^\circ$  pour laquelle les calculs sont particulièrement simples. La valeur  $n_p$  représente la longueur maximale des plages, ici elle correspond à la longueur de la semence.

La somme totale des longueurs de plages est donnée par :

$$t_p = \sum_{i=1}^{n_g} \sum_{j=1}^{n_p} h(i, j)$$

Cinq paramètres, décrits ci-dessous sont calculés à partir de la matrice des longueurs de plage.

- ***Accentuation des petites plages :***

$$l_c = \frac{1}{t_p} \sum_{i=1}^{n_g} \sum_{j=1}^{n_p} \frac{h(i, j)}{j^2}$$

Ce paramètre a une grande valeur si la texture comporte de petites longueurs de plage.

- ***Accentuation des longues plages :***

$$l_g = \frac{1}{t_p} \sum_{i=1}^{n_g} \sum_{j=1}^{n_p} j^2 h(i, j)$$

Ce paramètre met en évidence les longues plages.

- ***Distribution des niveaux de gris :***

$$l_n = \frac{1}{t_p} \sum_{i=1}^{n_g} \left[ \sum_{j=1}^{n_p} h(i, j) \right]^2$$

Ce paramètre mesure la non-uniformité des niveaux de gris. Quand les plages sont uniformément distribuées pour tous les niveaux de gris, ce paramètre a une valeur très faible.

- **Distribution des longueurs de plages :**

$$l_l = \frac{1}{t_p} \sum_{j=1}^{n_p} \left[ \sum_{i=1}^{n_g} h(i, j) \right]^2$$

Ce paramètre mesure la non-uniformité des longueurs de plages. Quand les plages sont uniformément distribuées pour toutes les longueurs de plages, ce paramètre est minimum.

- **Pourcentage de plages :**

$$l_p = \frac{1}{s} \sum_{i=1}^{n_g} \sum_{j=1}^{n_p} h(i, j)$$

où  $s$  représente la surface de la région. Ce paramètre  $l_p$  est simplement le rapport entre le nombre total de longueurs de plages et la surface de la graine. Ce paramètre a une valeur faible pour les textures de structure homogène.

### 1.4.3. Matrices de cooccurrences.

Notons  $o(i, j)$  le nombre d'occurrences de couples de pixels de niveaux de gris respectivement  $i$  et  $j$  situés à un déplacement  $d$  (préalablement défini) l'un de l'autre. Notons par  $n$  le nombre total d'occurrences, pour un déplacement  $d$  dans la région d'une graine. On définit la matrice  $P$  de cooccurrence dont les éléments, de la forme  $p(i, j)$  sont la probabilité du couple de pixel ayant les niveaux de gris respectivement égaux à  $i$  et  $j$ . On a évidemment  $p(i, j) = \frac{o(i, j)}{n}$

La matrice de cooccurrence a une dimension  $n_g \times n_g$ , où  $n_g$  est le nombre total de niveaux de gris, ici 256.

L'analyse de ces matrices pour différentes valeurs du vecteur  $d$  permet de déterminer si la texture possède une orientation particulière. Dans la présente étude, le vecteur de déplacement est fixé à  $(1, 1)$ , pour les mêmes raisons que pour les précédentes méthodes.

- **Probabilité maximum**

$$c_{max} = \max_{i \in \{1,2,\dots,n\}, j \in \{1,2,\dots,n\}} p(i, j)$$

- **Moyenne des lignes**

$$c_{mx} = \sum_{i=1}^{n_g} i \sum_{j=1}^{n_g} p(i, j)$$

- **Moyenne des colonnes**

$$c_{my} = \sum_{j=1}^{n_g} j \sum_{i=1}^{n_g} p(i, j)$$

- **Ecart type des lignes**

$$c_{ex} = \sqrt{\sum_{i=1}^{n_g} \sum_{j=1}^{n_g} [(i - c_{mx})^2 p(i, j)]}$$

- **Ecart type des colonnes**

$$c_{ey} = \sqrt{\sum_{i=1}^{n_g} \sum_{j=1}^{n_g} [(j - c_{my})^2 p(i, j)]}$$

- **Second moment angulaire**

$$c_e = \sum_{i=1}^{n_g} \sum_{j=1}^{n_g} p(i, j)^2$$

Ce paramètre est minimum quand les  $p(i, j)$  sont égaux. C'est la mesure de la dispersion des éléments de la matrice P.

- **Contraste**

$$c_c = \sum_{n=1}^{n_g-1} \delta^2 \left[ \sum_{i=1}^{n_g} \sum_{j=1}^{n_g} p(i,j) \right]$$

où  $\delta = |i - j|$

Dans cette formule, chaque élément de matrice  $p(i,j)$  est pondéré par sa distance à la diagonale. Le contraste est donc élevé lorsqu'on passe souvent d'un pixel très clair à un pixel très foncé (ou inversement), ces pixels fournissant des valeurs élevées de  $|i - j|$ .

- **Corrélation**

$$c_r = \frac{\left[ \sum_{i=1}^{n_g} \sum_{j=1}^{n_g} ij p(i,j) \right] - c_{mx}c_{my}}{c_{ex}c_{ey}}$$

Cet indice rend compte de la corrélation entre les lignes et les colonnes de la matrice de cooccurrence, donc de la corrélation entre les luminances des pixels avant et après translation.

- **Entropie**

$$c_{Ent} = - \sum_{i=1}^{n_g} \sum_{j=1}^{n_g} p(i,j) \ln(p(i,j))$$

Ce paramètre est maximum quand tous les éléments de la matrice de cooccurrence sont égaux.

- **Moment différentiel inverse**

$$c_h = \sum_{i=1}^{n_g} \sum_{j=1}^{n_g} \left[ \frac{1}{1 + (i - j)^2} p(i,j) \right]$$

Ce paramètre mesure l'homogénéité locale des niveaux de gris dans l'objet.

## 2. Méthodes d'exploitation des données.

La chimiométrie descriptive ou exploratoire a pour but de synthétiser, résumer et structurer l'information contenue dans les données. Elle utilise pour cela des représentations des données sous forme de tableaux, graphiques et indicateurs numériques. Le rôle de cette forme

de statistiques est de mettre en évidence des propriétés de l'échantillon et de suggérer des hypothèses. Les principales méthodes se décomposent en deux phases : une phase de description variable par variable, et une phase par couple de variables.

Dans la plupart des applications on observe non pas une variable par individu mais un nombre  $M$  souvent élevé. L'étude séparée de chacune de ces variables, celles de couples et les études de corrélation entre les variables sont une phase indispensable dans l'analyse des données. Mais elle est tout-à-fait insuffisante. Il faut donc analyser les données en tenant compte de leur caractère multidimensionnel.

## **2.1. L'analyse en composante principale (ACP)**

L'analyse en composante principale est une méthode particulièrement efficace pour explorer la structure de tels ensembles de données. Elle est également la mère de la plupart des méthodes descriptives multidimensionnelles. L'ACP a la capacité de résumer les données sur un espace réduit tenant compte de leur multi-dimensionnalité. L'ACP 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 ou de variables.

Tuffery, (2007) écrit : « pour les analyses multi-variées, les techniques factorielles sont très appréciées des statisticiens auxquels elles permettent à la fois de représenter en deux dimensions ou en trois dimensions le plus fidèlement possible les individus d'une population et aussi de détecter les liaisons entre les variables ainsi que les variables séparant le mieux les individus. Elles font appel à l'algèbre linéaire et à un outil très bien adapté à la classification et à la reconnaissance des formes : l'œil. Un simple coup d'œil permet de localiser les grandes masses d'individus, de détecter les individus exceptionnels et de repérer d'éventuels groupes isolés d'individus. Les techniques factorielles sont aussi un puissant outil de réduction des dimensions d'un problème qui permet de diminuer le nombre de variables étudiées en perdant le moins possible d'informations. »

La réduction des dimensions n'est possible que s'il y a redondance entre les variables. De manière générale dans notre travail, nous avons constaté que l'ACP se révèle extrêmement efficace. En matière de semences, notre expérience montre que certaines caractéristiques sont en effet corrélées entre elles.

Notons par  $X$  la matrice des observations centrées, de dimensions  $n \times p$ , et par  $V$  la matrice de variance-covariance de  $X$  définie par :

$$V = \frac{1}{n} X^t X$$

L'ACP repose simplement sur la diagonalisation de  $V$ . Puisque  $V$  est une matrice symétrique, les valeurs et les vecteurs propres correspondants sont des réels, on a :

$$VP = PL$$

Avec  $P$ , la matrice des vecteurs propres, de norme unitaire, et  $L$ , la matrice diagonale des valeurs propres. .

On a alors  $P^t P = I$  avec  $I$ , la matrice identité.

La formule précédente peut s'écrire, de manière équivalente :

$$P^t V P = L$$

Les vecteurs propres sont ordonnés dans l'ordre décroissant de leurs valeurs propres. Les coordonnées factorielles sont ensuite obtenues par projection des données initiales sur l'espace formé par les vecteurs propres,

$$T = X P$$

Où  $T$  est la matrice des coordonnées factorielles. La pertinence d'une composante principale est décrite par le rapport entre la valeur propre correspondante et la somme totale des valeurs propres.

La méthode la plus naturelle pour donner une signification à une composante principale est de la relier aux variables initiales en calculant les coefficients de corrélation linéaire et en s'intéressant aux plus forts coefficients en valeur absolue. Ces calculs s'effectuent pour chaque composante principale. On synthétise usuellement les corrélations sur une figure appelée « cercle de corrélation ».

## **2.2. Présentation générale de l'analyse de tableaux multiples.**

Dans notre étude, les variables décrivant les semences peuvent être regroupées selon leurs types, associés à la morphologie, la couleur et la texture. A chaque type de mesure nous pouvons faire correspondre un tableau de données. L'analyse peut être affinée en considérant

les relations entre ces tableaux qui décrivent les mêmes observations, mais avec des variables différentes. Il est important de pouvoir déterminer les informations spécifiques apportées par chaque tableau. Pour cela de nombreuses méthodes statistiques ont été conçues afin d'étudier des collections de tableaux liées soit par les observations, soit par les variables. Nous pouvons classer ces méthodes suivant leur principe : méthode reposant sur l'*analyse de cube de données*, l'*ACP concaténée*, l'*extraction de variables canoniques par maximisation d'un critère liens*. Nous insisterons plus particulièrement sur la méthode STATIS (Structuration des Tableaux A Trois Indices de la Statistique) que nous avons utilisé pour comparer les tableaux entre-eux.

***Méthode reposant sur l'analyse de cube de données.***

Dans de nombreuses situations on peut organiser les données sous la forme de cube de données. Un cube  $X$  de données est tel qu'il possède trois indices.

Dans une ACP, un élément  $x(i, j)$  est reconstruit comme étant un élément du produit d'une coordonnée factorielle ( $t$ ) par un élément des vecteurs propres ( $p$ ) selon l'équation :

$$x_{ij} = \sum_{i=1}^k t_{ik} p_{jk} + e_{ij}$$

Avec  $P$  la matrice des  $k$  vecteurs propres (en colonnes) associés à des valeurs propres non-nulles, et  $e_{ij}$ , un résidu.

Par analogie les méthodes d'analyse de cube de données reconstruisent un élément selon l'équation ci-dessous :

$$x_{ijk} = \sum_{l=1}^r w_{kl} u_{il} v_{jl} + e_{ijk}$$

Cette approche a été développée par (Rasmus 1997) sous le nom de PARAFAC (*Parallel Factor Analysis*). Pour pouvoir être utilisable, il faut que les données soient structurées sous forme de cube, c'est-à-dire que les tableaux aient le même nombre de variables et d'observations et que les variables soient homologues pour les différents tableaux. Ces contraintes rendent cette méthode inapplicable dans notre cas.

### ACP concaténée.

Une manière simple d'étudier les tableaux multiples (Figure 2.5) consiste à les concaténer selon les lignes ou selon les colonnes et à effectuer une ACP sur les tableaux concaténés. Soit un ensemble  $k$  de tableaux  $X^{(1)}, X^{(2)}, \dots, X^{(k)}$  ayant le même nombre d'observation mais pas nécessairement le même nombre de variables. On forme le tableau  $Z$  :

$$Z = [X^{(1)} | X^{(2)} | X^{(\dots)} | X^{(k)}]$$

L'ACP est alors calculée sur le tableau  $Z$ .

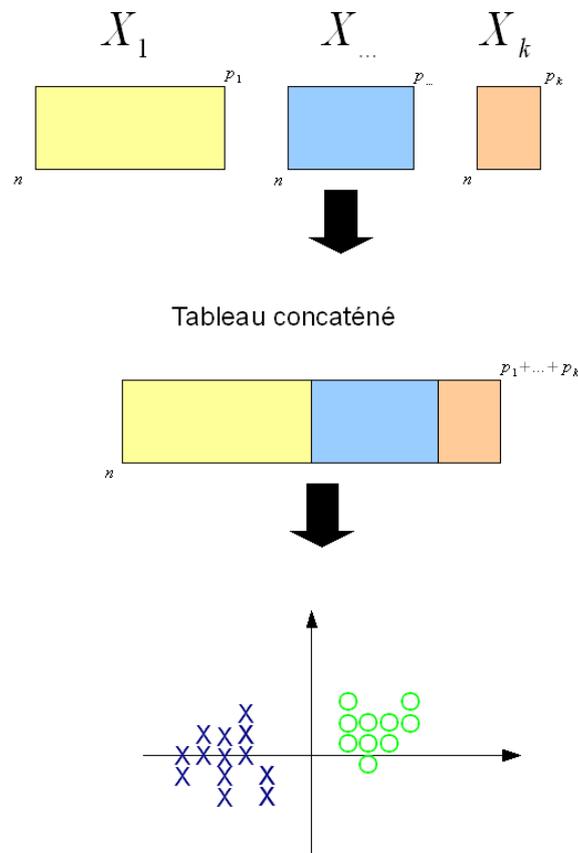


Figure 2.5 : Analyse en composante principale concaténée

Dans cette approche, une question essentielle est le problème de l'importance relative à donner à chacun des tableaux. En effet, si les variables sont de nature hétérogène, la matrice associée à chacun des tableaux a une norme qui lui est propre. Dans ces conditions, si l'on ne fait pas d'ajustement particulier, les tableaux pour lesquels la norme est la plus élevée joueront un rôle plus important dans l'analyse. Les différentes méthodes reposant sur cette approche attribuent des poids particuliers à chacun des tableaux de manière à supprimer ce

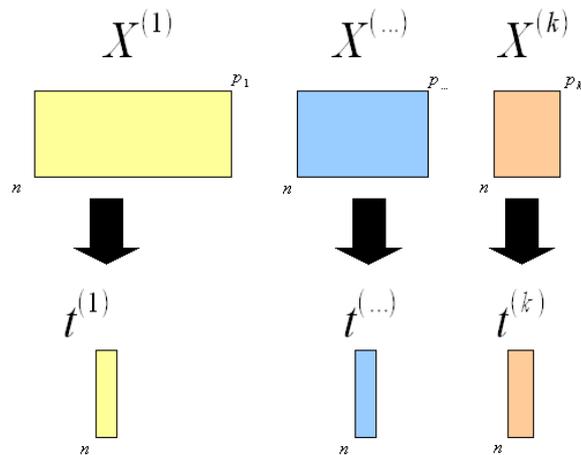
problème. L'idée la plus simple consiste à donner à tous les tableaux un poids égal à l'inverse de la norme de la matrice.

$$x_{ij}^{(k)} \leftarrow \frac{x_{ij}^{(k)}}{\|\mathbf{X}^{(k)}\|}$$

D'autres méthodes telles que STATIS (Lavit 1988) et l'analyse factorielle multiple (Escofier et Pages 1985) adoptent d'autres stratégies pour définir le poids de chaque tableau. Par construction STATIS tente de réduire le poids des tableaux qui apporte une information différente des autres et recherche ainsi un consensus. Cette stratégie n'est pas adaptée à notre travail, mais nous reviendrons sur un aspect de cette méthode qui est utile à notre étude et qui permet de comparer les tableaux entre-eux. De plus, les méthodes fondées sur l'ACP concaténée n'ont pas de comportement adapté au cas où certains tableaux n'auraient pas de liens entre eux. Pour cette raison, dans la partie expérimentale, nous n'avons appliqué des méthodes fondées sur la concaténation que pour des tableaux présentant, par nature, un certain lien. C'est le cas, par exemple, des tableaux, formés des mêmes variables, obtenus avec chacune des trois caméras.

- *Analyse canoniques avec maximisation de liens.*

Une autre catégorie de méthodes a comme philosophie de rechercher pour chaque tableau, un ensemble de variables synthétiques qui maximisent un critère de lien entre les tableaux. Ces variables sont alors des combinaisons linéaires (Figure 2.6) de la forme :  $t^{(i)} = X^{(i)}p^{(i)}$



**Figure 2.6 : Variables canoniques**

Ainsi on obtient un ensemble de variables canoniques  $t^{(1)}, t^{(2)}, \dots, t^{(k)}$  associées aux  $k$  tableaux reflétant les structures communes aux différents tableaux. Dans le cas de l'analyse canonique généralisée, on recherche un nouveau vecteur  $u$  de dimension  $n \times 1$  qui maximise la somme des corrélations au carré avec toutes les variables canoniques :

$$\sum_{i=1}^k cor^2(u, t^{(i)})$$

La variable  $u$  est alors une variable canonique représentant un compromis entre les tableaux suivant le critère précédent. La méthode est décrite dans des manuels de références (Saporta 2006). L'analyse canonique généralisée a rarement été utilisée en pratique car elle pose des problèmes numériques de calculs dans lequel intervient l'inversion des matrices de variance-covariance de chacun des tableaux. En pratique, de telles inversions ne sont réalisables que lorsque les matrices sont de rang plein, ce qui est rarement le cas. De plus, les variables canoniques n'ont en général aucune capacité de reconstruction des tableaux d'origine, ce qui est dans notre cas inapproprié.

L'analyse de co-inertie multiple (ACOM) (Chessel et Hanafi 1996) procède d'une manière similaire à l'analyse canonique généralisée mais le critère à maximiser est ici différent. Il est donné par :

$$\sum_{i=1}^k cov^2(u, t^{(i)})$$

Où *cov* désigne la covariance. Avec ce critère, on peut à la fois établir un lien entre les tableaux mais également calculer des variables latentes *t* permettant en général de reconstruire les données d'origine. Cet aspect est important lorsque l'on est dans une approche descriptive.

Nous avons testé l'ACOM pour caractériser le lien entre les tableaux de notre étude. Les résultats, difficiles à interpréter, ne sont pas présentés ici. En effet, bien que les tableaux de notre étude aient des structures internes très fortes, ils ne présentent que des corrélations entre tableaux assez faibles. Dans cette situation, l'ACOM ne conduit pas à des représentations factorielles suffisamment informatives. Pour cette raison, nous avons systématiquement appliqué l'ACP concaténée sur tableaux de même nature. Cette approche nous permet, par l'intermédiaire de l'analyse des cercles de corrélations, de bien comprendre la liaison des variables « inter » ou « intra » tableau. Cette étude a été complétée par l'analyse des coefficients RV entre tableaux, adaptée de la méthode STATIS, qui nous a permis de caractériser directement la distance entre tableaux.

### **2.3. La distance entre tableaux et sa représentation factorielle par STATIS**

Une des idées de base de la méthode STATIS repose sur la création d'un indice de ressemblance entre les tableaux. A partir de cet indice, il est possible d'avoir des représentations factorielles. Nous utilisons ici seulement l'aspect de cette méthode qui présente un intérêt dans notre étude. Soit un ensemble *k* de tableaux  $\mathbf{X}^{(1)}, \mathbf{X}^{(2)}, \dots, \mathbf{X}^{(k)}$  centrés, ayant le même nombre d'observations *m* mais pas nécessairement le même nombre de variables. La matrice des produits scalaires  $\mathbf{W}_i$  du tableau  $\mathbf{X}^{(i)}$  est définie par :

$$\mathbf{W}_i = \mathbf{X}^{(i)} \mathbf{X}^{(i)T}$$

Deux tableaux  $\mathbf{X}^{(i)}$  et  $\mathbf{X}^{(j)}$  qui représenteraient la même structure de distances entre les observations auraient des matrices de produits scalaires  $\mathbf{W}_i$  et  $\mathbf{W}_j$  dont les éléments seraient proportionnels. A partir de cette constatation, on peut établir un coefficient de ressemblance, appelé « coefficient RV » entre deux tableaux, par les formules suivantes :

$$s_{i,j} = \frac{1}{m^2} \text{Trace}(\mathbf{W}_i \mathbf{W}_j)$$

d'où

$$RV_{(i,j)} = \frac{s_{i,j}}{\sqrt{s_{i,j}} \sqrt{s_{i,j}}}$$

Le coefficient RV est analogue à un coefficient de corrélation établi entre tableaux. Il prend la valeur 1 pour des tableaux représentant des structures de distances identiques entre observations.

Les valeurs de RV obtenues pour tous les couples des  $k$  tableaux peuvent être regroupées dans une matrice  $\mathbf{RV}$ , de dimension  $k \times k$ . On peut examiner les valeurs de cette matrice, ou lorsque les tableaux sont nombreux, effectuer une analyse factorielle à partir de la matrice  $\mathbf{RV}$ . D'une manière très comparable à l'ACP sur matrice de corrélation, les coordonnées des tableaux sont, à un facteur multiplicatif près, les vecteurs propres associés à  $\mathbf{RV}$ .

Soient  $\mathbf{U}$  et  $\mathbf{L}$  respectivement la matrice des vecteurs propres (en colonnes) de  $\mathbf{RV}$  et la matrice diagonale des valeurs propres. Les coordonnées  $\mathbf{C}$  des tableaux sont données par :

$$\mathbf{C} = \mathbf{U} \mathbf{L}^{\frac{1}{2}}$$

Sur les cartes factorielles obtenues de cette manière, deux tableaux porteurs de la même information ont des positions voisines.

### 3. Partie expérimentale

#### 3.1. Matériel et méthode.

L'étude porte sur 1617 semences dont les images ont été prises par chacune des trois caméras, constituant une base de 4851 images numériques. Cette collection a déjà été décrite dans le chapitre 1. Elle comprend 11 espèces habituellement présentes dans les lots certifiés de tournesol auxquelles s'ajoutent deux catégories correspondant aux amandes et aux semences cassées de tournesol (ces éléments entrent dans les critères de certification des lots). Un petit nombre d'images incorrectement acquises ont été préalablement éliminées avant la constitution de cette base. Pour des raisons de lisibilité, nous donnons à nouveau le tableau qui comporte les effectifs dans chaque groupe qualitatif ( Tableau 2.1).

Espèce	Code	Effectif	Espèce	Code	Effectif
<b>Folle avoine</b>	<b>Af</b>	74	<b>Soja</b>	<b>G1</b>	<b>156</b>
<b>Betterave</b>	<b>Bv</b>	103	<b>Maïs</b>	<b>Ma</b>	<b>176</b>
<b>Liserons des haies</b>	<b>Cs</b>	135	<b>Blé tendre</b>	<b>Ta</b>	<b>105</b>
<b>Orge</b>	<b>Hv</b>	99	<b>Amande de tournesol</b>	<b>Am</b>	<b>83</b>
<b>Lentille</b>	<b>Lc</b>	103	<b>Tournesol endommagé</b>	<b>Td</b>	<b>108</b>
<b>Pois</b>	<b>Pi</b>	155	<b>Sclérotés</b>	<b>Sc</b>	<b>165</b>
<b>Tournesol</b>	<b>To</b>	155			

*Tableau 2.1 : Collection d'images de semences*

- *Organisation des données.*

Chaque semence est caractérisée par les différentes variables que nous avons décrits dans la première partie de ce chapitre.

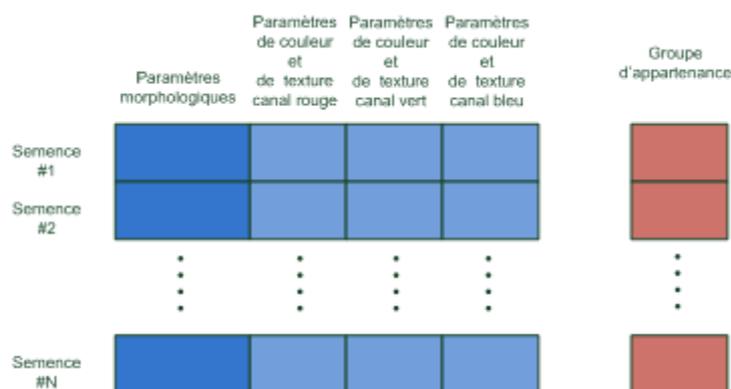
Le Tableau 2.2 donne la structure des variables. *A l'aide d'une seule caméra*, une semence est décrite tout d'abord par ces caractéristiques de forme (21 liées au calibre, 7 aux moments, 10 aux descripteurs de Fourier). Pour chaque canal de couleur, on dispose également de 6 paramètres de couleurs et des paramètres de texture (5 valeurs pour les histogrammes de différence de niveau de gris, 5 et 10 valeurs respectivement pour les longueurs de plage et les cooccurrences). Ces variables sont calculées pour chacun des 3 plans des espaces de couleurs que nous avons retenus, soient RVB, YCbCr et HSV. La couleur et la texture sont ainsi caractérisées par  $(6 + 5 + 5 + 10) * 9$  variables. *A l'aide d'une seule caméra*, on obtient ainsi  $(21+7+10)+(6+5+5+10)*9$  variables, soient 272 valeurs. L'utilisation de trois caméras donne finalement  $272 * 3 = 816$  variables pour chaque semence.

Nature des variables	Nombre	
<i>Calibre</i>	21	<b>Par semence</b>
<i>Moment</i>	7	
<i>Descripteur de Fourier</i>	10	<b>Pour chacun des canaux de RVB, YCbCr et HSV.</b>
<i>Paramètre de couleur</i>	6	
<i>Histogramme des différences de niveaux de gris</i>	5	
<i>Longueur de plage</i>	5	
<i>Cooccurrence</i>	10	

**Tableau 2.2 : structure des variables caractérisant une semence**

Le Tableau 2.2 présente pour chaque grand type de caractéristiques, le nombre de variables extraites.

Ces caractéristiques sont alors enregistrées dans une matrice de dimension  $n \times p$  où  $n$  représente le nombre d'observations et  $p$  le nombre de variables. En plus de cette matrice de données, un vecteur-colonne de dimension  $n \times 1$  comporte l'information d'appartenance de chaque observation à son espèce. Cette base d'étiquetage permet de pouvoir comparer la prédiction des algorithmes avec l'appartenance réelle de chaque observation. Cette base comporte des valeurs numériques entières associées à chaque espèce numérotées de 1 à  $g$  où  $g$  représente le nombre d'espèces acquises.



**Figure 2.7 : Organisation des données**

L'organisation des données est une étape essentielle dès lors qu'on a pour objectif d'identifier des objets à partir de nombreuses variables mesurées. Ces éléments sont à replacer dans une base de données qui contient à la fois les caractéristiques de l'objet et toute l'information qui

permet de définir son appartenance à un groupe qualitatif (ou sa classe). Une fois la base d'images créée, il est intéressant d'en extraire les caractéristiques.

Notre étude se décompose en quatre parties. Trois d'entre-elles sont consacrées à un seul type de variables : *morphologie*, *couleur* puis *texture*. Dans la quatrième, les différentes variables sont groupées dans des tableaux séparés, en fonction de leur type. Nous nous sommes ici intéressés à la relation entre ces tableaux

Remarque : l'ensemble des procédures d'analyse d'images et de traitement statistiques ont été développées dans l'environnement statistique MATLAB.

## **3.2. Résultats**

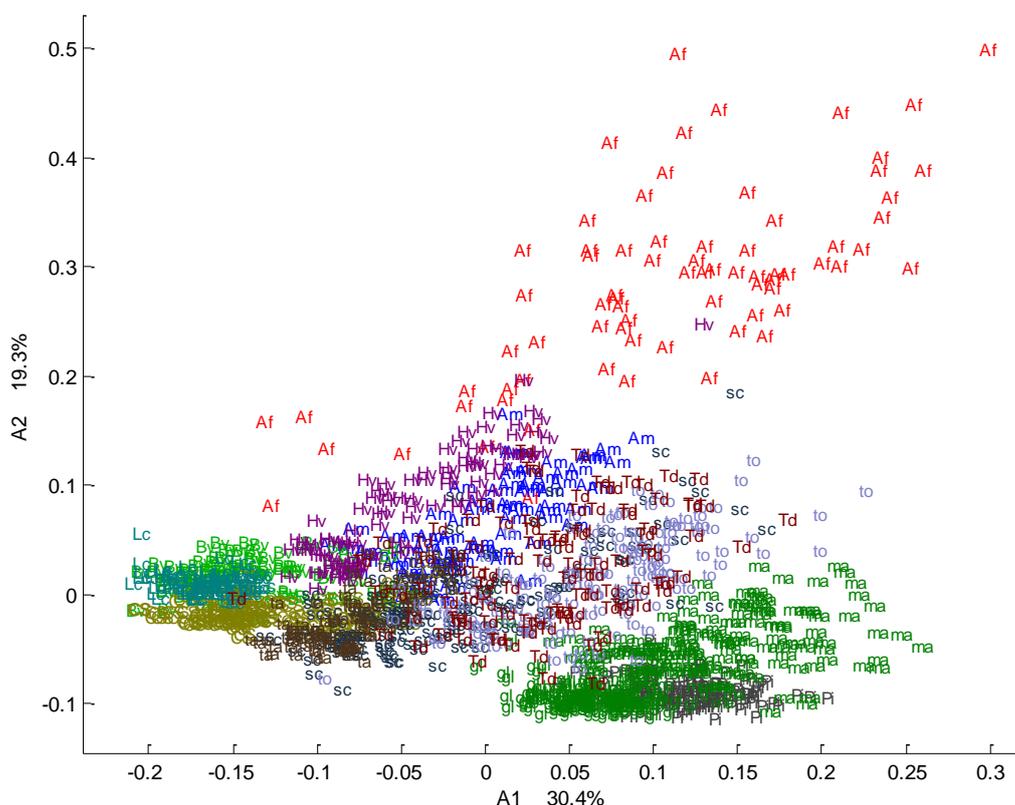
### **3.2.1. Etude de la morphologie des semences.**

La morphologie des semences est décrite par trois groupes de descripteurs, un premier décrivant le calibre de la semence, un second décrivant l'arrangement spatial de l'objet et le dernier décrivant de façon fréquentielle les contours de l'objet. Nous analyserons séparément ces trois aspects en utilisant une ACP pour visualiser de façon globale chacune de ces catégories de descripteurs. Considérant la grande quantité de types de variables, nous avons restreint notre présentation aux deux premières coordonnées factorielles des ACP. Le chapitre suivant, portant sur la discrimination, permettra de compléter cette présentation avec une identification des variables les plus intéressantes et une analyse des cartes factorielles associées à la discrimination. Pour chaque type de variables étudiées, nous avons concaténé les tableaux associés aux images des trois caméras. De cette manière, nous pouvons analyser les corrélations des mêmes variables mesurées sur les images obtenues avec les différentes caméras. Du fait de l'introduction et du principe de la chute libre, les semences peuvent avoir une orientation aléatoire face aux différentes caméras. Cette variabilité a pour effet de générer des données elles-mêmes très variables. Elle s'ajoute à la variabilité naturelle des semences et plus particulièrement à la variabilité inter et intra-espèces. La base est constituée de onze espèces, toutes de morphologie différente. Ainsi, la folle avoine est une semence oblongue, velue et dotée parfois d'une arête. Cette semence peut avoir une forme plus ou moins ouverte et éclatée ; elle est très difficile à mettre en place dans un système automatisé. Son défilement est très délicat parce que les semences s'accrochent entre elles. Les aspérités et les poils dont elles sont munies peuvent les retenir dans leur chute, d'autant plus qu'elles sont légères. L'arête, fragile, peut se détacher du reste de la semence lors de la manipulation ou lors du

convoyage dans l'automate, ce qui introduit une difficulté supplémentaire dans la description de sa morphologie. Le tournesol est une semence trapue, de forme elliptique et aplatie. Lorsque cette semence est cassée, elle a pour caractéristique d'avoir un contour avec une transition brusque, ce qui tranche avec les semences indemnes qui sont toutes arrondies. Les pois et les sojas ont des semences très sphériques, très semblables par leur morphologie, mais faciles à distinguer l'une de l'autre par la couleur, verte pour les pois et beige pour le soja. La betterave a une forme d'étoile à plat. Elle a la particularité de pouvoir s'agglomérer à l'intérieur d'enveloppes qui entrent en coalescence. Les sclérotés sont des champignons solidifiés, particulièrement indésirables dans les lots de tournesol. Ils peuvent avoir des formes très hétérogènes, souvent liées à la position dans laquelle ils se trouvent au milieu de semences, et de contours complètement imprévisibles. Les lentilles et le renoué sont des semences de forme circulaires et aplaties, de plus petite taille que les autres semences. L'orge et le blé sont des céréales dont les semences ont une forme oblongue, presque cylindrique. Elles comportent une fente dans le sens de leur longueur, ce qui ajoute à la variabilité dans la prise de vue multiple. Le maïs, a une semence encore différente, de forme plate et ressemblant à une dent (on parle de semence « dentale »).

- *Calibre*

Le calibre prend en compte la longueur, la largeur, la surface, le périmètre ainsi que différents rapports définis dans la partie. Les analyses de données réalisées jusqu'à présent n'ont pas donné au calibre un rôle déterminant pour la discrimination en dehors de ce qui apparaît évident comme la distinction entre petites et grosses semences.



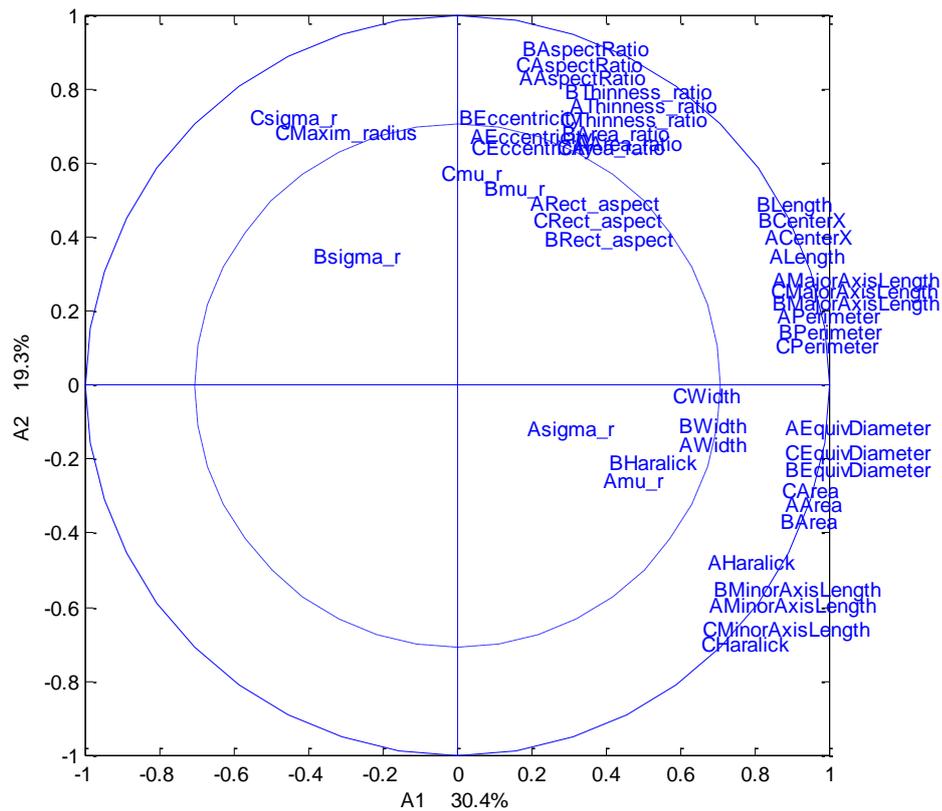
**Figure 2.8 : Carte factorielle de représentation selon les deux premières composantes**

**ACP sur les variables de calibre des semences.**

**Premier plan factoriel**

**Codes : Af : folle avoine ; Bv : Betterave ; Cs : Liseron ; Hv : orge ; Lc : Lentille ; Pi : Pois ; Gl : Soja ; Ma : Maïs ; Ta : Blé tendre ; Am : Amande de Tournesol ; Td : Tournesol endommagé ; Sc : Sclérote**

L'ACP (Figure 2.8) porte sur 21 descripteurs de calibre sur les trois caméras, soit 63 descripteurs). Les différentes espèces se distinguent par leur calibre selon les deux premières composantes. La folle avoine (code Af, en rouge) présente une très forte variabilité de calibre. Elle occupe la partie haute de la carte, mais elle envahit aussi la zone du bas. En revanche les betteraves, les renoués, les lentilles, le soja, le maïs, le pois, le blé forment des groupes compacts, à faible variabilité selon les critères de calibre. Les semences de tournesol forment plusieurs groupes, en rapport avec la présence de semences cassées. Il est possible d'analyser la corrélation entre les différentes variables composant les deux premières composantes principales en utilisant un cercle de corrélation où chaque variable est représentée par un point (Figure 2.9).



**Figure 2.9: ACP sur les variables de calibre des semences. Cercle de corrélation des variables**

**(Plan 1-2)**

**Codes : première lettre : A, B, C : nature de la caméra**

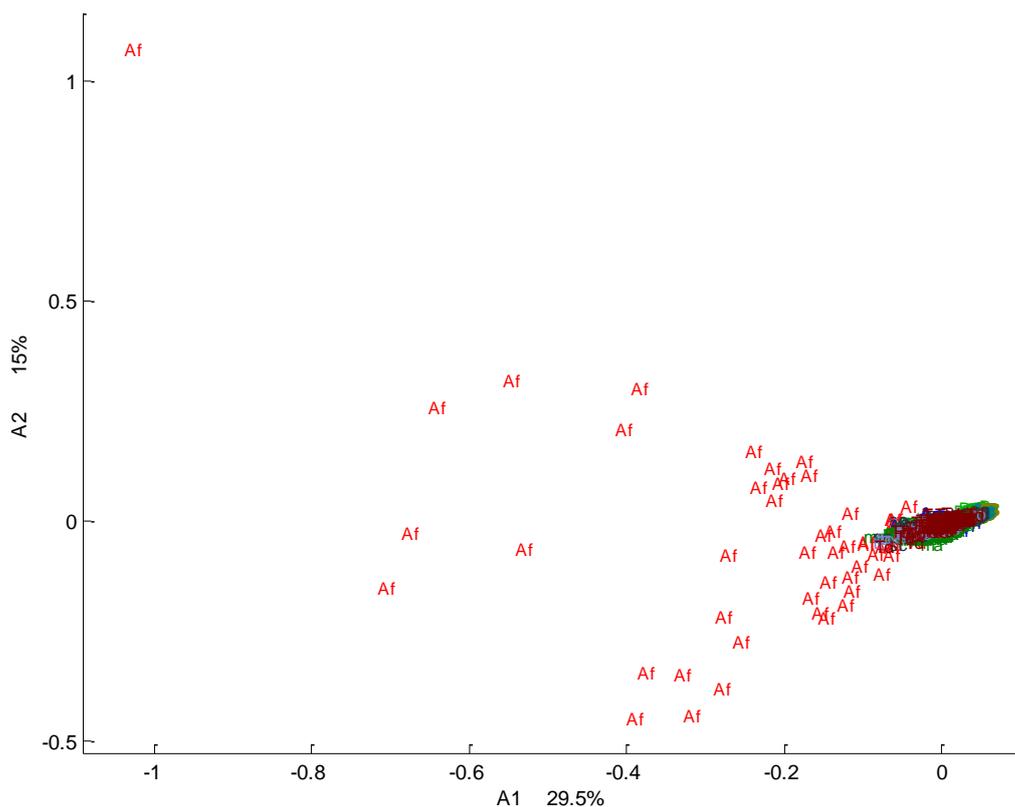
Le cercle de corrélation fait apparaître plusieurs groupes de variables fortement corrélées avec les principaux axes. Un premier groupe composé du rapport d'amincissement (*Thinness\_ratio*), du rapport de surface (*Area\_ratio*) et de l'excentricité (*Eccentricity*) comprend des variables corrélées avec le deuxième axe principal. Un deuxième groupe est composé de la longueur (*Length*), de l'axe majeur (*MajorAxisLength*) et du périmètre (*Perimeter*). Un troisième groupe, également associé comprend la surface (*Area*) et le diamètre équivalent (*EquivDiameter*). Enfin un quatrième groupe inclut l'axe mineur (*MinorAxisLength*) et le rapport entre la moyenne et l'écart-type du rayon de la semence (*Haralick*), ces trois derniers groupes montrent une forte corrélation avec le premier axe factoriel. Ainsi, la première composante semble être essentiellement représentative de la taille globale des semences, tandis que la deuxième oppose les semences très allongées par rapport aux semences plus rondes. Cette interprétation est en accord avec la carte factorielle des observations. Ces corrélations s'observent sur les trois caméras. Les variables de calibre

présentent naturellement des corrélations internes. Par exemple, le rapport entre le diamètre équivalent et la surface est évident, par sa formule même : si la surface est importante, le diamètre équivalent l'est aussi. On remarque, de plus que les variables homologues et bien représentées sur le premier plan factoriel sont en général fortement corrélées entre elles. Par exemple, les longueurs de l'axe majeur (*AmajorAxisLength*, *BmajorAxisLength* et *CmajorAxisLength* ) caractérisées par les 3 caméras (*A*, *B* et *C*) occupent des positions voisines sur la figure 11. Il est à noter que ces corrélations ne veulent pas dire que les trois caméras donnent des informations exactement identiques. Ainsi, lorsqu'une graine possède une forme allongée, l'image de cette semence selon sa plus grande dimension peut apparaître aléatoirement sur l'une des trois caméras.

- ***Moment***

Les moments font également partie des descripteurs morphologiques. Ils sont couramment utilisés dans le domaine de la reconnaissance de caractères. Ils ont, suivant les conditions de leur utilisation, les propriétés d'être invariants en translation, en rotation et au changement d'échelle, ce qui dans notre cas, peut être intéressant car les semences se présentent de manière aléatoire devant les caméras.

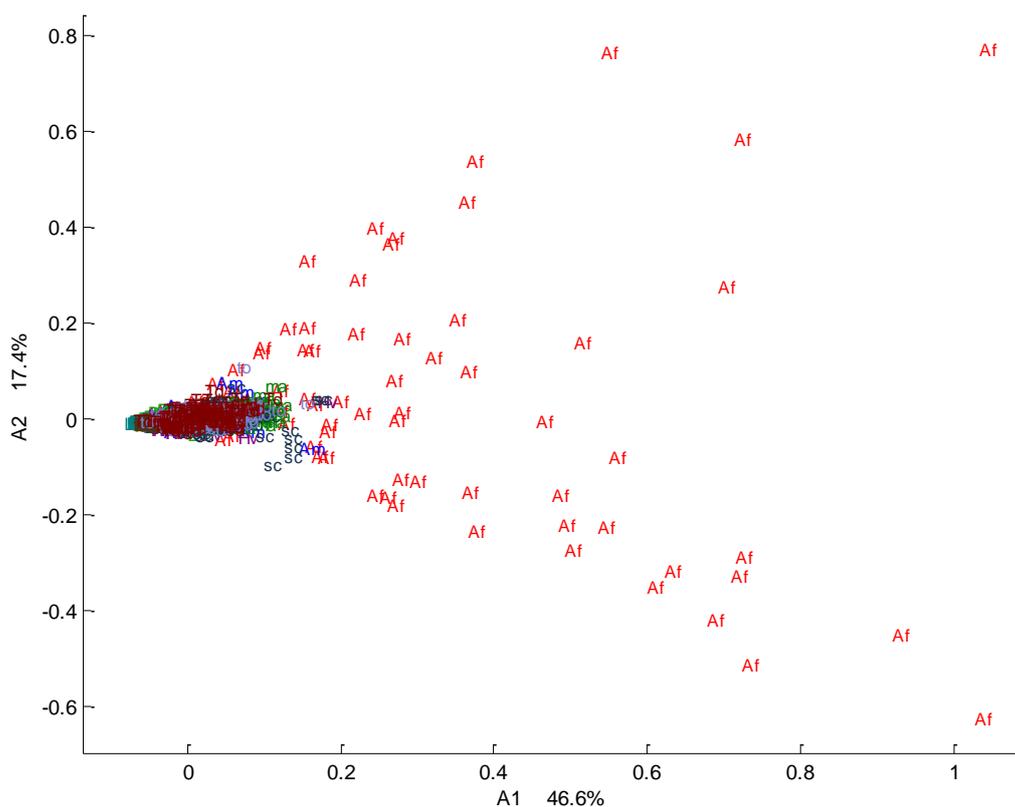
Comme pour le calibre, l'ACP est appliquée sur une base réduite de variables contenant les sept moments extraits sur les trois caméras (Figure 2.10). Seuls trois groupes se distinguent sur la carte factorielle: un premier groupe décrivant une partie des semences de tournesol cassées (Td), un deuxième les semences de folle avoine (Af), et enfin un dernier, où se retrouve toutes les autres semences. Contrairement aux résultats obtenus sur le calibre, il est difficile de distinguer la plupart des semences avec ces paramètres liés aux moments. Le système trois caméras n'apporte rien de plus sur ce point en dehors de la détection des semences de tournesol cassées. Les caractéristiques de moments apparaissent donc comme assez peu informatives. De plus, leur calcul met en jeu des puissances numériques élevées, ce qui est sans doute la source d'instabilités numériques.



**Figure 2.10 : ACP sur les variables associées aux moments des semences. Premier plan factoriel  
codes : voir Figure 2.8.**

- **Contour**

L'analyse du contour repose sur l'analyse de Fourier des pixels du périmètre de la semence. Un inconvénient de cette analyse est que dans le cas des semences il peut y avoir des concavités qui nuisent à l'utilisation de cette méthode pour la description fréquentielle du contour. En effet la méthode de Fourier est prévue pour analyser des signaux continus pour lesquels, à un temps donné, la fonction périodique ne prend qu'une seule valeur. Cependant, dans le cas d'un contour présentant des concavités ou de forme complexe, cette fonction peut prendre plusieurs valeurs. Ce problème apparaît particulièrement dans l'analyse des semences de folle avoine et de sclérotés. En ce qui concerne la folle avoine, cela est principalement dû au fait qu'elle est velue. Lors de la segmentation, c'est-à-dire lors du passage d'une image couleur à une image binaire déterminant la position de la semence sur l'image, il est possible d'avoir pour un même angle polaire de la semence plusieurs occurrences du contour. Tout comme les deux dernières sections, nous appliquerons une ACP sur la base de données réduite aux dix premières harmoniques de l'analyse de Fourier (Figure 2.11).



**Figure 2.11: ACP sur les variables associées aux coefficients de Fourier semences. Premier plan factoriel**

**codes : voir Figure 2.8.**

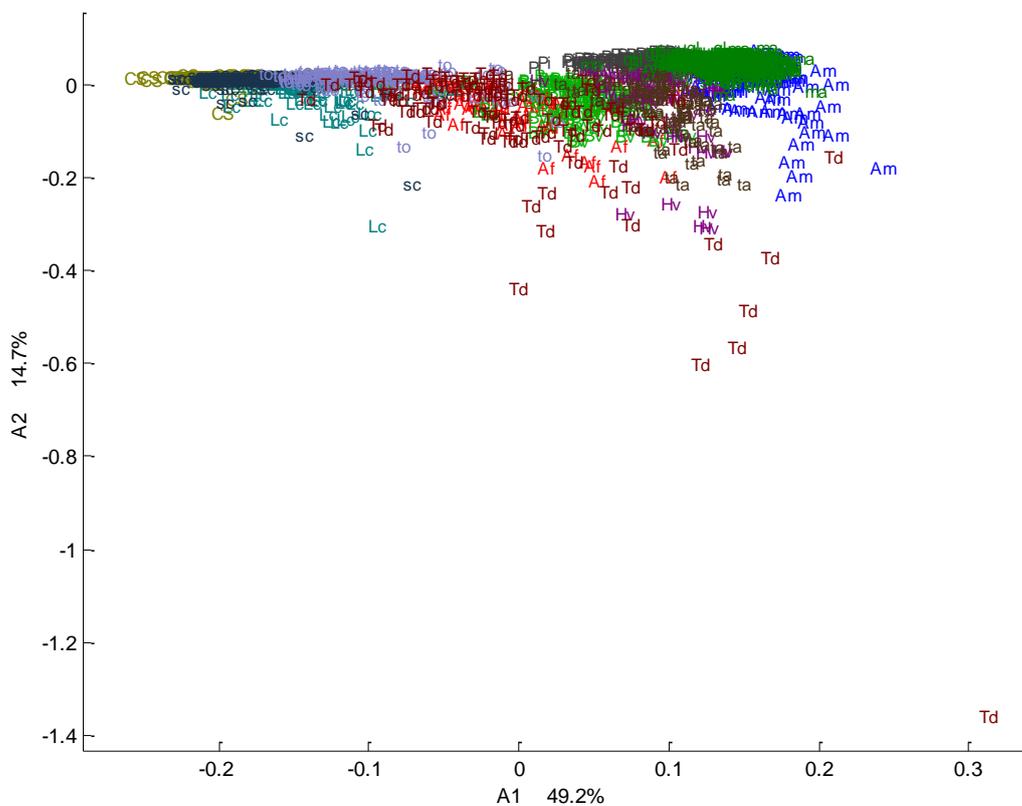
Les résultats sont très comparables à ceux obtenus avec les moments. Il apparaît que comme pour les moments, il est difficile de distinguer la totalité des espèces contrairement à ce que l'on obtenait à partir des descripteurs liés au calibre.

### **3.2.2. Etude de la couleur**

Nous avons indiqué précédemment que la couleur pouvait être codée de plusieurs manières différentes suivant le choix d'un espace de couleur donné. Nous allons donc maintenant analyser l'apport de la couleur comme élément unique de la caractérisation des semences, mais également analyser l'apport de différents systèmes de codage de la couleur. Nous analyserons successivement les descripteurs de la couleur sur les espaces colorimétriques RVB, YCbCr, et HSV.

- **RVB**

Il est intéressant d'analyser le comportement des descripteurs sur l'espace colorimétrique RVB qui est en général l'espace de référence brut donné par les capteurs d'acquisition d'images. Il est également, comme on l'a vu, l'espace de base à partir duquel les autres espaces colorimétriques peuvent être créés. Dans l'espace *RVB*, la luminance joue un grand rôle dans la corrélation entre les différents canaux. Par conséquent, nous nous attendons à trouver une forte proximité des variables sur le cercle de corrélation des différents canaux de couleur.

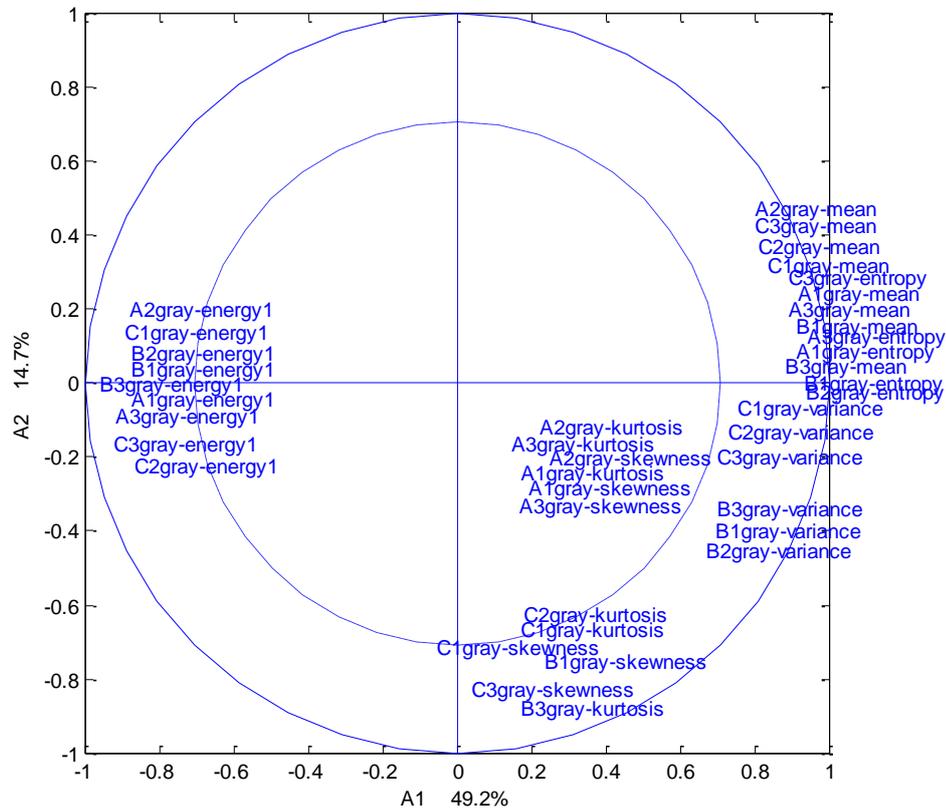


**Figure 2.12: ACP sur les paramètres de couleurs associés à l'espace RVB. Premier plan factoriel**

**codes : voir Figure 2.8.**

La carte factorielle des observations (Figure 2.12) montre qu'au niveau colorimétrique, il apparaît quelques groupes d'espèces différenciées par la couleur, essentiellement en fonction de la luminance, représentée par le premier axe. Néanmoins ces paramètres ne permettent pas de séparer nettement les espèces contrairement au calibre. La deuxième composante montre une séparation de certaines semences de tournesol endommagé (Td). Le cercle de corrélation (Figure 2.13) montre que le deuxième axe est représentatif de la dissymétrie (*skewness*) et de

l'appâtissement (*kurtosis*). Certaines semences de tournesol endommagé peuvent présenter des contrastes de couleur très marqués, ce qui se traduit effectivement par une forme particulière des histogrammes de couleur. Il y a bien une corrélation entre les canaux RVB, quelle que soit la caméra. Ces résultats sont donc en accord avec ce qui était attendu.

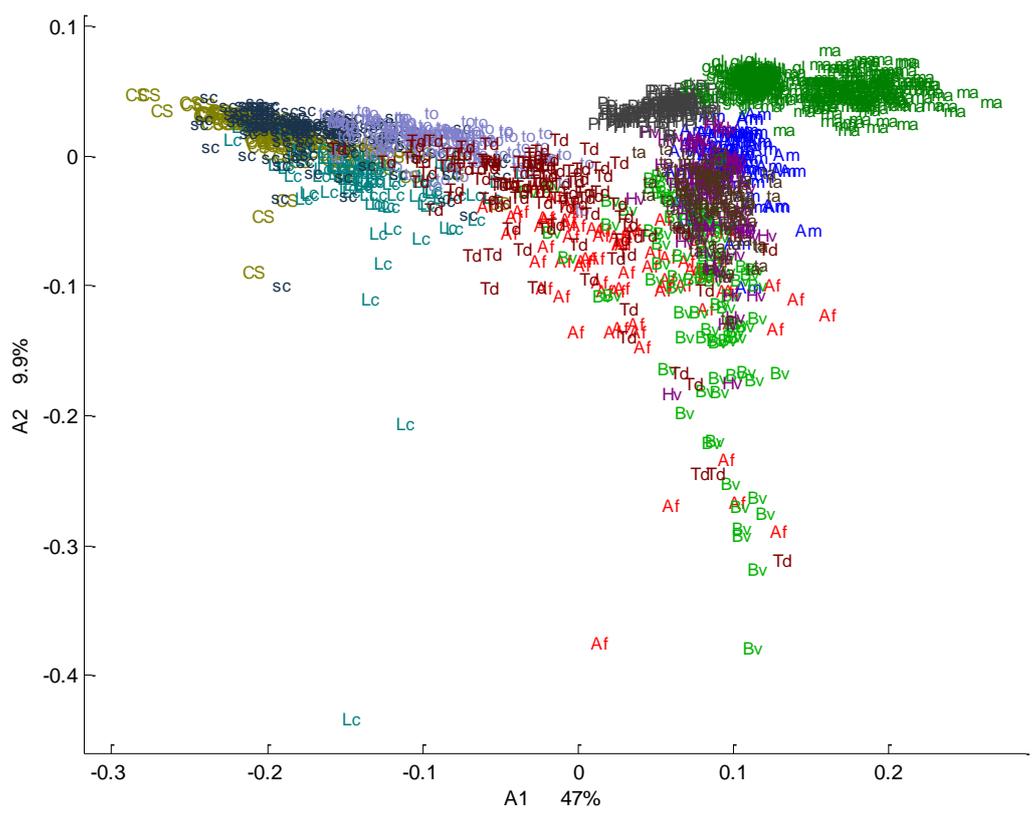


**Figure 2.13:** ACP sur les paramètres de couleurs associés à l'espace RVB. Cercle de corrélation associé aux deux premières composantes

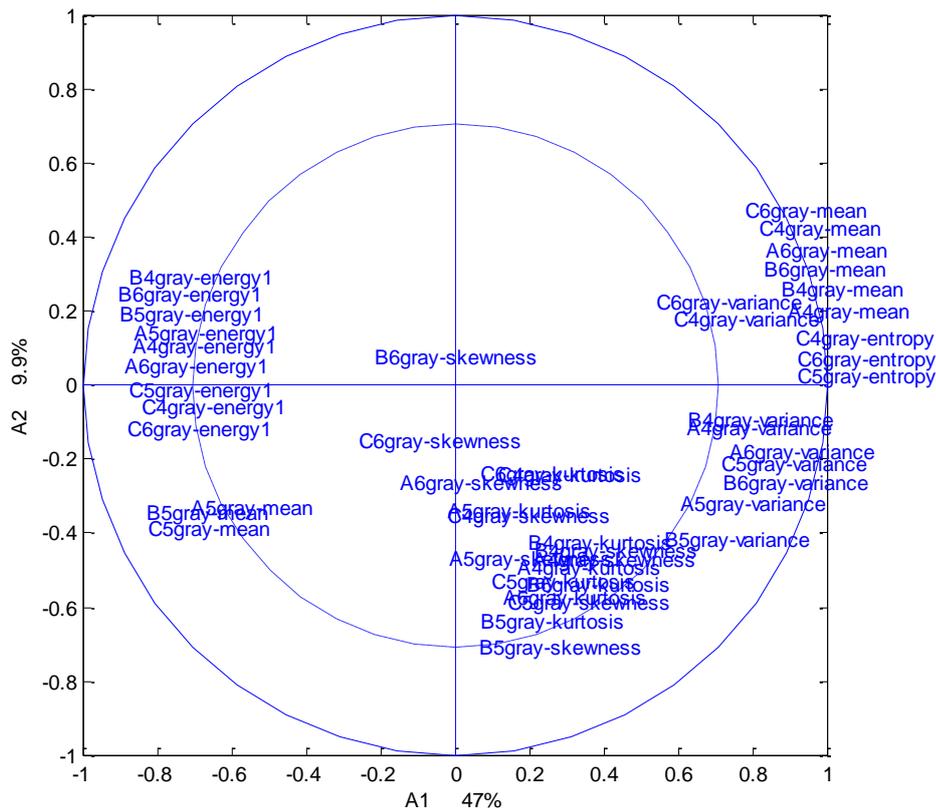
Codes : Voir annexe

- **YCbCr**

L'espace YCbCr permet d'extraire la luminance et la chrominance suivant le rouge et le bleu à partir de l'espace RVB par une transformation linéaire. Cette transformation permet de « décorrélérer » légèrement les différents canaux. On observe sur la Figure 2.14 que les groupes de semences se distinguent mieux que sur la Figure 2.15. Le cercle de corrélation montre également qu'il y a une moindre corrélation entre les différents descripteurs. Les remarques précédentes concernant la corrélation entre les caméras s'appliquent également ici. En revanche, les trois canaux de cet espace (soient Y, Cb et Cr) sont moins corrélés.



**Figure 2.14:** ACP sur les paramètres de couleurs associés à l'espace YCbCr. Premier plan factoriel  
 codes : voir Figure 2.8.



**Figure 2.15: ACP sur les paramètres de couleurs associés à l'espace YCbCr**

*Cercle de corrélation selon les deux premières composantes*

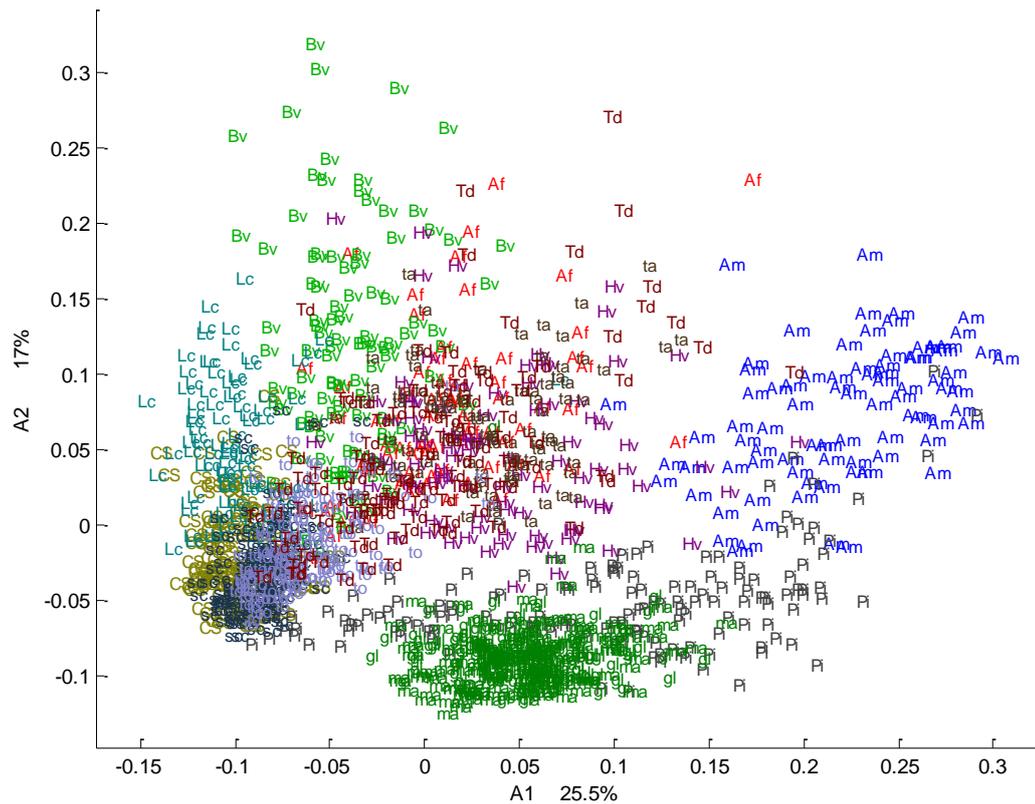
*Codes : voir annexe.*

- **HSV**

A la différence des précédents, l'espace HSV est issu d'une transformation non linéaire à partir de l'espace de référence RVB. Il permet de décomposer la couleur des semences suivant la teinte, la saturation et la luminosité. Cet espace permet une « décorrélation » importante entre les différents canaux codant la couleur. Il est de plus en plus utilisé dans le domaine de l'analyse des semences. L'analyse de la couleur des semences se tourne vers un autre espace de couleur perceptuel, qui est l'espace L\*a\*b\*. Nous avons déjà signalé les difficultés pratiques à employer cet espace, et pour les besoins de cette étude, l'espace HSV demeure le meilleur candidat.

Les deux Figure 2.16 et 2.17 ci-dessous montrent qu'il y a un réel gain dans la distinction des différentes espèces. En effet, il apparaît plus clairement des espèces telles que le maïs, la folle

avoine, la betterave. Le cercle de corrélation confirme également que les différents paramètres sont faiblement corrélés entre les canaux, ils montrent maintenant une corrélation entre les caméras. Cela signifie que pour la plupart des espèces, leur couleur est homogène quelle que soit la face qu'elles présentent à la caméra.



**Figure 2.16:** ACP sur les paramètres de couleurs associés à l'espace HSV. Premier plan factoriel  
codes : voir Figure 2.8.

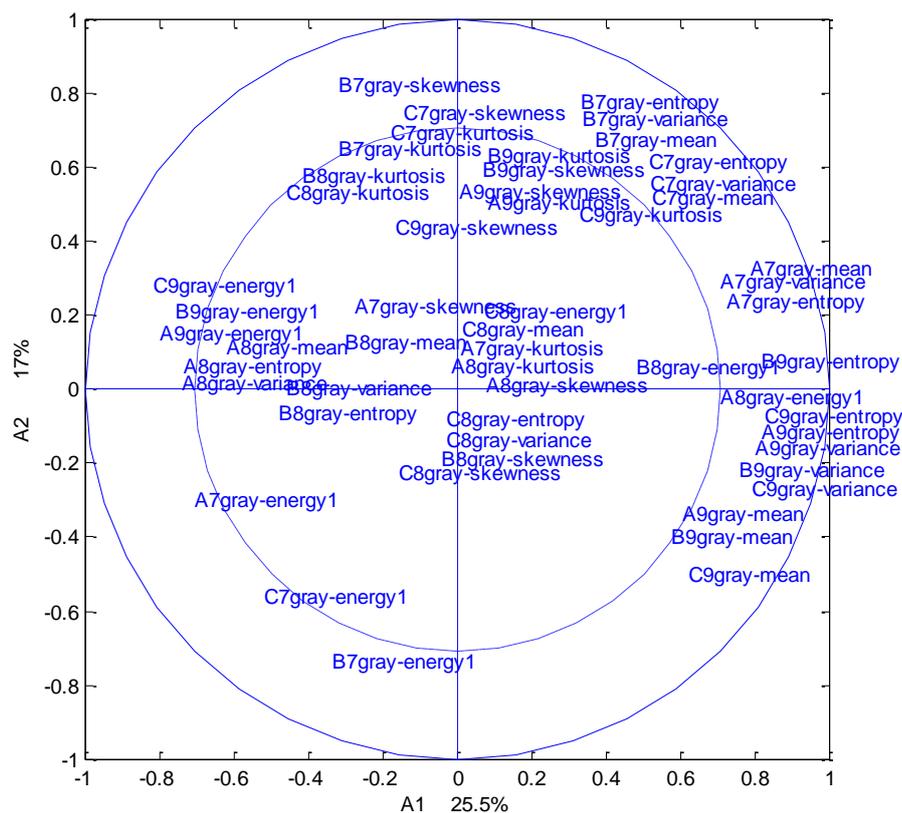


Figure 2.17: ACP sur les paramètres de couleurs associés à l'espace HSV. Cercle de corrélation sur les deux premières composantes.

Codes : voir annexe

### 3.2.3. Etude de la texture

L'extraction des paramètres de texture est, comme celle des paramètres de couleurs, sensible à l'espace de couleur codant l'image. Dans la partie 1.5, nous avons présenté les trois catégories de descripteurs statistiques des paramètres de texture que nous utilisons. Comme ces méthodes sont appliquées sur chacun des plans des espaces couleurs, le nombre de tableaux associés à la texture est très grand, et il n'est pas possible de présenter ici toutes les analyses de texture. Nous nous limiterons à l'étude des différents paramètres de texture sur l'espace de couleur HSV. Dans l'étude précédente des paramètres de couleur, cet espace a montré une plus grande capacité de description. Nous analyserons tout d'abord les paramètres extraits à partir des *histogrammes de différences de niveau de gris*, puis à partir des *matrices de co-occurrences* et enfin à partir des *matrices de longueurs de plages*.

- ***Histogramme des différences de niveau de gris***

Les paramètres extraits à partir des histogrammes de différences de niveaux de gris caractérisent principalement les gradients de couleur sur la semence. La carte factorielle des observations de l'ACP (Figure 2.18) ne montre pas une démarcation prononcée des différentes espèces de semences. Il apparaît cependant 3 groupes d'espèces :

Un premier groupe, entouré par une ellipse bleue sur la figure, comportant les espèces de blé tendre, d'orge, de pois, de maïs, de soja et d'amande de tournesol.

Un second groupe, représenté par une ellipse rouge, comportant les espèces et groupes qualitatifs de betterave, de folle avoine, d'achène de tournesol, de tournesols cassés, de sclérotés.

Un troisième représenté par une ellipse verte comportant les espèces de lentille et de renoué.

Il apparaît donc que la méthode fondée sur les histogrammes de différences des niveaux de gris permet, sur les deux premières composantes, de faire la distinction entre les semences considérées comme plutôt clair (ellipse bleue) et celles présentant une couleur homogène noire (ellipse verte).

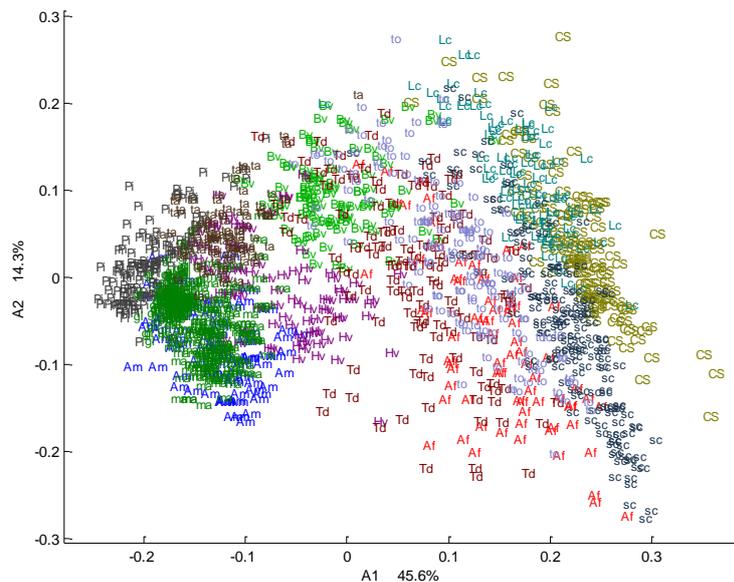
Le cercle de corrélation (Figure 2.19) montre une corrélation entre certains paramètres extraits sur les différentes caméras. Par exemple, on peut voir que la moyenne (*mean*) de l'histogramme extraite sur la caméra 1 est corrélée avec le contraste (*contrast*) extrait sur la caméra B. On remarque également que les paramètres du canal 9 (*value*, luminosité) sont fortement corrélés entre eux sur les caméras B et C.



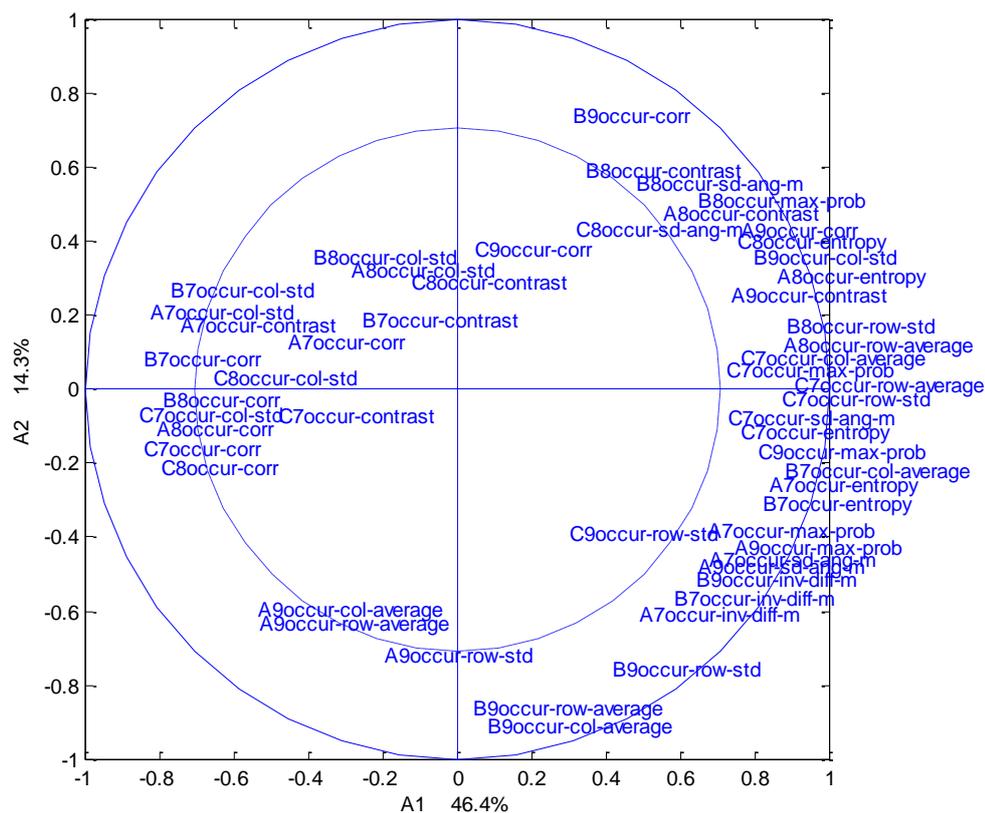
*Codes : voir annexe*

- **Matrices de cooccurrence**

La matrice de cooccurrence est l’histogramme bidimensionnel de la fréquence d’un couple de niveau de gris avec un pas donné. Les paramètres extraits permettent de résumer l’organisation de la matrice et les dépendances entre les différents niveaux de gris. La représentation obtenue sur les deux premières composantes principales de l’ACP (Figure 2.20) montre que les descripteurs de textures issus des matrices de cooccurrences permettent une meilleure séparation des différentes espèces. Le cercle de corrélation (Figure 2.21) montre également que de nombreux descripteurs sont fortement corrélés entre eux. Certains paramètres tels que les moyennes ou les écart-types par colonne et par ligne sont en effet redondants. Ces paramètres sont principalement corrélés dans le même espace de couleur et sur la même caméra. Cela signifie que les caméras ne « voient » pas forcément la même chose mais c’est bien ce que nous recherchions. Ainsi, par exemple, les semences présentant des faces de différentes couleurs sont bien caractérisées par le système à trois caméras.



**Figure 2.20 : ACP sur les paramètres de texture associés à la méthode des matrices de cooccurrence. Premier plan factoriel. codes : Figure 2.8.**



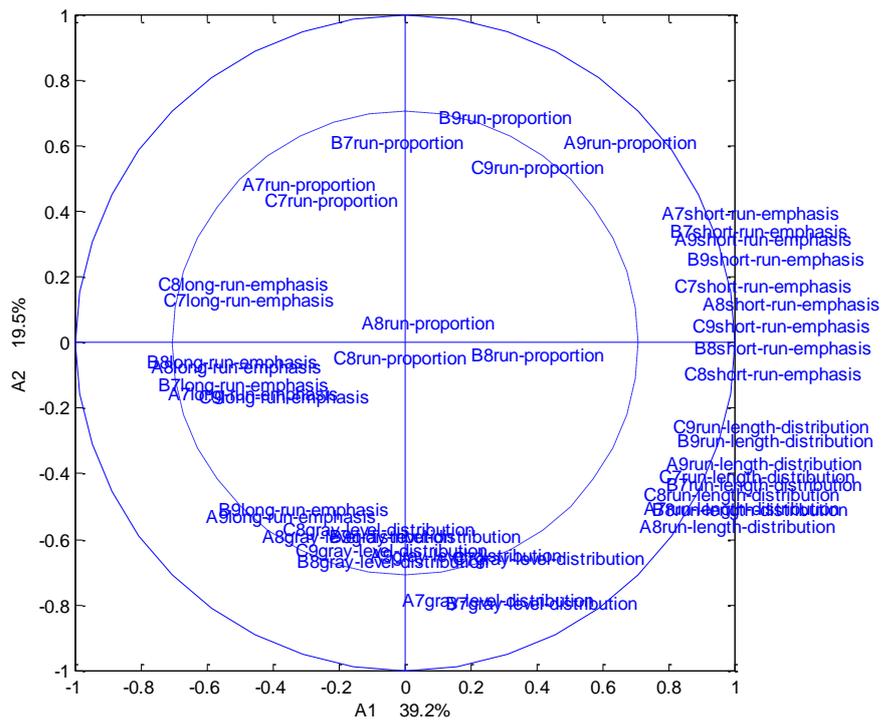
**Figure 2.21: ACP sur les paramètres de texture associés à la méthode des matrices de cooccurrence. Cercle de corrélation**

*codes : voir annexe.*

- **Longueur de plage**

La matrice de longueurs des plages donne, pour une direction donnée, le nombre de niveaux de gris consécutifs ayant la même valeur. Cette matrice permet donc de décrire des semences à partir du degré d'homogénéité des plages de couleurs, au sens des canaux colorimétriques présentés précédemment. De nombreuses semences de notre base de données sont bicolores. Certains défauts se manifestent par une variation de couleurs plus ou moins importante. C'est le cas, par exemple des semences de tournesols cassés. On remarque sur la Figure 2.22 que les semences monocolores sont représentées de manière compacte. On retrouve ainsi un groupe de semences extrêmement homogène composés d'espèces tel que le blé tendre, le maïs, le pois, le soja, la betterave et les amandes de tournesols. Un autre groupe homogène est, ici encore, formé par la paire « liseron des haies et lentille ». Le groupe Td (tournesol endommagé) forme deux groupes nettement séparés. Ceci paraît logique, si l'on considère que, suivant l'orientation et le degré de cassure, les semences de tournesols cassées peuvent





**Figure 2.23: ACP sur les paramètres de texture associés à la méthode des longueurs de plage. Cercle de corrélation**

**codes : voir annexe.**

### **3.2.4. Description des interrelations entre les tableaux.**

Nous avons étudié les représentations et les corrélations variables par variables. Dans cette partie nous présentons les ressemblances et l'apport d'information en analysant les données par blocs d'information. La méthode STATIS nous permet de décrire les interrelations entre tableaux. Elle permet de calculer un degré de ressemblance entre tableaux, sous la forme de *coefficient RV*. A partir de ces coefficients, il est possible de créer des représentations factorielles, dans lesquelles chaque point du graphique représente un tableau. Deux tableaux porteurs d'informations voisines sont proches sur ces représentations. Nous recomposons les données par type de caractéristiques. Nous avons ainsi des tableaux indépendants portant sur le calibre, le moment, la transformée de Fourier du contour et les descripteurs de couleurs et de texture. Nous avons adopté la nomenclature suivante :

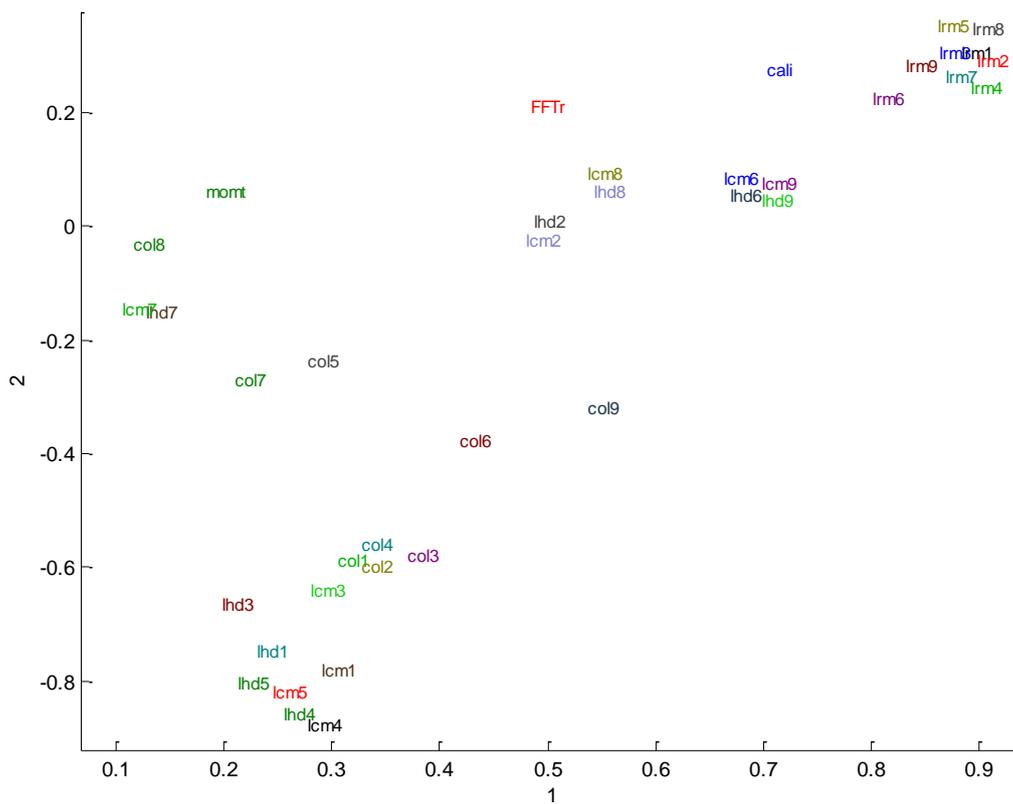
Un groupe de quatre caractères définit le type du tableau : *cali* pour le calibre, *momt* pour le moment, *FFTr* pour le descripteur de Fourier, *col* pour les paramètres de couleur, *lhd* pour les histogrammes de niveau de gris, *lcm* pour les matrices de cooccurrence et *lrm* pour les longueurs de plage.

Le dernier caractère M est un entier compris entre 1 et 9 permettant d'identifier le canal de couleur, dans l'ordre R, G, B, Y, Cb, Cr, H, S, V.

La matrice de données représente 816 variables qui peuvent ainsi être divisée en 117 tableaux. La méthode STATIS, faisant intervenir les produits scalaires associés à chacun des tableaux demande une grande puissance de calcul et ne peut pas être appliquée directement sur l'ensemble des 117 tableaux. Pour cette raison, nous avons effectué trois analyses séparées, pour chaque ensemble de 39 tableaux obtenu avec chacune des trois caméras. Nous avons également sélectionné aléatoirement un cinquième de chaque groupe d'espèce, pour accélérer les calculs. Cette sélection ne devrait pas avoir d'influence marquée sur les conclusions de l'étude.

Les 3 cartes factorielles associées à chaque caméra sont pratiquement identiques, ce qui indique que la structure de ressemblance entre les tableaux est identique. Pour cette raison nous ne représentons ici qu'une seule carte factorielle de ressemblance des tableaux Figure 2.24.

Il apparaît que les tableaux correspondant aux paramètres des histogrammes des différences de niveau de gris (lhd) et les matrices de cooccurrence (lcm) ont une forte ressemblance, quel que soit le canal. Les tableaux représentatifs de la couleur (col) sont, logiquement, plus dispersés. Il apparaît également que les paramètres de longueur de plages montrent une ressemblance prononcée avec les caractéristiques du calibre. Ceci est logique, si l'on considère que la longueur de la plage d'un niveau de gris est dépendante du calibre de la semence. En effet, la longueur de plage maximale que l'on puisse rencontrer dans une forme est égale ou inférieure à la plus grande dimension de cette forme. Dans le cas des matrices de cooccurrence et des différences des histogrammes de niveau de gris, ces deux descripteurs utilisent le voisinage des pixels pour décrire une texture.



**Figure 2.24: Méthode STATIS sur caméra A.**

**Représentation factorielle des tableaux.**

*code : cali : calibre ; momt : moment ; FFTr : descripteur de Fourier ; col : couleur ; lhd : histogramme des différences de niveau de gris ; lcm : cooccurrences ; lrm : longueurs de plage; Dernier caractère : canal de l'espace couleur (de 1 à 9), respectivement : R, G, B, Y, Cb, Cr, H, S, V*

## ***Récapitulation et conclusions du chapitre 2***

*Dans le présent chapitre, nous avons tout d'abord recherché des variables permettant de décrire les semences en tenant compte de leur forme, leur couleur et leur texture, et nous avons détaillé leurs procédures de calcul. Les caractéristiques de couleur et de texture peuvent être évaluées dans différents espaces de couleur. Nous en avons retenu trois dans le présent travail. Les caractéristiques d'images que nous pouvons ainsi extraire sont très nombreuses. Sur un jeu d'images de semences, nous avons analysé de manière exploratoire, les interrelations entre ces différentes variables, et étudié leur intérêt potentiel dans l'optique de la discrimination.*

*Il apparaît que les mesures effectuées dans les trois espaces de couleurs sont assez différentes, et semblent apporter des informations complémentaires sur les semences. De plus, on remarque qu'un système à trois caméras permettant d'observer la totalité de la surface des semences est plus performant qu'un dispositif ne comprenant qu'une caméra. En particulier, les objets présentant des surfaces hétérogènes sont beaucoup mieux décrits.*

*Avec certains types de variables, par exemple celles qui décrivent la texture, on obtient déjà une certaine séparation, « non supervisée » des différentes espèces de semences. Dans une approche exploratoire, cette séparation n'est probablement pas la meilleure que l'on puisse obtenir avec les données disponibles.*

*Le chapitre suivant est consacré aux méthodes et aux stratégies d'identification de ces espèces, avec une approche prédictive.*



# **CHAPITRE 3 :**

## **DISCRIMINATION DES SEMENCES ET PRISE DE DECISION.**

*L'objectif de ce troisième chapitre est de présenter les différentes stratégies de discrimination des semences et des graines dans le cas d'un système à trois caméras. Cet objectif soulève de nombreuses questions : la première est de savoir ce qu'apporte le choix d'un système comprenant trois caméras par rapport au système reposant sur une seule caméra. La seconde est de savoir quelle organisation des données et quels algorithmes choisir pour obtenir la meilleure classification des semences.*

*Il s'agit d'étudier les méthodes de discrimination offrant les meilleures performances sur la collection de référence présentée dans les chapitres 1 et 2. De manière à pouvoir comparer les différentes méthodes, nous étudierons les procédures d'échantillonnage et de validation.*

*Dans une partie expérimentale nous présenterons les résultats obtenus grâce à ces différentes méthodes. A partir de ces essais, nous pourrons émettre des hypothèses sur la possibilité d'obtenir une discrimination optimale avec un système complètement autonome, dont les spécifications seront présentées dans le chapitre suivant.*

## 1. Les algorithmes de discrimination des semences.

### 1.1. Les méthodes de discrimination appliquées aux semences.

La recherche dans le domaine de la discrimination et la caractérisation des semences et des graines par la vision artificielle remonte aux années 80. Elle s'attache particulièrement à l'étude des semences de la grande culture céréalière. Le blé a été majoritairement étudié, mais d'autres céréales telles que l'orge, le seigle, le maïs et le riz ont également donné lieu à des travaux, moins nombreux. On doit également signaler sur le même thème des études portant sur des graines de mauvaises herbes. Ces études ont été menées simultanément en Amérique du nord sur le blé (Majumdar et Jayas, 2000a, 2000b, 2000c, 2000d), en Chine sur le riz (Wan 2002), en Europe (Chtioui, 1997) et en Argentine (Granitto, Verdes et Ceccatto 2005) sur les mauvaises herbes.

Nous présenterons successivement les travaux réalisés sur riz, puis sur celle des mauvaises herbes et enfin sur les céréales, qui sont les plus nombreux.

#### 1.1.1. Riz

Sakai, Yonekawa et Matsuzaki, (1996) ont étudié la possibilité d'utiliser la vision artificielle pour caractériser la forme des grains de riz. Pour cette étude 4 variétés de riz (*Nipponbare*, *Bluebonnet 50*, *Jhona 349* et *Arborio*) ont été cultivées dans une ferme expérimentale de l'université de Tokyo, elles sont caractérisées par 6 paramètres de taille : surface, périmètre, longueur, largeur, circularité et élongation. Une analyse de variance sur les moyennes des paramètres montre que la séparation entre *Nipponbare* et *Bluebonnet* est possible. Cette étude ne va cependant pas jusqu'à la discrimination.

Cheng et Ying, (2004) ont étudié l'apport de la transformée de Hough pour détecter des structures formant des lignes dans des images de grains de riz, pouvant apparaître lorsque les grains sont fissurés ou endommagés. Cinq variétés de riz (*Jinyou 402*, *Shanyou 10*, *Zhongyou 207*, *Jiayou* et *Ilyou*) sont analysées selon trois critères de qualité : « normale », « finement fissuré » et « ouverte ». Ces différentes catégories permettent de déterminer la vigueur et donc la qualité des lots de riz. Les résultats expérimentaux montrent qu'il est possible de détecter avec un taux de 96% les semences normales, 92 % les semences avec des fissures fines et 87% pour des semences ouvertes. Une étude menée à Taïwan (Wan 2002) présente l'utilisation d'un système d'acquisition, déjà décrit dans le chapitre 1, dévolu à l'analyse automatique des lots de riz. Treize catégories de qualité des lots, telles que les semences de couleur verte, craquées, cassées sont identifiées. Le système possède deux modes de

fonctionnement : en réflexion ou en transparence. Le mode en réflexion permet de caractériser les semences de riz selon des paramètres de formes et de couleurs tandis que le mode en transmission permet de mesurer des paramètres de transparence. Le système de classification est composé d'un réseau de neurones à trois couches utilisant comme fonction d'activation une sigmoïde avec comme entrée les 16 caractéristiques et comme sortie les 13 catégories à identifier. Le pourcentage de classification obtenue est 85,9 %.

### 1.1.2. Mauvaises herbes.

La première étude sur l'utilisation de la vision artificielle pour la caractérisation d'espèce végétale adventice remonte aux années 80 (Travis et Draper 1985). Ces auteurs ont tenté d'identifier 49 espèces végétales dans des lots de semences, dont 42 espèces cultivées et 7 graines nuisibles. Les graines, au nombre de 30 par espèces, ont été caractérisées selon leur morphologie (surface, périmètre, longueur, largeur et coefficient d'amincissement). Deux caractéristiques, la longueur et le coefficient d'amincissement, sont en général suffisantes pour obtenir une bonne discrimination des espèces. Cependant, dans le cas des lots de semences de carotte, il est nécessaire de tenir compte également de paramètres de couleurs pour séparer correctement les différentes espèces présentes.

Petersen et Krutz, (1992) ont étudié l'intérêt de l'analyse de texture d'images en couleur pour la discrimination de 4 espèces d'impureté (*Matricaria chamomilla* L., *Solanum nigrum* L., *Chrysanthemum segetum* L., et *Rumex crispus* L.). Il a été montré que l'ajout de caractéristiques de texture (Histogramme de niveau de gris, co-occurrence et longueur de plage) permettait d'augmenter nettement la séparation de ces impuretés, passant de 42,5% à 90,8% d'observations correctement classées.

La présente thèse s'inscrit dans la continuité des travaux menée par Chtioui, (1997), dont l'objectif était d'analyser la potentialité et les limites de la vision artificielle pour la caractérisation automatique des semences. Une collection composée de semences de Fétuque rouge, Ray-gras anglais, Avoine sauvage, Rumex, Mélilot, Luzerne, Dactyle, et Minette a été constituée. Les semences sont ici placées manuellement sous l'objectif de la caméra. De nombreux algorithmes de classification ont été testés (Chtioui, Bertrand et Dattée 1996 ; Chtioui et Bertrand 1996 ; Chtioui, Bertrand et Barba 1998 ; Chtioui, Bertrand, et al., 1997 ; Chtioui, Bertrand, et al. 1997) allant de l'analyse discriminante linéaire à l'étude des réseaux de neurones probabilistes basées sur la théorie bayésienne. Cette thèse a montré l'efficacité des réseaux de neurones probabilistes permettant d'avoir un taux de classification correcte

pouvant aller jusqu'à 100% suivant la nature de la collection de graines. Il est cependant difficile d'obtenir un taux de 100% dans le cas de graines d'apparence proche comme le Mélilot et la Luzerne.

A la suite de cette étude, d'autres travaux ont été menés par Granitto, Verdes et Ceccatto, (2005). Une base de données composée de 10310 images de 236 espèces de mauvaises herbes différentes a été constituée. L'objectif de cette étude est d'analyser l'efficacité d'un algorithme reposant sur la théorie bayésienne (Asselin de Beauville et Kettaf 2005) avec la sélection de caractéristiques les plus discriminantes. Les résultats sont comparés avec ceux obtenus par des réseaux de neurones. La sélection des variables s'effectue de manière directe (montante) ou rétrograde, avec comme objectif de maximiser la qualité de la discrimination (Jain et Zongker 1997). La sélection de 12 paramètres (6 morphologique, 4 de couleur et 2 de texture) conduit à la meilleure discrimination. Les algorithmes de classification de type bayésien et les réseaux de neurones donnent des résultats similaires.

### 1.1.3. Céréales.

La discrimination des semences de blé a fait l'objet de nombreux travaux, certains portent simplement sur la caractérisation (Keef et Draper 1986 ; Symons et Fulcher 1988 ; Zayas, et al. 1994), d'autres ont également un objectif de discrimination de semences de blé (Zayas, Pomeranz et Lai, 1985 ; Zayas, Pomeranz et Lai, 1989), d'orge, de seigle et d'avoine (Jayas, Murray et Bulley 1999 ; Nair 1999 ; Paliwal, Visen, et al. 2003 ; Paliwal, Visen, et al., 2003 ; Wang et Paliwal 2006). Ces différentes études sont principalement menées dans les universités des grandes plaines fertiles des Etats Unis dans le prolongement du fleuve Mississippi continuant sur l'état canadien du Manitoba. Le commerce céréalier est très actif dans cette région. Pour preuve une bourse des céréales, d'importance mondiale, se tient à Chicago. Des études menées par Majumdar et Jayas, (2000d), sur une base de 42000 semences, analysent l'intérêt des paramètres spécifiques des caractéristiques de *morphologie*, de *couleur* et de *texture* pour la discrimination des semences de blé dur roux d'hiver (*hard red winter wheat*), de blé dur roux de printemps (*hard red spring wheat*), d'orge, de seigle et d'avoine. Cette base est séparée en une collection d'apprentissage de 30500 semences et une collection de test de 10500 semences. Les différents résultats présentés ci-dessous sont obtenus sur la collection de test en utilisant un algorithme de discrimination linéaire. Dans l'étude sur la *morphologie* (Majumdar et Jayas 2000a), il est montré que les 10 caractéristiques morphologiques les plus significatives permettent d'identifier avec un taux de

succès de 98,9%, 93,7% , 96,8%, 99,9% et 81,6%, respectivement le blé dur roux d'hiver, le blé dur roux de printemps, l'orge, l'avoine et le seigle,.

Dans l'étude sur la *couleur* (Majumdar et Jayas 2000b), il est montré que les 10 caractéristiques les plus significatives permettent d'identifier avec une précision de 94,1%, 92,3% , 93,1%, 95,2% et 92,5%, respectivement le blé dur roux d'hiver, le blé du roux de printemps, l'orge, l'avoine et le seigle.

Dans l'étude sur la *texture* (Majumdar et Jayas 2000c), les 15 caractéristiques les plus discriminantes permettent d'identifier avec un taux de succès de 85,2%, 98,2%, 100%, 100% et 76,3%, respectivement le blé dur roux d'hiver, le blé dur roux de printemps, l'orge, l'avoine et le seigle.

Dans une dernière étude (Majumdar et Jayas 2000d), ont analysé l'apport de la combinaison des paramètres morphologiques, de couleur et de texture pour la discrimination de la même base de semences. La sélection des 20 paramètres les plus significatifs conduit à un taux d'identification correct compris entre 98,9% et 99,9%.

Ces études montrent l'intérêt de la combinaison des paramètres de morphologie, de couleur et de texture pour la discrimination des céréales.

Visen et al, (2002) ont appliqué différents types de réseaux de neurones à rétro-propagation d'erreur, de Ward, régression généralisée et probabilistes. Ils ont également étudié une combinaison de ces différentes approches, ainsi que des systèmes spécialisés. L'idée principale des réseaux spécialisés consiste à réaliser tout d'abord un apprentissage entre une espèce précise et le reste. Dans l'étude, 5 sous-réseaux ont été mis en œuvre. Les semences sont caractérisées par des paramètres morphologiques et des paramètres de couleur. L'algorithme de discrimination offrant le meilleur résultat est un système de réseaux de neurones probabilistes spécialisés, donnant un pourcentage de classifications correctes compris entre 96,9% et 99,3%. Les auteurs concluent que le seul désavantage d'un tel système est la génération de 5 réseaux différents qui doivent être réalisés et entraînés séparément.

## 1.2. Les algorithmes de discrimination.

### 1.2.1. Analyse discriminante linéaire

L'analyse discriminante est basée sur le critère de maximum de vraisemblance *a posteriori*. Chaque observation est attribuée au groupe auquel elle a le plus de chance d'appartenir. Ceci peut être représenté sous forme probabiliste par :

$$P(w_k/x) = \max(p(w_i/x))$$

pour  $i=1 \dots K$ , avec  $K$  le nombre de groupes qualitatifs.

$P(w_k/x)$  est la probabilité conditionnelle *a posteriori* d'appartenance de l'observation  $x$  au groupe  $k$  sachant que l'observation vaut  $x$ . Cette probabilité est en pratique difficile à estimer. En effet, elle nécessite l'estimation de la distribution des densités de probabilité pour chaque observation  $x$ . Le théorème de Bayes permet d'exprimer cette probabilité en fonction de la probabilité a priori  $p(w_k)$ ,

$$p(w_k/x) = \frac{p(x/w_k)p(w_k)}{p(x)}$$

Le critère de maximum de vraisemblance a posteriori devient donc,

$$p(x/w_k)p(w_k) = \max(p(x/w_k)p(w_i))$$

L'analyse discriminante suppose que la distribution de chaque groupe est gaussienne. La probabilité conditionnelle *a priori* du groupe  $k$  s'écrit donc,

$$p\left(\frac{\mathbf{x}}{w_k}\right) = \frac{1}{(2\pi)^{\frac{p}{2}}} \frac{1}{\sqrt{\det(\Sigma)}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu}_i)^t \Sigma^{-1}(\mathbf{x}-\boldsymbol{\mu}_i)}$$

Où  $\boldsymbol{\mu}_i$  et  $\Sigma$  représentent respectivement le vecteur moyen et la matrice de variance-covariance de l'ensemble des groupes. Le critère de vraisemblance conduit alors à la règle de décision définie par :

$$p(x/w_k)p(w_k) = \max\left[\frac{1}{(2\pi)^{\frac{p}{2}}} \frac{1}{\sqrt{\det(\Sigma)}} e^{-\frac{1}{2}(\mathbf{x}-\boldsymbol{\mu}_i)^t \Sigma^{-1}(\mathbf{x}-\boldsymbol{\mu}_i)} p(w_i)\right]$$

Les fonctions discriminantes sont invariantes par toute transformation monotone croissante. Un exemple intéressant est la transformation en logarithme népérien. L'analyse discriminante quadratique revient alors à calculer chacune des fonctions discriminantes  $g_i(x)$ ,

$$g_i(x) = -\frac{1}{2}(x - \mu_i)^t \Sigma^{-1}(x - \mu_i) - \frac{1}{2} \ln [\det (\Sigma) ] + \ln [p(w_i)]$$

L'observation  $x$  est attribuée au groupe  $k$  si,

$$g_{i(x)} = \max g_i(x)$$

On peut alors considérer  $\ln [\det (\Sigma) ]$  comme constant. Les fonctions discriminantes deviennent,

$$g_{i(x)} = -\frac{1}{2}(x - \mu_i)^t \Sigma^{-1}(x - \mu_i) + \ln [p(w_i)]$$

Où  $\Sigma$  est la matrice de variance-covariance totale. Si les groupes sont équiprobables a priori, on obtient l'analyse discriminante linéaire,

$$g_{i(x)} = -\frac{1}{2}(x - \mu_i)^t \Sigma^{-1}(x - \mu_i)$$

Chaque observation  $x$  est attribuée au groupe le plus proche au sens de la distance de Mahalanobis. Les frontières de la décision sont des hyperplans.

Dans notre étude nous appliquerons ces méthodes sur les données mais également sur les coordonnées factorielles d'une ACP.

### 1.2.2. Analyse discriminante factorielle.

L'analyse factorielle est décrite dans de nombreux manuels (Saporta 2006).

Soit  $X$  la matrice centrée des données de dimension  $n \times p$ , avec  $n$  représentant le nombre d'observations et  $p$  le nombre de variables. Soit  $k$  le nombre de groupes qualitatifs. La Figure 3.1 récapitule les principales formules matricielles qui interviennent dans l'analyse discriminante, permettant de définir les matrices de variance-covariance totales  $T$ , interclasse  $B$  (*Between*) et intraclasse  $W$  (*Within*). La matrice  $B$  décrit la dispersion des centres de gravité

(moyennes des observations appartenant à un même groupe), tandis que la matrice  $\mathbf{W}$  est caractéristique de la dispersion à l'intérieur d'un groupe.

$$\mathbf{g} = \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \quad \text{Centre de gravité}$$

$$\mathbf{g}_j = \frac{1}{n_j} \sum_{i=1}^{j} \mathbf{x}_i \quad \text{pour } \mathbf{x}_i \in G_j \quad \text{Centre de gravité du groupe } j$$

$$\mathbf{V} = \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \mathbf{g})(\mathbf{x}_i - \mathbf{g})' \quad \text{Matrice de variance-covariance totale}$$

$$\mathbf{V}_j = \frac{1}{n_j} \sum_{\mathbf{x}_i \in G_j} (\mathbf{x}_i - \mathbf{g}_j)(\mathbf{x}_i - \mathbf{g}_j)' \quad \text{Matrice de variance-covariance du groupe } j$$

$$\mathbf{B} = \sum_{j=1}^k n_j (\mathbf{g}_j - \mathbf{g})(\mathbf{g}_j - \mathbf{g})' \quad \text{Matrice de variance Between (interclasse)}$$

$$\mathbf{W} = \sum_{j=1}^k n_j \mathbf{V}_j \quad \text{Matrice de variance Within (intraclasse)}$$

On a :

$$\mathbf{V} = \mathbf{W} + \mathbf{B}$$

Figure 3.1: Formules matricielles intervenant dans l'analyse discriminante

L'analyse factorielle discriminante effectue une transformation de l'espace initial en un espace de représentation dans lequel les classes sont mieux séparées. Chaque nouvel axe, appelé « axe factoriel discriminant », maximise l'inertie inter-classe, et minimise l'inertie intra-classe. Ceci revient à maximiser le rapport  $\frac{B}{W}$ . A partir de la formule de décomposition de Huyghens ( $\mathbf{V}=\mathbf{W}+\mathbf{B}$ ), on montre que les axes factoriels discriminants sont les vecteurs propre de  $\mathbf{V}^{-1}\mathbf{B}$ . L'amplitude d'une valeur propre est un indice du pouvoir discriminant de l'axe factoriel correspondant. Par nature, il y a, au plus,  $K-1$  axes factoriels discriminants. Les vecteurs propres de  $\mathbf{V}^{-1}\mathbf{B}$  sont regroupés, en colonnes, dans une matrice  $\mathbf{F}$ , de dimensions  $p \times m$  où  $m$  est le nombre d'axes factoriels retenus (avec  $m < K - 1$ ). Les coordonnées factorielles  $\mathbf{SS}$  sont alors calculées par projection orthogonale sur les axes discriminants :

$$\mathbf{S} = \mathbf{XF}$$

D'une manière similaire, les coordonnées factorielles des centres de gravité sont calculées par,

$$J = GF$$

où  $G$  désigne la matrice de dimension  $K \times p$  regroupant les centres de gravité.

Chaque observation d'étalonnage  $s$ , ligne de la matrice  $S$ , est attribuée à la classe  $k$  si sa distance euclidienne au groupe  $k$  dans l'espace de l'analyse discriminante, est la plus petite. Cette distance est définie par :

$$(s - j_k)T(s - j_k)$$

Les observations test sont d'abord projetées dans l'espace factoriel, et affectées aux groupes les plus proches. L'inconvénient majeur de l'analyse factorielle discriminante est que la diagonalisation de  $V^{-1}B$  n'est pas toujours possible car cette matrice peut être de rang incomplet.

### 1.2.3. Analyse discriminante PLS.

La régression PLS (Tenenhaus 1998) (*partial least squares*, moindres carrés partiels) est une méthode de régression qui a reçue de très nombreuses applications pratiques, notamment en spectroscopie, dans les problèmes d'étalonnages de spectromètres et d'autres instruments de mesure. Cette méthode a comme objectif de créer un modèle linéaire permettant d'estimer une ou plusieurs variables  $y$  connaissant une matrice de données prédictives. Soit une matrice de données prédictives  $X$  de dimension  $n \times p$  et une matrice de  $K$  variables  $Y$  de dimension  $n \times K$ . Un modèle de régression s'écrit :

$$\hat{Y} = XB$$

avec  $\hat{Y}$  a matrice  $n \times K$  des valeurs estimées de  $Y$ ,  $B$  la matrice  $p \times K$  des coefficients de régression, à estimer à partir de  $X$  et de  $Y$ .

On cherche évidemment à trouver des valeurs de  $B$  qui « prédisent au mieux » l'ensemble des variables de  $Y$ .

Lorsque les coefficients  $B$  ont été déterminés, on peut appliquer le modèle sur un jeu de données pour lesquelles les valeurs de  $Y$  sont inconnues.

La régression PLS procède en deux étapes. Dans la première étape, d'une manière comparable à l'ACP, elle permet de définir des coordonnées factorielles (ou « scores ») notées  $T$  plus

appropriées que les données prédictives de départ. Les scores de PLS sont des combinaisons linéaires des variables d'origine :

$$\mathbf{T} = \mathbf{XP}$$

avec  $\mathbf{P}$ , une matrice dimensionnée  $n \times q$  appelée matrice des « *loadings* ». Ces loadings sont les homologues des vecteurs propres de l'ACP.  $q$  est une valeur à déterminer, la *dimension* du modèle PLS.

Le modèle de régression linéaire multiple est ensuite appliqué sur  $\mathbf{T}$  à la place de  $\mathbf{X}$ , soit :

$$\hat{\mathbf{Y}} = \mathbf{TB}$$

Dans le cas de l'analyse discriminante PLS (Chevallier et al. 2006), on procède d'une manière très voisine. Mais dans cette analyse, les variables  $\mathbf{Y}$  sont les *indicatrices* des groupes qualitatifs. Pour une observation donnée appartenant au groupe d'indice  $k$ , les indicatrices, formant un vecteur  $\mathbf{y}$  à  $K$  éléments prennent la valeur 0, excepté pour l'élément d'indice  $k$  qui prend la valeur 1. Ces indicatrices sont regroupées dans la matrice  $\mathbf{Y}$  dimensionnée  $n \times K$ . En appliquant la régression PLS, on détermine une matrice de scores  $\mathbf{T}$  comme précédemment. L'analyse discriminante linéaire simple est ensuite appliquée en prenant  $\mathbf{T}$  comme matrice de données prédictives.

$$d_e^2(\mathbf{t}_x, \boldsymbol{\mu}_r) = (\mathbf{t}_x - \boldsymbol{\mu}_r)^t \boldsymbol{\Sigma}^{-1} (\mathbf{t}_x - \boldsymbol{\mu}_r),$$

avec  $\boldsymbol{\Sigma}$  la matrice de variance covariance globale.

Le calcul de  $\mathbf{T}$  repose sur un critère lié à la maximisation de la covariance entre  $\mathbf{X}$  et  $\mathbf{Y}$ . Pour pouvoir expliquer l'algorithme itératif, nous donnons l'indice 0 au matrices  $\mathbf{X}$  et  $\mathbf{Y}$

On recherche *deux* combinaisons linéaires, associées l'une à  $\mathbf{X}_0$  et l'autre à  $\mathbf{Y}_0$ , de la forme :

$$\mathbf{t}_1 = \mathbf{X}_0 \mathbf{p}_1 \quad \text{et} \quad \mathbf{u}_1 = \mathbf{Y}_0 \mathbf{r}_1$$

$\mathbf{p}_1$  et  $\mathbf{u}_1$  sont de normes unitaires et définis de telles sortes que la covariance entre  $\mathbf{t}_1$  et  $\mathbf{u}_1$  soit maximale.

On « déflationne » ensuite les matrices  $\mathbf{X}_0$  et  $\mathbf{Y}_0$  de manière à déterminer de nouvelles matrices  $\mathbf{X}_1$  et  $\mathbf{Y}_1$  orthogonales à  $\mathbf{t}_1$  (le vecteur  $\mathbf{u}_1$  n'est pas utilisé dans la suite).

Déflation de  $X_0$  : 
$$X_1 = X_0 - t_1 p_1^T,$$

Déflation de  $Y_0$  :

On calcule tout d'abord le vecteur  $c$ , défini par  $c = \frac{Y_0^t t_0}{t_0^t t_0}$

Puis

$$Y_1 = Y_0 - t_1 c^t$$

Ces formules indiquent que les matrices  $X_1$  et  $Y_1$  sont les résidus de la prédiction des colonnes de  $X_0$  et de  $Y_0$  par régression linéaire simple avec  $t_1$  comme variable prédictive.

$X_1$  et  $Y_1$  remplacent  $X_0$  et  $Y_0$  et le processus est réitéré un certain nombre de fois. Le nombre d'itérations correspond aux dimensions du modèle PLS, qui est à déterminer expérimentalement. Nous indiquerons dans la partie « Résultats » la procédure que nous avons retenue pour définir le nombre de dimensions.

#### 1.2.4. Réseaux de neurones probabilistes.

Nous avons présenté dans la section précédente les différentes méthodes de discrimination de type linéaire. L'une des méthodes les plus utilisées dans le domaine de la discrimination non linéaire est le réseau de neurones multicouches (RNM, Dreyfus, et al. 2004). Cet algorithme dit « neuromimétique » est défini par le nombre de couches, de neurones et la fonction d'activation (généralement une sigmoïde) qui le compose. Il nécessite cependant de longues heures de traitement pour obtenir un modèle candidat dont l'analyse et le comportement sont difficilement interprétable. Un autre désavantage de la méthode utilisant les réseaux de neurones est que l'initialisation est généralement aléatoire ce qui a pour effet de ne jamais avoir un réseau identique à chaque apprentissage sur les mêmes données d'étalonnage. La méthode utilisant des *réseaux de neurones probabilistes* (RNP) nous paraît plus simple et conduit à des résultats plus faciles à interpréter. Les essais de Chtioui, (1997) ont montré leur intérêt dans un problème de classification de semences. De manière générale, les RNP utilisent une approche dérivée de la théorie Bayésienne.

Soit une base de données composée d'observations décrites par  $p$  variables appartenant à  $K$  classes. Nous définirons  $h_i$  comme la probabilité *a priori* d'appartenir à une classe  $i$ . Le

critère du maximum de vraisemblance consiste à classer une observation dans le groupe pour lequel sa probabilité d'appartenance est la plus élevée. (Note : Pour des raisons de clarté, nous redonnons quelques formules déjà présentées au paragraphe 1.2.1 avec une notation différente)

$$p(c = c_i/x) = \max(p(c = c_j/x)) \text{ pour } j=1, 2, \dots, k$$

où  $p(c = c_i/x)$  représente la probabilité conditionnelle d'appartenir à la classe  $i$  sachant  $x$ .

Le théorème de Bayes donne :

$$p(c = c_i/x) = \frac{h_i f(x / c = c_i)}{\sum_{j=1}^k h_j f(x / c = c_j)}$$

avec  $f(x/c = c_i)$ , la fonction de densité de probabilité (FDP) associée à la classe  $i$  et  $h_i$  la probabilité *a priori* qu'a une observation d'appartenir à la classe  $i$ .

A partir des deux équations précédentes la règle de décision peut être reformulée de la manière suivante :

$$h_i f(x / c = c_i) = \max h_j f(x / c = c_j) \text{ pour } j=1, 2, \dots, k$$

Le problème principal est donc d'estimer les FDP à partir des données d'étalonnage. Dans le cas des RNP, l'estimation de la FDP est réalisée par une sommation portant sur des fonctions de noyaux de Parzen.

La FDP de  $x$  associé à la classe  $j$  est estimée par:

$$f(x / c = c_j) = \frac{1}{n_j} \sum_{i=1}^n W(d_{x, x_i \in c_j}, \sigma)$$

Où  $\sigma$  : est un paramètre de lissage,  $W$  la fonction de noyau et  $d_{x, x_i \in c_j}$  la distance entre l'observation d'étalonnage  $x_i$  et  $x$ .

Pour être cohérente, la fonction  $W$  doit prendre sa valeur maximale quand la distance  $d_{x, x_i \in c_j}$  est nulle et décroît rapidement avec la distance.

Une fonction de noyau très couramment utilisée est le noyau Gaussien définie par :

$$w_i e^{-\frac{d_{x, x_i \in c_j}^2}{\sigma}}$$

où  $w_i$  est un poids associé à ce noyau. Dans de nombreuses études, on a donné la même valeur à tous les poids. Dans le présent travail, nous avons fixé  $\sigma$  expérimentalement à la même valeur pour tous les noyaux, mais nous avons cherché à donner des valeurs différentes aux poids  $w_i$ . Le poids  $w_i$  du noyau indique la « confiance » que nous avons dans l'observation d'étalonnage  $x_i$ .

L'algorithme est le suivant :

- **Etape initiale : ajustement de  $\sigma$**

Le gain  $g$  est initialisé à une valeur légèrement supérieure à 1, tandis que  $\sigma$  est initialisé à une petite valeur. Toutes les observations composant la base d'étalonnage sont alors classées selon la règle du maximum de vraisemblance, en fixant  $w_i=1$  pour tous les noyaux. La proportion d'observations bien classées est alors déterminée et mémorisée. La valeur de  $\sigma$  est ensuite augmentée selon  $\sigma \leftarrow g\sigma$ .

Parmi toutes les valeurs testées, la valeur de  $\sigma$  donnant le meilleur pourcentage de classification est alors sélectionnée.

- **Ajustement individuel du poids des noyaux**

Une fois le facteur de lissage  $\sigma$  ajusté, une des manières pour accroître le rôle d'un noyau utile ou pour réduire celui d'un noyau nuisible à la classification est de modifier individuellement les poids. Les poids sont initialisés à la valeur 1. Nous définissons un facteur de réduction  $l$  dont la valeur est positive et inférieure à 1. Un vecteur  $h$  ayant le même nombre d'éléments que le nombre d'observations dans la collection d'étalonnage est initialisé à la valeur 0 pour tous ces éléments. Ce vecteur nous permet de caractériser la « contre-performance » de chaque noyau. Nous initialisons de même un vecteur de même longueur que  $h$ . Ce vecteur nous servira à caractériser la « bonne performance » de chaque noyau.

Nous appliquons la règle suivante :

Toutes les observations du jeu-test sont classées avec les fonctions de noyau en cours. Si une observation-test est bien classée,  $h$  n'est pas modifié. Considérons le cas de la mauvaise classification dans lequel une observation  $x$  appartenant réellement à la classe  $a$  a été erronément classée dans la classe  $b$ . On recherche l'observation d'étalonnage, plus proche voisin de  $x$ , appartenant à la classe  $b$ . Soit  $x_i$  cette observation, qui a le plus contribué à

l'erreur de classification. La valeur  $h_i$  est incrémentée de 1. A la fin de la classification, les valeurs élevées de  $\mathbf{h}$  correspondent aux noyaux conduisant à des erreurs de classification. Soit  $h_j$  la valeur maximale de  $\mathbf{h}$ . Le poids du noyau  $j$  est réduit selon  $w_j \leftarrow l w_j$ . Une procédure similaire peut être appliquée pour augmenter l'apport des observations contribuant le plus à une bonne classification des observations. Toujours sur le même exemple de mauvaise classification, on recherche l'observation d'étalonnage, plus proche voisin de  $\mathbf{x}$ , appartenant à la classe  $a$ . Le poids de cette observation devrait être augmenté. Soit  $\mathbf{x}_i$  cette observation. C'est l'observation qui permettrait le plus de réduire l'erreur de classification. La valeur  $q_i$  est incrémentée de 1. A la fin de la classification, les valeurs élevées de  $\mathbf{q}$  correspondent aux noyaux les plus susceptibles de réduire les erreurs de classification. Soit  $q_j$  la valeur maximale de  $\mathbf{q}$ . Le poids du noyau  $j$  est augmenté selon  $w_j \leftarrow \frac{l}{w_j}$ .

On arrête l'algorithme lorsque la modification des poids ne conduit plus à une réduction du taux d'erreurs de classification.

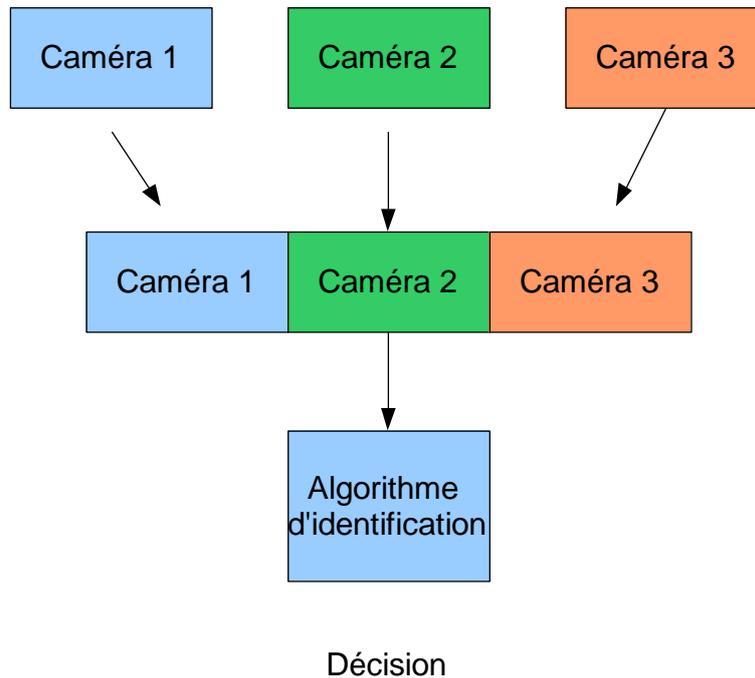
### 1.3. Stratégies de prise de décision dans le cas d'un système tri-caméras.

Le système de vision que nous avons construit comprend trois caméras qui permettent d'acquérir indépendamment trois images numériques du même objet. Pour une collection de semences données, nous disposons finalement de trois tableaux de caractéristiques de même taille. Il est nécessaire de définir des stratégies de prise de décision adaptées à une telle situation. Il existe de nombreuses méthodes permettant de prendre une décision en combinant les résultats issus de plusieurs algorithmes d'identification (Kuncheva 2004). Nous présenterons dans cette section les différentes stratégies que nous avons testées. L'étude de ces stratégies, nous permettra de choisir les algorithmes et l'architecture électronique les plus appropriés pour la réalisation d'un système embarqué.

La stratégie de prise de décision comprend deux éléments portant sur l'*organisation des données* et sur les *règles d'affectation* des observations.

Soit  $\mathbf{X}^{(1)}$ ,  $\mathbf{X}^{(2)}$ ,  $\mathbf{X}^{(3)}$  les tableaux de caractéristiques, ayant chacun le même nombre de ligne  $n$  et le même nombre de colonnes  $p$ . Une première stratégie, la plus simple, consiste à concaténer les données dans le sens des variables (Figure 3.2). On forme le tableau  $\mathbf{Z}=[\mathbf{X}^{(1)}|\mathbf{X}^{(2)}|\mathbf{X}^{(3)}]$  de

dimension  $n \times (3p)$  sur lequel portent les analyses discriminantes (structure *de concaténation des caméras selon les colonnes*, désignée par « *CONCATCOL* »).



**Figure 3.2 : Modèle par concaténation des données selon les colonnes**

Une deuxième approche consiste à considérer que les caractéristiques mesurées avec chacune des caméras soient des répétitions. On ne tient pas compte ici des différences entre caméras, et on cherche à trouver un modèle discriminant commun *unique* qui convienne pour les trois caméras. Les données sont alors concaténées selon les lignes (Figure 3.3). Le tableau concaténé  $\mathbf{Z}$ , de dimension  $(3n) \times p$  prend alors la forme :

$$\mathbf{Z} = \begin{bmatrix} \mathbf{X}^{(1)} \\ \mathbf{X}^{(2)} \\ \mathbf{X}^{(3)} \end{bmatrix}$$

C'est la structure *de concaténation des caméras selon les lignes* désignée par « *CONCATLIG* ». L'intérêt de cette méthode est qu'elle est capable de prendre en compte la variabilité issue des différentes prises de vues et de déterminer le meilleur espace de classification commun à toutes les caméras. Si les résultats de cette méthode étaient satisfaisants, on pourrait en conclure qu'il existe un algorithme d'identification capable de prendre en compte la variabilité induite par les données biologiques mais également par les caméras.

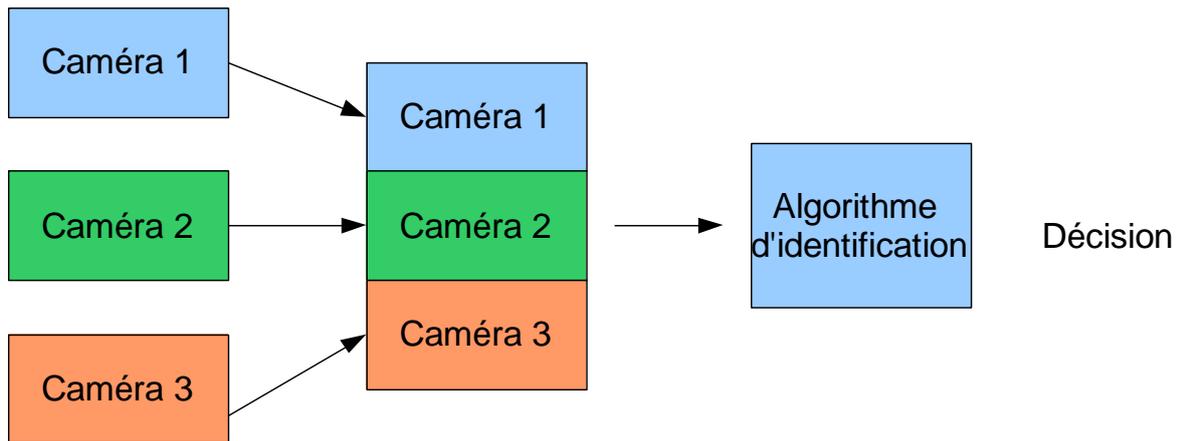


Figure 3.3 : Modèle par concaténation selon les lignes.

Il faut noter que cette organisation nous donne une affectation pour une même semence, pour chacune des « répétitions ». Enfin, une dernière stratégie d'organisation des données (Figure 3.4) consiste, contrairement à la précédente, à considérer que les trois caméras sont des instruments de mesure différents. Les modèles discriminants sont alors établis indépendamment sur chacun des tableaux. (Structure de *tableaux séparés*, notée *SEPARE*).

Algorithme de  
décision par  
caméra

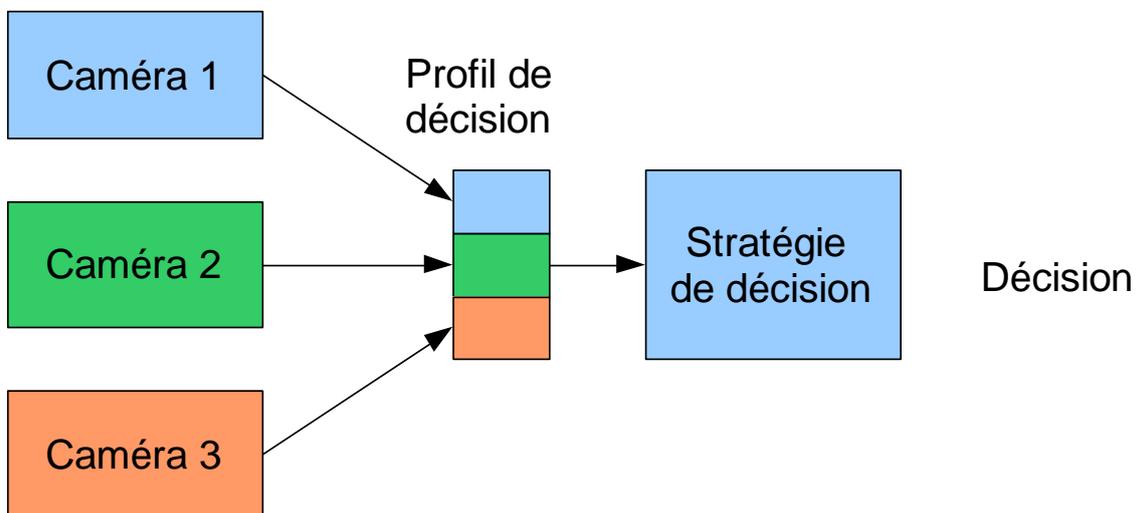


Figure 3.4 : Modèle portant sur des tableaux séparés.

- Règle d'affectation

L'utilisation des structures *CONCATLIG* et *SEPARE* conduit à trois valeurs d'affectation possibles pour un objet étudié. Il peut y avoir une concordance complète (les caractéristiques mesurées avec les trois caméras conduisent à affecter l'objet dans le même groupe qualitatif)

ou désaccord entre les affectations. Il est alors nécessaire de définir des règles d'affectation particulières, sous la forme de *vote*. On considère que les affectations obtenues à partir de chaque tableau sont des votes. Dans la règle d'affectation « majoritaire » (*MAJORITAIRE*) l'observation est classée comme appartenant à la classe donnant le maximum de votes en sa faveur. Dans la règle d'affectation unanime (*UNANIME*) l'observation  $i$  est classée dans une classe s'il y a unanimité des votes. Dans le cas contraire, l'objet est affecté à une *classe de rejet*.

Dans le cas des méthodes de classification utilisant des méthodes de vote, il est possible de créer facilement une classe rejet. Contrairement aux applications utilisant la classe de rejet comme étant des observations dont les profils de décision sont inférieures à un seuil fixé, dans notre application la classe de rejet revient à identifier une indétermination de classification liée au fait que les votants ne permettent pas de répondre au profil de stratégie définie. Par exemple, la classe de rejet, dans le cas d'une stratégie de décision par vote majoritaire, est représentée par les observations pour lesquelles au moins deux « classifieur » ne sont pas du même avis. Dans le cas d'un vote unanime si les trois « classifieurs » ne sont pas du même avis alors l'observation est rejetée. Dans ces conditions, il est difficile de pouvoir mettre en place une matrice de confusion qui serait liée de part sa construction à une matrice d'occurrence définie par le couple groupe prédit et groupe réel.

#### 1.4. Méthodes de validation.

Les méthodes de validation des analyses discriminantes nécessitent l'utilisation d'une base de données servant pour l'*apprentissage* (ou « étalonnage ») d'une part et d'une autre pour la *validation*. Les données d'étalonnage nous permettent de créer des modèles prédictifs discriminants, qui sont ensuite testés sur le jeu de validation. Dans de nombreuses situations, les jeux d'étalonnage et de validation sont créés en sélectionnant des observations dans la collection de données dont on dispose. Nous présentons ici quelques méthodes couramment utilisées dans ce cas (qui est celui qui s'applique à notre étude).

- *Méthode de rééchantillonnage (Bootstrap) :*

Supposons que l'on dispose de  $n$  observations. Dans cette méthode, on construit un *unique* jeu de données en tirant au sort, *avec remise*,  $n$  observations dans la collection complète. La procédure est répétée un grand nombre de fois et des statistiques appropriées (concernant, par exemple, la distribution des erreurs) peuvent être calculées. Bien que fondée sur le plan

statistique, cette méthode paraît contraire à la logique puisqu'elle aboutit à avoir les mêmes observations pour créer le même modèle. De plus, des essais expérimentaux montrent qu'elle conduit à des résultats trop « optimistes ». Elle est assez peu appliquée en pratique.

- *Méthodes de validation croisée par segment et « Leave one out » :*

Dans cette méthode, la collection est divisée en  $\nu$  différents segments comportant un nombre égal d'observations. A chacune des  $\nu$  essais, un segment est pris comme collection de validation, tandis que le reste de la collection compose le jeu d'étalonnage. L'erreur finale est alors estimée en faisant la moyenne des  $\nu$  taux d'erreurs obtenus. La méthode *Leave-one-out* (« retirer un à la fois ») consiste à appliquer cette méthode en ne plaçant qu'une seule observation dans le jeu de validation.  $\nu$  est alors égal à  $n$ , le nombre d'observations de la collection. Cette méthode est évidemment longue à mettre en œuvre et ne peut s'appliquer que sur des jeux de données ne comportant qu'un petit nombre d'observations. Des essais expérimentaux semblent montrer qu'elle conduit à des résultats trop optimistes également.

- *Méthode sans remise (Hold out) :*

Cette méthode distingue l'ensemble d'apprentissage et l'ensemble de validation. Les observations formant le jeu de validation sont tirées au sort, *sans remise*, dans la collection disponible. L'échantillon de test permet alors de donner une probabilité d'erreurs puisqu'on peut étudier combien d'erreurs ont été commises par le « classifieur ». Si l'ensemble de test est de taille  $m$  et que le « classifieur » étudié commet  $r$  erreurs de classement sur cet ensemble, alors la proportion d'erreurs estimée est:

$$\hat{E} = \frac{r}{m}$$

Cette procédure de validation peut être répétée plusieurs fois de suite. On estime la qualité du « classifieur » par la moyenne et l'écart type de la proportion d'erreurs obtenue dans les différents essais. C'est cette méthode que nous avons retenue.

## 2. Partie expérimentale

### 2.1. Matériels et méthodes.

- *Nature des données*

L'étude porte sur les 1617 semences dont les images ont été prises par chacune des trois caméras, constituant ainsi une base de 4851 images numériques. Cette collection a déjà été décrite dans le chapitre 1. Elle comprend 11 espèces habituellement présentes dans les lots certifiés de tournesol auxquelles s'ajoutent deux catégories correspondant aux amandes et aux semences cassées de tournesol.

- *Sélection de variables.*

Les caractéristiques des semences extraites des images forment un ensemble de 271 variables pour chaque caméra. Nous avons vu dans le chapitre 2, avec l'analyse descriptive, que certaines de ces variables n'étaient pas porteuses d'information. Il apparaît donc nécessaire de réduire la base de données aux seules caractéristiques présentant un intérêt pour la discrimination, à la fois pour réduire le temps de calcul des algorithmes et pour éliminer le bruit qui serait introduit par des variables non pertinentes.

Quelle que soit la structure de données étudiée (*CONCATLIG*, *CONCATCOL* ou *SEPARE*, définie précédemment), nous avons sélectionné les variables pour toutes les méthodes de discrimination testées par l'analyse discriminante linéaire montante (*forward*). Cette méthode consiste à introduire les unes après les autres les variables les plus discriminantes sur la base du taux d'observations correctement classées à chaque itération. La procédure itérative est arrêtée lorsque l'ajout d'une variable supplémentaire ne se traduit plus par l'augmentation de ce taux.

Une fois cette sélection effectuée, nous appliquons l'ensemble des algorithmes testés à cette base réduite.

- *Méthode de validation.*

Nous avons vu dans la partie précédente qu'il existait quatre grandes méthodes pour l'estimation de la performance d'un système d'identification. Dans l'étude réalisée par Majumdar et Jayas, (2000), il a été montré que l'utilisation de la méthode par validation croisée par segment et celle de l'échantillon test dans le cas de discrimination linéaire à haute dimension ne présentait pas de différence significative pour sélectionner une méthode plutôt

qu'une autre. Nous préférons pour des raisons de simplicité utiliser la méthode de validation reposant sur la méthode de l'échantillon test.

Pour chaque essai, un tiers des observations sont placées dans le jeu de validation, les autres observations faisant partie de la collection d'apprentissage. Cette procédure est répétée 20 fois. Tous les résultats donnés dans la suite sont les moyennes de 20 valeurs obtenues sur les jeux de validation. Dans chacun de ces essais, les observations sont toujours sélectionnées aléatoirement dans la totalité de la base de données.

- *Comparaison des méthodes de discrimination*

Dans tous les essais, nous avons appliqué une approche systématique qui consiste tout d'abord à sélectionner des variables discriminantes par ADL pas à pas. Sur la matrice réduite aux seules variables sélectionnées, nous avons appliqué plusieurs méthodes de discrimination : l'analyse factorielle discriminante (AFD), l'analyse discriminante PLS (PLSDA), l'analyse discriminante linéaire (ADL), réseau de neurones probabilistes (RNP).

## **2.2. Résultats et discussions.**

Dans la partie précédente, nous vous avons présenté les différentes méthodes de classification et les différentes stratégies de décision. Dans cette partie, nous vous présenterons les différents résultats obtenues avec ces différentes méthodes. Le système présenté au chapitre 1 étant différent du système ayant servi pour les travaux préliminaires (Plainchault, et al. 2003) et des évolutions (Muracciole, et al. 2007), nous reprendrons tout d'abord des essais avec un système mono-caméra fondé sur la nouvelle organisation d'acquisition. Nous étudierons ensuite les différentes stratégies de décision quant à l'utilisation d'un système utilisant trois caméras.

### **2.2.1. Modèle mono-caméra**

Le système que nous avons réalisé comporte trois caméras. Il nous apparaît donc important d'évaluer l'avantage que peut présenter un système à trois caméras en comparaison avec un système mono-caméra. Une telle étude, nous permet également d'identifier plus facilement l'ensemble des variables qui possèdent un pouvoir discriminant.

De manière théorique, le choix de la caméra pour mener l'étude mono-caméra n'a pas d'importance. Cependant l'étude montre que parmi les caméras prises une à une, les caméras B et C sont semblables en terme de performance de classification. La caméra A montre une

efficacité de classification légèrement moindre mais toujours bonne avec cependant une plus grande variabilité. Cette différence n'est pas due à l'effet caméra que l'on a pu constater au chapitre 1 ; elle provient du mécanisme d'introduction. En effet, ce mécanisme étant un bol vibrant la succession de petites et brèves vibrations a pour conséquence de mettre les semences toujours de la même façon sur leur position d'équilibre. Cela introduit un biais dans la présentation des semences devant le système d'acquisition. La caméra A étant orientée et disposée de façon parallèle au mécanisme d'introduction, il est probable que dans le cas de semences cassées l'information ne soit pas optimale comme pour les caméras B et C qui présentent elles des résultats similaires.

Pour la suite de l'étude mono-caméra nous avons sélectionné la caméra 3.

Rang	Variable	Pourcentage d'identification	Rang	Variable	Pourcentage d'identification
1	6gray-mean	39,18	14	8occur-corr	90,26
2	sigma_r	78,36	15	3gray-energy1	91,46
3	1occur-sd-ang-m	79,09	16	Maxim_radius	91,73
4	1occur-corr	81,67	17	3gray-mean	92
5	9gray-mean	82,68	18	6occur-row-std	92,09
6	6run-length-distribution	85,45	19	1gray-energy1	91,36
7	Thinness_ratio	84,35	20	5gray-entropy	92
8	mu_r	87,39	21	1gray-entropy	92,18
9	Haralick	87,21	22	3gray-entropy	92,82
10	2occur-sd-ang-m	86,94	23	9occur-col-std	92,55
11	MajorAxisLength	88,69	24	8gray-entropy	92,64
12	5gray-variance	89,52	25	7run-length-distribution	92,46
13	MinorAxisLength	88,88			

*Tableau 3.1 : Variables sélectionnées automatiquement sur la caméra C*

L'analyse discriminante linéaire, nous a permis de retenir vingt-cinq variables discriminantes (Tableau 3.1). Nous constatons ainsi que le premier paramètre caractérisant la couleur moyenne de la composante, couleur Cb, classe à hauteur de 39%. L'apport de l'écart-type des distances de rayon est de 39% également. Il apparaît donc qu'avec ces deux premiers paramètres caractéristiques, l'algorithme est capable de discriminer environ plus des deux tiers des semences. Au vu des résultats, l'injection successive des caractéristiques marque un plateau. L'ajout des caractéristiques suivantes jusqu'à la quinzième caractéristique est en moyenne de 1,5%. Ceci n'est pas négligeable puisqu'au total, c'est plus de 15% de pourcentage de classification gagné. On remarque également que sur la caméra 3, les paramètres de calibre, de couleur et de texture sont tous utilisés. En revanche, les paramètres décrivant le contour et les moments ne sont pas présents. Ceci est en accord avec les résultats présentés par l'analyse descriptive dans le chapitre 2. Les paramètres de calibre principalement sélectionnés sont des paramètres liés à la forme globale de la semence, tels que l'axe majeur, l'axe mineur et ce qui a trait aux dimensions des rayons décrivant le contour de la semence. On remarque également que les paramètres de texture et donc de caractérisation des répartitions des teintes sont également bien représentés. En ce qui concerne les espaces de couleur, ils sont tous représentés dans les variables sélectionnées. L'utilisation de ces neuf canaux de couleur est donc porteuse d'information.

Algorithme de classification	Pourcentage de classification moyen	Ecart type
AFD	83,06	1,50
PLSDA	84,87	1,20
ADL	91,14	1,31
RNP	93,38	1,17

*Tableau 3.2: Pourcentage de classification sur la caméra C*

Les résultats obtenus sur le système mono-caméras montrent qu'il est possible de discriminer les semences avec un pourcentage compris entre 83 et 92% (Tableau 3.2). La moins bonne classification est réalisée par l'analyse factorielle discriminante avec une moyenne de 83% de bonne classification et une variabilité de 1,5%. PLSDA est plus performant qu'AFD à discriminer les semences. On remarque que les méthodes basées sur la discrimination selon des sous-espaces, tenant compte des données brutes, ne sont pas efficaces dans ce cas de

figure. Les deux algorithmes utilisant directement les méthodes de discrimination sur les données brutes montrent une capacité à discriminer les semences à plus de 90%. Ces deux méthodes utilisent deux types de discrimination, l'analyse discriminante linéaire comme son nom l'indique discrimine les semences par un hyperplan séparateur et les RNP est une méthode à base de noyaux probabilistes réalisant une séparation non linéaire dans l'espace des données. Nous remarquons que la différence entre la méthode non linéaire et la méthode linéaire n'est que de 1 % en moyenne. Nous constatons sur le tTableau 3.3, que ces différents algorithmes sont stables par rapport aux données.

	Af	Am	Bv	Cs	Hv	Lc	Pi	Td	Gl	Ma	Sc	Ta	To
Af	19	0	1	0	1	1	0	2	0	0	0	0	0
Am	0	27	0	0	0	0	0	0	0	0	0	0	0
Bv	0	0	31	0	3	0	0	0	0	0	0	0	0
Cs	0	0	0	33	0	11	0	0	0	0	1	0	0
Hv	0	0	3	0	30	0	0	0	0	0	0	0	0
Lc	0	0	0	12	0	20	0	0	0	0	2	0	0
Pi	0	0	0	0	0	0	50	1	0	0	0	0	0
Td	0	0	0	0	0	0	0	33	0	0	0	0	1
Gl	0	0	0	0	1	0	0	0	53	0	0	0	0
Ma	0	0	0	0	1	0	0	0	0	56	0	0	0
Sc	0	0	0	1	0	0	0	1	0	0	48	0	6
Ta	0	0	0	0	0	0	0	0	0	0	0	33	0
To	0	0	0	0	0	0	0	0	0	0	5	0	48

*Tableau 3.3 : Matrice de confusion obtenue sur ADL de la caméra 3*

Afin de mieux comprendre le comportement de ces différents algorithmes de discrimination, nous allons étudier la matrice de confusion de l'ADL (Tableau 3.3). La matrice de confusion permet de montrer les erreurs de classification. Nous allons décrire la lecture de la matrice de confusion par un exemple, la betterave. La betterave (Bv) a été classée en tant que semence d'orge (code Hv) 3 fois. On remarque également qu'une semence de folle avoine a été classée comme une semence de betterave. La colonne Bv représente la classification des semences de betterave et de quelques autres comme étant des betteraves. On constate ainsi qu'une semence de folle avoine et trois semences d'orge ont été classées dans la catégorie des betteraves. Nous constatons dans le Tableau 3.3 que des erreurs de classification importantes et croisées sont nombreuses entre les lentilles et les liserons des haies. Ceci est principalement dû au fait que

les semences sont sombres et de calibres proches. Par conséquent, un système mono-caméra en chute libre n'est sûrement pas capable de distinguer à coup sûr de telles espèces. Le système d'acquisition introduit également des possibilités d'erreurs de classification sur les semences de tournesol cassées car elles ne présentent pas forcément la face indemne de cassure. Ceci se traduit généralement par une classification en tournesol comme si elles n'avaient aucun défaut. Une autre catégorie pouvant soulever des problèmes est celle des sclérotés qui, en plus de la variabilité liée à la chute libre, introduit une variabilité morphologique des sclérotés elles-mêmes, amenant à des erreurs de classification entre elles et les semences de tournesol. Ce problème est visible sur le Tableau 3.3 où 6 sclérotés ont été classés en tant que tournesol, tandis qu'une a été classée en tournesol abîmé. C'est également le cas des tournesols purs qui sont classés en tant que sclérotés, d'où 5 cas dans la ligne To et la colonne Sc, et aussi 6 cas dans la ligne Sc et la colonne To. Cette dernière erreur de classification est particulièrement dommageable car cela veut dire que le système mono-caméra n'est pas capable de répondre aux contraintes de certification liées aux lots de tournesol, car les deux espèces où le système ne doit pas commettre d'erreur sont précisément la folle avoine et les sclérotés. On peut remarquer que dans ces conditions d'éclairage et de fonctionnement, certaines espèces peuvent être très bien identifiées. C'est le cas avec un fort taux de séparation, telles que le pois, le maïs, le soja, le blé tendre et les amandes de tournesol.

## 2.2.2. Modèle multi-caméra avec concaténation des variables

Rang	variable	Pourcentage d'identification	rang	variable	Pourcentage d'identification
1	Amu_r	42,05	14	C3occur-sd-ang-m	93,28
2	AHaralick	53,32	15	B2gray-energy1	93,19
3	C6gray-mean	74,57	16	C3gray-entropy	93,28
4	C1occur-sd-ang-m	74,93	17	A7gray-entropy	93,83
5	BMaxim_radius	77,97	18	A5gray-mean	93,92
6	C9gray-mean	79,26	19	A6gray-mean	94,01
7	AMaxim_radiu	80,46	20	Asigma_r	95,02
8	B5gray-entropy	85,35	21	CWidth	95,11
9	B4gray-entropy	87,66	22	BAspectRatio	95,66
10	AMajorAxisLength	90,06	23	A1gray-entropy	95,48
11	C8gray-skewness	89,88	24	B7gray-skewness	95,75
12	A7gray-mean	91,26	25	CHaralick	96,11
13	A8occur-col-std	93,1			

**Tableau 3.4 : Sélection des 25 variables les plus discriminantes sur CONCATCOL**

Dans cette partie, nous allons étudier l'organisation des données issues d'un système multi-caméra par concaténation des variables. Cela signifie que nous utilisons un algorithme de sélection des variables de la même manière que pour un système mono-caméra. Il s'agit de déterminer si le fait de considérer que les caméras apportent des caractérisations selon trois angles pour une seule observation est viable pour la discrimination des semences. L'architecture issue de ce fonctionnement n'est pas foncièrement différente du fonctionnement d'un système mono-caméra. La sélection des variables appliquées à cette organisation pourra donc déterminer le meilleur compromis discriminant des variables caractérisées par les différentes caméras (Tableau 3.4). Dans ce cas de figure, on remarque

que les deux premières caractéristiques les plus discriminantes sont des paramètres de calibre qui sont liés à un facteur près. En effet, ces deux premiers paramètres sont non seulement issus de la même caméra mais sont liés également par une formule mathématique (cf chapitre 2), ils représentent 53% de la discrimination. Le premier définit la moyenne des rayons caractérisant la semence, et le second est le rapport d'Haralick caractérisant le rapport entre la moyenne des rayons et son écart-type.

Le troisième paramètre sélectionné décrit la moyenne de la couleur. Ce paramètre est issu de la caméra numéro 3. De manière générale, on remarque que les différents paramètres sélectionnés sont effectivement des combinaisons issues des différentes caméras.

La morphologie joue encore un grand rôle dans la discrimination de ces espèces de calibres différents. Nous remarquerons aussi que les paramètres de contour et de moment ne sont pas discriminants. Nous pouvons constater que dans cette sélection, très peu de paramètres décrivant la texture des semences entrent en ligne de compte. Ils ont un apport très faible, par exemple le paramètre de rang 4 dont l'apport de discrimination n'est que de 0.36%. Cela dit, il faut bien être conscient que s'il a été sélectionné, c'est que son apport à ce moment-là était supérieur à ceux qui sont classés dans des rangs plus lointains. Il est difficile d'envisager ce qu'auraient été les performances des paramètres suivants s'ils n'avaient pas fait partie des paramètres discriminants qui les précèdent.

Algorithme de classification	Pourcentage de classification moyen	Ecart type
AFD	96,49	0,67
PLSDA	96,79	0,73
ADL	95,85	0,71
RNP	95,46	0,82

*Tableau 3.5 : Pourcentage de classification obtenue sur CONCATCOL*

Les algorithmes d'identification appliqués sur cette organisation des données montrent une capacité d'identification comprise entre 95,4 et 96,8%. Ces résultats sont très bons et montrent toute l'efficacité du passage à un système à trois caméras. En effet, nous sommes passés de 90% pour le système mono-caméra présenté précédemment à 95%, sur la même base d'espèces. Contrairement aux cas précédent mono-caméra, les méthodes utilisant des sous-espaces de données tenant compte de l'ensemble des variables tels que l'AFD et le PLSDA montrent une meilleure capacité de classification. Cela tient au fait de leur

fonctionnement et surtout de l'intérêt d'utiliser un sous-espace de données permettant de compresser les données. L'écart-type inférieur à 1% montre une grande stabilité sur ces données de la décision.

	Af	Am	Bv	Cs	Hv	Lc	Pi	Td	Gl	Ma	Sc	Ta	To
Af	23	0	1	0	0	0	0	0	0	0	0	0	0
Am	0	27	0	0	0	0	0	0	0	0	0	0	0
Bv	0	0	33	0	1	0	0	0	0	0	0	0	0
Cs	0	0	1	39	0	5	0	0	0	0	0	0	0
Hv	0	0	0	0	33	0	0	0	0	0	0	0	0
Lc	0	0	0	3	0	31	0	0	0	0	0	0	0
Pi	0	0	0	0	0	0	51	0	0	0	0	0	0
Td	0	0	0	0	0	0	0	34	0	0	0	0	0
Gl	0	0	0	0	0	0	0	1	53	0	0	0	0
Ma	0	0	0	0	0	0	0	0	0	57	0	0	0
Sc	0	0	0	0	0	0	0	0	0	0	55	0	1
Ta	0	0	0	0	0	0	0	0	0	0	0	33	0
To	0	0	0	0	0	0	0	0	0	0	2	0	51

*Tableau 3.6 : Matrice de confusion sur RNP sur CONCATCOL*

La matrice de confusion va nous montrer les différents secteurs de la discrimination qui ont été améliorés par l'ajout de deux caméras. Cette matrice est issue de la discrimination faite par l'algorithme PLSDA qui est l'algorithme offrant la meilleure discrimination. Une étude des autres matrices montre qu'elles sont proches de celle-ci en termes d'erreurs de classification.

Sur le Tableau 3.6, on remarque que les principales causes d'erreur de classification demeurent. Dans notre cas, l'indétermination entre les lentilles (Lc) et les liserons des haies (Cs) demeure. Cela tient particulièrement à leur petite taille et à une forme proche. Il n'est pas impossible de penser que la résolution du capteur dans ces conditions n'est pas suffisante pour discriminer au mieux ces espèces. Cependant pour l'application sur les lots de tournesol, le simple critère morphologique est suffisant pour les séparer des lots de tournesol.

Cette organisation des données ne permet cependant pas, comme nous le montre la matrice de confusion, de séparer de façon sûre les sclérotés des semences de tournesol.

### **2.2.3. Modèle multi-caméra avec concaténation des observations**

L'intérêt principal de l'utilisation de cette méthode est de pouvoir déterminer s'il existe un modèle commun capable de pouvoir prendre en compte les particularités des différentes caméras. D'un point de vue pratique, il est également intéressant car il permet d'avoir une architecture commune aux différentes caméras. La sélection des paramètres nous permettra donc de déterminer s'il existe des caractéristiques permettant de répondre à ces différentes questions. Cette organisation permet également de pouvoir créer un système de vote majoritaire par caméra et en même temps de pouvoir rajouter une classe de rejet pour les indéterminations liées aux votes des caméras.

#### **2.2.3.1. Stratégie simple de classification**

Dans cette étude, la sélection des variables montre les différentes caractéristiques offrant le meilleur compromis en termes de caractéristiques discriminantes communes aux différentes caméras. On remarque ainsi que les trois premiers paramètres les plus discriminants sont la teinte moyenne, l'axe mineur et le rapport d'aspect. La teinte moyenne permet donc de déterminer dans le cas d'une semence sa couleur, les deux autres sont des paramètres de forme qui comme d'habitude permettent de séparer une partie importante de la base. On remarque que la couleur, la morphologie et la texture ont une part déterminante dans la discrimination et l'édition d'un modèle commun. Ceci confirme bien que ces trois catégories de caractéristiques sont importantes pour la discrimination des semences.

Dans cette étude, la sélection des variables montre les différentes caractéristiques offrant le meilleur compromis en termes de caractéristiques discriminantes communes aux différentes caméras. On remarque ainsi que les trois premiers paramètres les plus discriminants sont la teinte moyenne, l'axe mineur et le rapport d'aspect. La teinte moyenne permet donc de déterminer dans le cas d'une semence sa couleur, les deux autres sont des paramètres de forme qui comme d'habitude permettent de séparer une partie importante de la base. On remarque que la couleur, la morphologie et la texture ont une part déterminante dans la discrimination et l'édition d'un modèle commun. Ceci confirme bien que ces trois catégories de caractéristiques sont importantes pour la discrimination des semences.

rang	variable	pourcentage d'identification	rang	variable	pourcentage d'identification
1	6gray-mean	30,56	14	6gray-energy1	84,59
2	MinorAxisLength	49,13	15	5gray-variance	84,84
3	AspectRatio	58,07	16	4occur-row-std	83,58
4	1occur-corr	60,65	17	3hist-energy	84,38
5	Haralick	69,19	18	8gray-mean	84,44
6	8occur-corr	75,69	19	Area	84,99
7	5gray-entropy	78,18	20	8gray-entropy	84,87
8	4gray-entropy	79,20	21	9gray-mean	85,27
9	4occur-col-average	80,96	22	2occur-col-std	85,33
10	EquivDiameter	80,86	23	2gray-entropy	85,89
1	Maxim_radius	82,25	24	2gray-variance	86,47
12	6run-length-distribution	83,91	25	3occur-corr	86,66
13	3gray-mean	84,22			

**Tableau 3.7 : Sélection des variables sur CONCATLIG**

Dans cette étude, la sélection des variables montre les différentes caractéristiques offrant le meilleur compromis en termes de caractéristiques discriminantes communes aux différentes caméras. On remarque ainsi que les trois premiers paramètres les plus discriminants sont la teinte moyenne, l'axe mineur et le rapport d'aspect. La teinte moyenne permet donc de déterminer dans le cas d'une semence sa couleur, les deux autres sont des paramètres de forme qui comme d'habitude permettent de séparer une partie importante de la base. On remarque que la couleur, la morphologie et la texture ont une part déterminante dans la discrimination et l'édition d'un modèle commun. Ceci confirme bien que ces trois catégories de caractéristiques sont importantes pour la discrimination des semences.

Algorithme de classification	Pourcentage de classification moyen	Ecart type
AFD	85,86	0,80
PLSDA	85,86	0,80
ADL	85,86	0,80
RNP	88,39	0,72

*Tableau 3.8 : Pourcentage de classification obtenue sur CONCATLIG*

Comme on pouvait s’y attendre, la réalisation d’un modèle commun montre une difficulté dans la capacité à classer de façon efficace les différentes espèces de semences au-delà de 85-88%. Ces résultats sont en retrait par rapport à ce qu’on obtenait avec un système mono-caméra et avec les autres méthodes. On retire comme enseignement qu’il existe un compromis permettant de séparer plus de 85% des espèces avec un modèle unique. On remarque dans ce cas-là que l’algorithme de séparation non linéaire obtient le meilleur résultat, avec 6% de mieux que les autres. Cependant, les algorithmes linéaires permettent tout de même de classer plus de 85% des semences. On peut conclure qu’il est possible de mettre au point une séparation linéaire tenant compte de la variabilité des différentes prises de vues, et tenant compte de la variabilité de la semence sous ses différents aspects. Les algorithmes montrent que ce compromis est capable de discriminer des semences dont l’orientation n’est pas forcément optimale pour le tri. Ce sont donc des conditions de classification particulièrement difficiles et pourrait-on dire extrêmes. Nous retrouvons dans la matrice de confusion les différentes erreurs de classification déjà connues dans le système mono-caméra. Nous retrouvons les erreurs de classification liées au couple lentilles et liseron des haies. Nous retrouvons l’impossibilité de discriminer les semences cassées des semences non cassées, et nous retrouvons de nouveau le couple sclérotés-tournesol. Ce modèle commun nous fait donc revenir aux problématiques d’un système mono-caméra. Il apporte cependant la possibilité d’introduire une nouvelle stratégie de classification utilisant le vote comme élément supplémentaire pour la discrimination.

	Af	Am	Bv	Cs	Hv	Lc	Pi	Td	Gl	Ma	Sc	Ta	To
Af	64	0	0	0	0	1	0	1	1	0	0	0	0
Am	1	77	0	0	1	0	1	1	0	0	0	0	0
Bv	4	0	99	0	11	0	0	2	1	0	1	0	2
Cs	1	0	1	115	0	29	0	0	0	0	5	0	0
Hv	0	3	0	0	86	0	1	0	0	1	0	0	0
Lc	1	0	1	19	0	72	0	4	0	0	1	0	0
Pi	0	0	0	0	0	0	150	0	0	3	0	0	0
Td	1	0	0	0	0	0	0	56	0	0	0	0	6
Gl	0	1	0	0	1	0	1	0	160	8	0	0	0
Ma	0	0	0	0	0	0	0	0	0	153	0	0	0
Sc	0	0	1	1	0	0	0	4	0	0	158	0	13
Ta	0	0	0	0	0	0	0	2	0	6	0	99	2
To	0	0	0	0	0	0	0	32	0	0	3	0	136

*Tableau 3.9 : Matrice de confusion sur RNP sur CONCATLIG*

### 2.2.3.2. Stratégie de vote

Nous avons étudié dans la section précédente le fonctionnement d'un algorithme de décision unique et mono-caméra. Cependant, il est possible du fait du système d'introduire une stratégie tenant compte des trois caméras. Il nous vient donc de façon naturelle d'introduire la notion de vote. Nous étudierons les répercussions d'un vote majoritaire et d'un vote minoritaire sur les performances de discrimination.

#### 2.2.3.2.1. Majoritaire

Algorithme de classification	Pourcentage de classification moyen	Ecart type
AFD	90,83	0,93
PLSDA	90,83	0,93
ADL	90,83	0,93
RNP	92,84	1,01

*Tableau 3.10 : Pourcentage de classification obtenue sur CONCATLIG+ MAJORITAIRE*

Les résultats nous montrent qu'une fois de plus, les algorithmes utilisant comme règle de décision la théorie Bayésienne (non linéaire) offrent de très bons résultats dans cette

organisation des données. Les résultats sont compris entre 90 et 92%. Cette fourchette de résultats est 4% supérieure à ce qu'on obtient avec un système sans introduction de la notion de vote. On voit ici tout l'intérêt d'un système multi-caméra, qui n'a pas seulement comme avantage de distinguer des semences comportant des faces abîmées, mais aussi d'améliorer globalement la capacité à discriminer.

L'avantage d'un vote majoritaire est de pouvoir créer une classe de rejet, correspondant aux observations pour lesquelles les caméras n'ont pas donné de groupe d'appartenance majoritaire.

	Af	Am	Bv	Cs	Hv	Lc	Pi	Td	Gl	Ma	Sc	Ta	To	rejeté
Af	24	0	0	0	0	0	0	0	0	0	0	0	0	0
Am	0	27	0	0	0	0	0	0	0	0	0	0	0	0
Bv	0	0	33	0	0	0	0	0	0	0	0	0	0	1
Cs	0	0	0	39	0	5	0	0	0	0	0	0	0	1
Hv	0	0	0	0	33	0	0	0	0	0	0	0	0	0
Lc	0	0	0	7	0	26	0	0	0	0	0	0	0	1
Pi	0	0	0	0	0	0	51	0	0	0	0	0	0	0
Td	0	0	0	0	0	1	0	20	0	0	0	0	9	4
Gl	0	0	0	0	0	0	0	0	54	0	0	0	0	0
Ma	0	0	0	0	0	0	0	0	1	51	0	1	0	4
Sc	0	0	0	0	0	0	0	0	0	0	55	0	0	1
Ta	0	0	0	0	0	0	0	0	0	0	0	33	0	0
To	0	0	0	0	0	0	0	0	0	0	1	0	52	0

**Tableau 3.11 : Matrice de confusion avec RNP sur CONCATLIG+ MAJORITAIRE**

La matrice de confusion nous montre que les indéterminations ont été réduites. Cependant les groupes de morphologie et de couleur semblables ne sont pas supprimés totalement par la stratégie du vote majoritaire. Cette matrice nous montre également que dans certains cas, deux caméras peuvent donner des réponses de type faux-positifs, dans des cas limites pour des semences comme les lentilles et liseron des haies parce que leur morphologie et leur couleur sont extrêmement proches. On remarque également le problème posé par la distinction des semences cassées et des semences non cassées n'est pas supprimé. On constate également qu'un bon nombre d'indéterminations ont été classées en tant que rejet, ce qui n'est pas négligeable en termes de résultats. Cela est particulièrement intéressant dans le cas du groupe

des sclérotés, qui a été classé en rejet, systématique dans le cas de ce lot. C'est ce qu'on recherchait. Même chose pour la folle avoine, qui n'est ni rejetée ni représentée à tort dans des groupes autres. Cet acquis permet de répondre aux contraintes de la certification des lots de tournesol.

Les graines cassées étant classées comme des semences pures sont principalement des semences faiblement touchées. Dans le cadre de la certification une composante qui n'entrait pas en jeu jusqu'à présent dans notre problématique peut être signalée : les semences dont plus de 50% de la surface est indemne sont considérées comme des semences « pures » au sens de la certification, c'est-à-dire non cassées. Ce qui est ici le cas pour les neuf semences de tournesol cassées classées comme semences de tournesol « pures ».

### 2.2.3.2.2. Unanime

Algorithme de classification	Pourcentage de classification moyen	Ecart type
AFD	100	0
	(67,98*)	(1,58)
PLSDA	100	0
	(67,98*)	(1,58)
ADL	100	0
	(67,98*)	(1,58)
RNP	100	0
	(73,37*)	(1,25)

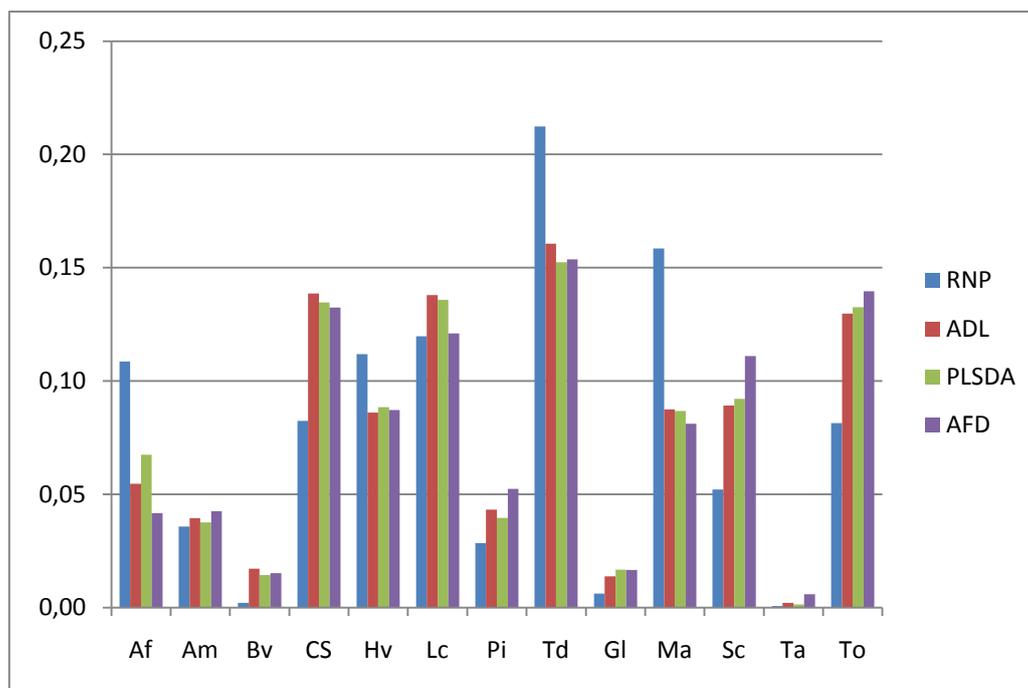
**Tableau 3.12 : Pourcentage de classification obtenue sur CONCATLIG+ UNANIME**

*\* proportion d'objets non rejetés*

Le vote unanime correspond au fait que les trois caméras donnent le même résultat. Par conséquent il est l'inverse du vote majoritaire, et est beaucoup plus sélectif. Il donne forcément de moins bons résultats, puisqu'il suffit d'une seule contradiction provenant d'une caméra pour aboutir au rejet d'une semence. Ces résultats sont donc moins bons que ceux obtenus par un système mono-caméra. Il introduit cependant un atout non négligeable, celui de pouvoir réaliser une classe de rejet. L'étude menée sur la matrice de confusion montre qu'il est possible d'obtenir une classification ne contenant aucun faux-positif. Autrement dit, toutes les semences qui ont été classées dans les groupes sont correctement classées à 100%. On constate qu'aucune semence n'apparaît dans un autre groupe que celui d'origine, hormis

un cas de tournesol cassé (Td) classé comme du tournesol pur (To). L'examen de la semence en question a montré que c'est sans doute un effet du positionnement de la semence lors de prise de vue qui n'a montré à aucune des caméras une trace de la cassure qui l'affecte. On peut en conclure que l'organisation des caméras ne permet pas de couvrir la totalité de la surface des semences et que l'organisation de l'automatique au plan mécanique nécessite une amélioration sur ce point.

Cependant le vote unanime permet d'offrir une classification pour la certification tout-à-fait convenable, ce qui permet à un analyste de pouvoir se concentrer sur la seule classe des semences rejetées. Les classes rejetées sont le plus souvent les semences qui posaient déjà problème comme le tournesol cassé, les lentilles, liseron des haies, sclérotés. En attendant, on observe avec satisfaction que les sclérotés et la folle avoine sont rejetés et ne viennent pas s'introduire dans les autres classes.



**Figure 3.5 : Fréquence de rejet par espèce en pourcent sur la stratégie CONCATLIG**

La Figure 3.5 présente la fréquence de rejet des différentes espèces analysées. Nous pouvons remarquer que les différents algorithmes utilisés ne sont pas égaux en termes de rejet. En effet, bien que le RNP présente une meilleure classification globale, il apparaît que sur les espèces du maïs (Ma), de la folle avoine (Af), du tournesol cassé (Td), et de l'orge (Hv), cet algorithme présente une fréquence de rejet plus importante que les autres. La forte proportion

de semences de tournesol cassé est principalement due au fait que ces semences ne présentent leurs défauts que sur une ou deux caméras ce qui suffit à les rejeter. Ce résultat était attendu et était une limite du précédent automate présenté dans le paragraphe 1.4.5. Le fort rejet de l'espèce maïs est principalement du à sa nature lisse et brillante qui suivant l'orientation de la semence peut être proche du soja ou du pois. Cette similarité était déjà visible lors de l'analyse descriptive dans la partie 3.2 du chapitre 2. Nous remarquons également que certaines espèces telles que le soja, la betterave et le blé tendre présentent un très faible taux de rejet. Cela s'explique par le fait que ces semences ont des formes et des couleurs très atypiques par rapport aux autres espèces acquises.

## 2.2.4. Modèle caméra indépendante

### 2.2.4.1.1. Vote majoritaire

Algorithme de classification	Pourcentage de classification moyen	Ecart type
AFD	84,33	1,33
PLSDA	87,20	1,26
ADL	95,99	0,77
RNP	97,23	0,64

*Tableau 3.13 : Pourcentage de classification obtenue sur SEPAIRE+MAJORITAIRE*

On remarque sur le Tableau 3.13 que les méthodes basées sur l'utilisation de sous-espaces de discrimination ne donnent pas satisfaction en termes de classification puisqu'ils sont environ 10% inférieurs aux méthodes travaillant sur les données brutes. On a donc une scission en termes de pourcentages de classification. Les méthodes AFD et PLSDA comprises entre 84 et 87% et les méthodes RNP et ADL comprises entre 96 et 97,2%. Cela nous montre également que sur les données brutes, la méthode de discrimination non linéaire apporte une meilleure classification que la méthode linéaire.

Ces résultats sont supérieurs à la méthode commune fondée sur la concaténation des observations qui visaient à déterminer un modèle commun aux caméras. Cela montre que les différentes caméras offrent une meilleure discrimination lorsqu'elles fonctionnent de façon indépendante. Ce nouveau modèle, cette stratégie fondée sur l'indépendance des caméras, permet de dépasser l'information de compromis qui certes montrait qu'il pouvait y avoir une variabilité induite par les caméras, mais qui ne parvenait pas à exploiter la variabilité de la

semence selon l'angle de la prise de vue. Cela ne veut pas dire pour autant qu'il y a une différence dans la qualité de la prise de vue. C'est plutôt le mécanisme introducteur qui génère un biais dans la disposition des semences, et c'est par là que la variabilité du compromis apparaît.

La matrice de confusion montre une meilleure séparation que la méthode du vote majoritaire sur concaténation des observations. Cependant les gros groupes d'indétermination, lentilles (Lc) et liseron des haies (Cs), sont à nouveau ceux qui posent problème. Ils ont été réduits, mais non supprimés. Cette indétermination se retrouve finalement quelle que soit la méthode employée. On remarque également que l'indétermination demeure entre les sclérotés (Sc) et le tournesol (To). La classe de rejet est dans cette étude très réduite (un seul cas en lentilles, un seul en maïs).

	Af	Am	Bv	Cs	Hv	Lc	Pi	Td	Gl	Ma	Sc	Ta	To	Rejeté
Af	24	0	0	0	0	0	0	0	0	0	0	0	0	0
Am	0	27	0	0	0	0	0	0	0	0	0	0	0	0
Bv	0	0	34	0	0	0	0	0	0	0	0	0	0	0
Cs	0	0	0	43	0	2	0	0	0	0	0	0	0	0
Hv	0	0	0	0	33	0	0	0	0	0	0	0	0	0
Lc	0	0	0	6	0	27	0	0	0	0	0	0	0	1
Pi	0	0	0	0	0	0	51	0	0	0	0	0	0	0
Td	0	0	0	0	0	0	0	34	0	0	0	0	0	0
Gl	0	0	0	0	0	0	0	0	54	0	0	0	0	0
Ma	0	0	0	0	0	0	0	0	0	56	0	0	0	1
Sc	0	0	0	0	0	0	0	0	0	0	55	0	1	0
Ta	0	0	0	0	0	0	0	0	0	0	0	33	0	0
To	0	0	0	0	0	0	0	0	0	0	1	0	52	0

*Tableau 3.14 : Matrice de confusion sur RNP sur CONCATLIG+ MAJORITAIRE*

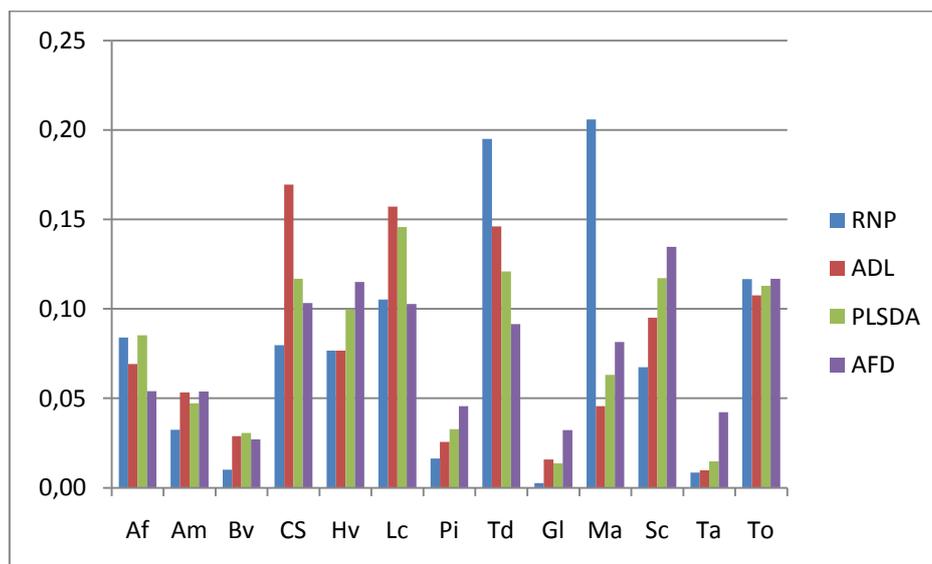
### 2.2.4.1.2. Vote unanime

Algorithme de classification	Pourcentage de classification moyen	Ecart type
AFD	100	0
	(50,77 <sup>*</sup> )	(1,50)
PLSDA	100	0
	(58,16 <sup>*</sup> )	(1,45)
ADL	100	0
	(78,38 <sup>*</sup> )	(1,57)
RNP	100	0
	(81,58 <sup>*</sup> )	(1,54)

**Tableau 3.15 : Pourcentage de classification obtenue sur SEPARE+UNANIME**

*\* proportion d'objets non rejetés*

Comme toujours le vote unanime donne des résultats moins bons globalement que le vote majoritaire, avec des taux de 50 à 58% pour les méthodes AFD et PLSDA, et seulement de 78 à 82% pour les méthodes linéaires ADL et non linéaires RNP. La matrice de confusion montre que cette méthode permet d'obtenir 100% sur la classification des semences, dès lors que se trouve écartées toutes les semences qui n'ont pas été acceptées par le vote unanime, soit 19% de cas si on le rapporte à l'ensemble des espèces classées.



**Figure 3.6 : Fréquence de rejet par espèce en pourcent sur la stratégie SEPARE**

La Figure 3.6 présente des fréquences de rejet similaire au paragraphe 2.2.3.2.2. On remarque que la proportion de rejet est supérieure sur les tournesols cassés, et le maïs. Cette figure présente à nouveau une grande disparité dans la fréquence de rejet selon les différents groupes de classification et selon les « classifieurs ». Cette disparité est cependant plus prononcée que pour la méthode *CONCATLIG+UNANIME* Figure 3.5.

Les algorithmes de classification montrent que les caméras sont donc en accord pour AFD et PLSDA à plus de 50%, et ADL et RNP à plus de 78%. Ces résultats sont bons, et l'intérêt du vote unanime est confirmé.

### 3. Conclusion

Méthodes RNP	Pourcentage de classification	Ecart-type	Méthode ADL	Pourcentage de classification	Ecart-type
CAMERA C	93,38	1,17	CAMERA C	91,14	1,31
CONCATCOL	97,53	0,83	CONCATCOL	96,14	0,59
CONCATLIG	88,39	0,72	CONCATLIG	85,86	0,80
CONCATLIG+ MAJORITAIRE	92,84	1,01	CONCATLIG+ MAJORITAIRE	90,83	0,93
CONCATLIG+ UNANIME	100 (73,37*)	(1)	CONCATLIG+ UNANIME	100 (67,98*)	(1,58)
SEPARE+ MAJORITAIRE	97,23	0,64	SEPARE+ MAJORITAIRE	95,99	0,77
SEPARE+ UNANIME	100 (81,58*)	(1,54)	SEPARE+ UNANIME	100 (78,38*)	(1,57)

*Tableau 3.16 : Pourcentage de classification obtenu avec les classifieurs sur données brutes.*

*\* proportion d'objets non rejetés*

*En ce qui concerne la question d'un système à trois caméras et celle de la discrimination des semences, nous constatons que l'apport est réel. Les essais avec le système mono-caméras n'ont pas permis de dépasser le score de 93,3% de bonnes classifications. En revanche, le système à trois caméras a permis d'atteindre des scores de l'ordre de 97%, notamment sur le CamVM (méthode RNP), Tableau 3.16. Mais surtout il a permis d'introduire la notion de classe de rejet lorsqu'il y a désaccord entre le verdict d'une caméra par rapport aux autres. Cette méthode est évidemment réservée aux systèmes multi-caméras, et fait appel à la notion de vote entre les caméras, vote majoritaire et vote unanime.*

*Cette conception correspond tout-à-fait à ce que réclame la certification, dont les contraintes sont notamment, pour certaines espèces, de parvenir à un taux d'élucidation de 100%.*

*Le vote unanime parvient à ce résultat et donc satisfait pleinement aux contraintes que la certification impose à un automate d'analyse de caractéristiques physiques. On note bien sûr que plus d'un quart des semences n'est pas trié (27%).*

*Au point où nous en sommes, et compte tenu de ce résultat, les perspectives ouvertes sont les suivantes :*

- *Il faut envisager d'augmenter le nombre des caméras, afin de couvrir la totalité de la surface des semences, voire d'obtenir des clichés qui permettent un recouvrement des zones photographiées ;*
- *Il faut mieux cerner le choix des algorithmes de décision, et examiner en particulier ce qu'ils réclament comme ressources en termes de mémoire et en termes de temps de calculs.*

*Parmi les possibilités, deux algorithmes se distinguent : les réseaux de neurones probabilistes et l'analyse discriminante linéaire.*

*En ce qui concerne les réseaux de neurones probabilistes, leur intérêt réside dans le fait que les noyaux utilisés pour l'apprentissage peuvent être traités de manière indépendante, ce qui convient à un traitement massivement parallèle. Le nombre de noyaux est déterminé par le nombre d'observations composant dans la base d'apprentissage. Dans notre cas, cela représente plusieurs milliers d'observations. Ce dernier point nécessite énormément de ressources de type mémoire, ce qui le rend extrêmement compliqué à mettre en œuvre dans un système embarqué. Le mode de fonctionnement exige en outre un temps d'apprentissage long.*

*En revanche, l'analyse discriminante linéaire, alors qu'elle offre des résultats à peine inférieurs, présente d'abord l'intérêt d'un temps d'apprentissage court. En effet, le calcul de la moyenne et celui d'une matrice de variance-covariance sur l'ensemble de la base d'apprentissage sont suffisants pour calibrer l'algorithme, ce qui occupe le système pendant un laps de temps inférieur à la seconde.*

*Il présente ensuite un autre avantage qui est celui de travailler sur des matrices qui représentent l'ensemble des données, alors que la méthode des neurones probabilistes travaille sur des observations brutes. C'est une différence considérable, car le fait de travailler sur des matrices est infiniment plus commode et ne mobilise de ce fait plus que des calculs mathématiques élémentaires, addition, soustraction et multiplication. Cette caractéristique convient tout-à-fait à l'utilisation d'un système basé sur des FPGA.*

# CONCLUSION ET PERSPECTIVES

L'objectif principal de la présente étude était de concevoir et de réaliser un automate de vision artificielle permettant de discriminer des semences et d'autres objets biologiques à une cadence élevée dans l'optique de la certification de lots commerciaux.

Notre premier travail a été de réaliser le dispositif permettant d'acquérir les images numériques de ces objets au cours de leur chute libre. Ce système utilise un flash à effet stroboscopique afin que le défilement très rapide de l'objet devant le capteur ne nuise pas à la qualité du cliché. Il est muni de trois caméras permettant de caractériser la quasi-totalité de la surface apparente des objets. Le dispositif électronique permet d'atteindre une grande vitesse d'acquisition des images numériques allant jusqu'à 50 images par seconde. Cependant le mécanisme d'introduction actuel n'autorise pas de telles cadences et ne permet pas dépasser de un débit de 4 objets par seconde, de plus, il ne convient que pour des objets d'une taille comprise entre 1 et 2 mm. L'automate a une bonne précision dans la mesure de la taille des objets. Ainsi, sur des billes dont le diamètre est de quelques millimètres, l'erreur d'estimation du diamètre est d'environ 140  $\mu\text{m}$ . Nous avons utilisé l'automate pour créer une collection d'environ 1600 images de semences et objets biologiques qui nous a servi de jeux d'essai dans la suite de l'étude. Les objets étudiés sont représentatifs des lots commerciaux de tournesol. Les semences sont ensuite caractérisées par des variables quantitatives extraites de leurs images. Ces caractéristiques correspondent à des paramètres de taille, de forme (y compris les descripteurs de Fourier et les 7 moments invariants), de couleur et de texture. Nous avons retenu trois méthodes statistiques d'analyse de texture : histogrammes des différences des niveaux de gris, matrices de co-occurrences et longueurs de plages. Les paramètres relevant de l'analyse de la couleur et de la texture sont fortement dépendants de l'espace colorimétrique. Nous avons choisi d'étudier trois espaces colorimétriques couramment utilisés dans le domaine de la vision artificielle : RGB, YCbCr et HSV. Chacun de ces espaces est tri-dimensionnel. Après transformation, les images sont constituées de 9 composantes (R,G,B,Y,Cb,Cr,H,S,V). Une semence est finalement décrite par 272 paramètres pour chacune des caméras. Les données ainsi extraites sont tout d'abord étudiées avec une approche de statistique descriptive. Nous avons étudié séparément les différents types de

variables que représentent la morphologie, la couleur et la texture perçues par les trois caméras. Les descripteurs de Fourier et les moments invariants ne permettent pas de distinguer les différents groupes de classification des objets. Au contraire, les variables associées à la texture et à la couleur ont un plus grand pouvoir séparateur des groupes. L'utilisation de différents espaces de couleurs conduit à une nette amélioration de la distinction. Après avoir analysé les corrélations entre les variables, nous avons cherché à caractériser la ressemblance entre groupes de variables. Dans ce but, le tableau initial de données a été découpé en 117 tableaux liés par les observations. Chacun de ces tableaux représente une nature particulière de caractéristiques. Un tel découpage nous a permis de mettre en œuvre une méthode adaptée à cette structure de tableaux multiblocs, la méthode STATIS. Cette méthode permet d'analyser directement les ressemblances entre les tableaux, nous avons mis en évidence la forte ressemblance qui s'établit entre certains paramètres de couleurs. Cette étude a été menée sur chacune des caméras, il apparaît que les relations inter-tableaux sont approximativement les mêmes quelle que soit la caméra. Cette analyse a mis en évidence des ressemblances importantes entre les caractéristiques de longueurs de plage et les paramètres de calibre. Les matrices de cooccurrences et les histogrammes de différences de niveaux de gris présentent des similarités assez fortes.

L'étude de la classification et la décision constituent l'étape suivante du travail. Nous avons testé plusieurs méthodes de classification, en prenant en compte l'utilisation de trois caméras. Quatre méthodes de discrimination, trois de classification linéaire et une de classification non-linéaire, ont été comparées. La présence de trois caméras donnant trois résultats d'affectation indépendant, nous a conduit à définir des stratégies de décision fondée notamment sur une méthodologie de vote. Sur l'ensemble des essais, les deux méthodes retenues, l'analyse discriminante linéaire et celle des réseaux de neurones probabilistes, apparaissent comme très performantes. En termes de ressources informatiques, l'analyse discriminante linéaire nécessite la mémorisation d'une matrice de variance covariance inversée et du barycentre multidimensionnel des différents groupes de classification. Dans le cas de la méthode de réseau de neurones probabilistes, chaque observation de l'étalonnage participe à l'identification d'une observation inconnue. La charge de calcul et la mémoire nécessaires à l'application des réseaux de neurones probabilistes dépendent par construction de la taille de la collection d'apprentissage.

Parmi les stratégies de décision, les méthodes fondées sur le vote majoritaire et le vote unanime sont les plus performantes. Le vote majoritaire conduit à des taux de classifications correctes de la totalité des observations, supérieurs à 95%. La méthode de vote unanime permet d'obtenir une classification sans erreur de toutes les graines non rejetées. En revanche, la classe de rejet a un effectif important pouvant atteindre 30% des objets étudiés. Ces résultats nous conduisent à privilégier le vote unanime en ce qui concerne la certification des lots de semences qui doit se faire pratiquement sans erreur. En suivant cette approche, il serait nécessaire de confier à un spécialiste l'analyse visuelle des objets rejetés.

Une perspective nouvelle consisterait à implémenter les algorithmes de caractérisation des semences dans un circuit logique programmable de type « FPGA ». Il n'est pas possible dans un tel circuit d'implémenter des algorithmes complexes nécessitant une grande puissance de calcul, tels que ceux qui sont mis en œuvre pour les exponentielles et les logarithmes. Pour cette raison, nous privilégierons, dans notre choix, les caractéristiques des semences et les algorithmes de décision qui ne demandent pas de tels calculs. Ainsi, par exemple, nous tenterons de supprimer l'entropie de la liste des caractéristiques. Ce paramètre nécessite en effet le calcul d'un logarithme. Les réseaux de neurones probabilistes sont apparus comme très performants dans notre étude. Cependant, la complexité de leur algorithme conduit à leur préférer l'analyse discriminante linéaire.

Nous pouvons maintenant examiner de manière critique les variables à choisir afin d'établir un modèle de discrimination en tenant compte de leur coût algorithmique. Cette réflexion nous conduit à sélectionner les caractéristiques de *calibre*, de *couleur* et de *texture*. La méthode fondée sur l'histogramme de différence de niveau de gris apparaît comme particulièrement appropriée, à la fois en terme de capacité discriminante et de simplicité algorithmique pour définir la texture d'une semence. Parmi les espaces de couleurs, pour des raisons similaires, nous sélectionnons l'espace YCbCr. En tenant compte de ces contraintes, nous avons effectué une simulation en sélectionnant *a priori* les variables associées au calibre, à la couleur et à la différence des niveaux de gris dans l'espace YCbCr. Le nombre de variables est alors réduit à 54 pour chacune des caméras, contre 272 initialement. Sur cette collection ainsi réduite, nous avons appliqué la démarche décrite au chapitre 3 (Tableau 0.1).

<b>Analyse discriminante linéaire</b>	<b>Moyenne (%)</b>	<b>Ecart type (%)</b>
<b>Caméra</b>	86.85	0.91
<b>CONCATCOL</b>	89.29	1.18
<b>CONCATLIG</b>	78.65	1.06
<b>CONCATLIG+UNANIME</b>	100 (53.91 <sup>*</sup> )	(1.59)
<b>CONCATLIG+MAJORITAIRE</b>	84.75	1.24
<b>SEPARE+VM</b>	90.11	1.30
<b>SEPARE&amp;VU</b>	100 (61.82 <sup>*</sup> )	(1.19)

**Tableau 0.1 : Pourcentage de classification suivant les différentes méthodes utilisées**

Variables sélectionnées a priori sur un critère de faible coût algorithmique.

*\* proportion d'objets non rejetés*

Le système permet ici d'identifier sans erreur 61% du lot dans le cas du vote unanime. Ainsi, 39% du lot reste à trier par un analyste expérimenté. L'évolution de l'électronique et des circuits FPGA fait qu'il sera possible d'extraire des paramètres de plus en plus nombreux dans les prochaines années.

Le système développé peut recevoir d'autres applications que celles initialement envisagées. Nous disposons en effet d'un dispositif d'acquisition à haut débit permettant de mener des études portant, par exemple, sur le phénotypage à haut débit de semences. L'automate est formé de modules mécaniques et électroniques indépendants. Il peut être adapté à l'acquisition de semences de dimension inférieure au millimètre. L'ajout de caméras spécifiques est également possible ce qui permettrait de visualiser plus complètement la surface des semences et sans doute de créer des modèles en trois dimensions.

# BIBLIOGRAPHIE

International Seed Federation. 2006. <http://www.worldseed.org>.

Actel. *Actel : Low Power and Mixed Signal FPGA solutions*. <http://www.actel.com/>.

Alleysson, David. *30 ans de démosaïçage*. Vol. 21. 2004.

Altera. *FPGA CPLD and ASIC from Altera*. <http://www.altera.com/>.

Asselin de Beauville, J.P., and F.Z. Kettaf. *Bases théorique pour l'apprentissage et la décision en reconnaissance des formes*. Cépadues, 2005.

Battle, J. ., J. Marti, P. Ridao, and J. Amat. "A New FPGA/DSP-Based Parallel Architecture for Real-Time Image Processing." *Real-Time Imaging (Real-Time Imaging)* 8 (2002): 345–356.

Bayer. Ed. US Patents. Patent 3971065. 1976.

Bouridane, A., D. Crookes, P. Donachy, L. Alotaibi, and K. Benkrid. "A high level FPGA-based abstract machine for image processin." *Journal of systems architecture* 45 (1999): 809-824.

Cheng, F., and Y Ying. "Machine vision inspection of rice seed based on Hough transform." *Journal of Zhejiang University of science* 5, no. 6 (2004): 663-667.

Cheng, F., Z-Y. Liu, and Y-B. Ying. " Machine Vision Analysis of Characteristics and Image Information Base Construction for Hybrid Rice Seed." *Rice Science* 12, no. 1 (2005): 13–18.

Chessel, D., and M. Hanafi. "Analyses de la co-inertie de K nuages de points." *Revue de statistique appliquée* 44, no. 2 (1996): 35-60.

Chevallier, S., D. Bertrand, A. Kohler, and P. Courcoux. "Application of PLS-DA in multivariate image analysis." *J. Chemometrics* 20 (2006): 221-229.

Chtioui, Y. "Reconnaissance automatique des semences par vision artificielle basée sur des approches statistiques et connexionnistes." Edited by Université de Nantes. 1997.

Chtioui, Y., and D., Barba, D. Bertrand. "Reduction of the size of the learning data in a probabilistic neural network by hierarchical clustering. Application to the discrimination of seeds by artificial vision." *Chemometrics and Intelligent Laboratory Systems* 35 (1996): 175-186.

Chtioui, Y., D. Bertrand, and D. Barba. "Feature selection by a generic algorithm. Application to seed discrimination by artificial vision." *Journal of the science of food and agriculture* 76, no. 1 (1998): 77-86.

Chtioui, Y., D. Bertrand, and Y. Dattée. "Identification of seeds by color imaging : comparison of discriminant analysis and artificial neural network." *Journal of the Science of Food and Agriculture* 71 (1996): 433-441.

- Chtioui, Y., D. Bertrand, D. Barba, and M.F. Devaux. "Comparison of multi-layer perceptron and probabilistic neural networks in artificial vision." *Journal of Chemometrics* 11, no. 2 (1997): 111-129.
- Chtioui, Y., D. Bertrand, D. Barba, and Y. Dattée. "Application of fuzzy C-Means clustering for seed discrimination by artificial vision." *Chemometrics and intelligent laboratory systems* 38, no. 1 (1997): 75-87.
- Dreyfus, G., et al. *Réseaux de neurones: méthodologie et applications*. Eyrolles, 2004.
- Egelberg, P., O. Mansson, and C. Petersen. "Assessing cereal grain quality with a fully automated instrument using artificial neural network processing of digitized color video images." Edited by SPIE. *Proceeding Of Optics in Agriculture, Forestry, and Biological Processing*, no. 2345 (1994): 146-158.
- Escofier, B., and J. Pages. *Mise en oeuvre de l'analyse factorielle multiple pour les tableaux numériques qualitatifs ou mixtes RR-429*. INRIA, 1985.
- Feng, X., T. Pearson, F. Dowell, and N. Zhang. "Detecting Vitreous Wheat Kernels Using Reflectance and Transmittance Image Analysis ." *Cereal Chemistry* 81, no. 5 (2004): 594–597.
- Fisher, Robert E., Biljana Tadic-Galeb, and Paul R. Yoder. *Optical system design*. SPIE Press, 2008.
- Foveon. *Foveon*. <http://www.foveon.com>.
- Galloway, M.M. "Texture analysis using gray level run lengths." *Computer graphics and image processing* 4 (1975): 172-179.
- Gaudin, J. *Colorimétrie appliquée à la vidéo*. Dunod, 2006.
- GNIS. 2008. <https://www.gnis.fr>.
- GNIS. "Directive 2002/57/CE." *Journal officiel* (Journal officiel), 2002: L.195/32.
- Granitto, P. M., P. F. Verdes, and H. A. Ceccatto. "Large-scale investigation of weed seed identification by machine vision." *Computers and Electronics in Agriculture* 47, no. 1 (2005): 15-24.
- Gunturk, Bahadir K., John Glotzbach, Yucel Altunbasak, Ronald W. Schafer, and Russell M. Mersereau. "Demosaicking: Color filter array interpolation in single-chip digital cameras." *IEEE Signal Processing Magazine* 22, no. 1 (2005): 44-54.
- Hamid, G. Quality Assessment Of Product In Bulk Flow. Ed. World Intellectual Property Organization. Patent WO/2004/024350. 2004.
- Haralick, R. "Statistical and structural approaches to textures." *Proceedings IEEE* 67, no. 6 (1979).
- Jain, A., and D. Zongker. "Feature selection : Evaluation, application and small sample performance." *IEEE Trans. on Pattern Analysis and Machine Intelligence* 19, no. 2 (1997): 153-158.

- Jayas, D.S., C.E. Murray, and N.R. Bulley. "An automated seed presentation device for use in machine vision identification of grain." *Canadian agricultural engineering* 41, no. 2 (1999): 113-118.
- Keefe, P.D. "Observation concerning shape variation in wheat grains." *Seed Science and Technologie* 18 (1990): 629-640.
- Keefe, P.D., and S.R. Draper. "The measurement of new characters for cultivar identification in wheat using machine vision." *Seed science and technology* 14 (1986): 715-724.
- Kiryati, N., and D. Maydan. "Calculating geometric properties from fourier representation." *Pattern Recognition* 22, no. 5 (1989): 469-475.
- Kuncheva, L. *Combining pattern classifiers : methods and algorithms*. Wiley, 2004.
- Kunt, M. *Reconnaissance des formes et analyse de scènes*. Presses polytechniques et universitaires romandes, 2000.
- Lai, F.S., I. Zayas, and Y. Pomeranz. "Application of pattern recognition techniques in the analysis of cereal grains." *Cereal chemistry* 63, no. 2 (1986): 168-172.
- Lavit, Christine. *Analyse conjointe de tableaux quantitatifs*. Elsevier-Masson, 1988.
- Liu, Z.Y, F. Cheng, Y.B. Ying, and X.Q. Rao. "Identification of rice seed varieties using neural network." *Journal of Zhejiang University Science* 11 (2005): 1095-1100.
- Lohier, F. *Méthodologies de programmation et évaluation des processeurs de traitement de signal parallèles pour le traitement d'images en temps réel*. Université Paris 6, 2000.
- Majumdar, S., and D.S. Jayas. "Classification of cereal of grains using machine vision : IV- Combined morphology, color and texture models." *Trans. of the ASAE* 43, no. 6 (2000d): 1689-1694.
- Majumdar, S., and D.S. Jayas. "Classification of cereal of grains using machine vision : I- Morphology models." *Trans. of the ASAE* 43, no. 6 (2000a): 1669-1675.
- Majumdar, S., and D.S. Jayas. "Classification of cereal of grains using machine vision : II- Color models." *Trans. of the ASAE* 43, no. 6 (2000b): 1677-1680.
- Majumdar, S., and D.S. Jayas. "Classification of cereal of grains using machine vision : III- Texture models." *Trans. of the ASAE* 43, no. 6 (2000c): 1681-1687.
- McDonald, M.B., A.F. Evans, and M.A. Bennet. "Using scanners to improve seed and seedling evaluations." *Science and Technologie*, 2001: 683-689.
- Merill. Patent WO/2002/027804. 2002.
- Muracciole, V., P. Plainchault, D. Bertrand, and M.-R. Mannino. "Development of an automated device for sorting seeds - application on sunflower seeds." *ICINCO*, 2007: 311-318.
- Nair, M. *Dockage identification in wheat using machine vision*. Thesis-Master of Science, The University of Manitoba, 1997.

Ni, B., M.R. Paulsen, and J.F. Reid. "Size grading of corn kernels with machine vision." *ASAE* 14, no. 5 (1998): 567-571.

Nixon, Mark, and Alberto Aguado. *Feature Extraction and Image Processing second edition*. Associated press, 2008.

Otsu, N. "A threshold selection method from gray-level histograms." *EEE Trans. Sys., Man., Cyber.* 9 (1979): 62–66.

Paliwal, J., N.S. Visen, D.S. Jayas, and White N.D.G. "Cereal grain and dockage identification using machine vision." *Biosystems engineering* 85, no. 1 (2003): 51-57.

Paliwal, J., N.S. Visen, D.S. Jayas, and White N.D.G. "Comparison of a neural network and non parametric classifier for grain kernel identification." *Biosystems engineering* 85, no. 4 (2003): 405-413.

Pearson, T. "Machine Vision system for automated detection of stained pistachio nuts." Edited by SPIE. *Proceedings Of Optics in Agriculture, Forestry, and Biological Processing* 2345, no. 95-103 (1994).

Petersen, P.E.H., and G.W. Krutz. "Automatic identification of weed seeds by colour machine vision." *Seed science and technology* 20, no. 2 (1992): 193-208.

Plainchault, P., S. Tourveille, D. Demilly, D. Bertrand, and A. Feutry. "Development of an imaging system for the high-speed identification of seeds." Edited by IEEE. *Proceeding of Sensors* 1 (2003): 499-501.

Poynton, C. *A technical introduction to digital video*. John Wiley & Sons, 2003.

QPCARD. *QPCARD*. <http://www.qpcard.se/>.

*QuickLogic Corporation*. <http://www.quicklogic.com/>.

Rasmus, Bro. "PARAFAC. Tutorial and applications." Edited by Elsevier. *Chemometrics and Intelligent Laboratory Systems* 38, no. 2 (1997): 149-171.

Sakai, N., S. Yonekawa, and A. Matsuzaki. "Two-dimensional image analysis of the shape of rice and its application to separating varieties." *Journal of Food Engineering* 27 (1996): 397-407.

Saporta, Gilbert. "Probabilités et statistique : analyse des données 2ème édition." *Technip* (Technip), 2006.

Stallings, W. *Computer organization and architecture: design for performance* . Pearson Education, 2006.

Symons, S.J., and R.G. Fulcher. "Determination of wheat kernel morphological variation by digital image analysis : I. Variation in eastern canadian milling quality wheats." *Journal of cereal science* 8 (1988): 211-218.

Tahir, M.A., A. Bouridiane, and F. Kurugollu. "An FPGA Based Coprocessor for GLCM and Haralick Texture Features and their Application in Prostate Cancer Classification." *Analog Integrated Circuits and Signal Processing* 43, no. 2 (2005): 205-215.

Tenenhaus, Michel. *La régression PLS: Théorie et pratique*. Technip , 1998.

Travis, A.J., and S.R. Draper. "A computer based system for the recognition of seed shape." *Seed Science and Technologie* 13 (1985): 813-820.

Tuffery, S. *Data mining et statistique décisionnelle*. Technip, 2007.

Visen, N. S., J. Paliwala, D. S. Jayas, and N. D. G. White. "Specialist Neural Networks for Cereal Grain Classification." *Biosystems Engineering* 82, no. 2 (2002): 151-159.

Wan, Y.-N. "Kernel handling performance of an automatic grain quality inspection." *Transaction ASAE* 45, no. 2 (2002): 369-378.

Wang, W., and J. Paliwal. "Separation and identification of touching kernels and dockage components in digital images." *Canadian biosystems engineering* 48 (2006): 7.1-7.7.

Wonnacott, Thomas H. *Statistique : Economie - Gestion - Sciences - Médecine (avec exercices d'application)*. Economica, 1998.

Xilinx. *FPGA and CPLD solutions from Xilinx*. <http://www.xilinx.com/>.

—. *Multi Port Memory Controller Reference Design*. [http://www.xilinx.com/esp/wired/optical/xlnx\\_net/mpmc.htm](http://www.xilinx.com/esp/wired/optical/xlnx_net/mpmc.htm).

Yang, C.-C., S.O. Prasher, and J.A. Landry. "Weed recognition in corn fields using back-propagation neural network models ." *Canadian Biosystems Engineering* 44 (2002): 7.15-7.22.

Zayas, I., Y. Pomeranz, and F.S. Lai. "Discrimination between Arthur and Arkan wheats by image analysis." *Cereal chemistry* 62, no. 6 (1985): 478-480.

Zayas, I., Y. Pomeranz, and F.S. Lai. "Discrimination of wheat and nonwheat components in grain samples by image analysis." *Cereal Chemistry* 66, no. 3 (1989): 233-237.

Zayas, I.Y., D.B. Bechtel, J.D. Wilson, and R.E. Dempster. "Distinguishing selected hard and soft red winter wheats by image analysis of starch granules." *Cereal chemistry* 71 (1994): 82-86.

# ANNEXES

# LISTE DES PARAMETRES EXTRAITS POUR CARACTERISER LA MORPHOLOGIE DES SEMENCES

Paramètres définis dans la thèse	Codage des paramètres dans le programme
<i>Longueur</i>	Length
<i>Largeur</i>	Width
<i>Surface</i>	Area
<i>Périmètre</i>	Perimeter
<i>Diamètre équivalent</i>	EquivDiameter
<i>Facteur d'amincissement</i>	Thinness_ratio
<i>Aspect rectangulaire</i>	Rect_aspect
<i>Rapport de surface</i>	Area_ratio
<i>Rayon maximum</i>	Maxim_radius
<i>Rayon minimum</i>	Minim_radius
<i>Rapport des rayons</i>	Radius_ratio
<i>Moyenne des rayons</i>	Mu_r
<i>Ecart type des rayons</i>	Sigma_r
<i>Rapport d'Haralick</i>	Haralick
<i>Axe majeur</i>	MajorAxisLength
<i>Axe mineur</i>	MinorAxisLength
<i>Excentricité</i>	Eccentricity
<i>Orientation</i>	Orientation
<i>Elongation</i>	AspectRatio
<i>Barycentre X</i>	CenterX
<i>Barycentre Y</i>	CenterY

# LISTE DES DESCRIPTEURS DE FOURIER

## EXTRAITS POUR CARACTERISER LES SEMENCES

Paramètres définis dans la thèse	Codage des paramètres dans le programme
<b>Fourier harmonique 1</b>	fft1
<b>Fourier harmonique 2</b>	fft2
<b>Fourier harmonique 3</b>	fft3
<b>Fourier harmonique 4</b>	fft4
<b>Fourier harmonique 5</b>	fft5
<b>Fourier harmonique 6</b>	fft6
<b>Fourier harmonique 7</b>	fft7
<b>Fourier harmonique 8</b>	fft8
<b>Fourier harmonique 9</b>	fft9
<b>Fourier harmonique 10</b>	fft10

# **LISTE DES MOMENTS INVARIANTS EXTRAITS POUR CARACTERISER LES SEMENCES**

<b>Paramètres définis dans la thèse</b>	<b>Codage des paramètres dans le programme</b>
<b>Moment invariant 1</b>	moment1
<b>Moment invariant 2</b>	moment2
<b>Moment invariant 3</b>	moment3
<b>Moment invariant 4</b>	moment4
<b>Moment invariant 5</b>	moment5
<b>Moment invariant 6</b>	moment6
<b>Moment invariant 7</b>	moment7

# LISTE DES PARAMETRES EXTRAITS POUR CARACTERISER LA COULEUR DES SEMENCES

Paramètres définis dans la thèse	Codage des paramètres dans le programme
<i>Moyenne</i>	gray-mean
<i>Variance</i>	gray-variance
<i>Entropie</i>	gray-entropy
<i>Energie</i>	gray-energy1
<i>Dissymétrie</i>	gray-skewness
<i>Aplatissement</i>	gray-kurtosis

# LISTE DES PARAMETRES EXTRAITS POUR CARACTERISER LA TEXTURE DES SEMENCES

- **Histogramme des différences de niveau de gris**

Paramètres définis dans la thèse	Codage des paramètres dans le programme
<i>Moyenne</i>	hist-mean
<i>Variance</i>	hist-variance
<i>Entropie</i>	hist-entropy
<i>Energie</i>	hist-energy
<i>Contrast</i>	hist-contrast

- **Longueurs de plage**

Paramètres définis dans la thèse	Codage des paramètres dans le programme
<i>Accentuation des petites plages</i>	short-run-emphasis
<i>Accentuation des longues plages</i>	long-run-emphasis
<i>Distribution des niveaux de gris</i>	gray-level-distribution
<i>Distribution des longueurs de plages</i>	run-length-distribution
<i>Pourcentage des longueurs de plage</i>	run-proportion

- **Matrice de cooccurrence.**

Paramètres définis dans la thèse	Codage des paramètres dans le programme
<i>Probabilité maximale</i>	occur-max-prob
<i>Moyenne des occurrences par ligne</i>	occur-row-average
<i>Moyenne des occurrences par colonne</i>	occur-col-average
<i>Ecart type par ligne</i>	occur-row-std
<i>Ecart type par colonne</i>	occur-col-std
<i>Second moment angulaire</i>	occur-sd-ang-m
<i>Contrast</i>	occur-contrast
<i>Corrélation</i>	occur-corr
<i>Entropie</i>	occur-entropy
<i>Moment différentiel inverse</i>	occur-inv-diff-m

# CODAGE DES TABLEAUX MULTIPLES

numéro caméra	type de tableau	composante colorimétrique	catégorie
A à C	Cali		Calibre
A à C	Momt		Moment invariant
A à C	FFtr		Descripteur de Fourier
A à C	Lhd	1 à 9	Histogramme de différence de niveau de gris
A à C	Lcm	1 à 9	Matrice de cooccurrence
A à C	Lrm	1 à 9	Longueur de plages
A à C	Col	1 à 9	Caractéristiques de couleur



# Abstract

The goal of this PhD Thesis is to study and design an automated artificial vision system to discriminate the nature and the variety of seeds from their numerical image.

A first study has been done on a mono-camera acquisition system to determine the ability of such a system to certify seed lots. This study has shown that a mono-camera is not able to discriminate damaged or multicolor seeds in one pass.

A second study has been done on the study and the design of a new acquisition system, with three cameras, able to acquire three different seed faces images simultaneously. A prototype has been designed based on a new electronic and optical arrangement. A collection of seed images has been collected thanks to this system. On this collection, image processing and pattern classifier algorithms have been tested. The seeds are numerically characterised by their morphology, their color and their texture and stored in a dataset. These features are used as input of pattern classifiers. Some pattern classifiers have been tested (Linear Discriminant Analysis, Factorial Discriminant Analysis, PLS Discriminant Analysis, Probabilistic Neural Network) on a reduced dataset on which features were selected by their discriminative power with a forward LDA algorithm.

The three cameras used offer the possibility of multiple classifications, either by combining pattern classifiers and use majority or unanimity vote, or by concatenating features to design single classifiers.

The comparison test shows that in all conditions the PNN classifier is more accurate than the others. However, the LDA results are close to the PNN. For sake of simplicity, the LDA classifiers seem to be the best compromise for a real time automated system able to certify seed lots.

# Résumé

L'objectif de la présente thèse est d'étudier, de définir et de mettre en place un système de vision artificielle permettant de discriminer la nature et la variété de semences à partir de leurs images numériques.

Une première étude a porté sur l'étude d'un dispositif mono-caméra destiné au contrôle de la qualité de lots de semences dans l'optique de leur certification. Il est apparu qu'un système mono-caméra ne permettait pas d'identifier les semences dont les faces présentent une disparité de couleur. Ainsi, les semences endommagées ne peuvent pas être correctement détectées avec un tel dispositif.

Une deuxième étude a porté sur l'étude et la réalisation d'un nouveau système d'acquisition, muni de trois caméras, et capable de prendre plusieurs images de plusieurs faces d'un même objet. Un prototype a été construit, reposant sur une nouvelle architecture optique et électronique. A l'aide de ce prototype, une collection d'images de semences et de contaminants a été acquise. Sur cette collection, des algorithmes de traitement d'images et de discrimination ont été testés. Les semences composant cette collection ont été caractérisées par plusieurs centaines de variables quantitatives, portant sur leur morphologie, leur couleur et leur texture. Plusieurs méthodes de discrimination ont été étudiées : l'analyse discriminante linéaire (ADL), l'analyse factorielle discriminante, l'analyse discriminante PLS et une méthode de réseau de neurones probabilistes à ajustement adaptatif de poids. Dans tous les cas, les variables ont été sélectionnées préalablement par ADL avec introduction successive des variables les plus discriminantes. L'existence de trois images numériques pour chaque objet étudié offre des possibilités nouvelles en ce qui concerne la prise de décision. Plusieurs heuristiques ont été testées. Nous avons comparé les résultats obtenus en concaténant les tableaux de caractéristiques acquises à l'aide des trois caméras ou en mettant en jeu une stratégie de vote, majoritaire ou unanime.

Quelle que soit la stratégie de décision, le réseau de neurones probabilistes donne les résultats les meilleurs, légèrement supérieurs à ceux obtenus par l'ADL. Nous avons conclu que, en considérant la simplicité de l'analyse discriminante linéaire, cette méthode était la plus appropriée pour la réalisation d'un automate fonctionnant en temps réel et capable de répondre aux contraintes de la certification des lots de semences.

Mots clés : Traitement de l'image, Algorithmes de classification, Vision artificielle